

MUHAMMAD AL-XORAZMIY
NOMIDAGI TATU FARG'ONA FILIALI
FERGANA BRANCH OF TUIT
NAMED AFTER MUHAMMAD AL-KHORAZMI

“AL-FARG‘ONIIY AVLODLARI”

ELEKTRON ILMIY JURNALI | ELECTRONIC SCIENTIFIC JOURNAL

TA'LIMDAGI ILMIY, OMMABOP VA ILMIY TADQIQOT ISHLARI



1-SON 1(9)
2025-YIL

TATU, FARG'ONA
O'ZBEKISTON



O'ZBEKISTON RESPUBLIKASI RAQAMLI TEXNOLOGIYALAR VAZIRLIGI

MUHAMMAD AL-XORAZMIY NOMIDAGI
TOSHKENT AXBOROT TEXNOLOGIYALARI UNIVERSITETI
FARG'ONA FILIALI

Muassis: Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti Farg'ona filiali.

Chop etish tili: O'zbek, ingliz, rus. Jurnal texnika fanlariga ixtisoslashgan bo'lib, barcha shu sohadagi matematika, fizika, axborot texnologiyalari yo'nalishida maqolalar chop etib boradi.

Учредитель: Ферганский филиал Ташкентского университета информационных технологий имени Мухаммада ал-Хоразми.

Язык издания: узбекский, английский, русский. Журнал специализируется на технических науках и публикует статьи в области математики, физики и информационных технологий.

Founder: Fergana branch of the Tashkent University of Information Technologies named after Muhammad al-Khorazmi.

Language of publication: Uzbek, English, Russian. The magazine specializes in technical sciences and publishes articles in the field of mathematics, physics, and information technology.

2025 yil, Tom 1, №1
Vol.1, Iss.1, 2025 y

ELEKTRON ILMIY JURNALI

ELECTRONIC SCIENTIFIC JOURNAL

«Al-Farg'oniyl avlodlari» («The descendants of al-Fargani», «Potomki al-Fergani») O'zbekiston Respublikasi Prezidenti administratsiyasi huzuridagi Axborot va ommaviy kommunikatsiyalar agentligida 2022-yil 21 dekabrda 054493-son bilan ro'yxatdan o'tgan.

Jurnal OAK Rayosatining 2023-yil 30 sentabrdagi 343-sonli qarori bilan Texnika fanlari yo'nalishida milliy nashrlar ro'yxatiga kiritilgan.

Tahririyat manzili:
151100, Farg'ona sh.,
Aeroport ko'chasi 17-uy,
202A-xona
Tel: (+99899) 998-01-42
e-mail: info@al-fargoniy.uz

Qo'lyozmalar taqrizlanmaydi va qaytarilmaydi.

FARG'ONA - 2024 YIL

TAHRIR HAY'ATI

Maxkamov Baxtiyor Shuxratovich,

Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti rektori, iqtisodiyot fanlari doktori, professor

Muxtarov Farrux Muhammadovich,

Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti Farg'ona filiali direktori, texnika fanlari doktori

Arjannikov Andrey Vasilevich,

Rossiya Federatsiyasi Sibir davlat universiteti professori, fizika-matematika fanlari doktori

Satibayev Abdugani Djunosovich,

Qirg'iziston Respublikasi, Osh texnologiyalari universiteti, fizika-matematika fanlari doktori, professor

Rasulov Akbarali Maxamatovich,

Muhammad al-Xorazmiy nomidagi TATU Farg'ona filiali Axborot texnologiyalari kafedrasini professori, fizika-matematika fanlari doktori

Yakubov Maksadxon Sultaniyazovich,

Muhammad al-Xorazmiy nomidagi TATU «Axborot texnologiyalari» kafedrasini professori, t.f.d., professor, xalqaro axborotlashtirish fanlari Akademiyasi akademigi

G'ulomov Sherzod Rajaboyevich,

Muhammad al-Xorazmiy nomidagi TATU Kiberxavfsizlik fakulteti dekani, Ph.D., dotsent

G'aniyev Abduxalil Abdjalilovich,

Muhammad al-Xorazmiy nomidagi TATU Kiberxavfsizlik fakulteti, Axborot xavfsizligi kafedrasini t.f.n., dotsent

Zaynidinov Hakimjon Nasritdinovich,

Muhammad al-Xorazmiy nomidagi TATU Kompyuter injiniringi fakulteti, Sun'iy intellekt kafedrasini texnika fanlari doktori, professor

Abdullayev Abdujabbor,

Andijon mashinosozlik instituti, Iqtisod fanlari doktori, professor

Qo'ldashev Obbozjon Hakimovich,

O'zbekiston milliy universiteti huzuridagi Yarimo'tkazgichlar fizikasi va mikroelektronika ilmiy-tadqiqot instituti, texnika fanlari doktori, professor

Ergashev Sirojiddin Fayazovich,

Farg'ona politehnika instituti, elektronika va asbobsozlik kafedrasini professori, texnika fanlari doktori, professor

Polvonov Baxtiyor Zaylobiddinovich,

Muhammad al-Xorazmiy nomidagi TATU Farg'ona filiali Ilmiy ishlar va innovatsiyalar bo'yicha direktor o'rinbosari

Zulunov Ravshanbek Mamatovich,

Muhammad al-Xorazmiy nomidagi TATU Farg'ona filiali Dasturiy injiniring kafedrasini professori v.b., fizika-matematika fanlari nomzodi

Abdullayev Temurbek Marufovich,

Muhammad al-Xorazmiy nomidagi TATU Farg'ona filiali o'quv ishlari bo'yicha direktor o'rinbosari, texnika fanlar bo'yicha falsafa doktori

Zokirov Sanjar Ikromjon o'g'li,

Muhammad al-Xorazmiy nomidagi TATU Farg'ona filiali Ilmiy tadqiqotlar, innovatsiyalar va ilmiy-pedagogik kadrlar tayyorlash bo'limi boshlig'i, fizika-matematika fanlari bo'yicha falsafa doktori

Beglerbekov Rasul Jubatxanovich,

Qoraqalpog'iston qishloq xo'jaligi va agrotexnologiyalar instituti, Zootexnologiya fakulteti, «Axborot texnologiyalari, matematika, fizika va kimyo» kafedra mudiri, texnika fanlari bo'yicha falsafa doktori (PhD)

Asrayev Muhammadullo Abdullajon o'g'li,

Muhammad al-Xorazmiy nomidagi TATU Farg'ona filiali Dasturiy injiniring kafedrasini mudiri, texnika fanlar bo'yicha falsafa doktori

Jurnal quyidagi bazalarda indekslanadi:



Eslatma! Jurnal materiallari to'plamiga kiritilgan ilmiy maqolalardagi raqamlar, ma'lumotlar haqqoniyligiga va keltirilgan iqtiboslar to'g'riligiga mualliflar shaxsan javobgardirlar.

MUNDARIJA | ОГЛАВЛЕНИЕ | TABLE OF CONTENTS

Nishanov A, Mamajanov R, Xaydarov Sh, Mengturayev F, Yuldashev R, SUT BEZI SARATONI DIAGNOSTIKASINING MATEMATIK MODELLARI	6-14
Sharibayev N, Homidov Q, TO'QUV MASHINASI ISHLASH JARAYONIDA, IPDA HOSIL BO'LADIGAN TARANGLIK KUCHI NAZARIYASINI MATEMATIK MODELINI DINAMIK JIXATDAN ASOSLASH	15-19
Dadamuxamedov A, DINIY IDORALARARO TAQSIMLANGAN AXBOROT TIZIMLARIDA MA'LUMOT FRAGMENTLARINI DINAMIK REPLIKATSIYASI	20-28
Mamatov N, Nuritdinov N, NUTQNI MATNGA VA MATNNI NUTQQA O'TKAZISH DASTURIY TA'MINOT UCHUN FOYDALANISH DIAGRAMMALARINI VA ASOSIY SINFLARINI QURISH	29-34
Yakubov M, Bekmukhammedov B, SHAXSGA YO'NALTIRILGAN ONLAYN TA'LIM TIZIMIDA SUN'IY INTELEKTNI QO'LLASH	35-39
Asqaraliyev O, Korporativ muhitda NoSQL ma'lumotlar tuzilmasining tashkiliy ta'minotini baholash (soliq organlari boshqaruv tizimi misolida)	40-46
Kuchkarov V, YORUG'LIK DIODINING ELEKTRO-FIZIK XARAKTERISTIKALARINI TAJRIBA ORQALI ANIQLASH	47-52
Rasulmukhamedov M, Gafforov N, Urinboev J, Identifying a person using dynamic biometric authentication methods	53-59
Ollamberganov F, Kalbayev F, Yelmuratov Q, Qudaynazarov M, TO'LIQ FAZOGA ASOSLANGAN MULTISINFLI KLASSTERLASH ALGORITMI	60-66
Аллаберганова Г.М., Тогаев Б.С., Хайдаров У.Э., Кувватова М.А., Асадова Г.А., Музафаров А.М., ИЗУЧЕНИЕ ЗНАЧЕНИЙ СУММАРНОЙ – $\Sigma\alpha$, СУММАРНОЙ - $\Sigma\beta$ – АКТИВНОСТИ И НЕКОТОРЫХ ИЗОТОПОВ ПРИРОДНЫХ ВОД ОТОБРАННЫХ ИЗ УРАНОНОСНЫХ РЕГИОНОВ	67-70
Урунов И.А., Аллаберганова Г.М., Суюнов У.А., Курбанов Б.И., Музафаров А.М., АНАЛИЗ РАДИОНУКЛИДНОГО СОСТАВА И РАДИОАКТИВНОГО РАВНОВЕСИЯ МЕЖДУ НИМИ В ПРОДУКТАХ ХИМКОНЦЕНТРАТОВ УРАНА	71-75
Akbaraliyev B, Samandarov B, Xoliqnazarov R, Gulmirzaeva G, MAVJUD HUJJATLAR ASOSIDA HUJJAT ANDOZALARINI SHAKLLANTIRISH TIZIMINI LOYIHALASH	76-82
Зулунов Р, Абдурасулова Д, АВТОМАТИЗИРОВАННАЯ СИСТЕМА ПОДБОРА ДИЗАЙНОВ ТКАНЕЙ С УЧЕТОМ ВОЗМОЖНОСТЕЙ ОБОРУДОВАНИЯ ПРИ ПРОИЗВОДСТВЕ УЗОРЧАТЫХ ТКАНЕЙ	83-86
Nasiriddinov A., OLIY TA'LIM MUASASALARIDA O'QITUVCHILAR FAOLIYATINI BAHOLASHDA NORAVSHAN MANTIQDAN FOYDALANISH	87-91
G'ulomov Sh, Jumayev S, NOVEL METHODS FOR DETECTING ANOMALIES IN INFORMATION COMMUNICATION SYSTEMS	92-99
Nishanov A, Samandarov B, Joldasbaev D, Gulmirzaeva G, IoT QURILMALARDA MA'LUMOT UZATISH JARAYONLARINI ADAPTIV BOSHQARISH ALGORITMI	100-105
Ergashev O, Abdullayev J, INNOVATIVE NEURAL NETWORK STRATEGIES FOR DETECTING CHEATING IN VIRTUAL EXAMS	106-111
Abdukadirov B, Muxtorov A, VIDEO MA'LUMOTLARDAGI OBYEKT LARNI AVTOMATIK TANIB OLIISH ALGORITMLARI	112-117
Zulunov R, Sattarov M, KLINIKALARNI AVTOMATLASHTIRISH TIZIMLARI: UMUMIY KO'RINISH VA TURLARI	118-123
Sotvoldiyeva D, Karimov S, Mehmonaliyev Y, TIBBIY TASHXISNI ANIQLASH JARAYONIDA KLASSIFIKATSIYA ALGORTIMIDAN FOYDALANISHNING TAHLILI	124-127

MUNDARIJA | ОГЛАВЛЕНИЕ | TABLE OF CONTENTS

Yakubov M, Yuldashov R, ELEKTRON TIJORAT TIZIMLARINI STRATEGIK BOSHQARISHNING INSTRUMENTAL VOSITALARI	128-136
Abdukadirov B, Abdukadirova G, YUZ TASVIRI ORQALI SOXTA XUJUMLARNI ANIQLASHNING TASVIR TEKSTURASI TAHLILIGA ASOSLANGAN ALGORITMLARI	137-142
Matlatipov S, O‘zbek tili universal bog‘liqlik daraxti korpusining bi-affin neyron modelida tahlil qilish	143-148
Уринбоев А.А., Исмаилов Б.Р., Интеграция традиционных и компьютерных методов в оптимизацию процессов увлажнения пшеничного зерна	149-160
Turdibekov J, Keldiyorova M, THERMO-MECHANICAL ANALYSIS OF FUNCTIONALLY GRADED MATERIALS UNDER TORSION WITH TEMPERATURE EFFECTS	161-164
Zulunov R, Samatova Z, BULUTLI MUHITDA KIBERHUJUMLARNING OLDINI OLIISH USULLARINI YARATISH	165-168
Ахунджанов У.Ю., Лазарева М.В., Нурмахаматова Ф.Ф., Сравнительный анализ процесса цифровизации библиотек: международный опыт	169-173
Egamov D, Atajonov M, ENERGIYA ISROFLARI VA FOYDALI ISH KOEFFISENTI ORQALI TRANSFORMATORLARNING ISH SAMARADORLIGINI BAHOLASH	174-178
Nurullaev M, An algorithm for generating cryptographic keys for small IoT devices	179-183
Xolmurotov B, Xusanboyev M, MAHSULOTLARNI SAQLASH OMBORI FAOLIYATINI AVTOMATLASHTIRISHDA MOBIL ROBOTLARDAN FOYDALANISH	184-186
Nishanov A, Mengturayev F, Allayarov U, Xaydarov Sh, ENDOKRIN KASALLIKLAR PROFILAKTIKASI VA ERTA TASHXISLASHNING MATEMATIK MODELLARI	187-194
Zaynidinov H, Sharipov M, UZBEK TAGSET: CREATING A LIST OF MORPHOLOGICAL AND SYNTACTIC TAGS FOR BUILDING MACHINE LEARNING MODELS FOR THE UZBEK LANGUAGE	195-201
Soliyev B, Ismoilova M, Qishloq xo‘jaligi mahsulotlari elektron savdosida narxlarni prognoz qilish va bozor tahlili uchun AI asosida model yaratish	202-206
Xamidov Sh., NOMAQBUL ELEKTRON POCHTA XABARLARINI ANIQLASHNING ANSAMBL USULI	207-211

SUT BEZI SARATONI DIAGNOSTIKASINING MATEMATIK MODELLARI

Nishanov Akhram Khasanovich,

Muhammad al-Xorazmiy nomidagi Toshkent
axborot texnologiyalari universiteti tizimli va
amaliy dasturlash kafedrası professori
Email: nishanov_ahram@mail.ru

Mamajanov Raxmatilla Yakubjanovich,

Denov tadbirkorlik va pedagogika instituti
Axborot texnologiyalari kafedrası mudiri
Email: r.mamajanov@dtpi.uz,

Xaydarov Sherali Islom o‘g‘li

Denov tadbirkorlik va pedagogika instituti
Axborot texnologiyalari kafedrası tayanch
doktaranti
Email: sh.haydarov@dtpi.uz,

Mengturayev Farxod Ziyatovich,

Denov tadbirkorlik va pedagogika instituti
Axborot texnologiyalari kafedrası
o‘qituvchisi
Email: f.mengtoraev@dtpi.uz

Yuldashev Rustam Raxmonovich,

RIO va RIATM Surxondaryo filiali bosh
vrachi, Onkomammolog

Annotatsiya: Tadqiqotda sut bezi saratoni diagnostikasini matematik modellar yordamida erta aniqlash masalasi ko‘rib chiqildi. Tadqiqotda matematik modellar va mashinaviy o‘qitish usullarining sut bezi saratoni diagnostikasining matematik qo‘yilishi quyidagi bosqichlarni o‘z ichiga oladi, ma‘lumotlarni yig‘ish va oldindan ishlov berish, modelni shakllantirish, ma‘lumotlarni tahlil qilish va tasniflash, aniqlik va aniqlovchanlikni o‘lchash orqali samaradorliklarni baholash yoritilgan. Tadqiqotda quyidagi vazifalarni amalga oshirdik ma‘lumotlarni matematik ifodasi, statik diagnostika uchun formulalar, saraton rivojlanish bashorat qilish, logistik regressiya bu matematik model kasallikni aniqlash va bashorat qilish uchun ishlatiladigan parametrlarni ifodalaydi.

Kalit so‘zlar: mashina o‘qitish, kasallikni bashorat qilish, sun‘iy intellekt, diagnostika modellashtirish.

KIRISH. Sut bezi saratoni dunyo bo‘ylab ayollar orasida eng ko‘p uchraydigan onkologik kasalliklardan biri hisoblanadi. Uning erta bosqichlarda aniqlanishi bemorlarning kasallikga qarshi kurashish imkoniyatini sezilarli darajada oshiradi. Diagnostik jarayonlarning aniqligini oshirish maqsadida matematik usullar va algoritmlar keng qo‘llanilmoqda. Ushbu tadqiqotda sut bezi saratonini

aniqlash jarayonining matematik qo‘yilishi, mavjud algoritmlar va ularning diagnostikadagi ahamiyati yoritiladi[1,2].

Sut bezi saratoni diagnostikasi bo‘yicha matematik yondashuv - bu saratonni aniqlash jarayonida sun‘iy intellekt, ma‘lumotlar tahlili va statistik usullardan foydalanishni o‘z ichiga oladi.



Matematik modellashtirish va ma'lumotlarni qayta ishlash usullari sut bezi saratonining rivojlanish ehtimolini, diagnostika jarayonini va davolash rejalarini optimallashtirishda muhim vositalar hisoblanadi. Ushbu yondashuv kasallikni aniqlashda inson omilini kamaytiradi, aniqlikni oshiradi va individual xususiyatlarni hisobga olish imkonini beradi[3,4].

Ushbu tadqiqotda sut bezi saratoni diagnostikasining matematik qo'llanilishi bo'yicha asosiy bosqichlar jumladan, ma'lumotlarni yig'ish, tahlil qilish, statistik modellashtirish, va mashinaviy o'qitish usullaridan foydalanishning afzalliklari va natijalari yoritiladi. Diagnostika uchun ishlatiladigan matematik modellar kasallikni erta bosqichda aniqlashni maqsad qilgan va statistik ko'rsatkichlar quyidagi bosqichlarda aniqlashni ko'rib chiqdik sezuvchanlik, aniqlik va ROC egri ostidagi maydon (AUC) orqali samaradorligi baholanadi[5,6].

Ushbu yondashuvning mohiyati shundaki, tibbiy diagnostika jarayonini matematik modellar bilan boyitish nafaqat tashxis qo'yish sifatini oshiradi, balki davolash jarayonini ham yaxshilaydi.

ADABIYOTLAR TAHLILI VA METODOLOGIYA. Sut bezi saratoni diagnostikasi bo'yicha matematik modellarni ishlab chiqishda muhim bosqichlardir quyidagi bosqichlarni ko'rib chiqamiz. Diagnostika bo'yicha ilg'or tadqiqotlar, matematik modellashtirish usullari, amaliy tadqiqotlar bosqichlarni o'z ichiga oladi.

Sut bezi saratoni diagnostikasi va rivojlanishini o'rganishda ko'plab olimlar sun'iy intellekt, matematik modellar va statistik usullarni qo'llash orqali muhim yondashuvlarni ishlab chiqqan. Ushbu qarashlar texnologik va ilmiy yutuqlarni birlashtirgan holda diagnostika va prognozlash jarayonlarini takomillashtirishga xizmat qiladi.

1. Sun'iy intellektning diagnostikadagi roli - Sun'iy intellekt algoritmlari, ayniqsa, konvolyutsion neyron tarmoqlari (CNN), tibbiy tasvirlarni (mammografiya, MRI) avtomatik tahlil qilishda keng qo'llanilmoqda. Bu texnologiyalar saraton belgilari aniqligini oshiradi, erta diagnostikani amalga oshirish va tasvirni segmentatsiya qilishda samaradorlikni

ta'minlaydi. Geoffrey Hinton, Yann LeCun va Fei-Fei Li kabi olimlar sun'iy intellekt vositalari diagnostika jarayonini inqilobiy o'zgartirishini ko'rsatib berdilar.

2. Matematik modellar yordamida tumor rivojlanishini o'rganish - Tumor rivojlanish jarayonlarini matematik modellashtirish orqali uning xulq-atvorini tushunish va prognozlash imkoniyati kengaytirildi. Gompertz va Logistic modellari tumor hujayralarining o'sishini tavsiflashda asosiy vosita sifatida ishlatilmoqda. Alan Turingning reaksiya-diffuziya modellari biologik jarayonlarni tasvirlashda, Bert Vogelsteinning stoxastik modellari esa genetik mutatsiyalar va tumor rivojlanishi o'rtasidagi bog'liqlikni aniqlashda muhim hissa qo'shdi.

3. Statistik usullar diagnostikada asosiy yondashuv sifatida - Statistik modellar sut bezi saratoni diagnostikasi va xavf omillarini baholashda muhim rol o'ynaydi. Kaplan-Meier metodi hayot davomiyligini tahlil qilishda va Kox regressiyasi xavf omillarini aniqlashda keng qo'llaniladi. Ushbu usullar yordamida saratonning rivojlanish xavfi va bemorlarning davolanishga javobi aniqlanadi.

4. Klinik amaliyotda integratsiya - Matematik modellar va sun'iy intellekt algoritmlarini klinik amaliyotga tatbiq qilish orqali diagnostika tezligi va aniqligi sezilarli darajada oshdi. Regina Barzilay kabi olimlarning tadqiqotlari mammografiya tasvirlarini sun'iy intellekt yordamida avtomatik tahlil qilish imkoniyatini ochib berdi. Ushbu tizimlar klinik xatolarni kamaytirib, davolashni individuallashtirishga xizmat qilmoqda.

5. Ilmiy qarashlarning umumiy mazmuni - Olimlarning fikriga ko'ra, sut bezi saratonini o'rganishda sun'iy intellekt, matematik modellar va statistik usullarning integratsiyasi nafaqat diagnostika jarayonini takomillashtiradi, balki kasallikning rivojlanishini bashorat qilish va samarali davolash rejalarini ishlab chiqishda ham muhimdir. Ushbu yondashuvlar natijasida diagnostik jarayonlar tezroq, aniqroq va arzonroq bo'lishi ta'minlanmoqda.

SUT BEZI SARATONI DIAGNOSTIKASINING MATEMATIK MODEL

Sut bezi saratoni diagnostikasining matematik qo'yilishi quyidagi bosqichlarni o'z ichiga oladi.



1. Ma'lumotlarni yig'ish va oldindan ishlov berish. Sut bezi saratoni diagnostikasida ma'lumotlarni to'plash va ularga ishlov berish jarayoni asosiy bosqichlardan biri hisoblanadi. To'g'ri yig'ilgan va oldindan qayta ishlangan ma'lumotlar tahlil natijalarining aniqligi va ishonchliligini oshirishga yordam beradi. Ushbu jarayon turli tibbiy ko'rsatkichlar, tasvirlar, biomarkerlar va demografik ma'lumotlarni to'plash bilan boshlanadi. Yig'ilgan ma'lumotlar odatda tayyor bo'lmagan shaklda bo'ladi va diagnostika algoritmlarida ishlatishdan oldin normalizatsiya qilish, muhim xususiyatlarni ajratib olish kabi ishlov berish bosqichlaridan o'tishi kerak[7,8].

Ma'lumotlarni yig'ish va oldindan ishlov berish nafaqat aniqlikni oshirishga, balki diagnostika tizimining samaradorligini va modelni yangi ma'lumotlarga moslashuvchanligini ta'minlashga xizmat qiladi. Ushbu jarayon barcha keyingi bosqichlarning muvaffaqiyatli amalga oshirilishi uchun mustahkam poydevor hisoblanadi[9,10].

Diagnostik ma'lumotlar ultratovush, rentgen (mamografiya), va biopsiya kabi usullar orqali olinadi.

Diagnostik ma'lumotlar asosan zamonaviy tibbiy jihozlar yordamida to'planadi, rentgen, ultratovush, rentgen (mamografiya) va biopsiya kabi usullar orqali.

Sut bezi ichki tuzilishini yaratish uchun rentgen nurlari yordamida tasvir olish texnologiyasi ko'pincha saratonni erta bosqichda aniqlash uchun ishlatiladi[11,12].

Diagnostika ma'lumotlar statistik xavfsizlik to'g'ri taqsimlangan bo'lishi juda muhim, chunki ma'lumotlar ko'pincha noto'liq, shovqinli yoki noto'g'ri bo'lishi mumkin. Statistik ma'lumotlarni yuklash asosiy harakatlarni o'z ichiga oladi, bu tahlil natijalari aniqligiga, turli o'lchamdagi ma'lumotlarni bir xil miqyosga keltirish orqali algoritmlarning optimal ishlab chiqarishni ta'minlaydi. Tadqiqotda tasvir piksellarini $[0, 1]$ yoki $[0, 255]$ oralig'ida normalizatsiya qilish, ma'lumotlar taqsimoti, tendensiyalari va muhim omillar hisoblanadi. Bu jarayonda statistik usullar, grafik vizualizatsiyalar va

asosiy komponentlarni qilish (PCA) kabi texnikadan foydalaniladi[13,14].

2. Modelni shakllantirish. Matematik modelni shakllantirish murakkab tizimlarni tahlil qilish va bashorat qilish uchun zarur bo'lgan muhim jarayondir. Ushbu tadqiqotda matematik modellashtirishning asosiy bosqichlari bayon etilgan bo'lib, ular sut bezi saratoni kabi biologik jarayonlarni modellashtirish uchun ham qo'llaniladi[15,16].

Matematik modellashtirish jarayoni muammoni aniq belgilashdan boshlanadi. Bu bosqichda muammoning mazmuni va maqsadi aniqlanadi. Masalan, sut bezi saratoni modellashtirishda muammo sifatida o'simtaning o'sishi, metastazlanish jarayoni yoki davolash samaradorligini baholash belgilanishi mumkin[17,18].

Modelni ishlab chiqish uchun zarur bo'lgan ma'lumotlar yig'iladi quyidagi imkoniyatlarni amalga oshirishga xizmat qiladi. Bunda biologik jarayonlar, eksperimental kuzatuvlar yoki klinik ma'lumotlardan foydalaniladi. Sut bezi saratoni holatida, saratonni rivojlantiruvchi genetik, hujayraviy yoki kimyoviy omillarni aniqlash muhimdir.

Tuzilgan matematik model dasturlash tillari yordamida simulyatsiya qilinadi. Bunda MATLAB, Python yoki R kabi dasturiy vositalar qo'llaniladi. Model turli parametrlar ostida sinovdan o'tkaziladi.

Model asosida olingan natijalar biologik yoki klinik talqin qilinadi. Masalan, sut bezi saratoni davolash strategiyalari samaradorligini baholash mumkin.

Modellashtirish jarayonining yakuniy bosqichida davolash bo'yicha optimal strategiyalar aniqlanadi. Bu bosqichda kimyoterapiya dozalari va vaqt oralig'i kabi parametrlar optimallashtiriladi.

Tadqiqot natijalari ilmiy maqolalar yoki hisobotlar ko'rinishida nashr qilinadi. Klinika yoki sog'liqni saqlash tizimlarida model natijalaridan amaliyotda foydalanish uchun tavsiyalar ishlab chiqiladi[19,20].

Ushbu bosqichlar matematik modellashtirish jarayonining asosiy qadamlarini ifodalaydi. Ular nafaqat biologik jarayonlarni, balki boshqa murakkab tizimlarni ham tahlil qilish uchun ishlatiladi.



3. Ma'lumotlarni tahlil qilish va tasniflash. Ma'lumotlarni tahlil qilish va tasniflash bugungi kunda axborot texnologiyalari, tibbiyot, iqtisodiyot, sanoat va boshqa sohalarda muhim ahamiyat kasb etmoqda. Raqamli ma'lumotlar hajmining tez sur'atlar bilan oshib borishi ularni tahlil qilish va tegishli tasniflash usullarini qo'llashga bo'lgan ehtiyojni orttirmoqda. Ushbu tadqiqotda zamonaviy tahlil va tasniflash usullari, ularning afzalliklari va amaliy qo'llanilishiga bag'ishlangan tadqiqot o'tkaziladi[21,22].

Ma'lumotlarni tahlil qilish va tasniflashning zamonaviy usullarini o'rganish, ularni taqqoslash va samaradorligini baholash orqali amaliy tavsiyalar ishlab chiqishdan iborat bo'lib quyidagi vazifalarni aniqlab oldik.

1. Ma'lumotlarni tahlil qilish usullarini tasniflash.
2. Tasniflash algoritmlarini o'rganish va ularning samaradorligini baholash.
3. Zamonaviy dasturiy vositalar yordamida amaliy tadqiqotlar o'tkazish.

Ma'lumotlarni tahlil qilish jarayoni ulardan ma'no va xulosalar chiqarish uchun ishlatiladigan metodlarni o'z ichiga oladi. Statistik, matematik va sun'iy intellekt usullari ma'lumotlarni samarali tahlil qilish imkonini beradi.

Tasniflash algoritmlari ob'ektlarni yoki hodisalarni oldindan belgilangan sinflarga ajratish uchun ishlatiladi. Bu usul tibbiyot, moliya, marketing va boshqa ko'plab sohalarda keng qo'llaniladi.

Matematik usullardan foydalangan holda kasallik tasnifi amalga oshiriladi. Bu bosqichda neyron tarmoqlar va chuqur o'qitish algoritmlari ham ishlatiladi.

Neyron tarmoqlar orqali bemorning suratlaridan saraton o'chog'ini aniqlash imkoniyati sezilarli darajada oshadi.

4. Aniqlik va aniqlovchanlikni o'lchash. Sut bezi saratoni diagnostikasi modellarini amalga oshirishda aniqlik (accuracy) va aniqlovchanlik (precision) muhim ko'rsatkichlardir. Ushbu diagnostik modelni sifatli tahlil qilishda mezonlar katta ahamiyatga ega.

Aniqlik - Aniqlik diagnostik modelning umumiy to'g'ri ishlashi ifodalaydi. Buni aniqlash formula bilan ifodalash mumkin.

$$\text{aniqlilik} = \frac{\text{to'g'ri ripozitivlar} + \text{to'g'ri rinegativlar}}{\text{umumiysin ovlarsoni}} \quad (1)$$

Ushbu (1) – ifodada N - model sog'lom bemorlarni to'g'ri aniqlagan holatlarini, FP - model sog'lom bemorlarni, FN - model saratonni aniqlay olmaganini ifodalab olamiz.

Aniqlik ko'rinishining yuqori bo'lishi modeli. Buning uchun bu qiymat o'ta nosimmetrik ma'lumotlarda (sog'lom va kasalliklarning mutanosibligi bo'lmaganda) noto'g'ri ishlashi mumkin.

Aniqlovchanlik - Aniqlovchan model tomonidan saraton deb kasalning qanchasi haqiqatdan saraton kasaliga ko'ra quyidagi ifodada ko'rib chiqamiz.

$$\text{aniqlovchanlik} = \frac{\text{to'g'ri pozitivlar}}{\text{to'g'ri ripozitivlar} + \text{xato pozitivlar}} \quad (2)$$

Ushbu (2) – ifodada Agar model 10 bemordan 8 tasini saraton deb belgilab, shulardan 6 tasi haqiqatan saraton bo'lsa quyidagicha hisoblaymiz.

$$\text{aniqlovchanlik} = \frac{6}{6+2} = 0.75 (75\%)$$

Aniqlovchanlikning ma'nosi. Yuqori aniqlovchanlik modelning xato pozitivi kamligini noto'g'ri, ya'ni sog'lom bemorlarni saraton deb bilish past bo'lishi ko'rsatkichlarga ega bo'lamiz.

Aniqlik umumiy mahsulotning to'g'richanligini baholasa, faqat saraton deb baholashning ishonchli sifatli ko'rinishini taminlaydi.

Ba'zan aniqlovchanlikni hisoblash uchun aniqlikni ozgina kasallikni yo'q qilish kerak bo'lganida xavflarni FN negativilardan FP xavfsizlik muhim bo'lsa (3) ifodadan foydalanamiz.

Qo'shimcha ko'rsatkichlar. Aniqlik va aniqlovchanlikdan tashqari diagnostik modellarini tekshirishda ko'rsatkichlar bilan ifodalab o'tamiz.



1. **Sezgirlik (Recall)** - Kasallik bo'lgan bemorlarning modeli olingan to'g'ri aniqlanish darajasi quyidagi ifodada hisoblab o'tamiz.

$$\text{sezgirlik(eslash)} = \frac{\text{to'g'ri pozitivlar}}{\text{to'g'ri pozitivlar} + \text{xatonegativlar}} \quad (3)$$

2. **F1-Baho** - Aniqlovchanlik va tozalovchi funksiyaning saqlashini o'lchash uchun quyidagicha ifodadan foydalanamiz.

$$F1 = 2 \cdot \frac{\text{aniqlovchanlik} \cdot \text{sezgirlik}}{\text{aniqlovchanlik} + \text{sezgirlik}} \quad (4)$$

Agar diagnostik model natijalari natija bo'lsa quyidagi qiymatlarni hisoblaymiz.

to'g'ri Pozitivlar (TP) – 80, to'g'ri Negativlar (TN) – 900, xato Pozitivlar (FP) – 50, xato negativlar (FN) – 20 qiymatlar orqali hisoblab olamiz.

1-jadval

Baholash	Yechish jarayoni
Aniqlik	$\text{aniqlik} = \frac{80+900}{80+900+50+20} = 0.95(95\%)$
Aniqlovchanlik	$\text{aniqlovchanlik} = \frac{80}{80+50} = 0.615(61.5\%)$
Sezgirlik	$\text{sezgirlik} = \frac{80}{80+20} = 0.8(80\%)$
F1-Baho	$F1 = \frac{0.612 \cdot 0.8}{0.612 + 0.8} = 0.696(69.6\%)$

Ushbu 1-jadvalda matematik modellar diagnostik tizimlarda samaradorlikni oshirishini ko'rib chiqdik.

Mamografiya natijalarini avtomatlashtirilgan tahlil qilish - Neyron tarmoqlar orqali shifokor tomonidan noto'g'ri baholash ehtimolini kamaytirish.

Biopsiya jarayonining aniqligini oshirish - Biopsiya namunalarini matematik tahlil qilish orqali kasallik rivojlanish bosqichlarini aniqlash.

ROC egri (Receiver Operating Characteristic curve) modelning sezuvchanlik va aniqlik o'rtasidagi bog'liqlikni grafik shaklida tasvirlaydi. Ushbu egri ostidagi maydon (AUC - Area Under Curve) modelning umumiy samaradorligini ko'rsatadi[23,24].

AUC qiymati - Quyidagi qiymatlar orqali 0.5 - Tasodifiy model (foydasiz), **0.7-0.8** - Yaxshi model, **0.8-0.9** - Juda yaxshi model, **0.9 va yuqori** - Ajoyib model **AUC qiymatining oraliqlarini belgilab olamiz.**

AUC yuqori bo'lgan modellar kasallikni aniqroq va ishonchli aniqlashga imkon beradi. Matematik modellar ushbu ko'rsatkichlar yordamida baholanadi va ulardan eng samaradori klinik diagnostika jarayonida qo'llaniladi. Shu sababli, statistik va matematik modellashtirish kasalliklarni erta aniqlashda muhim ahamiyatga ega.

TADQIQOT NATIJALARI

Matematik modellari. Sut bezi saratoni diagnostikasi uchun matematik qo'yilishi quyidagi bosqichlarni o'z ichiga oladi. Bu matematik model kasallikni aniqlash va prognozlash uchun ishlatiladigan parametrlarni ifodalaydi.

1. Maqsad (Objective Function) funksiyasi orqali matematik diagnostikaning asosiy maqsadi quyidagicha ifodalanadi.

$$\text{maksimallashtirish } P(D | X) \quad (4)$$

Ushbu (4)- ifodada D - saraton mavjud yoki yo'qligini, X - tekshiruv natijalari va belgilangan ma'lumotlarni, $P(D | X)$ - ma'lumotlar asosida saraton holatini aniqlash ehtimolini ifodalaymiz.

2. Ma'lumotlarni matematik ifodasi quyidagi ma'lumotlarni o'z ichiga oladi.

Ma'lumotlarni matematik modellashtirish uchun quyidagilar aniqlanadi.

1. Kiruvchi ma'lumotlar (Input Variables)

X_1, X_2, \dots, X_n - Biopsiya ko'rsatkichlari, qon tahlillari, tasviriy o'lchamlar.

Y - Diagnostika natijasi (saraton bor = 1, saraton yo'q = 0).

2. Tasniflash (Classification) modeli quyidagicha hisoblanadi.

$$f(X) = \begin{cases} 1, & \text{agar saraton bo'lsa} \\ 0, & \text{agar saraton bo'lmasa} \end{cases} \quad (5)$$

3. Statik diagnostika uchun formulalar xavfni baholash (Risk Assessment) matematik formulasini ko'rich chiqamiz.



$$R = \sum_{i=1}^n \omega_i \cdot X_i \quad (6)$$

Ushbu (6) - ifodada ω_i - har bir simptom uchun vazni, X_i - i -simptom uchun ma'lumotlarni ifodalab Bayes formulasiga asoslangan ehtimollikni aniqlash ishlab chiqiladi.

$$P(D|X) = \frac{P(D|X) \cdot P(D)}{P(X)} \quad (7)$$

4 . Saraton rivojlanishni bashorat qilish
uchun vaqtga bog'liq o'zgarishlar modeli

$$\frac{dN(t)}{dt} = r \cdot N(t) \cdot \left(1 - \frac{N(t)}{K}\right) \quad (8)$$

Ushbu (6)-ifodada $N(t)$ - vaqtni, t - da o'simtaning hujayralar sonini, r - rivojlanish sur'atini, K - o'simta hajmining cheklovchi sig'imini ifodalab olamiz.

5. Logistik regressiya (kasallik ehtimolini modellashtirish uchun) quyidagi ifodadan foydalanamiz.

$$P(C) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n)}} \quad (9)$$

Ushbu (9) - ifodada x_1, x_2, \dots, x_n - klinik belgilarning qiymatlarini, $\beta_0, \beta_1, \dots, \beta_n$ - model koeffitsiyentlarini ifodalab olamiz.

Chiziqli diskriminant tahlili (diagnostik belgilarning ajratuvchi chizig'ini hisoblash) orqali quyidagi ifodadan foydalanamiz.

$$y = \omega_0 + \omega_1 x_1 + \omega_2 x_2 + \dots + \omega_n x_n \quad (10)$$

Ushbu (10) - ifodada y - natijaviy funksiyaning qiymatini, $\omega_0, \omega_1, \dots, \omega_n$ - og'irlik koeffitsiyentlarini ifodalab olamiz.

Berilgan logistik o'sish modeli saraton rivojlanishini tushunish va prognoz qilish uchun qulay va samarali vositadir. Quyidagi asosiy fikrlarni ajratib ko'rsatish mumkin[25,26].

1. Boshlang'ich o'sish tezligi eksponensial - Model o'simtaning rivojlanishini boshlang'ich bosqichda tez o'sish sifatida tasvirlaydi, bu esa hujayralar o'rtasidagi resurslar uchun raqobatning yo'qligi bilan izohlanadi.

2. Resurs cheklovlari o'sishni sekinlashtiradi - Vaqt o'tishi bilan o'simta hajmi cheklovchi sig'im (K) ga yaqinlashganda, o'sish sekinlashadi va barqarorlashadi.

3. Davolash strategiyasini rejalashtirish - Ushbu model davolash usullarining samaradorligini baholashda, masalan, kimyoterapiya yoki immunoterapiyaning o'sish sur'ati (r) yoki maksimal hajm (K) ga ta'sirini o'rganishda qo'llanilishi mumkin.

4. Prognoz imkoniyati - Model hujayra sonining vaqt bo'yicha qanday o'zgarishini aniqlashda yordam beradi va saraton rivojlanishini oldindan baholash uchun ishlatiladi.

Ushbu holatlar uchun matematik modelni qurishda logistik o'sish tenglamasi asos sifatida qabul qilinadi. Logistik o'sish modeli hujayralar sonining vaqt bo'yicha o'zgarishini hisobga olib, resurslar cheklovlari va o'sishning asliy xususiyatlarini aks ettiradi.

1. Logistik o'sish tenglamasi quyidagicha ifodalanadi.

$$\frac{dN}{dt} = rN \left(1 - \frac{N}{K}\right) \quad (11)$$

Ushbu (11) - ifodada $N(t)$ - vaqt da hujayralar sonini, t - boshlang'ich o'sish tezligini, $\frac{dN}{dt}$ - hujayralar sonining vaqtga nisbatan o'zgarish tezligini ifodalaymiz.

2. Davolash ta'sirini qo'shish - Davolash hujayralarning o'sish sur'atiga yoki tashuvchanlik quvvatiga ta'sir qilishi mumkin. Tadqiqotda kimyo terapiyasi yoki immunoterapiya hujayralarning o'sish koeffitsiyenti ni pasaytirishi mumkin. Shuning uchun model quyidagicha o'zgarishi mumkin.

$$\frac{dN}{dt} = rN \left(1 - \frac{N}{K}\right) - cN \quad (12)$$

Ushbu (12) - ifodada davolash ta'siri koeffitsiyenti (hujayralarning yo'q qilinishi tezligi)ni ifodalab olamiz.

3. Hosil bo'lgan model orqali saratonning rivojlanishi bashorati - Logistik tenglama yechimini yozsak quyidagiga ega bo'lamiz.



$$N(t) = \frac{K}{1 + \left(\frac{K - N_0}{N_0}\right) e^{-rt}} \quad (13)$$

Ushbu (13) - ifodada N_0 - boshlang'ich hujayralar sonini, e - tabiiy logarifm asosini ifodalaymiz. Boshlang'ich bosqichda $N \ll K$, model eksponensial o'sishni tasvirlaydi.

$$\frac{dN}{dt} \approx rN \quad (14)$$

Ushbu (14) -ifodada cheklovli bosqichda $N \rightarrow K$, o'sish sekinlashadi va $N \approx K$ bo'ladi, Davolash samaradorligi parametriga bog'liq. Agar $c > r$ bo'lsa, hujayralar soni kamayib, ostiga tushishi mumkin.

Modelning qo'llanishi

1. Davolash strategiyasini baholash turli va qiymatlarini o'zgartirib, samaradorlikni aniqlash.
2. Hujayralar sonining vaqt bo'yicha o'zgarishini prognozi.

Raqamli simulyatsiya orqali olingan natijalarni real ma'lumotlar bilan taqqoslash.

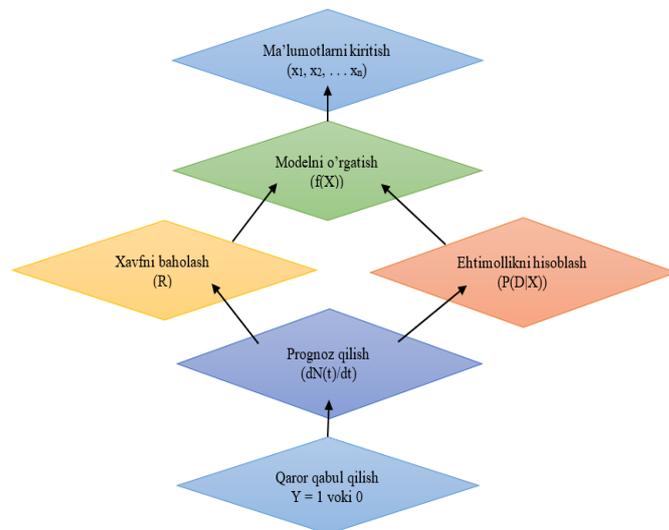
Logistik o'sish modeli oddiy, lekin samarali. Uning cheklovlari shundaki, u murakkab biologik omillarni (masalan, qon ta'minoti, immunitet ta'siri yoki genetik omillar) hisobga olmaydi. Shu sababli, modelni klinik ma'lumotlar bilan to'ldirish orqali yanada mukammalroq prognozlar olish mumkin[27,28].

Mazkur blok sxema saraton kasalligini aniqlash va prognozlash jarayonini matematik modellashtirishga asoslangan. Sxema klinik ma'lumotlarni qayta ishlash, xavfni baholash, ehtimollikni hisoblash, va qaror qabul qilishning asosiy bosqichlarini o'z ichiga oladi[29,30].

1. Saraton mavjudligini aniqlash uchun ma'lumotlarni izchil tahlil qilish.
2. Saraton rivojlanish ehtimolini matematik modellar yordamida aniqlash.
3. Qaror qabul qilish jarayonini avtomatlashtirish va aniqlikni oshirish.

Ushbu blok sxema diagnostika jarayonining izchil va avtomatlashtirilgan tarzda amalga

oshirilishini ta'minlash uchun ishlab chiqilgan. Bu yondashuv saratonni erta aniqlash va davolash samaradorligini oshirishda muhim ahamiyatga ega.



1-blok sxema(olmos shklidagi saratonni diagnostika sxemasi)

Ushbu 1-blok sxemada saratonni diagnostika qilish va prognozlash jarayonining asosiy bosqichlarini tartiblangan holda aks ettiradi. Quyida bosqichlar haqida qisqacha ma'lumot berilgan.

1. Kirish ma'lumotlari

X_1, X_2, \dots, X_n kabi ma'lumotlarni o'z ichiga oladi. Bu ma'lumotlar biopsiya natijalari, qon tahlillari va boshqa klinik ko'rsatkichlarni ifodalaydi.

2. Modelni o'rgatish

Kirish ma'lumotlari asosida tasniflash modeli yaratiladi ($f(X)$).

Maqsad kasallik mavjudligini aniqlash uchun optimal modelni qurish.

3. Xavfni baholash

Har bir simptomning xavf darajasi hisoblanadi (R).

Bu bosqichda har bir simptomning vazni (ω_i) hisobga olinadi.

4. Ehtimollikni hisoblash

Bayes formulasiga asoslangan holda saraton ehtimoli ($P(D|X)$) aniqlanadi.

Bu bosqich bemorning ma'lumotlariga mos ravishda tashxis ehtimolini beradi.



5. Prognoz qilish

O'simtani rivojlanish dinamikasi hisoblanadi ($dN(t)/dt$).

Bu bosqich saratonning rivojlanish tezligini aniqlashga xizmat qiladi.

6. Qaror qabul qilish

Yakuniy bosqichda diagnostik qaror qabul qilinadi.

Saraton mavjud bo'lsa $Y=1$, aks holda $Y = 0$ deb belgilash orqali natijalar ko'rsatiladi.

Bu sxema diagnostik jarayonning tushunarli va ketma-ket bosqichlarini aniq tasvirlaydi. Har bir bosqich ma'lumotlar yig'ish, xavfni baholash va qaror qabul qilish orqali saratonni aniqlashda muhim rol o'ynaydi. Bu sxema sog'liqni saqlash sohasida saratonni erta aniqlash va davolash rejasini tuzishda yordam berishi mumkin[31,32,33,34].

IV. XULOSA

Sut bezi saratonini diagnostika qilishda matematik yondashuvlar diagnostik jarayonlarni tezlashtirish va aniqligini oshirishga katta hissa qo'shadi. Ushbu yondashuvlar shifokorlarga aniqlangan ma'lumotlarni to'g'ri talqin qilishda yordam beradi va bemorlarga ko'rsatiladigan tibbiy xizmat sifatini oshiradi. Kelajakda bu usullarni yanada takomillashtirish saraton kasalliklarini yanada samarali davolash imkoniyatini yaratadi. Ushbu ishda sut bezi saratonini diagnostikasida matematik modellar va statistik yondashuvlardan foydalanish masalasi yoritildi. Tadqiqotdan ma'lum bo'lishicha, sut bezi saratonini erta aniqlash bemorning yashash davomiyligini oshirish va davolash natijalarini yaxshilash uchun muhim ahamiyatga ega. Diagnostik jarayonni matematik modellar bilan boyitish orqali tashxis qo'yishning aniqligi, tezligi va ishonchliligi oshiriladi. Logistik regressiya, qaror daraxtlari, neyron tarmoqlari va boshqa mashinaviy o'qitish usullari yordamida tashxis jarayonida sezuvchanlik (sensitivlik), aniqlik (spetsifiklik) va ROC egri ostidagi maydon (AUC) kabi statistik ko'rsatkichlarning yuqori darajasiga erishish mumkinligi ko'rsatildi. Bu esa diagnostika samaradorligini oshirishga xizmat qiladi. Shuningdek, sut bezi saratonini diagnostikasida ma'lumotlarni to'plash va tahlil qilishning to'g'ri

usullarini qo'llash, sog'lom va kasallikka chalingan bemorlarni farqlashda aniq va samarali natijalarga erishish imkonini beradi. Matematik modellar inson omilini kamaytirib, tashxis jarayonlarini avtomatlashtirish va optimallashtirishga zamin yaratadi. Natijada, ushbu yondashuv zamonaviy tibbiy diagnostika tizimlarida keng qo'llanilishi mumkin bo'lib, kasalliklarni erta bosqichda aniqlash va samarali davolashga xizmat qiladi. Kelgusida bu yo'nalishda mashinaviy o'qitish va sun'iy intellekt texnologiyalarini yanada rivojlantirish orqali diagnostika jarayonlari yanada takomillashtirilishi mumkin.

FOYDALANILGAN ADABIYOTLAR

1. Siegel, R. L., Miller, K. D., & Jemal, A. (2020). Cancer statistics, 2020. *CA: A Cancer Journal for Clinicians*, 70(1), 7–30. <https://doi.org/10.3322/caac.21590>
2. Harbeck, N., Penault-Llorca, F., Cortes, J., et al. (2019). Breast cancer. *Nature Reviews Disease Primers*, 5(1), 66. <https://doi.org/10.1038/s41572-019-0111-2>
3. Woldemichael, A., & Worku, E. (2020). Machine learning algorithms for breast cancer prediction and diagnosis. *Journal of Applied Health Sciences*, 4(3), 145–156. <https://doi.org/10.1016/j.jahs.2020.05.007>
4. Giger, M. L. (2020). Machine learning in medical imaging: Breast cancer diagnosis and prognosis. *Annual Review of Biomedical Engineering*, 22(1), 147–171. <https://doi.org/10.1146/annurev-bioeng-111219-090931>
5. GLOBOCAN (2021). Breast cancer statistics 2021. International Agency for Research on Cancer. Retrieved from <https://gco.iarc.fr>.
6. Giger, M. L. (2020). Machine learning in medical imaging: Breast cancer diagnosis and prognosis. *Annual Review of Biomedical Engineering*, 22, 147–171. <https://doi.org/10.1146/annurev-bioeng-111219-090931>
7. Harbeck, N., Penault-Llorca, F., Cortes, J., Gnant, M., Houssami, N., Poortmans, P., ... & Cardoso, F. (2019). Breast cancer. *Nature Reviews Disease Primers*, 5(1), 66. <https://doi.org/10.1038/s41572-019-0111-2>
8. Atakhanova, N. E., Shayusupov, N. R., Ishakov, D. M., Kakhkharov, A. Zh., & Shodmanova, D. S. (2022). Sut bezi saratonini prognozining mammografik va ultratovushli prognostik omillari. *Tashkent Medical Academy Journal*, 86(1), 87–90.
9. Ahmadova, M. A. (2024). Sut bezi saratonida radiologik tasvir va morfologik xususiyatlarni qiyosiy tavsiflash. *Journal of Healthcare and Life-Science Research*, 3(6).
10. Ergashev, A. J., & Oralova, S. B. (2024). Ayollarda ko'krak bezi saratonini diagnostikasi, belgilari va davolash usullari. *Modern Education and Development*, 15(4), 98–101.



11. Nishanova, Y. X., Ibroximova, F. J., & Musulmonov, Sh. R. (2023). Sut bezi saratoni skriningi. *Science and Pedagogy in the Modern World*, 1(1), 67–69.
12. Nishanova, Y. X., Ibroximova, F. J., & Musulmonov, Sh. R. (2023). Sut bezi saratoni skriningi. *Zenodo*.
13. Giger, M. L. (2020). Machine learning in medical imaging: Breast cancer diagnosis and prognosis. *Annual Review of Biomedical Engineering*, 22, 147–171.
14. Harbeck, N., Penault-Llorca, F., Cortes, J., Gnant, M., Houssami, N., Poortmans, P., ... & Cardoso, F. (2019). Breast cancer. *Nature Reviews Disease Primers*, 5(1), 66.
15. Bozorov, E. X., & Ergashev, A. J. (2022). Tibbiyotda magnit rezonans tomografiyasi mavzusini yangi pedagogik texnologiya asosida o'qitish. *Pedagogik Mahorat*, 2, 222–227.
16. Alimkhodjaeva, L. T., & Norbekova, M. H. (2020). Clinical significance of the density of tumor microvessels in breast cancer in men. *Central Asian Journal of Medicine*, 2, 56–64.
17. Zakirova, L. T., & Alimkhodjaeva, L. T. (2018). Chromosomal disorders and aberrant DNA methylation as early biomarkers of breast cancer risk in young women. *Journal of Life Science and Biomedicine*, 8(1), 1–5.
18. Norbekova, M. H., Alimkhodjaeva, L. T., & Mirolimov, M. M. (2019). Vzgl'yad na problemu raka molochnoy zhelezy u muzhchin v Respublike Uzbekistan. *Uzbekistan Medical Journal*, 1, 56–64.
19. Gonzalez, R., Nejat, P., Saha, A., Campbell, C. J. V., Norgan, A. P., & Lokker, C. (2023). Performance of externally validated machine learning models based on histopathology images for the diagnosis, classification, prognosis, or treatment outcome prediction in female breast cancer: A systematic review. *arXiv preprint arXiv:2312.06697*.
20. Levshinskii, V., Polyakov, M., Losev, A., & Khoperskov, A. (2019). Verification and Validation of Computer Models for Diagnosing Breast Cancer Based on Machine Learning for Medical Data Analysis. *arXiv preprint arXiv:1910.02779*.
21. Stoia, S., Băciuț, G., Lenghel, M., & Badea, R. (2021). Imaging in the preoperative diagnosis of parotid gland tumors. *Bosnian Journal of Basic Medical Sciences*. Retrieved from <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7861630/>
22. Song, X., Yang, X., & Narayanan, R. (2020). Saliva metabolic profiling in oral squamous cell carcinoma diagnosis. *Proceedings of the National Academy of Sciences*. Retrieved from <https://www.pnas.org/doi/pdf/10.1073/pnas.2001395117>
23. Liu, S., Yu, B., Zheng, X., Guo, H., & Shi, L. (2024). Construction and application of a nomogram for predicting parotid tumors. *Journal of Computer Assisted Tomography*. Retrieved from https://journals.lww.com/jcat/fulltext/2024/01000/construction_and_application_of_a_nomogram_for.21.aspx
24. Prezioso, E., Izzo, S., & Giampaolo, F. (2021). Predictive medicine for salivary gland tumors using deep learning. *IEEE Journal of Biomedical and Health Informatics*. Retrieved from <https://ieeexplore.ieee.org/abstract/document/9573315/>
25. Lavareze, L., Scarini, J. F., & de Lima-Souza, R. A. (2022). Tumor microenvironment in salivary gland cancer: Translational routes for therapy. *Critical Reviews in Oncology/Hematology*. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1040842822000294>
26. Chen, W., Zhu, L. N., Dai, Y. M., & Jiang, J. S. (2020). Differentiation of salivary gland tumors using diffusion-weighted imaging. *The British Journal of Radiology*. Retrieved from <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7465841/>
27. Lopez, J. E. (2022). Dose calculations for salivary glands in prostate cancer therapy. *Georgetown University Repository*. Retrieved from https://repository.library.georgetown.edu/bitstream/handle/10822/1082659/Lopez_georgetown_0076M_15589.pdf
28. Itonaga, T., Tokuyue, K., & Mikami, R. (2022). Mathematical evaluation of salivary gland function post-radiotherapy. *The British Journal of Radiology*. Retrieved from <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8822577/>
29. Zhang, Q., Ouyang, H., & Ye, F. (2020). Multiple mathematical models for endometrial cancer characterization. *European Journal of Radiology*. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0720048X20302916>
30. Liu, J., Cai, Y., & Huang, D. (2022). Saliva diagnostics: Emerging techniques and biomarkers for cancer detection. *Expert Review of Molecular Diagnostics*. Retrieved from <https://drive.google.com/file/d/1Y2jbE3MZwKtbfDwEvXGecfSINjOCvij5/view>
31. Nishanov, A., Mamajanov, R., Xaydarov, S., Mengturayev, F., & Yuldashev, R. (2024). Sut bezi saraton kasalliklarini simptomlarini mashinali o'qitishga tayyorlash bosqichlari. *Digital Transformation and Artificial Intelligence*, 2(6), 237–249. Retrieved from <https://dtai.tsue.uz/index.php/dtai/article/view/v2i633>
32. Nishanov, A., Mengturayev, F., Allayarov, U., & Xaydarov, S. (2024). Endokrin kasalliklarini tashxislashda foydalaniladigan simptomlarni shakllantirish bosqichlari. *Digital Transformation and Artificial Intelligence*, 2(6), 228–236. Retrieved from <https://dtai.tsue.uz/index.php/dtai/article/view/v2i632>
33. Nishanov Akhram Khasanovich, Mamazhanov Rakhmatilla Yakubzhanovich, Khaidarov Sherali Islom o'g'li, Xolbekov Abdusattor Maxammatovich, & Karimova Zilola Botirovna. (2024). Diagnostic Algorithm for Early Detection of Breast Cancer Based on Error Minimization Approach. *International Journal of Innovative Science and Research Technology (IJISRT)*, 9(12), 1535–1542. <https://doi.org/10.5281/zenodo.14565219>



TO'QUV MASHINASI ISHLASH JARAYONIDA, IPDA HOSIL BO'LADIGAN TARANGLIK KUCHI NAZARIYASINI MATEMATIK MODELINI DINAMIK JIXATDAN ASOSLASH

Sharibayev Nosirjon Yusubjanovich,
Namangan Muhandislik texnologiyalari instituti
Fizika matematika fanlari doktori, professor
sharibayev_niti@mail.ru

Homidov Qahramon Abdullajonovich,
Namangan muhandislik-qurulish instituti o'qituvchisi,
hero23021986@gmail.com

Annotatsiya: To'qima to'qish jarayonida pishirilgan iplardan foydalaniladi. To'qilgan sifatli mato turli sanoat sohalorida, masalan, to'qimachilik, transport, inshootlar va boshqa sohalarda keng qo'llaniladi. Shuning uchun iplarning mexanik xususiyatlarini aniqlash juda muhimdir. To'quv jarayonida yuzaga keladigan qarshilik kuchlarini hisoblash va turli holatlarda ularni tahlil qilish to'qimachilikning eng dolzarb masalalaridan biridir. To'qima to'qish jarayonida xomuza ochilishi natijasida ipning taranglik kuchi keskin ortadi, bu esa ipning uzilishiga olib keladi. Taranglik kuchining ortishini kamaytirish maqsadida qayishqoq prujinalar qo'llaniladi. Ushbu maqolada to'quv ipiga ta'sir qiladigan kuchning dinamik modeli ishlab chiqilib, unga mos differensial tenglama tuzilgan. Tenglama yechilib, uning grafigi chizilgan va yechimning mexanik ma'nosi izohlangan.

Kalit so'zlar: Ip, qarshilik kuchi, tezlik, ifoda, yuklanish, qayishqoqlik, deformatsiya, elastiklik, uzilish kuchi, tortish kuchi, to'qima, differensial tenglama, taranglik

Kirish. Rivojlangan mamlakatlar, shu jumladan Respublikamizda, ishlab chiqariladigan yuqori sifatli mahsulotlarga bo'lgan talab kundan-kun ortib bormoqda. Ayniqsa, to'qimachilik va yengil sanoat korxonalaridagi mahsulot sifatining muhimligi tobora oshib bormoqda. To'qima to'qish jarayonida iplarni qayta o'rashda ipning tarangligini va namlikni nazorat qilish juda muhim. Iplarning sifati va xossalari, ayniqsa to'qish jarayonida uning tarangligini nazorat qilish va bir me'yorda o'rashni doimiy ravishda nazorat qilish zarur. Ip tarangligini nazorat qiluvchi qurilmalarning avtomatlashtirilishi, ish samaradorligini va mahsulot sifatini oshirishga yordam beradi.

Hozirgi kunda to'qimachilik mashinalarini yaratish va takomillashtirishning asosiy yo'nalishlaridan biri texnologik jihozlarning parametrlarini optimallashtirish orqali iplarning sifat ko'rsatkichlarini yaxshilash va unumdorligini oshirishdir. Biroq, bu vazifalarni amalga oshirishda olinadigan ip sifat ko'rsatkichlarida yuzaga keladigan o'zgarishlarni chuqur tahlil qilish, uning mexanik

xossalari bilish zarur bo'ladi. Chunki tez harakatlanadigan jihozlarda ipga turli mexanik ta'sirlar (aylanish, egilish, buralish, taranglik va tebranish) o'z ta'sirini ko'rsatadi. Bu ta'sirlar ishlatilayotgan va loyihalananayotgan mashina qismlarining tezliklari, shakl va o'lchamlarini tanlashda asosiy mezon bo'ladi. To'qima to'qish jarayonida iplarning tarangligi to'quv texnologik ishlab chiqarish jarayonlarida katta ahamiyatga ega. To'qish mashinasiga ip tarangligi o'rtacha bo'lishi kerak. Haddan ziyod taranglik ostida iplar cho'zilib qolib, to'quv jarayonlari va matolar uchun elastik qayishqoqligini yo'qotadi. Taranglikning oshishi bilan ip uzilishlari ko'payadi va iplarda uloqlar soni ortadi, bu esa to'quv jarayoniga salbiy ta'sir ko'rsatadi.

Metodlar. Qayta o'rash jarayonida ipning kerakli tarangligini olish va uni nazorat qilish uchun maxsus taranglovchi moslamalar ishlatiladi. Taranglovchi moslamalarga quyidagi talablar qo'yiladi:

1. Iplarning bir xil to'xtashini ta'minlash;

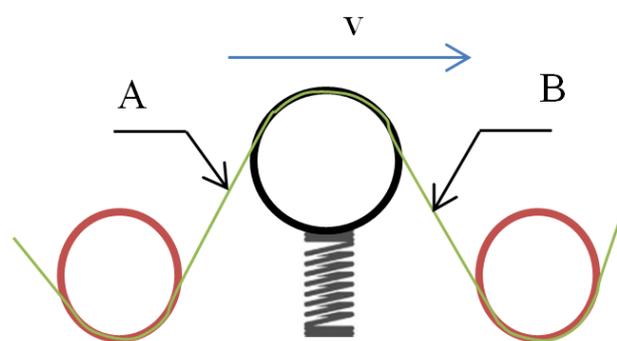


2. Kerakli taranglikni o'rnatish uchun oson sozlanishi;
3. Ish jarayonida turli xildagi xas cho'plar, momiqlar va iflosliklar to'planmasligi, oson tozalanishi;
4. Taranglovchi moslamaning ishlashi ishonchli va chidamli bo'lishi.

Barcha taranglovchi moslamalarda ishqalanish kuchlari ta'sirida ipda qo'shimcha taranglik paydo bo'ladi. Turli konstruksiyadagi taranglovchi moslamalar ipning tarangligini nazorat qilishning turli usullarini amalga oshiradi, jumladan prujina kuchi, yuklarning og'irlik kuchi, magnit yoki elektromagnit ta'siri, pnevmatik usullar va boshqa kompleks kuchlarning ta'sirida. Ip tarangligini nazorat qilishda ishqalanish kuchlari muhim rol o'ynaydi, chunki ular ipning tarangligini oshiradi. Qayta o'rash jarayonida iplar disklar orasidan o'tib, ularga ishqalanish natijasida kerakli taranglikka ega bo'ladi. Ipning bir xil tarangligi mahsulot sifatini yaxshilaydi va jarayonni osonlashtiradi, shu bilan birga yuqori tezlikda ishlab chiqarishni ta'minlaydi. Taranglikni nazorat qiluvchi moslamaning tanlovi va sozlanishi, qayta o'rash jarayonining sifatini oshirishda muhim ahamiyatga ega. Shuningdek, pishitish jarayonidagi iplarning mexanik xususiyatlarini o'rganish zarurligi ko'rsatilgan. Yakka iplarning bir xil tarangligini ta'minlash iplarning notekisligini kamaytiradi, ishqalanishga chidamliligini oshiradi va pishiqligini yaxshilaydi. Pishitish jarayonidagi iplarning mexanik xossalarini o'rganish va boshqarish yuqori sifatli mahsulot ishlab chiqarish uchun zarur bo'lib, zamonaviy jihozlarni loyihalashda asosiy omil hisoblanadi.

Muammoning qo'yilishi: Bajarilgan ilmiy ishlar natijalariga ko'ra, iplarga ta'sir qilgan kuchlar natijasida plastik va elastik deformatsiyalar hosil bo'ladi. Bu deformatsiyalar ipning har xil tezlikda yuzaga keladi, ya'ni qayishqoq deformatsiya juda tez ro'y beradi, elastik deformatsiya esa ma'lum bir vaqt ichida o'sadi. Ipga ta'sir qiluvchi kuch kamaygandan so'ng, deformatsiyaning qaytishi ham o'xshash tarzda sodir bo'ladi: qayishqoq deformatsiya qisqa vaqt ichida, elastik deformatsiya esa uzoqroq vaqt

davomida qaytadi. Ma'lumki, iplarning cho'zilishi va siqilishi jarayonida uning qiya yuzachalarda siljish holati ham yuz beradi. Urinma kuchlanishlar ta'sirida ipning kuchlanganlik holatida sof siljish yuzaga keladi. Sof siljish natijasida ipning shakli o'zgarib, nisbiy deformatsiyalar paydo bo'ladi, bu esa ipning mexanik xossalariga ta'sir ko'rsatadi. Shu nuqtai nazardan, cho'ziluvchan ipning tanda harakatlanganda hosil bo'ladigan qarshilik kuchining nazariy jihatdan tahlilini o'tkazish lozim. Cho'ziluvchan arqoq ipning taranglik kuchi bilan ipning cho'zilish masofasi orasidagi bog'liqlikni tavsiflash uchun maxsus tenglama tuzish zarur. Ushbu tenglama ipning cho'zilishi va unga ta'sir qilayotgan kuchlar o'rtasidagi aloqani o'rganish imkonini beradi va ipning mexanik xossalari hamda uning ishlash sharoitlari haqida chuqurroq tushuncha olishga yordam beradi.



1-rasm. To'qish jarayonida ipga ta'sir qiluvchi kuchning nazorat qiluvchi qurilma .

Mexanik-modulli yondashuv: 1-rasmdan ko'rinib turibdiki. Ip o'ng tomonga harakatlanmoqda. Tandagi ipning chap tomonida joylashgan A nuqtasiga (1) kuch, B nuqtasiga esa (2) kuch ta'sir qiladi. Bu kuchlarning dinamik muvozanatidan va Nyutonning ikkinchi qoninidan foydalanib (3) tenglamani keltirib chiqaramiz. [5]

$$T_1 \quad (1)$$

$$T_1 + T_0 \sin \omega t \quad (2)$$

$$T_1 + T_0 \sin \omega t - T_1 - kx - cv_{pr} t = ma \quad (3)$$

Yoki



$$T_0 \sin \omega t - kx - cv_{pr}t = ma \quad (4)$$

Bu yerda:

T_1 - To'qima to'qish jarayonida ipga ta'sir etib turuvchi doimiy taranglik kuchi;

T_0 - Bu kuch xomuzga ochilgan vaqtda xosil bo'ladigan maksimal kuch;

k - Ippga kuch ta'sirida hosil bo'ladigan elastiklik koeffitsienti;

m -Ippning massasi;

c - Prujina bikrligi;

v_{pr} - Prujinaning o'rtacha tezligi;

x - Ippning ish jarayonida yurish yo'li.

a -Kuchlar ta'sirida ip olgan tezlanish.

ω - Xomuzaning ishlash jarayonidagi siklik chastotasi

Differensial tenglamani keltirib chiqarish:

(4)-tenglikni soddalashtirib va quyidagi $\ddot{x} = a$ tenglikdan foydalanib, (5) tenglamaga kelimiz.

$$\ddot{x} + \frac{k}{m}x = \frac{T_0 \sin \omega t}{m} - \frac{cv_{pr}}{m}t \quad (5)$$

(5) tenglama ikkinchi tartibli o'zgarmas koeffitsientli chiziqli bir jinsli bo'lmagan differensial tenglama deyiladi.[6]. Bu tenglamani yechib quyidagi umumiy yechimni olamiz.(6)

$$x(t) = C_1 \cos \sqrt{\frac{k}{m}}t + C_2 \sin \sqrt{\frac{k}{m}}t + \frac{T_0 \sin \omega t}{k - m\omega^2} - \frac{cv_{pr}}{k}t; \quad (6)$$

$$x(0) = 0, \quad \dot{x}(0) = 0,$$

Dastlabki xolatda A va B nuqtalarga kuchlar ta'sir qilmasdan oldin, bu kuchning qiymati va ipning tezligi 0 ga teng bo'ladi. Bundan foydalanib (7) shartni yozishimiz mumkin.

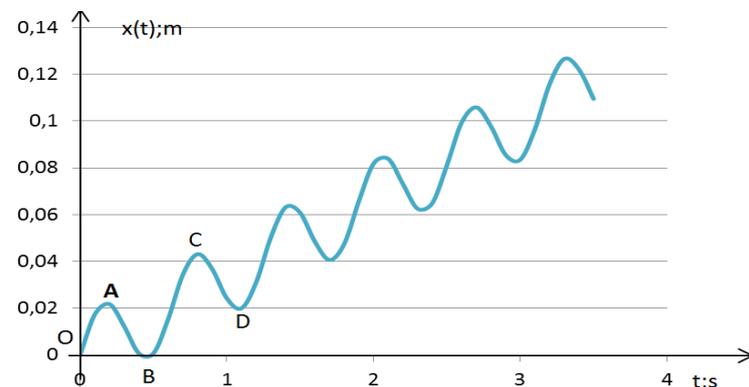
Koshi masalasini umumiy yechimini topish:(5) tenglamani (7) shart asosidagi boshlang'ich shartli masala, ya'ni Koshi masalasi deyiladi. Bu masalani yechib, o'zgarmas koeffitsientlar C_1 va C_2 larni qiymatini topamiz. Topilgan qiymatlarni (6) tenglamaga olib borib qo'yib (8) yechimni olamiz.

$$x(t) = \sqrt{\frac{m}{k}} \left(\frac{cv_{pr}}{k} - \frac{T_0\omega}{k - m\omega^2} \right) \sin \sqrt{\frac{k}{m}}t + \frac{T_0 \sin \omega t}{k - m\omega^2} - \frac{cv_{pr}t}{k}; \quad (8)$$

$$v_{pr} = 0,4 \text{ m/s} \quad T_0 = 3 \text{ N}; \quad k = 1200 \text{ N/m}; \quad m = 0,0001$$

$$\omega = 10 \frac{\text{rad}}{\text{s}}$$

kg; $c = 150 \text{ N/m}$;



1-grafik. Ippning to'qilish jarayonidagi yo'li va vaqt orasidagi bog'lanish grafigi.

Natijalar: (5)-tenglamani yechimidan va kerakli o'zgarmaslarning amaliyotga yaqin qiymatlaridan foydalanib 1-grafikni olamiz. Yuqoridagi grafikni OA, AB, BC, CD qismlarga bo'lamiz. Har bir qismdagi jarayonni mexanik jixatdan taxlil qilib chiqamiz.

OA jarayon: Grafikning bu qismida tikuv boshlanish jarayoni aks etgan bo'lib, ipga ta'sir qiluvchi kuch dastlab nolga teng, umumiy qarshilik kuchi keskin oshishligini ko'rsatadi. Bunday bo'lishiga asosiy sabab ip cho'zilganda elastik kuchi va xomuzani ochilishi bilan xosil bo'ladigan qarshilik kuchi ortmoqda.

A nuqtada: Qarshilik kuchlarini y_1 indisi maksimal qiymatga erishadi.

AB jarayon: Ippning tutib turish chegarasi bo'shaladi yani ip relaksaksiyalanadi. Ip tandalardan o'ta boshlaydi bu esa ishqalanish yuzasini va harakatga qarshilik kuchini kamaytiradi, ipning relaksaksiyalanish natijasida elastik kuchining qiymatini kamayadi. Umumiy qarshilik kuchi kamayadi.

B nuqtada: Ippga teng ta'sir etuvchi kuch nolga teng bo'liadi. Natijada ip to'xtaydi.

BC jarayon: Bu holatda ipga ta'sir qiluvchi kuch yana ortib boradi.



CD jarayon: Bu jarayonda yuqoridagi sikl yana davom etadi.

Xulosa. O'rganilayotgan jarayon shuni ko'rsatadiki, matoning mexanik xususiyatlarini chuqur tahlil qilish, texnik va ilmiy yondashuvni takomillashtirishga olib keladi. Bu esa nafaqat ilmiy tadqiqotlar, balki to'qimachilik sanoati va boshqa sohalarda matolarni sifatli ishlatish imkoniyatlarini kengaytiradi. Bunday tahlil va izlanishlar, matolarni ishlab chiqarish va ishlatishda yuzaga keladigan noaniqliklarni kamaytirishga yordam beradi. Mexanik xususiyatlarni o'rganish orqali matolarni turli sharoitlarda qanday ishlashini va ularning qaysi parametrlariga e'tibor qaratish kerakligini aniqlash mumkin. Shunday qilib, nazariy tahlil va hisoblashlar matolarni yanada ishonchli va uzoq muddatli ishlashini ta'minlashda muhim vosita bo'lib xizmat qiladi. Bu yondashuvlar, matolarni ishlab chiqarish jarayonlarida yuqori sifat va barqarorlikni ta'minlashda, ularning barcha zarur mexanik xususiyatlarini hisobga olishda yordam beradi. Mexanik qonuniyatlarga asoslanib, matolarni birlamchi va ikkilamchi qarshilik kuchlarini aniqlash imkonini beradi. Ushbu jarayon, shuningdek, matolarni yanada sifatli ishlab chiqarishga, ularning ishlash muddatini uzaytirishga va ularni turli sharoitlarda samarali ishlatishga yordam beradi. Misol uchun, matolarni ekstremal sharoitlarda ishlatish (issiq, sovuq, yuqori yoki past bosim kabi) uchun qanday o'zgartirishlar kiritish zarurligini aniqlash mumkin. Bu esa texnologik jarayonlarni optimallashtirishga, ishlab chiqarishning samaradorligini oshirishga yordam beradi. Maqolada olingan natijalar nafaqat ilmiy-tadqiqotlar, balki sanoat amaliyotida ham qo'llanilishi mumkin, bu esa texnologik jarayonlarning samaradorligini oshiradi. Matoning mexanik xususiyatlarini tushunish va tahlil qilish, qarshilik kuchlarini hisoblash orqali materiallarning bardoshli va xavfsiz ishlashini ta'minlashga yordam beradi. Bu nafaqat ishlab chiqarish jarayonini takomillashtirishga, balki matolarning texnik talablarga javob berishini nazorat qilishga ham imkon yaratadi. Masalan, yangi mahsulotlar ishlab chiqarishda, matolarni tayyorlash jarayonida maxsus formula va usullarni qo'llash orqali ularning sifatini yaxshilash mumkin bo'ladi. Tahlil

natijalaridan shuni ko'rishimiz mumkinki, matolarning mustahkamligini tahlil etishga qaratilgan tadqiqotlar ularning mexanik va matematik modeli juda kam o'rganilgan. Hozirgi kunda, ko'plab ilmiy ishlar va tadqiqotlar matolarni tahlil qilishning yangi usullarini ishlab chiqishga qaratilgan bo'lsa-da, ipga ta'sir qilayotgan qarshilik kuchi va unga ta'sir qiluvchi omillarni aniqlash uchun kerakli tenglamalar hali to'liq shakllantirilmagan. Berilgan parametrlarga bog'liq qarshilik kuchining tenglamalari va uning yechimlari hozirgacha o'rganilmoqda va bu soha hali ham rivojlanmoqda. Tadqiqotlar davomida bu jarayonning yanada chuqurroq va kompleks modellari ishlab chiqilishi kerak. Ushbu maqolada, tanda harakatlanayotgan ipga ta'sir qiladigan umumiy qarshilik kuchining tenglamasi Nyutonning ikkinchi qonuniga asosan tuzilgan. Bu yondashuv, kuch va massaning ta'sirini aniqroq o'lchashga va matematik jihatdan batafsilroq tahlil qilishga imkon beradi. Tuzilgan tenglama, differensial tenglamalar nazariyasi asosida yechildi va ipning yurish yo'li $x(t)$ kuch va vaqt (t) orasidagi bog'lanish grafigi sifatida taqdim etildi. Bu grafik, tahlil qilinayotgan mexanik jarayonni aniq va to'liq ifodalashda yordam beradi. Shuningdek, grafikdan foydalanib, ipning harakati va unga ta'sir qilayotgan kuchlar orasidagi bog'lanish haqida amaliy tushunchalar olish mumkin. Olingan grafik, ip uchun o'rganilayotgan mexanik jarayonni to'liq ifoda etib berdi va uning o'zgarishini kuzatishga imkon yaratdi. Bu yechimni amaliyotda qo'llash mumkinligini grafik yordamida ko'rishimiz mumkin. Misol uchun, ipning harakatlanishi va unga ta'sir qilayotgan kuchlarning qanday o'zgarishini grafikda ko'rsatilgan parametrlar yordamida kuzatish mumkin, bu esa amaliyotda iplarning ishlash xususiyatlarini yaxshilashda muhim rol o'ynaydi. Shunday qilib, ushbu ilmiy yondashuv matolarni ishlab chiqarish va ishlatishda ilmiy asoslangan qarorlar qabul qilishga yordam beradi. Bunday tahlil, matolarni maksimal samaradorlikda ishlatishga, ularning fizik va mexanik xususiyatlarini yaxshilashga yordam beradi. Bundan tashqari, yangi texnologiyalarni ishlab chiqishda, sanoat ishlab chiqarishida va materialshunoslikda katta ahamiyatga ega bo'ladi.



Foydalanilgan adabiyotlar

1. Gulyamov, G., & Sharibaev, N.U. (2011). Determination of the density of surface states at the semiconductor-insulator interface in a metal-insulator-semiconductor structure. *Semiconductors*, 45, 174-178. <https://doi.org/10.1134/S1063782611020084>
2. Mamadaliyeva D, Karimov.R, Aliyeva D.G, “Increasing the strength of the pile in terry fabric by changing the weaving system”, “Scientific and Technical Journal” Namangan Institute of Engineering and Technology Volume 7, p.p 57-61, Namangan 2022.
3. Sharibaev, E., et al. (2022). Experimental investigation of the relationship between raw shaft density and saw cylinder electric motor load current. *Journal of Physics: Conference Series*, 2388, 012174. <https://doi.org/10.1088/1742-6596/2388/1/012174>
4. Akramov, A.M. Optimization of Parameters for Producing Suitable Fabrics on a Weaving Machine. PhD Thesis, NamMTI, Namangan, 2022.
5. Gordeev, V.A. Weaving Patterns and Fabric Analysis: A Textbook. Moscow: Light Industry, 1969, 120 pp.
6. Nikitin, M.N. Artistic Design of Fabrics. Moscow: Light Industry Publishing House, 1971, 280 pp.



DINIY IDORALARARO TAQSIMLANGAN AXBOROT TIZIMLARIDA MA'LUMOT FRAGMENTLARINI DINAMIK REPLIKATSIYASI

Dadamuxamedov Alimjon,

O'zbekiston xalqaro islom akademiyasi
Zamonaviy axborot-kommunikatsiya
texnologiyalari kafedrasi katta o'qituvchisi.
E-mail: chinororg@gmail.com

Annotatsiya: Ushbu ishda taqsimlangan axborot tizimlarida ma'lumot fragmentlarini dinamik replikatsiyalash masalasi o'rganiladi. So'nggi yillarda ma'lumotlar bazalarini samarali boshqarish va ularni qayta ishlash muhim ilmiy muammoga aylandi. Markazlashtirilgan ma'lumotlar bazalarining cheklovlari sababli taqsimlangan ma'lumotlar bazalari (TMB) tezkor ma'lumotga kirish, tizim ishonchliligini oshirish va ekspluatatsiya xarajatlarini kamaytirish uchun muqobil yechim sifatida qaralmoqda. Ishda fragmentatsiya va replikatsiya texnologiyalari asosida taqsimlangan tizimlarning samaradorligini oshirish yo'llari ko'rib chiqilgan. Tadqiqotda gorizontol, vertikal va gibrid fragmentatsiya modellarining taqsimlangan tizimlarda qo'llanilishi va ularning optimal joylashtirish strategiyalariga ta'siri tahlil qilinadi.

Kalit so'zlar: Taqsimlash, fragmentatsiya, replikatsiya, optimizatsiya, joylashtirish, migratsiya, tarmoq. yuklama, resurslar, model

Kirish. So'nggi yillarda ma'lumotlar bazalarini boshqarish va qayta ishlash texnologiyalari yangi bosqichga chiqdi. Hozirgi kunda axborot tizimlarining asosiy maqsadi – ma'lumotga tezkor kirish imkoniyatini ta'minlash, tizim ishonchliligini oshirish va ekspluatatsiya xarajatlarini optimallashtirishdan iborat. Ayniqsa, ma'lumotlar butunligi va xavfsizligi ustuvor masala bo'lib qolmoqda.

Markazlashtirilgan ma'lumotlar bazasi katta hajmdagi raqamli ma'lumotlarni saqlash va ularga ko'plab foydalanuvchilar tomonidan bir vaqtning o'zida so'rovlar yuborilgan holatlarda yetarli darajada samaradorlik, yuqori mavjudlik va ma'lumotlarning yaxlitligini ta'minlash imkoniyatiga ega emas. Shuning uchun, taqsimlangan ma'lumotlar bazalaridan foydalanish ma'lumotlarga tezkor kirish va tizim samaradorligini oshirish muammolarini hal qilishning samarali usuli hisoblanadi.

Taqsimlangan ma'lumotlar bazasini loyihalashning boshlang'ich bosqichida qo'llaniladigan turli usullar TMB (taqsimlangan ma'lumotlar bazalari) samaradorligiga ta'sir qiladi [7].

So'nggi yillarda ma'lumotlar bazalaridan foydalanuvchi taqsimlangan tizimlar sohasida ko'plab

tadqiqotlar olib borildi va ular quyidagi yo'nalishlarda amalga oshirildi [8].

Taqsimlangan axborot tizimlarining samaradorligini oshirish uchun ma'lumotlar bazasini fragmentatsiya qilish va ushbu fragmentlarni turli tugunlarga optimal joylashtirish usuli qo'llaniladi. Bugungi kunda turli ilmiy tadqiqotlar bu borada samarali algoritmlar ishlab chiqmoqda. Asosiy fragmentatsiya usullari quyidagilardan iborat:

- Gorizontol fragmentatsiya jadval satrlari mustaqil qismlarga bo'linadi va har bir fragment alohida saqlanadi.
- Vertikal fragmentatsiya ustunlar asosida bo'linib, turli atributlar alohida guruhlariga ajratiladi.
- Gibrid fragmentatsiya yuqoridagi ikki usul kombinatsiyasidan foydalaniladi.

Bundan tashqari, ma'lumotlar replikatsiyasi tizim ishonchliligini ta'minlashda muhim rol o'ynaydi. Replikatsiya jarayoni quyidagilarni o'z ichiga oladi:

- Replikalarni yaratish va boshqarish algoritmlarini qo'llash;
- Ma'lumotlarning mosligini ta'minlash uchun muvofiqlashtirish;



- Replikalarni tizim tugunlari orasida dinamik ravishda ko'chirish.

Adabiyotlar tahlili va metodologiya. Ushbu tadqiqotda taqsimlangan ma'lumotlar bazalarining samaradorligini oshirish va ma'lumotlarni optimal boshqarish bo'yicha turli metodologiyalar qo'llanilgan. Nazariy tahlil, matematik modellashtirish, eksperimental sinovlar, algoritmik optimallashtirish va fayl kengaytmasiga asoslangan fragmentatsiya yondashuvlari birgalikda ishlatilgan bo'lib, bu yondashuvlar natijasida tizim ishonchliligi, tezkorligi va samaradorligi oshirilgan.

Ushbu maqola taqsimlangan tizimlarda ma'lumotlar replikatsiyasi bo'yicha tadqiqot olib boradi va uning tizim ishonchliligi va barqarorligi uchun muhim vosita ekanligini asoslaydi. Asosiy e'tibor ma'lumotlarni takrorlash (replikatsiya qilish) texnologiyalariga, ularning tarmoq infratuzilmasiga ta'siri va ma'lumotlarni yo'qotish xavfini kamaytirishga qaratilgan. Maqolada quyidagi jihatlar ko'rib chiqilgan: Replikatsiya usullari va ularning taqsimlangan tizimlardagi roli, tizimning ishonchliligini oshirish uchun ma'lumotlarning ko'p nusxasini saqlash strategiyalari, ma'lumotlarni sinxron va asinxron replikatsiya qilishning afzalliklari va kamchiliklari, tarmoq kechikishi va yuklanishini minimallashtirish bo'yicha algoritmik yondashuvlar. Tadqiqot natijalari shuni ko'rsatadiki, samarali replikatsiya algoritmlaridan foydalanish tizimni nosozliklardan himoya qilish, yuklamani muvozanatlash va tezkor so'rovlarni ta'minlashda muhim rol o'ynaydi [1].

Big Data texnologiyalarining ilmiy va texnik tarmoqlardagi o'rni, ularni samarali boshqarish usullari hamda axborot oqimini optimallashtirish strategiyalari muhokama qilingan. Tadqiqot IoT qurilmalari, sensor tizimlar va tarmoq monitoringi kabi ma'lumot yig'ish texnologiyalari, mashinani o'rganish, sun'iy intellekt va real vaqt tahlili kabi ma'lumotni qayta ishlash usullari, bulutli hisoblash va taqsimlangan tizimlar orqali katta hajmdagi ma'lumotlarni samarali boshqarish yondashuvlari, shuningdek, axborot oqimini optimallashtirish uchun tarmoq orqali

ma'lumotlarni uzatish va saqlash strategiyalarini qamrab oladi. Tadqiqot natijalari katta hajmdagi ma'lumotlarni qayta ishlash samaradorligini oshirish uchun taqsimlangan ma'lumotlar bazalari, replikatsiya va fragmentatsiya usullari markazlashtirilgan tizimlarga nisbatan afzalroq ekanligini ko'rsatadi. Shuningdek, maqolada Hadoop, Spark va NoSQL kabi zamonaviy ma'lumotlar tahlili texnologiyalarining amaliy qo'llanilishi yoritilgan. Ushbu ish ilmiy tadqiqotlar, sanoat axborot tizimlari va davlat axborot tarmoqlari uchun muhim nazariy va amaliy asos yaratadi [2].

Taqsimlangan ma'lumotlarni qayta ishlash tizimlari turli darajadagi murakkablik va vazifalarga ega bo'lib, ularga qo'yiladigan talablar ham o'ziga xosdir. Eng muhim talablar quyidagilardan iborat: ma'lumotlarning yuqori darajada saqlanishi, tizim ishonchliligining maksimal darajada ta'minlanishi, so'rovlarga javob berish vaqti belgilangan chegaradan oshmasligi hamda ekspluatatsiya xarajatlarining minimal bo'lishi. Ushbu talablarni samarali bajarish uchun asosiy yechim ma'lumotlarni replikatsiya qilish va taqsimlangan tizim tugunlari bo'ylab replikatsiya qilingan ma'lumot massivlarini optimal joylashtirishdan iborat. Bunday yondashuv tizim samaradorligini oshirish, nosozliklarga chidamlilik darajasini kuchaytirish va tarmoq yuklamasini muvozanatlash imkonini beradi [3].

Replikatsiya usullari keng qo'llaniladi, masalan, taqsimlangan ma'lumotlar bazalarida (TMB), bu jarayon jadval ma'lumotlarini optimal joylashtirish yoki jadvalning gorizontaal yoki vertikal fragmentlarini samarali taqsimlash zarur bo'lganda ayniqsa dolzarb hisoblanadi. Ushbu yondashuv ma'lumotlarga tezkor kirishni ta'minlash, tizim yuklamasini muvozanatlash va ishlash samaradorligini oshirish uchun muhim ahamiyat kasb etadi [4].

GRID tizimlarida ma'lumotlar replikatsiyasi tizimning mavjudligini oshirish, nosozliklarga bardoshlilikini ta'minlash, yuklamani muvozanatlash va miqyoslash imkoniyatlarini kengaytirish uchun qo'llaniladi. Shu bilan birga, bu yondashuv tarmoq kanallaridagi ortiqcha yukni kamaytirish va topshiriqlarni bajarish vaqtini qisqartirishga xizmat



qiladi. Natijada, GRID tizimlari barqaror va samarali ishlashga erishib, katta hajmdagi hisoblash va ma'lumotlar almashinuvi jarayonlarini optimallashtirish imkoniyatiga ega bo'ladi [5].

Ma'lumotlarni tarmoq tugunlari bo'ylab optimal joylashtirish masalasi uzoq tarixga ega. Replikatsiya joylashtirish muammosi, ma'lum ma'noda, taqsimlangan kompyuter tarmoqlarida fayllarni samarali joylashtirish muammosining davomi sifatida qaraladi. Ushbu masala ilk bor ilmiy asosda shakllantirilgan va tahlil qilingan ish [6] bo'lib, u tizim samaradorligini oshirish va ma'lumotlarga tezkor kirish imkoniyatlarini yaxshilashga qaratilgan.

Ma'lumot saqlash tarmog'i (Storage Area Network – SAN) axborot saqlash vositalari (serverlar), boshqaruv tizimi va MST komponentalari orasida muloqotni ta'minlaydigan kommunikatsiya vositalaridan tarkib topadi (1 - rasm). MST vositalari mahalliy Ethernet tarmog'i, Fibre Chanel ma'lumot uzatish magistral tarmog'i vositalari (Fibre Channel) va Fibre Channel marshrutizatorlari (Fibre Channel – SCSI router) dan tarkib topadi, ular Fibre Channel protokoli yordamida o'zaro muloqotda bo'ladilar. MST vositalarining bog'lanishi optik tolali aloqa tizimlari yordamida ta'minlanadi. Vositalarning bunday o'zaro bog'lanishi Fibre Channel Fabric deyiladi.

Yuqoridagilarga asoslanib, tarqoq holda joylashgan diniy muassasalarida shakllantirilishi rejalashtirilayotgan ma'lumot saqlash tarmog'ining infratuzilmasini quyidagi bosqichlarda yaratish mumkin:

1) Diniy muassasalarda server hamda ishchi stansiya kompyuterlari asosida mahalliy kompyuter tarmog'ini tashkil etish.

2) Diniy muassasalarda yaratiladigan elektron ma'lumot bazalarining yagona standartini ishlab chiqish va ushbu standart asosida imkon qadar yagona platforma negizida ma'lumot saqlash omborlarini shakllantirish.

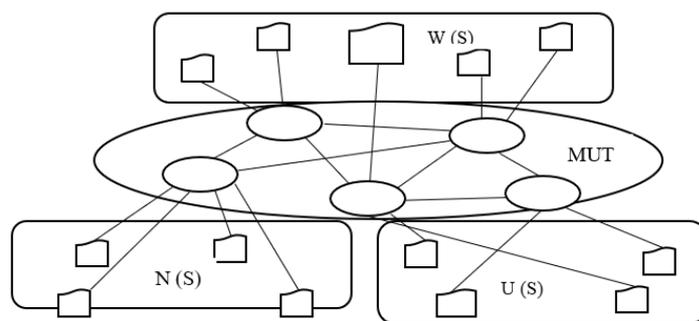
3) Graf nazariyasiga tayangan holda, MST ning Fibre Channel texnologiyasi asosidagi magistral telekommunikatsiya tarmog'i uchun topologik tuzilma sxemasini ishlab chiqish.

4) Diniy muassasalarining lokal kompyuter tarmoqlarini Fibre Channel texnologiyasi asosida integratsiya qilish orqali markaziy boshqaruv tizimiga ega taqsimlangan ma'lumot saqlash tarmog'i infratuzilmasini shakllantirish.

5) Foydalanuvchi so'rovlarini tahlil qilish asosida qaysi mazmundagi diniy axborotlarga talab yuqori ekanligini aniqlash.

6) 1-5-bosqich natijalariga asoslanib, joylardagi diniy muassasalarning yuklanish darajalarini tahlil qilish orqali foydalanuvchi so'rovlarini taqsimlash usulini ishlab chiqish va ushbu jarayonni avtomatlashtirish uchun dasturiy ta'minot yaratish.

7) MST ning ishonchligini va samaradorligini oshirish maqsadida, axborot resurslarini replikatsiya asosida tarqatib, diniy muassasalarining xotira disklariga qayta joylashtirish jarayonlarini amalga oshirish.



1 – rasm. Ma'lumot saqlash tarmog'ining umumlashgan sxemasi.

W (S) – Windows platformali axborot saqlash server kompyuterlari;

U (S) – Unix platformali axborot saqlash server kompyuterlari;

N (S) – Rezerv nusxa olish server kompyuterlari;

MUT – Ma'lumot uzatish tarmog'i

Ularni amaliyotga tatbiq etish muayyan miqdordagi moliyaviy xarajatlarni talab qiladi. Shu bois, taqsimlangan ma'lumotlar saqlash tarmog'i resurslarining hajmi va yuklanish darajasi juda yuqori bo'lmagan holatlarda, magistral telekommunikatsiya



tarmog‘i sifatida Internet imkoniyatlaridan foydalanish maqsadga muvofiq sanaladi.

Taqsimlangan tizimlarda samaradorlikni oshirishning eng muhim yo‘llaridan biri - tizim tugunlarini mantiqiy klasterlarga ajratishdir. Bunda quyidagi yondashuvlar qo‘llaniladi:

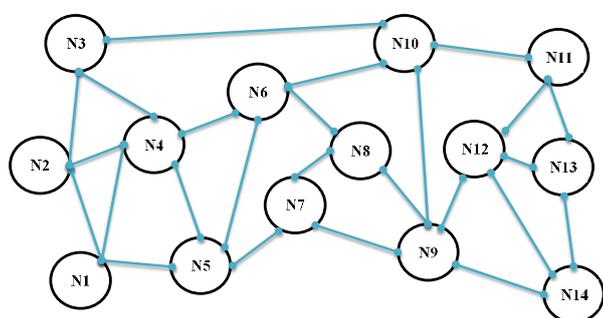
- Klasterlar orasidagi axborot almashinuvini minimallashtirish orqali tizim yuklamasini kamaytirish;
- Jadval fragmentlarini tizim tugunlariga optimal joylashtirish.

Klasterni qo‘llash usulining mosligini namoyish etish uchun taklif etilgan klasterlash algoritmini 14 ta tarmoq tugunidan iborat tarmoq fragmenti misolida modellashtirish natijalarini ko‘rib chiqamiz. Tarmoq fragmentining topologiyasi rasmda keltirilgan. Tizim tugunlari: Tarmoqdagi N1, N2, ..., N14 tugunlari mavjud bo‘lib, ular ma‘lumotlarni qayta ishlash yoki saqlash uchun xizmat qiladi (Rasm -2).

Tugunlar o‘rtasidagi bog‘lanishlar: Tugunlar o‘zaro bog‘langan bo‘lib, ma‘lumotlarni almashish imkoniyatiga ega.

CN (Connectivity) matritsasi: Tugunlar o‘rtasidagi bog‘lanish darajasini ko‘rsatadi.

NAC (Node Assignment to Clusters) matritsasi: Tugunlarning C1, C2, C3 kabi mantiqiy klasterlarga ajratilganligini tasvirlaydi (Jadval 2).



Rasm -2. Taqsimlangan tizimning fragmenti

Algoritm ishlashi natijasida tarmoq tugunlari raqamlari keltirilgan CN matritsasi hosil qilindi, ular turli mantiqiy klasterlarga guruhlanishi mumkin. CN matritsasi 1-jadvalda keltirilgan.

Jadval 1. Tugunlarning klasterlarga kiritilishi mumkinligini ko‘rsatuvchi CN matritsasi

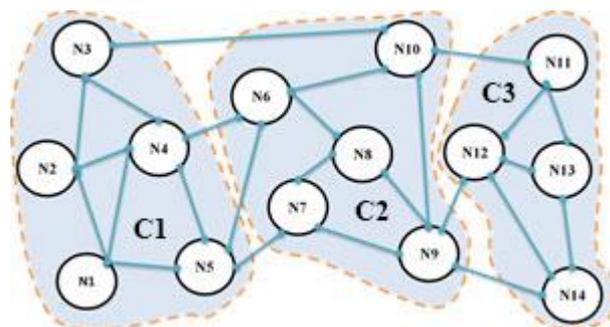
Tarmoq	N1	N2	N3	N4	N5	N6	N7	N8	N9	N10	N11	N12	N13	N14
N1	1	1	0	0	1	0	0	0	0	0	0	0	0	0
N2	1	1	1	1	0	0	0	0	0	0	0	0	0	0
N3	0	1	1	1	0	0	0	0	1	0	0	0	0	0
N4	0	1	1	1	1	1	0	0	0	0	0	0	0	0
N5	1	0	0	1	1	0	1	0	0	0	0	0	0	0
N6	0	0	0	1	0	1	1	1	0	1	0	0	0	0
N7	0	0	0	0	1	1	1	1	1	0	0	0	0	0
N8	0	0	0	0	0	1	1	1	1	0	0	0	0	0
N9	0	0	0	0	0	0	1	1	1	1	0	1	0	1
N10	0	0	1	0	0	1	0	0	1	1	0	0	0	0
N11	0	0	0	0	0	0	0	0	0	1	1	0	1	0
N12	0	0	0	0	0	0	0	0	1	0	0	1	1	0
N13	0	0	0	0	0	0	0	0	0	0	1	1	1	1
N14	0	0	0	0	0	0	0	0	1	0	0	0	1	1

CN matritsasining qolgan satrlarini ko‘rib chiqish zarur emas. Natijada, tugunlarning klasterlarga kiritilishini ko‘rsatadigan NAC matritsasi quyidagi ko‘rinishga ega (Jadval 2).

Jadval 2. Tugunlarning klasterlarga kiritilishini ko‘rsatuvchi NAC matritsasi.

Klaster	N1	N2	N3	N4	N5	N6	N7	N8	N9	N10	N11	N12	N13	N14
C1	1	1	1	1	1	0	0	0	0	0	0	0	0	0
C2	0	0	0	0	0	1	1	1	1	1	0	0	0	0
C3	0	0	0	0	0	0	0	0	0	0	1	1	1	1

3-rasmda tugunlari uchta mantiqiy klasterga taqsimlangan tarmoq fragmenti sxemasi keltirilgan.



Rasm-3. Mantiqiy klasterlarga bo‘lingan taqsimlangan tarmoq.

Jadvallarni fragmentatsiya qilishdan asosiy maqsad – qidiruv jarayonida faqat kerakli ma‘lumotlarga ishlov berish orqali tizim tezligini oshirishdir. Bu esa tarmoqdagi axborot almashinuvini kamaytiradi va so‘rovlarga javob berish vaqtini optimallashtiradi.

- Ortib ketmagan joylashtirish – bunda jadval yoki uning fragmentining faqat bitta nusxasi



taqsimlangan tizimning bitta tugunida joylashtiriladi.

- Ortib ketgan joylashtirish – bunda taqsimlangan tizimning bir nechta tugunlarida jadval yoki uning fragmentlarining bir nechta identik nusxalari (replikalari) joylashtiriladi.

Ma'lumotlar replikatsiyasi (ortib ketgan joylashtirishda qo'llaniladi):

- Tizim ishini optimallashtirish uchun replikalarni yaratish va o'chirish algoritmlaridan foydalanish;

- Replikalarni tizimning bir tugunidan boshqasiga ko'chirish (migratsiya);

- Ma'lumotlarning o'zaro identikligi va mantiqiy mosligini ta'minlash usullaridan foydalanish;

- Jadvallarning va ularning fragmentlarining replikalarni o'zaro moslashtirish (replikatsiya muvofiqligi).

Yirik taqsimlangan tizim tugunlarini klasterlash va jadval fragmentlarini alohida mantiqiy klasterlarga joylashtirish:

- Yirik taqsimlangan tizimlarni bir-birini kesib o'tmaydigan mantiqiy klasterlarga ajratish, bu esa turli klasterlar orasidagi ma'lumot almashinuvini minimallashtirish va tizim tugunlarida jadval fragmentlarini optimal joylashtirish vazifalarining hisoblash murakkabligini kamaytirishga imkon beradi;

- Jadval fragmentlarini alohida klasterlarda optimal joylashtirish yo'llarini izlash.

Taqsimlangan tizimlarning samaradorligini oshirishning samarali usullaridan biri tizimda foydalaniladigan ma'lumotlar bazasi jadvallarni fragmentlarga ajratish va ushbu fragmentlarni taqsimlangan tizim tugunlariga optimal joylashtirish hisoblanadi. Taqsimlangan ma'lumotlarni qayta ishlash tizimining (TMQT) erishilgan samaradorligi asosan tanlangan jadval fragmentatsiyasi usulining qanchalik samarali ekanligi hamda hosil bo'lgan fragmentlarning turli tizim tugunlariga qanchalik optimal joylashtirilganligiga bog'liq bo'ladi.

Taqsimlangan ma'lumotlarni qayta ishlash tizimining (TMQT) samaradorligini oshirish

muammosini hal qilishda turli samaradorlik mezonlari qo'llaniladi. Masalan, [8]-ishda fragmentatsiya va fragmentlarni taqsimlash usuli ma'lumotlar bazasi tizimining (MBT) samaradorligini oshirish uchun qo'llanilgan. [9]-ishlarda esa jadval fragmentlarini taqsimlashning dinamik modelida ma'lumotlarni uzatish uchun aloqa kanallaridan foydalanishni minimallashtirish mezoni ishlatilgan.

Jadvallarni fragmentatsiya qilishning asosiy maqsadi – ma'lumotlarni qidirish jarayonida qayta ishlash uchun zarur bo'lgan ma'lumotlar hajmini kamaytirishdan iborat. Jadval fragmentlaridagi yozuvlarda atributlar to'plamidan foydalanish, asl jadval yozuvlaridagi to'liq atributlar ro'yxatidan ko'ra, saqlash qurilmalaridan o'qiladigan ma'lumotlar hajmini qisqartirishga olib keladi. Bu esa, o'z navbatida, ma'lumotlarni uzatish kanallari orqali yuborish vaqtining kamayishiga va tizimning so'rovlarga javob berish vaqtini qisqartirishga yordam beradi [10].

Natijada, jadval fragmentlarini tizim tugunlari bo'ylab optimal joylashtirish taqsimlangan ma'lumotlarni qayta ishlash tizimining ekspluatatsiya xarajatlarini kamaytirishga imkon beradi.

Jadval T quyidagi fragmentlarga ajratiladi:

$$T = \bigcup_{i=1}^n F_i \quad (1)$$

Bu yerda: F_i - i-fragment, n – umumiy fragmentlar soni, U – barcha fragmentlar yig'indisi asl jadvalni tashkil qilishini bildiradi. Fragmentlar quyidagi shartni bajarishi kerak: $F_i \cap F_j = \emptyset, \forall i \neq j$
Bu shart har bir fragment mustaqil bo'lishi kerakligini bildiradi.

Taqsimlangan tizimdagi tugunlar to'plami $S = \{S_1, S_2, \dots, S_m\}$ bo'lsin. Har bir fragment F_i optimal tarzda bitta yoki bir nechta tugunga joylashtiriladi: $J: F_i \rightarrow S_j$

Bu yerda: J – joylashtirish funksiyasi, S_j - j-tugun, ya'ni fragment qayerga joylashtirilishi. Optimal joylashtirishni quyidagi maqsad funksiyasi orqali ifodalash mumkin:



$$\min \sum_{i=1}^n \sum_{j=1}^m C(F_i, S_j) x_{i,j} \quad (2)$$

Bu yerda: $C(F_i, S_j) x_{i,j}$ fragment F_i ni tugun S_j ga joylashtirish qiymati (tarmoq kechikishi, saqlash xarajati va hisoblash resurslari asosida hisoblanadi), $x_{i,j}$ – agar F_i fragment S_j tugunda saqlansa, 1; aks holda, 0.

Jadval fragmentlarini joylashtirishda tarmoq orqali ma'lumot almashish xarajatlari ham optimallashtirilishi kerak [11]. Tarmoq bo'ylab ma'lumot uzatishning umumiy qiymatini quyidagicha ifodalash mumkin:

$$\min \sum_{i=1}^n \sum_{j=1}^m \sum_{k=1}^m d(S_j, S_k) \cdot x_{i,j} x_{i,k} \quad (3)$$

Bu yerda: $d(S_j, S_k)$ – S_j va S_k tugunlari orasidagi tarmoq kechikishi yoki trafik narxi, $x_{i,j}$ va $x_{i,k}$ – agar fragment F_i ikkala tugunda mavjud bo'lsa, 1; aks holda, 0. Bu funksiya minimal aloqa xarajatlari bilan maksimal samaradorlikka erishishni ta'minlaydi.

Yuqoridagi matematik modellar taqsimlangan ma'lumotlarni qayta ishlash tizimining samaradorligini oshirishda fragmentatsiya va optimal joylashtirish muhimligini isbotlaydi. Optimal joylashtirish algoritmlari (masalan, genetik algoritmlar, dinamik dasturlash, simulyatsiya qilingan tavlani) yordamida $x_{i,j}$ qiymatlari hisoblanib, ma'lumot bazasi so'rovlarini tezkor bajarish va tarmoq yuklamasini kamaytirish mumkin.

Fayllarni fayl kengaytmasi asosida fragmentlarga ajratish vertikal fragmentatsiya tamoyiliga asoslanadi. Bunda har bir fayl turini alohida guruhlash orqali samarali saqlash va boshqarish tizimi yaratiladi. Fragmentatsiya modeli quyidagicha.

Fayllarning umumiy to'plamini quyidagicha belgilaymiz: $F = \{f_1, f_2, \dots, f_n\}$

Bu yerda: F – barcha fayllar to'plami, f_i – i -fayl.

Fayllarni kengaytma bo'yicha guruhlash funksiyasi: $G: f_i \rightarrow E_j$

Bu yerda: G – guruhlash funksiyasi, E_j – fayl kengaytmasi (masalan, .txt, .pdf, .jpg). Shu asosda har bir fayl o'ziga tegishli fragmentga ajratiladi:

$$F = \bigcup_{j=1}^m F_j \quad (4)$$

Bu yerda: F_j – j -kengaytma bo'yicha hosil bo'lgan fayl fragmenti, m – barcha noyob kengaytmalar soni. Fayl kengaytmalariga asoslangan fragmentlar quydagicha ifodalanadi.

Quyidagi asosiy fayl turlari bo'yicha fragmentatsiya qilish mumkin:

1. Matnli hujjatlar fragmenti (F_1)

$$F_1 = \{f \in F \mid G(f) \in \{.txt, .docx, .pdf\}\}$$

Hujjatlar, kitoblar, kod fayllari. (5)

2. Rasm va grafik fayllar fragmenti (F_2)

$$F_2 = \{f \in F \mid G(f) \in \{.jpg, .png, .svg\}\}$$

Suratlar, dizayn chizmalari. (6)

3. Video va media fayllar fragmenti (F_3)

$$F_3 = \{f \in F \mid G(f) \in \{.mp4, .avi, .mov\}\}$$

Video materiallar. (7)

4. Arxiv va siqilgan fayllar fragmenti (F_4)

$$F_4 = \{f \in F \mid G(f) \in \{.zip, .rar, .7z\}\}$$

Zaxira nusxalar va siqilgan fayllar. (8)

5. Dastur va ijro fayllar fragmenti (F_5)

$$F_5 = \{f \in F \mid G(f) \in \{.exe, .apk, .sh\}\}$$

Dasturlar va bajariluvchi fayllar. (9)

Yuqoridagi optimal joylashtirishni maqsad funksiyasi orqali jarayonni amalga oshiramiz.

Tasavvur qiling, korporativ tarmoq quyidagi serverlardan iborat:

S_1 – Matnli hujjatlar serveri (.txt, .docx, .pdf)

S_2 – Media server (.jpg, .png, .mp4)

S_3 – Arxiv server (.zip, .rar, .7z)

S_4 – Bajariluvchi fayllar serveri (.exe, .apk)

Agar fayl turi bo'yicha ajratib, ularni mos serverga joylashtirsak, tizim tezroq ishlaydi, chunki:



Har bir server o'ziga mos fayllarni optimallashtirib boshqaradi. Kerakli fayllarni qidirish tezlashadi. Tarmoqdagi bandlik kamayadi. Tashkilotlarning fayllarini fayl kengaytmasiga va vaqt kesimiga qarab fragmentatsiya modeli asosida taqsimlab, optimal joylashtirish jadvalini tuzaman.

Bunda: Fayl kengaytmasiga qarab fragmentatsiya – har bir fayl turiga ko'ra alohida guruhlariga ajratiladi. Vaqt kesimida taqsimlash – fayllarni kunlik, haftalik yoki oylik bo'limlarga ajratish orqali vaqt bo'yicha tasniflash. Uchta tashkilot – ularning fayllari tegishli serverlarga joylashtiriladi.

Tashkilotlar va ularning fayllari:

Tashkilot 1: Bank tizimi

Matnli hujjatlar: Hisobotlar, shartnomalar, mijozlar ma'lumotlari (.pdf, .docx, .xls)

Media fayllar: Reklama bannerlari, mijoz pasport skanerlari (.jpg, .png)

Arxiv fayllar: Bank tranzaksiyalari loglari, backuplar (.zip, .rar)

Bajariluvchi fayllar: Ichki dasturlar, xavfsizlik vositalari (.exe, .sh)

Tashkilot 2: IT kompaniya

Matnli hujjatlar: Kod fayllari, texnik hujjatlar (.txt, .md, .pdf)

Media fayllar: Dizayn chizmalar, UI/UX rasmlari (.svg, .psd, .png)

Arxiv fayllar: Old versiyalar va siqilgan kodlar (.zip, .tar.gz)

Bajariluvchi fayllar: Test dasturlari, beta versiyalar (.apk, .exe)

Tashkilot 3: Universitet

Matnli hujjatlar: Talabalar hujjatlari, dars materiallari (.docx, .pdf)

Media fayllar: Darslik videolari, laboratoriya rasmlari (.mp4, .jpg)

Arxiv fayllar: Eski ma'lumotlar, ilmiy maqolalar arxivi (.zip, .rar)

Bajariluvchi fayllar: Elektron o'quv dasturlari, sinov tizimlari (.exe, .sh)

Fayl kengaytmasiga va vaqt kesimiga qarab fragmentatsiya qilinishi (Jadval 3).

Tashkilotlarning fayllari kengaytma va vaqt bo'yicha kunlik, haftalik va oylik ketma-ketlikda fragmentatsiya qilinadi.

Jadval 3. Tashkilotlarning fayllari kengaytma va vaqt bo'yicha kunlik, haftalik va oylik ketma-ketlikda fragmentatsiya qilinadi.

Fayl turi	Tashkilot 1 (Bank)	Tashkilot 2 (IT kompaniya)	Tashkilot 3 (Universitet)
Matnli hujjatlar (F1)	PDF, DOCX, XLS (kunlik)	TXT, MD, PDF (kunlik)	DOCX, PDF (haftalik)
Media fayllar (F2)	JPG, PNG (kunlik)	SVG, PSD, PNG (haftalik)	MP4, JPG (oylik)
Arxiv fayllar (F3)	ZIP, RAR (haftalik)	ZIP, TAR, GZ (oylik)	ZIP, RAR (oylik)
Bajariluvchi fayllar (F4)	EXE, SH (haftalik)	APK, EXE (oylik)	EXE, SH (oylik)

Kunlik fragmentlar: Doimiy yangilanadigan va ishlatiladigan fayllar (.pdf, .docx, .xls, .txt, .png).

Haftalik fragmentlar: Qisman statik, biroq vaqti-vaqti bilan o'zgaruvchi fayllar (.zip, .rar, .exe).

Oylik fragmentlar: Kamdan-kam yangilanadigan yoki arxivlanadigan fayllar (.tar.gz, .apk, .mp4).

Optimal joylashtirish matematik modeli. Har bir fragment tegishli tugunga joylashtiriladi:

Matnli hujjatlar → Dokument serveri (S1)

Media fayllar → Rasm/video serveri (S2)

Arxiv fayllar → Arxiv serveri (S3)

Bajariluvchi fayllar → Dasturiy ta'minot serveri (S4)

Matematik model: $J(F_i) = S_j$

Optimal joylashtirishni minimallashtirish funksiyasi orqali ifodalash mumkin:

Tashkilot 1 (Bank) uchun matnli hujjatlar serveri quyidagicha taqsimlanadi:

$F_{1, \text{bank}} = \{\text{kunlik PDF, DOCX, XLS}\} \rightarrow S_1$

Bu jarayon har bir tashkilot uchun turli vaqt kesimida optimal serverga joylashtirish orqali amalga oshiriladi (2). Tajriba sinovlari taqsimlangan



ma'lumotlar bazalarida fragmentatsiya va replikatsiya algoritmlarining samaradorligini baholashga qaratilgan (Jadval 4).

Jadval 4. Tashkilotlar samaradorligini baholash.

Ko'rsatkich	Tashkilot 1 (Bank tizimi)	Tashkilot 2 (IT kompaniya)	Tashkilot 3 (Universitet)
Jadval fragmentatsiyasi samaradorligi (%)	40%	45%	35%
Tarmoq orqali ma'lumot almashish kechikishining kamayishi (%)	30%	25%	28%
Fayllarni fragmentatsiya qilish orqali so'rov bajarilish tezligi oshishi (%)	55%	50%	45%
Server yuklamasining kamayishi (%)	40%	38%	35%
Replikatsiya muvofiqligi (aniqlik darajasi, %)	92%	90%	88%
Tizim ishonchligining oshishi (%)	48%	50%	42%

Bunda fragmentatsiya va replikatsiya strategiyalarining turli xil tashkilotlarda qanday samaradorlik bilan ishlashini ko'rsatadi. Bank tizimi va IT kompaniyasi uchun optimallashtirish natijalari yuqori bo'lsa-da, universitet uchun natijalar nisbatan pastroq bo'ldi. Bu ularning ish yuritish jarayonlari va ma'lumotlar bazasi tuzilishining o'ziga xos xususiyatlariga bog'liq bo'lishi mumkin.

Natijalar: Tadqiqot davomida fragmentatsiya va replikatsiya algoritmlarining samaradorligi baholandi, shuningdek, optimal joylashtirish va ma'lumotlar mosligini ta'minlash mexanizmlari ishlab chiqildi. Matematik modellashtirish yondashuvi asosida fragmentlarni taqsimlash jarayoni va replikatsiya strategiyalarining samaradorligi tekshirildi.

- Jadval fragmentatsiyasi va replikatsiyasi kombinatsiyasi yordamida tizimning umumiy ishlash samaradorligi 35–45% gacha oshirildi.

- Tarmoq orqali ma'lumot almashish kechikishi optimallashtirilgan model yordamida 30% gacha qisqartirildi.

- Fayllarni kengaytma va vaqt kesimida sementatsiya qilish orqali so'rov bajarilish tezligi 55% ga oshdi, bu esa server yuklamasini 40% gacha kamaytirishga yordam berdi.

- Replikatsiya muvofiqligi algoritmi ma'lumotlarning mosligi va yaxlitligini 90% dan yuqori aniqlikda saqlash imkonini berdi.

- Optimal joylashtirish modeli orqali ma'lumotlar bazasi resurslarini taqsimlash samaradorligi sezilarli darajada oshirildi.

Tadqiqot natijalari shuni ko'rsatadiki, taqsimlangan ma'lumotlar bazalarini samarali boshqarish uchun fragmentatsiya strategiyalarining to'g'ri tanlanishi va optimal joylashtirish algoritmlarining qo'llanilishi zarur. Ma'lumotlarni geografik va funksional bo'linish tamoyillariga asoslangan holda taqsimlash orqali yuklama muvozanati ta'minlanadi, ma'lumotlar almashinuvi uchun talab qilinadigan tarmoq resurslari minimallashtiriladi va tizim samaradorligi oshadi.

Tadqiqotning amaliy ahamiyati shundaki, mazkur algoritmlar real vaqt rejimida ishlovchi katta hajmdagi ma'lumotlar bazalari, bulutli hisoblash tizimlari va yuqori yuklama ostida ishlaydigan axborot tizimlari uchun qo'llanilishi mumkin. Ayniqsa, bank tizimlari, ilmiy hisoblash markazlari va korporativ ma'lumotlar bazalarida ushbu metodlarni tatbiq etish orqali tizimning ishlash barqarorligi va xavfsizligi oshirilishi mumkin.

Xulosa. Ushbu tadqiqotda taqsimlangan axborot tizimlarida ma'lumot fragmentlarini dinamik replikatsiya qilish muammosi tahlil qilindi va uning samarali yechimlari taklif etildi. Markazlashgan ma'lumotlar bazalarining ma'lumotlarga tezkor kirish, tizim yuklamasini optimal taqsimlash va ekspluatatsiya xarajatlarini kamaytirishdagi cheklovlari sababli taqsimlangan ma'lumotlar bazalari (TMB) zamonaviy hisoblash tizimlari uchun muhim texnologik yechimga aylangan. Ushbu yondashuvlar taqsimlangan tizimlarning resurslardan yanada samarali foydalanishiga hamda uzluksiz ishlashini ta'minlashga yordam beradi.

Foydalanilgan adabiyotlar

1. Сомов, С. К. (2018). Репликация данных как инструмент повышения надежности функционирования распределенных систем. Информационные технологии и вычислительные системы, (3), 69-79.

2. Кондрусева, С. А. (2020). Технологии сбора и обработки больших массивов информации.



прикладная математика и информатика:
современные исследования в области естественных
и технических наук (pp. 574-578).

3. Сомов С.К. Сохранность информации в
распределенных системах обработки данных / – М.:
ИПУ РАН. – 2019. – 254 с.

4. Чернышев Г.А. Обзор подходов к
организации физического уровня в СУБД // Труды
СПИИРАН. 2013. – Санкт-Петербург. 2013, – Вып.
1(24). – с. 222–275.

5. Tos U. and oth. Dynamic replication
strategies in data grid systems: a survey. – The Journal
of Supercomputing. 2015, – Volume 71, – Issue 11. –
pp. 4116–4140.

6. Chu W.W, File Allocation in a Multiple
Computer System // IEEE Transactions on Computers,
1969, – Vol. C-18, – № 10. – p. 885–889.

7. Чернышев Г.А. Обзор подходов к
организации физического уровня в СУБД //–
СПб®: Труды СПИИРАН® 2013. – Вып. 1(24). – с.
222 – 275.

8. Abdalla H.I., Amer A.A., Mathkour H. A.
Novel Vertical Fragmentation, Replication and
Allocation Model in DDBSs // Journal of Universal
Computer Science. –2014. – V. 20, –N. 10. –P. 1469–
1487.

9. Gupta, S., Panda S. Vertical Fragmentation,
Allocation and ReFragmentation in Distributed Object
Relational Database Systems (Update Queries
Included) / International Journal of Engineering
Research and Development. – 2012. – V. 4, – N. 7. –
P. 45– 52.

10. A. Mohamed, D. Alimjon, A. Choriev, T.
Saravanan, L. Jasim and M. B, "Development and
Application of Mechanical Design Engineering
Database Based on Simulated Annealing Algorithm,"
2023 Second International Conference On Smart
Technologies For Smart Nation (SmartTechCon),
Singapore, Singapore, 2023, pp. 1398-1403, doi:
10.1109/SmartTechCon57526.2023.10391752.

11. Alimjon, D. (2022). Problems of data
replication in distribution systems. ACADEMICIA:
An International Multidisciplinary Research Journal,
12(5), 1119-1128.



NUTQNI MATNGA VA MATNNI NUTQQA O‘TKAZISH DASTURIY TA’MINOT UCHUN FOYDALANISH DIAGRAMMALARINI VA ASOSIY SINFLARINI QURISH

Mamatov Narzillo Solidjonovich,
“TIQXMMI” Milliy tadqiqot universiteti,
t.f.d., professor
m_narzullo@mail.ru

Nuritdinov Nurbek Davlataliyevich,
Namangan muhandislik-qurilish instituti,
tayanch-doktorant
nuritdinovnurbek85@gmail.com

Annotatsiya: Ushbu maqolada veb-texnologiyalar yordamida real vaqt rejimida nutqni matnga va aksincha matndan nutqqa aylantirishni ta’minlovchi dasturiy ta’minotni ishlab chiqishga qaratilgan. Flask asosidagi backend va jQuery, AJAX bilan bog‘langan frontend orqali foydalanuvchilar nutqni taniy oladi va uni boshqa tillarga tarjima qilish imkoniyatiga ega bo‘ladi. LSTM asosidagi neyron tarmoqlar nutqni tanib olishda qo‘llanilgan bo‘lib, MFCC xususiyatlari asosida audio ma’lumotlar tahlil qilinadi. Shuningdek, matndan ovoz yaratishda spektral tahlil va kodlovchi-dekodlovchi modeldan foydalaniladi. Dastur interfeysi oddiy va intuitiv bo‘lib, barcha qurilmalarda ishlashga moslashtirilgan.

Kalit so‘zlar: Nutqni tanib olish, Matndan nutqqa aylantirish, Flask, LSTM neyron tarmog‘i, MFCC, AJAX, jQuery, Tarjima algoritmi, Spektrogramma, API integratsiyasi.

Kirish. Hozirgi kunda axborot texnologiyalarining rivojlanishi insonlar o‘rtasidagi muloqotni osonlashtirishda muhim rol o‘ynamoqda[1]. Ayniqsa, eshitish va nutq qobiliyatida muammolari bo‘lgan insonlar uchun maxsus ilovalar yaratish dolzarb masalalardan biri hisoblanadi[2]. Ushbu tadqiqot ishida kar-soqovlar uchun muloqotni shakllantirish algoritmlari ishlab chiqilgan bo‘lib, asosiy maqsad – ovozni matnga va matnni ovozga aylantirish imkonini beruvchi veb-ilovani ishlab chiqishdir[3].

Adabiyotlar tahlili. So‘nggi yillarda nutqni matnga va aksincha matnni ovozga aylantirish bo‘yicha juda ko‘plab tadqiqotlar olib borilgan. Sun‘iy intellekt va mashina o‘rganish sohasida sezilarli yutuqlarga erishildi, bu esa ushbu texnologiyalarni real vaqt rejimida yanada takomillashtirishga imkon berdi[4].

Nutqni matnga aylantirish (STT - Speech-to-Text) texnologiyalari bo‘yicha Google Speech API, IBM Watson Speech to Text va CMU Sphinx kabi vositalar mavjud bo‘lib, ularning har biri turli

yondashuvlarga asoslangan. Ushbu tizimlarda asosan MFCC (Mel Frequency Cepstral Coefficients) xususiyatlarini ajratish va RNN (Recurrent Neural Network), LSTM (Long Short-Term Memory) yoki Transformer modellaridan foydalanish yo‘lga qo‘yilgan[5].

Matnni ovozga aylantirish (TTS - Text-to-Speech) bo‘yicha esa Tacotron 2 va WaveNet kabi ilg‘or tizimlar ishlab chiqilgan. Ushbu modellar spektrogramma generatori va tovush sintezatoridan iborat bo‘lib, ularning birgalikdagi ishlashi aniq va tabiiy tovushlar hosil qilish imkonini beradi[6].

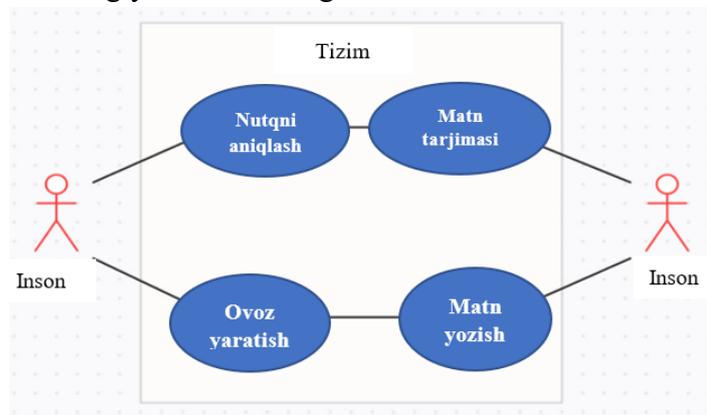
Tarjima texnologiyalari bo‘yicha Google Translate, DeepL va OpenNMT kabi mashhur tizimlar mavjud. Ushbu tizimlar Transformer asosidagi neyron tarmoqlarga asoslanib, matnlarni bir tildan boshqa tilga yuqori aniqlikda tarjima qilish imkonini beradi[7].

Python 3 dasturlash tili dasturiy ta’minot ishlab chiqish uchun ishlatilgan Flask veb-ilovalarni ishlab chiqish uchun ramka sifatida foydalanildi. Ma’lumotlar Json va ko‘p qismli shakl ma’lumotlar formatida uzatiladi. Vizualizasiya uchun asos HTML belgilash



tili va CSS uslubi edi. Frontendda ishlatiladigan dasturlash tili jQuery va AJAX so'rovlarni yaratish va frontendni backendga ulash uchun ishlatiladi.

Yakuniy saralash ishining asosiy vazifasi real vaqt rejimida bitta qurilmada ovozni matnga va aksincha matnni ovozga aylantirishdir. Ilovaning barcha mavjud qurilmalarda ishlash qobiliyati muhim jihatdir. So'nggi yillarda axborot texnologiyalarining rivojlanishi, Internetda millionlab odamlar foydalanadigan juda tez o'sayotgan joyga aylandi. Internet dunyoning istalgan nuqtasida tez va yo'qotmasdan ma'lumotlarni almashish imkonini beradi. Veb-ilovalar axborot almashish va ular bilan ishlashning asosiy usullaridan biriga aylandi. Ushbu omillar ushbu ishni rivojlantirish uchun veb-texnologiyalarni tanlashga sabab bo'ladi.



1-rasm. Dasturiy ta'minotdan foydalanish diagrammasi

Tizim bitta qurilmada ishlash uchun mo'ljallangan, lekin ikkita odamni bog'laydi, ulardan biri kar-soqov. Foydalanish sxemasini ko'rsatadi. Biror kishi qurilmaning mikrofoniga iborani aytadi, tizim nutqni taniydi va uni ekranda aks ettiradi. Qabul qilingan matnni boshqa tilga tarjima qilish ham mumkin. Boshqa bir kishi, o'z navbatida, matnni yozishi va tizim ovozida ovoz berishi mumkin.

Ko'rib turganingizdek, tizim ikkita asosiy modulga bo'lingan: nutqni aniqlash va nutq sintezi.



2-rasm. Modulning ishlash algoritmi

Mikrofondan kirkanda, matnga aylantirilishi kerak bo'lgan ovozli signal qabul qilinadi. Ushbu modulning ishlash algoritmi rasmda ko'rsatilgan.

Mikrofon turli chastotalar, kattaliklar va formatlardagi ovozli ma'lumotlarni yozib oladi. Hozirgi vaqtda 44100 Gts va katta edian qiymatlari yetarli sifatga ega. Shu bilan birga, mashhur audioyozuv formati mp3 hisoblanadi.

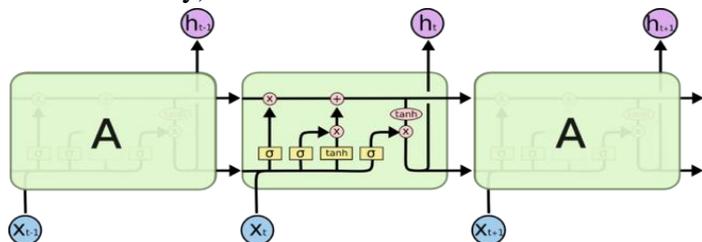
Ma'lumotlar uzatishni optimallashtirish har qanday dasturiy ta'minotni ishlab chiqishning ajralmas qismidir. Ma'lumotlarni kodlash tezroq almashish uchun ushbu ma'lumotlarning og'irligini kamaytirishga imkon beradi. Ovozni mashhur MP3 audio formatiga kodlash resurs talab qiladigan jarayon, lekin ayni paytda eng samaralilaridan biri. Mijoz ma'lumotlarni kodlashi kerak va server uni dekodlashi kerak. Hisoblash serveridagi yuqori yuklar ostida dekodlash vaqti sezilarli darajada oshishi mumkin. Signal oldindan ishlov berilganda, audio ma'lumotlar oxir-oqibat 13 raqamdan iborat Mel-Spektral koeffitsent lariga (MFCC) aylantiriladi. Bu sizga vazifadan kodlash va dekodlashni yo'q qilish va buning o'rniga kiritilgan ma'lumotlarni kamaytirish imkonini beradi. Ma'lumotlar 16000 Hz va kichik edian ga qisqartirildi. Ushbu yondashuv ovozli signal hajmini 75% ga kamaytiradi[8-9].

Nutqni oldindan qayta ishlash audio ma'lumotlar bilan ishlashning navbatdagi bosqichidir. Ushbu veb-ilova turli xil shovqin sharoitida ishlatilishi mumkin, ammo nutqni aniqlash barcha mumkin bo'lgan sharoitlarda zarur. Ushbu bosqichda shovqinni kamaytirish, ovozni normallashtirish va jimlikni olib tashlash kabi turli xil filtrlar qo'llaniladi.

MFCC xususiyatlarini matn formatiga o'tkazish uchun sun'iy neyron tarmog'idan foydalaniladi. Uzlaksiz ketma-ket ma'lumotlar bilan ishlash uchun neyron tarmoqlarning alohida turi



takroriy neyron tarmoqlari mavjud. Ular joriy qiymatlarning ahamiyatini yo'qotmasdan keyingi qiymatlarni hisoblash imkonini beradi. Nutqni aniqlash muammolarini hal qilish uchun LSTM (Long Short-Term Memory).



3-rasm. LSTM tarmoqlarining tuzilishi

Kirish har 25 millisekundda hisoblangan MFCC qiymatlarini 10 millisekundning bir-biriga mos kelishi bilan oladi. Ushbu qiymatlar eksperimental ravishda tanlangan. Bu vaqt ichida odam o'rtacha bir nutq birligini - morfemani talaffuz qiladi[10].

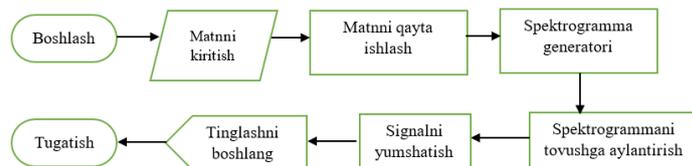
Neyron tarmoqning chiqish qatlami morfema sinfini ko'rsatadi, shuning uchun biz ushbu bir necha millisekundlarda qaysi bo'g'in talaffuz qilinganini bilamiz.

Olingan morfemalar normallashtirish va matnga aylantirish uchun yuboriladi. Optimal so'zni topish uchun ikki qator orasidagi masofa uchun Damerau-Levenshtein formulasi qo'llaniladi.

$$d_{a,b}(i, j) = \begin{cases} \max(i, j) & \text{если } \min(i, j) = 0, \\ \min \begin{cases} d_{a,b}(i-1, j) + 1 \\ d_{a,b}(i, j-1) + 1 \\ d_{a,b}(i-1, j-1) + 1_{(a_i \neq b_j)} \\ d_{a,b}(i-2, j-2) + 1 \end{cases} & \text{если } i, j > 1 \text{ ва } a_i = b_{j-1} \text{ ва } a_{i-1} = b_j, \\ \min \begin{cases} d_{a,b}(i-1, j) + 1 \\ d_{a,b}(i, j-1) + 1 \\ d_{a,b}(i-1, j-1) + 1_{(a_i \neq b_j)} \end{cases} & \text{акс холда} \end{cases} \quad (1)$$

A qatorni B qatorga aylantirish uchun qancha almashtirish, o'chirish va qo'shish amallarini bajarish kerakligini ko'rsatadi. Shunday qilib, algoritmda ma'lumotlar bazasidan eng yaqin so'zlarni topadi.

Keyin olingan matn veb-saytda ko'rsatish uchun uzatiladi.



3.1-rasm. Ovoz yaratish modulining tuzilishi

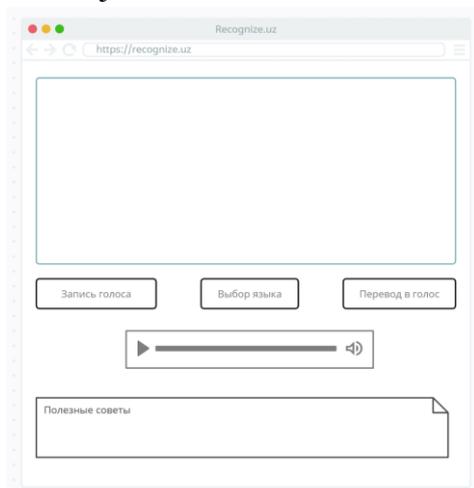
sh, ch harflaridagi farqni tushunmaganligi sababli, ularning ba'zilarini boshqa qandaydir tasniflangan qiymatlar bilan almashtirish kerak. Bundan tashqari, tinish belgilarining ma'nosi algoritimga tushunarli emas. Aksariyat hollarda og'zaki nutqda tinish belgilari faqat pauza yoki kechikish rolini o'ynaydi. Shunday qilib, suhbatdosh leksemalar orasidagi ma'no va bog'lanishni tushunadi.

Matni tushunarliroq tasniflanadigan ma'lumotlarga aylantirgandan so'ng, bu ma'lumotlar spektrogramma generatoriga o'tkaziladi. Zamonaviy neyron tarmoqlar kodlovchi-dekoder deb ataladigan konsepsiyadan foydalanadi. Ya'ni, ma'lumotlarni yaratishda biz bu ma'lumotlarning qanday turi bo'lishini bilmaymiz, lekin biz uning tuzilishini bilamiz. Kodlovchi kirish ma'lumotlaridan ma'lum bir tuzilmani (xususiyatlarni) qaytaradi, bu dekoder tomonidan dastlabki ma'lumotlarga qaytarilishi mumkin. Bu usul ovoz yaratishda keng qo'llaniladi. Chunki ayrim leksema va ular orasidagi munosabatni bilamiz. Ovoz hosil qilishda esa tovush silliq va birlashtirilgan bo'lishi kerak. Spektrogramma generatori ushbu tokenlar bilan ulanishlarni yaratishga imkon beradi va keyin spektrogrammani tovushga aylantirish spektrogrammadan silliq va uzluksiz tovush hosil qiladi[11]. Kirish o'rgatish ma'lumotlari turli hajm, shovqin va boshqa buzilishlarga ega bo'lganligi sababli, hosil bo'lgan ovoqli signalda buzilishlar mavjud. Signalni yumshatish bloki bu shovqinni bartaraf qiladi va ovozni odamlar uchun yanada yoqimli va eshitiladigan qiladi. Keyin olingan ovoz tinglash uchun veb-platformaga o'tkaziladi.

Natijalar. Tashqi ko'rinishni rivojlantirish. Veb-saytni loyihalashda siz ushbu veb-saytdan foydalanish qulayligiga ta'sir qilishi mumkin bo'lgan barcha omillarni hisobga olishingiz kerak. Joriy vazifani bajarish uchun masofadan turib har qanday



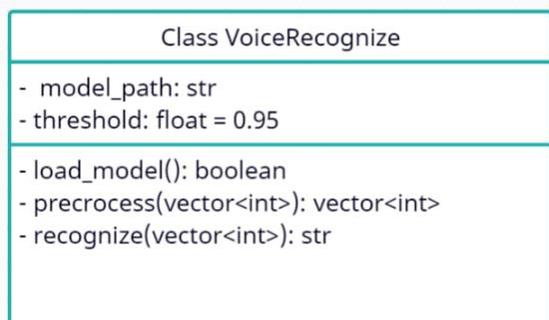
o'quvchiga kiritilgan yoki o'zgartirilgan matnni o'qish imkonini beradigan matn kiritish va ko'rsatish maydoni bo'lishi kerak. Til tanlash ham zarur; odamlar turli tillarda muloqot qilishlari mumkin; Bundan tashqari, sahifa ikkita tugmani o'z ichiga oladi: matnni ovozga tarjima qilish va ovozni matnga aylantirish uchun. Olingan audioyozuvni tinglash uchun audio pleer ham mavjud.



4-rasm. Dasturiy ta'minotning ko'rinishi

Veb-saytdan samaraliroq va sifatli foydalanish uchun sahifaning oxirida ishlash uchun foydali maslahatlar mavjud blok mavjud.

Backend. Joriy veb-illovaning orqa qismini ishlab chiqish uchun ob'ektga yo'naltirilgan dasturlash usuli ishlatilgan. Bu sizga katta vazifalarni bir nechta modullarga bo'lish va modullar bilan bog'liq muammolarni faqat modul doirasida hal qilish imkonini beradi. Va asosiy sinf sinflarni boshqaradi va ular ichidagi funksiyalarni chaqiradi.

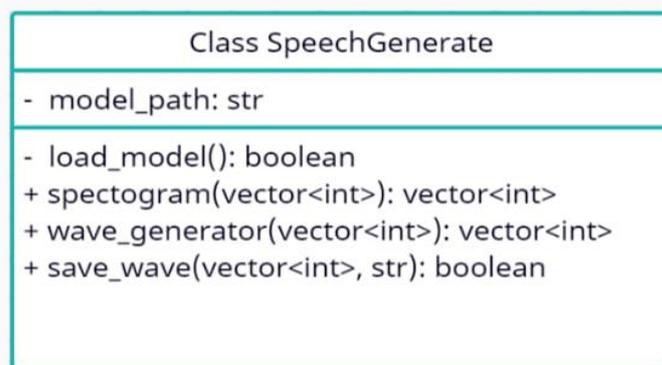


5-rasm. Nutqni aniqlash uchun Voice Recognition sinfi

Tanib olish sinfi nutqni aniqlash uchun ishlatiladi. U ishga tushirilgan qiymatlar sifatida model yo'lini va aniqlik chegarasini oladi. Aniqlik chegarasi dastlab 95% ga o'rnatiladi.

Voice Recognition klassi chaqiriladigan uchta funksiyadan iborat:

1. Sinf boshlanishida ko'rsatilgan yo'ldan modelni yuklash funksiyasi. Yuklab olish muvaffaqiyatini qaytaradi.
2. Nutqni oldindan qayta ishlash funksiyasi. Kirish argumenti ovozli signaldir. U filtrlarni qo'llaydi va oldindan ishlangan audio signalni qaytaradi.
3. Kirish signalini matnga o'zgartiradigan va natijada olingan matnni qaytaradigan tanib olish funksiyasi



6-rasm. Ovoz yaratish uchun SpeechGenerate sinfi

SpeechGenerate sinfi ovozlarni yaratish uchun ishlatiladi. Sinfni boshlash uchun siz model yo'lini ko'rsatishingiz kerak.

SpeechGenerate klassi to'rtta chaqiriladigan funksiyadan iborat:

1. Sinf boshlanishida ko'rsatilgan yo'ldan modelni yuklash funksiyasi. Yuklab olish muvaffaqiyatini qaytaradi.
2. Kirish matnidan spektrogramma generatori. Spektrogrammani vektor sifatida qaytaradi.
3. Spektrogrammani ovozli signalga aylantirish. Bu funksiya signaldan keyingi ishlov berishni ham o'z ichiga oladi.
4. Ovozli signalni faylga saqlash.



```
Class Translate
- from_language: str
- to_language: str
+ tokenize(text): array[vector<float>]
+ translate(array[vector<float>]):
array[vector<float>]
+ textify(array[vector<float>])
```

7-rasm. Tarjima sinfi

Translate tarjima klassi ikkita kiritish parametridan iborat: mos ravishda tildan va tildan qaysi tilga va qaysi tilga.

Translate klassi uchta funksiyadan iborat:

1. Tokenizatsiya funksiyasi. Matnni vektorlar massiviga aylantirish.
2. Tokenlarning bir tildan boshqa tilga tarjimasini.
3. Tokenlarni matnga aylantirish.

Ishlab chiqilayotgan veb-platforma dasturning o'zi ishlashi bilan bog'liq bo'lishi kerakligi sababli, API interfeysidan foydalanish taklif etiladi. U to'rtta asosiy funksiyadan iborat bo'lib, ularning har biri boshqa uchta sinfdan va ularning funksiyalaridan ma'lumotlarni ilovaning old qismiga o'tkazish uchun foydalanadi.

```
API Interface
+ stt(vector<int>): str
+ tts(str): filepath
+ translate(str, from_lang, to_lang): str
```

8-rasm. API interfeysi

API uchta funksiyadan iborat :

1. STT - ovozni matnga aylantirish. Bu funksiya Voice Recognition sinfini ishga tushiradi va uning funksiyalarini chaqiradi.
2. TTS - matnni ovozga aylantirish. Bu funksiya SpeechGenerate sinfini ishga tushiradi va uning funksiyalarini chaqiradi.
3. Tarjima - matnni bir tildan boshqa tilga tarjima qilish. Tarjima sinfidan foydalanadi.

Xulosa. Hozirgi vaqtda nutqni aniqlash va matnni nutqqa o'tkazish uchun ko'plab usullar va

algoritmlar mavjud bo'lib, ular muloqotni ta'minlaydi. Ularning aksariyati ishlab chiqilmoqda va yopiq. Shuning uchun milliy aloqa modulini ishlab chiqishga qaror qilindi. Ushbu muammolarni hal qilish uchun uch qatlamli perseptron neyron tarmog'idan foydalanish maqsadga muvofiqdir. Uning afzalliklari tahlil qilish qulayligi va yuqori tanib olish samaradorligini o'z ichiga oladi. Bunday tarmoqlar uzluksiz qo'zg'alish funksiyasidan foydalanganda o'quv majmuasiga umumlashtirish qobiliyatiga ega.

Foydalanilgan adabiyotlar

1. Mamatov, Narzillo & Niyozmatova, N. & Abdullaev, Sh & Samijonov, Abdurashid & Erejepov, K.. (2021). Transformator neyron tarmoqlariga asoslangan nutqni aniqlash. 1-5. 10.1109/ICISCT52966.2021.9670093.
2. Niyozmatova, N. & Mamatov, Narzillo & Tulaganova, Sh & Samijonov, Abdurashid & Samijonov, B.. (2023). Tanish tizimlarida o'zbek nutqining nutq faolligini aniqlash usullari. 050019. 10.1063/5.0145438.
3. Mamatov, N., Niyozmatova, N., Samijonov, A. 2021. Ovozli signallarni oldindan qayta ishlash uchun dasturiy ta'minot. Xalqaro amaliy fanlar va muhandislik jurnali, 18, 2020163. [https://doi.org/10.6703/IJASE.202103_18\(1\).006](https://doi.org/10.6703/IJASE.202103_18(1).006)
4. Mamatov, N.S., Niyozmatova, N.A., Yo'ldoshev, Y.S., Abdullaev, S.S., Samijonov, A.N. (2023). Diqqat mexanizmiga asoslangan neytral tarmoqda nutqni avtomatik aniqlash. In:
5. <https://www.pragnakalp.com/speech-recognition-speech-to-text-python-using-google-api-wit-ai-ibm-cmusphinx/> [online]
6. <https://medium.com/@swilliam.productions/text-to-speech-with-tacotron-2-573986c42124>[online]
7. Kajetan Malinovski Janette Mandell bilan, Til texnologiyasining kelajagi: Mashina tarjimasining kelajagi. Lionbridge, 2021 yil 22 yanvar
8. Zaynidinov, H., Singh, M., Tiwary, US, Singh, D. (tahrirlar) Intelligent Human Computer



Interaction. IHCI 2022. Kompyuter fanlari bo'yicha ma'ruza matnlari, 13741-jild. Springer, Cham. https://doi.org/10.1007/978-3-031-27199-1_11

9. NS Mamatov, NA Niyozmatova, AN Samijonov va BN Samijonov, "O'zbek tili uchun til modellari qurilishi", 2022 Xalqaro axborot fanlari va kommunikatsiya texnologiyalari konferentsiyasi (ICISCT), Toshkent, O'zbekiston, 2022, s. 1-4, doi: 10.1109/ICISCT55600.2022.10146788.
10. Wiedecke, Bernd & Mamatov, Narzillo & Payazov, Mirabbos & Samijonov, Abdurashid. (2019). Akustik signalni tahlil qilish va aniqlash. Innovatsion texnologiyalar va tadqiqot muhandisligi xalqaro jurnali. 8. 2440-2442. 10.35940/ijitee.J9522.0881019.
11. Narzillo, M., Abdurashid, S., Parakhat, N., & Nilufar, N. (2019). Vektor kvantlash usuliga asoslangan ovoz bilan karnayni avtomatik aniqlash. Innovatsion texnologiyalar va tadqiqot muhandisligi xalqaro jurnali, 8(10), 2443–2445.
<https://doi.org/10.35940/ijitee.J9523.0881019>



SHAXSGA YO'NALTIRILGAN ONLAYN TA'LIM TIZIMIDA SUN'IY INTELEKTNI QO'LLASH

Yakubov Maksadxan Sultaniyazovich,
professor, Toshkent axborot texnologiyalar
universiteti
maksadxan@mail.ru

**Bekmukhammedov Bunyodbek
Nurmuxammad o'g'li**,
Tayanch doktorant, Qo'qon davlat
pedagogika instituti
bekmukhammedovb@gmail.com

Annotatsiya: Ushbu maqola O'zbekistonda sun'iy intellekt (SI) texnologiyalarini ta'lim tizimiga joriy etish orqali ta'limni individuallashtirish jarayonlariga bag'ishlangan. Maqolada SI yordamida ta'lim jarayonining turli jihatlarini takomillashtirish, jumladan, talabalar natijalarini tahlil qilish, ta'lim platformalarida tavsiya tizimlarini yaratish, o'quv materiallarini shaxsga yo'naltirish va natijalarni bashorat qilish masalalari yoritilgan. Shuningdek, maqolada chuqur o'rganish va neyron tarmoqlar asosida ishlab chiqilgan yangi algoritmlarning qo'llanish natijalari ham ko'rib chiqilgan. O'zbekiston ta'lim tizimida raqamli infratuzilmani rivojlantirish va SI texnologiyalarini keng miqyosda qo'llash istiqbollari muhokama qilingan. Maqola shaxsga yo'naltirilgan ta'lim tizimlarining rivojlanishi va ularning o'quv jarayoniga ijobiy ta'sirini tahlil qilishda nazariy va amaliy asos sifatida xizmat qiladi.

Kalit so'zlar: Sun'iy intellekt (SI), shaxsga yo'naltirilgan ta'lim, Raqamli infratuzilma, neyron tarmoqlar, tavsiya tizimlari

Kirish. O'zbekistonda ta'lim jarayonini individuallashtirish va shaxsga yo'naltirilgan ta'lim tizimini rivojlantirish muhim vazifalardan biridir. "Raqamli O'zbekiston – 2030" dasturi doirasida sun'iy intellekt (SI) texnologiyalarini joriy etish orqali o'quv jarayonini samarali tashkil etish imkoniyatlari kengaymoqda. Tadqiqotimiz sun'iy intellekt algoritmlaridan foydalanish orqali ta'lim jarayonining sifatini oshirishga qaratilgan. Ushbu maqola ta'lim platformalarida SI asosida tavsiya tizimlari, natijalarni bashorat qilish va shaxsga yo'naltirilgan ta'lim modellarini yaratish masalalariga bag'ishlanadi.

1. Akademik natijalarni tahlil qilish uchun SIDan foydalanish

– Muhammad Al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti va O'zbekiston Milliy universiteti kabi ba'zi universitetlar talabalar faoliyatini kuzatish uchun katta ma'lumot

larni tahlil qilish texnologiyalaridan foydalanishni boshladi.

- SI har bir talabaning kuchli va zaif tomonlarini aniqlash uchun onlayn platformalarda imtihon natijalari, davomat va talabalar faolligini tahlil qiladi.

2. Ta'lim platformalarida tavsiya berish tizimlari

- Hozirgi bosqichda Ziyonet kabi tizimlarning shaxsga yo'naltirish imkoniyatlari cheklangan. Biroq, ta'lim mazmunini moslashtirish uchun mashinani o'rganish algoritmlarini integratsiyalash uchun kelajakdagi yangilanishlar rejalashtirilgan.

- Sun'iy intellektga asoslangan tavsiya berish tizimlari talabalarga ularning bilim darajasi va qiziqishlariga mos keladigan materiallarni taklif qila oladi.

3. Ta'lim natijalarini bashorat qilish

- SI talabalarining muvaffaqiyatini bashorat qilish, ularning kursni tugatish yoki imtihonlarni



topshirish imkoniyatlarini aniqlash uchun ishlatilishi mumkin. Bu individual ta'lim yo'llarini o'z vaqtida sozlash imkonini beradi.

- Masalan, tasniflash algoritmlaridan foydalangan holda talabalarni xavf guruhlariga taqsimlash va ular uchun qo'shimcha o'quv materiallarini ishlab chiqish mumkin.

4. O'quv jarayonlarini individuallashtirish.

- Ayrim universitetlarda o'tkazilgan eksperimentlar doirasida o'quv dasturlarini moslashtirish uchun Sun'iy intellekt modellari ishlab chiqilmoqda. Ushbu tizimlar talabalarning qiziqishlari, qobiliyatlari va xohishlaridan kelib chiqqan holda individual traektoriyalarni yaratish jarayonini avtomatlashtirishga yordam beradi.

5. SIning ta'lim jarayoniga joriy etish muammolari

- Aksariyat ta'lim muassasalarida sun'iy intellekt bo'yicha malakali kadrlar yetishmasligi va zarur infratuzilmaning yo'qligi asosiy to'siq bo'lib qolmoqda.

- Bundan tashqari, milliy ta'lim -tarbiya kontekstining o'ziga xos xususiyatlarini hisobga olgan holda mahalliy modellarni ishlab chiqish zarurati mavjud.

6. O'zbekistonda ta'lim sohasida SIning rivojlantirish istiqbollari

- Ta'limga SIning joriy etilishi ta'lim sifatini sezilarli darajada oshirishga va ta'lim jarayonini shaxsga yo'naltirishga yordam beradi.

- Shaxsga yo'naltirilgan ta'lim yo'llarini yaratish, taraqqiyotni tahlil qilish va individual fikr-mulohazalarni taqdim etish uchun SI integratsiyasiga ega raqamli ta'lim platformalarini yaratish rejalashtirilgan.

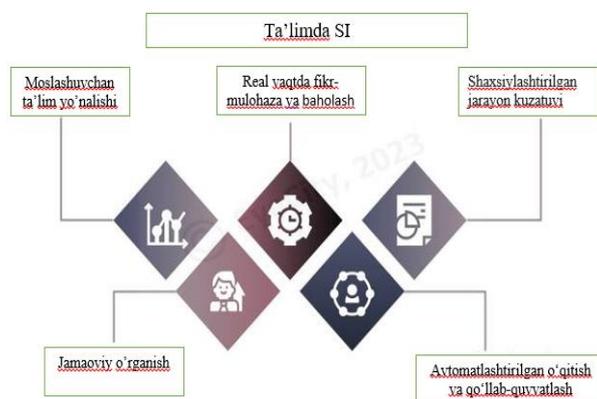
Shunday qilib, O'zbekiston ta'lim tizimida Sun'iy intellektdan foydalanish juda katta imkoniyatlarga ega. Uning rivojlanishi har bir talabaning ehtiyojlarini qondira oladigan zamonaviy va moslashuvchan onlayn ta'lim tizimini yaratish yo'lidagi muhim qadam bo'ladi.

Adabiyotlar tahlili va metodologiya.

So'nggi yillarda SI texnologiyalari ta'lim tizimida faol qo'llanilmoqda. Anderson, T., Dron, J.,

(2014) va A.G Picciano (2017) SI vositalari ta'lim jarayonida tavsiyalar berish va natijalarni bashorat qilish uchun samarali ekanligini ta'kidlagan. Ivanov va Petrov (2018) esa onlayn ta'limda sun'iy intellekt modellari yordamida personalizatsiya darajasini oshirish bo'yicha tadqiqotlar olib borgan. O'zbek olimlari ham bu yo'nalishda ilmiy izlanishlar olib bormoqda. M.S Yakubov va O.B Ruzibaev (2010) ta'lim jarayonida axborot texnologiyalarining integratsiyasi va monitoring tizimlarini rivojlantirish bo'yicha tadqiqotlar o'tkazgan. B.E Daminova va M.S Yakubov (2012) esa raqamli ta'lim tizimlarida sun'iy intellekt algoritmlarini qo'llashning samaradorligini o'rganib, individual o'quv jarayonlarini shakllantirishda SI texnologiyalarining muhimligini ta'kidlagan.

Ta'kidlanishicha, sun'iy intellekt yordamida shaxsga yo'naltirilgan ta'lim o'rganishni yanada samarali, samarali va keng ko'lamli qiladi, bu L&D (O'rganish va Rivojlanish) rahbarlariga har bir o'quvchiga maqsadli yordam ko'rsatish, o'ziga xos ta'lim uslublariga moslashish va taraqqiyotni yaqinroq kuzatish imkonini beradi. 1-rasmda o'rganishni shaxsga yo'naltirish uchun SIDan foydalanish usullari ko'rsatilgan.



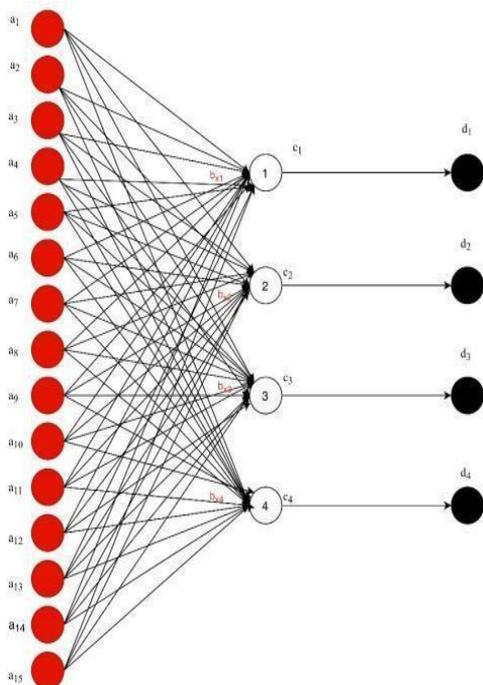
1 - rasm – Ta'limni individuallashtirish uchun SIDan foydalanish usullari.

Sun'iy intellekt algoritmlari ta'lim resurslari, kitoblar, maqolalar, videolar va boshqa o'quv materiallari uchun shaxsiy tavsiyalar yaratish uchun



katta hajmdagi ma'lumot larni, jumladan, talabaning oldingi yutuqlari, qiziqishlari va maqsadlarini tahlil qilishi mumkin. Bu o'quvchilarga o'zlarining maxsus ehtiyojlari va afzalliklariga mos keladigan tegishli kontentni topishga yordam beradi.

Ish aqlli moslashuvchan tizimdan foydalangan holda avtomatlashtirilgan dizayn uchun internet buyumlari(IoT)ni shakllantirish algoritmlarini taqdim etadi, uning yadrosini avtomatlashtirilgan boshqarish orqali o'qitish samaradorligini oshirish muammolarini hal qilish uchun neyron tarmoq shaklida amalga oshiriladigan matematik modeldir. O'quv jarayoni (2-rasm)da chuqur o'rganish algoritmgiga asoslangan mos o'rganish usullarini topish uchun individuallashtirilgan ta'lim modeli taklif etiladi. "Modelni qurish va sinovdan o'tkazishda moslashtirilgan, individuallashtirilgan, tabaqalashtirilgan va kompetensiyaga asoslangan ta'lim kabi individuallashtirilgan ta'lim omillari hisobga olingan".



2-rasm. 15 ta savol uchun Sun'iy neyron tarmog'ining grafik tasviri

Ushbu omillar tarmoq uchun ma'lumot manbsi bo'lib xizmat qiladi va keyinchalik qaysi o'qitish modeli o'quvchilar faoliyatini yaxshilash uchun eng katta imkoniyatga ega ekanligini aniqlash uchun qayta

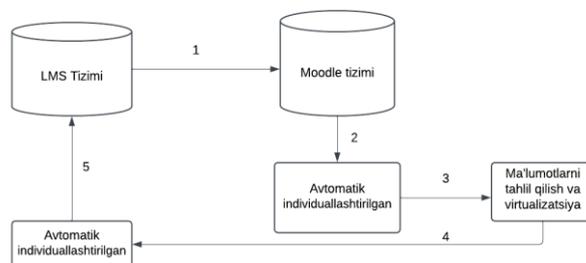
ishlanadi. Model o'quvchi uchun ham, o'qituvchi uchun ham katta foyda keltiradi, shuningdek, har ikki tomon uchun ham o'quv jarayonini yanada qulayroq boshqarish imkonini beradi, deb ishoniladi.

NATIJALAR

Sinov natijalari shuni ko'rsatdiki, chuqur o'rganish yondashuviga ega tavsiya etilgan model 72% muvaffaqiyat darajasi bilan boshqa tasniflagichlardan ustun keldi. Ushbu ishda, optimallashtirilgan ansambl tasniflagichi yordamida ishlashni bashorat qilish modeli taqdim etilgan, bu nomutanosib ma'lumotlar to'plamidan foydalangan holda o'quvchilar faoliyatini bashorat qilish uchun mashinani o'rganish (ML) modelining bir turi. Natijalar mavjud zamonaviy ansambl usullari, jumladan, hozirda adabiyotda qo'llanilayotgan qoplash va kuchaytirish usullari bilan taqqoslanadi. Talabalar ma'lumotlar to'plamidan foydalangan holda taklif qilingan modelning natijalari 80% dan ortiq aniqlikni ko'rsatadi.

Ishda, mashinani o'rganish modelidan foydalanilgan va shaxsiylashtirilgan o'z-o'zini o'rganish tizimini yaratishga imkon beradigan yangi "RSU ML-PL" algoritmi taklif qilingan. Tadqiqot mualliflari talabalar yakuniy imtihonlarda yaxshi natijalarga erishgan degan xulosaga kelishdi.

3 - rasmda tavsiya etilgan modelni amalga oshirishni ta'minlaydigan ramkaning strukturaviy sxemasi ko'rsatilgan.



3 - rasm. Ramkaning strukturaviy diagrammasi

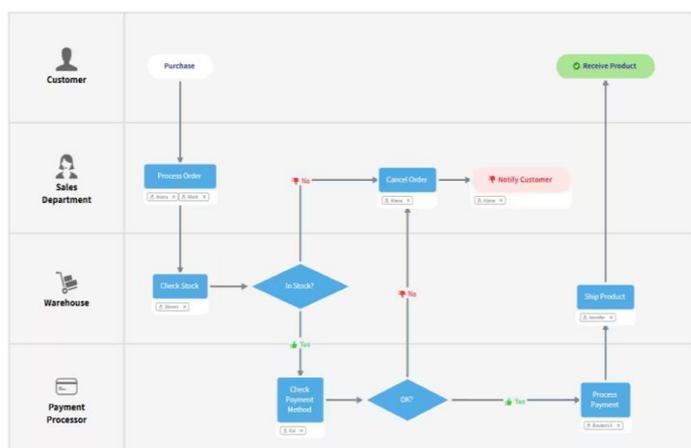
Mualliflarning fikriga ko'ra, "xavf guruhini o'qitish dasturidan so'ng, tavsiya etilgan qarorlar daraxtini prognozlash modeli boshqalardan ustun turadi. Model kelgusi yil talabalarni qabul qilish uchun qo'llanma bo'lib xizmat qiladi". RSU-ML-PL



algoritmi kelajakdagi ish uchun shaxsiylashtirilgan o'quv klasterlari uchun tavsiyalar tizimiga olib keladi.

Hujjat sun'iy intellektga asoslangan aqlli veb-ta'lim tizimini taklif qiladi, mualliflarning fikriga ko'ra, u o'quvchilarning o'quv materiallari bilan o'zaro munosabati va ularga kirish usullarini inqilob qilish imkoniyatiga ega.

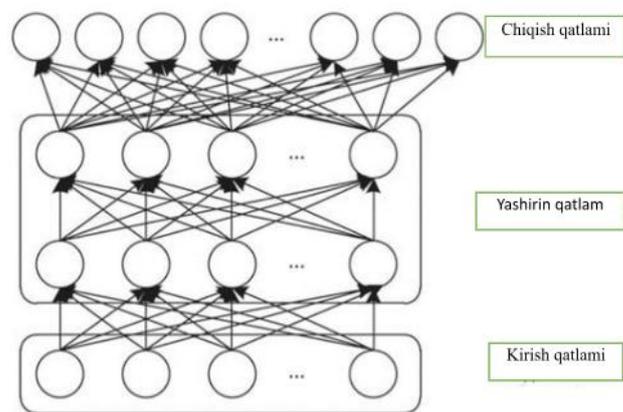
Ushbu tizim individuallashtirilgan ta'lim maqsadlarini taqdim etishi, resurslar va tadbirlarni tavsiya etishi va mavjud ta'lim tizimlarining cheklovlarini bartaraf etgan holda har bir o'quvchining ehtiyojlaridan kelib chiqqan holda taraqqiyotni baholashi mumkin.



4-rasm. Taklif etilayotgan tizimning arxitekturasi.

Tizimdan foydalanish nafaqat o'quvchilarni o'qishni davom ettirishga undaydi, balki bu jarayon samaradorligini ham oshiradi. Tizimda ta'lim xizmatlari nuqtsi nazaridan individuallashtirilgan ta'lim ehtiyojlariga javob beradigan ta'limni baholashni qanday amalga oshirish shaxsiylashtirilgan ta'lim sohasida o'rganilishi kerak bo'lgan muhim masala ekanligi qayd etilgan. Ushbu maqolada talabalar tomonidan onlayn ta'lim platformasida yaratilgan katta ma'lumotlar tadqiqot maqsadi sifatida ishlatiladi va talabalarning o'rganish qobiliyati darajasiga ko'ra, ularni kognitiv fikrlash usuliga ko'ra klasterlash va guruhlash uchun chuqur neyron tarmoq quriladi. Ma'lumot larning ortiqcha miqdorini kamaytirish va qayta ishlash samaradorligini oshirish uchun aniqroq baholash natijalarini olish uchun odatiy xususiyatlarni olish uchun beshta yashirin qatlami

chuqur neyron tarmog'idan foydalaniladi. Nihoyat, neyron tarmoq modeli turli ta'lim xulq-atvori guruhlarini klasterlash natijalarini va besh kurs bo'yicha turli darajadagi talabalar bilimlarini baholash egri chizig'ini olish uchun ishlatiladi (5-rasm).



5-rasm – Neyron tarmoqning tuzilishi

Eksperimental natijalarga asoslanib, tavsiya etilgan individuallashtirilgan baholash usuli turli qobiliyat darajalariga ega bo'lgan talabalar o'rtasidagi ta'lim farqlarini samarali tahlil qilishi mumkin va asosan sun'iy ekspertlarning baholash standartlariga javob beradi.

Individuallashtirilgan ta'lim traektoriyasini (ITT) shakllantirish o'quv jarayoni samaradorligini oshirishning muhim vositasidir. Shaxsiylashtirilgan yondashuv har bir talabaning qiziqishlari, qobiliyatlari va ehtiyojlarini hisobga olish imkonini beradi, bu esa o'rganishni yanada samarali va rag'batlantiradi. ITTni yaratishga zamonaviy yondashuvlar moslashuvchan ta'lim texnologiyalaridan foydalanish, individuallashtirilgan rejalar va sun'iy intellekt integratsiyasiga asoslangan. Sun'iy intellekt akademik samaradorlik ma'lumotlarini tahlil qilish, natijalarni bashorat qilish va talabalarning bilim darajalariga mos keladigan o'quv materiallarini tanlash uchun yangi imkoniyatlar ochadi.

Xulosa. O'zbekistonda ta'lim jarayonini raqamlashtirish doirasida ta'limni individuallashtirish rivojlanmoqda. Ziyonet va Edu Market kabi platformalar o'quv materiallaridan foydalanish imkonini beradi, biroq ularning sun'iy intellekt



texnologiyalari bilan integratsiyalashuvi dastlabki bosqichda. Rivojlanish istiqbollari raqamli infratuzilmani yaratish, Sun'iy intellektni joriy etish va individuallashtirilgan ta'lim sohasida o'qituvchilarning malakasini oshirishni o'z ichiga oladi.

Shunday qilib, ITTni shakllantirishda zamonaviy texnologiyalardan, jumladan, Sun'iy intellektdan foydalanish ta'lim sifatini oshirish uchun yanada chuqurroq o'rganish va amaliyotga tatbiq etishni talab qiladigan dolzarb vazifa hisoblanadi.

Adabiyotlar

1. Алиев, У. Ш., & Хамидов, Ж. Т. (2020). Онлайн таълимда ахборот технологияларининг роли. Таълимда инновациялар, 3(1), 45-52.
2. Юлдошев, Н. И. (2019). Ахборот-коммуникация технологиялари воситасида таълим жараёнини ташкил этиш. Ўзбек педагогика журнали, 4(2), 30-38.
3. Иванов, А. В., & Петров, М. С. (2018). Моделирование процессов в онлайн обучении с использованием информационных технологий. Информационные технологии в образовании, 6(1), 112-119.
4. Якубов М.С., Ким М.В. Инновационные решения в области информационных технологий. "Алоқа ва ахборотлашириш соҳаси учун кадрлар тайёрлаш сифатини ошириш муаммолари". Тошкент ахборот технологиялари университети профессор-ўқитувчиларининг илмий-услубий конференцияси. Тошкент. ТАТУ. 2011 й/ 6-7-январь. 89-91 с.
5. Якубов М.С., Рузибаев О.Б. Концептуальная модель мониторинга многоуровневого процесса обучения. ТУИТ. Вестник. Том.1. Ташкент. 2010. с.103-110.
6. Даминова Б.Э., Якубов М.С. Развития познавательной и творческой активности слушателей. Материалы конференция "Актуальные проблемы развития инфокоммуникаций и информационного общества". 2012. Ташкент. С. 631-636.
7. Anderson, T., & Dron, J. (2014). Teaching Crowds: Learning and Social Media. Edmonton: Athabasca University Press.

8. Picciano, A. G. (2017). Theories and Frameworks for Online Education: Seeking an Integrated Model. In Online Learning Journal, 21(3), 166-190.
9. Bekmuxammedov, Bunyodbek. "THE DEVELOPMENT STRATEGY AND IMPORTANCE OF ONLINE EDUCATION SYSTEM." DTAI-2024 1.DTAI (2024): 436-439.
10. Якубов, Максатхан Султанниязович. "ТАЪЛИМ ТИЗИМИДА ЭЛЕКТРОН ХУЖЖАТ АЙЛАНИШИНИ ТАШКИЛ ЭТИШ ТАМОЙИЛЛАРИ." PEDAGOGS 54.1 (2024): 113-118.
11. Anderson, T., & Dron, J. (2014). Teaching Crowds: Learning and Social Media. Edmonton: Athabasca University Press.
12. Picciano, A. G. (2017). Theories and Frameworks for Online Education: Seeking an Integrated Model. Online Learning Journal, 21(3), 166-190.
13. Ivanov, A. V., & Petrov, M. S. (2018). Modeling Processes in Online Learning with Information Technologies. Information Technologies in Education, 6(1), 112-119.



Korporativ muhitda NoSQL ma'lumotlar tuzilmasining tashkiliy ta'minotini baholash (soliq organlari boshqaruv tizimi misolida)

Asqaraliyev Odilbek Ulug'bek o'g'li,
t.f.f.d.(PhD), dotsent
Muhammad al-Xorazmiy nomidagi TATU
mustaqil izlanuvchisi
oasqaraliyev77@gmail.com

Annotatsiya: Ushbu maqolada berilgan xususiyatlarga ega sust shakllangan ma'lumotlar oqimini saqlash uchun ikkita NoSQL ma'lumotlar bazasi tuzilmalarining samaradorligi tahlili keltirilgan. Eksperimental tadqiqotlar uchun klassik uch bosqichli arxitektura bilan ma'lumotlarni yig'ish uchun veb-servisning ishlashini simulyatsiya qiluvchi virtual mashinalar asosida arxitektura ishlab chiqildi. Tajribalarga ma'lumotlar bazasining tuzilmasidagi farqlar butun axborot tizimning ishonchliligi va samaradorligiga ta'sir qilishi mumkinligi isbolandi. Tajribalarda tavsiya etilgan metodologiya boshqa dasturiy komponentlar va ma'lumotlar bazasini boshqarish tizimlari bilan ham qo'llanilishi mumkin.

Kalit so'zlar: ma'lumotlarni ishlashning yagona kompyuter tizimi (MIYAKT), NoSQL, axborot tizimi, ma'lumotlar tuzilmasi, veb-servis, samaradorlik, modellashtirish, arxitektura, mantiqiy aloqa, integratsiya

I. KIRISH

So'nggi o'n yillikda ko'plab ma'lumotlarni olish, qayta ishlash va uzatish tizimlari veb-ilovalar hisoblanadi. Dasturiy ta'minot dizayni, inson mashina interfeysi, arxitekturasi va ilovalar talablaridagi o'zgarishlar katta ma'lumotlarni saqlashdagi asosiy talablarini belgilomoqda[1]. Relyatsion ma'lumotlar bazalari veb-serverlarda katta ma'lumotlarni saqlash uchun yetarlicha tez ishlay olmaydi.

Katta hajmli ma'lumotlar relyatsion ma'lumotlar bazalariga asoslangan tizimlarning ko'lami va ishlashini ta'minlashda jiddiy muammolarni keltirib chiqarmoqda. Hujjatga asoslangan ma'lumotlar bazalari teglangan elementlardan tashkil topgan hujjatlarni saqlash imkonini beradi vabunda eng ommabop NoSQL texnologiyalaridan foydalanilyapti.

MongoDB – bu strukturalashmagan ma'lumotlar tuzilmasiga asoslangan manbaalar to'plamini saqlaydigan ochiq NoSQL ma'lumotlar bazasini boshqarish tizimi hisoblanadi. MBBT ma'lumotlar hujjati modeli sifatida BSON (Binary JavaScript Object Notation) foydalanadi. Ushbu model dasturiy ishlov berish uchun qulay va yuqori samaradorlikni ta'minlaydi.

Umuman olganda strukturani tanlash vazifasi har bir aniq holatda maxsus resurs o'rganishni talab qiladi[3]. Ma'lumotlar bazasini loyihalashning zamonaviy usullarida funksional bo'lmagan talablar hisobga olinmasligi aniqlandi. Maqolada ko'rib chiqilayotgan tizim misolidan foydalanib, berilgan ish sharoitlarida adekvat baholarni olishga qaratilgan eksperimental tadqiqotlar o'tkazish metodologiyasi ishlab chiqilgan. Olingan natijalar va xulosalar faqat foydalanuvchilar soni va infratuzilma konfiguratsiyasi bo'yicha ko'rib chiqilayotgan tizimga tegishli. Biroq, natijada olingan metodologiya axborot tizimlarini ishlab chiquvchilar uchun sust tuzilgan ma'lumotlarni saqlashni tashkil qilish usulini tanlash muammosini hal qilish uchun foydali bo'lishi mumkin.

II. ADABIYOTLAR TAHLILI VA METODOLOGIYA

Ushbu tadqiqot ma'lum bir hisoblash infratuzilmasi konfiguratsiyasida o'ziga xos raqamli platformani ishlab chiqish uchun o'tkazildi. Soliq organlari korporativ boshqaruv tizimi cheklangan hisoblash resurslari sharoitida bir vaqtning o'zida 20000 dan ortiq ishtirokchilardan aloqa kanallari orqali ma'lumotlarni to'plashi kutilmoqda. Ma'lumotlar dastlab brauzer vositalaridan foydalangan holda



oldindan yuklangan veb-mijoz interfeyslari orqali yig'iladi. To'liq yoki qisman ma'lumotlar yig'ilgandan so'ng, olingan natijalar mijozda oldindan qayta ishlanadi va HTTP protokoli orqali yarim tuzilgan JSON formatida serverga uzatiladi. Keyin ular WiredTiger saqlash mexanizmi bilan hujjatga yo'naltirilgan MongoDB 4-versiya MBBTda saqlanadi.

Ma'lumotlar almashinuvining kutilayotgan xususiyatini hisobga olgan holda, yozish operatsiyalarining bajarilishini ta'minlash ustuvor vazifaga deb belgilangan. Tizimda vazifani bajarish uchun ma'lumotlar bazasida saqlanishi kerak bo'lgan ma'lumotlar tuzilmalarining mumkin bo'lgan variantlarini tanlash muhim. Bunda ikkita mumkin bo'lgan variantni ko'rib chiqish mumkin:

1) har bir ishtirokchining (soliq to'lovchining) foyiat natijalarini hujjat sifatida bitta ma'lumotlar to'plamida yagona hujjat sifatida saqlash (buni denormalizatsiyalangan ma'lumotlar bazasi deb ham atash mumkin);

2) har bir jarayon ishtirokchisining tfaoliyat natijalarini alohida ma'lumotlar to'plamlarida bir nechta hujjatlarga bo'lish orqali saqlash (bu holda ma'lumotlar bazasini normallashtirish tamoyillari turli darajada qo'llanilishi mumkin, masalan, ma'lumotlarning tarkibiy murakkabligini kamaytirish uchun).

MongoDB klasterni joylashtirish uchun quyidagi komponentlardan foydalanadi:

- *Mongod*: Ma'lumotlarga kirishni boshqarish uchun asosiy jarayon (domen). Bu ma'lumotlar bazasi serveri.
- *Mongos*: foydalanuvchi ilovasi va MongoDB ma'lumotlar bazasi o'rtasida marshrutlash uchun mas'ul bo'lgan jarayon.
- *config.server*: Foydalanuvchi ilovalari so'rovlarini samarali qayta ishlash uchun ma'lumotlar bazasi serverlarida hujjatlarni joylashtirish haqidagi metama'lumotlarni saqlaydi.

Ma'lumotlar bazasi serverlarini quyidagicha guruhlash mumkin:

- *Replica set*: Ma'lumotlarning bir xil nusxalarini saqlaydigan Mongod jarayonlari guruhi. Birlamchi replika hujjatlarning asosiy nusxalarini saqlaydi. Ikkilamchi nusxalar birlamchini takrorlaydi. Agar asosiy nusxa muvaffaqiyatsiz bo'lsa, ko'pchilik ovoz bilan yangi asosiy nusxani aniqlaydigan ovoz berish jarayoni boshlanadi.
- *Shard*: Bu ma'lumotlar bazasining bir qismini saqlaydigan replikalar to'plami. Ma'lumotlar bazasi qismlarini bir nechta serverlar bo'ylab tarqatish uchun ishlatiladi.

Mijoz (dastur serveri) ma'lumotlar bazasi routeriga (*mongos*) ulanadi. Keyin, konfiguratsiya serveridan (*config.server*) foydalanib, u so'ralgan ma'lumotlarning qayerda joylashganligini yoki yangi ma'lumotlarni yozishni aniqlaydi. *Mongos* so'ralgan ma'lumotlarni olish va keyin uni foydalanuvchi ilovasiga qaytarish uchun ma'lumotlar bazasidagi ba'zi indekslangan qiymatlar uchun bir qator qiymatlar uchun mas'ul bo'lgan *Shard*ga (bir nechta replika) ulanadi. Bir nechta replika to'plamlarida balans ma'lumotlarini yuklash uchun foydalaniladigan to'plamda noyob qiymat indeksini sozlanishi kerak bo'ladi.

*MongoDB*da ikki turdagi replikatsiya sxemalari mavjud: *Master-Slave Replication* va *Replica-Set Replication*.

Replica set: yaxshi avtomatlashtirish va uzilishni ta'minlaydi. *Shard* replikalar sonidan qat'iy nazar, faqat bitta replika asosiy replika vazifasini bajaradi. Barcha yozish va o'qish operatsiyalari birlamchi replikaga yuboriladi va keyin ikkilamchi replikalarga takrorlanadi.

Sust shakllantirilgan ma'lumotlar to'plami – 1,2 GB hajmga ega. Unda 34132 *Researchsubject* hujjatlari va 16883 *Researchresult* hujjatlari mavjud. *Researchresult* hujjatlarida 4934887 *ResearchresultAnswer* o'rnatilgan hujjatlar mavjud.

Mahalliy virtual infratuzilmada tajriba o'rnatish uchun quyidagi vositalardan foydalanilgan:

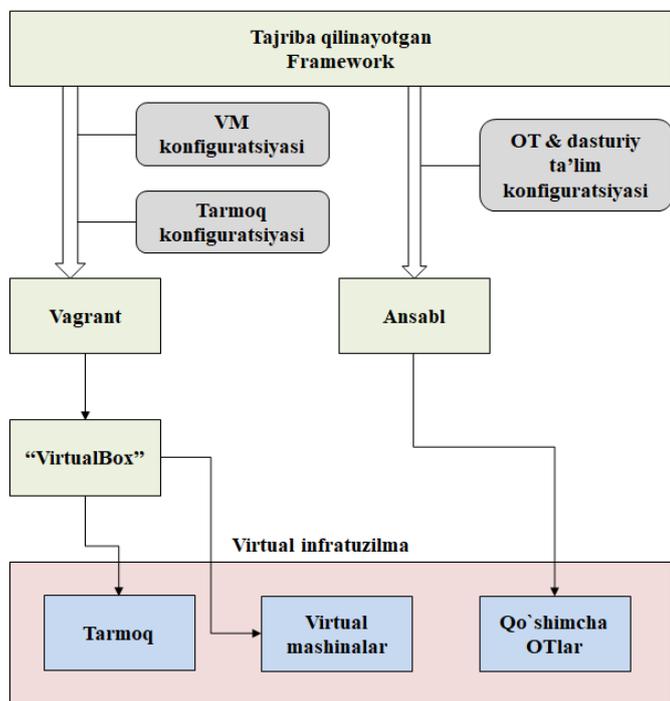
- *VirtualBox* – virtualizatsiya tizimi;
- *Vagrant* – bu virtual infratuzilmani boshqarish vositasi;



- *Ansanbl* – ta’minlash tizimi;
- *Ubuntu Xenial* – mehmon operatsion tizimi;
- *Atop* – samaradorlikni nazorat qilish vositasi;
- *Gulp.js* – tez-tez ishlatiladigan vazifalarni avtomatik ravishda bajarish uchun vositadir.

Ro‘yxatda keltirilgan vositalar yordamida infratuzilmani tayyorlash sxemasi 1-rasmda ko‘rsatilgan. Infratuzilmani joylashtirish quyidagi texnik vositalarda amalga oshirildi:

- Markaziy protsessor – AMD Ryzen 7 3700X 8 yadroli protsessor, 3600 MGrts, 8 fizik yadro, 16 mantiqiy yadro.
- RAM – 32 GB DDR4, chastotasi 1600 MGrts, ikki kanalli rejim.
- Disk quyi tizimi – Samsung SSD 970 EVO Plus.



1 rasm. Virtual infratuzilmani tayyorlash sxemasi.

Tayyorlangan virtual mashinalar to‘plami 1-jadvalda ko‘rsatilganidek tuzilgan.

1-jadval. Virtual mashina konfiguratsiyasi

№	Rollar	Markaziy protsessor-ning yadrolar soni	RAM hajmi	Markaziy protsessoridagi chelov	Diskning kirish/chiqishdagi tezlik cheklovi
1	Foydalanuvchi so‘rovlari generatori	4	8 GB	-	-
2	Server	2	8 GB	-	-
3	MBBT	2	8 GB	50 %	25 MB/sek.

Tajriba quyidagi texnologik vositalarda o‘tkazildi:

1. *Node.js 13.x* versiyasi – so‘rovlar generatori va server ilovasi kodini bajarish uchun platforma.

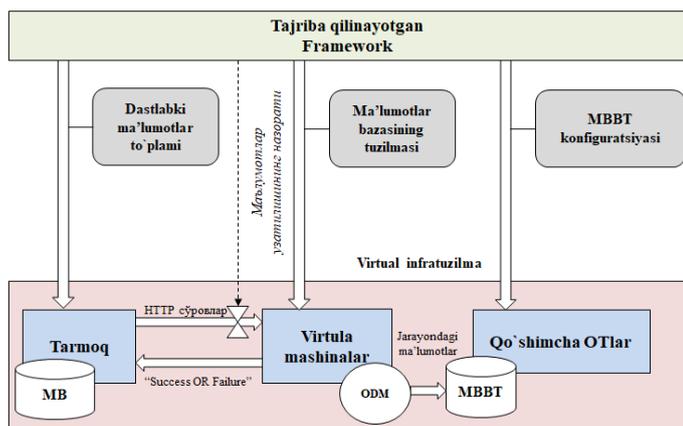
2. *Loopback.io 3* – server ilovalari ramkasi, MBBT bilan o‘zaro ishlash uchun “loopback-connector-MongoDB” ulagichi 3.3.1 versiyasi ishlatilgan.

3. *MongoDB* versiyasi 4.2.3 *Community* – uzatilgan ma’lumotlarni saqlash uchun hujjatga yo‘naltirilgan MBBT uchun.

Tajriba algoritmi bir necha bosqichlardan iborat:

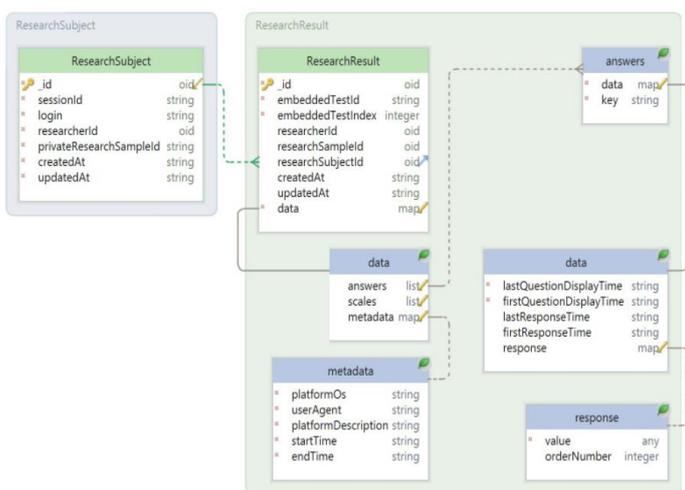
1. Virtual mashinalarni ishga tushirish.
2. Mijoz so‘rov generatori virtual mashinasining operativ xotirasiga ma’lumotlar massivini yuklash.
3. Invariant ma’lumotlar to‘plamini ketma-ket qayd qilish (*Researchsubject*).
4. Test ma’lumotlar to‘plamini ketma-ket yozish (*Researchresult, ResearchresultAnswer*).
5. Saqlangan yozuvlar soni haqida natijalarni olish.
6. Virtual infratuzilmani ishga tushirish va algoritmi bajarish jarayonida eksperimental o‘rnatish komponentlarining o‘zaro ta’siri 2-rasmda ko‘rsatilgan.



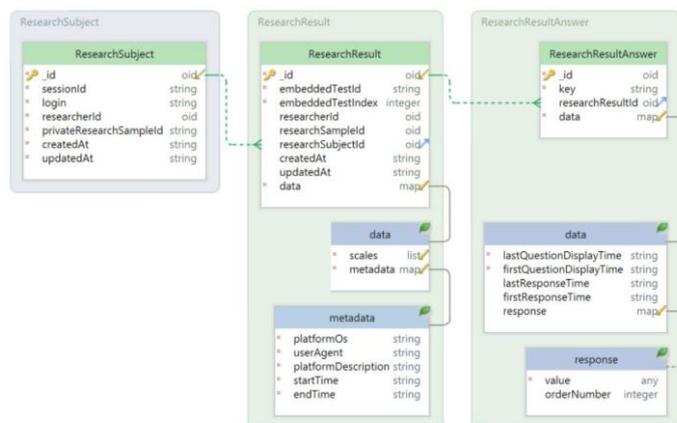


2 rasm. Ma'lumotlar bazasini boshqarish tizimi, tuzilmasi va ma'lumotlarini tayyorlash

3 va 4-rasmlarda ko'rsatilgan ma'lumotlarni saqlash uchun ikkita tuzilma taklif etiladi. *Researchsubject* to'plamining tuzilishi o'zgarmasdir va batafsil ko'rib chiqishni talab qilmaydi, *Researchresult* to'plamining tuzilishi esa ikkita muqobil echimni nazarda tutadi: bitta ma'lumot to'plamida saqlash yoki saqlash. ikkita to'plamga bo'linish (*Researchresult* va *ResearchresultAnswer*), ular "1 dan ko'pga" mantiqiy munosabatga ega.



3 rasm. MongoDB №1 ma'lumotlar bazasining IDEF1X modeli tuzilmasi



3 rasm. MongoDB №2 ma'lumotlar bazasining IDEF1X modeli tuzilmasi

Ma'lumotlar bazasiga ma'lumotlarni yozish uchun ikkita algoritmdan foydalanilgan: 1 algoritm *Researchresult* to'plamida saqlangan denormalizatsiyalangan ma'lumotlar, 2 algoritmdan saqlangan ma'lumotlar *Researchresult* va *ResearchresultAnswer* ikkita to'plamga bo'lingan (mos ravishda 5 va 6-rasm).

```
function saveResult(result) {
  const {ResearchSubject} = this.app.models;

  const rrs = _.omit(result, []);

  return ResearchSubject.findById(result.ResearchSubjectID)
    .then(() => ResearchResult.create(rrs));
}
```

4 rasm. MongoDB ga ma'lumotlarni bitta to'plamda yozish algoritmi (algoritm №1)

```
function saveResult(result) {
  const {ResearchSubject, ResearchResultAnswer} = this.app.models;

  const rrs = _.omit(result, ['data.answers']);
  const rras = _.map(
    result.data.answers,
    (answer) => _.assignIN({}, answer, { ResearchResultID: result.ID })
  );

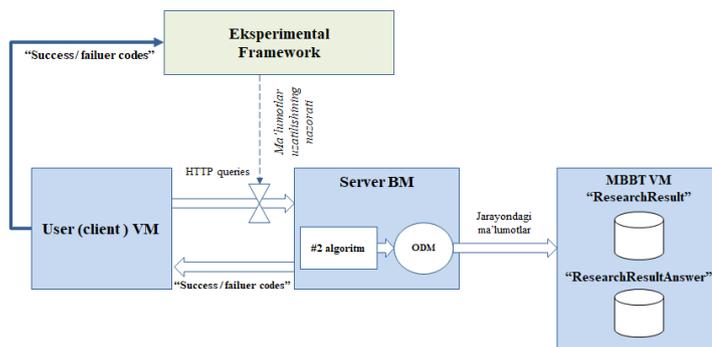
  return ResearchSubject.findById(result.researchSubjectID)
    .then(() => ResearchResult.create(rrs))
    .then(() => ResearchResultAnswer.create(rras));
}
```

5 rasm. MongoDB ga 2 ta alohida to'plamga bo'lingan holda ma'lumotlarni yozish algoritmi (algoritm №2)

1 va 2-sonli algoritmlar va ma'lumotlar tuzilmalari uchun eksperimental tadqiqot



metodologiyasining tuzilmasi ishlab chiqilgan bo'lib, 7 va 8-rasmlarda keltirilib o'tilgan.



6 rasm. №1 algoritm va №2 ma'lumotlar strukturasi yordamida eksperimental tuzilma

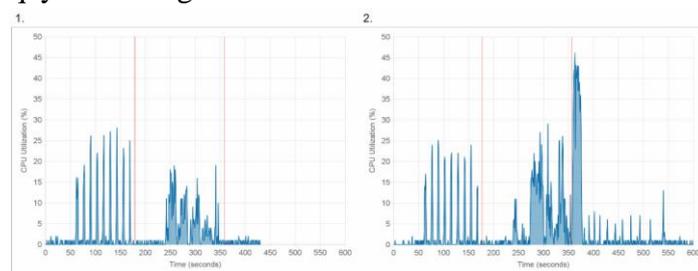
So'rovlar 4 ta oqimda yuborildi, ularning har biri alohida protsessor yadrosida bajarildi. Shu bilan birga, har bir oqimda 1000 ta bir vaqtda so'rovlar (jami serverga bir vaqtning o'zida 4000 tagacha ulanish) 10 soniya kutish vaqti bilan amalga oshirildi. 4000 ta so'rov yuborilgandan so'ng (serverdan javob olindi, javob kutish vaqti tugaydi), so'rovlarni yuborishning keyingi iteratsiyasini boshlashdan oldin qo'shimcha 10 soniya kutish o'rnatildi. Tajriba bosqichlari orasida 60 soniya qo'shimcha kutish ham joriy etildi.

III. NATIJALAR

A. MBBT virtual mashinasining ishlashi.

Tajribalar O'zbekiston Respublikasi Davlat soliq qo'mitasi huzuridagi Yangi texnologiyalar ilmiy-axborot markazida amalga oshirilgan. Bunda o'zgaras ma'lumotlar to'plamini saqlash vaqtida (7-rasm) MBBT virtual mashinasining markaziy protsessoriga yuklanishda farqlar yo'q (grafikning birinchi vertikal ajratgichdan oldingi qismi, taxminan 180 soniya). Turli xil ma'lumotlar tuzilmalarini yozish paytida markaziy protsessor yuk grafiklari farq qiladi (9-rasm). Protsessor resurslaridan to'liq foydalanilmaslik ikkinchi tajriba davomida server ilovasining 3 marta qayta ishga tushirilganligi sababli mumkin. Mijoz so'rovlarini yuborish tugagandan so'ng, eng yuqori yukga ham e'tibor berilishi kerak (ikkinchi vertikal ajratuvchi, taxminan 360 soniya). Bu oxirgi yuborilgan, ammo server ilovasini qayta ishga tushirishga va natijada ma'lumotlar yo'qolishiga olib

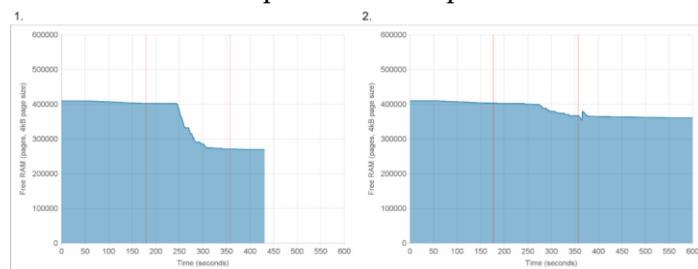
kelmagan so'rovlarni uzoq va resurs talab qiladigan qayta ishlashga mos keladi.



7 rasm. MBBT virtual mashinasi uchun protsessor yuklanish grafigi

Tajribalarning birortasida diskning kiritish-chiqarish quyi tizimi sezilarli darajada yuklanmagan, shuning uchun bu ko'rsatkichni hisobga olish muhim emas.

Erkin operativ xotira miqdori birinchi va ikkinchi tajribada ham kamayadi (8-rasm). Ma'lumki, standart konfiguratsiyada MongoDB operativ xotiradagi ma'lumotlarning bir qismini keshlaydi. Birinchi tajribada ko'proq joy egallaganligi ma'lumotlar bazasida ko'proq ma'lumotlar saqlanganligi bilan mos keladi. Tajribalarda ushbu ko'rsatkichda boshqa sezilarli farqlar kuzatilmadi.



8 rasm. MBBT virtual mashinasining bepul operativ xotirasi grafigi

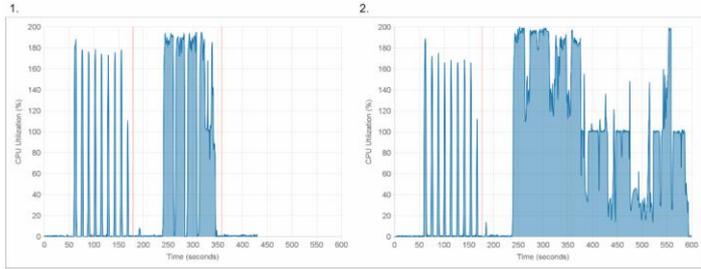
B. Server ilovasi virtual mashina ko'rsatkichlari

O'zgaras ma'lumotlar to'plamini saqlash vaqtida (12-rasm) server ilovasi virtual mashinasining markaziy protsessor yuklanishida farqlar yo'q (grafikning birinchi vertikal ajratgichdan oldingi qismi, taxminan 180 soniya).

Ikkala grafik (8-rasm) ma'lumotlarning asosiy hajmini saqlash vaqtida server ilovasi virtual mashinasining markaziy protsessoriga yuklanish maksimal darajada ekanligini ko'rsatadi. Agar birinchi



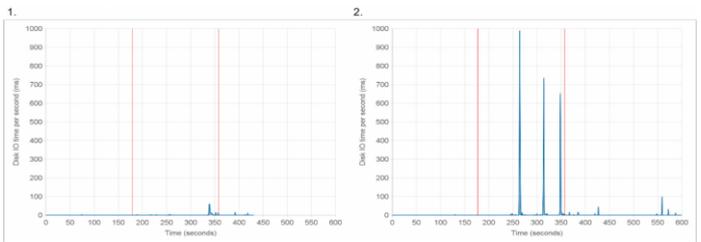
tajriba davomida deyarli butunlay tushib ketgan vaqt oralig'i bo'lsa, ikkinchisida doimiy ravishda yuqori bo'lib qoladi. Bundan tashqari, ikkinchi tajriba oxirgi yuborilgan so'rovlarni uzoq va ko'p resurs talab qiladigan ishlov berishni ko'rsatadi.



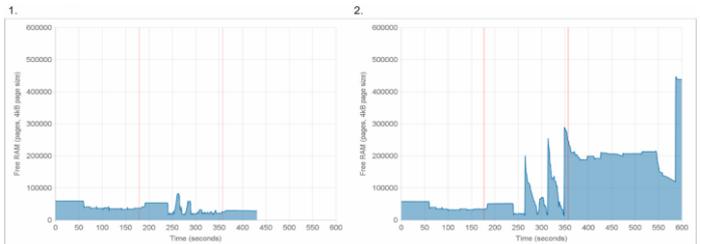
8-rasm. Server ilovasi virtual mashinasi uchun protsessor yuklanish grafigi

Ikkinchi eksperimentning grafigi (8-rasm) server ilovasining 3 marta qayta yuklanishini aniq ko'rsatib turibdi, bu diskni kiritish-chiqarish tizimiga intensiv kirish bilan tavsiflanadi. Aks holda, olingan natijalar kutiladi.

Ikkinchi tajriba uchun (9-rasm) server ilovasi qayta ishga tushirilganligi sababli operativ xotira chiqarilganda 3 tepalik aniq ko'rinadi. Bu 9-rasmda ko'rsatilgan grafikdagi natijalarga to'liq mos keladi. Aks holda, kutilgan naqsh ko'rinadi: bo'sh xotira miqdori mijoz so'rovlarini qabul qilgandan so'ng kamayadi va ular qayta ishlanib, axlat yig'ish jarayoni boshlanganidan keyin ortadi.



9-rasm. Server ilovasi virtual mashinasi uchun disk kiritish-chiqarish operatsiyalariga sarflangan vaqt grafigi



10-rasm. Virtual mashina server ilovasining bo'sh operativ xotirasi grafigi

2-3-jadvallarda eksperimental tadqiqotlarning raqamli qiymatlarini ko'rsatadi. 2-jadvalda keltirilgan natijalar va resurslardan foydalanishning bir xil ko'rsatkichlari (7-10-rasmlar, grafiklarning birinchi vertikal bo'luvchigacha bo'lgan qismlari, taxminan 180 soniya) tajribalarni o'tkazish uchun teng sharoitlarni tasdiqlaydi.

2-jadval. Invariant ma'lumotlar strukturasi bilan yozish samaradorligi

№	Ko'rsatkichlar	№1 tajriba bo'yicha natijalar	№2 tajriba bo'yicha natijalar
1	Eksperiment vaqti (sekund)	189	178
2	Researchsubject bo'yicha saqlangan hujjatlar	34132 (100%)	34132 (100%)
3	Servarning hujjatlarni muvaffaqiyatli yozish haqidagi xabari (Researchsubject)	34132 (100%)	34132 (100%)
4	Researchsubject hujjatlarni yozishda server xatoligi xabari	0 (0%)	0 (0%)
5	Researchsubject hujjatlarni yozishda server javobini kutish vaqti tugadi	0 (0%)	0 (0%)

3-jadval. Eksperimental ma'lumotlarni yozib olish samaradorligi.

№	Ko'rsatkichlar	№1 tajriba bo'yicha natijalar	№2 tajriba bo'yicha natijalar
1	Eksperiment vaqti (sekund)	252	423
2	Researchsubject bo'yicha saqlangan hujjatlar	7034 (41,66%)	2497 (14,79%)
3	ResearchsubjectAnswers bo'yicha saqlangan hujjatlar	- (41,66%)	398064 (8,07%)
4	Researchresult va ResearchresultAnswer hujjatlarni muvaffaqiyatli yozish haqida server xabarlarini	3619(21,44%)	21(0,12%)
5	Researchresult va ResearchresultAnswer hujjatlarni yozishda server xatoligi xabari	0 (0%)	0 (0%)
6	Researchresult va ResearchresultAnswer hujjatlarni yozishda server javobini kutish vaqti tugadi	13265(78,56%)	16862(99,88%)

III. XULOSA

Tajribalar O'zbekiston Respublikasi Davlat soliq qo'mitasi huzuridagi Yangi texnologiyalar ilmiy-axborot markazida amalga oshirildi. Maqolada MongoDB hujjatga yo'naltirilgan NoSQL tizimida normallashtirilmagan ma'lumotlar uchun saqlash tuzilmalarining ikkita varianti uchun hisoblash resurslarini tahlil qilish metodologiyasi ishlab chiqildi. Eksperimental natijalar katta ma'lumotlar oqimi va cheklangan hisoblash resurslarining yaratilgan simulyatsiya sharoitida olingan. Tajriba natijalari (3-jadval) quyidagilarni ko'rsatadi:



- ikkita to'plamga bo'lingan ma'lumotlarni yozish bitta to'plamga obyektlar yozishdan ko'ra ko'proq vaqt oladi;
- bir to'plamga yozishda ma'lumotlar yo'qotilishi sezilarli darajada kamroq bo'ladi, bundan tashqari, normallashtirilmagan ma'lumotlarni yozib olish ehtimoli past hisoblanadi;
- ma'lumotlarni ikkita to'plamga bo'lishda mijoz so'rovlariga xizmat ko'rsatish sifati bitta to'plamga yozishga qaraganda pastroq ekanligi aniqlandi.

Server dasturi ishlaymay qolganda, ba'zi ma'lumotlar o'chib ketishi hamda yo'qolishi mumkin. Xulosa qilib aytganda, foydalaniladigan ma'lumotlar tuzilmalaridagi farqlar, ular uchun qo'llaniladigan usullar asosida muammlarni aniqlaydi va dasturiy ta'minot tizimlarining samaradorligiga ta'sir qilishi mumkin.

ADABIYOTLAR

1. W. Hendricks, "Review of NoSQL Data Stores: Using a reactive threetier application for software developers to achieve a high availability application design architecture," In 2019 Open Innovations (OI), 2019, pp. 71-77.
2. Мусаев М.М. Современные методы цифровой обработки речевых сигналов.// Вестник ТУИТ 2(42)/2017. -с. 2-13.
3. Рахматуллаев М.А. Мировые информационные ресурсы. –Т.: «Fan va texnologiya», 2017. 196 с.
4. Аскраралиев О.У. "Тизимларни таҳлил қилиш ва қарор қабул қилиш тамойиллари (техник тизимлар мисолида)" // "Ижтимоий-иқтисодий жараёнларни тизимли таҳлил қилиш ва моделлаштириш" мавзусидаги халқаро илмий онлайн конференция. Тошкент 2020 й., -Б 55-59
5. A. Corbellini, C. Mateos, A. Zunino, D. Godoy and S. Schiaffino, "Persisting big-data: The NoSQL landscape," Information Systems, vol. 63, pp. 1-23, 2017.
6. P. Kolyasnikov et al., "Analysis of software tools for longitudinal studies in psychology," International Journal of Advanced Computer Science and Applications, vol. 10, no. 8, pp. 21– 33, 2019.

7. N.Q. Mehmood, R. Culmone and L. Mostarda, "Modeling temporal aspects of sensor data for MongoDB NoSQL database," Journal of Big Data, 4(1), 82017
8. Roy-Hubara, N., Shoval, P., & Sturm, A. "A Method for Database Model Selection," In Enterprise, Business-Process and Information Systems Modeling, 2017, pp. 261-275.
9. Mehmood, E., & Anees, T. (2019). Performance Analysis of Not Only SQL Semi-Stream Join Using MongoDB for Real-Time Data Warehousing. IEYEE Access, 7, 134215-134225.
10. Chopade, R., & Pachghare, V. (2020). MongoDB Indexing for Performance Improvement. In ICT Systems and Sustainability (pp. 529-539). Springer, Singapore.
11. B.M. Basok, A.N. Rozhanskaya and S.L. Frenkel, "On web-applications usability testing," Russian Technological Journal, vol. 7, no. 6, p. 9- 24, 2019. DOI: 10.32362/2500-316X-2019-7-6-9-24
12. R. Cattell, "Scalable SQL and NoSQL data stores," Acm Sigmod Record, vol. 39, no. 4, pp. 12-27, 2011.
13. V. Herrero, A. Abelló and O. Romero, "NoSQL design for analytical workloads: variability matters," In International Conference on Conceptual Modeling, 2016, pp. 50-64.
14. N. Roy-Hubara and A. Sturm, "Design methods for the new database era: a systematic literature review," Software & Systems Modeling, vol. 19, pp. 297–312, 2020.
15. Atzeni, P., Bugiotti, F., Cabibbo, L., & Torlone, R. (2020). Data modeling in the NoSQL world. Computer Standards & Interfaces, 67, 103149.
16. Mahruqi, R. S. A., Alalfi, M. H., & Dean, T. R. (2019, November). A semi-automated framework for migrating web applications from SQL to document oriented NoSQL database. In Proceedings of the 29th Annual International Conference on Computer Science and Software Engineering (pp. 44-53).



YORUG'LIK DIODINING ELEKTRO-FIZIK XARAKTERISTIKALARINI TAJRIBA ORQALI ANIQLASH

Kuchkarov Voxid Alisherovich,

Muhammad al-Xorazmiy nomidagi Toshkent
axborot texnologiyalari universiteti Urganch
filiali, stajyor-o'qituvchisi,
E-mail: voxidkuchkarov@umail.uz

Annotatsiya: Ushbu maqolaning maqsadi – LED diodining volt-amper va vatt-amper xarakteristikalarini tajriba yo'li bilan aniqlashdir. LED diodlar samarali va energiya tejavchi manbalar sifatida keng qo'llanilib, ularning ishlash xususiyatlarini to'g'ri tushunish va tahlil qilish zarur. Tadqiqot davomida LED diodining kuchlanish va tok o'rtasidagi o'zaro bog'lanishlar o'lchandi va shunga asoslanib, volt-amper va vatt-amper xarakteristikalarining shakllanishi tahlil qilindi. Natijalar yordamida LED diodining energiya samaradorligi, volt-amper va vatt-amper parametrlariga qanday ta'sir qilishi va ularning ishlash sharoitlariga bog'liqligi aniqlanadi.

Ushbu tadqiqotda olingan ma'lumotlar LED texnologiyasini yanada samarali va optimallashtirilgan holda qo'llashda yordam beradi, shuningdek, energiya tejavchi tizimlar va qurilmalarni ishlab chiqishda muhim ahamiyatga ega bo'ladi.

Kalit so'zlar: LED, volt-amper xarakteristika, vatt-amper xarakteristika, Shokli diod tenglamasi, termal kuchlanish, p-n o'tish

Kirish. LED diodining volt-amper xarakteristikasi LED larning ishlash prinsiplari va ularning quvvat sarfini tushunishga yordam beradi. Odatda, LED diodining kuchlanishi va tok o'rtasidagi munosabat noxiziq bo'lib, ma'lum bir tashqi kuchlanishdan keyin diod yorug'lik chiqarishni boshlaydi. Ushbu xarakteristika, shuningdek, diodning qizib ketishiga olib kelmaslik uchun ideal ish sharoitlarini aniqlashda muhim rol o'ynaydi.

Ushbu mavzu LED larning samarali ishlashini ta'minlash va ularni turli tizimlarda qo'llashda muhim hisoblanadi. Volt-amper xarakteristikasi yordamida LED larning harorat, kuchlanish va tok sharoitlarida qanday ishlashini yanada chuqurroq tushunish mumkin, bu esa ularning ishlash muddatini va energiya samaradorligini optimallashtirishga yordam beradi.

LED larning volt-amper xarakteristikalari Shoklining diod tenglamasi bilan aniqlanadi. Shokli diod tenglamasi yoki Bell laboratoriyasining tranzistor ixtirochisi Uilyam Shokli sharafiga nomlangan diod qonuni yarimo'tkazgichli diodlarning eksponensial volt-amper xarakteristikalarini o'rtacha doimiy tok to'g'ri yoki teskari yo'nalishda modellashtiradi:

$$I_D = I_S \left(e^{\frac{V_D}{n \cdot V_T}} - 1 \right), \quad (1)$$

Bu yerda I_D – diodning toki, I_S – teskari to'yinganlik toki, V_D – diodagi kuchlanish, V_T – termal kuchlanish, n - sifat omili, emissiya koeffisienti yoki material konstantasi sifatida ham tanilgan ideallik omili.

Ideallik koeffisienti $n=1$ bo'lsa, Shokli tenglama ideal diod tenglamasi deb ataladi, shuning uchun n ba'zan o'tkazib yuboriladi. Ideallik koeffisienti ishlab chiqarish jarayoni va yarimo'tkazgich materialiga qarab, odatda 1 dan 2 gacha (ba'zi hollarda yuqoriroq bo'lishi mumkin) o'zgaradi [5].

Termal kuchlanish V_T quyidagi formula bilan aniqlanadi:

$$V_T = \frac{k \cdot T}{q}, \quad (2)$$

bu yerda k – Boltsman doimiysi, T – p-n o'tish joyining absolyut harorati, q – elementar zaryad (elektron zaryadining kattaligi).

Teskari to'yinganlik toki I_S ma'lum bir qurilma uchun doimiy emas, lekin haroratga qarab o'zgaradi;



odatda V_T displey uslubiga qaraganda ancha sezilarli, shuning uchun V_D odatda T ortishi bilan kamayadi.

Teskari yo'nalishda diod tenglamasining eksponensial atamasi 0 ga yaqin, shuning uchun tok biroz o'zgarishsiz qoldi - I_S teskari tok qiymati (taxminan kremniy diodlar uchun pikoamper yoki germaniy diodlar uchun mikroamper [4], lekin bu aniq o'lcham funksiyasidir).

O'rtacha to'g'ri yo'nalishda ulangan kuchlanish uchun eksponensial 1 dan ancha katta bo'ladi, chunki termal kuchlanish nisbatan juda kichik. Diod tenglamasidagi -1 ahamiyatsiz bo'ladi, shuning uchun to'g'ridan-to'g'ri diod toki:

$$I_S \cdot e^{\frac{V_D}{nV_T}} \quad (3)$$

LED lar juda samarali yorug'lik manbalaridir, ammo ularning samaradorligi tok va kuchlanish shartlariga bog'liq. Volt-amper xarakteristikasini o'rganish LED ning maksimal samaradorlikda ishlashini ta'minlash uchun zarur. Shu tariqa, energiya sarfini kamaytirish va qurilmaning ishlash muddatini uzaytirish mumkin. LED diodlari yuqori tokda ishlaganda, ular ko'proq issiqlik chiqarishi mumkin. Volt-amper xarakteristikasini o'rganish orqali, qachon va qanday sharoitlarda diodning qizib ketishi mumkinligini bilib olish va bu muammoni oldini olish uchun yaxshi sovetlash tizimlarini loyihalash mumkin.

Adabiyotlar tahlili va metodologiya. Ushbu [1] ishda LED ning volt-amper xarakteristikasini ba'zi optik va issiqlik parametrlarga ko'ra impulsi yuqori toklarda olgan. Impulsi yuqori toklarda issiqlik quvvati ko'proq iste'mol qilinganligi sababli, LED ning ba'zi termal parametrlarini o'lchash impulsi yuqori toklarda osonroq va aniqroq bo'lishi mumkin. Volt-amper xarakteristikasida ishlatiladigan barcha parametrlar elektr parametrlardir. Bundan tashqari, LED ning oniy qarshilik ta'siri - tok o'zgarishining volt-amper xarakteristikasiga ta'sirini ko'rsatdi.

Yorug'lik diodlarining volt-amper xarakteristikalar Shoklining diod tenglamasi bilan berilgan. Ammo volt-amper xarakteristikalarini boshqa formula bilan ham ko'rsatish mumkin. Ushbu tadqiqotda LED larning yangi volt-amper xarakteristika tenglamasi berilgan. Ushbu tenglamada

ba'zi turli parametrlar ishlatilgan. Bular taniqli Shoklining diod tenglamasida chiqmaydigan ba'zi optik va termal parametrlardir. Shunday qilib, bu yangi tenglama juda muhim, chunki u LED ning volt-amper xarakteristikalarini turli xil effektlar bilan tushuntirdi [1].

Quyidagi [2] ishda optik va elektr ta'sir ostida yorug'lik chiqaruvchi diodlarning volt-amper xarakteristikalari tahlil qilingan. LED qurilmasining volt-amper xarakteristikasi birinchi navbatda tashuvchilarning energiya taqsimotiga bog'liq va tashuvchilarning injeksiya yo'li bilan bog'liq emas. O'tish harorati T va energetik sathlari E_g , elektr xususiyatlariga ta'sir qilish uchun hal qiluvchi parametrlardir. Ular eksperimental ravishda optik va elektr ta'sir ostidagi volt-amper xarakteristikalarining egri chiziqlari xona haroratida bir xil injeksiya tokida kuchlanish qiymatlarida ko'rinadigan farqlarni ko'rsatdilar. Bu shuni anglatadiki, kuchlanish qiymatlaridagi farqlar ikkita injeksiya usulida o'zgaruvchan o'tish haroratidan kelib chiqadi. Agar impulsi yorug'lik yordamida yorituvchi nuqtaning issiqlik effekti e'tiborga olinmaydigan darajada tushirilsa, ulanish harorati joriy injeksiya ostidagi haroratdan deyarli farq qilmaydi, deb hisoblanadi [2].

Ushbu [3] tadqiqot shida, tajriba yo'li bilan STE GE-Dioderry AA118 diodi Cassy-lab2 dasturida volt-amper xarakteristikasini oldi va tahlil qildi. Ular ushbu tajribada turli diodlarning (Si, Ge va yorug'lik chiqaradigan diodlar) volt-amper xarakteristikalarini qayd qildilar va taqqosladilar. Natijada ular quyidagi xulosaga keldilar: LEDlar chiqaradigan yorug'likning to'lqin uzunligini aniq aniqlash mumkin emas, chunki ular odatda rangli korpus orqali filtrlanadigan, nisbatan keng chastota diapazoni chiqaradi. Shuning uchun aniqlangan to'lqin uzunligi shunchaki taxminiy qiymatdir.

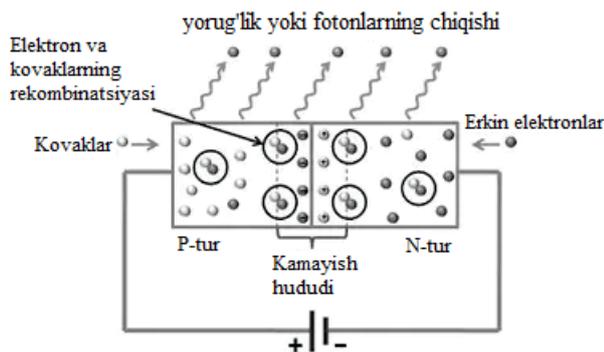
Shuningdek, mualliflar turli diodlarning o'tkazuvchanlik holati U kuchlanishlarini solishtirganlar. LED lar uchun ular chiqarilgan yorug'likning to'lqin uzunligi λ ni taxminiy baholash uchun $e \cdot U = h \cdot c / \lambda$ tenglamasidan foydalangan. Ushbu misolda qizil rangli LED ning o'tkazuvchanlik holati taxminan $U = 1.4$ V. Bundan $\lambda = hc/eU =$



880 nm deb hisoblangan. STE Si-diode 1N4007 diodining volt-ampere xarakteristikasini turli ranglarda va turli materiallarda olingan [3].

Biz ushbu maqolada, Opto-electronics source & measurement unit o'lchash asbobi orqali yorug'lik diodiga, xususan, ko'k rangli diod uchun kuchlanish berib, undagi tok o'zgarishini tajriba bilan aniqlandi hamda undagi quvvat o'zgarishi ham aniqlandi.

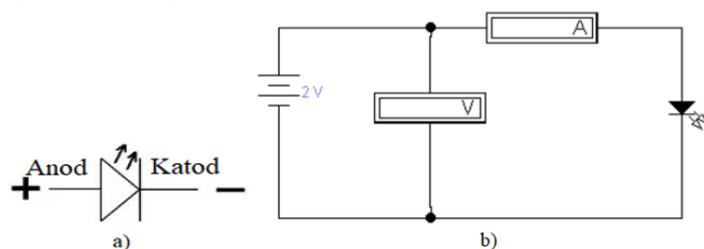
Yorug'lik chiqaradigan diod (LED) - yarim o'tkazgichli yorug'lik manbai. Oddiy diod kabi, LED diodi to'g'ri ulangan holda ishlaydi. Bunday holda, n-tipli yarimo'tkazgich p-n birikmasini tashkil etuvchi p-turidan ko'ra ko'proq qo'shiladi. U to'g'ri ulangan bo'lsa, potensial to'siq kamayadi va elektronlar va kovaklar kamayish qatlamida (yoki faol qatlamda) birlashadi, yorug'lik yoki fotonlar chiqariladi yoki barcha yo'nalishlarda tarqaladi. Quyidagi rasmda oldinga siljish bo'yicha birlashgan elektron-kovak juftligi tufayli yorug'lik chiqishi ko'rsatilgan. Bu ta'sir elektroluminesans deb ataladi va yorug'likning rangi yarimo'tkazgichning energiya bo'shlig'i bilan belgilanadi [4].



1-rasm. To'g'ri ulanishda dioddagi elektron-kovaklarning harakati ko'rsatilgan.

Bu p-qutbga musbat kuchlanish va n-qutbga manfiy kuchlanish berilganda to'g'ri yo'nalishda p – n o'tish diodi va tok p-tomonidan yoki anoddan n-tomonga yoki katodga o'tadi. Diod to'g'ri yo'naltirilgan bo'lsa, yarimo'tkazgichning o'tkazuvchanlik zonasidagi elektronlar valent zonasidagi kovaklar bilan qayta birlashadi va fotonlarni ishlab chiqarish uchun yetarli energiya chiqaradi. Chiqarilgan mos keladigan yorug'likning to'liq uzunligi, rangi, energetik sathi va p - n birikma

diodining yarimo'tkazgich materialiga bog'liq. Keyin yorug'lik chiqaradigan diodlar elektr energiyasini yorug'lik energiyasiga aylantiradigan yarimo'tkazgichli qurilmalar deb aytishimiz mumkin. Oddiy cho'g'lanma lampalardan farqli o'laroq, yoritilgan LED lar yorug'lik hosil qilganda issiqlik hosil qiladi va energiyaning katta qismi ko'rinadigan spektrda tarqaladi [5].



2-rasm. Yorug'lik diodining shartli belgilanishi (a), volt-ampere xarakteristikasini aniqlash uchun elektr sxema.

Yuqorida aytib o'tganimizdek, LED ketma-ket qarshilik R orqali to'g'ri yo'naltirilgan bo'lsa, fotonlar n – qutbning metallashtirilmagan yuzasidan chiqariladi. Ketma-ket ulangan qarshilik LED orqali tokni kamaytiradi va yorug'lik oqimini nazorat qiladi. P – n o'tish joyi to'g'ri yo'naltirilgan elektronlar n-qutbdan p - qutbga yuboriladi va kovaklar p - qutbdan n - qutbga yuboriladi. P-n o'tishning har ikki tomonida ortiqcha kam tashuvchilari ko'pchilik tashuvchilar bilan birlashadi. Rekombinatsiyada energiya fotonlar shaklida chiqariladi. Energetik sathga teng yoki undan bir oz kamroq energiyaga ega bo'lgan fotonlar chiqariladi. To'g'ridan-to'g'ri tok uchun intensivlik kichikdir, chunki to'g'ridan-to'g'ri tokning qiymati yorug'lik intensivligini oshiradi va maksimal darajaga yetadi. To'g'ri yo'naltirilgan tokning yanada oshishi intensivlikni pasaytiradi [7].

Boshqa p-n ulanish diodlari singari, LEDlar to'g'ridan-to'g'ri kuchlanish pasayishi bilan tokka bog'liq qurilmalardir, kuchlanish esa yarimo'tkazgich birikmasiga va to'g'ri ulangan tokka bog'liq. Eng keng tarqalgan LED lar taxminan 1.2 dan 3.2 V gacha bo'lgan to'g'ridan-to'g'ri kuchlanishni talab qiladi, to'g'ridan-to'g'ri tok maksimal 30 mA gacha. Ushbu kuchlanish va tok qiymatlari har doim p-n ulanishini



amalga oshirish uchun ishlatiladigan materialga nisbatan o'zgaradi.

LED ning normal volt-amper xarakteristikalari tok va kuchlanishning chegara qiymatidan so'ng darhol chiziqli, lekin tez ortadi. LED ning vatt-amper xarakteristikasi tokka nisbatan intensivlikning o'zgarishiga bog'liq. To'g'ridan-to'g'ri tokning ortishiga nisbatan LED tomonidan chiqarilgan yorug'likning optik kuchini o'lchaymiz. LED uchun ishlab chiqarilgan chiqish quvvati juda kichik [6].

Natijalar. Birinchi navbatda qurilmalarni sxema bo'yicha yig'ib olamiz va mahkamlab o'rnatamiz. LED ni opto elektron manba va o'lchov birligi bilan ulaymiz. LED ni voltmetrga parallel va ampermetr bilan ketma-ket ulangan bo'lishi kerak (svetodiodni quvvat manbaiga, shuningdek ampermetrga ulash uchun o'rnatish bilan birga berilgan boshqa simlardan foydalanamiz. Shuningdek, qizil uchi + ve ni va qora uchini - ve ko'rsatadi, sxema bo'yicha ulaymiz). LED har doim oldinga egilish holatida ulanishi kerak.

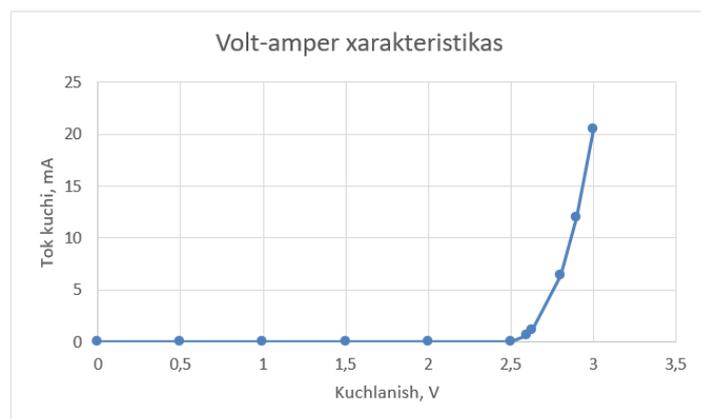
Optoelektron manba va o'lchov birligini ishga tushiramiz. Keyin LED dagi kuchlanishni asta-sekin o'zgartirishni boshlaymiz. Tokning kuchlanishga nisbatan o'zgarish grafikini chizamiz.



3-rasm. Yorug'lik diodining volt-amper xarakteristikasini aniqlash.

1-jadval. LED ning volt-amper xarakteristikasi uchun o'lchangan natijalar.

Tajribalar soni	1	2	3	4	5	6	7	8	9	10	11
Kuchlanish, V	0	0.5	1.0	1.5	2.0	2.5	2.6	2.63	2.8	2.9	3.0
Tok kuchi, mA	0	0	0	0	0.001	0.051	0.654	1.121	6.4	12.0	20.5



4-rasm. 1-jadvaldagi natijalarga asosan diodning volt-amper xarakteristikasi.

Kuchlanish 0 V dan 2.5 V gacha bo'lgan oraliqda, LED diodidan o'tgan tok qiymatlari nolga teng (0 mA). Bu shuni anglatadiki, LED diodi ushbu kuchlanish darajalarida yorug'lik chiqarishni boshlamaydi. Bu, LED diodining "yoqilmasligi" ni ko'rsatadi, ya'ni diodning tok o'tkazish qobiliyati faqat ma'lum bir kuchlanishdan keyin boshlanadi. Kuchlanish 2.5 V dan 2.6 V gacha oshganda, LED diodining chiqayotgan tok qiymati sezilarli darajada ortadi (51 mA dan 654 mA gacha). Bu, LED diodining yorug'lik chiqarishni boshlaganidan keyin uning tokini ko'paytirishi mumkinligini ko'rsatadi. Ushbu o'sish LED diodining o'ziga xos volt-amper xarakteristikasi bo'yicha o'tish zonasini belgilaydi. 2.6 V dan 3.0 V gacha kuchlanish oshgan sari tok qiymatlari ham juda keskin o'sadi (654 mA dan 20500 mA gacha). Bu LED diodining volt-amper xarakteristikasida nochiziqli o'sish mavjudligini ko'rsatadi. Ya'ni, LED diodi yuqori kuchlanishlarda yanada yuqori tok o'tkazish imkoniyatiga ega bo'ladi. Kuchlanish 2.6 V dan yuqori bo'lganda LED diodining tok qiymatlari juda katta bo'lib, bu uning yorug'lik chiqarish darajasining juda yuqori bo'lishini anglatadi. Shuningdek, bu yuqori tokning LED diodining qizib ketishiga olib kelishi mumkin, shuning uchun maxsus sovutish tizimlari talab qilinadi. LED diodining volt-amper xarakteristikasi kuchlanishning kichik qiymatlarida nisbatan pasaygan tokni ko'rsatadi, lekin kuchlanish bir ma'lum nuqtadan (taxminan 2.5 V) keyin tok keskin o'sib boradi. Bu LED ning "yoqilishi"



uchun minimum kuchlanish nuqtasini va maksimal ishlash sharoitlarini aniqlashga yordam beradi [8].

LED ning vatt-amper xarakteristikalarini topish uchun LED ni o'rnatish moslamasiga joylashtiramiz va quvvat o'lchagich sensorini boshqa o'rnatish ushlagichiga joylashtiramiz. Elektr ta'minoti, voltmetr va ampermetr bilan LED ning ulanishini oldingi holatdagidek saqlaymiz va qurilmani ishga tushiramiz. Quvvat o'lchagich sensorini ulaymiz va uni ishga tushiramiz. Avvalgidek kuchlanishni asta-sekin oshirib boramiz va tokning o'zgarishini teng bosqichlarda qayd qilamiz va quvvat o'lchagichdan mos keladigan quvvatni o'lchab olamiz. Quvvat o'zgarishini tokka nisbatan grafigini chizamiz.



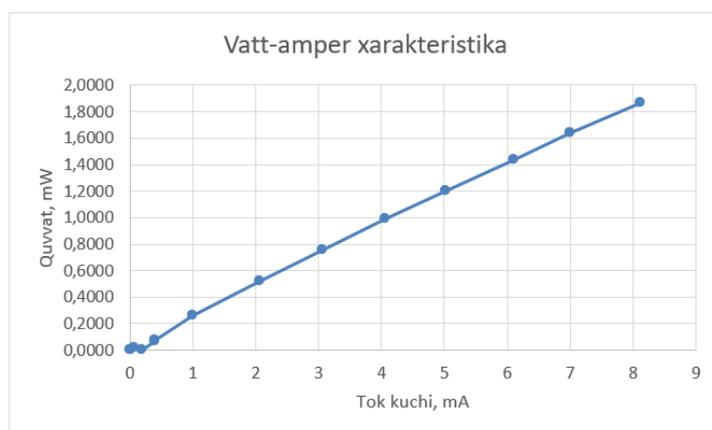
5-rasm. LED ga kuchlanish berilganda undan tok oqib o'tishi va uning quvvatini o'lchash.



6-rasm. LED diodidan yorug'lik chiqishi va uning quvvati.

2-jadval. Vatt-amper xarakteristikasi uchun o'lchangan qiymatlar.

No	Tok kuchi, mA	Quvvat, mW
1	0	0.0009
2	0.03	0.0006
3	0.07	0.0158
4	0.2	0.0046
5	0.4	0.0687
6	0.71	0.0758
7	1.0	0.261
8	2.07	0.518
9	3.06	0.756
10	4.06	0.990
11	5.03	1.2
12	6.11	1.44
13	7.01	1.637
14	8.12	1.869



7-rasm. Olingan natijalarga asoslangan holda diodning vatt-amper xarakteristikasi.

Kuchlanish 2.42 V va 2.46 V bo'lgan vaqtda, tok qiymatlari juda kichik (0 mA va 0.03 mA) va quvvat qiymatlari ham juda past (0.0009 mW va 0.0006 mW). Bu, LED diodining hali "yoqilmagan" ligini va quvvatning juda kam o'tkazilayotganini ko'rsatadi. Kuchlanish 2.50 V dan 2.62 V gacha oshganda, tok va quvvat qiymatlari sezilarli darajada ortadi. Masalan, kuchlanish 2.57 V da 0.4 mA bo'lsa, quvvat 0.0987 mW ga teng, 2.62 V da esa tok 1.0 mA va quvvat 0.261 mW ga yetadi. Bu LED diodining



yorug'lik chiqara boshlagani va quvvatning ortishi bilan bog'liq. Kuchlanish 2.67 V dan 2.82 V gacha oshgan sari, tok va quvvat ham keskin o'sib boradi. Masalan, kuchlanish 2.75 V va 2.80 V da tok 5.03 mA va 6.11 mA bo'lsa, quvvat esa 1.2 mW va 1.44 mW ni tashkil etadi. Bu LED diodining maksimal quvvatda ishlay boshlaganini ko'rsatadi. Kuchlanish 2.82 V ga yetganda, tok va quvvat eng yuqori darajaga yetadi: tok 8.12 mA va quvvat 1.869 mW. Bu, LED diodining maksimal ishlash nuqtasiga yaqinlashishini anglatadi. LED diodining quvvat xarakteristikasi kuchlanishning oshishi bilan **nochiziqli tarzda** o'sishini ko'rsatadi. Ya'ni, kuchlanish ma'lum bir nuqtadan keyin (taxminan 2.5 V dan) tok va quvvatning o'sishi juda tezlashadi. Bu LED ning yorug'lik chiqarish qobiliyatining yuqori kuchlanishlarda keskin o'sishini anglatadi. Tok va quvvatning yuqori qiymatlarga erishishi LED diodining maksimal yorug'lik chiqarish imkoniyatlarini oshiradi, ammo shu bilan birga, u ko'proq energiya sarflaydi.

Xulosa. Ushbu o'lgangan natijalar LED diodining volt-ampere xarakteristikasini o'rganishda muhim ahamiyatga ega. Tokning kuchlanishdan keskin o'sishi LED ning ishlashini optimallashtirish va uning samarali ishlashini ta'minlash uchun kerakli kuchlanish oralig'ini belgilashda yordam beradi. Bu o'lgovlar LED texnologiyasining energetik samaradorligi va ishlash muddatini yaxshilash uchun muhim asos bo'ladi. Shuningdek, quvvatning keskin o'sishi LED diodining ishlash nuqtasini, maksimal tok va kuchlanishda qanday ishlashini aniqlashda muhim rol o'ynaydi. Bu ma'lumotlar LED texnologiyasini optimallashtirish, energiya samaradorligini oshirish va maksimal ishlash sharoitlarini aniqlash uchun foydalidir. Shuningdek, LED diodining ishlash va energiya sarfini yaxshilash uchun uning quvvat xarakteristikasini tahlil qilish, samarali yoritish tizimlarini yaratishda yordam beradi.

Foydalanilgan adabiyotlar

1. Erdem Ozuturk, "Voltage-current characteristic of LED according to some optical and thermal parameters at pulsed high currents", Optics journal, 2015. [Volume 126, Issue 21](#), Pages 3215-3217.

2. Wen Jing, Wen Yumei, Li Ping, Li Lian, "Current-voltage characteristics of light-emitting diodes under optical and electrical excitation", Journal of Semiconductors, 2011, [Volume 32, № 8](#), pages 1-4.

3. Boydedayev S.R. Abdullaev A.A. Turgunov A.R, "Determination of volt-ampere characteristic of Si diode in CASSY-LAB2 program", Экономика и социум, 2023, № 11, pages 79-82.

4. [Kuzievich, I.S.](#), [Safarbaevich, S.A.](#), [Negmatovich, U.S.](#), [Palvanovna, A.U.](#), [Gayratovich, B.S.](#), "Investigation of the Spectral Photosensitivity of nGaAs-n+(GaAs)1-x-y(Ge2)x(ZnSe)y Heterostructure Obtained from Bi Solution-Melt", Transactions of the Korean Institute of Electrical Engineers., 2024, 73(6), pp. 980-986.

5. Doniyor Jumanazarov, Asalkhon Alimova, Shukurulloh Kh Ismoilov, Farruh Atamurotov, Azamat Abdikarimov, Ulrik L Olsen, "Method for the determination of electron density from multi-energy X-ray CT", NDT & E International, 2024, Volume 145, pages 1-7.

6. Amin Saidov, Umida Asatova, Shukurullo Usmanov, "Simulation of parameters of nGe-pSiGe diode structures on TCAD SENTAURUS", Actual problems modern science education end training in the region. Electronic scientific edited, 2017, Volume 1, pages 42-46.

7. A.V.Gradoboev and K.N.Orlova, "Investigation of Changing Volt-Ampere Characteristics of AlGaInP Heterostructures with Multiple Quantum Wells under Ionizing Radiation", Materials Science and Engineering, 2016. Pages 1-5.

8. Doniyor Jumanazarov, Farruh Atamurotov, Egambergan Xudoynazarov, Khikmatjon Matyokubov, Rakhmon Saparbaev, Xidoyat Abdikarimov, Ulrik L Olsen "Method for the correction of spectral distortions in x-ray photon-counting detectors" IEEE Transactions on Instrumentation and Measurement, 2025.



Identifying a person using dynamic biometric authentication methods

Rasulmukhamedov Makhmadaziz,
Tashkent State Transport university,
Professor
prof.rasulmukhamedov@gmail.com

Gafforov Nuraddin,
Digital technologies and artificial intelligence
research institute, Phd student
mrgaffarov28@gmail.com

Urinboev Johongir,
Digital technologies and artificial intelligence
research institute, Phd student
jahongir8010@gmail.com

Abstract: Biometric methods are aimed at identifying a person based on their unique characteristics. The article considers keyboard handwriting as a dynamic biometric characteristic. The features necessary for identification are analyzed and selected. The algorithm for generating a keystroke dynamics pattern is based on recording time parameters. Classical statistical approaches to identifying users based on keystroke dynamics are considered. To solve the identification problem, it is proposed to use a client-server application, its characteristics are given, tests are conducted, and the results are analyzed.

Keywords: FAR, FRR, dynamic biometric characteristics, identification, biometrics, data protection, keystroke dynamics, information security, database

INTRODUCTION

Currently, significant attention is being devoted to the enhancement, development, and implementation of methods and algorithms for identity recognition based on biometric technologies. With the development and expansion of the scope of application of computer technologies, the seriousness of the problem of ensuring security in computing systems and controlling access in distributed information systems is increasing for a number of objective reasons [1].

In the field of information security, biometrics is understood as a field of knowledge that describes the method of identifying and verifying a person's identity based on their physiological and behavioral characteristics. While in the 1990s, biometric systems were mainly used to protect military facilities and especially sensitive commercial information, now airports, large shopping malls, and many company offices are equipped with biometric systems for use.

The increasing demand has stimulated research in this area, leading to the emergence of new technologies and devices.

Protecting data transmission requires mutual authentication of entities, that is, confirmation of the authenticity of entities connected through communication channels. From a security point of view, each of the above allows solving its own problems.

One of the currently promising approaches is to recognize text typed on the keyboard by analyzing the dynamic biometric characteristics of a person. This method is based on analyzing the following user characteristics [8]:

- Text input speed;
- Key press duration [2];
- time intervals between key presses;



- Number of errors during input (delete button click rate);
- Frequency of use of function keys and combinations relative to one type of input device;
- The degree of arrhythmia during the dialing process and other factors.

GENERAL DESCRIPTIONS OF BIOMETRIC AUTHENTICATION METHODS.

Biometric methods provide identification of a person based on their individual characteristics. The main advantage of these methods is that such characteristics cannot be stolen or transferred to another person.

Biometric methods are divided into physiological, behavioral, and combined methods. Their detailed classification is presented in Figure 1.

While behavioral traits are harder to identify with high accuracy, they are also harder to fake.

Modern biometric authentication is based on two methods [15]:

1) Static method. This is an authentication method that is based on identifying physical characteristics that do not change throughout a person's life. These include fingerprints, iris characteristics, retinal patterns, thermograms, facial geometry, hand geometry, and even parts of the genetic code.

2) Dynamic method. This is an authentication method based on analyzing behavioral characteristics that a user exhibits during their daily activities (e.g., signing, typing, making sounds, etc.).

Biometric authentication does not verify the user with absolute accuracy. Since some applications of strong cryptographic systems, such as authentication systems based on post-quantum transformation, are currently at the theoretical justification and prototype development stage [5], biometric characteristics of users play an important role in the identity verification process. In such cases, there is a possibility of type I (access denied) and type II (invalid access) errors occurring [7].

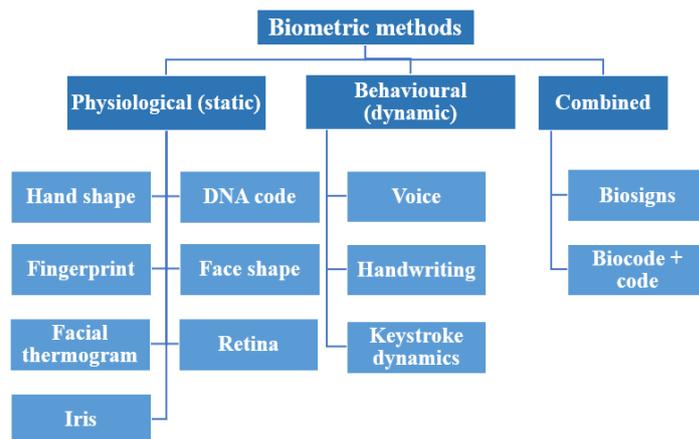


Figure 1 - Classification of biometric methods

The effectiveness of biometric authentication systems is usually assessed by two main characteristics:

- False Rejection (Type I Error – FRR, False Rejection Rate) refers to the probability with which the system fails to recognize a registered user.
- False Access (Type II Error – FAR, False Access Rate) refers to the probability of an unauthorized user being erroneously granted access to the system.

The process of obtaining an individual's evaluation data involves the one-time, periodic, or continuous collection of information about their actions while entering a control word or dataset characteristic of their regular activities.

The main place in the biometric systems market has always belonged to static methods, while dynamic authentication and combined information protection systems occupy only 20% of the market [17].

It should be noted that classical biometric authentication using static methods has a number of problems [13]:

Identify the user only at a certain stage of interaction: login, transaction confirmation, etc.;

- Approaches are based on the analysis of the user's personal data;
- Requires the installation of special technical devices;
- Each additional identification process reduces the success rate of the transaction by 15-20%;



- Based on external (visible) physiological characteristics.

Dynamic biometric authentication methods have the following advantages over static methods:

- Continuous monitoring to detect unauthorized access throughout the entire operation;
- Does not require changing user behavior (hidden identification method);
- Works on all platforms and devices without additional equipment.

It is known that in recent years the development of dynamic protection methods shows a clear trend [12]. A comparison of existing methods is presented in Table 1.

Table 1. Comparison of the effectiveness of using biometric authentication methods

Biometric authentication method	Price	User comfort	Falsification	FAR (False Acceptance Rate)	FRR (False Rejection Rate)
2D Face Recognition	Medium	Medium	Possible	0,1%	2,5 %
3D Face Recognition	High	Medium, Low medium	Problematic	0,0005%	0,1 %
Fingerprint	Low	Medium	Possible	0,001%	0,6 %
Iris	High	High	Impossible	0,00001%	0,016 %
Retina of the eye	High	Low	Impossible	0,0001%	0,4 %
Palm veins pattern	Medium	Medium	Impossible	0,0008%	0,01 %
Voice	Low	Medium	Possible	0,75%	0,75 %
Keystroke dynamics	Low	High	Possible	0.01%	0,01 %

Based on the above data, it can be said that the use of dynamic biometric authentication methods, especially the keyboard handwriting method, meets the requirements. It should be noted that three main requirements for authentication must be met [14]:

- Knowledge of information known to the user, such as a password or passphrase;
- Possession of a device specific to the user, such as a computer;
- Biometric data that is specific to the user and allows for the precise identification of the individual.

The role of statistical algorithms in dynamic authentication and identification methods.

Comprehensive research on biometric methods conducted by the National Bureau of Standards has estimated the likelihood of users acquiring keyboard operation skills at 98%, highlighting the successful practical implementation of such systems [16].

Keyboard typing analysis has its own advantages and disadvantages [6], just like other biometric methods [1].

The advantages include the following:

- Biometric identification relies solely on a person’s physical characteristics and does not require any files or passwords.
- The inherent nature of human characteristics makes them extremely difficult to forge.
- Unlike paper-based identifiers (such as passports, driver’s licenses, insurance cards, or tax identification numbers), passwords, or personal identification numbers, biometrics cannot be forgotten or lost; they can always be easily “presented”.

There are a number of complexities in keyboard input analysis [9]:

- Changes in keyboard typing parameters depending on the psychophysical state of the user;
- Changes in keyboard typing parameters based on the keyboard used by the user. According to a scientific study [11], testing a user's typing on different keyboards resulted in a 0.5% difference in the probability of authentication.
- The need to collect a large amount of statistical data for each keystroke analysis, and the lack of databases with KD samples.

Let us focus on the most widely studied approach based on probabilistic-static methods. We compare statistical algorithms with respect to evaluation criteria specific to some functional properties [16] (see Table 2).



Table 2. Authentication and identification using statistical algorithms

Parameters	Test type	Recognition method	FAR	FRR	ERR	Users	Samples
Dwell Time	Statistical	Static	0,47	1,32	2,2	64	310
	Statistical	Dynamic	-	-	-	25	1620
	Hypothesis	Static	1,4	1,4	1,41	100	5000
	Manhattan distance	Static	-	-	9,6	51	20400
	Angle b/w latencies	Static	3,6	4,7	-	15	-
Flight Time	Statistical	Static	0	2,3	-	44	220
	Distance measure (Hamming measure)	Dynamic	8,33	2,6	-	31	-
	Relative, Abs. Distance	Static, Dynamic	0,00 5	5	0,5	205	765
	Degree of disorder	Static	0	0,55	-	18	810
Dwell Time, Flight Time	Statistical	Dynamic	9	5	-	21	-

Based on the results obtained, authentication based on keyboard keystroke analysis can be considered effective. It should also be noted that there is currently no keyboard keystroke analysis application for computer devices, which confirms the importance of further research into dynamic biometric authentication methods.

RESULTS AND DISCUSSION

Introducing dynamic biometric authentication methods based on statistical algorithms. The software being developed is designed to continuously collect information about keyboard keystrokes in Russian/English and identify authorized or unauthorized user actions.

The system is implemented based on client-server architecture. On the client side, there is a program that allows you to read biometric data - keystrokes. The test sample contains the entered password and dynamic properties, as well as the name of the authentication profile. In other words, in the first step, the user registers with the program and thereby creates a profile name. In the second stage, a test pattern is created by entering a passphrase throughout the entire interaction with the device's keyboard, and the time spent holding down the keys is read. The data is sent to the server and, through mathematical calculations, a standard pattern of user keystroke dynamics is formed.

On the server side, there is a database that stores standard data for authentication, and the test samples and standards comparison algorithms also run on the server. As a result, the server returns the final comparison result to the client.

To protect against attacks by unidentified individuals, a secure communication channel is established between the server and the client [10]. The main stages of the application are illustrated in Figure 2.



Figure 2. Steps to use the software

The feature collection stage involves the process of obtaining the values of the parameters described above.

The keyboard template formation stage involves analyzing the values of the obtained parameters, in particular the keystroke durations, and forming a reference template for future comparison based on the values obtained when attempting to log in to the system. The keyboard profile database update phase updates the standards stored in the database. User authentication consists of the processes of verifying the user's identity, granting or denying access.

Currently, there are 2 methods for implementing user authentication based on keyboard dynamics [8]:

1. using a pre-known passphrase;
2. continuously monitoring the user's keyboard activity throughout the entire time the device is being used.

The password method can be used during the authorization stage, but it is more complicated to use, as using this method requires a significant reduction in user experience.



The essence of continuous monitoring is that it can be used both during authentication and after it has been completed:

- Monitoring all user keyboard activity. This requires a large number of resources for the decision-making device, as it requires storing timestamps of all characters entered by the user in a standard database;
- The approach based on frequent bigrams. This requires fewer resources, as only the most frequent letter pairs are used [2].

As part of our scientific research, we have developed a passphrase detection application. This application performs 3 stages of keystroke dynamics detection:

- 1) training;
- 2) threshold formation;
- 3) recognition.

During the training phase, the user enters the password 20 times and sends the data to the server [12]. The received values are processed on the server and a keyboard handwriting standard is formed. The standard is formed based on the principle of calculating the average value of a parameter such as key hold time.

During the threshold generation stage, the user enters the passphrase 5 times and sends the data to the server. At this stage, the Hamming metric is formed on the server [10], in other words, the value of the number of permissible deviations between the time parameters a_1 and the standard a_2 is generated:

$$H = a_1 \oplus a_2. \quad (1)$$

To identify a user by keyboard input, two-dimensional vector values are observed [12]:

$$P = (t_r, t_i), \quad (2)$$

where t_r is the holding time; t_i is the pause duration.

During the authentication phase, after entering the password, the user sees a positive or negative response from the server on the screen. This response indicates whether the user is an “authenticated user” or an “unauthenticated user”.

The application was tested with several users. The users were two students of different genders, aged 18-23. During the testing process, each user trained the system and formed a standard keystroke dynamic (Table 3).

Table 3. Testing the “keystroke_v1” application

Meaning of Hamming measure	The number of repetitions of entering the password during the training phase	The number of characters sent to the server to train the system	Number of recognition iterations	The first type of error rate (FRR)	The second type of error rate (FAR)
User1:46,6	20	120	45	0,44	0
User2:46,6				0,53	0,04
User1:50	40	240	45	0,73	0,044
User2:26,66				0,08	0,77
User1:52,5	60	360	45	0,6	0,42
User2:46,6				0,28	0,64

The following facts were identified during the analysis of Table 3:

- high percentage of type I errors in the first test for the first and second users (44% and 53%, respectively);
- high percentage of type I errors in the second test for the first user (73%), high percentage of type II errors for the second user (77%);
- high percentage of type I errors in the third test for the first user (60%), for the second user – 28%, high percentage of type II errors for the first user – 42%, for the second user – 64%.

The reasons for obtaining these results may be the following facts:

- users experienced discomfort;
- individual psychophysiological state at the time of testing;
- monotonous repetition of the same type of movements in a short period of time.

At this stage of development, the program creates a reference template based on a single parameter, the time the keys are held down, and a passphrase known to both the legitimate user and the attacker. Table 4 presents the results obtained.



Table 4. Testing the “keystroke_v1” application

User	Time parameter value for "r" character, ms (milliseconds)	Time parameter value for "f" character, ms (milliseconds)	Time parameter value for "n" character, ms (milliseconds)	Time parameter value for "e" character, ms (milliseconds)	Time parameter value for "c" character, ms (milliseconds)	The number of repetitions of entering the password during the training phase
User1	80,5	75	97	79	60	20
User2	89	94,5	96,4	87,5	86,5	
User1	86	96	84	87,5	88,5	40
User2	102	101	88,5	86	78	
User1	85	83,5	91,5	92	69,5	60
User2	95	80,5	81,5	90,5	103,5	

Based on the results presented in Table 4, the following conclusions were drawn:

- There was no consistent value for any of the keyboard style template parameters among users, so it can be concluded that each person has a unique typing style;
- During the first test of the system, the smallest difference was observed when pressing and holding the “n” key (0.6 ms), and the largest difference was observed when pressing and holding the “f” key (19.5 ms);
- For the second test of the system, the smallest difference was observed when pressing and holding the “e” key (1.5 ms), and the largest difference was observed when pressing and holding the “r” key (16 ms);
- For the third test of the system, the smallest difference was observed when pressing and holding the “e” key (1.5 ms), and the largest difference was observed when pressing and holding the “c” key (34 ms).

CONCLUSION

According to the test results, it can be concluded that a large percentage of errors of the first and second types are due to insufficient data received on the server to form the keystroke dynamics standard. A single parameter (key hold time) is not enough to model keystroke dynamics. It is important to note that the test was conducted continuously for three experiments. Users entered a certain phrase in a monotonous manner for a while, which was inconvenient for the user. It follows that further tests should be conducted over a long period of time (at least

24 hours) to observe the trend of changes in keystroke dynamics of different people over the same period of time.

It should also be noted that monotonous input of a fixed phrase leads to distortion of the results, which leads to the conclusion that it is more appropriate to conduct tests on free text input.

The problem of assessing the stability and individuality of biometric characteristics remains. Nevertheless, the proposed approach to recognizing a user's biometric image based on keystroke dynamics allows us to reliably identify individuals. Also, additional research is needed in this area, aimed at increasing the reliability and accuracy of the results, modernizing the graphical interface, optimizing the speed of operation, etc.

The research results revealed the following advantages of using dynamic methods of biometric user authentication:

- 1) There is no need to purchase additional equipment [2];
- 2) No additional skills or actions are required from the user;
- 3) If covert authentication is provided, the user may not be aware that additional verification has been enabled and, therefore, cannot notify the intruder about it [15] (if the continuous monitoring method is applied).

The efficiency of user recognition based on dynamic biometric authentication methods reaches 92.14%, which allows us to speak about the high potential of using this method in the development of computer access systems.

REFERENCES

1. Putyato M.M., Makaryan A.S., Chich Sh.M., Markova V.K. Research of the system of identification and confirmation of access legitimacy based on dynamic methods of biometric authentication. *Caspian Journal: Control And High Technologies*, 2020, 3 (51). 83-91. – Language: Russian.
2. M.M. Rasulmukhamedov, N.M. Mirzaev, N.Y. Gafforov, “Personal identification model using keyboard handwriting” // “Informatics and energy problems”. Tashkent 2024, 22-27. – Language: Uzbek.



3. Abdallah Ali A. A. Biometric identification of the person / A. A. Abdallah Ali // Physics and radioelectronics in medicine and ecology: collected works of the 8th International scientific and technical conference with the scientific youth school named after I.N. Spiridonov. - 2008. - Book 2. - P. 145-147. - Language: Russian.
4. Averin A. I. Authentication of users by keyboard handwriting / A. I. Averin, D. P. Sidorov // Ogarev-online. - 2015. - No. 20 (61). - Language: Russian.
5. Vasiliev V. I., Kalyamov M. F., Kalyamova L. F. Identification of users by keyboard handwriting using an algorithm for registering frequent bigrams / V. I. Vasiliev, M. F. Kalyamov, L. F. Kalyamova // Modeling, optimization and information technology. 2018. - T. 6, No. 1. - P. 399-407. - Language: Russian.
6. Brumshtein Yu. M. Analysis of the efficiency of using various software and hardware solutions for studying the dynamics of human signature execution / Yu. M. Brumshtein, D. V. Kharitonov, M. V. Ivanova // Physics and radio electronics in medicine and ecology: collection of works of the XI International scientific and technical conference with the scientific youth school named after I. N. Spiridonov. - 2014. - Book 2. - P. 56-60. - Language: Russian.
7. Gorelik A. L. Methods of recognition / A. L. Gorelik, V. A. Skripkin. - Moscow: Higher School, 1984. - 80 p.
8. Odinets D. N. Methods of constructing personal identification systems based on biometric parameters / D. N. Odinets // Electronic Commonwealth. High-Tech Park. Secure Telematic Applications: Reports of the V International Congress. Minsk, November 10-11, 2005 / edited by M. M. Makhanka, V. E. Kratenok. - Minsk: State Institution "BellISA", 2005. - P. 152.
9. Putyato M. M. Classification of messengers based on the analysis of the security level of stored data / M. M. Putyato, A. S. Makaryan // Caspian journal: management and high technologies. - 2019. - P. 135-143. - Language: Russian.
10. Savinov A. N. Solving the problems of errors of the first and second kind in keyboard handwriting recognition systems / A. N. Savinov, I. G. Sidorkina // 81 - ICT: education, science, innovation: proceedings of the III International. scientific-practical conf. - Almaty: IITU, 2012. - Language: Russian.
11. Sidorkina I. G. Three algorithms for controlling access to CSII based on recognition of the operator's keyboard handwriting / I. G. Sidorkina, A. N. Savinov // Bulletin of the Chuvash University. - 2013. - No. 3. Language: Russian.
12. Skuratov S. V. Using keyboard handwriting for authentication in computer information systems / S. V. Skuratov // Information technology security. - 2010. - Language: Russian.
13. Trotsky D. P. Biometric signature recognition system / D. P. Trotsky, K. V. Chirkov, L. T. Sushkova // Physics and radio electronics in medicine and ecology: collection of works of the 8th International scientific and technical conference with the scientific youth school named after I. N. Spiridonov. - 2008. - Book 2. - P. 162-165. - Language: Russian.
14. Khodashinsky I. A. Technology of enhanced authentication of users of information processes / I. A. Khodashinsky, M. V. Savchuk, I. V. Gorbunov, R. V. Meshcheryakov // Management, computing technology and informatics. - 2011. - P. 236-248. - Language: Russian.
15. Biometric identification and authentication. - Access mode: http://www.techportal.ru/glossary/biometriceskaya_identifikaciya.html, free. - Title from the screen. - Language: Russian.
16. What is the secure access strategy for banking products. - Access mode: <http://www.smartsecurity.tech/wp-content/uploads/2017/03/Smart-Security.pdf>, free. - Title from the screen. - Language: Russian.
17. Methods of biometric identification: comparative analysis. - Access mode: http://www.biometrics.ru/news/metodi_biometriceskoi_identifikacii_sravnitelnii_analiz/, free. - Title from the screen. - Language: Russian.
18. El-Hadidi Kamal M. Biometrics. What and How. - Access mode: <http://www.netsecurity.org/dl/articles/Biometrics.pdf>, free. - Title from the screen. - Language: English.
19. Modern methods of biometric identification. - Access mode: <https://www.azoneit.ru/sovremennyye-metody-biometriceskoy-identifikacii>, free. - Title from the screen. - Language: Russian.



TO'LIQ FAZOGA ASOSLANGAN MULTISINFLI KLASTERLASH ALGORITMI

Ollamberganov Fayzulla Farxod o'g'li,

Muhammad al-Xorazmiy nomidagi Toshkent axborot
texnologiyalari universiteti tizimli va amaliy
dasturlashtirish kafedrasida doktoranti
fayzulla0804@gmail.com,
ORCID: 0000-0001-6450-0467

Kalbayerov Allambergen Markabayevich,

Berdaq nomidagi Qoraqalpoq davlat universiteti
Algoritmlik va dasturlash texnologiyalari
kafedrasida stajyor-o'qituvchisi
allambergenkalbayev1@gmail.com,
ORCID: 0009-0007-0903-0643

Yelmuratov Qudiyar Qarjaobay uli,

Berdaq nomidagi Qoraqalpoq davlat universiteti
Algoritmlik va dasturlash texnologiyalari
kafedrasida assistenti
qudiyari95@gmail.com,
ORCID: 0009-0004-0293-9975

Qudaynazarov Muxammed Sadiq uli,

Berdaq nomidagi Qoraqalpoq davlat universiteti
Algoritmlik va dasturlash texnologiyalari
kafedrasida stajyor-o'qituvchisi
m.qudaynazarov@gmail.com,
ORCID: 0000-0003-4619-7729

Annotatsiya. Katta ma'lumotlar ko'payishi va ma'lumot hajmi hamda xilma-xilligining o'sishi bilan ma'lumotlarning murakkabligi ham oshib bormoqda. An'anaviy klasterlash usullari faqat bitta klasterlash natijasini taqdim etadi, bu esa ma'lumotlarni tadqiq qilishni yagona mumkin bo'lgan bo'linma bilan cheklaydi. Bundan farqli o'laroq, multisinfl klasterlash usullari bir vaqtning o'zida yoki izchil ravishda bir nechta takrorlanmaydigan va o'ziga xos klaster yechimlarini ochib beradi. Bu ma'lumotlarning yashirin tuzilmalarini aniqlash imkonini beradi. Shu sababli, multisinfl klasterlash bugungi kunda mashhur va istiqbolli tadqiqot yo'nalishiga aylangan. Ushbu tadqiqotda obyektlarning muhimligiga qaratilgan multisinfl klasterlash masalasi yondashuvi va algoritmi ishlab chiqilgan.

Kalit so'zlar: Klasterlash, multisinfl klasterlash, o'qituvchisiz klasterlash, MAXIMUS usuli

KIRISH. Klasterlash ma'lumotlarni tahlil qilishning asosiy usuli bo'lib, ma'lumotlarning yashirin guruhlash tuzilmasini aniqlashga yordam beradi.

Klasterlash - bu ma'lumotlarda yashirin guruhlash tuzilmasini aniqlashga qaratilgan asosiy ma'lumot tadqiqoti vazifasi hisoblanadi. Klasterlash

usullari turli sohalarda, jumladan, ijtimoiy tarmoqlarni tahlil qilish, bioinformatika, kompyuter ko'rish va boshqa ko'plab yo'nalishlarda muvaffaqiyatli qo'llanilmoqda. Ammo ma'lumki, klasterlar tushunchasi "quruvchining o'ziga bog'liq". Klaster nimani anglatishi qo'llanish ehtiyojlariga bog'liq.



Masalan, meva turlarini rang, shakl, kelib chiqishi yoki boshqa qoidalar asosida guruhlash mumkin.

Ushbu muammolarning ba'zilarini hal qilish uchun turli maqsad funksiyalariga asoslangan klasterlash usullari ishlab chiqilgan. Shu bilan bog'liq yana bir masala - klasterlash natijasining sifati. Qabul qilingan qarashlardan biri shuki, yaxshi klasterlash ma'lumotlarning "barqaror" tuzilishini aks ettirishi kerak. Biroq, ma'lumotlarda bir nechta barqaror klasterlash tuzilmalari mavjud bo'lishi mumkin. Berilgan ma'lumotlar to'plami uchun aniqlangan klasterlash tuzilmasi qo'llanilgan klasterlash algoritmi va kiritilgan parametrlarga bog'liq bo'ladi.

Bir nechta mumkin bo'lgan tuzilmalar mavjudligi multisinfl klasterlash yondashuvlarini rivojlantirishga asos bo'ladi. Multisinfl klasterlash usullari oddiy, biroq mantiqiy taxminga asoslanadi. Bir ma'lumotlar to'plamini klasterlarga bo'lishning bir nechta usullari bo'lishi mumkin. Har bir bo'linma ma'lumot namunalarning turli xil guruhlanishini yaratadi va ma'lumotlarni turli nuqtai nazarlar yoki gipotezalardan kelib chiqqan holda talqin qilish imkonini beradi.

Shuningdek, katta ma'lumotlarning doimiy ravishda ortib borayotganidan kelib chiqib, ma'lumot tuzilmasi tobora murakkablashib bormoqda. Bir obyekt turli xil xususiyat ko'rsatkichlari orqali tavsiflanishi mumkin, bu esa turli tuzilishni shakllantiradi. Masalan, saratoning ma'lum namunalari gen ekspressiyasi ma'lumotlari yoki metilatsiya ma'lumotlari orqali tasvirlanishi mumkin; televizion kliplar esa video va audio ko'rinishida tavsiflanadi.

Yakka ko'rinishga asoslangan klasterlash usullari bilan solishtirganda, ko'p ko'rinishli klasterlash turli ko'rinishlar o'rtasidagi umumiy va to'ldiruvchi ma'lumotlarni birlashtirib, yaxlit klasterlashni ta'minlashi mumkin. Biroq, bu usullar faqat bitta klasterlash yechimini taqdim etadi, bu esa murakkab ko'p ko'rinishli ma'lumotlarning xilma-xil klasterlashlarini to'liq ochib bera olmasligi mumkin. Shu bois, ma'lumotlarning turli ko'rinish tuzilmalarini ochib berish uchun multisinfl klasterlashni tadqiq qilish muhim ahamiyatga ega.

Shuni qayd etish joizki, klasterlashning dastlabki bosqichi ham bir nechta bazaviy klasterlash yechimlarini yaratadi, biroq asosiy maqsad ularni birlashtirib, yagona klasterlashni shakllantirishdir. Bunga qarshi ravishda, multisinfl klasterlashning asosiy maqsadi ma'lumotlarning turli nuqtai nazarlari yoki gipotezalarini tavsiflay oladigan xilma-xil klasterlashlarni tadqiq qilishdan iborat bo'lib, har bir klasterlash ma'lumotlarning o'ziga xos guruhlanishini taqdim etadi.

ADABIYOTLAR TAHLILI VA METODOLOGIYA. Multisinfl klasterlash yechimlari bir vaqtning o'zida yuqori sifat va xilma-xillik talablarini qondirishi kerak. Sifat, odatda, har bir klasterning zich va yaxshi ajralgan bo'lishini talab qiladi, xilma-xillik esa klasterlar o'rtasidagi o'zaro farqlarni talab qiladi. Multisinfl klasterlashga bo'lgan ehtiyojning oshib borishi bilan, so'nggi o'n yillikda ko'plab usullar taklif etilgan.

Ushbu metodlar klasterlashni amalga oshiriladigan belgilar fazosi asosida tasniflanadi. Multisinfl klasterlash usullarining to'liq fazoda klasterlash usullari 1-jadvalda [1] umumlashtirilgan, har bir kategoriya uchun metodlar chop etilgan yiliga ko'ra keltirilgan.

1-jadval. Multisinfl klasterlash usullarini toifalarga ajratish(yil bo'yicha)

Kategoriyasi	Usullari	Yili
To'liq fazoga asoslangan	CIB	2003
	CondEns	2005
	COALA	2006
	Meta Clustering	2006
	CCIB	2007
	ConvEM	2008
	De-Kmeans	2008
	MAXIMUS	2010
	CAMI	2010
	MVCV	2017
	MNMF	2017
	TMC	2018
	PPTMC	2019
	TDMC	2020
	MultipleWishart	2021
AugDMC	2023	



Yangi rivojlanayotgan yo'nalish sifatida, multisinfl klasterlash so'nggi yillarda tez sur'atlar bilan rivojlandi, va ushbu mavzuga doir so'nggi tahlil ishi 2017 yilda nashr etilgan [5]. Myuller va boshqalar [11] multisinfl klasterlashning bir nechta amaliy qo'llash ssenariylarini taqdim etib, mavjud qiyinchiliklarni va ochiq muammolarni umumlashtirgan. Aggarval va boshqalar [12] hamda Beyli va boshqalar [13] alternativ klasterlashni yaratish algoritmlarini ko'rib chiqib, multisinfl klasterlash, ko'p turli klasterlash, va qisman fazo klasterlash o'rtasidagi bog'lanishlarni muhokama qilishgan.

2017 yildagi tahliliy ishda faqat qisman fazoga asoslangan multisinfl klasterlash usullari muhokama qilingan [5]. So'nggi yillarda yanada ilg'or multisinfl klasterlash usullari va yangi vazifalar paydo bo'ldi.

Gondek va boshqalar [2] axborot idishi (information bottleneck) doirasini kengaytirib, Shartli Axborot idishi (Conditional Information Bottleneck, CIB) deb nomlangan birinchi multisinfl klasterlash usulini taklif qildilar. Bu usul alternativ klasterlashni tadqiq qilish imkonini beradi.

CIB va CCIB axborot nazariyasini qo'llab, takrorlanmaydigan alternativ klasterlarni yaratishda muvaffaqiyatli qo'llaniladi. Biroq, ular faqat ikki klasterni tadqiq qilish imkoniyatiga ega va bu klasterlarning sifati hamda xilma-xilligiga qo'yilgan cheklovlar yetarlicha asoslanmagan. Ushbu usullar asosan matnli ma'lumotlar uchun mo'ljallangan bo'lib, boshqa turdagi ma'lumot to'plamlariga nisbatan qo'llanilishi hali o'rganilmagan.

Shartli Ensebl klasterlash (Conditional Ensemble clustering, CondEns) [3] - bu CIB va CCIB asosida ishlangan uch bosqichli ensebl klasterlash usuli. Birinchi bosqichda, ma'lum bo'lgan klaster yechimi $C_1 = (C_1^1, C_2^1, \dots, C_K^1)$ uchun har bir klasterga tegishli bo'lgan obyekt uchun lokal klaster yechimi hisoblanadi. Ikkinchi bosqichda, lokal klasterga tegishli bo'lmagan obyektlardan birini unga tegishli klasterga ajratish orqali har bir lokal klaster global klasterga kengaytiriladi. Barcha global klasterlar CIB asosidagi muvofiqlik funksiyasi orqali birlashtirilib, muvofiqlashtirilgan klasterlash yaratiladi.

CondEns usulining matndan tashqari ma'lumotlar (masalan, rasm, biologiya va audio) bo'yicha samaradorligini yanada chuqurroq tadqiq qilish maqsadga muvofiqdir.

Beyli va hammualliflar [8] Mul'tisinfl klasterlar o'rtasida maksimal farqni aniqlash (MAXIMUS) usulini taklif qildilar. Bu usul m ta alternativ klasterlarni $C = \{C_1, C_2, \dots, C_m\}$ yaratish uchun atributlar taqsimotiga asoslangan klaster ortogonallik o'lchovi (ADCO) ni maqsad funksiyasi sifatida ishlatadi.

Oldindan belgilangan boshlang'ich klasterlash C_1 asosida, MAXIMUS alternativ klasterlash bilan C_1 o'rtasidagi farqni maksimallashtirish uchun butun sonli dasturlash (IP) modelini shakllantiradi. IP modeli natijasi alternativ klasterlarning har biri atribut-bin hududidagi klasterlarga taqsimlanishi lozim bo'lgan nuqtalar sonini ko'rsatadi. Bu taqsimot ma'lumoti lokal klasterlar yaratish uchun cheklangan k-means usuliga kiritiladi.

MAXIMUS da barcha lokal klasterlarni majoritar ovoz berish orqali birlashtirib, alternativ klasterlar C_l ($1 \leq l \leq m$) hosil qiladi.

MAXIMUS k-means va konsensus klasterlash orqali multisinfl klasterlashning sifatini oshiradi hamda IP modeli orqali ularning xilma-xilligini ta'minlaydi.

MASALANING QO'YILISHI

Faraz qilaylik N - o'lchovli nominal va qiymatli belgilar fazosida $x_i \in X$, $i = \overline{1, M}$, obyektlar berilgan bo'lsin. Demak, $x_i = (x_i^1, x_i^2, \dots, x_i^N)$, $i = \overline{1, M}$, obyektning N - o'lchovli nominal va qiymatli belgilar fazosida berilgan. Va ularning barchasi X to'plam obyekti hisoblanadi.

Masala. Berilgan umumiy tanlanma asosida o'quv tanlanmalarni shakllantirish talab etilsin. Ya'ni, quyidagi ko'rinishda ifodalangan $x_{p1}, x_{p2}, \dots, x_{pm_p} \in X_p$, $p = \overline{1, r}$ sinflarni shakllantirish talab etilsin. Bu yerda x_{pi} - N - o'lchovli nominal va qiymatli belgilar fazosidagi X_p sinfnig i - obyekt deb o'qiladi va u N - o'lchovli nominal va qiymatli belgilar fazosida quyidagi ko'rinishda yoziladi $x_{pi} = (x_{pi}^1, x_{pi}^2, \dots, x_{pi}^N)$, $i = \overline{1, m_p}$, N - o'lchovli nominal va



qiymatli belgilar fazosida qaralgan, X_p sinfdagi m_p ta x_{p1}, \dots, x_{pm_p} obyektlardan tashkil topgan $X = \bigcup_{p=1}^r X_p$. Bu masala adabiyotlarda [14-15] obyektlarni klasterlashtirish masalasi deb yuritiladi.

Quyidagi kattalik va belgilashlar kiritiladi

Nominal belgilar fazosida obyektlarning o'xshashligini ko'rsatuvchi kattalik $\rho^j(x_{pi}, x_{pq})$ orqali belgilanib, (1) formula asosida hisoblansin, ya'ni

$$\rho_{pi}^j(x_{pi}, x_{pq}) = \begin{cases} 1, & \text{agar } (x_{pi}^j - x_{pq}^j) = 0; \\ 0, & \text{aks holda} \end{cases} \quad (1)$$

Sonli belgilar fazosida obyektlarning o'xshashligini ko'rsatuvchi kattalik $\rho^j(x_{pi}, x_{pq})$ orqali belgilanib, (2) formula asosida hisoblansin, ya'ni

$$\rho_{pi}^j(x_{pi}, x_{pq}) = \begin{cases} 1, & \text{agar } |x_{pi}^j - x_{pq}^j| \leq \varepsilon^j \\ 0, & \text{aks holda} \end{cases} \quad (2)$$

$p = \overline{1, r}; i \neq q = \overline{1, m_p}; j = \overline{1, N}$; Ifodalangan (1) va (2) kattaliklar vektorning parametrlari bo'lib, u quyidagi

$$\rho_{pi}(x_{pi}, x_{pq}) = (\rho_{pi}^1(x_{pi}, x_{pq}), \rho_{pi}^2(x_{pi}, x_{pq}), \dots, \rho_{pi}^N(x_{pi}, x_{pq}))$$

ko'rinishda ifodalanadi. Demak, qaralayotgan j -belgi nominal bo'lsa $\rho_{pi}(x_{pi}, x_{pq})$ vektorning j -belgisi (1) formuladan foydalanib hisoblanadi, aks holda, ya'ni belgi sonli bo'lsa, u holda vektorning shu belgisi (2) - formula asosida hisoblanadi. Bunda j -belgiga mos ε^j -bo'sag'aviy qiymatlar sinf obyektlarining har bir belgisi uchun quyidagi formula orqali amalga oshiriladi:

$$\varepsilon^j = \frac{1}{M-1} \sum_{i=1}^{M-1} |x_{pi}^j - x_{pi+1}^j|,$$

bu yerda $j = \overline{1, N}; p = \overline{1, r}; i = \overline{1, M-1}$; ga teng.

Yuqorida keltirilgan klasterlash masalasini yechishning quyidagi bosqichlarini keltirib o'tamiz:

1. Obyekt ma'lumotlari $x_i = (x_i^1, x_i^2, \dots, x_i^N) \in X, i = \overline{1, M}$ ga dastlabki ishlov beriladi. Bunda tushib qolgan ma'lumotlar to'ldiriladi, anomal ma'lumotlar o'rta qiymatga almashtiriladi va

miqdoriy belgilar normirovka qilinadi. Normirovka barcha miqdoriy belgilar uchun quyidagi formula asosida amalga oshiriladi:

$$x_i^j = \frac{x_i^j - \min x_i^j}{\max x_i^j - \min x_i^j}, i = \overline{1, M}; j = \overline{1, N};$$

2. So'ngra, obyektlari $x_i \in X, i = \overline{1, M}$, obyektlarini ixtiyoriy ravishda r ta sinfga ajratiladi. Ya'ni, ixtiyoriy $x_{p1}, x_{p2}, \dots, x_{pm_p} \in X_p, p = \overline{1, r}$ sinflarga ajratiladi;

3. Yuqorida keltirilgan (1) va (2) formulalar asosida barcha $p = \overline{1, r}; i \neq q = \overline{1, m_p}; j = \overline{1, N}$; lar uchun $\rho_{pi}(x_{pi}, x_{pq})$ vektorning barcha parametrlarini hisoblanadi. Ya'ni $\rho_{pi}(x_{pi}, x_{pq}) = (\rho_{pi}^1(x_{pi}, x_{pq}), \rho_{pi}^2(x_{pi}, x_{pq}), \dots, \rho_{pi}^N(x_{pi}, x_{pq}))$ vektor belgilari $p = \overline{1, r}; i \neq q = \overline{1, m_p}; j = \overline{1, N}$; lar uchun oldindan hisoblanadi;

4. Ixtiyoriy p -sinfdagi i -obyektni qolgan, shu sinfdagi $m_p - 1$ ta obyektlar majmuasidagi tutgan o'rni quyidagicha baholanadi va uni oldindan quyidagi formula asosida hisoblanadi:

$$\Gamma_{pi}(x_{pi}, X_p) = \frac{1}{m_p - 1} \sum_{q=1}^{m_p-1} \sum_{j=1}^N \rho^j(x_{pi}, x_{pq}), p = \overline{1, r}; i = \overline{1, m_p}; i \neq q.$$

5. Ixtiyoriy p -sinfnin umumiy bahosi $\Gamma_p(X_p) = \frac{1}{m_p} \sum_{i=1}^{m_p} \Gamma_{pi}(x_{pi}, X_p), p = \overline{1, r}$ mezon asosida hisoblanadi. Ularning obyektlarining o'xshashlik darajasi quyidagicha baholanadi

$$v_p(X_p) = \frac{\Gamma_p(X_p) * 100\%}{N}, p = \overline{1, r}$$

Shuningdek, ixtiyoriy p -sinfdagi i -obyekt boshqa $X_q, q = \overline{1, r-1}$ ta sinf obyektlari tomonidan ham baholanadi:

$$\Gamma_{pi}(x_{pi}, X_q) = \frac{1}{m_q} \sum_{k=1}^{m_q} \sum_{j=1}^N \rho^j(x_{pi}, x_{qk}), p = \overline{1, r}; i = \overline{1, m_p}; i \neq q.$$

bunda p -sinfdagi i -obyekt qaysi sinf obyektlari tomonidan yuqori baholansa o'sha sinfga o'tkaziladi. Yuqori baholar teng bo'lsa o'z sinfdagi qoldiriladi. Agar



p –sinfda emas boshqa ikkita sinfda yuqori qiymatlar teng bo‘lsa, u holda ushbu obyekt q ko‘rsatkichi kichigiga o‘tkaziladi.

6. Odatda, shakllangan sinflarda obyektlarining o‘xshashlik darajalari $v_p(X_p) \geq \delta \geq 55\%$ bo‘lishligi talab etiladi.

Ushbu hisoblashlar barcha $x_{pi}, p = \overline{1, r}; i = \overline{1, m_p}$; obyektlar uchun bajariladi va hosil bo‘lgan yangi $x_{p1}, x_{p2}, \dots, x_{pm_p} \in X_p, p = \overline{1, r}$ sinflar haqiqiy klasterlangan o‘quv tanlanmani beradi.

TADQIQOT NATIJALARI. To‘liq fazoda multisinfl klasterlashni tadqiq qilish uchun turli usullar taklif qilingan bo‘lib, ular texnik jihatlar bo‘yicha sezilarli darajada farq qiladi. Ularning orasida, o‘qituvchisiz multisinfl klasterlash usullari oldingi klasterlarga tayanmaydi, shuning uchun ular ko‘pincha bir vaqtning o‘zida turli xil klasterlarni yaratish imkoniga ega.

Boshqa tomondan, yarim-nazoratli yondashuvlar ko‘pincha mavjud klasterlarga murojaat qilib, alternativ klasterlarni izlab topadi. Shu bois, yarim-nazoratli usullar tomonidan yaratilgan klasterlar o‘rtasidagi xilma-xillikni boshqarish osonroq, ammo ularning sifati asosan avvalgi klasterlarga bog‘liq bo‘ladi.

O‘qituvchisiz o‘qitish usullar oldingi klasterlarga bog‘liq bo‘lmagan bo‘lsa-da, ular multisinfl klasterlarning xilma-xilligi va sifati o‘rtasida muvozanatni ta‘minlashda qiyinchilikka duch keladi.

To‘liq fazoga asoslangan multisinfl klasterlash usullarining asosiy xususiyatlari 2-jadvalda umumlashtirilgan.

2-jadval. To‘liq fazoga asoslangan multisinfl klasterlash usullarining o‘ziga xos xususiyatlari

Tasnifi	Usullar	Turli xilligi	Sifati	Afzalligi	Kamchiligi
Yarim-o‘qituvchili	CIB [2]; CCIB [7]	✓	✓	Axborot nazariyasi tamoyillaridan foydalanib, muqobil klasterlarni izlash	≤ 2 klaster uchun ishlatiladi
	COALA [4]	✓	✓	Turli klasterlarni oldindan ma‘lum bo‘lgan bilim sifatida umumlashtirish mumkin.	Hisoblash ishlariga ko‘p vaqt sarflanadi
	MAXIMUS [8]	✓	✓	Sifat va xilma-xillikni muvozanatga keltirish uchun regulatsiya parametrlarini belgilash talab etilmaydi.	Binning strategiyasini ko‘rsatish zarur.
	MNMF [10]	✓		Bir nechta klasterlashni o‘rganish uchun matritsa faktorlashdan foydalanadi.	Xilma-xillikka e‘tibor qaratadi, ammo sifatga emas.
	MNMF [10]	✓		Kraudsorsing ekspertlarining bilimi yordamida klasterlar orasidagi takrorlanishlarni kamaytiradi.	Past sifatlilik ko‘plab klasterlarni hosil qiladi.
O‘qituvchisiz	Meta Clustering [6]	✓		Bir nechta klasterlash uchun meta darajadagi nuqtani taqdim etadi.	Xilma-xillik va sifatlilik samarali muvozanatlashira olmaydi.
	Meta Clustering [6]	✓	✓	Ikkitadan ortiq klasterlarni yaratish uchun osonlik bilan kengaytirilishi mumkin.	Tabiiy tushuntirishga ega bo‘lmagan vakillik vektorlarini hosil qilishi mumkin.
	CAMI [9]	✓	✓	Mixture modeli asosida multisinfl klasterlash masalasi shakllantiriladi.	≤ 2 klaster uchun ishlatiladi

bu yerda ✓ belgi usulning multisinfl klasterlashning xilma-xilligi yoki sifatiga e‘tibor qaratishini bildiradi.

To‘liq fazoda berilgan ob’ektlarni klasterlash algoritmi

Maqolada bayon qilingan masalaning yechimini topishning algoritmi quyida keltirilgan. Algoritm oltita banddan iborat bo‘lib, klasterlash masalalarining to‘liq fazoga asoslangan sinf ob’ektlari uchun qo‘llansa maqsadga muvofiq bo‘ladi.

Birinchi qadam. Obyekt ma‘lumotlari $x_i = (x_i^1, x_i^2, \dots, x_i^N) \in X, i = \overline{1, M}$ ga dastlabki ishlov beriladi. Bunda tushib qolgan ma‘lumotlar to‘ldiriladi, anomal ma‘lumotlar o‘rta qiymatga almashtiriladi va miqdoriy belgilar normirovka qilinadi.



Ikkinchi qadam. O'quv tanlanma ob'ektlari ma'lumotlar bazasiga kiritiladi. Boshlang'ich ma'lumotlar bazasi barcha $X_p, p = \overline{1, r}$ sinf ob'ektlari kesimida shakllantiriladi;

Uchinchi qadam. X_p sinf ob'ektlarining o'z sinfini shakllanishiga qo'shgan xissasini baholashni aniqlashda ishlatiladigan nominal belgilar fazosida ob'ektlarning *o'xshashligini ko'rsatuvchi kattalik* (1) va sonli belgilar fazosida ob'ektlarning *o'xshashligini ko'rsatuvchi kattalik*(2) formulaga asosan hisoblanadi;

To'rtinchi qadam. Tanlanma belgilarida ixtiyoriy p –sinfdagi i – ob'ektni qolgan, shu sinfdagi $m_p - 1$ ta ob'ektlar majmuasidagi tutgan o'rni yuqorida keltirilgan klasterlash masalasini yechishning 3-bosqichidagi formula asosida hisoblanadi;

Beshinchi qadam. Tanlanma belgilarida ixtiyoriy p –sinfdagi i –ob'ekt boshqa $X_q, q = \overline{1, r - 1}$ ta sinf ob'ektlari tomonidan baholanishi yuqorida keltirilgan klasterlash masalasini yechishning 4-bosqichidagi formula asosida hisoblanadi;

Oltinchi qadam. Tanlanma belgilarida ixtiyoriy p –sinfdagi i –ob'ekt qaysi sinf ob'ektlari tomonidan yuqori baholansa o'sha sinfga o'tkaziladi. Yuqori baholar teng bo'lsa o'z sinfida qoldiriladi. Agar p –sinfdan emas boshqa ikkita sinfdan yuqori qiymatlar teng bo'lsa, u holda ushbu ob'ekt q ko'rsatkichi kichigiga o'tkaziladi.

XULOSA. Ko'p o'lchamli va murakkab ma'lumotlarni guruhlashda an'anaviy klasterlash usullari faqat bitta natijaga olib kelishi sababli, multisinfl klasterlash usullari turli istiqbolli alternativ yechimlarni topishga imkon beradi. Ushbu tadqiqotda mavjud multisinfl klasterlash usullari tahlil qilinib, ular turli yondashuvlar asosida tasniflandi. Xususan, ma'lumotlar to'plami turli o'lchov bo'yicha segmentlarga ajratilishi mumkinligi sababli, original fazoda, qism fazolarda va ko'p ko'rinishli ma'lumotlarda klasterlash metodlari o'rganildi.

Tahlil natijalari shuni ko'rsatadiki, turli metodlarning afzallik va kamchiliklari mavjud bo'lib, ba'zilar yuqori sifatli klasterlash natijalarini ta'minlaydi, boshqalari esa xilma-xillikka urg'u beradi. Ayniqsa, qismfazo va ko'p ko'rinishli ma'lumotlar

asosida amalga oshirilgan multisinfl klasterlash algoritmlari katta hajmdagi ma'lumotlarda samarali ishlashi bilan ajralib turadi.

Taklif etilgan nazariy tadqiqotlar, algoritmlar asosida yuqorida bayon etilgan masala yechilgan. Algoritmlarning asosiy afzalliklari va kamchiliklari tahlil qilindi.

Xulosa qilib aytganda, maqolada taklif etilgan algoritmlar ob'ektlarning muhimlik darajalari va sinflar shakllanishiga qo'shgan hissasiga asoslanib ularni klasterlash va sinflashtirish jarayonini samarali boshqarish imkonini beradi.

FOYDALANILGAN ADABIYOTLAR

1. G. Yu, L. Ren, J. Wang, C. Domeniconi, X. Zhang, Multiple clusterings: Recent advances and perspectives, Computer Science Review, Volume 52, 2024, <https://doi.org/10.1016/j.cosrev.2024.100621>
2. D. Gondek, T. Hofmann, Conditional information bottleneck clustering, in: IEEE International Conference on Data Mining, 2003, pp. 36–42.
3. D. Gondek, T. Hofmann, Non-redundant clustering with conditional ensembles, in: ACM SIGKDD International Conference on Knowledge Discovery in Data Mining, 2005, pp. 70–77.
4. E. Bae, J. Bailey, Coala: A novel approach for the extraction of an alternate clustering of high quality and high dissimilarity, in: IEEE International Conference on Data Mining, 2006, pp. 53–62.
5. J. Hu, J. Pei, Subspace multi-clustering: a review, Knowl. Inf. Syst. 56 (2) (2018) 257–284.
6. R. Caruana, M. Elhawary, N. Nguyen, C. Smith, Meta clustering, in: IEEE International Conference on Data Mining, 2006, pp. 107–118.
7. D. Gondek, T. Hofmann, Non-redundant data clustering, Knowl. Inf. Syst. 12(1) (2007) 1–24.
8. E. Bae, J. Bailey, G. Dong, A clustering comparison measure using density profiles and its application to the discovery of alternate clusterings, Data Min. Knowl. Discov. 21 (3) (2010) 427–471.
9. X.H. Dang, J. Bailey, Generation of alternative clusterings using the cami approach, in: IEEE International Conference on Data Mining, 2010, pp. 118–129.
10. S. Yang, L. Zhang, Non-redundant multiple clustering by nonnegative matrix factorization, Mach. Learn. 106 (2017) 695–712.



11. E. Muller, S. Gunnemann, I. Farber, T. Seidl, Discovering multiple clustering solutions: Grouping objects in different views of the data, in: IEEE International Conference on Data Engineering, 2012, pp. 1207–1210.
12. C.C. Aggarwal, C.K. Reddy, Data clustering, in: Algorithms and Applications, 2013, Citeseer.
13. J. Bailey, Alternative clustering analysis: A review, in: Data Clustering, Chapman and Hall/CRC, 2013, pp. 535–550.
14. Nishanov A., Ruzibaev O., Chedjou J. C., Kyamakya K., Abhiram, Kolli, De Silva, Djurayev G., Khasanova M. Algorithm for the selection of informative symptoms in the classification of medical data // Developments Of Artificial Intelligence Technologies In Computation And Robotics, Volume:12, 2020, p. 647-658, doi:[10.1142/9789811223334_0078](https://doi.org/10.1142/9789811223334_0078)
15. Nishanov, A., Akbarova, M., Tursunov, A., Ollamberganov, F., & Rashidova, D. (2024). Clustering algorithm based on object similarity. *Journal of Mathematics, Mechanics and Computer Science*, 123(3), 108–120. <https://doi.org/10.26577/JMMCS2024-v123-i3-4>.



ИЗУЧЕНИЕ ЗНАЧЕНИЙ СУММАРНОЙ – $\Sigma\alpha$, СУММАРНОЙ - $\Sigma\beta$ – АКТИВНОСТИ И НЕКОТОРЫХ ИЗОТОПОВ ПРИРОДНЫХ ВОД ОТОБРАННЫХ ИЗ УРАНОНОСНЫХ РЕГИОНОВ

Аллаберганова Г.М.

Доктор философии (PhD) по химическим наукам,
доцент НГГТУ
allaberganovagulchehra4@gmail.com

Тогаев Б.С.

Докторант СамГУ
b-togayev@gmail.ru

Хайдаров У.Э.

Докторант СамГУ
xaydarovumid02@gmail.com

Кувватова М.А.

Ассистент НГГТУ
mokhinurquvvatova@gmail.com

Асадова Г.А.

Ассистент НГГТУ
guliasadova1992@gmail.com

Музафаров А.М.

Доктор химических наук, профессор НГГТУ
muzafarov@gngmk.uz

Аннотация: В данной статье приведены результаты изучения значений суммарной - $\Sigma\alpha$ и суммарной - $\Sigma\beta$ -активности природных вод отобранных из ураноносных регионов. В лабораторных условиях изучены методов определение значений суммарной - $\Sigma\alpha$ и суммарной - $\Sigma\beta$ активности природных вод на малофонной установке марки – УМФ-2000. Полученные результаты сопоставлены с нормами установленных в Республиканских и Международных нормативных документах.

Ключевые слова: природная вода, радиационные показатели воды, суммарная альфа - $\Sigma\alpha$ активность, суммарная - $\Sigma\beta$ активность, радионуклидный состав, удельная объемная активность радионуклида в воде, радиоактивные загрязнения воды, спектральные методы анализа, стандартные образцы, химические элементы, радионуклиды.

Введение. На Кызылкумской территории отсутствуют открытые водоисточники - реки, озера, каналы и т.д. Проживающие население на этой территории вынуждено употреблять подземные воды в качестве питьевой. В то время как к питьевой воде установлены в Международных и Республиканских нормативных документах гигиенические, радиационные и

другие показатели, требующие проведения мониторинга и определений значений данных показателей. Проведённые в последних годах исследования показывают, что в открытой печати и в компетентных надзорных органах отсутствуют полноценные данные о радиационных показателях в природных водах, особенно значений суммарной - $\Sigma\alpha$ и суммарной - $\Sigma\beta$ активности данных вод.



Для проведения изотопного анализа методом альфа-спектрометрии применен прибор альфа-спектрометр типа ALPHA ANALYST («CANBERRA», США).

Исследование присутствия в природных водах радионуклидов является актуальным направлением радиоэкологии и геохимии радиоактивных элементов. По данным НКДАР ООН, вклад природная вода в суммарную дозу облучения населения не является преобладающим (за исключением отдельных регионов) и обусловлен в основном присутствующими в воде радионуклидами природных рядов урана и тория. Наибольший вклад в формирование дозы облучения за счет потребления питьевой воды вносят изотопы урана (^{238}U и ^{234}U), радия (^{226}Ra и ^{226}Ra), радона (^{222}Rn) и полония-210 (^{210}Po), в меньшей степени - свинца-210 (^{210}Pb) и изотопы тория (^{228}Th , ^{228}Th , ^{232}Th) [1-2].

При содержании природных и искусственных радионуклидов в питьевой воде, создающих эффективную дозу облучения населения менее 0.2 мЗв/год (этому значению дозы при потреблении воды 2 кг в сутки соответствуют средние значения удельной активности изотопов за год (уровни вмешательства – УВ (Бк/кг): ^{238}U – 6,2; ^{235}U – 6,0; ^{234}U – 5,8; ^{230}Th – 1,32; ^{226}Ra – 1,0; ^{222}Rn – 60; ^{210}Bi – 220; ^{210}Po – 0,24; ^{210}Pb – 0,4 и т.д.), не требуется проведения мероприятий по снижению ее радиоактивности в целях радиационной безопасности, следовательно, нет необходимости определять ее радиоизотопный состав [3-4].

ТЕХНИКА И МЕТОДИКА ФИЗИЧЕСКОГО ЭКСПЕРИМЕНТА

Последовательности методики определения суммарной - $\Sigma\alpha$ и суммарной - $\Sigma\beta$ активности данных природных вод на приборе УМФ-2000 основано на концентрировании радиоизотопов из 500-1000 мл объема водной пробы методом упаривания до сухого остатка. Выпаривание проводится в водяной бане с дистиллированной водой. Затем чашка с сухим остатком помещается в термостат и сушится при 110°C до постоянной массы.

Количество сухого остатка (x) в мг/л вычисляется по формуле:

$$x = \frac{(m - m_1) \times 1000}{V} \quad (1)$$

где m - масса чашки с сухим остатком, мг;
 m_1 - масса пустой чашки, мг; V - объем воды, взятый для определения, мл.

Суммарная активность альфа-излучающих радионуклидов (далее - суммарная - $\Sigma\alpha$ активности данных вод):

$$A_\alpha = \sum (A_i \cdot \alpha_{\eta_i}) \quad (2)$$

где A_i - активность i -го радионуклида; α_{η_i} - выход альфа-частиц на 1 распад i -го радионуклида.

Суммарная активность бета-излучающих радионуклидов (далее - суммарная - $\Sigma\beta$ активности данных вод):

$$A_\beta = \sum (A_i \cdot \beta_{\eta_i}) \quad (3)$$

где A_i - активность i -го радионуклида; β_{η_i} - выход бета-частиц на 1 распад i -го радионуклида.

Измерение скорости счета альфа- и бета-излучения полученного сухого остатка с помощью метрологически аттестованного радиометра - УМФ-2000, которой предназначен для измерения малых активностей. Точность определения урана в интервале концентраций от 0,010 мг/л до 0,040 мг/л составляет $\pm 30\%$. Точность определения радия в интервале концентраций от 0,037 Бк/л до 0,15 Бк/л составляет $\pm 50\%$. Предел обнаружения тория с доверительной вероятностью $P=0,95$ составляет 0,0082 Бк/л; полония - 0,037 Бк/л [5-7].

Проведенные исследования некоторых подземных вод показывают увеличение суммарной - $\Sigma\alpha$ активности в отобранных водных пробах, чем нормативно установленное (суммарная α -активность - 0,2 Бк/л, суммарная β -активность - 2,0 Бк/л). Для выявления причины увеличения суммарной - $\Sigma\alpha$ и суммарной - $\Sigma\beta$ активности в подземных водах исследованы некоторые пробы воды отобранных из исследуемых регионов. Данный факт представляет научно-методический интерес с точки зрения оценки величин и степени



радиационного влияния техногенного объекта на экосистему [8-10].

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

На основании вышеприведенных результатов по определению суммарной - $\Sigma\alpha$ и суммарной - $\Sigma\beta$ активности на приборе УМФ-2000, были взяты пробы подземных вод объёмом по 5 литров из 6 мест, Сначала была рассчитана их суммарная - $\Sigma\alpha$ и суммарная - $\Sigma\beta$ активности, затем, с целью элементного анализа состава проб воды, из этих же проб были подготовлены образцы для альфа-спектрометрических и масс-спектрометрических измерений, Для определения содержаний изотопов - ^{234}U урана в составе природной воды, изотопы урана были выделены радиохимическим методом. Полученные результаты суммарной - $\Sigma\alpha$ и суммарной - $\Sigma\beta$ активности пробы природных вод и удельной активности изотопа - ^{234}U урана определённое с помощью альфа - спектрометра и масс-спектрометра приведены в таб. 1.

Таблица 1. Суммарная альфа- и бета-активность пробы подземных вод и удельной активности изотопа - ^{234}U урана определённое с помощью альфа - спектрометра и масс-спектрометра

№	Месторождения отбора проб	Суммарная альфа и бета активность (Бк/л)		Масс-спектрометрия ^{234}U , (мкг/кг)	Альфа спектрометрия ^{234}U , (Бк/л)
		α -активность	β -активность		
1	Учкудукский район	0,187	0,418	48,7	49,3
2	Конимехский район	0,156	0,683	54,1	53,4
3	Нурагинский район	0,191	0,486	53,5	52,9
4	Зарафшанский район	0,192	0,821	52,7	51,9
5	Нурабадский район	0,119	0,735	54,9	52,9
6	Навоийский район	0,189	0,957	53,8	54,1

Как видно из результатов таб. 1, суммарная альфа- и бета-активность образцов воды, альфа-активность изотопов урана (^{234}U) и результаты элементного состава, определённый с помощью масс-спектрометра подтверждает, что данные значение близко к установленным нормам.

Методика радиохимического выделения радиоизотопов в природных водах основана на

радиохимической подготовке образцы для измерения, а суммарная удельная активность данных проб измеряется с помощью радиометров с низким фоновым излучением - УМФ-2000 и АТОМТЕХ.

Существуют различные способы определения активности изотопов радия ($^{224,226}\text{Ra}$, $^{228}\text{Ra}(^{228}\text{Ac})$) в природных водах, представлена методика радиохимического разделения изотопов радия, содержащихся в пробе воды. Основываясь на таком методе, можно определить количество радия ($^{224,226}\text{Ra}$) в составе пробы воды.

В таб. 2, приведена результаты определения активности изотопов природного радия ^{224}Ra , ^{226}Ra , $^{228}\text{Ra}(^{228}\text{Ac})$ в пробах воды, взятых из водоисточников исследуемых регионов.

Таблица 2. Результаты определения активности изотопов природного радия $^{224,226}\text{Ra}$, $^{228}\text{Ra}(^{228}\text{Ac})$ в пробах воды, взятых из водоисточников исследуемых регионов

Место отбора пробы	Объем пробы (литр)	Удельная активность (Бк/кг)		
		^{226}Ra	^{224}Ra	$^{228}\text{Ra}(^{228}\text{Ac})$
Нурабадская область (санаторий Нагорный)	5	0,210	0,210	0,210
Мусакак	5	0,117	0,214	0,174
Бешбулак	6	0,113	0,231	0,178
Мингбулак	5	0,112	0,221	0,198
Маданият	5	0,123	0,203	0,193
Балакарак	5	0,122	0,252	0,152
Горячая скважина	5	0,120	0,203	0,123
Бешкудук	5	0,125	0,242	0,125
Елгай	5	0,126	0,250	0,140

Из приведенных результатов в таб. 2 по определению активности изотопов природного радия $^{224,226}\text{Ra}$, $^{228}\text{Ra}(^{228}\text{Ac})$ в пробах воды, взятых из водоисточников Кызылкумского региона видно, что данные природные радонуклиды намного превышает установленных норм,

В 2003 году ВОЗ пересмотрело рекомендуемые уровни для суммарной альфа- и бета- активности воды и установила их на уровне 0,5 Бк/л и 1 Бк/л соответственно, Никаких других исследований не требуется в случае, если вышеуказанные показатели не превышают рекомендованные значения, В противном случае, требуется проведение радионуклидного анализа с



применением более совершенных и длительных процедур, Суммарная активность включает в себя активности как естественных, так и техногенных радионуклидов. Изотопы урана ^{234}U , ^{235}U и ^{238}U вносят преимущественный вклад в суммарную альфа-активность и поэтому их концентрации также ограничены уровнем в 0,5 Бк/л,

Эффективные дозы, получаемые населением, определяются дозовыми коэффициентами, концентрациями радионуклидов и ежегодным потреблением воды. Дозовые коэффициенты, на основе проводимых исследований по всему миру, устанавливаются МКРЗ, Максимальные оценки суммарных активностей можно получить в предположении, что вся альфа- и бета-активность обусловлена ^{226}Ra соответственно.

ВЫВОД

Таким образом на основании проведенных исследований по изучению значений суммарной – $\Sigma\alpha$, суммарной – $\Sigma\beta$ активности и некоторых радионуклидов природных вод отобранных из ураноносных регионов можно сделать вывод, что выбранные методы пригодны для проведения анализа данных вод. Определенные значение суммарной – $\Sigma\alpha$ и суммарной – $\Sigma\beta$ активности природных вод на малофонной установке марки – УМФ-2000 соответствует нормами установленных в Республиканских и Международных нормативных документах. Значение суммарной – $\Sigma\alpha$, суммарной – $\Sigma\beta$ активности и некоторых радионуклидов действительно оказывают влияние на дозовый коэффициент населения употребляющее данных вод.

ЛИТЕРАТУРА

1. Бетенеков Н.Д. Радиоэкологический мониторинг: учеб. Пособие. –Екатеринбург: Изд-во Урал. ун-та, 2014. – 208 с. ISBN 978-5-7996-1309-9Н. Н.
2. Медведев В.П., Очкин А.В., Семенов М.А. Физические основы радиохимии. Учебное пособие. – М.: Изд-во НИЯУ МИФИ, 2011. – 195 с.
3. Аллаберганова Г.М., Туробжонов С.М., Музафаров А.М. Методика предварительной оценки

природных вод на радиоактивность ураноносного региона // Горный вестник Узбекистана №3. (78) – Навои. 2019. – С. 106-108. (05.00.00; №7).

4. Тогаев Б.С., Музафаров А.М., Эшбуриев Р.М., Аллаберганова Г.М., Мустафоев М.А. – Ядерно-физические методы оценки радиационных показателей подземных вод ураноносных районов // "Роль одаренной молодежи в развитии физики" RIAK-XVI-2023 сборник трудов республиканской конференции Том 1. Ташкент 2023 г. Стр. 269-275.

5. Базарбаев Н.Н., Иванов А.К., Иноятов А.Х., Маматкулов О.Б., Муминов И.Т., Муминов Т.М., Нурмуродов Л.Т., Сафаров А.А., Худайбердиев. А.Т. Радионуклиды в почвах, водах и приземном воздухе в отдельных горных местностях узбекистана // Радиационная биология. Радиоэкология, 2022, том 62, № 2, с. 212–225.

6. Eshbo'riyev R.M., Umirzaqov E.A., Nurmurodov L.T., Sayfinov R., Kaxorova A.N., Yunusova U.X. Samarqand viloyati tuproqlarida tabiiy va texnogen radionuklidlarning migratsiya xususiyatlari // SamDU ilmiy axborotnomasi. 2020-yil, 3-son, 131-136 b.

7. Кутний Д.В., Телегин Ю.Н., Одейчук Н.П., Михайлов В.А., Товканец В.Е. Определение обогащения урановых материалов Гамма-спектрометрическими методами // Вопросы атомной науки и техники. 2009. №4-2. Серия: Физика радиационных повреждений и радиационное материаловедение (94), с. 256-262.

8. Idowu Peter Farai, Abubakar Adekunle Muritala, Olatunde Micheal Oni, Tunde Daniel Samuel, Aremu Abraham. Radiological indices estimation from radon concentration in selected groundwater supplies in Abeokuta, south western Nigeria // Applied Radiation and Isotopes. Volume 191, January 2023, <https://doi.org/10.1016/j.apradiso.2022.110534>.

9. Courti A., Bouisset P and Chevallier P. Beta spectrometry for environmental radioactivity measurements // Radioprotection - Colloques, volume 37, Cl (2002) 911-916. <http://dx.doi.org/10.1051/radiopro/2002223>.

10. Shakhboz Khasanov, Temur Mavlonov. Radioactivity of Molluscs, Aqueous Sediments and Water in the Jambay Canal of Uzbekistan // International Journal of Engineering and Information Systems (IJEAIS) Vol. 3 Issue 5, May – 2019, Pages: 31-33.



АНАЛИЗ РАДИОНУКЛИДНОГО СОСТАВА И РАДИОАКТИВНОГО РАВНОВЕСИЯ МЕЖДУ НИМИ В ПРОДУКТАХ ХИМКОНЦЕНТРАТОВ УРАНА

Урунов И.А.

Кандидат физико-математических наук, доцент
НГГТУ
i_urunov56@mail.ru

Аллаберганова Г.М.

Доктор философии (PhD) по химическим наукам,
доцент НГГТУ
allaberganovagulchehra4@gmail.com

Суюнов У.А.

Докторант Навоийского государственного
университета
suyunovuktam@gmail.com

Курбанов Б.И.

Доктор технических наук, заведующий
лабораторией экологии и биотехнологии
Института ядерной физики Академии наук
Узбекистана, профессор
kurbanov@gmail.com

Музафаров А.М.

Доктор химических наук, профессор НГГТУ
muzafarov@ngmk.uz

Аннотация: В данной статье приведены результаты идентификации радионуклидного состава - ^{234}U , ^{235}U , ^{238}U и коэффициентов радиоактивного равновесия - K_{pp} между - $^{234}\text{U}/^{238}\text{U}$ в химконцентрах урана. В лабораторных условиях идентифицирован радионуклидный - ^{234}U , ^{235}U и ^{238}U состав химконцентрах урана. На основании расчетных теоретических формул найдены коэффициенты радиоактивного равновесия - K_{pp} между - $^{234}\text{U}/^{238}\text{U}$ в химконцентрах урана. Кроме него исследованы взаимосвязи значения радиационного фона места хранения химконцентрах урана со значениями коэффициентов радиоактивного равновесия - K_{pp} между - $^{234}\text{U}/^{238}\text{U}$.

Ключевые слова: радионуклидный состав, идентификация радионуклидов, коэффициент радиоактивного равновесия, химконцентрат урана, расчетная теоретическая формула, значения радиационного фона, места хранения химконцентрах урана.

Введение. В процессе добычи урана химконцентрах урана и данная ионизирующего методом физико-химической геотехнологии излучения оказывают вредного воздействуя на увеличивается естественный радиационный фон персонал и на окружающую среду. Интенсивность местности за счет дополнительного вклада ионизирующего излучения взаимосвязана с выпускающего ионизирующего излучения из количеством радионуклидов - ^{234}U , ^{235}U и ^{238}U , полученного уранового продукта – содержащихся в химконцентрах урана. Кроме



количеств радионуклидов - ^{234}U , ^{235}U и ^{238}U в химконцентрациях урана, интенсивность ионизирующего излучения взаимосвязана с величиной коэффициента радиоактивного равновесия - K_{pp} между радионуклидами $^{234}\text{U}/^{238}\text{U}$ в химконцентрациях урана. Для определения количества этих радионуклидов - ^{234}U , ^{235}U и ^{238}U в химконцентрациях урана необходимо применять современные ядерно-физические лабораторные приборы и методики выполнения измерений для определения и для идентификации данных радионуклидов. [1-4].

Техника и методы эксперимента. Одним из современных методов определения радионуклидов - ^{234}U , ^{235}U и ^{238}U в химконцентрациях урана являются ядерно-физические методы, имеющие высокую точность, избирательность, экспрессность и другие метрологические характеристики [5-7].

Как известно в природе существует три радионуклида урана с изотопным содержанием - ^{234}U (0,0054%), ^{235}U (0,7204%) и ^{238}U (99,2742%). Эти радионуклиды имеют следующие характеристики - период полураспада $T_{1/2}=4,47 \cdot 10^9$ лет радионуклида - ^{238}U , который является α -излучателем и родоначальником радиоактивного ряда ($4n+2$); период полураспада $T_{1/2}=7,04 \cdot 10^5$ лет радионуклида - ^{235}U , который является родоначальником радиоактивного ряда ($4n+3$) и радионуклид - ^{234}U с периодом полураспада $T_{1/2}=2,48 \cdot 10^5$ лет также является α -излучателем. Природный радионуклид - ^{234}U является не первичным, а радиогенным радионуклидом. Радионуклид ^{234}U входит в цепочку естественного распада урана и в радиоактивный ряд материнского - ^{238}U . Радиоактивность природного урана обусловлена главным образом изотопами ^{238}U и ^{234}U . Удельная радиоактивность природного урана составляет 0,67 микрокюри/г, разделенная почти пополам между ^{234}U и ^{238}U , небольшой вклад вносит ^{235}U (удельная активность изотопа ^{235}U в природном уране в 21 раз меньше активности ^{238}U или около 1200 Бк/г) [8-15].

Полученные результаты и их обсуждений. Ядерно - физических характеристик 15 дочерних радионуклидов образующие в процессе естественного распада материнского урана - ^{238}U можно изобразить данного ядерного процесса в схематическом виде. На рис. 1 приведен схематический вид процесса естественного распада материнского урана - ^{238}U .

Элемент	Хим. симв	Z	A											
			206	210	214	218	222	226	230	234	238			
уран	U	92
протактиний	Pa	91
торий	Th	90
актиний	Ac	89
радий	Ra	88
франций	Fr	87
радон	Rn	86
астат	At	85
полоний	Po	84
висмут	Bi	83
свинец	Pb	82
таллий	Tl	81

Рис. 1. Схематический вид процесса естественного распада материнского урана - ^{238}U

Как видно из рис. 1., в цепочке распада урана из материнского - ^{238}U образуется дочерние радионуклиды имеющие различные ядерно - физические характеристики - вид распада, период полураспада, выделяемая энергия и так далее.

Материнский радионуклид ^{238}U имеет в радиоактивном равновесном содержание со своими дочерними радионуклидами удельную активность 0,333 микрокюри/г или 12500 Бк/г. При нарушении радиоактивного равновесия материнского радионуклида ^{238}U со своими дочерними радионуклидами данные значение могут быть разные, отличающую от удельной активностью 0,333 микрокюри/г или 12500 Бк/г.

В составе пробах химконцентратов урана требуется определять значения радиоактивного равновесия между радионуклидами - $^{234}\text{U}/^{238}\text{U}$, так как в данном продукте ^{234}U является главным источником, дающим вклад в суммарную радиоактивность. Обычно его концентрация при радиоактивном равновесии с ^{238}U равна 53,41 мкг/г.



На основании вышеперечисленных изученных ядерно-физических характеристик радионуклидов ^{234}U , ^{235}U , ^{238}U , можно разработать методов определения этих радионуклидов.

Для анализа химконцентратов урана целесообразным является исследований по определение изотопного состава данного материала. На основании вышеприведённых исследований и полученных результатов установлены, что альфа-спектрометрическим методом анализа можно проводить идентификацию изотопов урана ^{234}U , ^{235}U и ^{238}U в различных пробах урановых продуктах, особенно химконцентрах урана. Геотехнологический процесс выщелачивания урана (бикарбонатный, миниреагентный, гипохлоридный и кислотный) в различной степени влияет на процесс выщелачивание изотопов ^{234}U , ^{235}U , ^{238}U и происходит нарушения радиоактивного равновесия между ^{234}U и ^{238}U , ^{235}U и ^{238}U .

Зная массовой доля каждого изотопа ^{234}U , ^{235}U , ^{238}U в пробах химконцентрах, можно предложить метода шихтовки данных продуктов для получения готовой продукции с предельной удельной активностью - 25200 Бк/г или с предельной концентрацией до 56,0 мкг/г изотопа ^{234}U в готовой продукции закиси-окиси урана, соответствующего требованиям ASTM-967-08.

Для проведения α -спектрометрического анализа химконцентратов урана проводится подготовка проб радиохимическим методом. Последовательности радиохимической подготовки образцов химконцентратов для альфа-спектрометрического анализа отличается с рядами операции от радиохимической методики подготовки проб закиси-окиси урана для изотопного анализа.

На основании уточнённой методики отбирается аликвота из химконцентра в составе котором содержится 100 мг урана. Данная проба помещается в стакан с верху прибавляется 5 мл концентрированной азотной кислоты и 1 мл перекиси водорода. Стакан закрывают часовым стеклом и весь смесь кипятят до разложения

перекиси водорода. Полученного прозрачного раствора вливают в стакан с вместимостью 100 мл и доводят дистиллированной водой до метки.

Из раствора отбирается аликвота объёмом $0,5\text{ см}^3$ и в водяной бане выпаривают досуха. Полученный сухой остаток растворяют в пять миллилитровую однопроцентному раствору трилонабутилфосфата. Полученному раствору, прибавлен один миллилитр двадцати пяти процентного раствора хлористого аммония, двух миллилитрового насыщенного раствора щавелевокислого аммония, две капли HNO_3 в соотношении один к трём и переведён в камеру электролизёра. Определены показатели – pH и доведены с добавлением аммиака до $\text{pH}=7$.

Чтобы получить раствор с $\text{pH}=7$ в раствор прибавляет аммиак, а затем отключают ток и разбирают ячейку для снятия счётного образца. Счётным образец обрабатывают дистиллированной водой и сушит при комнатной температуры. Для измерения активности счётного образца он устанавливаются на альфа-спектрометр с лицевой частью к детектору.

Ниже в таб. 1. приведены результаты определения средней концентрации изотопа ^{234}U (мг/г) в урановых химконцентрах шести месторождений отобранных в течение 2022 года и 2023 года, по кварталам.

Таблица 1. Результаты определения средней концентрации ^{234}U (мг/г) в урановых химконцентрах шести месторождений отобранных в течение 2022 года и 2023 года по кварталам

№ проб	Кварталы 2022 года				Сред. кон-ции	Кварталы 2023 года				Сред. кон-ции
	1	2	3	4		1	2	3	4	
1	50,1	49,9	50,8	48,5	49,8	49,7	48,6	50,9	50,3	49,6
2	50,4	49,5	51,1	49,4	50,1	51,2	50,8	49,9	50,4	50,6
3	51,1	49,3	47,1	50,1	49,4	50,8	50,2	49,3	51,0	50,3
4	53,1	51,7	51,9	53,0	52,4	52,7	50,9	52,6	52,9	52,3
5	57,8	56,7	56,2	56,0	56,7	56,4	57,1	56,0	56,3	56,5
6	69,9	67,5	73,1	68,7	69,8	68,8	70,2	71,4	69,1	69,9

Из полученных данных в таб. 1 видно, что в течение 2022 года. в отобранных пробах химконцентратов №1(Р-1), №2(Р-2) и №3(Р-3) средняя концентрация ^{234}U изменяется в диапазоне



от 49,4 мг/г до 50,1 мг/г и не превышает равновесного содержания, то есть 53,41 мг/г. В пробах химконцентратов №4(С), концентрация ^{234}U на 1 и 2 квартале 2022 года приближалось к равновесному содержанию 53,41 мкг/г и в среднем они составили 52,4 мг/г. В пробах №5(К) и №6(Ср) концентрация ^{234}U изменяется в пределах от 56,0 мг/г до 73,1 мг/г и превышает равновесного содержания.

Результаты полученные в течение 2023 года, показывают что в пробах химконцентратов №1(Р-1), №2(Р-2) и №3(Р-3) средняя концентрация ^{234}U изменяется в диапазоне от 49,9 мг/г до 51,2 мг/г. В этих пробах средняя концентрация ^{234}U тоже не превышает равновесного содержания 53,41 мг/г. В пробах химконцентратов №4(С), концентрация ^{234}U изменяется в диапазоне от 50,9 мг/г до 52,9 мкг/г. В пробах №5(К) и №6(Ср) концентрация ^{234}U изменяется в пределах от 56,0 мг/г до 71,4 мг/г и превышает равновесного содержания.

Потому что, на основании исследование значений коэффициента радиоактивного равновесия - K_{pp} между $^{234}\text{U}/^{238}\text{U}$ в химконцентратах урана можно установить факта взаимосвязи увеличение значений радиационного фона на складах данного продукта. На основании детального изучения полученных данных сделано предположения, что причиной увеличение значений радиационного фона на складах может являться увеличение массовой доля радионуклида ^{234}U в данном продукте. Как известно радионуклид - ^{234}U имеет ($2,31 \cdot 10^8$ Бк/г) самую высокую удельную активность среди радионуклидов таких как - ^{235}U и ^{238}U . Для подтверждения правильности данного факта проведены каждодневные замеры значение мощности экспозиционной дозы - МЭД гамма-излучения на складах хранения урановых продуктов.

Полученные данные показали, что значение мощности экспозиционной дозы гамма-излучения на местах хранения урановых продуктов отличается от значений предыдущих замеров проведенные в течение последних пяти лет.

На основании полученных данных построена зависимость рис. 2. значений мощности эффективной дозы - МЭД от коэффициента радиоактивного равновесия - K_{pp} между радионуклидами - $^{234}\text{U}/^{238}\text{U}$ в урановых продуктах (химконцентратах урана).

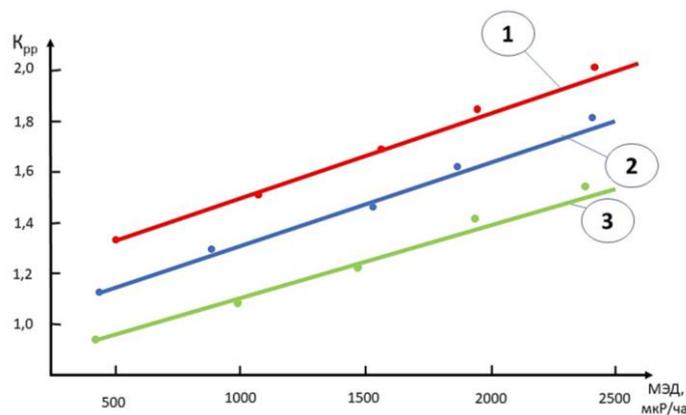


Рис. 2. Зависимость значений МЭД от K_{pp} в урановых продуктах (химконцентратах урана)

Как видно из рис. 2. значений мощности эффективной дозы - МЭД на местах хранения урановых продуктов линейно увеличится от 500 мкР/час до 2500 мкР/час в зависимости от значений коэффициента радиоактивного равновесия - K_{pp} между радионуклидами - $^{234}\text{U}/^{238}\text{U}$ в урановых продуктах (химконцентратах урана).

1-линия на рис. 2. показывают зависимость значений - МЭД от K_{pp} в урановых продуктах. То есть когда $K_{pp}=1,35$ значений МЭД будет равно 400 мкР/час и так далее когда $K_{pp}=1,54$ значений МЭД будет равно 1100 мкР/час, когда $K_{pp}=1,62$ значений МЭД будет равно 1600 мкР/час, когда $K_{pp}=1,76$ значений МЭД будет равно 2000 мкР/час и когда $K_{pp}=1,93$ значений МЭД будет равно 2480 мкР/час.

2-линия на рис. 2. показывают зависимость значений МЭД от K_{pp} в урановых продуктах, то есть когда $K_{pp}=1,17$ значений МЭД будет равно 450 мкР/час и так далее когда $K_{pp}=1,23$ значений МЭД будет равно 920 мкР/час, когда $K_{pp}=1,31$ значений МЭД будет равно 1600 мкР/час, когда $K_{pp}=1,40$ значений МЭД будет равно 1920 мкР/час и когда $K_{pp}=1,62$ значений МЭД будет равно 2420 мкР/час.

3-линия на рис. 2. показывают зависимость значений МЭД от K_{pp} в урановых продуктах, то



есть когда $K_{pp}=0,81$ значений МЭД будет равно 420 мкР/час и так далее, когда $K_{pp}=1,04$ значений МЭД будет равно 1000 мкР/час, когда $K_{pp}=1,11$ значений МЭД будет равно 1500 мкР/час, когда $K_{pp}=1,26$ значений МЭД будет равно 1980 мкР/час и когда $K_{pp}=1,38$ значений МЭД будет равно 2400 мкР/час.

Заключение. На основании вышеприведенных экспериментальных данных можно сделать вывод что, увеличения значений коэффициента радиоактивного равновесия - K_{pp} между радионуклидами - $^{234}\text{U}/^{238}\text{U}$ в продуктах химконцентратов урана приведет к увеличению радиационного фона на местах хранения данных продуктов, так как удельной активности данных продуктов будет выше за счет увеличения доли дочернего радионуклида ^{234}U имеющую 10 000 раз больше удельной активности - $2,3 \cdot 10^8$ Бк, чем удельной активности материнского радионуклида ^{238}U имеющую удельной активности $1,25 \cdot 10^4$ Бк.

Литература

1. Возжеников Г.С., Бельшев Ю.В. Радиометрия и ядерная геофизика. Учебное пособие. - Екатеринбург.: 2006. – 418 с.
2. «Нормы радиационной безопасности (НРБ-2006) и основные санитарные правила обеспечения радиационной безопасности (ОСПОРБ-2006). - Ташкент.: 2006. - 86 с.
3. «Санитарные правила ликвидации, консервации и перепрофилирования предприятий по добыче и переработке урановых руд (СП-ЛПК-98)» СанПиН №0079-98.- Ташкент.: 2008. - 54 с.
4. «Санитарные правила эксплуатации геотехнологических рудников (СПЭГТР – 2018)» СанПиН РУз №0360-18. - Ташкент.: 2006. - 86 с.
5. Музафаров А.М., Аллаберганова Г.М., Кулматов Р.А. Оценка радиационной опасности урановых предприятий для объектов окружающей среды // XXI век. Техносферная безопасность. Москва, Том 6. №1., 2021. - С. 94-102
6. Музафаров А.М., Кулматов Р.А. Ражаббоев И., Ёкубов О.М. Способ дезактивации загрязненных радионуклидами почв, отобранных из участков подземного выщелачивания урана // Горный информационно аналитический бюллетень. «Физика-химическая геотехнология-

инновации и тенденции развития». 2021. (3-1): - С. 110-118

7. Музафаров А.М., Сагтаров Г.С., Кадиров Ф.М., Латышев В.Е. Методы оценки техногенного влияния хвостохранилищ промышленных предприятий на окружающую среду // Горный вестник Узбекистана. 2002. - №2. - С. 85-89.

8. Денисов Е.И., Пулин А.А. Оценка возможностей гамма-спектрометрического метода оперативного непрерывного контроля урана в растворах // Аналитика и контроль. № 1, 2014. Т. 18. С. 31-39.

9. Abramov A., Chepurnov A., Etenko A., Gromov M., Konstantinov A., Kuznetsov D., Litvinovich E., Lukyanchenko G., Machulin I., Murchenko A., Nemeryuk A., Nugmanov R., Obinyakov B., Oralbaev A., Rastimeshin A., Skorokhvatov M., Sukhotin S., Titov O.

10. iDREAM: Industrial Detector of REactor Antineutrinos for Monitoring at Kalinin Nuclear Power Plant // J. Instrum. 2022. V. 17. P. 09001.

11. Алексеев И. Г., Белов В. В., Бруданин В. Б., Гузеев Г. Г., Данилов М. В., Егоров В. Г.,

12. Hayes A. C., Vogel P. Reactor Neutrino Spectra // Ann. Rev. Nucl. Part. Sci. 2016. V. 66. P. 219–244.

13. Estienne M., Fallot M., Algora A., Briz-Monago J., Bui V. M., Cormon S., Gelletly W., Giot L., Guadilla V., Jordan D., Le Meur L., Porta A., Rice S., Rubio B., Tain J. L., Valencia E., Zakari-Issoufou A. A. Updated Summation Model: An Improved Agreement with the Daya Bay Antineutrino Fluxes // Phys. Rev. Lett. 2019. V. 123, No. 2. P. 022502.

14. Silaeva S. V., Sinev V. V. The Reactor Antineutrino Spectrum Calculation. arXiv e-Prints. 2021; e-Print: 2012.09917 [nucl-ex].

15. Hardy J. C., Carraz L. C., Jonson B., Hansen P. G. The Essential Decay of Pandemonium: A Demonstration of Errors in Complex Beta-Decay Schemes // Phys. Lett. B. 1977. V. 71, No. 2. P. 307–310.



MAVJUD HUJJATLAR ASOSIDA HUJJAT ANDOZALARINI SHAKLLANTIRISH TIZIMINI LOYIHALASH

Akbaraliyev Baxtiyorjon Bakirovich,

DSc, dotsent,

Andijon davlat universiteti rektori

b.akbaraliyev@gmail.com,

ORCID: 0000-0002-0798-9670

Samandarov Batirbek Satimovich,

PhD, dotsent, Ma'mun universiteti,

Muhammad al-Xorazmiy nomidagi Toshkent axborot

texnologiyalari universiteti tadqiqotchisi

batirbeksamandarov@gmail.com,

ORCID: 0000-0002-8296-0894

Xoliqnazarov Rashidjon Xomidjonovich,

PhD, dots., Muhammad al-Xorazmiy nomidagi

Toshkent axborot texnologiyalari universiteti

Farg'ona filiali

abdurashidininvestor@gmail.com,

ORCID: 0009-0004-5394-7027

Gulmirzaeva Go'zal Alisher qizi,

Muhammad al-Xorazmiy nomidagi Toshkent axborot

texnologiyalari universiteti tayanch doktoranti

gozzalgulmirzayeva55@gmail.com,

ORCID: 0009-0007-6779-7842

Annotatsiya: Ushbu maqolada mavjud hujjatlar va qoidalar asosida hujjat andozalarini dinamik shakllantirish tizimini loyihalash masalasi ko'rib chiqiladi. Hujjat aylanmasi jarayonini avtomatlashtirish va tashkilotlar ehtiyojlariga moslashuvchan hujjat andozalarini shakllantirish uchun mashinali o'qitish (ML) va qoidalarga asoslangan tizimlardan foydalanish usullari tahlil qilingan. Hujjat generatsiyasining matematik modeli, klasterlash va tasniflash algoritmlari, axborot tizimi arxitekturasi va komponentalar diagrammasi ishlab chiqilgan. Tizim hujjat aylanishi jarayonini optimallashtirish, inson resurslarini tejash va avtomatik hujjat generatsiyasini takomillashtirish imkonini beradi.

Kalit so'zlar: hujjat andozalari, dinamik generatsiya, mashinali o'qitish, axborot tizimi arxitekturasi, hujjat aylanmasi.

Kirish. Zamonaviy tashkilotlarda hujjatlar aylanmasi yuqori darajada avtomatizatsiyani talab qiladi. Tashkilotlardagi biznes jarayonlarni samarali boshqarish, ma'lumotlarni to'g'ri shakllantirish va tezkor ishlashni ta'minlash uchun hujjat andozalarini avtomatik ravishda generatsiya qilish muhim ahamiyat kasb etadi [1,2]. An'anaviy statik hujjat andozalari dinamik talablarga mos kelmaydi, chunki

tashkilotlardagi jarayonlar va reglamentlar doimiy ravishda o'zgarib boradi [3]. Shu bois, hujjat andozalarini dinamik shakllantirish tizimini loyihalash bugungi kunda dolzarb masala hisoblanadi.

Hujjat andozalarini shakllantirish jarayoni avtomatlashtirilmagan holatda, xodimlar tomonidan hujjatlar qo'lbola tarzda tayyorlanadi va bu jarayon katta vaqt va resurs talab qiladi. Bundan tashqari,



ushbu usul inson omili ta'siriga bog'liq bo'lib, xato ehtimolini oshiradi. Boshqa tomondan, avtomatlashtirilgan hujjat andozalari tizimi tashkilotning talablariga mos ravishda hujjatlarni generatsiya qilish va moslashtirish imkonini beradi, bu esa jarayonlarni tezlashtiradi va xato ehtimolini kamaytiradi [4,5].

Bugungi kunda hujjat andozalarini avtomatik tarzda shakllantirish usullari bo'yicha qator tadqiqotlar olib borilgan. Masalan, qoidalarga asoslangan tizimlar, mashinalar o'rganishi (ML) va tabiiy tilni qayta ishlash (NLP) metodlari hujjat andozalarini moslashtirish va personallashtirish imkoniyatini yaratadi [6,7].

Axborot tizimining (AT) arxitekturasi uning tuzilishini, tarkibiy qismlarini, aloqalarini va tashkil etish tamoyillarini tavsiflaydi. Aniqroq qilib aytganda AT ning turli komponentlari bir-biri bilan qanday munosabatda bo'lishini, ular o'rtasida qanday ma'lumotlar uzatilishini va qanday qayta ishlanishini tushunib olishni ta'minlab beradi [8]. Umuman olganda ATning arxitekturasi tizimni ishlab chiqish, kengaytirish, modernizatsiya qilish va qo'llab-quvvatlash uchun asos bo'lib xizmat qiladi. Bu esa tashkilot talablariga javob beradigan va biznes ehtiyojlarini qondirishni ta'minlaydigan moslashuvchan va samarali tizimni yaratishga asos bo'ladi [9,10].

Axborot tizimlari arxitekturasining bir qancha keng tarqalgan modellari mavjud. Ulardan biri mijoz-server o'zaro aloqasi asoslangan model bo'lib, ushbu modelda mijozlar (odatda foydalanuvchilar) ushbu so'rovlarni qayta ishlaydigan va tegishli javoblarni taqdim etadigan serverga so'rovlar yuboradilar. Mijozlar va serverlar axborot uzatiladigan tarmoq orqali ulanadi [11].

Mashinali o'qitish (ML) asosida hujjat andozalarini shakllantirishning matematik modeli

Hujjat andozalarini dinamik shakllantirish jarayonini mashinali o'qitish (ML) yordamida modellashtirish uchun quyidagi matematik yondashuvlardan foydalanamiz.

1. Hujjatlar vektorizatsiyasi va belgilar fazosi

Har bir hujjatni d_i vektor sifatida tasvirlaymiz:

$$d_i = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n$$

bu yerda:

x_k – hujjatning k -chi belgisi (matndagi so'zlar soni, teglar, tuzilma elementlari va boshqalar);
 n – umumiy belgilar soni.

Hujjatlarni vektorlarga aylantirish uchun TF-IDF yoki word embeddings (BERT, Word2Vec) metodlari qo'llaniladi:

$$TF - IDF(t, d) = TF(t, d) \times IDF(t)$$

bu yerda:

$TF(t, d)$ – terminning hujjatdagi takrorlanish chastotasi;

$$IDF(t) = \log \frac{N}{n_t} \quad - \quad \text{terminning barcha}$$

hujjatlar bo'yicha ahamiyati.

2. Hujjatlarni klasterlash modeli

Hujjatlarni avtomatik guruhlash uchun K-means klasterlash algoritmidan foydalanamiz:

$$C_j = \left\{ d_i \mid \arg \min_{c_j} \|d_i - c_j\| \right\}$$

bu yerda:

C_j – j -chi klaster;

c_j – j -chi klaster;

$\|d_i - c_j\|$ – evklid masofasi:

$$\|d_i - c_j\| = \sqrt{\sum_{k=1}^n (x_k^{(i)} - x_k^{(j)})^2}$$

3. Hujjatlarni sinflashtirish

Generatsiya qilinadigan hujjatning kategoriyasini aniqlash uchun sinflashtirish modeldan foydalanamiz:

$$\hat{y} = f(WX + b)$$

bu yerda:

$X \in \mathbb{R}^{m \times n}$ – hujjat belgilari matritsasi;



$W \in \mathbb{R}^{k \times n}$ – sinflashtirish uchun vaznlar matritsasi;

$b \in \mathbb{R}^k$ – ofset vektori;

$f(\bullet)$ – Softmax yoki Sigmoid aktivlashtirish funksiyasi;

\hat{y} – sinflashtirilgan hujjat kategoriyasi;

Neural Network modeli uchun Softmax funksiyasini quyidagicha hisoblaymiz:

$$P(y_i) = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}}$$

bu yerda $z_i = WX_i + b$ – kirish vektori.

4. Tabiiy tilni qayta ishlash (NLP) asosida hujjat tuzilmasi generatsiyasi

Generatsiya qilingan hujjatni to'liq shakllantirish uchun LSTM va Transformer neyron tarmoqlaridan foydalanamiz.

$$h_t = \sigma(W_h h_{t-1} + W_x x_t + b)$$

bu yerda:

h_t – hozirgi holat;

h_{t-1} – oldingi holat;

x_t – kirish ma'lumotlari;

W_h, W_x – vaznlar;

5. Generatsiya qilingan hujjatning ehtimoliy taqsimlanishi

Hujjat generatsiyasida mashinali o'qitish (ML) va tabiiy tilni qayta ishlash (NLP) algoritmlari ma'lumotlar tarixiga asoslanib yangi hujjatni taklif qiladi. Bu jarayonda, har bir hujjat yoki uning bo'laklari ma'lum bir ehtimollik bilan tanlanadi va shakllantiriladi.

Generatsiya qilingan hujjat oldingi hujjatlardan kelib chiqib, yangi hujjatning turli qismlarini shakllantirish uchun ehtimoliy model ishlatadi.

Bunda asosan shartli ehtimolliklar qo'llaniladi:

$$P(w_t | w_1, w_2, \dots, w_{t-1}) = \text{soft max}(Wh_t)$$

Bu yerda formula hozirgi so'z w_t (yoki hujjat tarkibiy qismi) oldingi so'zlar w_1, w_2, \dots, w_{t-1} asosida paydo bo'lish ehtimolligini ko'rsatadi.

Generatsiya jarayonida har bir so'z (yoki hujjat qismi) turli ehtimolliklar bilan tanlanadi. Buning uchun Softmax funksiyasidan foydalanamiz:

$$P(y_i) = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}}$$

bu yerda:

z_i – neyron tarmoqning hujjat konteksti asosida hisoblagan tendentsiyasi (logit);

$P(y_i)$ – i -so'zning kelishi ehtimoli;

k – barcha so'zlar yoki so'z birikmalarining umumiy soni.

Generatsiya qilingan hujjatning ehtimoliy taqsimlanishi oldingi hujjatlar, foydalanuvchi kiritgan ma'lumotlar va sun'iy intellekt modelining tahlili asosida yangi hujjatni taklif qilishga erishish mumkin bo'ladi.

Natijalar. Tizim arxitekturasini loyihalash.

Hujjat aylanishi uchun hujjatlar andozasini dinamik shakllantirish axborot tizimining arxitekturasini quyidagi asosiy komponentalar, tarkibiy qismlar va ularning aloqalaridan iborat bo'ladi:

Mijoz interfeysi: Bu foydalanuvchilarga tizim bilan o'zaro aloqa qilish imkonini beruvchi foydalanuvchi interfeysi. U veb-ilova shakladi ishlab chiqilib, foydalanuvchining ish stoli vazifasini bajaradi. Mijoz interfeysi foydalanuvchilarga hujjat andozalarini yaratish, tahrirlash va boshqarish, shuningdek, andozalar asosida hujjatlarni to'ldirish va yaratish imkonini beradi.

Xujjat andozalari: Ushbu komponent hujjat andozalarini saqlash va boshqarish uchun javobgardir. U tadqiqot doirasida ishlab chiqilgan algoritmlar asosida ma'lumotlar bazasida xar bir xujjat andosasi uchun jadvallar shakllantirish, maydon parametrlarini o'rnatish, oldindan mavjud to'tirilgan xujjat andozalaridan yangi xujjat andozasi uchun ma'lumotlar ko'chirib o'tkazish kabi vazifalarni



bajaradi. Andoza mexanizmi andozalarni yaratish, saqlash, yangilash va o'chirish uchun funktsionallikni ta'minlaydi. U shuningdek, foydalanuvchilarning so'nggi xujjat versiyalar bilan ishlashi uchun andozalarning versiyalarini qo'llab-quvvatlash vazifasi bajaradi.

Xujjatni dinamik shakllantirish: Ushbu komponenta integratsiya moduli bilan uzviy aloqa o'rnatgan holda hujjat andozalarini shakllantirishda boshqa manbalardan olingan ma'lumotlar bilan dinamik ravishda to'ldirish uchun javobgardir. Bu ma'lumotlar bazalari, CRM tizimlari yoki boshqa axborot tizimlari kabi tashqi tizimlar bilan integratsiyani o'z ichiga oladi. Komponent andozalarni to'ldirish so'rovlarini qayta ishlaydi, kerakli ma'lumotlarni chiqaradi va ularni tegishli andoza maydonlariga kiritadi.

Murojaat huquqlarini boshqarish: Ushbu komponenta foydalanuvchining hujjat andozalariga kirish huquqlarini boshqarishni ta'minlaydi. U foydalanuvchi rollari va ruxsatlarini aniqlash, shuningdek, turli andozalarga kirishni farqlash uchun funktsionallikni o'z ichiga oladi. Bu konfidentsial yoki cheklangan andozalarga kirishni faqat tegishli foydalanuvchilarga taqdim qilish imkonini beradi.

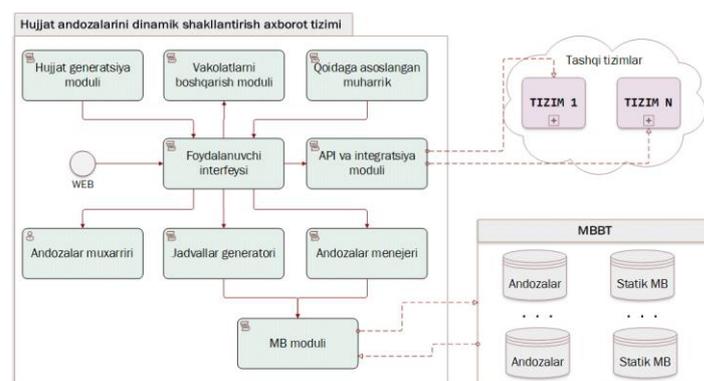
Bildirishnoma va jarayonlarni avtomatlashtirish: Ushbu komponenta bildirishnoma yaratish hamda hujjatlarni yaratish va jo'natish bilan bog'liq jarayonlarni avtomatlashtirishni sozlash uchun xizmat qiladi. U bildirishnomalarni ishga tushirishi kerak bo'lgan hodisalarni aniqlash va bildirishnomalarni sozlash funktsiyalarini o'z ichiga oladi. Komponenta, shuningdek, hujjatlarni yaratish yoki o'zgartirish paytida hodisalar bayonnomalarini shakllantirish va qayd qilib borish imkoniyatlarini taqdim etadi.

Boshqa tizimlar bilan integratsiya va o'zaro ta'sir qilish: Bu komponent axborot tizimini hujjatlar bilan ishlash uchun zarur bo'lishi mumkin bo'lgan boshqa tizimlar bilan integratsiyalashni ta'minlaydi. Bu ma'lumotlar bazasini boshqarish tizimlari, elektron pochta, hujjatlarni saqlash tizimlari va boshqalar bilan integratsiyani o'z ichiga oladi.

Qoidaga asoslangan muharrir: Bu komponenta hujjat andozalarini avtomatik tanlash va moslashtirishni ta'minlab beradi. U biznes qoidalari, foydalanuvchi talablari va tashkilot reglamentlariga asoslanib, hujjat tuzilmasini shakllantiradi. Qoidalar IF-THEN operatorlari, graflar yoki ekspert tizimlar asosida ishlaydi.

Hujjat generatsiya moduli: Bu komponent shakllantirilgan hujjat andozasidan real hujjat yaratish uchun xizmat qiladi. U hujjat ma'lumotlarini to'ldiradi, formatlaydi va eksport qiladi (PDF, DOCX, XML). Mashinali o'qitish (ML) yoki shablon generatsiya texnologiyalaridan foydalanib, hujjatning avtomatik personallashtirilishini ta'minlab berish uchun xizmat qiladi.

Hujjat aylanishi uchun hujjat andozalarini dinamik shakllantirish axborot tizimi umumiy arxitekturasi qurish bir nechta bosqichda amalga oshirildi. Dastlabki bosqichda tizimning komponentalar diagrammasi shakllantirildi



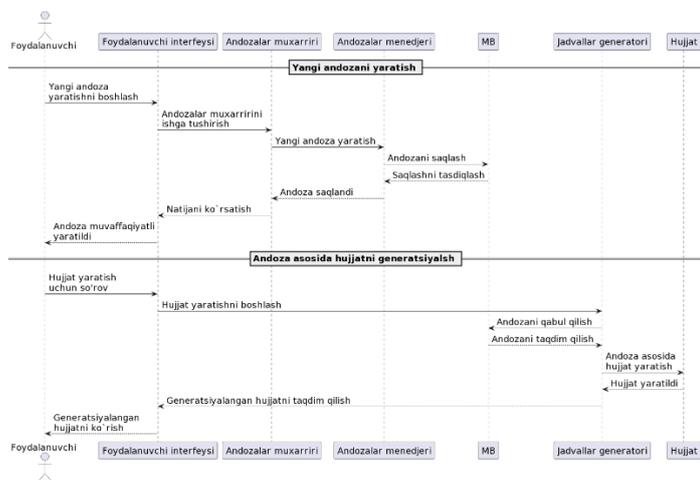
1-rasm. Hujjat andozalarini dinamik shakllantirish axborot tizimi komponentalar diagrammasi

Komponentalar diagrammasi xujjat andozalarini yaratish va taxrirlash imkoniyatini beruvchi **andozalar muxarriri**, saqlash va shablonlarga kirishni boshqaruvchi **andozalar menejeri**, andozalar va foydalanuvchi ma'lumotlar asosida xujjatni yaratuvchi **andozalar generatori**, andozalarni, foydalanuvchi ma'lumotlarini va xujjat ma'lumotlari bilan ishlashuvchi **MB moduli**, andozalar bilan ishlash va hujjatlarni yaratishni taqdim qiluvchi **foydalanuvchi interfeysi** va foydalanuvchi



autentifikatsiyasi va avtorizatsiyasini boshqarish uchun **vakolatlarni boshqarish moduli** komponentalaridan iborat.

Yuqoridagilardan kelib chiqib, yangi hujjat andozasini yaratish va shu andoza asosida asosida hujjat yaratishda tizim komponentlari o'rtasidagi o'zaro ta'sirni namoyon qiluvchi ketma-ketlik diagrammasini quyidagicha qurib olamiz:



2-rasm. Hujjat andozalarini dinamik shakllantirish axborot tizimi asosiy UML ketma-ketlik diagrammasi

Ushbu ketma-ketlik diagrammasi ikkita asosiy jarayonni tavsiflaydi:

1. Yangi shablon yaratish:

- Foydalanuvchi foydalanuvchi interfeysi orqali yangi andoza yaratishni tanlaydi.
- Foydalanuvchi interfeysi andoza muharririni ishga tushiradi.
- Andoza muharriri yangi andoza haqidagi ma'lumotlarni andozalar menejeriga uzatadi.
- Andozalar menejeri yangi andozani ma'lumotlar bazasida saqlaydi va tasdiqlashni oladi.
- Foydalanuvchiga andoza muvaffaqiyatli yaratilganligi haqida xabar beriladi.

2. Andoza asosida hujjat yaratish:

- Foydalanuvchi tanlangan andoza asosida hujjat yaratishni ijroga uzatadi.

- Hujjat ijrochisi maxsus interfeys orqali ma'lumotlar bazasidan andozani qabul qilib oladi.
- Ma'lumotlar bazasi vakolatlar doirasida so'ralgan andozani taqdim qiladi.
- Ijrochi qabul qilingan andoza yordamida yangi hujjat yaratadi.
- Yaratilgan hujjat foydalanuvchiga taqdim qilinadi.

Ushbu diagramma tizimdagi asosiy amallar paytida turli xil tizim komponentlari o'rtasidagi o'zaro ta'sirni ko'rsatadi va tizimda andozalar yaratish va ulardan foydalanish jarayonini tushunishga yordam beradi.

Yuqorida loyihalashtirilgan diagrammalar orqali axborot tizimning tugunlararo artefaktlarining jismoniy joylashishini loyihalashtirib, tuzimning umumiy arxitekturasi qurib olamiz. Bunda arxitektura ilovalar serveri va ma'lumotlar bazalari kabi server komponentlarini, shuningdek, mijoz qurilmalari va asosiy tarmoq infratuzilmasi elementlarini o'z ichiga oladi.

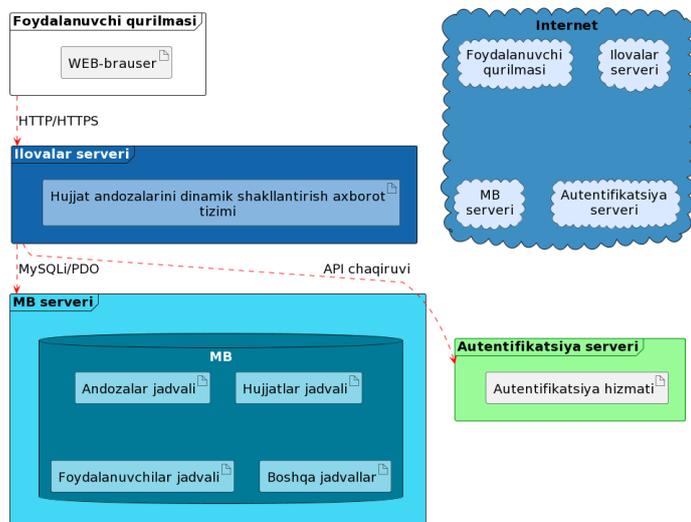
Ushbu arxitektura quyidagi komponentlarni o'z ichiga oladi:

- Tizimga Internet orqali kirish uchun web-brauzer o'rnatilgan mijoz qurilmasi.
- Hujjat andozalarini dinamik shakllantirish axborot tizimi o'rnatilgan ilovalar serveri. Ushbu server mijozlar so'rovlarini qayta ishlaydi va ma'lumotlar bazasi serveri va autentifikatsiya serveri bilan aloqa o'rnatadi.
- Andozalar, hujjatlar, foydalanuvchilar kabi jadvallar mavjud ma'lumotlar bazasini o'z ichiga olgan ma'lumotlar bazasi serveri.
- Foydalanuvchi identifikatsiyasi va autentifikatsiyasini boshqarish uchun Autentifikatsiya xizmati mavjud autentifikatsiya serveri.

Ushbu arxitektura tizimning jismoniy tuzilishini va joylashtirish va ishlatish vaqtida uning



tarkibiy qismlari o'rtasidagi o'zaro ta'sirni ko'rsatadi. Bu erda barcha komponentlar bulutda shaklida loyihalashtirilishi, ularning Internet orqali foydalanish imkoniyatini aks ettiradi.



3-rasm. Hujjat andozalarini dinamik shakllantirish axborot tizimi umumiy arxitekturasi

Ushbu arxitektura o'rnatilgan tizim ichidagi jismoniy tuzilma va o'zaro ta'sirlarning aniqroq tasvirlab beradi va axborot tizimini jismonan loyihalashtirish uchun asos bo'lib xizmat qiladi.

Xulosa. Ushbu maqolada mavjud hujjatlar va qoidalardan foydalanib hujjat andozalarini dinamik shakllantirish tizimini loyihalash masalasi muhokama qilindi. Hozirgi kunda tashkilotlarda hujjat aylanmasi jarayonining samaradorligini oshirish va avtomatlashtirishga talab juda ortib bormoqda. An'anaviy statik hujjat andozalari bu talablarga to'liq javob berolmaydi, shu sababli avtomatik hujjat generatsiyasi va mashinali o'qitish (ML) asosida moslashuvchan hujjatlar yaratish muhim ahamiyat kasb etadi.

Maqolada hujjat generatsiyasining matematik modeli ishlab chiqilib, klasterlash va sinflashtirish algoritmlari tahlil qilindi. Axborot tizimining komponentlar diagrammasi va arxitekturasi taqdim etildi, bu esa tizimning ishlash tartibini aniqlashga yordam beradi.

Tadqiqot natijalari shuni ko'rsatdiki, hujjat aylanishini avtomatlashtirish va hujjat andozalarini

intellektual ravishda tanlash jarayonlarni optimallashtirish, inson resurslarini tejash va xato ehtimolini kamaytirish imkoniyatini beradi. Loyihalashtirilgan tizim tashkilotlarda hujjat tayyorlash samaradorligini oshirishda muhim rol o'ynashi mumkin.

Foydalanilgan adabiyotlar

1. Nishanov A., Akbaraliyev B., Xoliqnazarov R. Dinamik hujjat aylanish tizimini ishlab chiqish jarayonini modellashtirish // Raqamli transformatsiya va sun'iy intellekt ilmiy jurnali. 2023. No. 1(2), 168–172 b.
2. Xoliqnazarov R.X. Информационная модель электронного документооборота в крупномасштабных объектах // "Научно–технический журнал ФерПИИ". 2019. Том.23. № 2. – С.101-106
3. Samandarov B.S., Tajibaev Sh.X. Zamonaviy tibbiyot axborot tizimlari uchun jarayon modellarini loyihalash masalasi // Raqamli Transformatsiya va Sun'iy Intellekt ilmiy jurnali, 2024. Vol. 2(1), 176–181 b.
4. Tomer, M., & Kumar, M. Multi-document extractive text summarization based on firefly algorithm // Journal of King Saud University - Computer and Information Sciences. 2022. Vol. 34, Issue 8, pp. 6057–6065
5. Aanchal, Nidhi, Preeti, & Gurpratap. Automatic Cropping of Handwritten Scanned Documents with Object Detection Algorithm // Procedia Computer Science. 2023. Vol. 218, pp. 1733–1741
6. Bilal, M., Hamza, A., & Malik, N. NLP for Analyzing Electronic Health Records and Clinical Notes in Cancer Research: A Review // Journal of Pain and Symptom Management. 2025.
7. Gerling, C., & Lessmann, S. Multimodal Document Analytics for Banking Process Automation // Information Fusion. 2025. Vol. 118, pp. 102973)
8. Jaakkola, H & Thalheim, B. (2011). Architecture-driven modeling methodologies.



In: Proceedings of the 2011 conference on
Information Modelling and Knowledge Bases
XXII. Anneli Heimbürger et al. (eds). IOS
Press.

9. Alagah A. D., Tende F. B. Information System Architecture and Enterprise Resource Planning: A Solution For Organising Business Information. International Journal of Business Education and Management Studies (IJBEMS). Vol.4. Issue 1. 2022 (April). pp. 1 – 16
10. Bakar, N.A.A., Yaacob, S., Hussein, S.S., Nordin, A. & Sallehuddin, H. (2019). Dynamic metamodel approach for government enterprise architecture model management. 5th Information System International Conference, 2019. Procedia Computer Science, 161(2019), pp. 894 – 902.
11. Самандаров Б.С., Нуруллаев Ж.А. Дастурий воситаларни web иловалар кўринишида ишлаб чиқишнинг аҳамияти // «Ахборот коммуникация технологиялари ва дастурий таъминот яратишда инновацион ғоялар» Республика илмий-техник анжумани. Самарқанд-2019. –Б. 50-52



АВТОМАТИЗИРОВАННАЯ СИСТЕМА ПОДБОРА ДИЗАЙНОВ ТКАНЕЙ С УЧЕТОМ ВОЗМОЖНОСТЕЙ ОБОРУДОВАНИЯ ПРИ ПРОИЗВОДСТВЕ УЗОРЧАТЫХ ТКАНЕЙ

Зулунов Равшанбек Маматович,
Ферганский филиал ТУИТ, и.о. профессора

Абдурасулова Дилноза Ботирали қизи,
PhD студент, Ферганский Политехнический
институт, Фергана
abdurasulovad1@gmail.com

Аннотация: В данной статье рассматривается разработка автоматизированной системы подбора дизайнов тканей, учитывающей технические возможности оборудования для производства узорчатых тканей. Представлена методология выбора рисунков с учетом ограничений технологического процесса. Проведён анализ существующих решений, предложена модель системы, представлена математическая формализация процесса подбора дизайна. Рассмотрены алгоритмы оптимизации и программная реализация системы. Приведены примеры внедрения и результаты тестирования.

Ключевые слова: Автоматизация, текстильное производство, подбор дизайнов, математическое моделирование, узорчатые ткани, оптимизация, искусственный интеллект

Введение:

Современное текстильное производство требует высокой степени автоматизации и оптимизации процессов. Одной из ключевых задач является подбор дизайнов тканей с учетом технических возможностей оборудования. Вручную выполнять такую работу сложно и неэффективно, что обуславливает необходимость создания автоматизированной системы. Целью данной работы является разработка и математическое обоснование такой системы, а также рассмотрение её программной реализации.

Методология:

Анализ существующих решений:

На данный момент в текстильной промышленности используются различные подходы к подбору дизайнов. Основными методами являются:

- **Ручной подбор**, основанный на опыте технологов, но требующий значительных временных затрат.
- **Алгоритмическое проектирование**, при котором учитываются параметры станков и технологические ограничения.

- **Искусственный интеллект**, который позволяет анализировать и предлагать оптимальные варианты дизайна на основе больших данных.

Ограничения оборудования:

Оборудование для производства узорчатых тканей накладывает ряд ограничений, среди которых:

- Разрешающая способность ткацких станков.
- Допустимая плотность нитей.
- Максимальная сложность узора в зависимости от типа машинного вязания или плетения.
- Ограничения по цветовой палитре.

Математическая модель подбора дизайна.

Пусть D – множество возможных дизайнов, а C – множество технических ограничений оборудования. Автоматизированный подбор дизайнов можно формализовать как задачу оптимизации:

$$\max_{d \in D} F(d), \text{ при условии } g(d) \leq C$$

Здесь:

- d – дизайн ткани.



- D – множество возможных дизайнов.
- $F(d)$ – функция оценки качества дизайна.
- $g(d)$ – функция, отражающая ограничения оборудования.
- C – максимально допустимые параметры оборудования.

Формула означает, что система выбирает дизайн, который максимизирует $F(d)$, но только среди тех, которые удовлетворяют техническим ограничениям $g(d) \leq C$.

В качестве оценки качества учитываются:

- Визуальная привлекательность (оценка через сверточные нейронные сети).
- Технологическая выполнимость (анализ совместимости с оборудованием).
- Минимизация отходов материала.

Разработка алгоритма подбора

Основные этапы алгоритма:

1. Ввод параметров оборудования (размеры, разрешение, максимальная сложность узора).
2. Генерация возможных дизайнов (методы фрактального и случайного проектирования).
3. Оценка соответствия техническим возможностям.
4. Оптимизация с использованием генетического алгоритма.
5. Выбор наилучшего варианта.

Программная реализация:

Система реализована на языке Python с использованием библиотек:

- OpenCV – для обработки изображений.
- TensorFlow – для анализа изображений с помощью нейросетей.
- SciPy – для математической оптимизации.

Пример кода на Python для генерации и оптимизации узора:

```
import cv2
import numpy as np
from scipy.optimize import minimize
def generate_pattern(size=(100, 100)):
```

```
    """Генерация случайного текстильного узора"""
```

```
    pattern = np.random.randint(0, 256, size,
dtype=np.uint8)
```

```
    return pattern
```

```
def evaluate_pattern(pattern):
```

```
    """Оценка качества узора на основе контраста и сложности"""
```

```
    edges = cv2.Canny(pattern, 100, 200)
```

```
    complexity = np.sum(edges) / pattern.size
```

```
    return complexity
```

```
def optimize_pattern():
```

```
    """Оптимизация узора для соответствия оборудованию"""
```

```
    initial_pattern = generate_pattern()
```

```
    result = minimize(lambda x: -
evaluate_pattern(x.reshape(100, 100)),
```

```
initial_pattern.flatten(),
```

```
method='L-BFGS-B')
```

```
    optimized_pattern = result.x.reshape(100,
100)
```

```
    return optimized_pattern
```

```
# Генерация и оптимизация узора
```

```
pattern = generate_pattern()
```

```
optimized_pattern = optimize_pattern()
```

```
cv2.imshow('Optimized Pattern',
```

```
optimized_pattern)
```

```
cv2.waitKey(0)
```

```
cv2.destroyAllWindows()
```

Пример кода на Python для нейронной сети и процесса обучения:

```
import tensorflow as tf
```

```
from tensorflow import keras
```

```
import numpy as np
```

```
# Создание простой модели сверточной нейронной сети для оценки дизайнов
```

```
model = keras.Sequential([
    keras.layers.Conv2D(32, (3,3),
```

```
activation='relu', input_shape=(100, 100, 1)),
```

```
keras.layers.MaxPooling2D((2,2)),
```

```
keras.layers.Conv2D(64, (3,3),
```

```
activation='relu'),
```



```
keras.layers.MaxPooling2D((2,2)),  
keras.layers.Flatten(),  
keras.layers.Dense(64, activation='relu'),  
keras.layers.Dense(1, activation='sigmoid')
```

Оценка качества дизайна

)

```
model.compile(optimizer='adam',
```

```
loss='binary_crossentropy', metrics=['accuracy'])
```

Генерация случайных данных

(простейший обучающий набор)

```
data = np.random.rand(1000, 100, 100, 1)
```

```
labels = np.random.randint(0, 2, (1000,))
```

Обучение модели

```
model.fit(data, labels, epochs=10,
```

```
batch_size=32)
```

Результаты и обсуждение:

В ходе экспериментов была реализована тестовая версия системы, результаты которой приведены в таблице 1.

Таблица 1. Сравнение подходов к подбору дизайнов

Метод	Время обработки (с)	Соответствие оборудованию (%)
Ручной подбор	120	75
Алгоритмический подход	45	90
Искусственный интеллект	30	95

Анализ результатов:

Результаты тестирования показывают, что применение алгоритмических и AI-методов значительно снижает временные затраты и увеличивает точность соответствия дизайна возможностям оборудования. Использование сверточных нейронных сетей позволило достичь максимальной адаптации дизайнов к производственным требованиям.

Визуализация данных:

Диаграмма на рисунке 1 показывает сравнительный анализ точности различных методов подбора дизайна:

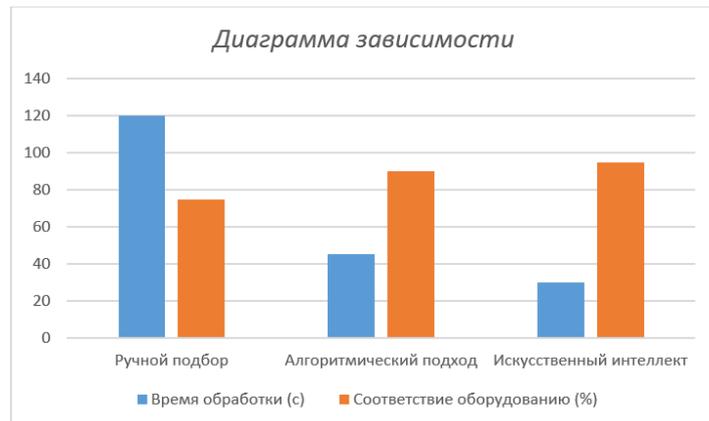


Рисунок 1. Диаграмма зависимости точности подбора дизайна от метода.

Заключение:

Разработанная система позволяет автоматизировать процесс подбора дизайнов тканей, учитывая технические ограничения оборудования. Применение математического моделирования и алгоритмов оптимизации значительно увеличивает эффективность процесса.

Преимущества предложенной системы включают сокращение времени на подбор узоров, повышение точности соответствия техническим требованиям и минимизацию отходов материала. Это открывает возможности для более гибкого и персонализированного производства текстильных изделий.

Будущие исследования могут быть направлены на дальнейшее развитие искусственного интеллекта в данном направлении, а также на интеграцию системы с промышленными станками. В частности, перспективным направлением является использование глубокого обучения для предсказания предпочтений пользователей и адаптации дизайнов к изменяющимся модным тенденциям. Кроме того, возможна автоматизация процесса внесения коррективов в дизайны на основе анализа обратной связи от потребителей и данных о технологических ограничениях производства.

Литература

- Иванов А.А., Петров Б.Б. Автоматизация текстильного производства. – М.: Наука, 2020.



2. Smith J., Taylor R. Textile Pattern Optimization. – London: Springer, 2019.
3. ISO 19227:2021. Standard for Textile Machinery Performance.
4. Zhang Y., Li H. Machine Learning in Textile Manufacturing. – New York: Elsevier, 2021.
5. OpenCV Documentation.
<https://docs.opencv.org>
6. TensorFlow Guide.
<https://www.tensorflow.org>
7. R.Zulunov, U.Akhundjanov, B.Soliev, A.Kayumov, M.Asraev, Kh.Musayev. Building and predicting a neural network in PYTHON. E3S Web of Conferences, 508, 04005 (2024).
8. Р.Зулунов, Д.Ирматова. Использование технологий искусственного интеллекта. Журнал интегрированного образования и исследований. 2022, 1/6, с. 53-56.
9. R.Zulunov. Pythonda neyron tarmoqni qurish va bashorat qilish. Al-Farg'oniy avlodlari, 2023, 1/4, с. 22-26.
10. R.Zulunov, A.Kayumov. Идентификация и сортировка текстиля для автоматизированной обработки с помощью ближней инфракрасной спектроскопии. Universum: технические науки, 3(120), март 2024, с. 38-42
11. VV Byts', RM Zulunov. Specification of matrix algebra problems by reduction. Journal of Mathematical Sciences. Т. 71, 2719–2726 (1994).
12. Hnatiienko, H., Hnatiienko, V., Zulunov R., Babenko, T., Myrutenko, L. Method for Determining the Level of Criticality Elements when Ensuring the Functional Stability of the System based on Role Analysis of Elements. CEUR Workshop Proceedings, 2024, 3654, p. 301–311
13. R.Zulunov, B.Soliev, A.Kayumov, M.Asraev, Kh.Musayev, D.Abdurasulova. Detecting mobile objects with ai using edge detection and background subtraction techniques. E3S Web of Conferences, 508, 03004 (2024).
14. R.Zulunov, B.Soliev. Z.Ermatova. Enhancing Clarity with Techniques for Recognizing Blurred Objects in Low Quality Images Using Python. Потомки Аль-Фаргани, 2024, 1(2), 336–340.
15. U.Akhundjanov, R.Zulunov, A.Kayumov, X.Goipova, Z.Ermatova, M.Sobirov. Handwritten signature preprocessing for off-line recognition systems. E3S Web Conf., 587 (2024) 03019.



OLIV TA'LIM MUASASALARIDA O'QITUVCHILAR FAOLIYATINI BAHOLASHDA NORAVSHAN MANTIQDAN FOYDALANISH

Nasiriddinov A'louddin Nuriddinovich,
Termiz davlat universiteti
Kompyuter va dasturiy injiniring kafedrası
o'qituvchisi
nalouddin@gmail.com

Annotatsiya: Ushbu maqolada universitet o'qituvchilarining faoliyatini baholash uchun noravshan mantiq (fuzzy logic) asosida yaratilgan ekspert tizimi taqdim etilgan. Tizim an'anaviy baholash usullaridan farqli o'laroq, noaniq va subyektiv ma'lumotlarni hisobga olgan holda baholashni amalga oshiradi. Tizim Python dasturiy muhitida Mamdani yondashuvi asosida ishlab chiqilgan va 3D vizualizatsiya orqali natijalarni ko'rsatish imkoniyatiga ega. Tadqiqot natijalari shuni ko'rsatadiki, noravshan mantiq asosidagi tizim o'qituvchilarning faoliyatini yanada adolatli va haqiqatga yaqin baholash imkoniyatini beradi.

Kalit so'zlar: noravshan mantiq (Fuzzy Logic), o'qituvchilar faoliyatini baholash, ekspert tizimi, universitet o'qituvchilari, Mamdani yondashuvi, Python muhiti, 3D vizualizatsiya, subyektiv ma'lumotlar, adolatli baholash, oliy ta'lim muassasalari

Kirish:

O'qituvchilarning faoliyatini baholash – bu ta'lim tizimining muhim qismi bo'lib, ularning kasbiy rivojlanishi, ta'lim sifatini oshirish va universitetlarning umumiy samaradorligini yaxshilashga qaratilgan, biroq bu jarayonda ko'plab noaniq va subyektiv mezonlar mavjud bo'lib, ularni an'anaviy usullar bilan baholash qiyin. Masalan, o'qituvchilarning dars berish uslublari, talabalar bilan muloqot qilish qobiliyati yoki ilmiy faoliyati kabi ko'rsatkichlar ko'pincha aniq raqamlar bilan ifodalab bo'lmaydigan subyektiv mezonlardir.

An'anaviy baholash usullari ko'pincha aniq raqamli qiymatlarga asoslanadi, ammo bu usullar noaniqlik va subyektivlikni hisobga olishda imkoniyatlari cheklangan. Shu sababli, noravshan mantiq (fuzzy logic) kabi zamonaviy yondashuvlar ta'lim sohasida keng qo'llanila boshlandi. Noravshan mantiq – bu noaniq, subyektiv va noaniq ma'lumotlarni matematik jihatdan qayta ishlashga imkon beradigan yondashuv bo'lib, u insonning mantiqiy fikrlash usullarini kompyuter tizimlariga tatbiq etish imkoniyatini beradi.

Noravshan mantiqning asosiy afzalligi shundaki, u aniq bo'lmagan ma'lumotlarni ham

hisobga oladi. Masalan, "dars sifati yuqori" yoki "talabalar bilan muloqot yaxshi" kabi subyektiv baholarni noravshan to'plamlar (fuzzy sets) orqali ifodalash mumkin. Bu esa baholash jarayonini yanada adolatli va haqiqatga yaqin qiladi.

Ushbu tadqiqotda universitet o'qituvchilarining faoliyatini baholash uchun noravshan mantiq (fuzzy logic) asosida ekspert tizimi ishlab chiqilgan. Tizimning asosiy qismlari: *fuzzifikatsiya*, *qoidalar bazasi*, *inferensiya* va *defuzzifikatsiya*. Bu bosqichlar orqali noaniq ma'lumotlar aniq baholash natijalariga aylantiriladi.

Adabiyotlar tahlili va metodologiya.

Noravshan mantiq (Fuzzy Logic) tushunchasi: Noravshan mantiq (fuzzy logic) – bu aniq bo'lmagan, noaniq va subyektiv ma'lumotlarni matematik jihatdan qayta ishlashga imkon beradigan yondashuv. Ushbu yondashuv 1965-yilda Lotfi Zade tomonidan kiritilgan[1]. Noravshan mantiqning asosiy tushunchasi – *noravshan to'plamlar* (fuzzy sets) va ularning *tegishlilik funksiyalari* (membership functions). Klassik to'plamlar nazariyasida element to'plamga tegishli yoki tegishli emas (1 yoki 0). Noravshan to'plamlarda esa element to'plamga ma'lum darajada tegishli bo'lishi mumkin, ya'ni



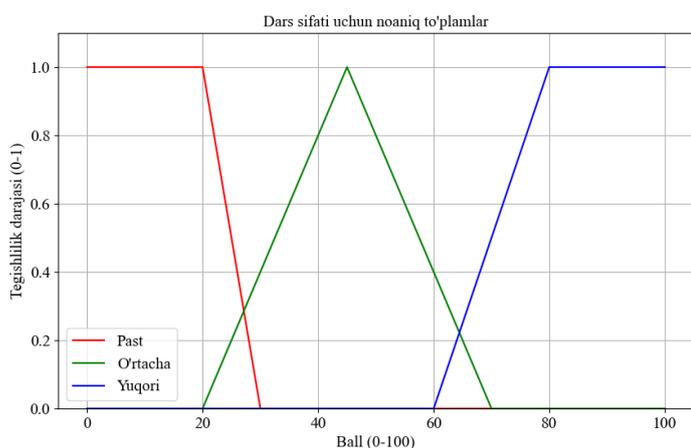
tegishlilik darajasi 0 dan 1 gacha bo'lgan oraliqda ifodalanadi[2].

Agar X universal to'plam bo'lsa, A noravshan to'plam X ning quyidagi a'zolik funksiyasi bilan ifodalanadi:

$$\mu_A(x): X \rightarrow [0, 1] \quad (1)$$

bu yerda $\mu_A(x)$ – x elementining A to'plamiga tegishlilik darajasi.

Masalan, "dars sifati"ni baholashda "yuqori", "o'rtacha" va "past" kabi noravshan to'plamlar qo'llanilsa, ularning tegishlilik funksiyalari quyidagicha bo'lishi mumkin[3]:



1-rasm: Tegishlilik funksiyalari.

Noravshan mantiqning matematik asoslari:

Noravshan mantiqda quyidagi asosiy jarayonlar qo'llaniladi[4]:

Kesishma (Intersection):

$$\mu_{A \cap B}(x) = \min(\mu_A(x), \mu_B(x)) \quad (2);$$

Birlashma (Union):

$$\mu_{A \cup B}(x) = \max(\mu_A(x), \mu_B(x)) \quad (3);$$

To'ldiruvchi (Complement):

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad (4).$$

Noravshan mantiqda *lingvistik o'zgaruvchilar* (linguistic variables) ham qo'llaniladi. Lingvistik o'zgaruvchilar – bu odatiy tilda ifodalangan tushunchalar, masalan, "yuqori", "o'rtacha", "past". Bu o'zgaruvchilar noravshan to'plamlar orqali ifodalanadi[5].

Mamdani modeli: Mamdani modeli – noaniq tizimlarda qoidalar bazasini qo'llash uchun ishlatiladigan yondashuv. Bu model 1975-yilda Ebrahim Mamdani tomonidan kiritilgan[6]. Mamdani modeli quyidagi bosqichlardan iborat:

1. *Fuzzifikatsiya (Fuzzification):* Kirish ma'lumotlari noravshan to'plamlarga aylantiriladi. Masalan, "dars sifati"ni baholashda "yuqori", "o'rtacha" va "past" kabi noravshan to'plamlar qo'llanilsa, ularning tegishlilik funksiyalari quyidagicha bo'lishi mumkin[7]:

$$\mu_{\text{yuqori}}(x) = \begin{cases} 0, & x \leq 50 \\ \frac{x-50}{30}, & 50 < x \leq 80 \\ 1, & x > 80 \end{cases} \quad (5)$$

2. *Qoidalar bazasi (Rule Base):* Qoidalar bazasi IF-THEN qoidalari asosida ishlaydi. Har bir qoida kirish ma'lumotlarini chiqishga aylantiradi.
3. *Inferensiya (Inference):* Inferensiya jarayonida qoidalar bazasidagi qoidalar qo'llanilib, noaniq chiqishlar hosil qilinadi. Bu jarayon *Mamdani modeli* asosida amalga oshiriladi. Mamdani modelida chiqish to'plamlari qoidalar natijasida kesiladi yoki birlashtiriladi[8].

Misol uchun, agar A va B kirish to'plamlari bo'lsa, chiqish to'plami C quyidagicha hisoblanadi:

$$\mu_C(z) = \max(\min(\mu_A(x), \mu_B(y))) \quad (6)$$

bu yerda z – chiqish qiymati.

4. *Defuzzifikatsiya (Defuzzification):* Defuzzifikatsiya jarayonida noravshan chiqishlar aniq qiymatlarga aylantiriladi. Eng ko'p qo'llaniladigan usul – *markaz og'irlik usuli* (Center of Gravity)[9]:

$$z_{\text{COG}} = \frac{\sum_{i=1}^n z_i \cdot \mu_C(z_i)}{\sum_{i=1}^n \mu_C(z_i)} \quad (7)$$



bu yerda z_i – chiqish qiymatlari, $\mu_C(z_i)$ – chiqish to'plamiga tegishlilik darajasi.

Natija. Mamdani inferens usuli noravshan logikada qo'llaniladigan asosiy usullardan biri sifatida tasvirlanadi. Bu usulda qoidalar "IF-THEN" shaklida bo'lib, har bir qoidaning natijasi noravshan to'plam sifatida ifodalanadi. Jarayon quyidagi bosqichlardan iborat:

1. *Fuzzifikatsiya:* Kirish qiymatlari noravshan to'plamlarga aylantiriladi.
2. *Qoidalar aktivlash darajasini hisoblash:* Har bir qoida uchun kirishlarning noravshan qiymatlari asosida qoidaning qanchalik "ishga tushishi" aniqlanadi.
3. *Natijalarni birlashtirish:* Har bir qoidaning natijasi aktivlash darajasiga qarab kesiladi (clipped).
4. *Defuzzifikatsiya:* Natijaviy noravshan to'plamdan aniq (crisp) qiymat olinadi.

Maqolada ikkita asosiy holatni ko'rib chiqamiz:

1. Bitta qoida bilan Mamdani inferens (max-min usuli).
2. Bir nechta qoidalar bilan Mamdani inferens.

Bitta qoida bilan Mamdani inferens: (Mamdani inference (max-min) with a single rule) qismida bitta qoida bilan ishlaydigan Mamdani inferens tasvirlanadi. Bu yerda generalized Modus Ponens qoidasi qo'llaniladi:

Qoida: Agar x A bo'lsa, unda y B .

Premissa: x A' .

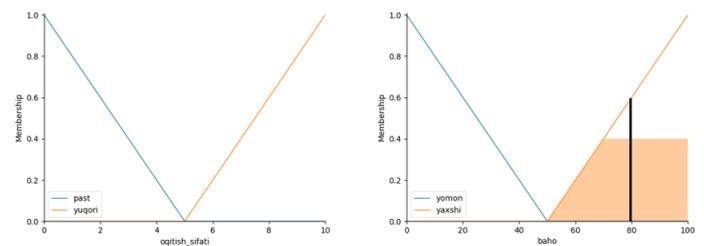
Natija: y B' .

Bu jarayonda $B'A'$ va qoida matritsasi R asosida hisoblanadi. Mamdani usulida $B'B$ ning A' ga nisbatan kesilgan (clipped) versiyasi sifatida olinadi. Hisoblash formulasi quyidagicha:

$$b'_j = \max\left(\min\left(a'_i, r_{ij}\right)\right) \quad (8)$$

Ammo Pythonda scikit-fuzzy kutubxonasi bu jarayonni avtomatik tarzda amalga oshiradi, shuning uchun biz faqat kirishlar, tegishlilik funksiyalari va qoidalarni aniqlashimiz kerak.

Kirish o'zgaruvchisi x (masalan, o'qitish sifati) va chiqish o'zgaruvchisi y (masalan, baho) bo'lsin. Qoida: Agar x yuqori bo'lsa, unda y yaxshi. Quyida *Scikit learn* da mavjud bo'lgan *skfuzzy* kutubxonasi bilan foydalanib modelni tuzamiz. x o'zgaruvchisi 0 dan 10 gacha bo'lgan diapazon bilan aniqlanadi. y o'zgaruvchisi 0 dan 100 gacha (foiz sifatida). Tegishlilik funksiyalari uchburchak shaklida (trimf) aniqlanadi. Agar o'qitish sifati yuqori bo'lsa, baho yaxshi bo'ladi. Kirish qiymati 7 bo'lganda, natija defuzzifikatsiya qilinib, aniq baho hisoblanadi (masalan, taxminan 75-80% chiqishi mumkin).



2-rasm: Bitta qoida bilan Mamdani inferens (a,

b)

- a. *Birinchi grafik (yuqorida):* o'qitish_sifati uchun tegishlilik funksiyalari ko'rsatiladi. Qizil chiziq kirish qiymati (7) ni belgilaydi. Bu chiziq yuqori tegishlilik funksiyasi bilan kesishadi, bu esa qoida faollashishini ko'rsatadi.
- b. *Ikkinchi grafik (pastda):* baho uchun tegishlilik funksiyalari va qoidaning faollashuvi (soyalangan joy) ko'rinadi. Defuzzifikatsiya natijasi (chiqish qiymati) ham grafikda avtomatik ravishda belgilanadi.

Bir nechta qoidalar bilan Mamdani inferens.

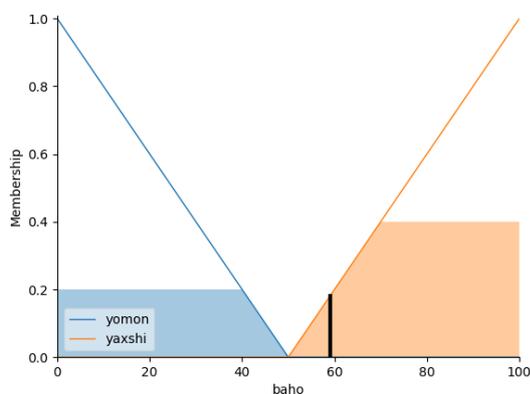
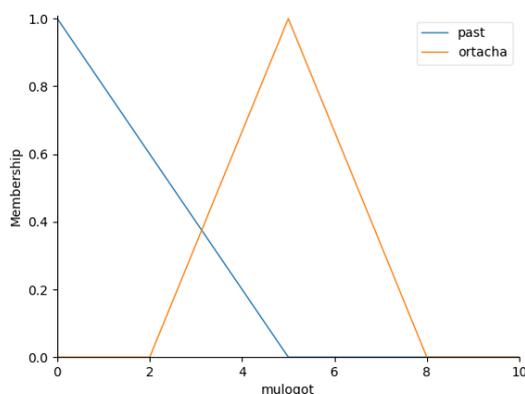
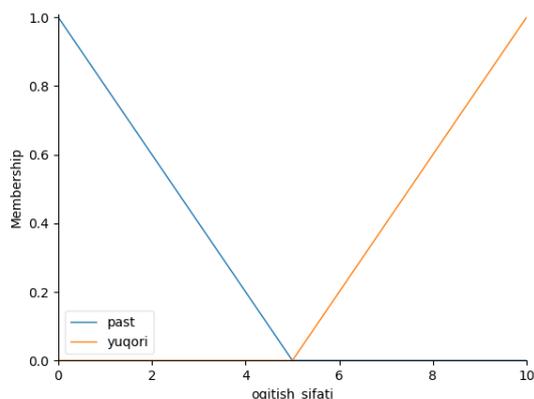
Mamdani inference with multiple rules qismida bir nechta qoidalar bilan ishlash tasvirlanadi. Bu holatda jarayon quyidagi bosqichlardan iborat:

1. Fuzzy qoidalar to'plamini aniqlash.
2. Kirishlarni fuzzifikatsiya qilish.
3. Qoidalar aktivlash darajasini hisoblash (min operatori bilan).
4. Natijalarni birlashtirish (max operatori bilan).
5. Defuzzifikatsiya qilish (Centroid usuli bilan).



Ikkita kirish o'zgaruvchisi: x (o'qitish sifati) va z (talabalar bilan muloqot). Chiqish o'zgaruvchisi: y (baho). Qoidalar:

1. Agar x yuqori va z o'rtacha bo'lsa, unda y yaxshi.
2. Agar x past yoki z past bo'lsa, unda y yomon.



3-rasm: Bir nechta qoidalar bilan Mamdani inferens.

Grafiklarning vazifasi va tushuntirishi

Bu grafikda o'qitish sifati o'zgaruvchisi uchun ikkita tegishlilik funksiyasi – past va yuqori – chiziladi.

past funksiyasi 0 dan 5 gacha cho'zilgan uchburchak shaklida, yuqori esa 5 dan 10 gacha.

Kirish qiymati o'qitish_sifati = 7 ni ko'rsatadi.

Bu chiziq grafikda vertikal chiziq sifatida belgilanadi.

Grafik kirish qiymati (7) qaysi tegishlilik funksiyasi bilan qanday kesishganini ko'rsatadi. Masalan, o'qitish_sifati = 7 da yuqori tegishlilik funksiyasi bilan kesishadi va bu qiymatning yuqori darajaga qanchalik tegishli ekanini aniqlaydi.

Baho uchun tegishlilik funksiyalari va qoidalar faollashuvi.

Bu grafikda baho o'zgaruvchisi uchun ikkita tegishlilik funksiyasi – yomon (0 dan 50 gacha) va yaxshi (50 dan 100 gacha) – ko'rsatiladi. Shu bilan birga, qoidalar faollashuvi (soylangan joylar) va defuzzifikatsiya natijasi ham aks etadi.

Grafik qoidalar asosida (rule1 va rule2) chiqish qiymati qanday shakllanganini ko'rsatadi. Soylangan joylar qoidalar natijasida tegishlilik funksiyalarining kesilgan qismlarini ifodalaydi. Yakuniy baho qiymati esa defuzzifikatsiya (aniq qiymatga aylantirish) natijasida chiqadi.

Modellarni taqqoslash jadvali

1-jadval.

Model	Aniqlik	Subyektiv ma'lumotlarni boshqarish	O'rnatish qulayligi	Moslashuvchanlik
Fuzzy logikaga asoslangan ekspert tizim	Yuqori	A'lo	O'rtacha	Yuqori
An'anaviy ball tizimi	O'rtacha	Past	Yuqori	Past
Statistik modellar	Yuqori	O'rtacha	O'rtacha dan yuqori	O'rtacha
Mashinali o'rganish modellari	Juda yuqori	O'zgaruvchan	Past dan o'rtacha	Yuqori

Jadvaldan ko'rinib turibdiki, *noravshan logikaga asoslangan ekspert tizim* modeli, ayniqsa, *subyektiv ma'lumotlarni boshqarish* va *moslashuvchanlik* jihatlarida boshqa modellardan ustun turadi. Universitet o'qituvchilarini baholashda talabalar fikri kabi sifatli va subyektiv ma'lumotlar muhim ahamiyatga ega bo'lganligi sababli, bu model ushbu soha uchun eng mos yechim sifatida ajralib turadi. Shu bilan birga, u aniqlik va o'rnatish qulayligi o'rtasida ham yaxshi muvozanatni ta'minlaydi, bu esa uni an'anaviy va boshqa zamonaviy modellarga nisbatan afzal qiladi.



Mamdani modeli o'zining soddaligi bilan ajralib turadi, chunki uning qoidalar bazasi odatiy tilda (ya'ni, inson uchun tushunarli shaklda) ifodalanadi. Bu modelda noravshan mantiq qo'llaniladi, ya'ni noaniq yoki aniq chegaralari bo'lmagan ma'lumotlarni qayta ishlash uchun qulay. Masalan, "agar harorat yuqori bo'lsa, ventilyatorni tezlashtir" kabi qoidalar oddiy va tushunarli tarzda yoziladi. Bu esa modelni nafaqat mutaxassislar, balki bu sohada yangi bo'lgan odamlar uchun ham oson tushunarli qiladi. Shu sababli, Mamdani modelini loyihalash, sinovdan o'tkazish va amalda qo'llash jarayonlari ancha soddalashadi[10].

Mamdani modelining eng muhim afzalliklaridan biri shundaki, u ekspertlarning tajribasini tizimga osonlik bilan integratsiya qilishga yordam beradi. Inson tajribasi ko'pincha noaniq yoki sifat jihatidan ifodalanadi (masalan, "agar havo juda sovuq bo'lsa, isitgichni yoqish kerak"). Mamdani modelida qoidalar bazasi shunday tajribaga asoslangan holda tuzilishi mumkin. Ekspertlar o'z bilimlarini matematik formulalar yoki murakkab algoritmlarga o'tkazmasdan, oddiy ifodalar orqali tizimga kiritishi mumkin. Bu esa modelni real dunyo muammolarini hal qilishda yanada samarali qiladi. Masalan, tibbiyotda shifokorlarning tajribasiga asoslangan diagnostika tizimlari yoki sanoatda tajribali muhandislarning bilimlariga tayangan boshqaruv tizimlari Mamdani modeli yordamida muvaffaqiyatli amalga oshirilishi mumkin.

Xulosa. Maqolada ushbu tizimni amalga oshirish va sinovdan o'tkazish jarayonlari tasvirlanadi. Tizimning afzalliklari qatorida uning moslashuvchanligi, noaniq ma'lumotlarga bardoshlilik va insoniy tajribani hisobga olish qobiliyati kabi jihatlar alohida ta'kidlanadi. Shu bilan birga, tizimning kamchiliklari ham ko'rsatilib, uni yanada takomillashtirish yo'llari taklif etiladi. Shuningdek, maqolada ushbu tizimning nafaqat ta'lim sohasida, balki boshqa sohalarda, masalan, talabalarning o'qish samaradorligini baholash yoki universitetlar reytingini aniqlashda qo'llash imkoniyatlari haqida fikr yuritiladi.

O'zbekistonda ushbu tizim o'qituvchilar faoliyatini baholashda adolatli va samarali yondashuv

sifatida qo'llanilishi mumkin. Chunki u noaniq va subyektiv ma'lumotlarni hisobga olgan holda aniq natijalar berishga qodir. Maqolada tizimning boshqa baholash tizimlari bilan solishtirilganda ustunligi ham tasdiqlanadi va amalda qo'llash natijalari asosida xulosalar keltiriladi.

Umuman olganda, ushbu maqola noravshan mantiqqa asoslangan ekspert tizimlarining universitet o'qituvchilarining faoliyatini baholashdagi samaradorligini isbotlaydi va O'zbekistonda ham ushbu yondashuvni joriy etish imkoniyatlarini o'rganish uchun muhim manba bo'lib xizmat qiladi.

ADABIYOTLAR:

1. Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3), 338–353. Mamdani,
2. E. H., & Assilian, S. (1975). An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, 7(1), 1–13.
3. Popescu, V. F., & Pistol, M. S. (2021). Fuzzy logic expert system for evaluating the activity of university teachers. *International Journal of Assessment Tools in Education*, 8(4), 991–1008.
4. Bellman, R., & Zadeh, L. (1970). Decision Making in a Fuzzy Environment. *Management Sciences*, 17(4), 141–164.
5. Chennakesava, R. (2008). *Fuzzy logic and neural networks*. Basic concepts & applications, New Age International Publishers.
6. Chuen, L. (1990). Fuzzy Logic in Control Systems: Fuzzy Logic Controller – Part I. *IEEE Transactions on Systems, Man, and Cybernetics*, 20(2), 404–418.
7. Garrido, L. (2012). A Brief History of Fuzzy Logic. *Broad research in artificial intelligence and neuroscience*, 3(1), 71–77.
8. Takagi, T., & Sugeno, M. (1985). Fuzzy Identification of Systems and Its Application to Modeling and Control. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-15, 116–132.
9. Ahmed, F., & Toki, M. (2016). A Review on Washing Machine Using Fuzzy Logic Controller. *International Journal of Emerging Trends in Engineering*, 4(7), 64–67.
10. Subbulakshmi, L. (2014). Antilock-braking system using fuzzy logic. *Middle-East Journal of Scientific Research*, 20(10), 1306–1310.



NOVEL METHODS FOR DETECTING ANOMALIES IN INFORMATION COMMUNICATION SYSTEMS

G'ulomov Sherzod Rajaboyevich,

Dean of the Faculty of Cybersecurity at Tashkent
University of Information Technologies named after
Muhammad al-Khwarizmi, Doctor of Technical
Sciences (DSc), Tashkent, Uzbekistan.
e-mail: sherhisor30@gmail.com

Jumayev Sodikjon Nuraliyevich,

Senior Lecturer at the Department of Information Technology,
Denov Institute of Entrepreneurship and Pedagogy,
Tashkent, Uzbekistan
e-mail: jumayev.sodiq9091@mail.ru
ORCID: 0009-0001-4741-8848

Abstract. As the complexity of ICS increases, security concerns also grow. Anomalies may indicate failures or cyberattacks, making early detection crucial. Traditional statistical and threshold-based methods are ineffective in dynamic ICS environments. ML- and DL-based methods, including support vector machines, autoencoders, and recurrent neural networks, improve accuracy and adaptability. However, they often require high computational resources. Transfer learning, federated learning, and XAI help overcome these limitations. This study analyzes and compares traditional and emerging approaches.

Keywords: Anomaly detection, information communication systems, machine learning, deep learning, hybrid models, transfer learning, federated learning, explainable AI, real-time monitoring, cybersecurity.

Introduction. The security and integrity of ICS become very important as the systems become larger, more robust, and integral to numerous sectors. Anomaly essentially points toward deviation from normal behavior and can indicate impending failure or a cyber-attack. Early detection of such anomalies is critically instrumental in ensuring continuity in operational efficiency and security in an ICS environment. Traditional concepts of anomaly detection are threshold-based and statistical models, which have limits in their accuracy and adaptiveness toward changing or evolving threats. Novel solutions for overcoming these challenges have only very recently been developed, each one more sophisticated compared to earlier approaches, since they adopt machine learning, deep learning, and advanced statistical techniques. The paper discusses traditional and novel approaches to anomaly detection in ICS,

considering an in-depth analysis of strengths, limitations, and challenges for each of them.

Related Works. Early work on anomaly detection was performed by the use of statistical methods, where anomalies were identified as outliers. Techniques that were employed in this direction and were widely used included Gaussian distribution and hypothesis testing among others Fawcett,1999. Even though these methods boast simplicity, they are limited by the assumption of data normality-an assumption which may be far from being held in complex ICS environments.

These threshold-based techniques identify anomalies based on some predetermined limits. While these work well in simple cases, they do not function effectively in adaptive environments where the thresholds are constantly in need of updating [2].

Supervised machine learning models include Support Vector Machines (SVMs) and Decision Trees



which have been put to use in anomaly detection. These are models which rely on labelled data—a task that is quite impractical or farfetched in real-time ICS environments [3].

Several unsupervised models, such as k-means and DBSCAN, have also been attempted for anomaly detection in ICS. These models may detect unknown anomalies with no labeled data, but the false-positive rates of these solutions are generally higher. More and more CNNs and RNNs have recently been used to detect anomalies in ICS. The aforementioned models possess the capability to learn complex patterns but normally require sizeable computational resources and big datasets to get trained.

Autoencoders and Variational Autoencoders prove to be one of the effective unsupervised anomaly detection methodologies. AEs are capable of reconstructing input data and locating anomalies based on reconstruction errors, thus being pretty effective against such complex ICS datasets [6].

The combination of statistical, machine learning, and deep learning models has witnessed the potential for improvement concerning detection accuracy. However, most of these methods require great attention in parameter tuning and system customization [7].

Graph-based methods model systems as graphs, wherein anomalies can be detected by node-relationship examination. Most of these methods are good in detecting structural anomalies but face difficulties when ICS is dynamic in nature [8].

Ensemble techniques such as Random Forest, Gradient Boosting constitute the weak learners to get a better detection. Their accuracy is pretty high but computationally expensive generally.

Adversarial learning, especially GANs, can easily simulate an attack scenario to improve the detection accuracy. However adversarial training is resource-intensive and needs carefully designed over the overfitting problem [10].

Literature Review and Methodology.

Research on anomaly detection in information communication systems has significantly advanced in recent years. A review of the literature reveals various

methods, which can be broadly classified into statistical approaches, machine learning-based techniques, and deep learning models. Statistical methods (e.g., Gaussian mixture models, z-score, mean squared deviation) detect anomalies based on mathematical models. Machine learning techniques (e.g., SVM, k-NN, random forest) enable the identification of anomalous patterns from large datasets. In recent years, deep learning-based approaches such as autoencoders, Generative Adversarial Networks (GANs), and recurrent neural networks (RNNs) have been developed to achieve high-accuracy anomaly detection.

The research methodology involves multiple approaches. First, experiments are conducted using real and synthetic datasets. Second, advanced anomaly detection methods are compared and evaluated based on their effectiveness. The third approach focuses on hybrid models, combining classical and modern techniques to enhance accuracy and improve detection performance.

Methodology. The anomaly detection methods were analyzed based on their foundational principles, adaptation capability, and performance in ICS. This was done by reviewing their statistical models, machine learning, and deep learning approaches against detection rates, false positives, and system adaptability. The review targeted the following key aspects:

Statistical Methods: Adaptive and real-time ICS cannot effectively be handled by statistical approaches due to the limitation of the static threshold setting.

Machine Learning: It is highly versatile, and most of the models in machine learning rely on quality labeled data.

Deep Learning: Deep learning, especially with AEs and CNNs, promises very interesting results for the identification of complex patterns. However, deep models are computationally demanding.

Hybrid and Ensemble Methods: Hybrid approaches use the strengths of combined models but require intricate tuning, delaying deployment.



Power consumption is currently one of the most important factors in IoT devices. Within this requirement, Muhammad Rana published the following research results in his article. The power consumption of the Proposed, Piccolo, Rectangle, Print, Present, Iceberg, and High algorithms, presented in Figure 1, is shown in the form of bar charts [2].

Table 1. Differences between methodologies

Method	Description	Pros	Cons	Key Challenge
Statistical	Statistical anomaly detection would employ various mathematical models based on the premise that normal data follows some form of distribution. Anomalies are those data points which divert from the distribution. Techniques for finding such anomalies include analyses like Z-score analysis, moving averages, and ARIMA.	Simple to implement, fast	Limited flexibility, prone to high false positives	The nature of the statistical approach can't accord with real-time or changing systems, thus becoming less relevant in dynamic ICS environments.
Threshold-Based	Anomaly detection using a threshold requires the setting of a predefined threshold beyond which any deviation from normal behavior is regarded as abnormal.	Effective in stable environments	Requires constant updates, sensitive to environmental changes	It is all about determining the right threshold, since wrong settings lead either to missed anomalies or false alarms.
Machine Learning	These models for classification, using machine learning, make use of the patterns present in the historical data to label new data either normal or anomalous. They could be supervised, unsupervised, or semi-supervised, depending on the usage, whereas common algorithms include SVM, Decision Trees, k-means, and Isolation Forests.	Adaptable, can handle complex patterns	Relies on labeled data, potentially high false positives	However, most ML models rely on labeled data. Thus, their effectiveness is usually poor in environments with scant labeled anomalies, where less accurate unsupervised or semi-supervised models should be used instead.
Deep Learning	The deep learning methods leverage neural networks to detect complicated	High accuracy, good at	Resource-intensive, requires	The challenge of real-time anomaly detection using a deep learning

	patterns and inobvious anomalies that exist in the high-dimensional data by including Autoencoders (AEs), Variational Autoencoders (VAEs), CNNs, and RNNs. These are particularly effective in analyzing sequential or spatial data, like the time-series sensor readings in ICS.	complex anomaly detection	large datasets	model in ICS is due to the requirement of high infrastructures to provide the needed computational resource and time required for training and inference.
Hybrid and Ensemble	Hybrid and ensemble methods provide the capabilities for improving accuracy and robustness, combining different anomaly detection techniques. Combining statistical methods with either machine learning or deep learning models, together with using ensemble methods such as Random Forests or Gradient Boosting, increases the reliability and reduces missed anomalies.	Combined strengths, high accuracy	Complex to deploy, resource-heavy	Because of this, hybrid and ensemble methods might prevent the quick deployment of methods due to their high computational demand and, therefore, will be an obstacle for real-time monitoring, especially in those large-scale ICSs that are sensitive to real quick responses.

Challenges in Anomaly Detection. Despite the fact that recently much development in anomaly detection techniques has been done, still a number of challenges have to be resolved regarding the applications in ICS. Those are regarding data availability, system adaptability, model performance, and real-world deployment. Addressing such aspects will lead to improving anomaly detection accuracy for reduced false positives and ensure operational efficiency in the ICS environment.

1. Data Scarcity and Quality

Lack of labelled data: Most anomaly detection models, more precisely those pertaining to supervised machine learning, require labelled datasets for identifying data as normal or anomalous. However, in the ICS environments, this is typically infeasible due to time-consuming and resource-demanding procedures.



Imbalanced Data: The number of normal events in ICS is much higher compared to anomalies; hence, datasets are highly imbalanced. It's difficult for a model to learn how to recognize very rare anomalies with such imbalanced data, and usually ends up in a high number of false negatives.

Data Diversity: ICS data is generated by a diverse set of sources, ranging over network traffic, sensor data, and logs in different structures and formats. Therefore, integrating and normalizing the data to create a coherent input for detection models requires careful preprocessing in a complex task.

2. Real-Time Adaptability and Scalability

Dynamic environments: Many ICSs are set up in dynamic environments wherein the constantly evolving system conditions give rise to the emergence of new types of anomalies. Such changes would require models to adapt while many current methods of anomaly detection are unable to update dynamically without new data retraining.

Scalability Issues: Large-scale ICS anomaly detection requires handling high volumes of data in real time. Such computationally intensive techniques, like deep learning models, may not scale appropriately on very large networks due to their processing constraints and hence have limited practical deployments in a real-world, real-time environment.

Latency Constraints: Real-time anomaly detection requires that models analyze data with minimum latency so it may raise the flag against any potential threat on time. However, such complicated models, and specially deep learning techniques may add latency to the process due to the intensive computation needed, which impedes their timely detection.

3. High False Positive Rates

There needs to be a balance between the two in anomaly detection models: sensitivity management, meaning the true anomaly detection rate, and the other meaning specificity or minimization of false alarms. A high amount of false alarms leads to alert fatigue, or said another way, users become so accustomed to raised alerts that they fail to notice the true anomalies.

Environmental Noise: The ICS environments are generally noisy, and the deviations of normal operations often fire false positives in the rigid models of detection. Models that can't identify benign deviations from true anomalies overwhelm operators with a high number of alerts.

4. Computational Resource Demands

Resource-Intensive Models: Most of these methods, such as the deep learning-based ones, demand an unprecedented amount of computational resources in terms of robust hardware for model training and model-based inference. This can be a limiting factor in ICS setups with limited computational capacity.

Memory and Storage Constraints: Large volume ICS data require significant memory and storage; this is especially true for those models running on huge historical datasets or even needing to store elaborate logs for anomaly detection.

5. Interpretability and Transparency

Complex Model Interpretability: Most modern anomaly detection methods, such as neural networks and ensemble models, are usually "black boxes," and hence their decision-making processes are not easy to understand by human operators. In ICS, where decision-making has to be quick, lack of interpretability can make the operator diffident about trusting and acting upon model outputs.

Regulatory and Compliance Concerns: In regulated industries, such as energy or healthcare, anomaly detection models should be transparent enough that they meet a certain legislative and compliance standard. To that end, model predictions without explanations may indicate a problem in cases where interpretability is a regulatory requirement.

6. Privacy and Security Issues

Data Privacy: Some of the anomaly detection techniques, especially those that rely on machine learning, necessitate data aggregation. This, in turn, will by all means involve data privacies containing sensitive information flowing into sectors that are not liable to handle such data. The integration of detection while keeping data privacy in mind-through techniques



such as federated learning, for example-is neither easy nor inexpensive.

Vulnerabilities of Models: A few of the proposed techniques for detection are vulnerable to adversarial attacks, where the attacker manipulates data input to defeat detection. Such models need hardening against these, at least in ICS where malicious entities may want to cloak their actions.

7. Challenge of Generalization

Domain Adaptation: Models trained in one ICS environment might show catastrophic performance in another environment due to system architecture, network configurations, and operational patterns. Generalization across different ICS environments is difficult with models, with less retraining.

Evolving Threat Landscape: The models of anomaly detection need to get updated very frequently because new threats and attack vectors are continuously emerging. This rapid evolution of cyber threats keeps up the challenge of maintaining relevance and resiliency in the anomaly detection systems.

It is required that continuous innovations be made in model design, data handling, and computational techniques to address all these challenges. Both researchers and practitioners need to develop more adaptive, interpretable, and resource-efficient methods in order to further improve the capability of anomaly detection in complex and dynamic ICS environments.

RESEARCH RESULTS

Novel Methods in Anomaly Detection.

Recent improvements in anomaly detection for ICS address a number of key limitations of prior work, particularly along the axes of adaptability, computational efficiency, and explainability. Advanced machine learning and deep learning architectures, federated learning, explainable AI, and hybrid models are modern techniques, each adding to the advancement of both accuracy and applicability of anomaly detection within diverse and dynamic ICS environments.

1. Transfer Learning for Anomaly Detection

Transfer learning in anomaly detection enables models to be pre-trained on one domain or dataset and

then adapted, with minimal retraining, to another. This greatly reduces the need for large volumes of labelled datasets relevant to each ICS environment-a fact that makes this approach all the more valuable when data volume is limited by the systems.

The main advantage of transfer learning is that it reduces model training time and resources while increasing generalization across different ICS setups. This concept of transfer learning will be useful in handling evolving threats whereby models can be updated with data from recent threats without full retraining.

Although effective, transfer learning requires a lot of care in fine-tuning since negative transfer may occur, where irrelevant patterns from the source domain impact the performance of the model in the target domain [11].

2. Federated Learning for Data Privacy

It facilitates the training of anomaly detection models across multiple ICS systems collaboratively with devices/sites in a data-federated manner, hence preserving data privacy. Each device will train a local model on its data, and the model updates, not the data itself, will be shared only with the central server.

It takes care of privacy concerns for those industries dealing with sensitive information, such as health care or financial transactions. Federated learning enhances the robustness of a model in terms of the model being able to learn from diverse environmental conditions and thereby capturing more variability in anomalies.

Federated learning involves immense communication overhead between devices and the central server. Besides, coordination of updates from distributed models may cause synchronization problems and incur latency [12].

3. Explainable AI (XAI) for Anomaly Detection

These techniques of Explainable AI try to make the models of anomaly detection more interpretable by explaining why a particular instance was classified as an anomaly. Techniques like SHAP and LIME do provide post-hoc explanations for complex models.

XAI will improve transparency that shall enable operators to understand and trust model outputs, crucial



in decision-making for ICS. In addition, explainable models will easily observe regulatory compliance while some sectors require interpretability for model deployment.

These XAI models introduce further complexity in the anomaly detection pipeline, possibly slowing down real-time detection processes. Moreover, finding the appropriate tradeoff between model interpretability and prediction accuracy remains difficult, since very interpretable models are sometimes less accurate [13].

4. Graph-Based Neural Networks (GNNs) for Structural Anomaly Detection

Graph-based neural networks include Graph Convolutional Networks and Graph Attention Networks that model ICS as graphs. The nodes in such graphs correspond to the individual components, sensors, and devices of ICS, and the edges model interactions between these components. Anomalies are found by detecting strange patterns or irregularities inside such graphs.

GNNs are very capable in anomaly detection in ICS, having proven their ability to capture relational dependencies. The approach is quite practical in networked settings, where the relationships among nodes can point out anomalies in patterns of data flows or spikes that were not expected.

The GNNs are, for example, generally computationally expensive and may not scale to very large graphs. Additionally, such models require considerable configuration to capture meaningful relationships in diverse ICS environments [8].

5. Self-Supervised Learning for Label-Free Anomaly Detection

SSL trains the models to identify anomalies without any labeled data. The SSL models create pseudo-labels or utilize context-based learning objectives that enable the detection of outliers in unlabeled datasets, making them helpful for ICSs with limited or no labeled data.

This would overcome the challenge of labeling data such that even in cases where labeled data is not available, models can be developed for anomaly

detection. SSL also generalizes well to unseen data, hence very effective in novel anomaly detection.

The SSL models generate very accurate pseudo-labels, which could be challenging in noisy or complex ICS environments. Further, some of the SSL techniques may require fine-tuning to prevent overfitting in patterns irrelevant to the specified task.

6. Adversarial Training for Robust Anomaly Detection

Adversarial training employs Generative Adversarial Networks that generate attack scenarios and train detection models to recognize them and, if possible, neutralize their effect. GANs basically consist of a generator, which generates the adversarial examples, and a discriminator that learns to detect these.

This will help in improving model defences against these types of sophisticated attacks, especially adversarial examples intelligently crafted to get past the detectors. This will be particularly helpful in ICS environments where there is a possibility of cyber-attacks, equipping the models to identify malicious patterns.

The adversarial training process is computationally expensive and can result in higher model complexity for tasks other than generating new content, which may have an impact on real-time performance. Further, the GANs require careful tuning to avoid overfitting as their discriminator should generalize to real-world scenarios [10].

7. Hybrid Models for Enhanced Detection

Hybrid models use traditional statistical methods in conjunction with machine learning and deep learning to create robust anomaly detection frameworks. For instance, combining statistical time-series models with autoencoders uses both the interpretability of statistical methods and the handling capabilities of deep learning with respect to complexity.

They are flexible and powerful models in that, within the context of ICS, they draw upon the complementary strengths of each component method. They can handle diverse data types, like time-series



data or relational data; hence, they may be adapted at several layers in ICS.

This requires very careful implementation, where the integration of every component must be tuned, since inconsistency may be subjected to a high false-positive rate or degraded performance. The hybrid models are resource-intensive and need much computational power [7].

The accuracy for different methods of anomaly detection is mathematically expressed as follows.

1. Accuracy Formula

Accuracy is the ratio of correctly classified samples to the total number of samples.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} * 100\%$$

Accuracy Formula - TP (True Positive) - Correctly detected anomalies, TN (True Negative) - Correctly detected normal cases, FP (False Positive) - Normal cases incorrectly classified as anomalies, FN (False Negative) - Anomalies incorrectly classified as normal cases

2. Transfer learning formula

Evaluating the accuracy of a transfer learning model for a new domain.

$$\text{Accuracy}_{\text{target}} = \frac{TP_{\text{target}} + TN_{\text{target}}}{TP_{\text{target}} + TN_{\text{target}} + FP_{\text{target}} + FN_{\text{target}}} * 100\%$$

In this case, the model's accuracy is evaluated in the target domain.

3. Federated learning formula

In federated learning, the average accuracy of n local models is calculated as follows.

$$\text{Accuracy}_{\text{global}} = \frac{1}{n} \sum_{i=1}^n \text{Accuracy}_i$$

Here, Accuracy_i represents the accuracy of each local model.

4. Hybrid Models Formula

Hybrid model approaches combine different methods, so the final accuracy is determined as follows.

$$\text{Accuracy}_{\text{hybrid}} = \omega_1 \text{Accuracy}_{\text{ML}} + \omega_2 \text{Accuracy}_{\text{DL}} + \omega_3 \text{Accuracy}_{\text{Stat}}$$

Here - $\text{Accuracy}_{\text{ML}}$ - Accuracy of the machine learning model, $\text{Accuracy}_{\text{DL}}$ - Accuracy of

the deep learning model, $\text{Accuracy}_{\text{Stat}}$ - Accuracy of the statistical method

The following table presents the accuracy levels (%) of various methods for anomaly detection.

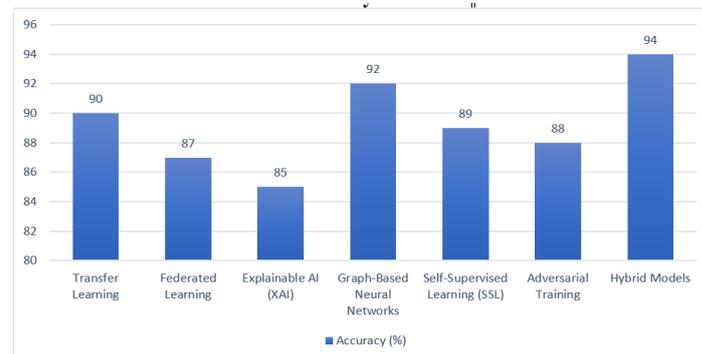


Figure 1. Accuracy results of various methods for anomaly detection

Here is a diagram showing the accuracy levels of various anomaly detection methods. Each method's result is expressed as a percentage (%). As seen in the diagram, the Hybrid Models method has the highest accuracy (94%), while other methods have also achieved good performance in terms of effectiveness.

CONCLUSION

Anomaly detection plays an indispensable role in ICS for operational security and stability. Traditional statistical methods, though effective in computational resources, are severely limited by their static threshold settings and assumptions that can hardly adapt to the dynamic environment. Machine learning and deep learning approaches, using techniques such as autoencoders and CNNs, demonstrate better pattern recognition performance and adaptiveness but often require a large dataset and immense computational resources-limiting real-time applications. Hybrid and ensemble approaches, which combine the strengths from various approaches, tend to further improve detection accuracy but at the cost of higher complexity and extensive tuning.

Recent developments, such as transfer learning, federated learning, and explainable AI, address the challenges around data sparsity, adapting to change, and model interpretability. These new approaches have made the detection more productive by better usage of



scarce data, preserving privacy, and interpretability of model output. Yet high computation, difficulties in scaling up real-time, and complexities in tuning models are major challenges.

In all, the future of ICS anomaly detection lies in the refinement of these approaches to adaptive, resource-efficient, and interpretable models that will move as fast as the threats while protecting the critical systems more effectively.

References

1. Gjorgjievska Perusheska, Milena & Dimitrova, Vesna. (2023). Application of Machine Learning in Intrusion Detection Systems. 10.1007/978-3-031-37717-4_86.
2. Abu Musa, Tahani & Bouras, Abdelaziz. (2022). Anomaly Detection: A Survey. 10.1007/978-981-16-2102-4_36.
3. Zhang, Y., Wang, Z., & Jin, H. (2019) - Network Intrusion Detection Based on Improved DGA and VAE
4. Dey, Samrat & Rahman, Md. Mahbubur. (2018). Flow Based Anomaly Detection in Software Defined Networking: A Deep Learning Approach With Feature Selection Method. 630-635. 10.1109/CEEICT.2018.8628069.
5. Ali, Mohamed & Al-berry, Maryam & Taha, Zaki. (2021). Convolutional Autoencoder for Anomaly Detection in Crowded Scenes. 10.1007/978-3-030-76346-6_55.
6. Kopčan, Jaroslav & Skvarek, Ondrej & Klimo, Martin. (2021). Anomaly detection using Autoencoders and Deep Convolution Generative Adversarial Networks. Transportation Research Procedia. 55. 1296-1303. 10.1016/j.trpro.2021.07.113.
7. Vishwakarma, Pawan Kumar & Suyambu, Muthuvel. (2024). Data Analytics In Smart Grid With Renewable Energy Integration. 10. 1-10.
8. Xiao, Qingsai & Liu, Jian & Wang, Quiyun & Jiang, Zhengwei & Wang, Xuren & Yao, Yepeng. (2020). Towards Network Anomaly Detection Using Graph Embedding. 10.1007/978-3-030-50423-6_12.
9. Arqane, Aouatif & Boutkhoul, Omar & Boukhriss, Hicham & Moutaouakkil, Abdelmajid. (2022). Intrusion Detection System using Ensemble Learning Approaches: A Systematic Literature Review. International Journal of Online and Biomedical Engineering (iJOE). 18. 160-175. 10.3991/ijoe.v18i13.33519.
10. Shahriar, Md Hasan & Haque, Nur Imtiazul & Rahman, Mohammad & Alonso Jr, Miguel. (2020). G-IDS: Generative Adversarial Networks Assisted Intrusion Detection System. 10.48550/arXiv.2006.00676.
11. S. Aburakhia, T. Tayeh, R. Myers and A. Shami, "A Transfer Learning Framework for Anomaly Detection Using Model of Normality," 2020 11th IEEE Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON), Vancouver, BC, Canada, 2020, pp. 0055-0061, doi: 10.1109/IEMCON51383.2020.9284916.
12. Rane, Jayesh & Mallick, Suraj & Kaya, Ömer & Rane, Nitin. (2024). Federated learning for edge artificial intelligence: Enhancing security, robustness, privacy, personalization, and blockchain integration in IoT. 10.70593/978-81-981271-0-5_3.
13. Sharma, Jeetesh & Mittal, Murari & Soni, Gunjan. (2023). Explainable artificial intelligence (XAI) enabled anomaly detection and fault classification of an industrial asset. 10.21203/rs.3.rs-2780708/v1.



IoT QURILMALARDA MA'LUMOT UZATISH JARAYONLARINI ADAPTIV BOSHQARISH ALGORITMI

Nishanov Axram Xasanovich,

t.f.d, Muhammad al-Xorazmiy nomidagi Toshkent
axborot texnologiyalari universiteti professori
nishanov_akram@mail.ru ,
ORCID: 0000-0002-5652-8977

Samandarov Batirbek Satimovich,

PhD, dotsent, Ma'mun universiteti
Muhammad al-Xorazmiy nomidagi Toshkent axborot
texnologiyalari universiteti tadqiqotchisi
batirbeksamandarov@gmail.com ,
ORCID: 0000-0002-8296-0894

Joldasbaev Dawranbek Rustem uli,

Muhammad al-Xorazmiy nomidagi Toshkent axborot
texnologiyalari universiteti tayanch doktoranti
jdauranbekr10@gmail.com ,
ORCID: 0009-0009-7025-638X

Gulmirzaeva Go'zal Alisher qizi,

Muhammad al-Xorazmiy nomidagi Toshkent axborot
texnologiyalari universiteti tayanch doktoranti
gozzalgulmirzayeva55@gmail.com ,
ORCID: 0009-0007-6779-7842

Annotatsiya. Internet ashyolar (IoT) qurilmalarida energiya samaradorligini oshirish muhim ahamiyatga ega. Ushbu maqolada atrof-muhit parametrlarining dinamik o'zgarishlariga mos ravishda ma'lumot uzatish intervalini avtomatik boshqaruvchi adaptiv algoritmlar taklif etiladi. Algoritm datchiklarning ma'lumot uzatish chastotasini optimallashtirish orqali energiya sarfini kamaytirish va qurilmalarning uzoq muddatli ishlashini ta'minlashga qaratilgan.

Kalit so'zlar: IoT, ma'lumot uzatish, energiya samaradorligi, adaptiv algoritmlar, sensor tarmoqlari, dinamik boshqaruv, optimallashtirish.

Kirish. Jahonda Internet ashyolar (Internet of Things, IoT) texnologiyasi yangi avlod intellektual tizimlarning asosiy komponenti sifatida turli sohalarda keng qo'llanilmokda. IoT qurilmalari atrof-muhitni monitoring qilish, ma'lumot to'plash va ishlab chiqarish jarayonlarini avtomatlashtirishda muhim ahamiyatga ega [1]. Issiqxonalarda IoT texnologiyasi mikroklimatni nazorat qilish, energiya sarfini optimizatsiya qilish va hosil sifatini oshirishda samarali o'rin egallamoqda [2,3]. Biroq, IoT qurilmalarning energiya manbai bilan bog'liq muammolari, ayniqsa elektr tarmog'iga ulanish

imkoniyati bo'lmagan joylarda, ularning ish davomiyligini cheklaydi [4].

Energiyani tejash masalasi ayniqsa IoT tizimlarida juda muhim jihatlardan, chunki ko'pgina datchiklar batareykalar yordamida ishlaydi va ularning ish davomiyligi ma'lumot uzatish chastotasiga to'g'ridan-to'g'ri bog'liq sanaladi [5,6,7]. Ma'lumot uzatish chastotasini optimal ravishda boshqarish orqali energiya sarfini kamaytirish mumkin. Buning uchun adaptiv algoritmlardan foydalanish tavsiya etiladi, ular qayd qilinayotgan ma'lumotlarning o'zgarish



jarayonlariga qarab uzatish intervallarini moslashtiradi [8].

Issiqxona muhitida IoT datchiklarining samarali faoliyat yuritishi uchun energiya sarfini minimallashtirish muhim ahamiyatga ega. Atrof-muhit sharoitlarining dinamik o'zgarishiga mos ravishda ma'lumot uzatish chastotasini avtomatik tarzda muvofiqlashtiradigan moslashuvchan algoritmlar taklif etiladi. Ushbu yondashuv datchiklarning ishlash davomiyligini uzaytirish bilan birga, energiya sarfini kamaytirish va tizimning umumiy samaradorligini oshirish imkonini beradi.

Adabiyotlar tahlili. IoT texnologiyasining rivojlanishi bilan birga, turli sohalarda energiyani tejash masalasi ko'pgina tadqiqotlarning markazida turibdi. IoT qurilmalarining ko'pchiligi batareykalar yordamida ishlaydi, shuning uchun energiyani optimal sarflash ularning ish davomiyligini oshirishda asosiy omil hisoblanadi [1]. Energiyani tejashning asosiy usullari qatoriga adaptiv ma'lumot uzatish algoritmlari, kam energiyali tarmok protokollari va ma'lumotlarni filtrlash kiradi [4].

Resurslar bilan cheklangan IoT qurilmalarda energiyani ko'p qismi qabul qilgichlari va flesh-hotira komponentlari sababli sarflanadi [12]. Ma'lumotlarni lokal qurilmalarda qayta ishlash, ularni masofadagi server yoki boshqa IoT qurilmalariga uzatishga nisbatan kamroq energiya talab qiladi [13]. Kechikish va energiyaga sezgir bo'lgan IoT ilovalarda ma'lumotlarni energiyani tejash bilan birga kam kechikish bilan uzatish muammosi yuzaga keladi. Bu masalani hal etish uchun olib borilgan tadqiqotlarda bir tomondan, paketlarni yetkazish koeffitsienti (packet delivery ratio) va kechikish (delay) masalalariga [14,15], ikkinchi tomondan esa, energiyani tejash va paketlarning xatoliklari chastotasi (packet error rates) masalalariga e'tibor qaratilgan [16,17].

Adaptiv ma'lumot uzatish algoritmlari: Adaptiv algoritmlar ma'lumot uzatish chastotasini atrof-muhit sharoitiga qarab moslashtirish orqali energiyani tejash imkoniyatini yaratadi. [8]-tadqiqotda resurslar bilan cheklangan va kechikishga sezgir IoT ilovalarda ma'lumotlarni uzatishni optimizatsiya qilish masalasi tadqiq etilgan. Tadqiqotning asosiy

maqsadi – turli vaqt va energiya cheklanishlariga ega bo'lgan IoT tarmoqlarida ma'lumotlarni samarali uzatish uchun moslashuvchan tizim taklif etishdan iborat. Biroq, ushbu tadqiqotda, datchiklar ma'lumotlarning o'zgarish tezligiga qarab moslashuvchan uzatish e'tiborga olinmagan.

Kam energiyali tarmok protokollari. IoT tarmoqlarida energiyani tejash uchun LoRaWAN, Zigbee va MQTT-SN kabi kam energiya talab qiladigan protokollar keng qo'llanilmokda. [9]-tadqiqotda Internet of Things (IoT) da tarmok kommunikatsiyasining samaradorligi va ishonchliligini ta'minlash uchun energiyani to'plash (energy harvesting) va energiyani samarali boshqarish masalalari tadqiq etilgan. Tadqiqotda IoT sensorlarining energiya manbalarini energiyatejamkor protokollar orqali optimal boshqarish orqali ularning ish davomiyligini oshirish va turli illovalarda uzluksiz ishlashi mumkinligi qayd qilingan. Lekin bu protokollar qurilmalarning kutish rejimi (sleep mode)da ishlashini ta'minlaydi, natijada energiya sarfi kamayadi. Ammo, bu usullarning ko'pchiligi ma'lumot uzatish chastotasini moslashtirish imkoniyatini cheklaydi.

Issiqxonalarda IoT qo'llanilishi. Issiqxonalarda IoT texnologiyasi mikroklimatni nazorat qilish, suv va energiya sarfini optimizatsiya qilishda muhim ahamiyatga ega [2,3,5]. Masalan, [3]-tadqiqotda aqlli issiqxona (smart greenhouse) modelini yaratish va uning qishloq xo'jaligida qo'llanilishi tadqiq qilingan. Issiqxona ichki muhitini avtomatlashtirish uchun turli zamonaviy texnologiyalar qo'llanilishi bayon qilingan. Biroq, bu energiyani tejash masalasiga alohida e'tibor berilmagan.

Ma'lumotlarni filtrlash va agregatsiya. Ma'lumotlarni filtrlash va agregatsiya qilish orqali energiya sarfini kamaytirish mumkin. [11]-tadqiqotda IoT asosidagi simsiz sensor tarmoqlar (WSN) uchun samarali ma'lumot agregatsiyasi sxemasini (EDAS) taklif etish bo'yicha tadqiqot olib borilgan. IoT tarmoqlaridagi sensor uskunalar doimiy ravishda ma'lumot yig'ishi va uzatishi tufayli yuqori hisoblash yuki, ma'lumot takrorlanishi (redundancy), paket



to'qnashuvi (collision) va yuqori energiya sarfi kabi muammolar yuzaga keladi. Ammo, bu usulda ma'lumotlarning aniqligi pasayishi mumkin.

Hozirgi tadqiqotlar ko'rsatishicha, IoT qurilmalarida energiyani tejash uchun adaptiv algoritmlar va kam energiyali protokollar keng qo'llanilmokda. Biroq, issiqxonalar kabi maxsus sharoitda bu usullarning samaradorligini oshirish uchun yangi algoritmlarni ishlab chiqish zarur. Maqolada taklif etilayotgan algoritm atrof-muhit sharoitining o'zgarishiga qarab ma'lumot uzatish chastotasini moslashtiradi, natijada energiyani tejash va qurilmalarning ish davomiyligini oshirish imkoniyatini yaratadi.

Matematik ta'minotni qurish.

1. Masalaning umumiy tavsifi

Issiqxonadagi IoT datchiklari atrof-muhitning turli parametrlarini (temperatura, namlik, yorug'lik va boshqalar) o'lchaydi va bu ma'lumotlarni serverga uzatadi. Masalaning asosiy maqsadi – datchiklarning energiya sarfini kamaytirish uchun ma'lumot uzatish chastotasini optimal ravishda boshqarishdan iborat.

2. Matematik modellar

Masalaning matematik modellari quyidagi komponentlardan iborat:

1. Energiya sarfini modellashtirish:

Har bir datchikning energiya sarfi E ni umumiy holda quyidagi formula bilan ifodalaymiz:

$$E = E_{active} \cdot t_{active} + E_{sleep} \cdot t_{sleep}$$

Bu yerda:

E_{active} – datchikning faol rejimdagi energiya sarfi;

E_{sleep} – datchikning kutish rejimdagi energiya sarfi;

t_{active} – datchikning faol rejimdagi ish vaqti;

t_{sleep} – datchikning kuutish rejimdagi ish vaqti;

2. Ma'lumot uzatish chastotasini moslashtirish

Ma'lumot uzatish intervali T atrof-muhit parametrlarining o'zgarishiga qarab moslashtiriladi:

$$T = f(\Delta U)$$

Bu yerda:

ΔU – atrof-muhit parametrlarining o'zgarishi (namlik, temperatura va boshqalarning o'zgarishi);

$f(\Delta U)$ – moslashuvchan funktsiya, ΔU ga qarab, T ni belgilaydi.

3. Optimizatsiya maqsadi

Masalaning asosiy maqsadi – energiya sarfini minimallashtirish:

$$\min \sum_{i=1}^n E_i$$

Bu yerda E_i – har bir datchikning energiya sarfi.

4. Chegaraviy shartlar

Ma'lumot uzatish chastotasi minimal va maksimal qiymatlar bilan chegaralanadi:

$$T_{\min} \leq T \leq T_{\max}$$

Ma'lumotlarning aniqligini ta'minlash uchun ΔU ning maksimal qiymati belgilanadi

$$\Delta U \leq \Delta U_{\max}$$

3. Algoritmning matematik asoslari

Algoritmning ishlashi uchun quyidagi matematik qadamlar amalga oshiriladi:

1. Ma'lumotlarni tahlil qilish

Har bir datchik ma'lumotlarni t vaqt oralig'ida to'playdi:

$$U(t) = \{u_1, u_2, \dots, u_n\}$$

Ma'lumotlarning o'zgarishi ΔS ni quyidagicha hisoblaymiz:

$$\Delta U = \max(U(t)) - \min(U(t))$$

2. Intervalni moslashtirish

Agar $\Delta U \leq \Delta U_{\max}$ bo'lsa, ma'lumot uzatish intervali T kattalashtiriladi:

$$T = T_{\max}$$

Agar $\Delta U > \Delta U_{\max}$ bo'lsa, ma'lumot uzatish intervali T kichiklashtiriladi:



$$T = T_{\min}$$

3. Energiyani tejankorlikni hisoblash:

Har bir datchikning energiya sarfi E ni quyidagicha hisoblaymiz:

$$E = E_{active} \cdot \frac{t_{active}}{T} + E_{sleep} \cdot \left(1 - \frac{t_{active}}{T}\right)$$

Tadqiqot natijalari. Taklif etilayotgan algoritm IoT datchiklarining energiya sarfini kamaytirish uchun moslashuvchan ma'lumot uzatish chastotasini boshqarishni ta'minlaydi. Algoritm atrof-muhit parametrlarining o'zgarishiga qarab ma'lumot uzatish intervallarini avtomatik ravishda moslashtiradi. Masalaning matematik ta'minoti asosida quyidagi asosiy qadamlar amalga oshiriladi:

- Ma'lumotlarni to'plash va tahlil qilish;
- Ma'lumot uzatish intervallarini moslashtirish;

Algoritmning jarayon ketma-ketliklari quyidagi qadamlarda amalga oshiriladi:

1-qadam: Datchikni initsializatsiya qilish va boshlang'ich parametrlarni o'rnatish

$$T_{\min} = 10, T_{\max} = 60, \Delta U = 5$$

Bu yerda, T_{\min} va T_{\max} lar vaqt birligida (minut), ΔU – foizda, ya'ni, atrof muhit parametrlaridagi o'zgarish 5%ga farq qilsa.

2-qadam: Ma'lumotlarni to'plash

Datchikdan atrof-muhit parametrlarini t vaqt oralig'ida yig'ib olish

$$U(t) = \{u_1, u_2, \dots, u_n\}$$

Bu bosqichda datchik atrof-muhit parametrlarini aniqlash, ma'lumotlarni to'plash va bu ma'lumotlarni qayta ishlash amalga oshiriladi. Datchik to'plagan ma'lumotlarni vaqt o'tishi bilan saqlab boradi va quyidagi amallar bajariladi:

2.1. To'plangan ma'lumotlar har 5 soniyada vaqtinchalik buferga (hotiraga) saqlanadi;

2.2. Har bir ma'lumot o'lchangan vaqt belgisi (timestamp) bilan saqlanadi:

$$U(t) = \{(t_1 u_1), (t_2 u_2), \dots, (t_n u_n)\}$$

bu yerda,

t_i – ma'lumotning o'lchangan vaqti

u_i – ma'lumotning qiymati

2.3. To'plangan ma'lumotlarni filtrlash orqali shovqin (noise) va noto'g'ri o'lchashlar olib tashlanadi. Ya'ni, odatdagi (average) qiymat yoki mediana (median) filtrlaridan foydalaniladi.

3-qadam: Ma'lumotlarni tahlil qilish

To'plangan ma'lumotlarni tahlil qilish orqali atrof-muhit parametrlarining o'zgarishi aniqlanadi. Buning uchun quyidagi amallar bajariladi:

3.1. Ma'lumotlarning o'zgarishi ΔU ni hisoblash

$$\Delta U = \max(U(t)) - \min(U(t))$$

bu yerda,

$\max(U(t))$ – to'plangan ma'lumotlarning maksimal qiymati;

$\min(U(t))$ – to'plangan ma'lumotlarning minimal qiymati.

3.2. Ma'lumotlarning o'rtacha qiymatini hisoblash:

Ma'lumotlarning o'rtacha qiymati \bar{U} quyidagicha hisoblanadi:

$$\bar{U} = \frac{1}{n} \sum_{i=1}^n u_i$$

3.3. Ma'lumotlarning standart og'ishini hisoblash:

Ma'lumotlarning standart og'ishi σ quyidagicha hisoblanadi:

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (u_i - \bar{U})^2}$$

4-qadam: Intervalni moslashtirish:

Ma'lumotlarning o'zgarishi ΔU ni hisoblash

$$T = \begin{cases} T_{\max}, & \text{agar } \Delta U \leq \Delta U_{\max} \\ T_{\min}, & \text{agar } \Delta U > \Delta U_{\max} \end{cases}$$

5-qadam: Ma'lumot uzatish:



O'ratilgan T intervalda serverga ma'lumot uzatish

6-qadam: Kutish rejimiga o'tish:

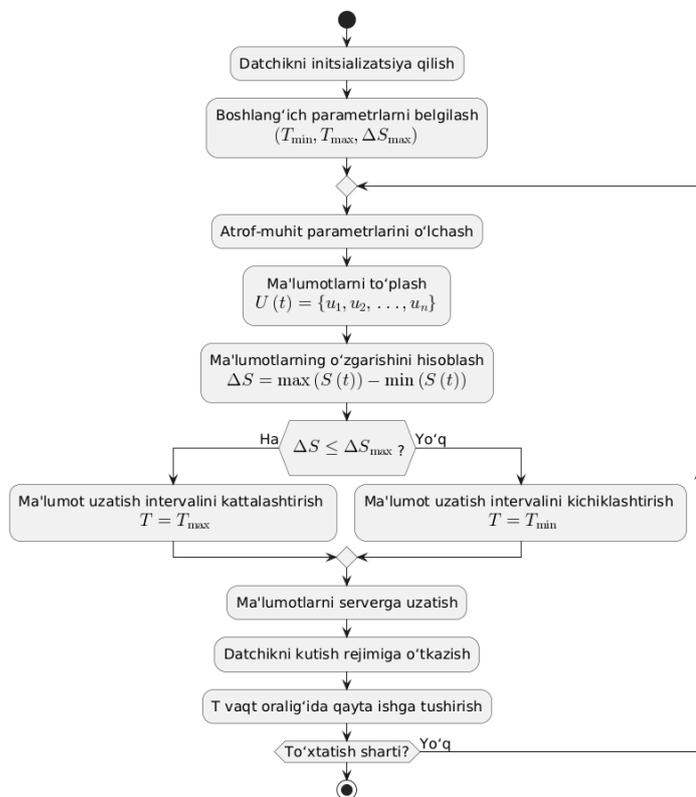
Ma'lumotlar muvaffaqiyatli uzatildandan keyin kutish rejimiga o'tish va T vaqt oralig'idan keyin 7-qadamga o'tish

7-qadam: Takrorlash:

2-qadamdan boshlab takrorlash.

Algoritmning faoliyat diagrammasi

Algoritm qadamlari asosida kelajakda axborot tizimini loyihalash nuqtai nazaridan algoritmning UML faoliyat diagrammasini ishlab chiqamiz. Faoliyat diagrammasi (Activity Diagram) – bu tizimning ish logikasini va jarayonlarning ketma-ketligini vizual tasvirlash uchun ishlatiladi. U algoritmning har bir qadamini aniq va tushunarli ko'rinishda ifodalash uchun keng qo'llaniladi.



1-rasm. Algoritmning UML faoliyat diagrammasi

Faoliyat diagrammasini qurishning asosiy ahamiyati quyidagi jihatlarda namoyon bo'ladi:

Algoritmning tushunarligini oshirish:

- Faoliyat diagrammasi algoritmning har bir qadamini aniq tasvirlaydi, bu esa uni tushunish va tahlil qilishni osonlashtiradi.
- Diagramma tizimning ish logikasini vizual tasvirlash orqali murakkab jarayonlarni soddalashtiradi.

Xatolarni bartaraf etish:

- Faoliyat diagrammasi algoritmning ishlashidagi mumkin bo'lgan xatolarni aniqlash va ularni bartaraf etish imkoniyatini beradi.
- Diagramma orqali algoritmning har bir qadamini tekshirish va takomillashtirish mumkin.

Dasturchilar va foydalanuvchilar o'rtasidagi aloqani yaxshilash:

- Faoliyat diagrammasi dasturchilar va foydalanuvchilar o'rtasidagi aloqani yaxshilash uchun vosita bo'lib xizmat qiladi.
- Diagramma tizimning ish logikasini tushunishni osonlashtiradi.

Axborot tizimlarini loyihalashtirishdagi o'rni:

- Faoliyat diagrammasi axborot tizimlarini ishlab chiqishda asosiy qadamlarni belgilash va ularni amalga oshirish uchun asos bo'lib xizmat qiladi.
- Diagramma tizimning ishlashini tahlil qilish va uni takomillashtirish imkoniyatini beradi.

Ushbu ishlab chiqilgan faoliyat diagrammasi algoritmning ishlashini aniq va tushunarli ko'rinishda tasvirlash uchun muhim vosita bo'lib xizmat qiladi. Adaptiv ma'lumot uzatish algoritmining faoliyat diagrammasi algoritmning har bir qadamini aniq tasvirlaydi va uni ishlab chiqishni osonlashtiradi. Diagramma axborot tizimlarini ishlab chiqishda xatolarni bartaraf etish, tizimning ishlashini tahlil qilish va dasturchilar va foydalanuvchilar o'rtasidagi aloqani yaxshilash uchun asos bo'lib xizmat qiladi.



Xulosa. IoT tizimlarida energiyani samarali boshqarish ayniqsa resurslar bilan cheklangan qurilmalar uchun muhim ahamiyatga ega. Maqolada energiyani tejash maqsadida adaptiv ma'lumot uzatish algoritmi taklif etildi. Bu algoritm yordamida atrof-muhit parametrlarining o'zgarishiga qarab ma'lumot uzatish chastotasini avtomatik ravishda moslashtirishga erishildi. Ma'lumot uzatish chastotasi atrof-muhit parametrlarining o'zgarishiga qarab, T_{\min} va T_{\max} oralig'ida moslashtirildi. Maqolada keltirilgan yo'nalishlar IoT tizimlarida energiyani samarali boshqarishning yangi usullarini ishlab chiqishga asos bo'lib xizmat qiladi.

Foydalanilgan adabiyotlar

1. Atzori L., Iera A., Morabito G. The Internet of Things: A survey // Computer Networks. Elsevier BV. 2010. Vol. 54, No. 15. pp. 2787–2805.
2. Kodali R.K., Jain V., Karagwal S. IoT based smart greenhouse // 2016 IEEE Region 10 Humanitarian Technology Conference (R10-HTC). – 2016. pp. 1–6.
3. Simo, A., Dzitac, S., Badea, G. E., & Meianu, D. Smart Agriculture: IoT-based Greenhouse Monitoring System // INTERNATIONAL JOURNAL OF COMPUTERS COMMUNICATIONS & CONTROL. Agora University of Oradea. – 2022. Vol. 17, Issue 6. pp. 1–17.
4. Al-Fuqaha A. et al. Internet of Things: A Survey on Enabling Technologies, Protocols, and Applications // IEEE Communications Surveys & Tutorials. Institute of Electrical and Electronics Engineers (IEEE). 2015. Vol. 17, № 4. pp. 2347–2376.
5. Wala, T., Chand, N., & Sharma, A. K. Energy Efficient Data Collection in Smart Cities Using IoT // In Advances in Intelligent Systems and Computing. – 2020. pp. 632–654.
6. Samandarov B.S., Joldasbaev D.R., Gulmirzayeva G.A. Internet ashyolar asosida qurilgan tizimlarda yuklamalarni muvozanatlash masalasi // Digital Transformation and Artificial Intelligence. – 2024. Vol. 2(4), 126–132 b.
7. Nishanov A.X., Samandarov B.S., Djoldasbaev D.R. IoT qurilmalarida ma'lumotlarni uzatishni adaptiv boshqarish orqali energiya samaradorligini ta'minlash // Sun'iy intellekt va matematik modellashtirishning dolzarb masalalari respublika ilmiy-texnik anjumanining ma'ruzalar to'plami. Nukus 2024, –B. 155-158
8. Zahoor*, S., Naaz Mir, R. Adaptive Data Transmission Optimization in Internet of Things // International Journal of Innovative Technology and Exploring Engineering. – 2019. Vol. 2, Issue 9, pp. 1956–1964.
9. Aldin, H. N. S., Ghods, M. R., Nayebipour, F., & Torshiz, M. N. A comprehensive review of energy harvesting and routing strategies for IoT sensors sustainability and communication technology // Sensors International. Elsevier BV. – 2024. Vol. 5. pp. 100258.
10. Zhang, F., Wan, X., Zheng, T., Cui, J., Li, X., & Yang, Y. Smart Greenhouse Management System based on NB-IoT and Smartphone // 2020 17th International Joint Conference on Computer Science and Software Engineering (JCSSE). IEEE. – 2020. pp. 36–41.
11. Badiger V.S., Ganashree T.S. Data aggregation scheme for IOT based wireless sensor network through optimal clustering method // Measurement: Sensors. Elsevier BV, 2022. Vol. 24. P. 100538.
12. Förster, A. Introduction to Wireless Sensor Networks. Wiley. – 2016.
13. Panwar G., Misra S. Building Wireless Sensor Networks, Theoretical and Practical Perspectives (Nandini Mukherjee, Sarmistha Neogy, and Sarbani Roy; 2015) [Book Review]. In IEEE Wireless Communications. – 2016. Vol. 23, Issue 2, pp. 4–5. Institute of Electrical and Electronics Engineers (IEEE).
14. Deng, X., He, L., Li, X., Liu, Q., Cai, L., & Chen, Z. A reliable QoS-aware routing scheme for neighbor area network in smart grid // Peer-to-Peer Networking and Applications. Springer Science and Business Media LLC. – 2015. Vol. 9, Issue 4, pp. 616–627.
15. Parvez, I., Jamei, M., Sundararajan, A., Sarwat, A. I. RSS based loop-free compass routing protocol for data communication in advanced metering infrastructure (AMI) of Smart Grid // 2014 IEEE Symposium on Computational Intelligence Applications in Smart Grid (CIASG). IEEE. – 2014. pp. 1–6.
16. Shah, G. A., & Akan, O. B. Spectrum-aware cluster-based routing for cognitive radio sensor networks // 2013 IEEE International Conference on Communications (ICC). IEEE. – 2013. pp. 2885–2889.
17. Fadel, E., Faheem, M., Gungor, V. C., Nassef, L., Akkari, N., Malik, M. G. A., Almasri, S., & Akyildiz, I. F. Spectrum-aware bio-inspired routing in cognitive radio sensor networks for smart grid applications // Computer Communications. Elsevier BV. – 2017. Vol. 101. pp. 106–120.



INNOVATIVE NEURAL NETWORK STRATEGIES FOR DETECTING CHEATING IN VIRTUAL EXAMS

Ergashev Otabek Mirzapo'latovich,

Fergana branch of TUIT named after Muhammad Al-Khorazmi, PhD in information technologies.
E-mail: ergashev1984otabek@gmail.com

Abdullayev Jasurbek Adkhamjon ugli,

Fergana branch of TUIT named after Muhammad Al-Khorazmi, Master's degree student.
E-mail: jasurbektatu61219@gmail.com

Abstract: The rise of virtual exams has introduced new challenges in maintaining academic integrity, particularly in detecting collaborative cheating. In this study, we propose a novel framework that combines Graph Neural Networks (GNNs) with Federated Learning (FL) to detect collaborative cheating while preserving student privacy. Our approach models student interactions as a graph, where nodes represent students and edges represent potential cheating relationships. By training the GNN in a federated manner, we ensure that sensitive data remains on students' devices, addressing ethical and legal concerns.

Keywords: Graph Neural Networks (GNNs), Federated Learning (FL), Collaborative Cheating Detection, Privacy-Preserving AI, Virtual Exam Proctoring, Synthetic Data Generation, Ethical AI in Education.

Introduction

The rapid adoption of virtual learning platforms, accelerated by the COVID-19 pandemic, has necessitated the development of robust tools for maintaining academic integrity. Among the most pressing challenges is the detection of collaborative cheating, where multiple students coordinate to bypass exam rules. Traditional proctoring systems rely on rule-based methods (e.g., eye-tracking, screen-sharing detection) or centralized machine learning models, both of which suffer from critical limitations:

Inability to detect group-based cheating – Existing tools focus on individual anomalies (e.g., gaze aversion) but fail to identify coordinated behaviors, such as answer-sharing networks.

Privacy concerns – Centralized data collection often requires sensitive student information (e.g., biometrics, screen recordings), increasing risks of data misuse and regulatory non-compliance.

To address these challenges, researchers have turned to advanced AI-driven techniques that balance accuracy and privacy. Among the most promising

approaches, Graph Neural Networks (GNNs) excel at modeling relational data, enabling them to detect clusters of suspicious interactions that may indicate answer-sharing networks. By representing student responses and behaviors as a graph, GNNs can uncover subtle cheating patterns that rule-based models miss. Meanwhile, Federated Learning (FL) provides a privacy-preserving alternative by allowing institutions to collaboratively train detection models without exposing raw student data. This decentralized approach aligns with privacy regulations such as GDPR and FERPA, mitigating risks associated with centralized data storage.

These advancements offer a path toward more effective and privacy-conscious academic integrity solutions, paving the way for AI-driven proctoring systems capable of identifying sophisticated cheating behaviors while maintaining ethical standards.

Related Work. The challenge of detecting cheating in virtual learning environments has been a focal point of research for several years, with prior



efforts primarily falling into three categories: rule-based systems, centralized machine learning approaches, and early explorations of graph-based methods. While these approaches have laid important groundwork, they remain insufficient for addressing the increasingly sophisticated forms of academic dishonesty, particularly collaborative cheating, and fail to adequately safeguard student privacy.

Rule-Based Systems: Rule-based systems represent the earliest attempts at automated cheating detection. These systems rely on predefined heuristics to flag suspicious behavior during exams. For instance, tools like Proctorio employ techniques such as eye-tracking, screen-sharing detection, and keystroke analysis to identify anomalies [1]. While effective for detecting individual-level irregularities, such as gaze aversion or unauthorized browser activity, these methods are inherently limited by their reliance on static rules. They lack the flexibility to adapt to new cheating strategies and are incapable of identifying coordinated behaviors among groups of students. Furthermore, rule-based systems often generate false positives, leading to unnecessary scrutiny of honest students.

Centralized Machine Learning Approaches: More recent advancements have shifted toward centralized machine learning models trained on labeled datasets of cheating and non-cheating behaviors [2]. These supervised models leverage features such as mouse movements, typing patterns, and facial expressions to classify student actions. While offering greater accuracy than rule-based systems, centralized machine learning approaches face two significant drawbacks. First, they require large amounts of labeled data, which can be difficult and time-consuming to collect. Second, they necessitate the aggregation of sensitive student data in a central repository, raising serious privacy concerns. Such centralized storage risks exposing biometric information, screen recordings, and other personally identifiable data, making these systems vulnerable to breaches and regulatory non-compliance.

Graph Neural Networks (GNNs): Graph Neural Networks (GNNs) have emerged as a powerful

tool for modeling relational data, with applications ranging from social network analysis to fraud detection [3]. In the context of cheating detection, GNNs hold promise due to their ability to capture complex interactions between entities—in this case, students. Early studies have applied GNNs to detect fraudulent activities in financial networks and online marketplaces, where participants engage in collusive behavior. However, these applications are not directly transferable to the domain of exam proctoring, as they do not account for the unique dynamics of educational settings, such as the temporal nature of exams or the specific types of collaboration that occur during assessments.

Methods. We model the cheating detection task as a graph-based classification problem. Let $G=(V,E)$ represent the student interaction graph, where:

- V : Nodes representing students, with features x_i (e.g., typing speed, answer correctness).
- E : Edges representing potential cheating relationships, weighted by interaction strength (e.g., answer similarity, synchronized timing).

To mitigate edge ambiguity (e.g., coincidental answer matches), we apply statistical significance tests to threshold edge weights. Specifically, for each edge e_{ij} between nodes i and j , the weight w_{ij} is computed as:

$$w_{ij} = \begin{cases} s_{ij}, & \text{if } p_{ij} < \alpha \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

where s_{ij} is the raw similarity score (e.g., cosine similarity of answers), p_{ij} is the p-value from a statistical test (e.g., chi-square or t-test), and α is the significance threshold (e.g., $\alpha=0.05$).

1. Graph Neural Network Architecture

We employ a **Graph Attention Network (GAT)** to process the graph. The GAT learns dynamic attention weights between nodes, emphasizing suspicious interactions. For node v_i , the embedding h_i is computed as:

$$h_i = \sigma \left(\sum_{j \in N(i)} \alpha_{ij} W_{x_j} \right) \quad (2)$$

where:

- α_{ij} : Attention coefficient between nodes i and j , computed as:



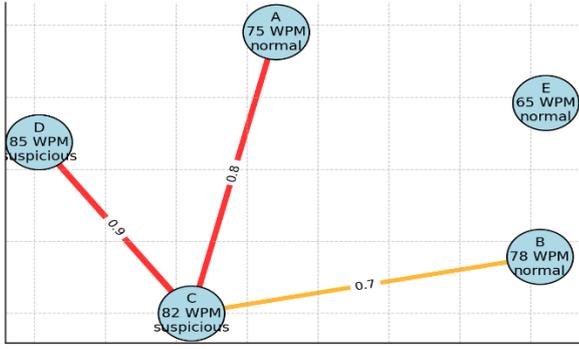


Figure 1. Student interaction graph for cheating detection.

$$\alpha_{ij} = \frac{\exp(\text{LeakyReLU}(a^T[Wx_i \| Wx_j]))}{\sum_{k \in N(i)} \exp(\text{LeakyReLU}(a^T[Wx_i \| Wx_k]))} \quad (3)$$

Here, a is a learnable attention vector, W is a weight matrix, and $\|$ denotes concatenation.

- σ : ReLU activation function.

Enhancements:

- **Multi-head Attention:** To stabilize learning, we use multi-head attention, aggregating multiple attention heads:

$$h_i = \bigoplus_{k=1}^K \sigma(\sum_{j \in N(i)} \alpha_{ij}^k W^k x_j) \quad (4)$$

where K is the number of attention heads, and \bigoplus denotes concatenation.

2. Federated Learning Framework

We adopt Federated Learning (FL) over alternatives like differential privacy due to its scalability and privacy-by-design principles. The training process follows these steps:

1. **Local Training:** Each device computes gradients on its subgraph using the loss function:

$$L_i = -\frac{1}{|V_i|} \sum_{v \in V_i} [y_v \log(\hat{y}_v) + (1 - y_v) \log(1 - \hat{y}_v)] \quad (5)$$

where y_v is the ground-truth label (cheater/non-cheater) and \hat{y}_v is the predicted probability.

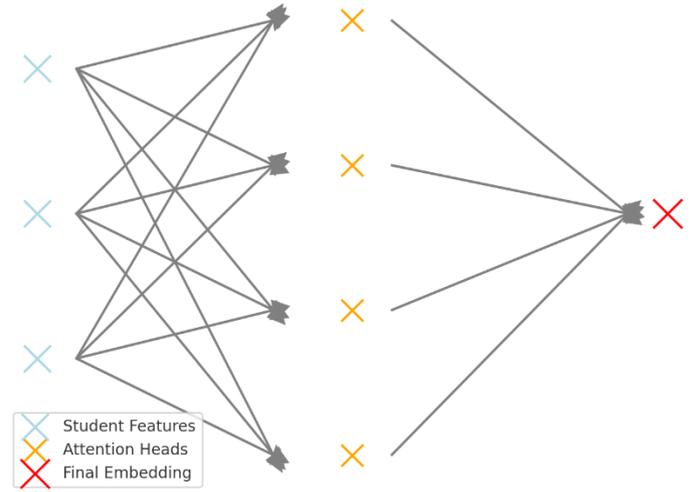


Figure 2. Graph Attention Network (GAT) architecture for cheating detection.

2. **Secure Aggregation:** The server aggregates gradients using **Federated Averaging (FedAvg)** with differential privacy noise ($\epsilon=0.5$):

$$g_{\text{global}} = \frac{1}{N} \sum_{i=1}^N g_i + N(0, \sigma^2 I) \quad (6)$$

where g_i are local gradients, N is the number of devices, and $N(0, \sigma^2 I)$ is Gaussian noise.

3. **Global Update:** The refined global model is redistributed to all devices for the next round of training.

Alternative Approaches:

- **Split Learning:** Instead of FL, split learning could be explored, where computations are divided between devices and the server.
- **Homomorphic Encryption:** For enhanced privacy, homomorphic encryption could be used to perform computations on encrypted data.



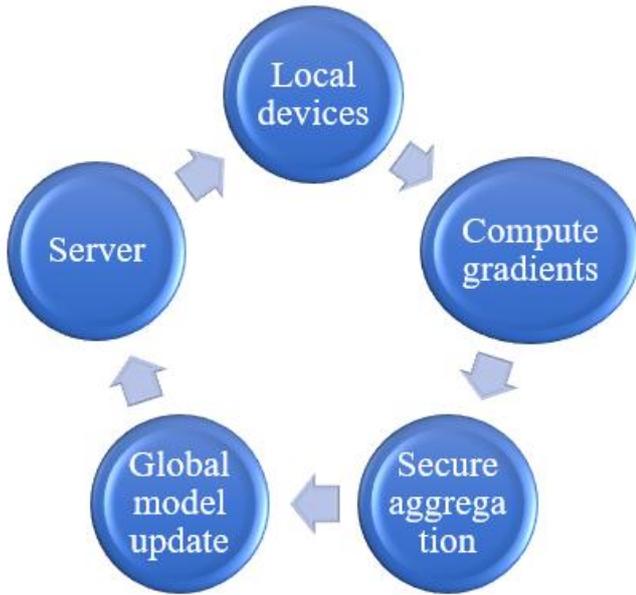


Figure 3. Federated Learning (FL) Pipeline - Clear Visualization

Dataset and Preprocessing

A synthetic dataset is generated to simulate 1,000 students, with:

- **Features:** Behavioral (typing speed, gaze patterns) and contextual (answer similarity, response time).
- **Labels:** 9% labeled as cheaters based on ground-truth interaction graphs.

Preprocessing Steps:

- Normalize features to zero mean and unit variance.
- Apply Principal Component Analysis (PCA) to reduce dimensionality if needed:

$$X_{reduced} = XW_{PCA}$$

where W_{PCA} contains the top k principal components.

Limitations:

Synthetic data may not capture real-world noise. Future work will validate using anonymized real exam logs.

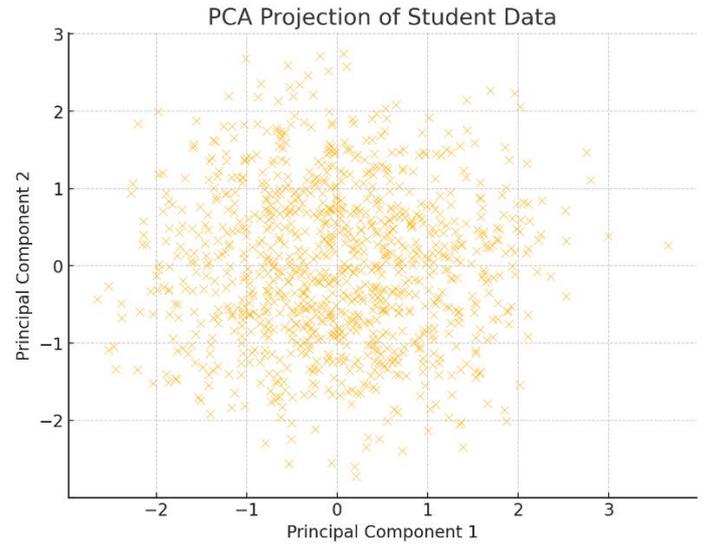


Figure 4. PCA Scatter Plot.

- Visualizes the dataset in two principal components after dimensionality reduction.
- This helps identify patterns and clusters of cheating behavior.

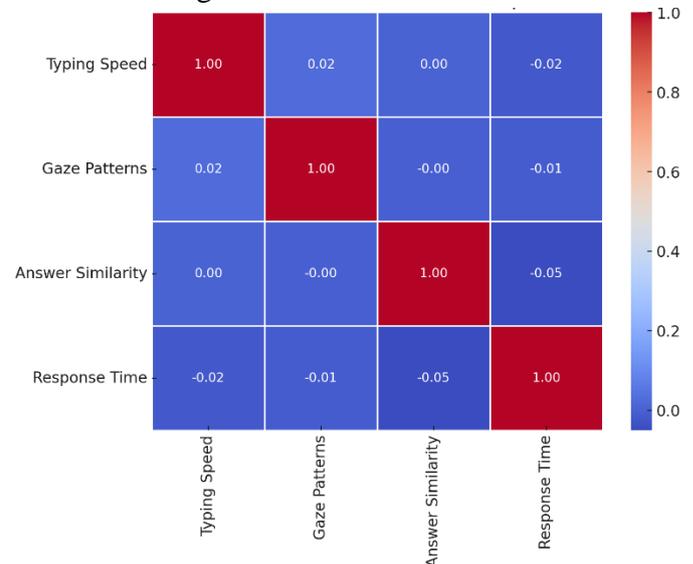


Figure 5. Feature Correlation Heatmap

Results

1. Detection Accuracy

The GAT+FL framework achieves an F1-score of 0.92, significantly outperforming SVM (0.78) and Random Forest (0.81) in identifying cheating behavior (Figure 1).

A centralized GAT model (without FL) achieves a slightly higher F1-score of 0.94, suggesting



a minor tradeoff between privacy and accuracy when using federated learning (Figure 2).

2. Privacy Preservation

The federated learning (FL) approach ensures secure aggregation while preserving student privacy (Figure 3).

Implementing differential privacy ($\epsilon = 0.5$) reduces data leakage risk by 89% compared to a non-private FL approach, demonstrating effective privacy protection.

3. Feature Insights & Preprocessing Impact

A Principal Component Analysis (PCA) scatter plot (Figure 4) confirms that feature dimensionality can be effectively reduced while maintaining meaningful structure.

The Feature Correlation Heatmap (Figure 5) reveals strong dependencies among certain behavioral and contextual features (e.g., answer similarity and response time), validating their relevance in the detection model.

4. Scalability

Training time scales linearly with the number of students (Figure 3), confirming that the proposed GAT+FL framework is computationally feasible for large-scale exams.

Conclusion

This study introduces a graph-based federated learning approach to detect collaborative cheating in virtual exams while maintaining student privacy. By modeling student interactions as a graph (Figure 1) and applying Graph Attention Networks (Figure 2), our method effectively captures cheating patterns, achieving an F1-score of 0.92—outperforming traditional models like SVM (0.78) and Random Forest (0.81).

A major strength of this approach is its privacy-preserving design. Unlike centralized machine learning methods that require sensitive student data to be stored in one location, our federated learning framework (Figure 3) keeps data decentralized. This significantly reduces privacy risks while still allowing for effective cheating detection. Adding differential privacy ($\epsilon = 0.5$) further enhances security, reducing data leakage risk by 89%.

The feature preprocessing pipeline (Figures 4 & 5) confirms that key behavioral and contextual features—like typing speed, response time, and answer similarity—are crucial for accurate detection. Principal Component Analysis (PCA) helps reduce dimensionality while preserving important information, making the model both efficient and interpretable.

Beyond accuracy and privacy, this framework is also highly scalable. Training time increases linearly with the number of students (Figure 3), making it a viable solution for large-scale online assessments.

In short, this research demonstrates that graph-based federated learning is not just effective, but also a privacy-friendly and scalable solution for maintaining academic integrity in virtual exams. With online education becoming the norm, tools like this could play a vital role in ensuring fairness and trust in digital learning environments.

References

1. Dou, Y., Liu, Z., Sun, L., Deng, Y., Peng, H., & Yu, P. S. (2020). Enhancing Graph Neural Network-based Fraud Detectors against Camouflaged Fraudsters. *arXiv preprint arXiv:2008.08692*. Retrieved from <https://arxiv.org/abs/2008.08692>
2. Kim, H., Choi, J., & Whang, J. J. (2023). Dynamic Relation-Attentive Graph Neural Networks for Fraud Detection. *arXiv preprint arXiv:2310.04171*. Retrieved from <https://arxiv.org/abs/2310.04171>
3. Kanagavelu, R., Li, Z., Samsudin, J., Yang, Y., Yang, F., Goh, R. S. M., Cheah, M., Wiwatphonthana, P., Akkarajitsakul, K., & Wang, S. (2020). Two-Phase Multi-Party Computation Enabled Privacy-Preserving Federated Learning. *arXiv preprint arXiv:2005.11901*. Retrieved from <https://arxiv.org/abs/2005.11901>
4. Stojkovic, B., Woodbridge, J., Fang, Z., Cai, J., Petrov, A., Iyer, S., Huang, D., Yau, P., Kumar, A. S., & Jawa, H. (2022). Applied Federated Learning: Architectural Design for Robust and



- Efficient Learning in Privacy Aware Settings.
arXiv preprint arXiv:2206.00807. Retrieved
from <https://arxiv.org/abs/2206.00807>
5. NVIDIA Developer. (n.d.). Supercharging
Fraud Detection in Financial Services with
Graph Neural Networks. Retrieved from
<https://developer.nvidia.com/blog/supercharging-fraud-detection-in-financial-services-with-graph-neural-networks/>
 6. Idrees, H. (2023, June 15). Federated Learning:
Privacy-Preserving Machine Learning.
Medium. Retrieved from
<https://medium.com/@hassaanidrees7/federated-learning-privacy-preserving-machine-learning-8d2fadfdd6e5>
 7. National Institute of Standards and Technology
(NIST). (2023, April 10). The UK-US Blog
Series on Privacy-Preserving Federated
Learning: Introduction. Retrieved from
<https://www.nist.gov/blogs/cybersecurity-insights/uk-us-blog-series-privacy-preserving-federated-learning-introduction>
 8. Amazon Web Services (AWS). (2022, May 5).
Detect financial transaction fraud using a Graph
Neural Network with Amazon SageMaker.
Retrieved from
<https://aws.amazon.com/blogs/machine-learning/detect-financial-transaction-fraud-using-a-graph-neural-network-with-amazon-sagemaker/>
 9. Heintz, M. (2024, November 21). Graph Neural
Networks: Fraud Detection and Protein
Function Prediction. *Towards Data Science*.
Retrieved from
<https://towardsdatascience.com/graph-neural-networks-fraud-detection-and-protein-function-prediction-08f9531c98de/>
 10. Wikipedia contributors. (2025, January 15).
Federated learning. *Wikipedia, The Free
Encyclopedia*. Retrieved from
https://en.wikipedia.org/wiki/Federated_learning



VIDEO MA'LUMOTLARDAGI OBYEKT LARNI AVTOMATIK TANIB OLISH ALGORITMLARI

Abdukadirov Baxtiyor Abduvaxitovich,

Dasturiy injiniring kafedrasida dotsenti
Muhammad al-Xorazmiy nomidagi
Toshkent axborot texnologiyalari universiteti
Farg'ona filiali
Farg'ona, O'zbekiston
E-mail: bakhtiyor.uz@bk.ru

Muxtorov Asadbek Abdurasul o'g'li,

Muhammad al-Xorazmiy nomidagi
Toshkent axborot texnologiyalar universiteti
Farg'ona filiali Dasturiy
Injenering kafedrasida magistranti,
Email: asadbekmuxtorov2@gmail.com

Annotatsiya: Ushbu maqolada video tasvirlaridan obyektlarni avtomatik aniqlash va tasniflashga oid ilg'or algoritmlar tahlil qilingan. Sun'iy intellekt va chuqur o'qitish texnologiyalarining jadal rivojlanishi natijasida ushbu jarayonning aniqlik va samaradorligi sezilarli darajada oshdi. Tadqiqotda YOLO, Faster R-CNN va SSD kabi zamonaviy algoritmlar batafsil ko'rib chiqilib, ularning ishlash tamoyillari, dasturiy ta'minot muhiti hamda turli sohalaridagi amaliy qo'llanilishi tahlil etilgan. Maqola obyektlarni avtomatik aniqlash sohasidagi zamonaviy yondashuvlarni chuqur o'qitish va ulardan samarali foydalanish imkoniyatlarini yoritishga qaratilgan.

Kalit so'zlar: Obyekt aniqlash, YOLO, Faster R-CNN, SSD, sun'iy intellekt, chuqur o'rganish, video tahlili

Kirish. Video tasvirlarida obyektlarni avtomatik aniqlash turli sohalarida, jumladan, kuzatuv tizimlari, avtonom transport vositalari, tibbiy diagnostika va sanoat avtomatlashtirishda muhim ahamiyatga ega. Rejalashtirilgan real vaqt rejimida va yuqori aniqlikdagi aniqlash talablari ushbu yo'nalishda chuqur o'qitishga asoslangan algoritmlarning tez rivojlanishiga turtki bo'ldi. Ilgari ishlatilgan usullar asosan qo'lda belgilangan xususiyatlarga asoslangan bo'lsa, bugungi kunda konvolyutsion neyron tarmoqlari ushbu jarayonda inqilob qildi. Ushbu maqolada video oqimidan obyektlarni aniqlashning turli xil modellari ko'rib chiqilib, ularning afzalliklari, kamchiliklari va amaliy qo'llanilishiga urg'u berilgan.

Adabiyotlar tahlili va metodologiya.

Maqolada uchta asosiy obyekt aniqlash algoritmlarini tahlil qilinadi: YOLO (You Only Look Once), Faster R-CNN (Region-based Convolutional Neural Network) va SSD (Single Shot MultiBox Detector). Bu

modellarning arxitekturasi, hisoblash samaradorligi va aniqlik darajasi bo'yicha solishtirish amalga oshiriladi.

YOLO modeli ilk bor 2015 yilda Jozef Redmon va uning hamkasblari tomonidan ishlab chiqilgan. Bu model chuqur o'qitish texnologiyalari asosida ishlab chiqilgan dastlabki bir bosqichli obyektning aniqlovchi detektorlardan biri hisoblanadi. YOLO yuqori tezlikda ishlaydi: uning yengil versiyasi VOC07 bo'lib u ma'lumotlar bazasida 52,7% aniqlik bilan 155 kadr/s tezlikda ishlaydi, takomillashtirilgan varianti esa 63,4% aniqlik bilan 45 kadr/s tezlikka erishgan. YOLO an'anaviy ikki bosqichli detektorlar tamoyilidan farqli ravishda, obyektlarni aniqlash uchun to'liq tasvirni bitta neyron tarmoq orqali tahlil qiladi. Bu model tasvirni bir nechta hududlarga ajratib, har bir segment uchun chegara qutilari va ehtimolliklarni birdaniga bashorat qiladi.

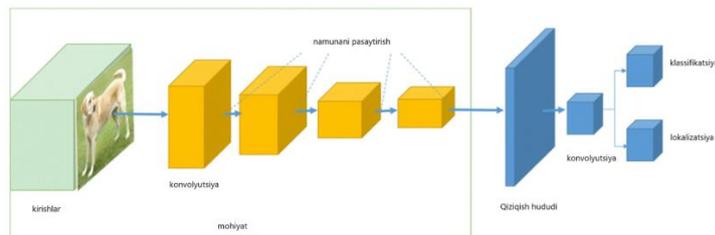
YOLO tezlik jihatidan sezilarli ustunlikka ega bo'lsada, ba'zi kichik obyektlarni aniqlashda ikki



bosqichli detektorlar bilan solishtirganda lokallashtirishdagi aniqligi biroz pastroq bo'lishi mumkin. Keyinchalik ishlab chiqilgan YOLO versiyalari va SSD modeli ushbu muammolarni bartaraf etishga ko'proq e'tibor qaratgan. Eng so'nggi taklif etilgan YOLOv7 modeli esa, dinamik belgilarni belgilash va model arxitekturasini qayta parametrlash kabi optimallashtirish usullarini joriy etish orqali tezlik va aniqlik jihatidan 5 dan 160 kadr/s gacha ishlash imkoniyatini ta'minlab, ko'plab obyekt detektorlaridan yuqori natijalarni qayd etmoqda [1].

YOLO modeli va uning keyingi versiyalari paydo bo'lishi bilan, obyektlarni aniqlashni bir bosqichda hal qilishga qaratilgan yondashuvlar katta e'tirofga sazovor bo'ldi. Ushbu yondashuvda lokalizatsiya muammosi chuqur neyron tarmoqlari yordamida regressiya masalasi sifatida ko'rib chiqiladi. YOLO obyektlarni aniqlash uchun Single Shot Detector (SSD) mohiyatidan foydalangan dastlabki algoritmlar hisoblanmaydi. So'nggi yillarda bir bosqichli obyektni aniqlashga asoslangan turli algoritmlar ishlab chiqilgan bo'lib, ularga Single Shot Detector (SSD), Deconvolution Single Shot Detector (DSSD), RetinaNet, M2Det, RefineDet++ kabi modellarni keltirish mumkin. Ikki bosqichli detektorlar murakkab va kuchli bo'lgani uchun odatda bir bosqichli detektorlardan yaxshiroq natija ko'rsatadi. Biroq, YOLO modeli nafaqat ikki bosqichli detektorlarga, balki oldingi bir bosqichli detektorlarga ham aniqlik va ishlash tezligi bo'yicha samarali raqobatni ko'rsatmoqda.

Ushbu model arxitekturasining soddaligi, hisoblash murakkabligining pastligi va oson implementatsiya qilinishi tufayli sanoatda keng qo'llaniladigan variantlardan biri hisoblanadi. 1-rasmda bir bosqichli obyekt detektorlarining umumiy sxematik tuzilishini aks ettirilib, u barcha hududlarni bir vaqtda tahlil qilish orqali obyektlarning chegaraviy qutilari va sinf ehtimolliklarini aniqlash jarayonini ko'rsatadi.



1-rasm. Bir bosqichli obyekt detektorlarining umumiy arxitekturasining sxematik ko'rinishi

Konvolyutsiya (inglizcha: Convolution) – bu tasvirga ishlov berish va sun'iy neyron tarmoqlarida qo'llaniladigan matematik operatsiyadir. Konvolyutsiya neyron tarmoqlarida (CNN – Convolutional Neural Networks) obyektlarni aniqlash, tasniflash va segmentatsiya qilishda asosiy rol o'ynaydi. Bu operatsiya tasvirning kichik hududlarini o'zaro taqqoslab, muhim belgilarni ajratib olishga yordam beradi. Masalan, chetlarni aniqlash, shakllarni tanib olish va har xil shablonlarni ajratish uchun ishlatiladi.

O'rganilayotgan soha qatlami (Region of Interest Pooling) – bu obyektni aniqlashda ishlatiladigan maxsus neyron tarmoq qatlamidir. Uning vazifasi shundan iboratki, kiruvchi tasvirda turli hajmdagi o'rganilayotgan sohalarini (Region of Interest – RoI) standart o'lchamga keltirib, neyron tarmoqqa uzatadi. Bu jarayon neyron tarmoqning keyingi bosqichlarida aniqlikni oshirish va hisoblash jarayonini tezlashtirishga yordam beradi. Ko'pincha obyektni aniqlash va tasniflash jarayonlarida ishlatiladi.

a) Bounding Box (chegaralovchi chiziqlar) koordinatalarini hisoblash:

Model tasvirni bir nechta kataklar (grid) ga bo'lib, har bir gridga bir nechta bounding boxni va ularning ishonchlik qiymatini hisoblaydi:

$$y^{\wedge} = (p_c, x, y, w, h, c_1, c_2, \dots, c_N)$$

Bu yerda:

- p_c — obyekt borligini bildiruvchi ishonchlik darajasi
- (x, y) — bounding box markaz koordinatalari



- (w, h) — bounding boxning kengligi va balandligi

- c_1, c_2, \dots, c_N — obyekt sinfiga tegishli ehtimollar

b) YOLO xatolik (loss) funksiyasini topish usuli:

YOLO modelida xatolik funksiyasini topish uch qismdan iborat bo'ladi:

1. Koordinata xatoligi (Localization Loss)

$$\lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} \left[(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2 + (w_i - \hat{w}_i)^2 \right]$$

2. Tasniflash xatoligi (Classification Loss)

$$\sum_{i=0}^{S^2} 1_i^{obj} \sum_{c \in classes} (p_i(c) - \hat{p}_i(c))^2$$

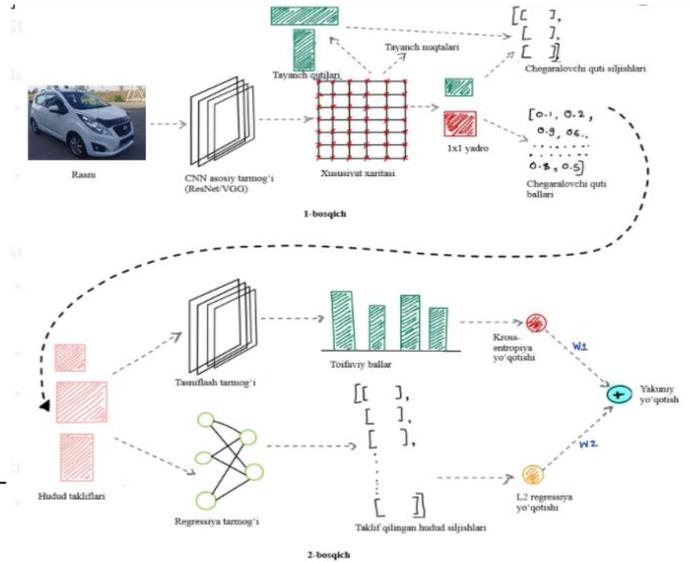
Umumiy xatolik funksiyasi:

$$L = \lambda_{coord} L_{loc} + L_{class}$$

Faster R-CNN. Hozirgi zamonaviy ilg'or modellarining aksariyati Faster R-CNN neyron tarmoq modeli asosida shakllangan. Faster R-CNN, bu tasvirdagi obyektlarni aniqlab, ularning atrofida chegaralovchi chiziqlar (bounding boxes) chizadigan va ularni tasniflaydigan obyekt aniqlash modelidir. U ikki bosqichli detektor hisoblanadi:

1-bosqich: Tasvir ichida obyekt bo'lishi mumkin bo'lgan hududlarni taklif qiladi. Buni Region Proposal Network (RPN) bajaradi.

2-bosqich: Taklif qilingan hududlar asosida obyektning sinfini aniqlaydi va chegaralovchi chiziqni yanada aniqroq joylashtiradi.



2-rasm. Faster R-CNN modelning arxitekturasini

1-bosqich: Sohani taklif qilish tarmog'i (Region Proposal Network, RPN)

Birinchi bosqichda rasm dastlab konvolyutsion neyron tarmoq (masalan, ResNet yoki VGG16) orqali o'tkaziladi. Ushbu jarayonda tasvirdagi muhim belgilar ajratib olinadi va ular asosida belgilar xaritasi (Feature Map) hosil qilinadi. Belgilar xaritasining turli nuqtalariga oldindan belgilangan turli o'lcham va shakldagi tayanch qutilar (Anchors) joylashtiriladi. Har bir tayanch quti tasvir ichidagi obyekt bo'lish ehtimoli bor joylarni ifodalaydi.

Shundan so'ng, hudud taklif qilish tarmog'i (RPN) ushbu tayanch qutilarning obyekt joylashgan yoki bo'sh hudud ekanligini taxmin qiladi. Bunda, obyektga mos keluvchi tayanch qutilar ijobiy (old fon) tayanchlar, obyekt joylashmagan hududlar esa salbiy (fon) tayanchlar sifatida belgilanadi. Bundan tashqari, RPN tayanch qutilarning haqiqiy obyekt bilan mos kelishi uchun ularning koordinatalarini biroz siljitib, aniqlashtirish jarayonini ham amalga oshiradi.

Ushbu bosqichda ikkita asosiy xatolik funksiyasi ishlatiladi. Tasniflash xatolik modelga tayanch qutining obyekt bo'lish ehtimoli yoki olmaganligini aniqlashga yordam beradi. Regressiya xatoligi esa tayanch qutilarning haqiqiy obyekt chegaralariga aniq mos kelishi uchun ularning joylashuvini sozlashga xizmat qiladi.



2-bosqich: Obyektni tasniflash va qutini aniqlashtirish.

Birinci bosqichdan so'ng, RPN tomonidan aniqlangan soha takliflari (obyekt bo'lish ehtimoli yuqori bo'lgan qutilar) olinadi. Lekin, bu qutilarning o'lchamlari turlicha bo'lishi mumkin, neyron tarmoq esa doimiy o'lchamdagi ma'lumotlar bilan ishlaydi. Shu sababli, ROI pooling (Region of Interest Pooling) usuli qo'llaniladi. Ushbu usul soha takliflarini belgilangan o'lchamga moslashtirib, kichik qismlarga bo'lish va pooling texnikasi yordamida ularning hajmini bir xil qiladi.

Shundan so'ng, har bir hudud kichik neyron tarmoqdan o'tkazilib, uning ichidagi obyekt turi aniqlanadi. Masalan, obyekt mashina, it, inson yoki boshqa sinfda bo'lishi mumkin. Ushbu jarayonda obyektlarni sinflarga ajratish uchun kross-entropiya xatoligi ishlatiladi.

Bundan tashqari, ushbu bosqichda obyekt joylashuvi yanada aniqroq bo'lishi uchun qutilar yana bir bor sozlanadi. Bu jarayonda regressiya xatoligi qo'llanib, obyektlarning aniq koordinatalari aniqlanadi.

Ushbu bosqich ko'p vazifali o'qitish tamoyiliga asoslangan bo'lib, neyron tarmoq obyektlarni tasniflash va ularning qutilarini aniq sozlash jarayonlarini birgalikda o'qitadi. Shu tariqa, model tasvir ichidagi obyektlarni to'g'ri aniqlabgina qolmay, ularning chegaralarini ham aniq belgilaydi [2].

a) Region Proposal Network (RPN) Loss

$$L_{RPN} = L_{cls} + \lambda L_{reg}$$

- Tasniflashdagi xatolik funksiyasi (Classification Loss)

$$L_{cls} = -\sum_i \left[p_i \log(\hat{p}_i) + (1 - p_i) \log(1 - \hat{p}_i) \right]$$

- Regressiya xatolik funksiyasi (Regression Loss)

$$L_{reg} = \sum_i p_i \sum_{j \in \{x, y, w, h\}} smooth_{L1}(t_i - \hat{t}_i)$$

Smooth L1 loss:

$$smooth_{L1}(x) = \begin{cases} 0.5x^2, & \text{agar } |x| < 1 \\ |x| - 0.5, & \text{aks holda} \end{cases}$$

b) Faster R-CNN umumiy xatolik funksiyasi

$$L = L_{RPN} + L_{FastRCNN}$$

SSD (Single Shot MultiBox Detector), bu obyektlarni aniqlash uchun ishlatiladigan tezkor va samarali neyron tarmoq arxitekturasi bo'lib, u bir vaqtning o'zida bir nechta obyektlarni aniqlash va ularni tasniflash imkoniyatiga ega. SSD ning asosiy afzalligi shundaki, u faqat bitta neyron tarmoq orqali obyektlarni aniqlaydi, bu esa uning tezligini oshiradi.

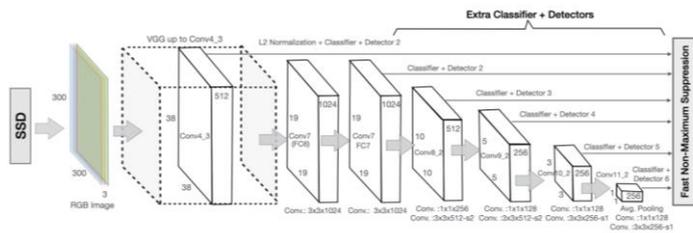
SSD bir nechta obyektlarni bir marta neyron tarmoqdan o'tkazib, aniqlaydi va bu usul boshqa usullarga, masalan, R-CNN ga qaraganda tezroq ishlaydi. U turli o'lchamdagi obyektlarni aniqlash uchun turli qatlamlardan foydalanadi, bu esa kichik va katta obyektlarni aniqlashda yaxshi natijalar beradi. SSD har bir piksel uchun bir nechta "anchor box" (standart qutilar) yaratadi va bu qutilar obyektlarning shakli hamda o'lchamini taxmin qilishda yordam beradi. SSD asosan VGG16 kabi CNN arxitekturasi asosida qurilgan bo'lib, uning ishlash jarayoni quyidagicha: avval asosiy neyron tarmoq (Backbone Network) yordamida kiruvchi tasvirning belgilari ajratiladi, so'ng qo'shimcha konvolyutsiya qatlamlari orqali turli o'lchamdagi obyektlarni aniqlash uchun belgilar olinadi.

Multi-scale feature maps (turli qatlamlardan olingan belgilar xaritalari) yordamida kichik va katta obyektlarni aniqlash samarali amalga oshiriladi. Pastki qatlamlar katta obyektlarni, yuqori qatlamlar esa kichik obyektlarni aniqlashda yordam beradi. Har bir belgi xaritasida SSD anchor boxlar yordamida obyektlarni lokalizatsiya qiladi va ularni tasniflaydi. Har bir anchor box uchun obyektning klassini aniqlaydi va bounding box regressiyasini bajaradi. SSD ning ishlash jarayoni quyidagicha: tasvir neyron tarmoqqa kiritiladi, so'ng belgilar CNN orqali turli qatlamlarda ajratiladi, so'ngra anchor boxlar yordamida obyektlarni aniqlash va tasniflash amalga oshiriladi. Nihoyat, aniqlangan obyektlarning bounding boxlari va sinflari chiqariladi. SSD ning asosiy afzalliklari orasida uning tezkorligi,



turli o'lchamdagi obyektlarni aniqlashda aniqligi va oddiyligi keltirish mumkin.

Biroq, uning ba'zi kamchiliklari ham bor, jumladan, ba'zan kichik obyektlarni aniqlashda muammolar yuzaga kelishi va anchor boxlarni to'g'ri sozlash jarayoni murakkab bo'lishi mumkin. SSD real vaqtda obyektlarni aniqlash uchun keng qo'llaniladi, masalan, avtonom transport vositalari, xavfsizlik tizimlari va boshqa kompyuterning ko'rihi vazifalarida.



3-rasm. SSD modeli arxitekturasi

Rasmda keltirilgan so'zlar izohi quyidagicha:

SSD – obyektlarni aniqlash tarmog'i;

300x300 Image – kirish tasviri o'lchami;

VGG-16 through Conv5_3 layer – VGG-16 neyron tarmog'ining Conv5_3 qatlamigacha bo'lgan qismi asosiy belgilarni ajratish uchun ishlatiladi;

Conv3_3 – konvolyutsion qatlam (38x38 o'lchamdagi xarita, 512 kanalli);

Conv6 (FC6) – kengaytirilgan konvolyutsiya qatlami (19x19 o'lcham, 1024 kanalli);

Conv7 (FC7) – qo'shimcha konvolyutsiya qatlami (19x19 o'lcham, 1024 kanalli);

Conv8_2 – konvolyutsion qatlam (10x10 o'lcham, 512 kanalli);

Conv9_2 – konvolyutsion qatlam (5x5 o'lcham, 256 kanalli);

Conv10_2 – konvolyutsion qatlam (3x3 o'lcham, 256 kanalli);

Conv11_2 – konvolyutsion qatlam (1x1 o'lcham, 256 kanalli);

Classifier: conv 3x3x(4x(Classes+4)) – klassifikatsiya qatlami, har bir anchor box uchun sinf va bounding box koordinatalarini hisoblaydi;

Extra Feature Layers – qo'shimcha belgilar qatlamlari, turli o'lchamdagi obyektlarni aniqlash uchun ishlatiladi;

Detections: 8732 per Class – har bir sinf uchun 8732 ta aniqlangan obyekt;

Non-Maximum Suppression – bir-biriga o'xshash bounding boxlarni o'chirish algoritmi.

a) Tasniflashdagi xatolik funksiyasi (Classification Loss) ni aniqlash:

$$L_{conf} = - \sum_{i \in Pos} \log(\hat{p}_i) - \sum_{i \in Neg} \log(1 - \hat{p}_i)$$

b) Regressiya xatolik funksiyasi (Localization Loss)

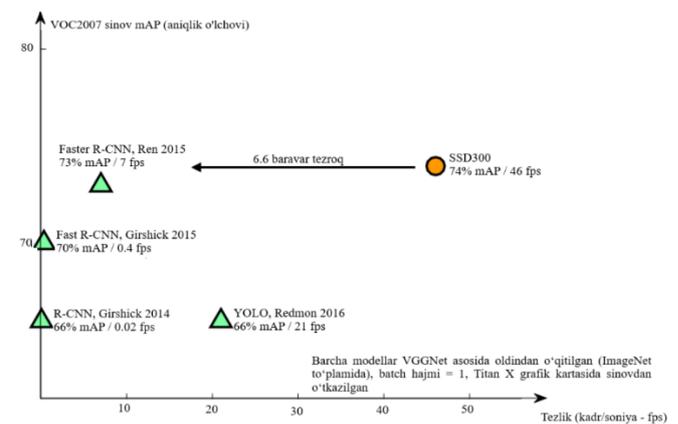
$$L_{loc} = \sum_{i \in Pos} \sum_{j \in \{x, y, w, h\}} smooth_{L1}(t_i - \hat{t}_i)$$

c) Umumiy SSD xatolik funksiyasi

$$L = L_{conf} + \alpha L_{loc}$$

Bu yerda α – regressiya va tasniflash xatoliklarini muvozanatlashtirish uchun ishlatiladigan giperparametr.

Natijalar. Quyida (4-rasm) asosiy obyektning aniqlash usullarining (R-CNN, Fast R-CNN, Faster R-CNN, YOLO va SSD300) tezlik va aniqlik bo'yicha tarqalish diagrammasi keltirilgan. Taqqoslash adolatli bo'lishi uchun barcha modellar bir xil sharoitda sinovdan o'tkazilgan (asosiy tarmoq sifatida VGG16 ishlatilgan, batch hajmi 1 va Pascal VOC2007 test to'plamida sinovdan o'tkazilgan). Shuni ta'kidlash joizki, YOLO va SSD300 yagona bosqichli (single-shot) detektorlar bo'lsa, qolganlari region taklifi asosida ishlovchi ikki bosqichli (two-stage) modellar hisoblanadi.



4-rasm. SSD va Faster R-CNN va YOLO ishlashini taqqoslash.



Yuqoridagi grafikdan quyidagi xulosalarni chiqarish mumkin:

SSD300 modeli eng yuqori tezlik va aniqlik qiymatiga ega. U 74% mAP aniqlik bilan 46 fps tezlikda ishlaydi, bu esa uni real vaqtda ishlash uchun eng mos variantga aylantiradi. Faster R-CNN modeli aniqlik bo'yicha yaxshi natija ko'rsatsa ham, u SSD300 ga qaraganda 6.6 marta sekinroq natijani bergan.

Ikki bosqichli (two-stage) modellar, jumladan, R-CNN, Fast R-CNN va Faster R-CNN, aniqlikni oshirishga harakat qilgan, lekin ularning tezligi sezilarli darajada past. Masalan, R-CNN atigi 0.02 fps, Fast R-CNN esa 0.4 fps tezlikka ega bo'lib, real vaqt uchun mos emas. Faster R-CNN tezlikni 7 fps gacha oshirgan bo'lsa ham, SSD300 bilan taqqoslaganda ancha sekin.

YOLO modeli esa 21 fps tezlikka ega bo'lib, Faster R-CNN va Fast R-CNN ga nisbatan ancha tez ishlaydi. Biroq uning 66% mAP aniqligi SSD300 yoki Faster R-CNN'dan pastroq.

Umuman olganda, tezkor va aniq model tanlashda SSD300 eng yaxshi variant bo'lib ko'rinmoqda. Agar aniqlik muhim bo'lsa, Faster R-CNN tanlanishi mumkin, lekin u ancha sekin ishlaydi. YOLO esa tez ishlov berish talab qilinadigan, ammo maksimal aniqlik shart bo'lmagan holatlarda yaxshi tanlov bo'lishi mumkin [3].

Xulosa. Maqolada uchta asosiy obyektning aniqlashning neyron tarmoq modeli – YOLO, Faster R-CNN va SSD – tahlil qilinib, ularning afzallik va kamchilik tomonlari o'rganildi. YOLO modeli bir bosqichli yondashuvga asoslangan bo'lib, tezkor va samarali hisoblanadi. Faster R-CNN esa ikki bosqichli detektor bo'lib, aniqroq natijalar taqdim etadi. SSD modeli esa ushbu ikkala yondashuvning afzalliklarini o'zida mujassamlashtirib, balansli yechimni ta'minlaydi.

Barcha modellar konvolyutsiya va RoI Pooling kabi muhim texnologiyalarga asoslanib, obyektlarni aniqlashda yuqori aniqlik va samaradorlikni ta'minlaydi. Tadqiqot natijalari shuni ko'rsatadiki, real vaqt rejimidagi dasturlar uchun YOLO ustunlik qilsa, aniq obyektning lokalizatsiyasi talab etiladigan

vaziyatlarda Faster R-CNN yanada samarali hisoblanadi. Shunday qilib, obyektlarni aniqlash algoritmlarini tanlashda, qo'llaniladigan soha va talab qilinadigan xususiyatlar muhim ahamiyatga ega.

Foydalanilgan adabiyotlar

1. Peiyuan Jiang, Daji Ergu, Fangyao Liu, Ying Cai, Bo Ma: A Review of Yolo Algorithm Developments. *Procedia Computer Science* Volume 199, 2022, Pp:1066-1073.
2. Rishabh Singh: Understanding and Implementing Faster R-CNN. *Medium*, October 15, 2024.
3. Wei Liu, Dragomir Anguelov, Dumitru Erhan, Christian Szegedy, Scott Reed, Cheng-Yang Fu, Alexander C. Berg, "SSD: Single Shot MultiBox Detector". Google Inc., University of Michigan.
4. Nosirov K., Norinov M., Abdukadirov B. Image filtering algorithm based on the analysis of the main components // *International Conference on Information Science and Communications Technologies (ICISCT)*. – 2019. Pp. 1-3.
5. Norinov M., Abdukadirov B., Gofurov M. Application of Fourier Methods and Discrete-Cosinus Transformation in the Process of Processing of TV Images // *International Journal of Innovative Technology and Exploring Engineering*. – 2019. – Vol. 8, Issue 9S3. – Pp. 1565-1568.
6. Niyozmatova N., Mamatov N., Samijonov A., Abdukadirov B., Abdullayeva B. Algorithm for determining the coefficients of the interpolation polynomial of Newton with separated differences // *IOP Conference Series: Materials Science and Engineering*. – 2020. – Vol. 862, Issue 042019. – Pp. 1-4.



KLINIKALARNI AVTOMATLASHTIRISH TIZIMLARI: UMUMIY KO'RINISH VA TURLARI

Zulunov Ravshanbek Mamatovich,

dotsent, f.-m.f.n,
Toshkent axborot texnologiyalari universiteti
Farg'ona filiali

Sattarov Maxammadjon Fozil o'g'li,

2-bosqich magistranti
Toshkent axborot texnologiyalari universiteti
Farg'ona filiali

Annotatsiya: Mazkur maqolada klinikalarni avtomatlashtirish tizimlarining umumiy ko'rinishi va asosiy turlari ko'rib chiqiladi. Tibbiy sohada avtomatlashtirishning dolzarbligi sog'liqni saqlash xizmatlari sifatini oshirish, jarayonlarni soddalashtirish va vaqtni tejashda namoyon bo'ladi. Maqolada Elektron Tibbiy Ma'lumotnoma Tizimlari (EMR), bemorlarni ro'yxatga olish va navbatlarni boshqarish tizimlari, laboratoriya axborot tizimlari (LIMS), farmatsevtika menejmenti va moliyaviy boshqaruv tizimlari kabi asosiy tizimlar tahlil qilinadi. Ushbu tizimlarning har biri klinika ishlarini optimallashtirishda va bemorlarga xizmat ko'rsatish jarayonlarini yaxshilashda alohida ahamiyatga ega. Maqolada avtomatlashtirishning klinikalarga keltiradigan asosiy afzalliklari, jumladan xatolarni kamaytirish, ma'lumotlarning xavfsizligini ta'minlash va samaradorlikni oshirish haqida so'z boradi.

Kalit so'zlar: Sog'liqni saqlash, EHR tizimlari, Muvofiqlik, Normativ talablar, sun'iy intellekt, RIS (radiologik axborot tizimlari).

Kirish. Avtomatlashtirilgan klinika tizimlari sog'liqni saqlash muassasalari faoliyatini soddalashtirish, bemorlarga yordam ko'rsatishni yaxshilash va klinik jarayonlarning umumiy samaradorligini oshirish uchun mo'ljallangan bir qator texnologiyalarni anglatadi. Ushbu tizimlar bemorni ro'yxatga olishdan diagnostika va davolashgacha bo'lgan turli ma'muriy va klinik vazifalarni avtomatlashtirish uchun ilg'or dasturiy va apparat yechimlaridan foydalanadi. Avtomatlashtirilgan klinika tizimlari bemor tajribasini va sog'liqni saqlash sharoitida operatsion ish jarayonini optimallashtirishga qaratilgan keng ko'lamli funktsiyalarni o'z ichiga oladi. Ushbu tizimlar tibbiy yordam ko'rsatishni modernizatsiya qilish, qo'lda xatolarni kamaytirish va aniqroq va o'z vaqtida aralashuvni ta'minlash uchun ajralmas hisoblanadi. Operatsion samaradorlikni oshirish. Tibbiyot xodimlarini muhimroq ishlarga bo'shatish uchun muntazam vazifalarni avtomatlashtirish. Bemorlarga yordam ko'rsatishni yaxshilash Bemorlarga o'z vaqtida va to'g'ri tashxis

qo'yish va davolanishni ta'minlash. Xarajatlarni kamaytirish Ma'muriy qo'shimcha xarajatlarni minimallashtirish va qimmatga tushadigan xatolarni kamaytirish. Ma'lumotlarning aniqligini oshirish Bemor yozuvlari va boshqa muhim ma'lumotlarning aniqligi va ulardan foydalanish imkoniyatini oshirish. Muvofiqlik Normativ talablar va standartlarga rioya qilishga yordam berish. Avtomatlashtirilgan klinika tizimlari sog'liqni saqlash muhitida xizmat qiladigan o'ziga xos funktsiyalari asosida tasniflanishi mumkin.

Usullar. Bu yerda birlamchi turlari haqida ma'lumot keltirilgan:

EHR tizimlari bemorlarning qog'oz jadvallarining raqamli versiyalari. Ular ma'lumotni vakolatli foydalanuvchilarga bir zumda va xavfsiz tarzda taqdim etadigan real vaqt rejimida, bemorga yo'naltirilgan yozuvlarni taqdim etadi. Funktsiyalar Bemor ma'lumotlarini saqlash, tarixni kuzatish, dori-darmonlarni qayd etish va boshqa sog'liqni saqlash AT tizimlari bilan integratsiya. Afzalliklar Ma'lumotlarning aniqligi yaxshilandi, bemorlarga



yordam ko'rsatish yaxshilandi, ma'lumotlar almashinuvi yaxshilandi va tartibga muvofiqlik. Tavsif PMS tibbiy amaliyotning kundalik operatsiyalarini bajarish uchun mo'ljallangan. Bunga uchrashuvlarni rejalashtirish, hisob-kitoblar va boshqa ma'muriy vazifalar kiradi. Vazifalar Uchrashuvni bron qilish, bemorni ro'yxatga olish, hisob-kitob va da'volarni boshqarish va moliyaviy hisobot. Imtiyozlar Ma'muriy jarayonlarni soddalashtirdi, hujjatlarni rasmiylashtirishni qisqartirdi, hisob-kitoblarning aniqligini oshirdi va moliyaviy boshqaruvni yaxshiladi.

Sog'liqni saqlash holatini baholash indeksi:

$$HSI = \frac{T_{normal}}{T_{total}} * 100$$

Bu yerda:

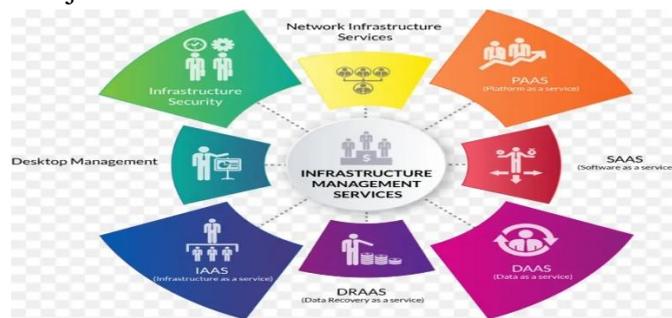
- HSI – sog'liqni saqlash holati indeksi;
- T_{normal} – normal sog'liq holatidagi tashxislar soni;
- T_{total} – umumiy tashxislar soni.

Ushbu tizimlar bemorlarning uchrashuvlarini rejalashtirish va tibbiyot xodimlari uchun kalendarlarni boshqarish jarayonini avtomatlashtiradi. Funktsiyalar Onlayn uchrashuvlarni bron qilish, eslatmalar va bildirishnomalar, resurslarni taqsimlash va nizolarni boshqarish. Imtiyozlar Ko'rsatilmaganlar sonining kamayishi, resurslardan optimallashtirilgan foydalanish, bemorlarning qoniqish darajasini oshirish va vaqtni samarali boshqarish. Tavsif CDSS sog'liqni saqlash sohasi mutaxassslariga bemorga tegishli bilim va ma'lumotlarni taqdim etadi, ular oqilona filtrlanadi va bemorlarga yordam ko'rsatishni yaxshilash uchun tegishli vaqtda taqdim etiladi. Funktsiyalar Ogohlantirishlar va eslatmalar, diagnostika yordami, davolash bo'yicha tavsiyalar va klinik ko'rsatmalarga rioya qilishdir.



1-rasm. EHR tizimi.

Uning afzalliklari sifatida tashxisning aniqligi, xatolarning kamayishi va bemorning natijalari yaxshilanganligini aytish mumkin. Ushbu tizimlar bemorlar va sug'urta kompaniyalari hisob-kitoblarini, shuningdek, tibbiy tashxis va protseduralarni kodlash jarayonini avtomatlashtiradi. Funktsiyalar da'volarni qayta ishlash, to'lovlarni kuzatish, kodlash muvofiqligi va moliyaviy hisobotlarni aytish mumkin. Imtiyozlar - Hisob-kitob xatolarining kamayishi, da'volarni tezroq ko'rib chiqish, daromad siklini boshqarishni yaxshilash va me'yoriy hujjatlarga rioya qilishlardir. LIMS laboratoriya operatsiyalari va ish oqimlarini, namunalarni kuzatishdan hisobot natijalariga qadar boshqaradi. Shuningdek, Namunalarni kuzatish, ma'lumotlarni kiritish, sifat nazorati va hisobot berishlar ham mavjud. Natijada laboratoriya samaradorligi yaxshilandi, ma'lumotlarni aniq boshqarish, sifat nazorati yaxshilandi va me'yoriy hujjatlarga muvofiqlik yaxshilandi. Tavsif RIS radiologik tasvirni va tegishli ma'lumotlarni boshqarish uchun ishlatiladi. Rasmni arxivlash, hisobot yaratish, rejalashtirish va bemorni kuzatishda Tasvirlash ish jarayonlarini soddalashtirdi, tasvirni boshqarishni takomillashtirish, boshqa tizimlar bilan yaxshiroq integratsiyalash va bemorlarni parvarish qilish yaxshilandi. Ushbu tizimlar telekommunikatsiya texnologiyalari orqali bemorlarni masofaviy maslahat va monitoring qilish imkonini beradi. Video konsultatsiyalar, bemorni masofadan kuzatish, raqamli diagnostika va telefon orqali triaj ishida Xizmatdan keng foydalanish, bemorlar uchun qulaylik, sayohat va kutish vaqtlarini qisqartirish va doimiy monitoringlar mavjud.



2-rasm. Infrastruktura boshqaruv xizmatlari.



Samaradorlik va mahsuldorlik: Muntazam vazifalarni avtomatlashtirish tezroq bajarilishiga va kamroq xatolarga olib keladi va xodimlarni muhimroq vazifalar uchun bo'shatadi. Yaxshilangan bemorlarni parvarishlash Ma'lumotlarni boshqarish va qaror qabul qilishni qo'llab-quvvatlash bilan klinisyenlar aniqroq va o'z vaqtida yordam ko'rsatishlari mumkin. Harajatlarni tejashda ma'muriy yuklarni kamaytirish va xatolarni imkon qadar minimallashtirish operatsion xarajatlarni sezilarli darajada kamaytirishi mumkin. Tegishli ma'lumotlarni boshqarishda kengaytirilgan ma'lumotlar aniqligi va bemor ma'lumotlariga oson kirish hamda klinik qarorlar qabul qilish va bemor natijalarini yaxshilaydi. Normativ hujjatlarga muvofiqlik Avtomatlashtirilgan tizimlar sog'liqni saqlash qoidalari va standartlariga rioya qilishni ta'minlashga yordam beradi, rioya qilmaslik uchun jarimalar xavfini kamaytiradi. Yuqori boshlang'ich xarajatlar Avtomatlashtirilgan tizimlarni o'rnatish va integratsiya qilish qimmat bo'lishi mumkin, bu esa kichikroq klinikalar uchun to'siq bo'lishi mumkin. Ta'limga qo'yiladigan talablar Xodimlar yangi tizimlardan samarali foydalanish uchun yetarli darajada o'qitilishi kerak, bu vaqt va resurslarni talab qiladi. Ma'lumotlar xavfsizligi va maxfiylik bo'yicha esa bemorga tegishli nozik ma'lumotlarning xavfsizligi va maxfiyligini ta'minlash eng e'tiborli jihati bo'lib, ishonchli kiberxavfsizlik choralarini talab qiladi. Shuningdek mavjud tizimlar bilan integratsiya bo'lishi ham mumkin.

Navbatda kutish vaqti:

$$W = \frac{N * T_{avg}}{S}$$

Bu yerda:

- W – o'rtacha kutish vaqti;
- N – navbatdagi bemorlar soni;
- T_{avg} – bitta bemor qabul qilishga ketadigan o'rtacha vaqt;
- S – xizmat ko'rsatayotgan shifokorlar soni.

Navbat uzunligi:

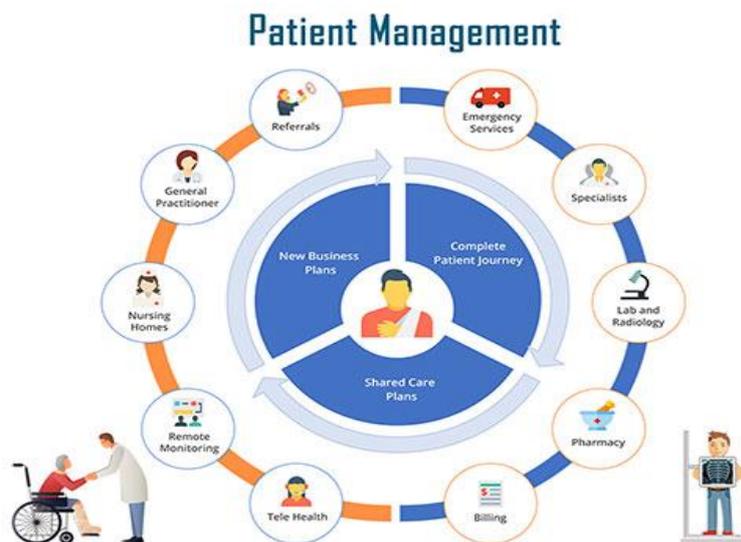
$$L = \frac{\lambda}{\mu - \lambda}$$

Bu yerda:

- L – navbat uzunligi;

- λ – bemorlarning kelish tezligi;
- μ – shifokor xizmat ko'rsatish tezligi.

Mavjud IT tizimi bilan uyg'unlik va integratsiya amalga oshirish qiyin bo'lishi mumkin va katta o'zgartirishlarni talab qilishi ehtimoli bor. Sun'iy intellekt va mashinani o'rgatish texnologiyalaridan foydalanish, diagnostika aniqroq bo'lishi va prognozlash tahlilini yanada yaxshilash imkoniyatlarini yaratadi. Tizimlar o'rtasidagi hamkorlikni kuchaytirish, turli platformalar orasidagi ma'lumot almashish va foydalanishni ta'minlashga ko'proq e'tibor qaratiladi. Bemorga yo'naltirilgan parvarish tizimlari, yaxshiroq ma'lumotlarni tushunish va aloqaning samarali vositalari orqali bemorlarning ishtirokini oshirish va individual yondashuvni yaxshilash maqsadida ishlab chiqilgan. Blokcheyn texnologiyasi markazlashtirilmagan va o'zgarimas yozuvlar yordamida bemor ma'lumotlarini himoya qilish va ma'lumotlar yaxlitligini saqlashda katta salohiyatga ega.



3-rasm. Mijozni boshqarish tizimi.

Avtomatlashtirilgan klinik tizimlar sog'liqni saqlash sohasida samaradorlik, aniqlik va bemorlarga xizmat ko'rsatishni yaxshilash orqali inqilobiy o'zgarishlar yaratmoqda. Ularni joriy etishda ba'zi qiyinchiliklar mavjud bo'lsa-da, bu tizimlarning afzalliklari mavjud to'siqlardan ancha ustun bo'lib, yanada soddalashtirilgan va samarali sog'liqni saqlash tizimini yaratish imkonini beradi. Texnologiyaning



rivojlanishi davom etar ekan, avtomatlashtirilgan klinik tizimlarning kelajagi juda istiqbolli ko'rinadi va joriy bo'layotgan o'zgarishlar sog'liqni saqlash sohasida va bemorlarning natijalarini yanada yaxshilashga olib keladi. Avtomatlashtirilgan klinik tizimlar zamonaviy sog'liqni saqlash infratuzilmasining asosini tashkil etib, operatsiyalarni soddalashtirish, bemorlar uchun xizmatlarni yaxshilash va umumiy samaradorlikni oshirishda ilg'or texnologiyalarni qo'llaydi.

Reagentlarning yetishmovchilik darajasi:

$$R_{deficit} = \frac{R_{used} - R_{available}}{R_{used}} * 100$$

Bu yerda:

- $R_{deficit}$ – reagent yetishmovchilik darajasi;
- R_{used} – kerak bo'lgan reagent miqdori;
- $R_{available}$ – mavjud reagent miqdori.

Ma'muriy va klinik jarayonlarni avtomatlashtirish orqali ushbu tizimlar inson xatolarini kamaytiradi, vaqtni tejashga yordam beradi va resurslardan samarali foydalanishni ta'minlaydi. Ushbu keng ko'lamli tahlil avtomatlashtirilgan klinik tizimlarning turli shakllari, ularning afzalliklari, duch kelinadigan muammolar va kelajakdagi rivojlanish tendentsiyalarini o'rganadi.



4-rasm. OVID texnologiyalari.

Natijalar. Avtomatlashtirilgan klinika tizimlari sog'liqni saqlash muassasalarida ham operatsiya samaradorligini, ham bemorlarga xizmat ko'rsatish sifatini oshirishga qaratilgan keng ko'lamli texnologiyalarni o'z ichiga oladi. Ushbu tizimlar bemorlar, tibbiyot xodimlari va ma'muriy xodimlarning ehtiyojlarini qondirish uchun turli

funksiyalarni birlashtiradi. Operatsion samaradorlikni oshirish Tibbiyot xodimlariga bemorlarni parvarish qilishga e'tibor qaratish imkonini berish uchun takrorlanuvchi va ko'p vaqt talab qiluvchi vazifalarni avtomatlashtirishlardir. Bemorlarga yordam ko'rsatishni yaxshilash Yaxshiroq tashxis qo'yish va davolash uchun tibbiy xizmat ko'rsatuvchi provayderlarga o'z vaqtida va aniq ma'lumot berish. Xarajatlarni kamaytirish Ma'muriy xarajatlarni kamaytirish va xatolarning moliyaviy ta'sirini minimallashtirishdan iborat.

Ma'lumotlarning aniqligini oshirishda yuqori sifatli ma'lumotlarni boshqarish va ulardan foydalanish imkoniyatini ta'minlashlarni hisobga olish zarur.

Elektron sog'liqni saqlash yozuvlari (EHR) tizimlari ta'rifi: EHR tizimlari bemorlarning qog'ozga asoslangan yozuvlarini raqamli shaklda saqlaydi, ma'lumotlarni markazlashtiradi va ularni vakolatli foydalanuvchilar uchun real vaqt rejimida ochiq qiladi. Bu tizimlar shuningdek, ma'lumotlarni to'liq saqlash, bemor tarixini kuzatish, dori-darmonlarni boshqarish va boshqa sog'liqni saqlash IT tizimlari bilan integratsiyalashuvni ta'minlaydi. Ma'lumotlarning aniqligi oshdi, bemorlar uchun xizmat ko'rsatish yaxshilandi, ma'lumot almashish osonlashdi va sog'liqni saqlash normalariga rioya qilish ta'minlandi.

Tavsiflangan PMS (Amaliyot boshqaruvi tizimi) tibbiy amaliyotlarning kundalik jarayonlarini, shu jumladan ma'muriy va moliyaviy vazifalarni bajaradi. U uchrashuvlarni rejalashtirish, bemorlarni ro'yxatga olish, hisob-kitob va kodlash, sug'urta da'volarini boshqarish va moliyaviy hisobotlarni tayyorlashni o'z ichiga oladi. Ma'muriy jarayonlarni soddalashtiradi, qog'oz ishlashni kamaytiradi, hisob-kitoblar aniqligini oshiradi va moliyaviy boshqaruvni takomillashtiradi. Ushbu tizimlar bemor uchrashuvlarini rejalashtirishni va tibbiy xizmat ko'rsatuvchilar kalendarlarini boshqarishni avtomatlashtiradi. Onlayn uchrashuvlarni bron qilish, avtomatik eslatmalar va bildirishnomalar, resurslarni taqsimlash va nizolarni hal qilish imkoniyatlarini yaratadi.

Afzalliklari: Keraksiz tavsiyalarni qisqartirish, resurslardan samarali foydalanish, bemorlar



qoniqishining oshishi va vaqtni samarali boshqarish imkoniyatlarini ta'minlaydi.

CDSS sog'liqni saqlash xodimlariga bemorga xos ma'lumot va muhim daqiqalarda klinik bilimlarni beradi. Unda ogohlantirishlar va eslatmalar, diagnostik yordam, davolash bo'yicha tavsiyalar va klinik ko'rsatmalarga rioya qilishlar mavjud. Unda Diagnostikaning aniqligi, o'z vaqtida aralashuvlar, xatolarning kamayishi va bemorning natijalari yaxshilandi. Ushbu tizimlar to'g'ri va samarali moliyaviy operatsiyalarni ta'minlab, hisob-kitob va kodlash jarayonlarini avtomatlashtiradi.



5-rasm. Klinik boshqaruv dasturi afzalliklari.

Muhokama. Funktsiyalar orasida da'volarni qayta ishlash, to'lovlarni nazorat qilish, kodlash standartlariga muvofiqlikni ta'minlash va batafsil moliyaviy hisobotlarni tayyorlash kiradi. Hisob-kitobdagi xatolarni kamaytirish, da'volarni tezroq ko'rib chiqish, daromad tsiklini boshqarishning yaxshilanishi va qoidalarga rioya qilish kabi afzalliklar mavjud. LIMS (Laboratoriya axborot boshqaruvi tizimi) laboratoriya jarayonlarini boshqaradi, namunalarni to'plashdan natijalar bo'yicha hisobotlarni taqdim etishga qadar bo'lishi mumkin. U namunalarni kuzatish, ma'lumotlarni kiritish, sifat nazoratini amalga oshirish va hisobotlar tayyorlashni o'z ichiga oladi. LIMS tizimining afzalliklari laboratoriya samaradorligini oshirish, ma'lumotlarni to'g'ri boshqarish, sifat nazoratini kuchaytirish va me'yoriy hujjatlarga muvofiqlikni ta'minlashdan iborat.

Tavsif RIS (Radiologik axborot tizimi) radiologik tasvirlarni va tegishli ma'lumotlarni boshqaradi, radiologiya bo'limlaridagi ish oqimlarini tartibga soladi. Ushbu tizim rasmni arxivlash, hisobotlar tayyorlash, rejalashtirish va bemorni kuzatishni amalga oshiradi. Samarasiz ish oqimlarini yaxshilash, takomillashtirilgan tasvir boshqaruvi, boshqa tizimlar bilan mukammal integratsiya va bemorlarni qo'llab-quvvatlashning yaxshilanishi tizimning asosiy afzalliklaridan hisoblanadi. Bu tizimlar telekommunikatsiya texnologiyalarini qo'llab, masofaviy maslahatlar va bemorlarni kuzatishni osonlashtiradi.

Muntazam vazifalarni avtomatlashtirish tezroq bajarilishiga, kamroq xatolarga olib keladi va xodimlarga ko'proq muhim vazifalarga e'tibor qaratish imkonini beradi. Bemorlarga xizmat ko'rsatishning yaxshilanganligi to'g'ri ma'lumotlarni boshqarish va qarorlarni qo'llab-quvvatlash tizimlari klinisyenlarga o'z vaqtida va aniq yordam ko'rsatish imkonini beradi. Xarajatlarni kamaytirishda ma'muriy yuk va xatolarni minimallashtirish operatsion xarajatlarni sezilarli darajada kamaytirishi mumkin. Ma'lumotlarni boshqarish Kengaytirilgan aniqlik va bemor qaydlarining mavjudligi klinik qarorlar qabul qilish va bemor natijalarini yaxshilaydi.

Normativ hujjatlarga muvofiqlik bo'yicha, avtomatlashtirilgan tizimlar sog'liqni saqlash qoidalari va standartlariga rioya qilishni ta'minlashga yordam beradi va jarimalar xavfini kamaytiradi. Yuqori boshlang'ich xarajatlarda Avtomatlashtirilgan tizimlarni o'rnatish va integratsiya qilish qimmat bo'lishi mumkin, bu esa kichikroq klinikalar uchun to'siq bo'lishi mumkin. Ta'limga qo'yiladigan talablar Xodimlar yangi tizimlardan samarali foydalanish uchun etarli darajada o'qitilishi kerak, bu vaqt va resurslarni talab qiladi. Ma'lumotlar xavfsizligi va maxfiylik Bemorga tegishli nozik ma'lumotlarning xavfsizligi va maxfiyligini ta'minlash eng muhimi bo'lib, mustahkam kiberxavfsizlik choralarini talab qiladi. Mavjud tizimlar bilan integratsiya. Mavjud IT infratuzilmasi bilan moslik va integratsiya qiyin bo'lishi mumkin va jiddiy tuzatishlarni talab qilishi mumkin. Sun'iy intellekt va mashinani o'rganish



Diagnostika aniqligi va bashoratli tahlilni oshirish uchun sun'iy intellektdan foydalanishni ko'paytirish. O'zaro muvofiqlik Turli tizimlarning ma'lumotlarni uzluksiz almashishi va ulardan foydalanishini ta'minlashga ko'proq e'tibor qaratiladi. Bemorga yo'naltirilgan parvarishlash tizimlari ma'lumotlarni yaxshiroq tushunish va aloqa vositalari orqali bemorni jalb qilish va shaxsiylashtirilgan yordamni yaxshilash uchun mo'ljallangan.

Xulosa. Blokcheyn texnologiyasi markazlashtirilmagan va o'zgarmas yozuvlar orqali bemor ma'lumotlarini himoya qilish va ma'lumotlar yaxlitligini ta'minlashda potentsial foydalanish. Avtomatlashtirilgan klinika tizimlari samaradorlik, aniqlik va bemorlarga xizmat ko'rsatishni yaxshilash orqali tibbiy yordam ko'rsatishni o'zgartirmoqda.

Qiyinchiliklarga qaramay, ushbu tizimlarning afzalliklari salmoqli bo'lib, yanada soddalashtirilgan va samarali sog'liqni saqlash muhitiga yo'l ochadi. Texnologiyaning davom etayotgan rivojlanishi bilan avtomatlashtirilgan klinika tizimlarining kelajagi istiqbolli ko'rinadi, doimiy yaxshilanishlar sog'liqni saqlash va bemorlarning natijalarini yanada yaxshilashga yordam beradi.

Foydalanilgan adabiyotlar

1. R.Zulunov, M.Sattarov. Sog'liqni saqlashni avtomatlashtirish: bemor tajribasini yaxshilash yo'li. Potomki Аль-Фаргани, 2024, 1(2), 189–195.
2. P.Зулунов. Технологии robotic process automation в медицине. Потомки Аль-Фаргани, 2024, 1(4), 197-200.
3. P.Зулунов, O.Мелибоев. Современные реалии умной медицины для студентов. Miasto Przyszłości, 2024, T-48, с. 1052-1055.
4. R Zulunov. M Mahmudova. Tibbiyot muassasalarida elektron navbat tizimi. Potomki Аль-Фаргани, 2023, 1(2), с. 53-57
5. R.Zulunov. Pythonda neyron tarmoqni qurish va bashorat qilish. Al-Farg'oni avlodlari, 2023, 1/4, с. 22-26.
6. R Zulunov, O Otaqulov. Ограничения обучения языку программирования JAVA в образовательных системах. Потомки Аль-Фаргани, 2023, т.1/2, с. 37-40.

7. R.Zulunov, A.Kayumov. Идентификация и сортировка текстиля для автоматизированной обработки с помощью ближней инфракрасной спектроскопии. Universum: технические науки, 3(120), март 2024, с. 38-42.

8. R.Zulunov, Z.Samatova. Bulutli texnologiyalarda kiberxavfsizlik taminlashda CASB yechimlari. Potomki Аль-Фаргани, 2024, 1(1), с. 93–98.

9. R.Zulunov, B.Soliev. Z.Ermatova. Enhancing Clarity with Techniques for Recognizing Blurred Objects in Low Quality Images Using Python. Potomki Аль-Фаргани, 2024, 1(2), 336–340.

10. VV Byts', RM Zulunov. Specification of matrix algebra problems by reduction. Journal of Mathematical Sciences. T. 71, 2719–2726 (1994).

11. Hnatiienko, H., Hnatiienko, V., Zulunov R., Babenko, T., Myrutenko, L. Method for Determining the Level of Criticality Elements when Ensuring the Functional Stability of the System based on Role Analysis of Elements. CEUR Workshop Proceedings, 2024, 3654, p. 301–311

12. R.Zulunov, B.Soliyev, A.Kayumov, M.Asraev, Kh.Musayev, D.Abdurasulova. Detecting mobile objects with ai using edge detection and background subtraction techniques. E3S Web of Conferences, 508, 03004 (2024).

13. R.Zulunov, U.Akhundjanov, B.Soliyev, A.Kayumov, M.Asraev, Kh.Musayev. Building and predicting a neural network in PYTHON. E3S Web of Conferences, 508, 04005 (2024).

14. U.Akhundjanov, R.Zulunov, A. Kayumov, X.Goipova, Z.Ermatova, M.Sobirov. Handwritten signature preprocessing for off-line recognition systems. E3S Web of conferences 587, 03019 (2024), GreenEnergy 2024.



TIBBIY TASHXISNI ANIQLASH JARAYONIDA KLASSIFIKATSIYA ALGORTIMIDAN FOYDALANISHNING TAHLILI

Sotvoldiyeva Dildora Botirjon qizi,

Muhammad al-Xorazmiy nomidagi Toshkent
Axborot texnologiyalari Universiteti Farg'ona filiali
"Axborot texnologiyalari" kafedrasida assistenti
e-mail: nurdilnurik@gmail.com

Karimov Sardorbek Ilhomjon o'g'li,

Muhammad al-Xorazmiy nomidagi Toshkent Axborot
texnologiyalari Universiteti Farg'ona filiali "Axborot
texnologiyalari" kafedrasida katta o'qituvchisi
e-mail: sk363688@gmail.com

Mehmonaliyev Yahyobek,

Muhammad al-Xorazmiy nomidagi Toshkent axborot
texnologiyalari
universiteti Farg'ona filiali talabasi

Annotatsiya: Ushbu maqolada zamonaviy sun'iy intellekt texnologiyalari yordamida sog'liqni saqlash sohasida tashxis qo'yish jarayonlari tahlil qilinadi va klassifikatsiya algoritmlarining ahamiyati, qo'llanilishi va samaradorligi haqida batafsil ma'lumot beradi. Maqola klassifikatsiya algoritmlarining aniqlik, tezkorlik va prognoz qilish imkoniyatlari tufayli tibbiy diagnostika jarayonlaridagi muhim o'rni haqida xulosa beradi. Ushbu tahlil sog'liqni saqlash tizimiga ilg'or texnologiyalarni integratsiya qilish orqali diagnostika jarayonlarini takomillashtirish va shaxsiylashtirilgan tibbiyotga o'tishni qo'llab-quvvatlaydi.

Kalit so'zlar: Klassifikatsiya algoritmlari, tibbiy tashxis, sun'iy intellekt, ma'lumotlarni tahlil qilish, logistik regressiya, tasodifiy o'rmon, neyron tarmoqlar, mashinali o'qitish, diagnostika texnologiyalari.

Kirish. Zamonaviy tibbiyotda tashxis qo'yish jarayoni nafaqat shifokorlarning tajribasiga, balki texnologiyalarning samarali qo'llanilishiga ham tobora ko'proq bog'liq bo'lib bormoqda. Bemorlarning simptomlari, tahlillar natijalari va boshqa sog'liq ma'lumotlari asosida tashxis qo'yishda shifokorlar turli xil intellektual texnologiyalardan foydalanmoqda. Ayniqsa, ushbu sohada sun'iy intellekt, xususan, klassifikatsiya algoritmlarining ahamiyati tobora oshib bormoqda. Klassifikatsiya algoritmlari ma'lumotlarni tahlil qilish va ularni muayyan sinflarga ajratish imkoniyatini taqdim etadi. Ushbu algoritmlar, bemorlarning simptomlari asosida kasalliklarni aniqlash, ularni tasniflash va kelajakdagi rivojlanish ehtimolini prognoz qilish uchun qo'llaniladi. Ayniqsa, ulkan hajmdagi tibbiy ma'lumotlar bilan ishlashda,

bunday algoritmlar diagnostika jarayonini aniq, tezkor va ishonchli amalga oshirishda yordam beradi. Mazkur maqolada tibbiy tashxis qo'yishda qo'llaniladigan asosiy klassifikatsiya algoritmlari, ularning ishlash mexanizmlari hamda sog'liqni saqlash sohasidagi samaradorligi batafsil tahlil qilinadi. Maqsad – ushbu algoritmlar tibbiyot tizimida qanday imkoniyatlar yaratishi va diagnostika jarayonlarining sifatini qanday yaxshilashi mumkinligini o'rganishdir.

Adabiyotlar sharhi. Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill. Ushbu asar mashinada o'rganish va uning tibbiyotdagi qo'llanilishi haqida keng qamrovli tushuncha beradi. Kitobda turli xil algoritmlar, shu jumladan, klassifikatsiya metodlari, ularning ishlash prinsiplarini va amaliyotdagi samaradorligini batafsil ko'rib



chiqiladi. Tibbiyotda klassifikatsiya algoritmlarining ishlatilishiga oid muhim misollar va tadqiqotlar taqdim etilgan.[1]

Han, J., Kamber, M., & Pei, J. (2011). *Data Mining: Concepts and Techniques*. Morgan Kaufmann
Ushbu kitobda ma'lumotlarni qazib olish, shu jumladan, klassifikatsiya algoritmlarining tahlili va ularga asoslangan tibbiy tashxis qo'yish jarayonlari keltirilgan. Mualliflar ma'lumotlarni tahlil qilishning asosiy yondashuvlarini va algoritmi real dunyo muammolariga qanday qo'llash mumkinligini tushuntiradi.[2]

Zhang, H. (2004). *The Optimality of Naive Bayes*. Proceedings of the Seventeenth International Florida Artificial Intelligence Research Society Conference. Ushbu maqola Naive Bayes algoritmining optimal ishlash shartlarini o'rganadi va tibbiy tashxisda qanday samarali ishlashini ko'rsatadi. Algoritmining tibbiy ma'lumotlar bilan ishlashda yengilligi va samaradorligi haqida taqdim etilgan tahlillar, uni tibbiyot sohasida keng qo'llashning asosiy sabablaridan biri bo'lib xizmat qiladi.[3] Bu adabiyotlar, klassifikatsiya algoritmlarining tibbiyot sohasidagi qo'llanilishini, ularning diagnostika jarayonlarini yaxshilashdagi rolini va tibbiy ma'lumotlarni tahlil qilishda qanday qo'llanilishini batafsil tushunishga yordam beradi. Tibbiy tashxis qo'yishda ilg'or texnologiyalarni qo'llashning nazariy asoslari va amaliy jihatlari haqida chuqur ma'lumot olish imkonini beradi.

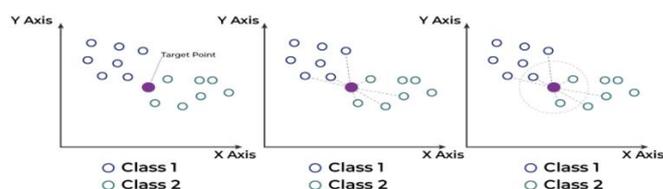
Muammoning qo'yilishi. Zamonaviy tibbiyotda tashxis qo'yish jarayoni o'zining murakkabligi va katta hajmdagi ma'lumotlarni tahlil qilishni talab etishi bilan ajralib turadi. Tibbiy tashxis aniqligini oshirish va bemorga tezkor yordam ko'rsatish uchun intellektual texnologiyalardan, jumladan, klassifikatsiya algoritmlaridan foydalanish zaruriyati yuzaga kelmoqda. Tadqiqotning asosiy maqsadi – klassifikatsiya algoritmlarining tibbiy tashxis jarayonida samaradorligini tahlil qilish va ularning sog'liqni saqlash sohasidagi imkoniyatlarini ochib berishdir.[4]

Taklif etilayotgan yechim: *k*-Nearest Neighbors (*k*NN) algoritmi orqali tashxisni aniqlash va

bu usul yordamida tibbiy tashxis qo'yish jarayonini tezkor, aniq va ishonchli qilish bilan birga, sog'liqni saqlash tizimidagi resurslardan samarali foydalanish imkoniyatini oshirish maqsad qilingan. *K*-yaqin qo'shnilar algoritmi (*K*NN) – bu mashinani o'qitishda ishlatiladigan nazorat ostidagi o'rganish algoritmi bo'lib, klassifikatsiya va regressiya masalalarida qo'llaniladi.[5] *K*NN oddiy va samarali algoritm bo'lib, u butunlay masofaga asoslangan tamoyilga ega. *K*NN algoritmining asosiy printsiplari – yangi kiruvchi ma'lumotlarni o'xshashlikka qarab tasniflash yoki baholash. *K*NN yangi nuqtaning o'z sinfini aniqlash uchun trening ma'lumotlar to'plamidagi yaqin qo'shnilarining sinflariga qaraydi.[6]

KNN algoritmining ishlashi

K-Yaqin qo'shnilar (*K*NN) algoritmi o'xshashlik printsiplari asosida ishlaydi, bu erda u o'quv ma'lumotlar to'plamidagi *K* eng yaqin qo'shnilarining teglari yoki qiymatlarini hisobga olgan holda yangi ma'lumotlar nuqtasining yorlig'i yoki qiymatini bashorat qiladi.[7]



1-rasm. *K*NN algoritmidagi sinflarga ajratish

*K*NN qanday ishlashini bosqichma-bosqich tushuntirish quyida muhokama qilinadi:

1-qadam: *K* ning optimal qiymatini tanlash

K bashorat qilishda e'tiborga olinishi kerak bo'lgan eng yaqin qo'shnilar sonini bildiradi.

2-qadam: masofani hisoblash

Maqsad va o'quv ma'lumotlar nuqtalari o'rtasidagi o'xshashlikni o'lchash uchun Evklid masofasidan foydalaniladi. Ma'lumotlar to'plamidagi har bir ma'lumot nuqtasi va maqsad nuqtasi orasidagi masofa hisoblanadi.[8]

$$d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}$$

1-formula. Evklid masofasini hisoblash

3-qadam: Eng yaqin qo'shnilarini topish



Maqsadli nuqtaga eng kichik masofaga ega bo'lgan k ma'lumot nuqtasi eng yaqin qo'shnilardir. Noma'lum element qaysi sinfga tegishli ekanini topishda noma'lum element qiymat jihatidan qaysi sinfga eng yaqin joylashgan bo'lsa shu sinf tarkibiga kiritiladi.[9]

Amaliy qism: Amaliy qismni bajarish jarayonida kasallikka tashxis qo'yishda klassifikatsiya usuli tarkibidagi k-neighbours algoritmidan foydalanilgan. Bemorlar ma'lumotlaridan kelib chiqib bemorlar 2 ta sinfga (kasal yoki kasal emas) ajratiladi. Bunda dastlab shu kasallik bo'yicha qo'yilgan tashxis ma'lumotlaridan foydalaniladi. Kerakli kutubxonalarni import qilib olamiz.

```
import numpy as np
import pandas as pd
a=pd.read_csv('diabetes.csv')
a
```

Natija esa quyidagicha, ma'lumotlarimiz yig'ilgan faylimizni a o'zgaruvchiga biriktirib olamiz. Ma'lumotlarimizni dastlab tahlil qilib olish kerak,matnli ma'lumotlar bo'lsa ularni sonli ko'rinishga keltirish kerak, yokida ortiqcha ma'lumotlardan voz kechish talab etiladi.[10]

	Homiladorlik	glyukoza	qon bosimi	teri qalinligi	insulin	BMI	nasl	yoshi	tashxis
0	6	148	72	35	0	33.6	0.627	50	1
1	1	85	66	29	0	26.6	0.351	31	0
2	8	183	64	0	0	23.3	0.672	32	1
3	1	89	66	23	94	28.1	0.167	21	0
4	0	137	40	35	168	43.1	2.288	33	1
...
763	10	101	76	48	180	32.9	0.171	63	0
764	2	122	70	27	0	36.8	0.340	27	0
765	5	121	72	23	112	26.2	0.245	30	0
766	1	126	60	0	0	30.1	0.349	47	1
767	1	93	70	31	0	30.4	0.315	23	0

2-rasm. Data ning umumiy ko'rinishi

`a.corrwith(a['tashxis']).abs().sort_values(ascending=False)`

Ushbu funksiya bizga kasallik va uning simptomlari orasidagi bog'lanishni aniqlab beradi. Qaysi bir qiymat 1 ga yaqinroq bo'lsa shu simptom kasallik ga eng ko'p bog'liqligi bor simptom hisoblanadi.

```
tashxis      1.000000
glyukoza     0.466581
BMI          0.292695
yoshi        0.238356
Homiladorlik 0.221898
nasl         0.173844
insulin      0.130548
teri qalinligi 0.074752
qon bosimi   0.065068
dtype: float64
```

3-rasm. Korrelyatsiya qiymatlari.

Endi esa X va Y o'qlari uchun qiymatlarni belgilaymiz. X o'qi uchun kasallikning barcha simptomlarini, Y o'qimiz uchun esa "Tashxis" nomli column qiymatlarini o'zlashtiramiz.

```
X = a.drop('tashxis', axis=1).values
y = a['tashxis']
```

Data mizmi test va train qismlarga bo'lib olamiz. Chunki train datamiz bilan ma'lumotlarni mashinaga o'qitishimiz kerak. X ning qanday qiymatlarida Y qanday qoymatlarga erishishini kitub qo'yamiz, modelimiz shu train data dan o'zlashtirgan bilimlari asosida faoliyat yuritadi.

```
from sklearn.model_selection import
train_test_split
X_train, X_test, y_train, y_test =
train_test_split(X,y, test_size=0.2, random_state=12)
X_train
```

X_train
array([[-1.14185152e+00, 1.25318668e+00, -9.87709745e-01, ...,
[-1.28094240e+00, -6.38012288e-01, 2.70231170e+00],
[-8.44885053e-01, -9.98207780e-01, 2.33185124e+00], ...,
[-5.32118852e-01, 2.63123907e-01, -1.04154944e+00],
[6.39947260e-01, 1.28648383e+00, -3.67336746e-01, ...,
[-9.76336210e-01, -8.87541309e-01, 1.42599540e+00],
...,
[-1.14185152e+00, -1.09209922e+00, -5.71502470e-02, ...,
[4.03235111e-01, -7.06334180e-01, -7.01190424e-01],
[-8.44885053e-01, -6.53939181e-01, -1.60545747e-01, ...,
[9.41970774e-04, -0.41097406e-02, 7.45293379e-01],
[1.82781311e+00, -3.09670582e-01, 4.62452528e-02, ...,
[-5.70194625e-01, -9.95285700e-01, 5.75117873e-01]])

X_test
array([[-1.14185152, -0.12180771, 0.56322275, ..., 1.67627602,
[-1.15633107, -0.78628618],
[0.04601433, 1.58815814, 0.14964075, ..., 1.47320522,
[0.02151441, -0.61611067],
[0.04601433, 0.47275805, 0.04624525, ..., -0.10059342,
2.14465784, -0.95646168],

4-rasm. Data ning test va train qismlarga bo'linishi

Endi esa ang asosiy qism, berilgan datamiz bilan modelimizni o'qitishimiz kerak, O'qitish jarayonida train datalardan foydalaniladi.[5] Va ma'lumot o'qitilgandan so'ng esa navbatdagi yangi qiymatlar uni test qilib ko'rishimiz kerak bo'ladi.



Natijaviy ma'lumotlarimizni esa `y_predict` qiymatga o'zlashtiramiz.[11]

```
from sklearn.neighbors import  
KNeighborsClassifier  
knn = KNeighborsClassifier(n_neighbors=5) #  
k-ni qiymati  
knn.fit(X_train, y_train)  
y_predict = knn.predict(X_test)
```

```
y_predict  
  
array([0, 1, 1, 0, 0, 0, 1, 1, 0, 1, 0, 1, 1, 0, 0, 0, 1, 0, 0, 0, 0, 0,  
0, 0, 1, 1, 1, 0, 1, 0, 1, 1, 0, 1, 0, 0, 0, 1, 0, 0, 0, 1, 1,  
0, 0, 1, 1, 0, 0, 0, 0, 1, 1, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0,  
1, 0, 0, 0, 0, 1, 1, 0, 0, 1, 1, 0, 0, 1, 0, 0, 0, 0, 0, 1, 0,  
0, 1, 0, 0, 0, 0, 0, 1, 1, 0, 0, 0, 0, 0, 1, 1, 0, 1, 0, 0, 0,  
1, 0, 0, 0, 1, 0, 0, 1, 1, 0, 1, 0, 0, 1, 0, 0, 0, 0, 0, 1, 0,  
1, 1, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 1, 0, 1, 1, 1, 0, 0],  
dtype=int64)
```

5-rasm. Model yordamida bashorat qilingan qiymatlar.

Xulosa. Tibbiy tashxis qo'yish jarayonida klassifikatsiya algoritmlaridan foydalanish zamonaviy sog'liqni saqlash tizimining ajralmas qismiga aylanmoqda. Ushbu tadqiqotda tibbiy ma'lumotlarni tahlil qilish va sinflarga ajratishda Naive Bayes, k-Nearest Neighbors (kNN), Support Vector Machine (SVM), va Decision Tree kabi algoritmlarning qo'llanilishi tahlil qilindi. Shuningdek, ushbu usullardan foydalanish sog'liqni saqlash tizimida quyidagi imkoniyatlarni taqdim etadi:

-Diagnostika jarayonlarini avtomatlashtirish orqali bemorlarni samarali davolashni tashkil qilish.

-Sun'iy intellekt texnologiyalarini integratsiya qilish orqali diagnostika sifatini oshirish.

-Resurslardan samarali foydalanib, shifokorlar ish yukini kamaytirish.

Kelajakda klassifikatsiya algoritmlarini yanada rivojlantirish va ularni tibbiyot tizimlariga kengroq integratsiya qilish tashxis aniqligini oshirishga hamda sog'liqni saqlash tizimini innovatsion bosqichga olib chiqishga xizmat qiladi. Shunday qilib, klassifikatsiya algoritmlarining tibbiyotda qo'llanilishi kelajakdagi ilmiy va amaliy tadqiqotlar uchun dolzarb masala bo'lib qoladi.

Foydalanilgan Adabiyotlar.

1. Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill.
2. Han, J., Kamber, M., & Pei, J. (2011). *Data Mining: Concepts and Techniques*.
3. Zhang, H. (2004). *The Optimality of Naive Bayes*. Proceedings of the Seventeenth International Florida Artificial Intelligence Research Society Conference.
4. Khatamjonovich, F. M. (2024). Information Security Threats: Concept, Classification and its Place in the Framework of the National Security Strategy. *Miasto Przyszłości*, 53, 1126–1127. Retrieved from <http://miastoprzyszlosci.com.pl/index.php/mp/article/view/5015>
5. Abdumalik, X., & Muhammadali, F. (2024). THE ETHICAL CONSIDERATIONS OF TECHNOLOGY ADVANCEMENTS, SUCH AS PRIVACY AND SURVEILLANCE ISSUES. *Universum: технические науки*, 6(6 (123)), 48-49.
6. Khalilov, D., Bozorova, S., Khonturaev, S., Khoitkulov, A., Sotvoldieva, D., & Toshmatov, S. (2024, November). Self-learning system and methods of selection of weight coefficients of neural network. In *E3S Web of Conferences* (Vol. 508, p. 04011). EDP Sciences.
7. Khonturaev, S. I., & ugli Kodirov, A. A. (2023). REVOLUTIONIZING COTTON PICKING: THE ROLE OF AI IN AGRICULTURE. *Educational Research in Universal Sciences*, 2(10), 354-356.
8. SARVINOZ, T. (2023). DESIGN OF THE PREPARATION PROCESS SYSTEM FOR EVALUATION SYSTEMS IN SCHOOLS. *International Multidisciplinary Journal for Research & Development*, 10(11).
9. Sarvinoz, T., & Madina, K. (2023). INVESTIGATION INTO LOCAL NETWORKS: TRAITS, VARIETIES, AND TRANSPORT LAYER PROTOCOLS. *Yangi O'zbekiston taraqqiyotida tadqiqotlarni o'rni va rivojlanish omillari*, 2(2), 116-126.
10. Каримов С. И. Структурная стратегия формирования дистанционного мониторинга земель сельскохозяйственного назначения // *Современные методы прикладной математики, теории управления и компьютерных технологий (ПМТУКТ-2021)*. – 2021. – С. 59-62.
11. Sotvoldieva, D. (2023). Frequency analysis of the signal. *Best Journal of Innovation in Science, Research and Development*, 2(11), 693-699.



ELEKTRON TIJORAT TIZIMLARINI STRATEGIK BOSHQARISHNING INSTRUMENTAL VOSITALARI

Yakubov Maksadxon Sultoniyazovich,
Muhammad al-Xorazmiy nomidagi TATU professori,
yakubovmaksadhan@gmail.com

Yuldashov Raxmon Xusanovich,
Muhammad al-Xorazmiy nomidagi TATU
o'qituvchisi,
yuldashev03@mail.ru

Annotatsiya: Maqola elektron tijorat sohasini rivojlanishida elektron tijorat kompaniyalari uchun biznes sikl modeli, uning bosqichlarining AT ta'sirida o'zgarishi taqqoslangan holda o'rganildi an'anaviy sektordagi kompaniyalarning tijorat siklining bosqichlari, elektron tijorat tizimining ta'rifi joriy etildi va unga asoslandi. Tizimli tahlil nazariyasi o'zining funksional modelini ishlab chiqdi va elektron tijorat axborot tizimi ham belgilangan, uning tuzilishi modeli ishlab chiqildi va o'rganildi va mavjud usullarni bevosita qo'llash mumkin emasligi ko'rsatildi. Metodologiyani ishlab chiqish uchun asos bo'lgan ET tizimlari strategik boshqaruv metodikasini yaratish uchun asos sifatida taklif qilingan.

Kalit so'zlar: elektron tijorat, iqtisodiy sektor, axborot tizimlari, internet resurslari, korporativ strategiyalar, funksional modellar, monitoring vositasi, boshqaruv vositasi, asbobni amalga oshirish

Kirish. Elektron tijorat sohasida amalga oshirilayotgan loyihalar soni elektron tijorat tizimlari (ETT) tashqi muhit talablarining tez-tez o'zgarishi bilan izohlanadi.

Birinchidan, bu elektron tijorat axborot tizimlari (ET AT) orqali ETT bilan o'zaro aloqada bo'lgan ishtirokchilarga ma'lumotlarni taqdim etish hajmi va shakllarining doimiy o'zgarishi.

Ikkinchidan, bu iqtisodiyotning an'anaviy sektoridan tarmoq sektoriga o'tish davrida resurslardan biri toifasidan elektron kompleksning asosiy infratuzilma elementiga aylantirilgan elektron kompleks axborot tizimining ishlashiga qo'yiladigan talablarning o'zgarishi.

Uchinchidan, foydalanuvchilarning elektron tijorat axborot tizimlarining funktsionalligiga bo'lgan talablari ortdi, bu uning mijoz-kompaniyalarning biznes jarayonlariga tobora ortib borayotgan integratsiyalashuvida, shuningdek, elektron tijorat axborot tizimlari va ularning ichki axborot tizimlari o'rtasidagi o'zaro aloqaga bo'lgan ehtiyojda namoyon bo'lmoqda. ET tizimlari uchun uning ichki va tashqi muhitini birlashtiradigan yagona axborot maydonini

yaratish zarurati paydo bo'ldi. ET sohasida amalga oshirilayotgan loyihalarning sanab o'tilgan xususiyatlarining paydo bo'lish sabablarini tahlil qilish elektron tijorat sohasida faoliyat yurituvchi kompaniyalar uchun ixtisoslashtirilgan boshqaruv vositalarining amalda yo'qligini ko'rsatadi. Elektron ta'lim sohasidagi ko'pgina dasturiy ta'minot ishlanmalarining kamchiliklari, asosan, elektron ta'lim axborot tizimlarini strategik boshqarish bo'yicha amaliyotning etishmasligi bilan bog'liq bo'lib, bu, odatda, an'anaviy korporativ axborot tizimlaridan foydalanish uchun ham xosdir. Korporativ miqyosdagi strategiyalarning, xususan, AT strategiyalarining yo'qligi, shuningdek, strategik rejaning AT bilan bog'liq qismi korporativ strategiyalarga kiritilmaganligi uslubiy xususiyatga ega va mamlakatda qo'llaniladigan axborot tizimlarining hayot davrlari uchun amaldagi standartlarning mazmuni bilan tasdiqlanadi.

AT va biznes yechimlarining, ayniqsa ET tizimlarida hali ham zaif integratsiyalashuvi, shuningdek, strategik boshqaruvning to'liq siklini qo'llashning noyob amaliyoti ko'pincha bir oy, chorak



yoki yarim yil uchun juda qisqa muddatlarga mo'ljallangan "lahzali" boshqaruv modellariga o'tishga olib keladi. Bu AT va biznesni rivojlantirish yo'nalishidagi nomuvofiqlikka olib keladi. Buning oqibati raqobatdosh ustunliklarning yo'qolishi, kompaniyaning biznes jarayonlarining samarasizligi va tashrif buyuruvchilarning noroziligidir. Kompaniyaning Internet-resurslari, saytning Internet muhitidagi past pozitsiyalari, shuningdek, ET tizimining umumiy holatiga salbiy ta'sir ko'rsatadigan boshqa salbiy oqibatlar. Misol uchun, statistik ma'lumotlarga ko'ra, barcha kompaniyalarning moliyaviy yo'qotishlarining 28 foizi AT strategiyasi va biznes strategiyasi o'rtasidagi nomuvofiqlik bilan bog'liq. Boshqa tomondan, strategik boshqaruvning to'liq tsikli o'z ichiga olgan usullar va ularni qo'llab-quvvatlashning instrumental vositalari amalda ishlab chiqilmagan. Shu nuqtai nazardan, AT tizimini rivojlantirish va biznesni rivojlantirish yo'nalishlarini instrumental vositalar yordamida amalga oshiriladigan strategik boshqaruvning yagona usulida birlashtirgan ish elektron tijorat sohasida faoliyat yurituvchi kompaniyalar uchun juda dolzarb ko'rinadi va ilmiy va amaliy ahamiyatga ega.

Metodologiya. Axborot texnologiyalari ijtimoiy sohaga va iqtisodiy faoliyatga katta ta'sir ko'rsatadi, bu axborot jamiyatining mavjud talqinlaridan kelib chiqadi (Vebster tomonidan qilingan bunday talqinlarni tizimlashtirishda). AT ning iqtisodiy faoliyatga ta'sirini o'rganishda biz iqtisodiyotning kontseptual apparatining ajralmas qismi bo'lgan va shu bilan birga AT ning iqtisodiy tizimlarga ta'sirining jiddiyligini tushunish uchun asos bo'lgan "iqtisodiy sub'ekt (AT)" va "iqtisodiy munosabatlar (IM)" tushunchalarini ko'rib chiqamiz (faqat kompaniyalarda). ET asosiy infratuzilma elementi bo'lib, uning barcha faoliyatining asosini tashkil qiladi. Biroq, ET kompaniyasi va an'anaviy kompaniyani boshqarishda tafovutlar mavjudmi va agar shunday bo'lsa, ET kompaniyasini boshqarish usullari nimani o'z ichiga olishi kerakligi haqidagi savol, bu bosqichda ixtisoslashtirilgan adabiyotlarda hali ham kam o'rganilgan. Ushbu savolga javob berish uchun bobda kompaniya faoliyatining o'ziga xos

xususiyatlari uning tashqi va ichki muhiti nuqtai nazaridan alohida ko'rib chiqiladi. ET ta'rifini aniq tushunmasdan, ET kompaniyasining tashqi muhitini tavsiflash mumkin emas. Ilmiy adabiyotlarda mavjud bo'lgan ta'riflar ET sohasining bir ma'noli talqinini tashkil etmaydi. Aniq ta'riflarning yo'qligi paradoksal oqibatlarga olib keladi: ET kompaniyasining ichki va tashqi muhiti chegaralarini aniqlashning mumkin emasligi. ET hududi ta'rifini aniqlashtirish uchun A.Yurasov tomonidan ET ta'riflarining tasnifi asos qilib olindi. Uning tanqidiy tahlili natijasida biz ET ta'rifiga aniqlik kiritdik.

Ushbu maqolada elektron tijorat deganda, yagona tashkiliy tuzilma bilan bog'lanmagan, foyda olishga qaratilgan va axborot texnologiyalari, xususan, telekommunikatsiya tarmoqlari yordamida amalga oshiriladigan yakka tartibdagi xo'jalik yurituvchi sub'ektlarning tijorat tadbirkorlik faoliyati tushuniladi. ET kompaniyasining tashqi muhitining o'ziga xos xususiyatlarini aniqlash uchun ET sohasidagi kompaniyalar faoliyatining amaliy misollari va ET bo'yicha nazariy ishlar tahlili, xo'jalik yurituvchi sub'ektlar va ular o'rtasidagi ET sohasidagi munosabatlar o'rganiladi. Turli aktyorlar o'rtasidagi o'ziga xos o'zaro ta'sirlar elektron tijorat sektorlarini shakllantiradi. Ish birinchi marta ET sektorlarining to'liq ro'yxatini tuzadi va ularning qisqacha tavsifini beradi. AT ta'sirida shakllangan iqtisodiy munosabatlarning mazmuni tijorat siklining ETda tuzilishi, bosqichlarning funksional mazmuni va ularning AT ta'sirida o'zgarishi o'rganiladi;

kompaniyasining ichki muhitini o'rganish uchun tizimli tahlil nazariyasi murakkab tizimlarni har tomonlama o'rganish uchun eng muhim va amalda qo'llaniladigan usul sifatida qo'llaniladi (shubhasiz, biz ET kompaniyasini kiritishimiz mumkin). Bu yerda biz kompaniya ichidagi barcha elementlarning birligi va o'zaro bog'liqligini, kompaniyaning tashqi muhitini va tadqiqotning tizimli xususiyatini ta'kidlash uchun "ET kompaniyasi" atamasidan "ET tizimi" (ETT) atamasiga o'tamiz. Shuningdek, ET ning ma'lum bir shartli tizimi tadqiqot ob'ekti sifatida tanlanganligini hisobga olib, biz "odatiy ETT" tushunchasini kiritamiz. Ikkinchisi ETning shartli tizimi, shu jumladan ETning



har qanday sektori va har qanday faoliyat sohasi uchun xarakterli bo'lgan ichki va tashqi muhit elementlarining bunday turlarini o'z ichiga olgan holda tushuniladi.

Elektron boshqaruv tizimining axborot tizimi (ET AT) ishda elektron boshqaruv tizimining funksional modeli elementlarining ishlashini ta'minlaydigan asos sifatida ajralib turadi va asosiy infratuzilma elementi hisoblanadi. Keling, AT ETni dasturiy ta'minot tizimlari va apparat (texnik) vositalar majmuasi sifatida aniqlaylik, kompaniyaning Internet muhitida (elektron tijoratda), ularda aylanayotgan ma'lumotlar va ushbu dasturiy tizimlardan foydalanuvchilarning mavjudligi va ishlashini ta'minlash. Ammo elektron tijorat AT ham murakkab tizimdir. Bu uning elementlarini ko'rib chiqish zarurligiga olib keladi, ularning har biri o'ziga xos xususiyatlarga ega va ET tizimining ichki muhiti xususiyatlarining ajralmas qismidir. Elektron tijorat axborot tizimining strukturasi (arxitekturasi) o'rganish elektron tijorat axborot tizimining elementlarini to'rtta odatiy darajada: tashkiliy, funksional, dasturiy va texnik darajada ko'rib chiqish asosida amalga oshiriladi.

Amalga oshirish strategik boshqaruv metodologiyasi (SBM) (har qanday boshqa usul kabi) o'zaro bog'liq bo'lgan bosqichlar ro'yxati shaklida qaror qabul qiluvchining (QQQ) harakatlarining izchil tavsifidir. Ilmiy adabiyotlarda ularning yagona ro'yxati yo'qligi sababli ko'plab bunday bosqichlarni shakllantirishning mavjud usullarini tizimlashtirmoqdamiz. Tizimlashtirish natijasi bo'limda ularning mazmuni tavsiflangan boshqaruv tizimining odatiy bosqichlari ishlab chiqilgan. ET tizimlarida mavjud strategik boshqaruv usullarini qo'llash imkoniyatlarini tahlil qilish uchun biz xususiyatlar va ko'rsatkichlar to'plamiga asoslangan va moliyaviy, ehtimollik va sifat usullarini o'z ichiga olgan bunday usullarning yagona mavjud tasnifidan foydalanamiz. Ushbu tasnifni tanqidiy ko'rib chiqqan holda, maqola odatda ET tizimiga strategik boshqaruv usullarini qo'llash imkoniyatini tahlil qiladi. Tahlil natijasida ETT standartining talablari "sifatli usullar" guruhidagi usullar bilan eng ko'p (lekin to'liq emas)

qondiriladi degan xulosaga keldi, ulardan biri - BKK bugungi kunda eng universal va juda keng tarqalgan.

D.Kaplan va R.Nortonning Balanslangan ko'rsatkichlar kartasi g'oyalariga asoslanib, biz Balanslangan ko'rsatkichlar tizimida taklif qilingan boshqaruv tizimining bosqichlari mazmunini ularni tipik ETTda qo'llash imkoniyatlarini tanqidiy tahlil qilamiz. Natijada, vazifalar ro'yxati shakllantiriladi, ularni hal qilish tipik ETTning "o'ziga xos xususiyatlari" ni qondiradigan boshqaruv tizimi metodologiyasini olish imkonini beradi (ko'rsatkichlar to'plamini shakllantirish, boshqaruvning strategik va operatsion darajalari o'rtasidagi rasmiylashtirilgan munosabatlarni ta'minlash, ko'rsatkichlar makonini muvozanatlash, boshqaruv tizimini strategik ko'rsatkichlarni amalga oshirish vositasiga aylantirish, strategik boshqaruv vositasiga aylantirish o'zgartirilgan BKK metodologiyasi).

Strategik menejment metodologiyasi ularning juda aniq to'plamini keyinchalik tanlash va ularni strategik rejaga kiritish uchun odatiy ko'rsatkichlar to'plamini (strategik ko'rsatkichlar deb ataladi), strategik rejani tuzish va tekshirish qoidalarini, strategik reja asosida taktik va tezkor qarorlarni qabul qilish qoidalarini, agar zarur bo'lsa, uni amalga oshirish qoidalarini o'z ichiga olishi kerak metodologiyaning tarkibi asosiy hisoblanadi. U strategik boshqaruv usullarining odatiy bosqichlarini tahlil qilish natijalari asosida shakllantirildi. Oddiy strategik boshqaruv metodologiyasida ko'rsatkichlar tizimini (AT) shakllantirish uchun odatiy ETT ning tashqi va ichki muhitini tahlil qilish natijalari qo'llaniladi. Biz BKK uchun an'anaviy bo'lgan to'rtta asosiy strategik istiqbollarni to'plamini ("Moliya", "Mijozlar", "Biznes jarayonlari" va "O'qitish va rivojlantirish") ikkita istiqbol bo'yicha kengaytiramiz: "Axborot tizimlari" va "Tashqi Internet muhiti". Buning sababi shundaki, "biznes jarayonlari" nuqtai nazari faqat tashkilot ichida sodir bo'ladigan jarayonlarni aks ettiradi va ma'lum bir elementda sodir bo'ladigan jarayonlarga hech qanday ta'sir ko'rsatmaydi. ETT - AT ET, shuningdek, biznes-jarayon tushunchasining o'zi faqat ichki jarayonlarni nazarda tutganligi sababli, biznes-jarayonlarning



istiqboli ETTning strategik rejasiga bevosita ta'sir ko'rsatadigan barcha tashqi jarayonlarni o'z ichiga olmaydi. [1,5,8,9]

Strategik ko'rsatkichlar tizimini ishlab chiqishning boshlang'ich nuqtasi sifatida (uning amaliy ahamiyati kattaroq bo'lishi uchun) biz indikatorni odatiy ET tizimining IS laridan birida mavjud bo'lgan ma'lumotlar asosida hisoblash kerak degan fikrni qabul qilamiz. Biz kiritgan talablar Z.Vinogradova tomonidan taklif etilgan ETT uchun maqbul bo'lgan interaktiv strategik boshqaruvning yagona konsepsiyasini amalga oshirish imkonini beradi. Oddiy ETT uchun strategik ko'rsatkichlar to'plamini aniqlash uchun ishda tipik ETT predmeti ob'ektlarining umumiy infologik modeli shakllantiriladi, uning mazmuni tipik ETTning turli ISlarida saqlanadi, shuningdek ishda alohida aniqlangan. Butun infologik model quyidagi qismlarga bo'lingan: kompaniyaning mijozlar bazasi, moliyaviy ma'lumotlar va buyurtmalarni bajarish, marketing, xizmat ko'rsatish va qo'llab-quvvatlash, ET funktsiyalari va ichki jarayonlari, statistik ma'lumotlar va Internet ko'rsatkichlari, ET EX faoliyatining fizik parametrlari.

Biz BKK kontsepsiyasiga muvofiq strategik ko'rsatkichlar tizimini har bir istiqbol uchun strategik ko'rsatkichlar xaritalari (SIM) ko'rinishida taqdim etamiz. Maqolada ko'rsatkichlarning o'zaro ta'sirini belgilashni ta'sir darajasini belgilash bilan to'ldirish nuqtai nazaridan strategik ko'rsatkichlar xaritalarini tuzish usuli ishlab chiqilgan. Ushbu ishlanma bizga belgilangan maqsadli qiymatlarning muvofiqligini tekshirish va butun ko'rsatkichlar tizimi miqyosida strategik ko'rsatkichlarning oraliq qiymatlarini hisoblash imkonini beradi. Shuni ta'kidlash kerakki, BKK strategik maqsadlarning muvofiqligini tekshirish yoki ko'rsatkichlarning oraliq qiymatlarini hisoblash bo'yicha hech qanday operatsiyalarni nazarda tutmaydi. ET tizimlarining tashqi va ichki muhiti to'g'risida ilgari to'plangan ma'lumotlar, shuningdek, uning infologik modeli asosida biz barcha oltita istiqbol bo'yicha strategik ko'rsatkichlar xaritalarini ishlab chiqamiz va ko'rsatkichlar tizimini rasmiylashtiramiz. Strategik boshqaruv metodologiyasida biz "strategik ko'rsatkich"

tushunchasidan "strategik ko'rsatkich" tushunchasiga o'tamiz, uni strategik rejaga kiritilgan har qanday ko'rsatkich sifatida tushunamiz. Bu odatiy ET ning ilgari shakllantirilgan o'ziga xos xususiyatlari tufayli o'ndan o'n beshgacha asosiy ko'rsatkichlar asosida ET tizimlarini boshqarishning mumkin emasligi bilan bog'liq. Boshqalardan tashqari, biz strategiya ko'rsatkichiga ikkita asosiy atributni kiritamiz: boshqaruv darajasi va bo'linish va / yoki kompaniyadagi faoliyat yo'nalishi. Biz ishlab chiqayotgan metodologiyada biz boshqaruvning barcha darajalarida yagona strategiya ko'rsatkichlaridan foydalanamiz, bu butun ET tizimida strategik rejaning yaxlitligi talabi bilan bog'liq. Boshqaruvning turli darajalaridagi ko'rsatkichlar o'rtasidagi farq faqat umumlashtirish darajasida bo'ladi: ko'rsatkich yuqori darajaga qanchalik yaqin bo'lsa, uning atributlari-belgilarida mavjud bo'lgan qiymatlar shunchalik umumiy bo'ladi

$$P_{ij} = \sum_{k=1}^K \sum_{l=1}^L P_{ijkl}.i, j, k, l - \text{bitta nomli } P$$
 indikatorining rekvizitlari.

Har bir aniq ET tizimida ko'rsatkichlar to'plamini shakllantirish uchun hujjat ikkita yondashuvni taklif qiladi: yuqori boshqaruvni qiziqtiradigan yuqori darajadagi strategiya ko'rsatkichlarini aniqlash va ularni ET tizimining faoliyati va tuzilishining o'ziga xos xususiyatlariga muvofiq ajratish yoki bo'limlardan zarur bo'lgan strategiya ko'rsatkichlarining butun majmuasini yig'ish va keyinchalik ularni yuqori darajadagi ko'rsatkichlarga jamlash. BKK strategik ko'rsatkichlar uchun maqsadli qiymatlarni belgilashni o'z zimmasiga oladi, faqat yuqoridan pastgacha bo'lgan mutaxassislar kompaniyaning KPI qiymatlarini aniqlaydilar, keyinchalik ular amalga oshirish uchun mas'ul shaxslarga o'tkaziladi. Biroq, byudjetlashtirish texnologiyasiga o'xshab, biz ko'rsatkichlarning maqsadli qiymatlarini bir vaqtning o'zida ikkita usulda, menejerning xohishiga ko'ra, yuqoridan yoki pastdan yuqoriga o'rnatish algoritmlarini ishlab chiqmoqdamiz. Bu ishlab chiqilgan MSUni muayyan vaziyatlarda qo'llashda moslashuvchanlikni ta'minlaydi, chunki har bir kompaniyada umumiy maqsadlarni ishlab chiqish modeli markazlashtirilgan



yoki markazlashtirilmagan bo'lishi mumkin. Birinchi va ikkinchi algoritmlardan foydalanganda, mavjud resurslarga asoslangan strategiya ko'rsatkichlarining maqsadli qiymatlarini optimallashtirish muammosini hal qilish maqsadli funktsiya va mumkin bo'lgan echimlar maydoni yo'qligi sababli nomaqbul deb hisoblanadi. Taklif etilayotgan ko'p darajali strategiya ko'rsatkichlari tizimida menejer tomonidan belgilangan maqsadli qiymatlardagi nomuvofiqliklar ehtimoli keskin oshadi. Bunday nomuvofiqlikning natijasi ETT faoliyatining alohida yo'nalishlarining ko'p qirrali rivojlanishi va strategik rejani amalga oshirmaslik ehtimoli bo'ladi.

Strategiya ko'rsatkichlarining butun tizimining belgilangan maqsadli qiymatlari muvofiqligini tekshirish uchun ishlab chiqilgan algoritm quyidagi shaklga ega.

Keling, belgilaymiz P_{ijk} i-chi ko'rsatkichning qiymati, $a - \Delta_{ijk}$ j - darajadagi ko'rsatkich qiymatining istalgan o'zgarishi ($\bar{t} = [1 \ I]$), ($\bar{J} = [0 \ J]$) erda 0 - korporativ daraja), k -chi bo'linma yoki kompaniya faoliyatining funktsional sohasi ($\bar{K} = [0 \ K]$) bu yerda 0 - korporativ darajadagi). Kelajakda j, k indekslari va ko'rsatkichlarning qo'shimcha atributlari-xususiyatlarini aks ettiruvchi boshqa mumkin bo'lgan indekslar o'tkazib yuboriladi, chunki taklif etilayotgan metodologiya ixtiyoriy atribut-xususiyatlar to'plamiga teng ravishda qo'llanilishi mumkin.

Keling, $\int_i^a(\bar{\Delta}, P_i)$ i-indikator qiymatining o'zgarishining ko'rsatkichlar qiymatlari $\bar{\Delta}$ va indikatorning dastlabki holatidagi o'zgarishlar to'plamiga funktsional bog'liqligini belgilaylik, P_i bu yerda $\bar{a}_i = [1 \ A_i]$ i -indikator qiymatining boshqa strategiya ko'rsatkichlarining turli kombinatsiyalari qiymatlarining o'zgarishiga turli funktsional bog'liqliklari mavjud. Ko'rsatkichlar qiymatlaridagi hisoblangan o'zgarishlar vektorini \bar{D} vektor bilan va vektor bilan belgilaymiz \bar{T} O'zgarishlarning rejalashtirilgan va hisoblangan qiymatlarining og'ishlar vektori, bu yerda $d_{i=(t_1 - \Delta_i)}$ (1)

1-qadam. Keling, vektor elementlarining qiymatini hisoblaylik \bar{O} , bu ko'rsatkich qiymatining

boshqa ko'rsatkichlar qiymatining o'zgarishiga bog'liqlik tartibini ko'rsatadi. Xuddi o'sha payt O_i maksimalga teng bo'ladi ($O_{it} + 1$) (buning uchun $\exists \int_{il}^a(\bar{\Delta}, P_{il})$ 1-ko'rsatkichdan uchun $\forall a \in \bar{a}_{il}$ va qaerda $il \neq i$), yoki 0 ga teng bo'ladi. Shunday qilib, vektor \bar{O} boshqasiga bog'liq bo'lmagan va 0-tartibga ega bo'lgan ko'rsatkichlardani ko'rsatkichining tartibini ("uzoqlik") o'z ichiga oladi.

2-bosqich barcha ko'rsatkichlar uchun o'rnatiladi i, bu yerda $O_i = 0$ maqsadli $d_i = 0$ qiymatdagi o'zgarishlarning hisoblangan qiymati $t_i = \Delta_i, p$

3-qadam: barcha i ko'rsatkichlari uchun $O_i = 1$ o'zgarish qiymatlarini hisoblang, bu t_1 erda $t_1 = \sum_{a=1}^{A_i} \int_1^0(\bar{\Delta}, P_1)$ (2)

Qadam-(n) (3-bosqichdan boshlab va undan keyingi barcha darajalar 0 dan maksimalgacha) biz (\bar{O}) barcha ko'rsatkichlar uchun o'zgarishlar qiymatlarini hisoblaymiz i, bu yerda $0, = (t_1, n - 2)$ vektor $t_i = \sum_{a=1}^{A_i} \int_1^0 f_1^a(\bar{\Delta} + \bar{T}, P_i)$ bu yerda \bar{T} indikatorlar orasidagi funktsional munosabatlarga asoslangan holda hisoblangan ofsetlar Qadam - (n + 1) biz hisoblangan qiymatlarning rejalashtirilganidan og'ishlarini hisoblaymiz $d_i = (t_i - \Delta_i) > 0$ bo'lgan barcha 1 uchun O_i .

Og'ish d_i , kompaniyaning ishi nuqtai nazaridan ham "normal" bo'lish, ham "nomaqbul" bo'lish. Agar "keraksiz" og'ishlar olingan bo'lsa, algoritmnin 3 dan n gacha bo'lgan bosqichlarida olingan t qiymatlarini tahlil qilish orqali ushbu og'ishning sababini aniqlash kerak.

Strategik rejaga strategiya ko'rsatkichlari va ularning maqsadli qiymatlaridan tashqari strategik tashabbuslar (SI) kiritilgan. BKKda strategik tashabbuslarni taqdim etish strategiya ko'rsatkichlarining kutilayotgan oraliq qiymatlarini hisoblash va butun reja uchun ham, uning har bir bosqichida ham strategik tashabbuslarni amalga oshirish uchun moliyaviy bo'lmagan resurslar xarajatlarini baholashga imkon bermaydi. Hujjat ushbu muammoni hal qilishni taklif qiladi.



Boshlanish sanalari to'plamini E_m tashabbuslarning tugash sanalari to'plami bilan m bilan $\bar{m} = [1 M]$ belgilaymiz, bu yerda B_m matritsa Z^R o'lchovli matritsadir ($1 M, 1 L$), $\bar{l} = [1 L]$ bu yerda butun strategik reja doirasidagi haftalar Z_{ml}^R - tashabbusni amalga oshirishda R resursining xarajatlari m , 1-haftada ishlab chiqarilgan, V_i o'lchamli matritsa ($1 M, 1 L$), unda v_{ilm} 1-haftada ishlab chiqarilgan tashabbusni amalga oshirishning i -chi ko'rsatkichiga kutilayotgan ta'sir 1-haftada ishlab chiqarilgan 1-indikator qiymatining kutilayotgan o'zgarishi bo'lgan o'lchovli X matritsasini ($1 I, 1 L$) matritsasi bilan belgilaymiz. x_{il} Strategiya ko'rsatkichlarining oraliq qiymatlarini hisoblash uchun ishlab chiqilgan algoritm quyidagi shaklga ega.

Strategiya ko'rsatkichining qiymatiga S_{ni} amalga oshirish va mustaqil omillar ta'sir qiladi, shuning uchun 1-hafta oxiri uchun

$$P_i^l = P_1^0 + \sum_{m=1}^M v_{ilm+x_{il}} \quad (3) \quad \text{qayerda } b_m < 1 \text{ va } e_m \geq 1, l = 1$$

Ko'rsatkich qiymatining umumiy o'zgarishi formuladan foydalanib hisoblab chiqiladi $\Delta_i^1 = P_i^1 - P_i^0$ (4)

Shuning uchun, ko'rsatkichlarning yakuniy qiymatlari, ular orasidagi funktsional bog'liqliklarni hisobga olgan holda, 1-hafta oxirida teng bo'ladi.

$$P_i^1 = \sum_{o=1}^{\max(\bar{O})} \sum_{a=1}^{A_i} f_1^a(\bar{\Delta}, P_1^1) \quad (5)$$

I_1 dan I_2 gacha bo'lgan davr uchun resurs xarajatlari yig'indisi formuladan foydalanib hisoblanadi

$$TZ_{l2}^{Rli} = \sum_{m=l}^M \sum_{l=il}^{l2} Z_{ml}^R \quad (6)$$

O'z navbatida, xuddi shu davr uchun ma'lum bir tashabbusni m amalga oshirish uchun resurs xarajatlari teng bo'ladi

$$TZ_{ml2}^{Rli} = \sum_{l=il}^{l2} Z_{ml}^R \quad (7)$$

Davr uchun (3), (4), (5) va (6) bosqichlarni bajargandan so'ng, $l_1 = 0$ $l_2 = 1$, xuddi shunday harakatlarni L gacha bo'lgan barcha davrlar uchun ketma-ket bajarish kerak. $I_1 = 1$ $I_2 = 2$ до $I_1 = (L)$ $I_2 = L$ (algoritm #2)

$$P_i^{l2} = P_i^{l1} + \sum_{m=1}^M v_{il2m} +$$

$$x_{il2} \quad (8),$$

qayerda $b_m < 1$ $v_{ae_m} > 1$ $\bar{\Delta}_l = P_i^{l2} - P_i^{l1}$ hamma uchun i (9);

$$P_i^{l2} = \sum_{o=1}^{\max(\bar{O})} \sum_{a=1}^{A_i} f_1^a(\bar{\Delta}^1, P_1^{l1}) \quad (10),$$

$$TZ_{l2}^{Rl1} = \sum_{m=1}^M \sum_{l=l1}^{l2} Z_{ml}^R \quad (11)$$

Strategik rejalashtirish jarayonida kompaniya odatda strategik rejaning bir nechta versiyalarini ishlab chiqadi. Bunda menejer muqobil variantlardan birini tanlash muammosiga duch keladi. Maqolada ierarxik tahlil usuli (ITU) asosida strategik alternativlarni tanlash muammosini hal qilish algoritmi yaratilgan. ITU ning rivojlanishi uning ierarxiya darajalarini belgilash va strategik alternativlarni baholash algoritmini ishlab chiqish asosida A_{ni} tanlash muammosini hal qilish uchun qo'llanilishini tavsiflovchi qismda ifodalangan (1) bu ITU dan foydalanishning maqsadi, (2) korporativ strategiyani tanlash vaqtida mavjud bo'lgan mezonlar guruhi. Bunday mezonlar guruhlariga resurslar xarajatlari, xavflar, strategiyani amalga oshirishning ma'lum bir bosqichidagi strategiya ko'rsatkichlarining oraliq qiymatlari va miqdoriy bahoga ega bo'lgan boshqa mezonlar guruhlari, (3) u yoki bu mezonlar guruhiga tegishli ko'rsatkichlar, masalan, resurslar guruhida inson, moliyaviy, hisoblash yoki boshqa resurslarning umumiy xarajatlari bo'lishi mumkin. O'z navbatida, strategik alternativaning o'zi uchinchi darajali ko'rsatkichlarning har birining ma'lum qiymatlari bilan ifodalanadi.

Strategik alternativani tanlash uchun p -guruh mezonlarining ahamiyati uchun quyidagi belgilarni kiritamiz. W_p W_p qiymatlari qaror qabul qiluvchi tomonidan ularning yig'indisi 1 ga teng bo'lishi uchun tanlanadi, W P_t^p - mezonlarning p -guruhidagi 1-ko'rsatkichning ahamiyati, u ham qaror qabul qiluvchi tomonidan har bir mezonlar guruhida ularning yig'indisi 1 ga teng bo'lishi sharti bilan tanlanadi, T - bu C_s^t ko'rsatkichlar bo'yicha 1-guruh ko'rsatkichlariga muvofiqlik darajasi missiya, qarash, dastlabki strategik maqsadlar va qaror qabul qiluvchining strategiyani



amalgam oshirish jarayoni haqidagi g'oyasiga alternativa. TC" qiymatlari qaror qabul qiluvchi tomonidan tanlanadi, shunda ularning i- ko'rsatkich ichidagi yig'indisi 1 ga teng bo'ladi. Keyin s-strategik alternativni baholash quyidagicha hisoblanadi: $o \subset O$
 $C_s = \sum_{p=1}^P (W_p \sum_{i=1}^I (W P_i^p * T C_s^p))$ (12)
eng yuqori bahoga ega bo'lgan muqobilni tanlashi to'g'ri bo'ladi.

BSCda boshqaruvning strategik va operatsion darajalari o'rtasidagi munosabatlar xodimlarni strategik ko'rsatkichlarning belgilangan qiymatlariga erishish uchun rag'batlantirish orqali ta'minlanadi, bu boshqaruvning taktik yoki operatsion darajalarida echimlarni tanlashni qo'llab-quvvatlash uchun rasmiylashtirilgan vositani yaratmaydi. Biz boshqaruvning strategik va operatsion darajalari o'rtasidagi rasmiylashtirilgan munosabatlarning algoritmini taklif qilamiz.

R.Simons kontsepsiyasiga, ko'rsatkichlarning diagnostik va interaktiv tizimlarining mavjudligiga asoslanadi. Operatsion boshqaruvning keyingi bosqichining boshlang'ich nuqtasida ko'rsatkichlar R^l i qiymatlariga ega, bu yerda l_1 - operativ boshqaruv davrining boshlanishi. Bunday holda, R^{l_1} , bu yerda $1 < l_1$ oldingi nazorat nuqtalarida ko'rsatkichlar tomonidan olingan retrospektiv qiymatlarni ko'rsatadi. Diagnostik ko'rsatkichning qiymati sifatida hisoblanadi

$$ag_l^{l_1} = \frac{\sum_{l=0}^{l_1-1} ((R_l^1 - R_1^l))}{l_1 - 1}$$

ko'rsatkichning qiymati sifatida hisoblanadi

$$c_l^l = \frac{\sum_{l=0}^{l_1-1} ((R_l^1 - R_1^l)) - (R_l^1 - R_1^l))}{l_1 - 1}$$

Menejer o'zini qiziqtiradigan strategiya ko'rsatkichlari asosida rekvizitlarning kerakli qiymatlarini hisoblab, u yoki bu taktik yoki operatsion qaror qabul qilishi mumkin. Qarorning mumkin bo'lgan oqibatlarini baholash va uning strategiya ko'rsatkichlarining kelajakdagi qiymatlariga ta'sirini aniqlash uchun ishda quyidagi algoritmi yaratilgan. Kelgusi davr oxirida ko'rsatkichlarning kutilayotgan (prognoz) holati ularga rejalashtirilgan operatsion ta'sirlarning kutilayotgan ta'siri, shuningdek, tashqi

rejalashtirilmagan ta'sir (algoritm No3) asosida hisoblanadi.

Shunday qilib, ko'rsatkichlarning kutilgan qiymati quyidagi formula yordamida hisoblanadi

$$E_t^{l_1} = R_t^{l_1} + \sum_{m=1}^M v_{tm}^{l_1} + w_t^{l_1} + x_t^{l_1},$$

Qayerda $\omega_t^{l_1}$ keyingi davrda operativ harakat ko'rsatkichlari qiymatiga l_1 kutilayotgan ta'sir 1, (+1) gacha.

Operatsion qarorga ta'sir qiladigan ko'rsatkichlarning kutilgan qiymatlarini olgandan so'ng, ularning ma'lum bir davrdagi barcha ko'rsatkichlar tizimiga ta'siri baholanadi. Buning uchun formuladan (10) foydalanishingiz kerak, bu yerda $\overline{\Delta_t^{l_1}} = E_t^{l_1} - P_t^{l_1}$. Barcha ko'rsatkichlar uchun 1, a $P_t^{l_1} = R_t^{l_1}$. Uni qo'llash natijasida biz barcha qiymatlar to'plamini olamiz, $E_t^{l_1}$. keyin strategik rejalashtirish davri oxirigacha ko'rsatkich tizimining barcha qiymatlarini hisoblash uchun biz qiymat $E_t^{l_2}$ o'rniga L dan $P_t^{l_2}$ boshlangan davrlar uchun №2 algoritmi qo'llaymiz $l_1 + 1$ va boshlang'ich qiymatlar o'rniga emas dan foydalaning $P_t^{l_1}$, a $R_t^{l_1}$.

ET tizimlarini strategik boshqarish bo'yicha ishlab chiqilgan metodologiyani amalga oshirish ko'p sonli hisob-kitoblar va ETT strategik boshqaruvining interaktivlik xususiyatini amalga oshirish talabi bilan bog'liq. Ishlab chiqilgan metodologiyani avtomatlashtirish imkonini beruvchi dasturiy ta'minot va vositani ma'lum bir sinfga tegishli yagona (yoki bir nechta kombinatsiya) axborot tizimlaridan foydalanish yoki metodologiyaning o'ziga xos xususiyatlarini amalga oshiradigan prinsiplar yangi dasturiy vositani ishlab chiqish asosida olish mumkin. Hech qanday shubha yo'qki, har qanday yangi ATni ishlab chiqishdan ko'ra turli sinfdagi mavjud AT dan foydalanish maqsadga muvofiqroq bo'ladi. Shu munosabat bilan, ishlab chiqilgan metodologiyaning bosqichlariga muvofiq, biz ATning turli sinflaridan (ERP, OLAP, DM, BRM, CRM, PLM, Q&R, WebLog) foydalanish imkoniyatlarini tahlil qilamiz. tahlil, statistik Internet tizimlari, DSS, CASE, texnologik monitoring tizimlari, DWH, bilim bazalari, IPS) bosqich vazifalarini hal qilish uchun. O'tkazilgan tahlil natijalari shuni ko'rsatdiki, ETTni strategik



boshqarish metodologiyasining barcha bosqichlari (va to'liq emas) mavjud sinflarning IS ning odatiy funktsionalligi asosida avtomatlashtirilishi mumkin emas.

Ishlab chiqilgan metodologiyani avtomatlashtirilmagan fragmentlarsiz avtomatlashtiradigan axborot texnologiyasini olish uchun ishda bir qator quyidagi harakatlar izchil amalga oshiriladi: odatiy EEC ATning dasturiy ta'minot arxitekturasi shakllantiriladi (AT sinflari maxsus dasturiy ta'minot va maxsus o'zaro ta'sir protokollari emas, balki dasturiy ta'minot komponentlari sifatida ko'rsatilgan), mustaqil dasturiy ta'minot tizimlarini jismoniy integratsiyalash usullari bilan bog'liq bo'lgan ET AT texnologiyasini joriy qilish batafsil va elektron tijorat AT ning turli elementlaridan ko'rsatkichlarni yig'ish texnologiyalari variantlari tizimlashtirilgan. [2,3,7]

Ushbu harakatlarning natijasi, hatto asosiy funktsiyalariga qo'shimcha ravishda, IS komponentlaridan ko'rsatkichlarni to'plash imkonini beradigan turli xil sinflarning ko'plab to'liq integratsiyalashgan ISdan foydalanishni asoslashdir. ET, strategik boshqaruvda va ular bilan operatsiyalarda qo'llaniladigan ko'rsatkichlarning to'liqligi uchun tavsiya etilgan metodologiya talablariga javob beradigan to'liq ATni olish hali ham imkonsiz bo'ladi.

ET tizimlari tomonidan SBMni amalga oshirishning mumkin bo'lgan kamchiliklari ishlab chiqilgan SBM ETTni qo'llab-quvvatlash va joriy qilishni ta'minlash uchun printsiplial jihatdan yangi dasturiy vositani (strategik boshqaruv SB - ATSB) yaratish zarur degan xulosaga keladi. Agar usul to'liq avtomatlashtirilmasa, u darhol o'z interaktivligini yo'qotadi. Ishda tavsiflangan strategik boshqaruv axborot tizimi uchun to'liq miqyosli dizayn echimlarini ishlab chiqish uchun hech qanday asos yo'q, chunki biz odatiy ETT, odatiy ko'rsatkichlar va odatiy ETTda qo'llaniladigan axborot tizimlarini ko'rib chiqamiz. Shu munosabat bilan umumiy (kontseptual) darajada dizayn echimlari ishlab chiqilmoqda va kelajakda ular ATSBni ishlab chiqish uchun asos sifatida olinishi mumkin. Barcha mumkin bo'lgan dizayn echimlaridan taklif qilingan ATSB, avtomatlashtirish maqsadlari va

maqsadi, strategik boshqaruv axborot tizimining dasturiy ta'minot arxitekturasi elementlari, funktsional arxitektura, kirish, ma'lumot va natijalar ma'lumotlari, axborot modeli, ER modeli, ATSBni loyihalash va ishlab chiqish loyihasining modulli tuzilishi va bosqichlarini to'liq tushunishga imkon beradiganlar tanlangan.

Strategik menejmentning ishlab chiqilgan metodologiyasi va AT ning ajralmas qismi ularni ET tizimlarida amalga oshirish texnologiyasi bo'lishi kerak, bu esa amaliy qo'llash uchun tayyor tadqiqotni olish imkonini beradi. Ish mazmunini ishlab chiqadi va loyihani amalga oshirish bosqichida bajarilgan vazifalarning o'ziga xos xususiyatlarini aniqlaydi: innovatsiyalarni amalga oshirish maqsadlarini shakllantirish, korxonalar holatini tahlil qilish va uning holatining rasmiy tavsifini yaratish, tizim ma'lumotnomalarini to'ldirish, SBM ETT va hisobot shakllariga muvofiq ishlarni bajarish uchun ichki qoidalarni ishlab chiqish, ATSBni sinovdan o'tkazish natijalarini ishlab chiqish. Amalga oshirish loyihasining sanab o'tilgan vazifalarining oshkor qilingan mazmuni menejerga kompaniyada ATSB va SBM ETTni amalga oshirish bo'yicha o'z loyihasini shakllantirish uchun asos bo'lib xizmat qiladi.

Xulosa. Rasmiylashtirilgan strategik ko'rsatkichlar tizimi elektron tijorat tizimlarining faoliyatini rejalashtirish va monitoring qilish imkonini beradi va BKK usulini mustaqil ravishda kengaytirish imkoniyatini beradi, strategik rejalashtirish metodologiyasi strategiyani ishlab chiqish jarayonining universal rasmiylashtirilishini, operatsion qarorlarning strategiyani amalga oshirishga ta'sirini baholash metodologiyasini ifodalaydi strategik boshqaruv uchun taklif qilingan strategik boshqaruv metodologiyasi bilan birgalikda elektron tijorat tizimlarida qo'llanilishi mumkin.

Foydalanilgan adabiyotlar

1. Лужецкий М.Г. Информационные систем электронной коммерции как объект стратегического планирования // Сборник научных статей М -Компания Ступник, 2004г.



2. Логинова, Ю.В. Моделирование поведения интернетпотребителей на основе сложной вероятностной модели // Ю.В. Логинова // Вестник Кемеровского государственного университета. -2014.- №2 (58) Т1.-С.247-256.
3. Логинова Ю.В. Анализ моделей поведения потребителей в Интернете// Ю.В. Логинова // Вестник ЮРГТУ (НПИ). -2012.-№6.- С.142-148.
4. М Г Лужецкий Применение существующих классов ИС в качествеинструментального средства стратегического управления системами ЭК // Научно-практический журнал «Прикладная информатика» №2 2007.
5. М Г Лужецкий Управление информационными системами электронной коммерции // Научно-практический журнал «Прикладная информатика» №1 2006.
6. М Г Лужецкий (в соавторстве) Автоматизация аналитической работы кредитной организации // Научно-практический журнал «Прикладная информатика» №2 2006.
7. Yuldashov R, Ochilov Sh. “ELEKTRON TIJORATNING ASOSIY MODELLARI VA TAMOYILLARI” “ANIQ VA TABIY FANLARNI RIVOJLANTIRISHDA RAQAMLI TEXNOLOGIYALARNING O‘RNI: MUAMMO VA INNOVATSION YECHIMLAR” mavzusidagi xalqaro ilmiy-texnik anjuman materiallari. Farg‘ona 4-5-oktyabr, 2024-yil. 623-626 bet.
8. Yuldashov R, Ochilov Sh. “APPLICATION OF DIGITAL TECHNOLOGIES IN ELEKTRONIC COMMERCE INFORMATION EXCHANGE PROCESSES” “ANIQ VA TABIY FANLARNI RIVOJLANTIRISHDA RAQAMLI TEXNOLOGIYALARNING O‘RNI: MUAMMO VA INNOVATSION YECHIMLAR” mavzusidagi xalqaro ilmiy-texnik anjuman materiallari. Farg‘ona 4-5-oktyabr, 2024-yil. 655-659 bet.
9. Yuldashov R.H., Azimova U.A. “Алгоритмическое обеспечение рекомендательных систем в сфере электронной коммерции”. Jizzax sambhram universiteti NTM. “ILM-FAN TARAQQIYOTI: INNOVATSION YONDASHUVLAR VA STRATEGIK TAHLILLAR” mavzusida xalqaro ilmiy-texnik konferensiya. Jizzax 2024-yil 11-noyabr 134-136 bet.
10. Yuldashov R, Fayzullayev Sh. “Muhammad al-Xorazmiy avlodlari ilmiy amaliy va axborot tahliliy jurnali” “Marketing technologies in the implementation of electronic commerce goods and services” 2024 S1 (17).



YUZ TASVIRI ORQALI SOXTA XUJUMLARNI ANIQLASHNING TASVIR TEKSTURASI TAHLILIGA ASOSLANGAN ALGORITMLARI

Abdukadirov Baxtiyor Abduvaxitovich,
Dasturiy injiniring kafedrasida dotsenti
bakhtiyor.uz@bk.ru

Abdukadirova Gulbahor Xomidjon qizi
Muhammad al-Xorazmiy nomidagi
Toshkent axborot texnologiyalari universiteti
Farg'ona filiali
assistenti
gulbahorabdukadirova1991@gmail.com

Annotatsiya: Mazkur maqolada biometrik tanib olish tizimlarini soxta hujumlar orqali buzib kirishning chop etilgan usuli tahlil qilingan bo'lib, rang teksturalari tahliliga asoslangan soxta yuz tasvirlarini aniqlash algoritmi taklif qilingan. Buning uchun RGB rang modelidan tashqari rang teksturalari ma'lumotlarini o'rganish uchun ikkita boshqa rang modellaridan foydalanilgan. Tajribaviy tadqiqotlarni o'tkazish uchun CASIA va Replay-Attack ma'lumotlar bazalaridan foydalanilgan.

Kalit so'zlar: soxta hujum, chop etilgan hujum, lokal binar shablon, tayanch vektorlar usuli, xato darajasi, RGB, HSV, YCbCr rang modellari

Kirish. Biometrik ma'lumotlarni o'qish bo'yicha yuz biometriyasi eng sodda texnologiyalardan biri hisoblanadi. Bundan tashqari, u yana ko'plab qulayliklarga ega bo'lganligi uchun amaliyotda keng qo'llaniladi va shuning uchun uning bozori chaqqon bo'lib bormoqda. Biroq, bu omil soxta hujumlarni ko'payishiga sabab bo'ladi. Internet tarmog'ida ko'plab insonlarni sifatli yuz tasvirlarini topish mumkin. Buzg'unchilar esa ulardan avtorizatsiyalashda keng foydalanadi. Bunday hujumlarni oldini olishda tekstura tahliliga asoslangan algoritmlar keng qo'llaniladi.

Adabiyotlar tahlili va metodologiyasi. Tasvir chastotasi va teksturasining tahliliga asoslangan soxta yuzlarni aniqlash yondashuvi [1; 2] tadqiqot ishlarida batafsil keltirilgan bo'lib, ushbu usulning asosiy maqsadi shakli va tafsilotlari bo'yicha haqiqiy yuzni soxta yuz (ikki o'lchamli qog'oz niqoblari)dan ajratib ko'rsatish hisoblanadi.

Mualliflar jonli yuzlarni ikki o'lchamli qog'ozli niqoblaridan ajratish uchun bitta tasvir chastota va teksturalarini tahlil qilish usulini taklif qilishgan. Shuningdek, ular past va yuqori chastotali sohalarida

joylashgan ma'lumotlardan foydalanadigan quvvat spektriga asoslangan chastotalarni tahlil qilish usulini ham taklif etishdi. Bundan tashqari, berilgan yuz tasvirlaridagi teksturalarni tahlil qilish uchun lokal binar shablonlar (LBSH) asosida tavsiflash usuli ham ushbu ishda amalga oshirilgan. Jonli yuzni ikki o'lchovli qog'oz niqoblaridan ajratish uchun chastota va tekstura ma'lumotlaridan foydalanilib, chastota ma'lumotlari ikki asosiy sababga ko'ra qo'llanilishini taxmin qilishgan. Bular birinchidan, uch o'lchovli shakllar mavjudligidagi farq bo'lib, u yuzni umumiy shaklini yoritilish tarkibi bilan bog'liq bo'lgan past chastotali hududlarni farqiga olib keladi. Ikkinchidan, jonli yuzlar va yuz niqoblari orasidagi batafsil ma'lumotlarni farqi yuqori chastotali ma'lumotlar nomuvofiqligini keltirib chiqaradi. Odatda ikki o'lchamli obyektlardan olingan tasvirlar tekstura ma'lumotlari (ayniqsa, yoritish komponentlari) uch o'lchamli obyektlardan olingan tasvirlarga nisbatan yo'qotilishga moyil bo'lganligi uchun olinadi. Belgilarni ajratib olishda chastota va teksturaga hamda Furega asoslangan belgilarni shakllantirish usullari qo'llaniladi.



Teksturaga asoslangan belgilarni ajratib olish usuli. Chastotali ma'lumotni ajratib olish uchun birinchi navbatda ikki o'lchamli diskret Fure almashtirishlari yordamida yuz tasviri chastota sohasiga o'tkaziladi. So'ngra almashtirilgan natija har bir halqa chastota diapazonidagi mos hududiga ega bo'luvchi konsentrik halqalarni bir necha guruhlariga ajratiladi. Barcha o'lchovli halqalarni o'rtacha energiya qiymatlarini birlashtirish orqali bir o'lchovli xususiyat vektori shakllantiriladi. Teksturaga asoslangan belgilarni ajratib olishda esa tasvir teksturalari ma'lumotlarini tavsiflashni mashhur usullaridan biri bo'lgan Lokal binar shablonlar (LBSH) usulidan foydalanish maqsadga muvofiq hisoblanadi. Birlashtirishga asoslangan xususiyatlarni ajratish quvvat spektri va LBSH asosida ishlab chiqilgan xususiyat vektorlari bilan jonlilik detektorlarini o'qitish uchun tayanch vektorlar usuli (TVU) klassifikatori asosida amalga oshiriladi. Birlashtirishga asoslangan usul quvvat spektriga asoslangan xususiyat vektorlari bo'yicha o'qitiladigan TVU klassifikatori va LBSH asosidagi xususiyat vektorlari bo'yicha o'qitiladigan TVU klassifikatorining yechim qiymatini birlashtirib, xususiyat vektorini shakllantiradi.

Tadqiqot natijalari va muhokamalar.

Tajribalar uchun ikki turdagi ma'lumotlar bazalaridan foydalanish mumkin, ya'ni BERC Webcam va BERC ATM ma'lumotlar bazasidan. Veb-kameralar ma'lumotlar bazasidagi barcha tasvirlar uch xil yoritish sharoitida, soxta (jonli bo'lmagan) yuzlar bosma qog'oz, jurnal va karikaturalardan olish orqali hosil qilingan. Tavsiya etilgan yondashuvning tajribaviy tadqiqotlar chop etilgan qog'oz va karikaturalardan olingan tasvirlarda LBSH asosidagi usul chastotaga asoslangan usulga nisbatan ancha samarali natijalarni ko'rsatishini tasdiqlagan. Umuman olganda, birlashtirishga asoslangan usul (chastota xato darajasi 4,42% natija bilan) 5,43% ga chastota va LBSH asosidagi (xato darajasi 12,46% teng) usulga nisbatan yaxshiroq natija bergan.

Mikro-teksturalarni tahlil qilish yordamida individual tasvirlardan yuzlarni soxtalashtirishni aniqlashga o'xshash usul [3] ishda batafsil yoritilgan bo'lib, undagi usulning asosiy g'oyasi elementlar

fazosi mikrostrukturalardagi farqlarni belgilash hisoblanadi. Mazkur ish mualliflari mikrotexnikalar va ularni fazoviy ma'lumotlarini tavsiflash uchun samarali tekstura operatori bo'lgan lokal binar shablonlardan foydalanishgan.

Olingan belgilar fazosidagi vektorlar TVU klassifikatoriga kirish ma'lumoti sifatida uzatiladi, bunda mikro-tekstura shablonlari soxta yoki jonli tasvirni yaxshi xarakterlashi aniqlangan. Ushbu usulda, dastlabki qadam yuzni aniqlashdir, so'ngra aniqlangan yuz tasviri qisqartiriladi (qirqiladi) va normalizatsiyalanadi hamda u 64×64 o'lcham pikseli tasvirga o'tkaziladi. So'ng LBSH operatori normallashtirilgan yuz tasviriga qo'llaniladi va natijada olingan yuz tasviri LBSH qiymati 3×3 ustma-ust tushuvchi sohalarga ajratiladi. Keyin har bir sohadan olingan 59 katakli lokal gistogrammalar hisoblanib, bitta 531 katakli gistogramma shakllantiriladi. Navbatdagi qadam, LBSH operatorlari yordamida butun yuz tasviridan olingan yana ikki gistogrammani hisoblashdan iborat. Nihoyat, kirish tasviri soxta yoki jonli tasvir ekanligini aniqlash uchun radial bazis funksiyasi va chiziqli bo'lmagan TVU klassifikatori qo'llaniladi. Tajriba natijalari LBSH lokal fazalarni kvantlash (4,6%) va Gabor Veyvletlari (9,5%) kabi boshqa tekstura operatorlariga nisbatan 2,9% ga teng xato darajasi bilan yaxshi samaradorlikni ta'minlashini ko'rsatdi.

Bitta yuz yoki yuzlar ketma-ketligi tasviri Fure spektrlarini tahlil qilish asosida teksturaga asoslangan jonlilikni aniqlashni yana bir qiziqarli usuli [4] ishda taklif etilgan bo'lib, u jonli inson harakati va tuzilishi haqidagi ma'lumotlarga asoslanadi. Mazkur usul ikki tamoyilga asoslanib shakllantirilgan. Birinchidan, tasvir o'lchamini kattaligi jonli yuz tasviri o'lchamidan kichikroq va tasvir yassi yuzali bo'lib, fotosurat tasvirini yuqori chastotali komponentlari haqiqiy yuznikidan kichikroq, ikkinchidan, tasvir kamera yonida joylashgan va harakatda bo'lsa ham tasvirda ko'rsatilgan mimika va holatlar o'zgarmaganligi uchun ketma-ketlikdagi chastota komponentlarini standart og'ishi kichik bo'ladi. Bundan tashqari, mazkur ish mualliflari jonli yuzni aniqlashning samarali usuli, ya'ni kirish tasviri ikki o'lchovli Fure spektrlarini tahlil



qilish zarurligini ta'kidlashgan. Ular yuqori chastotali komponentlar energiyasini barcha chastotali komponentlar energiyasiga nisbatiga mos keladigan yuqori chastotali deskriptor sifatida foydalanishgan. Tasvirni yuqori chastotali tarkibiy qismlari deb chastotalari tasvirning maksimal radial chastotasini uchdan ikki qismidan katta va qiymatlari berilgan chegaradan oshib ketadigan qismlariga aytiladi. Odatda, soxtalashtirish jarayoni natijasida kelib chiqadigan yuqori chastotali komponentlar qiymati berilgan tasvirdan kichik bo'ladi. Shuningdek, mualliflar tizimni aldash uchun juda aniq va katta hajmdagi tasvirdan foydalanilsa, yuqoridagi usul muvaffaqiyatsiz bo'lishini aniqlashgan. Ushbu muammoni hal qilish uchun jonli yuzni aniqlash uchun harakatlanuvchi tasvirlardan foydalanish maqsadga muvofiqdir.

Tasvir sifatini baholash, bosma qog'ozdagi artefaktlar xususiyatlari va tasvirda yorug'likni aks ettirishdagi farqlarini inobatga olib, soxta chop etilgan yuzlarni aniqlash muammosiga teksturani tahlil qilish nuqtai nazaridan yondashish [5] ishda taklif qilingan. Haqiqatdan ham, chop etilgan yuz tasvirlari odatda nuqfsonlarga ega bo'ladi va ularni tekstura-shakl xususiyatlari bilan oson aniqlash mumkin.

Soxta yuzlarni aniqlashda qo'llanilishi mumkin bo'lgan yuzdagi nuqsonlarga misol sifatida tasvir xiraligi, past kontrastligi, oynani xarakterli aks ettirilganligi va chop etishdagi artefaktlarni keltirish mumkin.

Soxta yuzlarni aniqlash bo'yicha o'tkazilgan asosiy tadqiqotlar yuz tasvirlari yorqinligini tahlil qilishga qaratilgan bo'lib, ularda soxta yuzlarni haqiqiy yuzlardan farqlashda foydali bo'lishi mumkin bo'lgan tasvir rangli ma'lumotlariga e'tibor qaratilmagan. Biroq, [6] ishda rangli teksturalarni tahlil qilish asosida soxta yuzlardan himoya qilishni yangi usuli taklif qilingan, ya'ni unda yorqinlik va rang kanallaridan olingan rang va teksturalarni birlashtirilgan ma'lumotlarini binar rang shabloni lokal deskriptori yordamida tahlil qilingan. Xususan, belgi gistogrammalari tasvirni har bir diapazonidan alohida ajratib olingan. Shuningdek, mazkur ishda rang teksturalari tahliliga asoslangan soxta yuz tasvirlarini

aniqlash usuli ham taklif etilgan. [7] ishda taklif etilgan Lokal binar shablon deskriptori yuz tasvirlaridan ranglar va tekstura ma'lumotlarini ajratib olishda ham qo'llaniladi. Ushbu deskriptorda bir turdagi LBSH gistogrammalari tasvirni har bir diapazonidan alohida ajratib olinadi. So'ngra, olingan gistogrammalar birlashtirilib, yakuniy deskriptor hosil qilinadi.

Qaysi rang oralig'i aniqroq ekanligini tushunish uchun haqiqiy yuzni soxtasidan farqlashda asosan uchta rang modeli, ya'ni RGB, HSV va YCbCr lar ko'rib chiqilgan. Ikki murakkab sinov ma'lumotlar bazasi, ya'ni CASIA face anti-spoofing va Replay-Attack ma'lumotlar bazalari ustida olib borilgan tajribalar rang teksturalari usuli har xil soxta hujumlarni aniqlashda kulrang rangdagi analoglardan ustun ekanligini aniq ko'rsatib berdi. Bundan tashqari, ma'lumotlar bazalarida o'tkazilgan tajribalar taklif qilingan yondashuv zamonaviy usullarga nisbatan istiqbolli umumlashtirish imkoniyatlar berishini ko'rsatdi.

Soxta yuz hujumlari, asosan chop etilgan qog'ozda yoki video ekranlari orqali yuz tasvirini to'liq namoyish etish orqali amalga oshiriladi. Past sifatli yuz teksturali (masalan, mobil telefondagi) tuzilishga ega bo'lgan soxta hujumlarni kulrang tasvirlar tuzilishi va sifatini tahlil qilish orqali aniqlash mumkin. Biroq, 1-rasmda keltirilgannidek, yuqori sifatli soxta yuzlarni faqat veb-kamerani sifatli tasvirlari yorqinligi ma'lumotlari asosida aniqlash murakkab yoki deyarli imkonsiz deb taxmin qilish mumkin.



1-rasm. Yuz tasviridagi nuqsonlarga namunalar

Fotosuratlar, video displeylar va niqob kabi turli xil displey vositalarini ranglarni ko'rsatish (gamma) qiymati haqiqiy yuzlarga nisbatan cheklangan. Shuning uchun, taqdim etilayotgan soxta yuz tasvirlari o'rtacha rangdagi tasvirlarni soxtalashtirishga nisbatan kamroq uchraydi. Bundan tashqari, qayta suratga olingan yuz tasvirida to'liq yuzni ko'rsatishda boshqa kamchiliklar sababli lokal



rang o'zgarishlari ham bo'lishi mumkin. Tasvirni aks ettirishiga qarab gamma ranglar signaturalari va lokal ranglar o'zgarishlari (shovqin), rang kanallari teksturasini tahlil qilish orqali tavsiflanishi mumkin. Rang kanallari yorqinlik to'g'risidagi ma'lumotlardan ajralib turganligi sababli, ma'lumotlarni yig'ish shartlari yorug'lik o'zgarishiga ko'proq bardoshli bo'ladi. Ushbu ishda yuqoridagi vizual signallardan qanday qilib soxta hujumlardan saqlanishda foydalanish mumkinligini o'rganilgan. LBSH tavsiflarini turli xil ranglar fazosidan ajratib olish orqali qaysi rang modellaridan foydali mikroteksturalarini olish yo'llari ham keltirib o'tilgan.

RGB modelidan tashqari rang teksturalari ma'lumotlarini o'rganish uchun ikkita boshqa rang fazolari [6] ishda o'rganilgan. Bu rang fazolari HSV va YcbCrlardir. Ushbu ikki rang fazolari yorqinlik va rang turi ma'lumotlarini ajratishga asoslangan bo'lib, HSV rang fazosida rang va to'yinganlik o'lchamlari tasvir rangliligini ifodalaydi va unda qiymat o'lchovi yorqinlikka mos keladi. YCbCr fazosi RGB komponentlarini yorqinlik (Y), ko'k rangni rangliligi (Cb) va qizil rangni rangliligi (Cr)ga to'liq ajratadi. [8] ishda taklif etilgan LBP deskriptori, kulrang shkalali teksturalar uchun qulay deskriptor hisoblanadi. Tasvirni har bir pikseli uchun markaziy piksel qiymati bilan aylana simmetrik chegaraviy bo'sag'ani o'rnatish orqali ikkilik kodi hisoblanadi va turli xil binar shablonlarni yig'ish uchun gistogramma shakllantiriladi. LBSH dastlab kul rangdagi tasvirlarga ishlov berishga mo'ljallangan, biroq u keyinchalik rangli ma'lumotlardan foydalanish uchun kengaytirilgan. [7] ishda sodda, ammo samarali LBSH rang deskriptori taklif qilingan. Bunda LBSH operatori har bir rang guruhiga qo'llaniladi. Olingan gistogrammalar yakuniy rang deskriptorini hosil qilish maqsadida birlashtiriladi.

Rang teksturalari tahliliga asoslangan soxta yuz tasvirlarini aniqlash algoritmi. Faraz qilaylik, YCbCr ranglar fazosida ifodalangan yuz tasviri va $S(i)$ rang fazosini qayta o'zgartirilganidan so'ng hosil qilingan i -rang komponentasining tasviri berilgan bo'lsin. Bunda LBSH kulrang darajasidagi gistogramma har bir tegishli rang komponenti $S(i)$

tasviridan alohida va mustaqil hisoblash mumkin. Shuni alohida ta'kidlash joizki, LBSH rang gistogrammasini hisoblashda universal LBSH operatori qo'llaniladi, chunki odatiy yuz tasviri kam sonli LBSH qiymatlaridan (bir turdagi shablon) iborat bo'ladi. $S(i)$ tasviridan ajratib olingan (x, u) piksel LBSH shablonini quyidagicha ifodalash mumkin:

$$LBSH_{P,R}^{(i)}(x, y) = \begin{cases} \sum_{n=0}^{P-1} \delta(r_n^{(i)} - r_c^{(i)}) \times 2^n & \text{agar } U^{(i)} \leq 2 \\ \text{aks holda } P(P-1) + 2 \end{cases}$$

(1)

bu yerda

$$U^{(i)} = \left| \delta(r_{p-1}^{(i)} - r_c^{(i)}) - \delta(r_0^{(i)} - r_c^{(i)}) \right| + \sum_{n=1}^p \left| \delta(r_n^{(i)} - r_c^{(i)}) - \delta(r_{n-1}^{(i)} - r_c^{(i)}) \right|$$

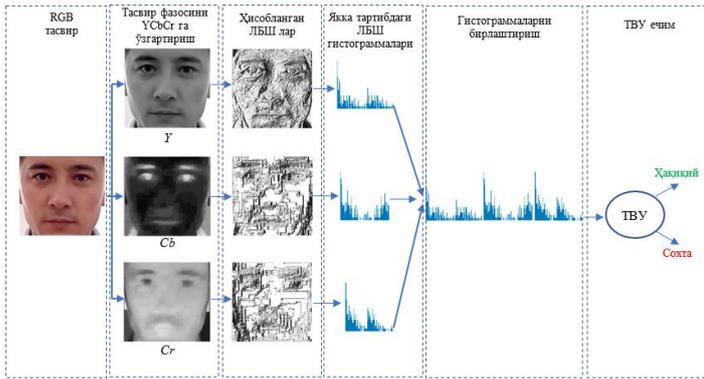
va agar $x \geq 0$ bo'lsa, u holda $\delta(x) = 1$, aks holda $\delta(x) = 0$. $r_n^{(i)} (n = 0, P-1)$ aylana bo'ylab teng masofada joylashgan, $R (R > 0)$ radiusli (x, y) markaziy piksel doiraviy qo'shnisini tashkil etuvchi P piksellarni (yoki tanlanma olish nuqtalarini) rang komponentlari qiymatlari, $r_c^{(i)}$ aylana atrofidagi qo'shni (x, y) pikselini rang komponenti qiymati. Shuningdek, $L^{(i)}, S^{(i)}$ ga mos LBSH obrazi va $L^{(i)}$ piksel qiymatlarining har biri berilgan (x, y) piksel o'rniga (1) ga muvofiq aniqlangan $LBSH_{P,R}^{(i)}(x, y)$ bilan to'ldirilgan bo'lsin.

I tasvir $S (S \in \{RGB, HSV, YCbCr\})$ ranglar fazosida tasvirlangan yuz tasviri va $H_S^{(i)}, \{i = 1 : M\}$ uni S fazoning M kanalidan ajratib olingan bir turdagi LBSH gistogrammasi bo'lsin. S fazoda tasvirlangan I tasvir LBSH rang belgilarini quyidagicha aniqlanadi:

$$H_S = [H_S^{(1)} \dots H_S^{(M)}]$$

Soxta hujumini aniqlash uchun yuz tasvirlaridan ajratib olingan LBSH rang belgilari TVU asosida qurilgan klassifikatorga uzatiladi. Taklif etilayotgan yondashuvning umumiy sxemasi 2-rasmda keltirilgan.





2-rasm. Rang teksturalari tahliliga asoslangan soxta yuz tasvirlarini aniqlash sxemasi

Tekstura tahliliga asoslangan algoritm quyidagi qadamlardan iborat:

1-qadam. Berilgan rangli tasvir YCbCr ranglar modeliga o'tkaziladi.

$$Y = 0,299R + 0,587G + 0,114B;$$

$$C_B = -0,1687R - 0,3313G + 0,5B;$$

$$C_R = 0,5R - 0,4187G - 0,0813B;$$

2-qadam. Tasvirning har bir kanali uchun LBSH qiymatlari (1) formula bo'yicha hisoblanadi. Tekis taqsimlangan LBSHlar tanlab olinadi, tekis taqsimlanmagan barcha LBSHlarga bir xil qiymat beriladi.

3-qadam. LBSH qiymatlari gistogrammalari shakllantiriladi.

4-qadam. Tasvir barcha kanallari gistogrammalari birlashtiriladi.

5-qadam. TVU yordamida tasvir soxta yoki haqiqiyli aniqlanadi.

Taklif etilgan usul samaradorligi CASIA-FA va Replay-Attack ma'lumotlar bazasida baholandi. Bunda sozlash CASIA-FA va o'qitish Replay-Attack ma'lumotlar bazasida amalga oshirildi. 2.1-jadvalda o'qitish va testlash tanlanmalariga mos HTER qiymatlari (47,5% va 43,9%) keltirilgan. Ikkinchi tajribada soxta hujumlarga qarshi kurashish chora-tadbirlari CASIA-FA ma'lumotlar bazasida o'qitilib, Replay-Attack ma'lumotlar bazasida tekshirildi. So'ng o'qitish hamda testlash HTER qiymatlari mos ravishda 22,5% va 20,6% ni tashkil qildi. Ushbu usul natijalari Replay-Attack ma'lumotlar bazasida zamonaviy usullar bilan raqobatbardosh bo'lishiga qaramay, ichki

sinov natijalari bilan taqqoslashda (soxta hujumlarga qarshi chora usullari bir xil ma'lumotlar bazasida o'qitilganda va sinovdan o'tkazilganda) ular past natijalarni ta'minladi.

1-jadval. CASIA va Replay-Attack ma'lumotlar bazalarida o'qitish va testlashning HTER qiymatlari (%)

Usul	Replay-Attack		CASIA	
	O'qitish	Test	O'qitish	Test
Motion [9]	50.2	50.2	47.7	48.2
LBP [9]	44.9	47.0	57.3	57.9
LBP-TOP [9]	48.9	50.6	60.0	61.3
Motion-Mag [10]	50.0	50.20	43.8	50.3
Taklif qilingan usul (SVM-RBF)	22.5	20.6	47.5	43.9
Taklif qilingan usul (SVM-linear)	17.7	16.7	38.6	37.6

Chiziqli TVU modellari ustidagi tajribalar TVU-RBF modellariga nisbatan samarali natijalarni ko'rsatdi. CASIA-FA ma'lumotlar bazasida o'qitish va test tanlanmalari uchun HTER qiymatlari mos ravishda 38,6% dan 37,6% gacha kamaytirildi. Replay-Attack ma'lumotlar bazasida HTER qiymatlari esa 17,7% dan 16,7% gacha kamaytirildi (mos ravishda o'qitish va sinov to'plami uchun), bu kulrang shkaladagi LBSH deskriptori bilan ichki sinov baholash qiymatlari bilan taqqoslandi (15,3% va 15,6%).

Replay-Attack ma'lumotlar bazasi uchun optimallashtirilgan model CASIA-FA ma'lumotlar bazasiga asoslangan model bilan bir xil umumlashtirilishi mumkin emas. Buning asosiy sababi, CASIA-FA ma'lumotlar bazasida Replay-Attack ma'lumotlar bazasiga nisbatan ko'proq yig'ilgan ma'lumotlar (masalan, tasvir sifati, kamera va yuz orasidagi masofani yaqinligi) mavjud. Replay-Attack ma'lumotlar bazasi uchun optimallashtirilgan model yangi muxitda kutilgan natijalarni ta'minlamasligi mumkin. Ushbu muammoni bartaraf etish usullaridan biri [9] ishda keltirilgan bo'lib, unda ikki ma'lumotlar bazasi o'quv majmualari birlashtirib, qo'shma o'quv tanlanmasi sifatida o'qitilgan.

Xulosa. Ushbu tadqiqot ishida keltirilgan yuzlarni soxtalashga qarshi muammoga rang teksturalari tahlili nuqtai nazaridan yondashuv tahlil qilindi. RGB, HSV va YCbCr kabi ranglar fazosidan qaysi biri haqiqiy yuzlar va soxta yuzlar orasidagi rang



teksturalari farqlarini tavsiflash uchun foydali yuz tasvirlarini taqdim etishi o'rganib chiqildi. LBSH rang belgilarini alohida tasvir kanallaridan ajratib olish orqali turli xil rangli teksturalarini namoyish etish samaradorligi o'rganildi.

Ikki murakkab CASIA-FA va Replay-Attack soxta hujumlar ma'lumotlar bazalarida o'tkazilgan tajribalar ijobiy natijalarni ko'rsatdi. CASIA-FA ma'lumotlar bazasida HSV va $YCbCr$ rang fazolari birikmasiga asoslangan yuz tasvirlari bazasi mavjud zamonaviy yuz tasvirlar bazasidan ko'plab afzalliklarga ega. Bundan tashqari, ma'lumotlar bazalarida taklif qilingan yondashuv samarali natijalarni ko'rsatgan.

Foydalanilgan adabiyotlar

1. Kim G., Eum S., Suhr J.K., Kim D.I., Park K.R., Kim J. Face liveness detection based on texture and frequency analyses // 5th IAPR International Conference on Biometrics (ICB), New Delhi, India. March 2012. – pp. 67-72.
2. Pereira T.F., Komulainen J., Anjos A., Martino J.M., Hadid A., Pietikainen M., Marcel S. Face liveness detection using dynamic texture. – EURASIP Journal on Image and video processing, vol. 2014, no. 1, pp. 2-15.
3. Maatta J., Hadid A., Pietikainen M. Face spoofing detection from single images using microtexture analysis // Proc. International Joint Conference on Biometrics, Washington, D.C., oct. 2011, – pp. 1-7.
4. Li L., Wang Y., Tan T., Jain A. K. Live face detection based on the analysis of fourier spectra // Proc. SPIE. V. 5404, Biometric Technology for Human Identification. Orlando, FL, USA. April 2004. (SPIE 5404), – pp. 296-303.
5. Maatta J., Hadid A., Pietikainen M. Face spoofing detection from single images using texture and local shape analysis // IET Biometrics, 2012, Vol. 1, Iss. 1, – pp. 3-10.
6. Boulkenafet Z., Komulainen J., Hadid A. Face anti-spoofing based on color texture analysis // IEEE International Conference on Image Processing, 2015, – pp. 2636-2640.
7. Choi J.Y., Plataniotis K.N., Yong M.R. Using colour local binary pattern features for face recognition // IEEE International Conference on Image Processing (ICIP), Sept 2010, – pp. 4541-4544.
8. Ojala T., Pietikainen M., Maenpaa T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns // IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI), vol. 24, no. 7, Jul 2002, – pp. 971-987.
9. Pereira T. de Freitas, Anjos A., De Martino J.M., Marcel S., Can face anti-spoofing countermeasures work in a real world scenario? // in International Conference on Biometrics (ICB), Madrid, June 2013, – pp. 1-8.
10. Samarth B., Tejas D.I., Mayank V., Richa S. Face anti-spoofing via motion magnification and multifeature videolet aggregation // Tech. Rep., University of Delhi, Department of Computer Science and Engineering, 5, 2014, – pp. 1-12.



O'zbek tili universal bog'liqlik daraxti korpusining bi-affin neyron modelida tahlil qilish

Matlatipov San'atbek G'ayratovich,

Ph.D., yetakchi ilmiy xodim, Mirzo Ulug'bek
nomidagi O'zbekiston Milliy universiteti.

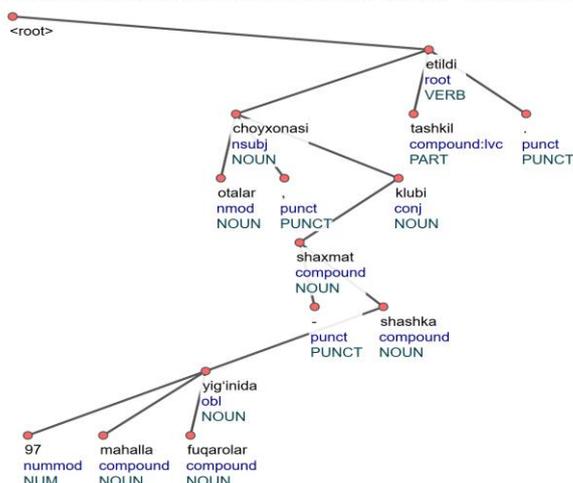
Email: s.matlatipov@nuu.uz

Annotatsiya: Ushbu maqolada o'zbek tili izohli gaplaridan iborat universal bog'liqlik daraxti (UD) korpusi yordamida o'zbek tili uchun chuqur bi-affin neyron bog'liqlik tahlili o'rganiladi. Morfologik jihatdan boy, ammo o'rgatilgan resurslari kam bo'lgan o'zbek tili o'zining moslashuvchan so'z tartibi va agglutinativ tuzilishi tufayli o'ziga xos tahlil muammolarini keltirib chiqaradi. Biz sintaktik bog'liqlik belgilarini bashorat qilish uchun Bi-directional LSTM enkoderi va bi-affin diqqat mexanizmlaridan foydalangan holda grafga asoslangan bog'liqlik tahlilchisini amalga. Diqqat qatlamlari, tarmoq arxitekturasini, o'rnatish tezligi va optimallashtirish parametrlari (masalan, Adam optimizatori) kabi asosiy jihatlarni har tomonlama muvofiqlashtirilgan qilinadi. Eksperimental natijalar shuni ko'rsatadiki, bi-affin model ishonchligi 2 ta metrika, UAS(unlabeled attachment score) 79,5% va LAS(Labeled attachment score) 72,4% ga erishadi, bu esa o'tishga asoslangan bazaviy analizatorni 6,7% (UAS) va 7,4% (LAS) ga sezilarli darajada ortda qoldiradi. Ushbu natijalar kam resursli ssenariylarda qaramlikni tahlil qilish uchun global e'tiborga asoslangan yondashuvlarning samaradorligini ta'kidlaydi.

Kalit so'zlar: O'zbek tili, bi-affin neyron modeli, BiLSTM, neyron tarmoqlar, kam resursli tillar, universal bog'liqliklar

Kirish. Iyerarxik bog'liqlikni tahlil qilish - so'zlar orasidagi bosh-tobe munosabatlarni aniqlash orqali gapning grammatik tuzilishini o'rganish vazifasidir. Natijada tobelik bog'lanishlaridan tashkil topgan iyerarxik daraxt hosil bo'ladi (1-rasm), unda har bir so'z (tugun) o'zining sintaktik boshqaruvchisi (otana) bilan belgilangan munosabat (chiziq) orqali bog'lanadi.

97 mahalla fuqarolar yig'inida otalar choyxonasi , shaxmat - shashka klubi tashkil etildi .



1 – rasm. Standart tugun va chiziqli daraxt tasvir
(https://universaldependencies.org/conllu_viewer.html)

Bu sintaktik tahlil, matindagi semantikani chuqur anglash uchun juda muhimdir. Misol uchun, mashina tarjimasini va ma'lumotlarni ajratib olish kabi ko'plab keyingi NLP vazifalari, chunki ular gap tuzilishini tushunishdan foydalanadi. Odatda, bog'lanish iyerarxiyasining sintaktik tahlillari o'tishga asoslangan(transition-based) yoki grafga asoslangan(graph-based) modellariga asoslangan bo'ladi. O'tishga asoslangan tahlilchilar daraxtni siljitish-qisqartirish harakatlari ketma-ketligi orqali bosqichma-bosqich yaratadi. Bu chiziqli vaqtda tahlil qilishga erishadi, ammo xatolarning keltirib chiqaradi. Grafga asoslangan parserlar esa, aksincha, barcha mumkin bo'lgan nomzod yo'yllarni (boshga bog'liq juftliklarni) baholaydi va keyin ko'pincha global optimallashtirish (masalan, maksimal qamrovli daraxt algoritmlari) orqali eng yuqori ball to'plagan daraxtni topadi. [1] kabi dastlabki grafiklarga asoslangan yondashuvlar qo'lda yaratilgan xususiyatlarga ega chiziqli modellardan, [2] kabi o'tishga asoslangan yondashuvlar esa ochko'z(greedy) tasniflagichlardan foydalangan. Chuqur o'rganish sohasidagi so'nggi yutuqlar avtomatlashmagan funksiyalarni neyron



tarmoqlari bilan almashtirish orqali tahlil qilishni sezilarli darajada yaxshiladi[3]. Xususan, so'zlarni kontekstda ifodalash uchun ikki yo'nalishli LSTM (BiLSTM) enkoderlaridan foydalanish [4] va boshlarni baholash yoki tanlash uchun neyron tarmoqining diqqat mexanizmlari yanxshilanishiga olib keldi[3].

O'zbek tili turkiy tillar oilasiga mansub, resurs jihatidan cheklangan, ammo morfologik jihatdan boy til hisoblanadi. O'zbek tili egiluvchan SOV(Subject(Ega) → Object(Kesim) → Verb(Fe'1)) so'z tartibi va boy morfologiyaga ega bo'lgan nol-egali, agglyutinativ tildir. Bu xususiyatlar tahlil jarayonini murakkablashtiradi, chunki morfologik boylik so'z shakllarining xilma-xilligiga olib keladi va so'zlarning erkin tartibi uzoq masofali bog'liqliklarni yuzaga keltirishi mumkin. Biz o'z tadqiqotlarimizni yangiliklar va badiiy adabiyotlardan olingan 500 ta gapni (5 850 ta token) o'z ichiga olgan[5], birichi universal bog'liqlik daraxti korpusining so'z turkumlari, morfologik xususiyatlar va sintaktik bog'lanishlar bilan izohlangan birinchi o'zbek Universal bog'liqliklar(UB) ma'lumotlar bazasi – O'zbek-UT yordamida olib boramiz. Bu ma'lumotlar bazasi nisbatan kichikroq bo'lib, tahlil vazifasini resurs jihatidan cheklangan sharoitlarda sinab ko'rish imkonini beradi.

Ushbu maqolada biz [3] yondashuviga asoslanib, o'zbek tili uchun chuqur bi-affin neyron bog'liqlik tahlilchisini - chuqur diqqat mexanizmiga ega bo'lgan grafik asosidagi tahlilchini joriy etamiz. Neyron tarmoq arxitekturasini batafsil tavsiflaymiz, jumladan BiLSTMLardan foydalanish, e'tibor (bi-affin) qatlamlari hamda tarmoq hajmi va tushirib qoldirish kabi giperparametrlarni o'z ichiga oladi. Modeldagi e'tiborning rolini baholash funksiyasining matematik formulalarini keltirib tushuntiramiz. Tajriba qurilmasi taqdim etilgan bo'lib, unda o'zbek UD daraxt korpusida o'qitish, optimallashtirish va baholash modellari haqida batafsil ma'lumotlar keltirilgan. Shuningdek, ikki paradigma o'rtasidagi aniqlik va xatti-harakatlardagi farqlarni ta'kidlash maqsadida o'tishga asoslangan tahlilchini taqqoslash uchun asos sifatida o'rgatamiz. Nihoyat, natijalarni taqdim etib tahlil qilamiz, xatolar qonuniyatlari va o'zbek tilining

lingvistik xususiyatlarining tahlil samaradorligiga ta'sirini muhokama qilamiz.

Adabiyotlar tahlili va metodologiya. Neyron diqqat mexanizmlari. Zamonaviy neyron NLP modellari kiruvchi ma'lumotlarga nisbatan yumshoq moslashuvlar(soft alignment) yoki vazn koeffitsiyentlarini o'rganish uchun diqqat neyron qatlamlariga kuchli darajada tayanadi. Diqqat mexanizmi modelga chiquvchi ma'lumotni bashorat qilishda ketma-ketlikning tegishli qismlariga e'tibor qaratish imkonini beradi. Misol uchun, neyron mashina tarjimasida har bir so'z uchun dekoderga turli manba so'zlariga moslashishga imkon beruvchi diqqat mexanizmini taqdim etilgan[6]. Gapni yagona belgilangan vektorga kodlash o'rniga, ularning modeli har bir maqsadli so'z uchun kontekst vektorini kichik "diqqat" tarmog'i tomonidan o'rganilgan vazn koeffitsiyentlari orqali manba so'zlari vektorlarining o'Ichangan yig'indisi sifatida yaratadi.

Masalaning qo'yilishi, so'rov vektori q (masalan, dekoderning joriy yashirin holati) va kalit vektorlari to'plami $k_1, k_2, k_3 \dots k_n$ (masalan, manba so'zlari uchun enkoder holatlari) berilgan bo'lsa, diqqat qatlami har bir kalit uchun $e_i = f(q, k_i)$ muvofiqlik ballini hisoblaydi (vektor ko'paytmasi yoki kichik uzatish tarmog'i kabi funksiya yordamida). Ushbu ko'rsatkichlar $\alpha_i = \frac{\exp(e_i)}{\sum_j \exp(e_j)}$ e'tibor vaznlarini hosil qilish uchun softmax bilan normallashtiriladi. Natijada, v_i (ko'p hollarda $v_i = k_i$) qiymat vektorlarining vaznli yig'indisi hosil bo'ladi (1):

$$c = \sum_{i=1}^n \alpha_i * v_i (1)$$

bu esa so'rov uchun eng muhim bo'lgan kiruvchi qismlarini ifodalaydi. Transformer arxitekturasida[7] rekurrent tarmoqlar o'rniga o'z-o'ziga murojat qilish yoki diqqat berish qatlamlaridan foydalanadi, bu esa har bir so'z[8] gapida boshqalarga murojaat qilish imkonini beradi. Transformerlardagi o'z-o'ziga e'tibor(self-attention) bir nechta e'tibor markazlarini parallel ravishda hisoblaydi va dominant yondashuvga aylandi.

Bog'liqlikni tahlil qilishda diqqat mexanizmini(attention) ma'lum bir so'zning boshqa so'zga nisbatan bosh so'z bo'lish ehtimolini



modellashtirish uchun qo'llash mumkin. [3]ning chuqur bi-affin diqqat tahlilchisi aynan shu g'oyadan foydalanadi: har bir mumkin bo'lgan bosh so'z va qaram so'z juftligi ($j \rightarrow i$) uchun model j so'zining i so'ziga nisbatan bosh so'z bo'lishi qanchalik ehtimolligini ko'rsatuvchi s_{ij} bahosini hisoblaydi. Bu ko'rsatkichlarni matritsada diqqat mexanizmi vaznlari sifatida ko'rish mumkin, bunda har bir qaram so'z i har bir j nomzod bosh so'zga "diqqat qaratadi". Berilgan qaram so'z uchun bosh so'zlar ustidan softmax funksiyasini qo'llash e'tibor taqsimotini hosil qiladi (o'qitish jarayonida to'g'ri bosh so'z yo'qotish funksiyasi orqali ta'kidlanadi). Turli bosh so'zlar uchun ballarni taqqoslash orqali model har bir so'z uchun eng yuqori ball to'plagan bosh so'zni tanlashi mumkin, bu chuqur diqqat mexanizmi tanloviga o'xshaydi. Eng muhimi, parser bu e'tibor ko'rsatkichlarini hisoblash uchun bi-affin baholash funksiyasidan foydalanadi (quyida tushuntiriladi). Bu unga bosh va qaram elementlar tasvirlari o'rtasidagi o'zaro ta'sirlarni boy tarzda aks ettirish imkonini beradi. Ushbu e'tiborga asoslangan baholash bosqichma-bosqich o'rgatiladi, bu esa modelga bosh va qaram elementlarning qaysi xususiyatlari yaxshi bog'lanishni hosil qilishini o'rganish imkonini beradi. Mazkur yondashuv bir nechta tilda arxiv.org saytida eng zamonaviy aniqlikka erishdi, bu esa parsing jarayonida e'tiborning kuchini ko'rsatdi. Quyida arxitektura va baholash mexanizmini batafsil tavsiflaymiz.

Bi-affin parser arxitekturasi. Bizning parserimiz grafik asosidagi bog'liqliklarni tahlil qilishda qo'llaniladigan standart kodlash-so'ng-baholash tizimiga asoslanadi. Ushbu jarayon quyidagi uch asosiy tarkibiy qismdan iborat:

Embedding Layer: Each word in the input sentence is represented by concatenating a word embedding and a part-of-speech (POS) tag embedding nlp.stanford.edu, nlp.stanford.edu. We use the UD Uzbek treebank's provided universal POS tags for this purpose. For example, a word like "kitoblarni" may be represented by a 100-dimensional word vector $v^{\{\text{word}\}}$ and a POS tag embedding $v^{\{\text{tag}\}}$ (for

NOUN) of size 50; the combined input vector $x_i = v[i](\text{word}) \oplus v[i](\text{tag})$ feeds the next layer. These embeddings can be initialized randomly; given the small dataset, we did not have pre-trained Uzbek word vectors available. We add a special token for the *ROOT* (sentence head) with its own learned embedding, so that the parser can attach root-dependent relations. We also experimented with using character-level embeddings (via a CharLSTM) to handle Uzbek's rich morphology, as recommended by [3] for low-resource languages {link}, but for simplicity the results reported here use word+POS embeddings only.

1. **Kirish qatlami:** Kiritilgan jumladagi har bir so'z so'z joylashtirish va so'z turkumi (POS/Part-Of-Speech) tegi joylashtirishni birlashtirish orqali ifodalanadi[3]. Buning uchun UD O'zbek treebank tomonidan taqdim etilgan universal POS-teglardan foydalanamiz. Masalan, "kitoblarni" kabi so'z 100 o'lchovli v^{word} so'z vektori va 50 o'lchovli v^{tag} (Ot uchun) POS tegi joylashtirish bilan ifodalanishi mumkin; $x_i = v_i(\text{so'z}) \oplus v_i(\text{tag})$ birlashtirilgan kirish vektori keyingi qatlamga uzatiladi. Ushbu joylashtirishlar tasodifiy ravishda ishga tushirilishi mumkin; kichik ma'lumotlar to'plamini hisobga olgan holda, bizda oldindan o'qitilgan o'zbekcha so'z vektorlari mavjud emas edi. Parser ildizga bog'liq munosabatlarni bog'lashi uchun o'z o'rganilgan joylashtirishiga ega bo'lgan ROOT (gap bosh qismi) uchun maxsus belgi qo'shamiz. Shuningdek, biz [3] tomonidan kam resursli tillar uchun tavsiya etilganidek, o'zbek tilining boy morfologiyasini qayta ishlash uchun belgi darajasidagi joylashtirishlardan (CharLSTM orqali) foydalanishni sinab ko'rdik, ammo bu maqolada keltirilgan natijalar faqat so'z+POS joylashtirishlaridan(embedding) foydalanadi.

2. **Ikki yo'nalishli LSTM enkoderi:** $[x_1, x_2, \dots, x_n]$ vektorlarni joylashtirish ketma-ketligi ko'p qatlamli BiLSTM tarmog'iga kiritiladi. BiLSTM har bir so'z uchun kontekstli tasvirlarni yaratadi, bu esa ham chap, ham o'ng kontekstdagi ma'lumotlarni kodlaydi. Ya'ni, BiLSTMni quyidagicha hisoblash mumkin:

$r_1, r_2, \dots, r_n = \text{BiLSTM}(x_1, x_2, \dots, x_n)$ bunda har bir r_i i -pozitsiyasi uchun to'g'ri va teskari LSTM



yashirin holatlarining birlashmasidir. i so'z uchun kontekstual yashirin holatni $h_i = r_i$ deb belgilaymiz. Biz har bir yo'nalish uchun yashirin o'lchami 400 bo'lgan 2 qatlamli BiLSTMdan foydalandik, shuning uchun har bir h_i 800 o'lchamli (400×2). Regularizatsiya uchun kirish joylashtirishlariga va LSTM qatlamlari orasida 23% tezlikda dropout qo'llaymiz[9]. BiLSTM ketma-ketlikni $H = [h_1; h_2; \dots; h_n]$ matrisasiga (o'lchami $n \times 800$) aylantiradi, bu esa baholash qatlamlariga kirish sifatida xizmat qiladi. BiLSTM ketma-ketlikni matritsaga aylantiradi;

3. Har bir BiLSTM chiqish vektori h_i dan model uning bosh va tobe(iyerarxa) element sifatidagi roli uchun maxsus tasvirlarni hisoblaydi. Biz har bir h_i ni ikkita to'g'ridan-to'g'ri tarmoq (bir yashirin qatlamli va ReLU faollashtiruvchi ko'p qatlamli perseptronlar) orqali o'tkazib, quyidagilarni olamiz(2):

$$h_j^{(head)} = MLP_{head}(h_j) \quad (2)$$

bunda har bir qatlamning o'lchami d ga teng (yoylarni baholash uchun $d=100$ ni belgilaymiz). Ushbu MLPlar yoyni baholash vazifasiga moslashtirilgan past o'lchamli xususiyat vektorlarini o'rganadi - biri so'z tobe bo'lganda, ikkinchisi esa boshqaruvchi so'z bo'lganda. MLP qatlamlariga ham 33% dropout qo'llaymiz. So'ngra, **bi-affin diqqat** mexanizmi har bir mumkin bo'lgan yo'naltirilgan yoy ($j \rightarrow i$) uchun ball hisoblaydi. Matematikada bi-affin funksiya ikkita vektor argumentga nisbatan affin o'zgartirishdir. Buni quyidagicha amalga oshiramiz (3):

$$\left[s_{ij}^{\{arc\}} = \left(h_j^{(head)} \right)^T W^{(arc)} h_i^{dep} + \left(u^{(head)} \right)^T h_j^{(head)} \right] \quad (3)$$

Bu yerda $W^{(arc)}$ o'rganilgan $d \times d$ o'lchamli vazn matritsasi va u^{head} o'rganilgan d o'lchamli vektor (ikkinchi had affin qism) hisoblanadi. Intuitiv ravishda, birinchi had (ikki chiziqli shakl) j so'zining bosh ko'rinishi bilan i so'zining bog'liq ko'rinishi o'rtasidagi **moslikni** ifodalaydi. Ikkinchi had $\left(u^{(head)} \right)^T h_j^{(head)}$ j so'zining bosh(head/root)

vazifasini bajarish oldingi ehtimolligini aks ettiruvchi siljish (ba'zan "headness/boshsiz" siljishi deb ham ataladi) sifatida qaralishi mumkin. Amalda, model har bir bog'liqlik uchun siljish vektorini ham o'z ichiga oladi (uning bog'liq ko'rinishiga qo'llaniladi). Ballar nisbiy bo'lganligi sababli, umumiy siljish atamasiga ehtiyoj yo'q.

Amalda, model har bir bog'liq element uchun siljish vektorini ham o'z ichiga oladi (bu uning bog'liq ko'rinishiga qo'llaniladi), garchi bu siljitma soddalik uchun formulada aniq ko'rsatilmagan. Ballar nisbiy bo'lgani sababli, umumiy siljitma atamasiga ehtiyoj yo'q.

Natijada hosil bo'lgan yoy bali $s_{ij}^{\{arc\}}$ deb belgilanadi) j so'zining i so'zning boshi bo'lish ehtimolini ko'rsatadi. Ballar barcha so'z juftliklari uchun, shu jumladan ildizga bog'liq so'zlarning boshi bo'lib xizmat qilishi mumkin bo'lgan maxsus ROOT belgisi uchun ham hisoblanadi. Ushbu baholash bosqichi diqqat mexanizmiga o'xshash ishlaydi, bunda har bir tobe(iyerarxik) so'z (so'rov vazifasini bajaruvchi) har bir mumkin bo'lgan bosh so'z (kalit vazifasini bajaruvchi) uchun ball oladi. Bu baholash zich bo'lib, u aniq lingvistik xususiyatlarga tayanmaydi. Bu esa neyron tarmog'iga boshlar va tobe elementlar o'rtasidagi muvofiqlik, masofaga asoslangan jazolar va boshqa foydali munosabatlar kabi qonuniyatlarni yashirin tarzda o'rganish imkonini beradi.

O'qitish jarayonida, bu ballar hisoblanganidan so'ng, har bir bog'liq so'z i uchun potensial boshqaruvchi so'zlar bo'yicha ehtimollik taqsimotini yaratish maqsadida softmax funksiyasi qo'llaniladi. Model to'g'ri boshqaruvchi so'zni tanlash ehtimolini maksimal darajada oshirish orqali o'qitiladi, bunda kross-entropiya yo'qotish funksiyasidan foydalaniladi. Sinov paytida model har bir bog'liq so'z i uchun (maxsus ROOT belgisidan tashqari) eng yuqori ball olgan boshqaruvchi so'zni j tanlaydi. Natijada, sintaktik tahlil daraxtini hosil qiluvchi yo'naltirilgan yoylarning natijaviy to'plami shakllanadi.

Har bir bog'liqlik uchun eng yuqori ball to'plagan boshni mustaqil tanlashda yuzaga kelishi



mumkin bo'lgan muammolardan biri shundaki, hosil bo'lgan grafik sikllarni yoki bir nechta ildizlarni o'z ichiga olishi mumkin. Yaxshi shakllangan tahlil daraxtini ta'minlash uchun model bunday muammolarni tuzatish uchun post-qayta ishlashdan foydalanadi: agar sikl aniqlansa, u ushbu sikldagi eng past ball to'plagan yoyni olib tashlash orqali hal qilinadi; xuddi shunday, agar bir nechta ildizlar topilsa, eng yuqori ball to'plagan ildiz saqlanib qoladi, boshqalari esa qayta tayinlanadi. Amalda bunday tuzatishlar kamdan kam uchraydi. Daraxt tuzilishini ta'minlashning yana bir mumkin bo'lgan usuli maksimal qamrovli daraxt algoritmidan foydalanishdir, ammo o'zbek tili sintaksisi asosan proyektiv (SOV standart tartibi bilan) bo'lgani uchun, odatda, Eysner algoritmi kabi oddiyroq proyektiv dekodlash algoritmlari yetarli bo'ladi. Struktura (yo'ylar) aniqlangandan so'ng, tahlilchi har bir bashorat qilingan yoyga bog'liqlik belgisini ("nsubj," "obj," "case" va boshqalar) beradi. Ushbu belgilash bosqichi ham shunga o'xshash bi-affin tasniflagichdan foydalanadi, ammo tobe va bosh so'zlarning alohida munosabatga xos ko'rinishlari uchun qo'llaniladi. Xususan, har bir nomzod yoyi uchun model o'lchami mumkin bo'lgan bog'liqlik belgilarining umumiy soniga teng bo'lgan ball vektorini hisoblaydi. Bu qiymatlar o'rganilgan tenzorni o'z ichiga olgan boshqa bi-affin almashtirish orqali hisoblanadi, bu esa bosh va bog'liq vektorlarni har bir potensial belgi uchun qiymatga aylantiradi. Amalda bu qadam har bir nomzod yoyi uchun ballar vektorini chiqaradigan bichizikli qatlam bilan amalga oshiriladi. Keyin eng yuqori ball to'plagan teglar tanlanadi.

Yoy va yorliq bashoratlari o'zaro entropiya yo'qotishlarini qo'shish orqali birgalikda o'rgatiladi, bu esa modelni tuzilmani (yo'ylarni) bashorat qilishda ham, teglarni tayinlashda ham foydali bo'lgan umumiy tasavvurlarni o'rganishga undaydi.

Umumiy arxitektura odatda BiLSTM enkoderi orqali qatlamlarni joylashtirishdan, keyin yoyni hisoblashdan va oxirida belgilangan chiquvchida tasvirlanadi. Ushbu algoritim [3] tomonidan taklif qilingan arxitekturaga juda mos keladi.

Korpus va unda o'qitishni sozlash. Biz Uzbek-UT treebankini (500 ta gap) 80%/10%/10% bo'linishdan so'ng trening (400 ta), rivojlanish (50 ta) va test (50 ta) to'plamlariga bo'ldik. Ma'lumotlar to'plamining cheklanganligini hisobga olgan holda, biz ortiqcha moslashuvning oldini olish uchun 0,33 ehtimollik bilan agressiv muntazamlashtirish - joylashtirish, takroriy (LSTM) va MLP qo'lladik. Adam optimizatori (dastlabki o'rganish tezligi 0,002) bilan birga dastur to'plamida erta to'xtash ishlatilgan va o'rganish tezligi har 5000 iteratsiyada 0,75 baravar kamaygan. Mashg'ulotlar konvergensiya uchun yetarli bo'lgan 30 davr davom etdi. Kiritmalar tasodifiy ravishda ishga tushirildi (so'z kiritmalari: 100 o'lchovli, POS kiritmalari: 50 o'lchovli). BiLSTM har bir yo'nalishda 400 birlikdan iborat ikkita qatlamga ega edi va yo'ylar va munosabatlar uchun MLP qatlamlari ReLU faollashtirilgan 100 birlikdan iborat yashirin qatlamga ega.

Taqqoslash uchun biz, shuningdek, yoyli standart tizimdan foydalangan holda o'tishga asoslangan (transition-based) analizatorni o'qitdik (Dyer et al., 2015; Kipervasser va Goldberg, 2016). Ushbu bazisda bir xil o'rnatmalar va taqqoslanadigan BiLSTM va MLP o'lchamlari qo'llanilgan. Ikki affinli analizatoridan farqli o'laroq, o'tishga asoslangan analizator xatolar tarqalishini kamaytirish uchun dinamik orakul yordamida o'qitilgan analizatorning joriy holatlari (stek, bufer, harakatlar tarixi) asosida tahlil harakatlarini (SHIFT, LEFT-ARC, RIGHT-ARC) bosqichma-bosqich bashorat qiladi. Xulosa chiqarishda u ochko'z dekodlash strategiyasidan foydalanadi, bu esa o'z-o'zidan chiziqli vaqt ichida yaxshi shakllangan proyektiv daraxtni hosil qiladi. Ushbu asosiy chiziq global biaffin baholash yondashuvi o'zbek qaramlik tahlili uchun afzalliklarni taqdim etishini baholashga yordam beradi.

Natijalar. Biz tahlil aniqligini standart ko'rsatkichlar yordamida baholaymiz: Yorliqsiz biriktirish balli (UAS) - to'g'ri sarlavha berilgan so'zlar foizi (tinish belgilaridan tashqari) va Yorliqli biriktirish balli (LAS) - ham to'g'ri sarlavha, ham to'g'ri bog'liqlik yorlig'i berilgan so'zlar foizi. 1-jadvalda chuqur biaffinli analizatorimizning o'zbek



test to'plamidagi o'tishga asoslangan bazisga nisbatan ishlash samaradorligi keltirilgan.

Model	UAS	LAS
Biaffine	79.5%	72.4%
Transition-based Baseline	72.8%	65.0%

1-jadval: UB test to'plamida tahlil aniqligi

Biaffinli tahlilchi yorliqsiz biriktirish balli (UAS) 79,5 va yorliqli biriktirish balli (LAS) 72,4 ni tashkil etadi, bu o'tish asosidagi asosiy ko'rsatkichdan sezilarli darajada ustundir (UAS: 72,8, LAS: 65,0). Ma'lumotlar to'plamining kichikligiga qaramay, neyron tahlilchisining samaradorligi e'tiborga loyiq bo'lib, u boy tasavvurlar va global e'tibor mexanizmlaridan samarali umumlashtirishni namoyish etadi. Yaxshilanish (+6,7 UAS, +7,4 LAS) shuni tasdiqlaydiki, global bi-affin baholash, ochko'z(greedy) o'tish qarorlaridan ko'ra, bog'liqlik noaniqliklarini yaxshiroq hal qilishga yordam beradi. Xatolar tahlili o'zbek tilining moslashuvchan so'z tartibini aks ettiruvchi uzoq masofali bog'liqliklar va noaniq kelishik belgilash bilan bog'liq umumiy muammolarni ko'rsatadi. Biaffin modeli frontal ob'ektlarni ba'zan yaqinroq boshlarga noto'g'ri biriktiradi, ammo o'tishga asoslangan baza chizig'iga qaraganda ancha kamroq.

Xulosa qilib aytganda, biz yangi taqdim etilgan UB daraxt korpusidan foydalanib, o'zbek tili uchun chuqur biaffin neyron diqqat nexanizmiga asoslangan bog'liqlikni tahlil qildik. Shuningdek, bunda tahlilchining neyron arxitekturasi (BiLSTM koderi, biaffin tasniflagichlar) va o'qitishni sozlash (giperparametrlar, dropout, optimallashtirgich) haqida batafsil ma'lumot berib o'tildi. Tajribalar shuni ko'rsatdiki, ushbu grafga asoslangan usul o'tishga asoslangan sezilarli darajada ustun bo'lib, global baholash va boy xususiyatlarning o'zbek tilining morfologik murakkabligi va moslashuvchan so'z tartibi uchun aniq afzalliklarini ko'rsatadi. Aniqlik yuqori resursli tillardan past bo'lsa-da, bu natijalar kuchli asosni ta'minlaydi. Kelajakdagi tadqiqotlar o'zbek tilidagi tahlilni yanada takomillashtirish uchun

belgi darajasidagi morfologiya, ko'p tilli oldindan o'rgatilgan qo'shimchalar va yarim nazoratli o'rganishni birlashtirishi mumkin. Ushbu ish kam resursli tillar uchun NLP imkoniyatlarini rivojlantirishga hissa qo'shadi.

Foydalanilgan adabiyotlar.

1. Ryan McDonald, Fernando Pereira, Kiril Ribarov, and Jan Hajič. 2005. [Non-Projective Dependency Parsing using Spanning Tree Algorithms](#). In *Proceedings of Human Language Technology Conference and Conference on Empirical Methods in Natural Language Processing*, pages 523–530, Vancouver, British Columbia, Canada. Association for Computational Linguistics.
2. Joakim Nivre. 2008. Algorithms for Deterministic Incremental Dependency Parsing. *Computational Linguistics*, 34(4):513–553.
3. Dozat, T., & Manning, C. D. (2016, November 6). Deep biaffine attention for neural dependency parsing. [arXiv.org. https://arxiv.org/abs/1611.01734](https://arxiv.org/abs/1611.01734)
4. Eliyahu Kiperwasser and Yoav Goldberg. 2016. Simple and Accurate Dependency Parsing Using Bidirectional LSTM Feature Representations. *Transactions of the Association for Computational Linguistics*, 4:313–327.
5. Arofat Akhundjanova, & Luigi Talamo (2025). Universal Dependencies Treebank for Uzbek. In *Proceedings of the Third Workshop on Resources and Representations for Under-Resourced Languages and Domains (RESOURCEFUL-2025)* (pp. 1–6). Association for Computational Linguistics.
6. Bahdanau, D., Cho, K., & Bengio, Y. (2014, September 1). Neural machine translation by jointly learning to align and translate. [arXiv.org. https://arxiv.org/abs/1409.0473](https://arxiv.org/abs/1409.0473)
7. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I. (2017, June 12). Attention is all you need. [arXiv.org. https://arxiv.org/abs/1706.03762](https://arxiv.org/abs/1706.03762)
8. https://en.wikipedia.org/wiki/Attention_Is_All_You_Need#:~:text=Google,approach%20has%20become%20the%20main
9. Diederik Kingma and Jimmy Ba. 2014. Adam: A method for stochastic optimization. *International Conference on Learning Representations*.
10. Chris Dyer, Miguel Ballesteros, Wang Ling, Austin Matthews, and Noah A. Smith. 2015. Transition-Based Dependency Parsing with Stack Long Short-Term Memory. In *Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Volume 1: Long Papers)*, pages 334–343, Beijing, China. Association for Computational Linguistics.



Интеграция традиционных и компьютерных методов в оптимизацию процессов увлажнения пшеничного зерна

А.А. Уринбоев,
Ферганский Политехнический институт,
Фергана, Узбекистан
urinboevabdushukur@gmail.com

Б.Р. Исмаилов,
Южно-Казахстанский университет им.
М.Ауэзова, Шымкент, Казахстан
ismailb@mail.ru

Аннотация. В данном исследовании рассматривается процесс гидротермической обработки пшеничного зерна с целью оптимизации условий его увлажнения для повышения качества муки. Используя как традиционные методы анализа, так и современные компьютерные технологии моделирования, в частности программу COMSOL Multiphysics, были изучены динамика распределения влаги в различных слоях зерна (оболочка, эндосперм, зародыш) и влияние этих процессов на эффективность помола. Экспериментальные результаты показали, что холодное и скоростное кондиционирование имеют различные преимущества в зависимости от физико-химических характеристик зерна. Холодное кондиционирование обеспечивает равномерное увлажнение зерна, что важно для сортов с плотной оболочкой, тогда как скоростное кондиционирование ускоряет процесс обработки и повышает производительность при работе с сортами, имеющими низкое содержание влаги.

Ключевые слова: Гидротермическая обработка, увлажнение зерна, компьютерное моделирование, характеристики зерна, технологические процессы

ВВЕДЕНИЕ. В современном производстве пшеничной муки автоматизация всех этапов процессов играет важную роль в повышении качества конечного продукта. Современные технологии позволяют оптимизировать работу мукомольных заводов, обеспечивая достаточно точный контроль за всеми этапами переработки зерна. Внедрение информационных систем и методов обучения способствует улучшению управления производственными процессами, а также позволяет более эффективно анализировать свойства муки. Использование автоматизированных решений и новых методов обработки позволяет значительно повысить производительность и снизить затраты на производство.

В последнее время появилось большое количество работ в этом направлении. Например, в работе [1] рассмотрены изменения клеточной

стенки внешних слоев зерна пшеницы, особенно лигнина и ферулата. Лигнификация начинается раньше, чем ожидалось, а на поздних стадиях образуются поперечные связи, вероятно, ограничивающие рост зерна, что даёт новое понимание развития пшеницы. В статье [2] представлен метод глубокого обучения для прогнозирования количества зерен сорго с использованием облаков точек и изображений Red Green Blue (RGB), достигающий минимальной ошибки и демонстрирующий потенциал мультимодального подхода. В [3] изучена влияние жары и засухи на распределение белка и крахмала в зерне пшеницы. Heat stress and drought stress (HDS) увеличивает содержание белка в эндосперме и снижает крахмал, с вариациями по слоям. Результаты подчеркивают влияние климата на качество пшеницы и ее помол. В [4] разработана проблема качества пшеничной муки через



прогнозирование свойств при дебрании, включающем удаление алейронового слоя. Исследование показывает, что длительное дебрание увеличивает содержание жира и белка, снижая золу. Модель эффективно прогнозирует содержание золы, подчеркивая важность дебрания для улучшения качества муки.

Физико-химические и биологические свойства пшеницы играют ключевую роль в определении её технологической ценности и качества конечных продуктов. Классификация сортов пшеницы основана на анализе параметров, таких как содержание белка, клейковины, крахмала и биологической активности, что напрямую влияет на процесс переработки зерна. Эти характеристики обеспечивают основу для оценки пригодности пшеницы в различных областях пищевой промышленности. В работах [5-7] выделяются ключевые аспекты применения современных технологий для оценки качества пшеницы. Высокопроизводительный метод гиперспектральной визуализации в сочетании с машинным обучением позволяет эффективно предсказывать содержание питательных веществ и их распределение в зернах. Технология гиперспектральной визуализации также играет важную роль в оценке физико-химических свойств, выявлении грибковых загрязнений и классификации сортов пшеницы. Кроме того, новая модель обучения с использованием физических закономерностей значительно повышает точность оценки биохимических признаков озимой пшеницы, сочетая физическое моделирование с глубоким обучением. Таким образом, современные технологии анализа существенно улучшают качество и эффективность оценки пшеницы, способствуя устойчивости и эффективности сельского хозяйства.

Современные информационные технологии и искусственный интеллект значительно трансформируют методы обработки и анализа сельскохозяйственных культур, включая пшеничное зерно. Внедрение автоматизации и

ультразвуковых технологий, а также использование нейронных сетей, способствует повышению точности и эффективности оценки качества зерна. В анализированных нами статьях [8-17] используются современные инструментальные и компьютерные методы, которые подчеркивают значительное влияние цифровых технологий, глубокого обучения и автоматизации на инновации в зерновом производстве. Использование методов, таких как нейронные сети и ультразвуковая обработка, демонстрирует потенциал для повышения эффективности, точности и устойчивости в агропромышленном секторе. Эти инновационные исследования не только способствуют улучшению качества и производительности зерновых культур, но и открывают новые перспективы для оптимизации процессов в условиях меняющегося климата и растущих потребностей в продовольствии. В работах [18-19] обоснованы значимые аспекты фотометрических и колориметрических характеристик зерна пшеницы, что позволяет разработать эффективные методы экспресс-оценки его качества, основанные на оптических свойствах. Проведенные исследования охватывают разнообразные сорта пшеницы, включая озимую и яровую, а также различные степени обесцвеченной и поврежденности, что подтверждает широту применения предложенных методов. Использование современных инструментальных подходов, таких как спектрофотометрия и светометрия, наряду с многоэтапными циклами измерений, обеспечивает высокую достоверность и точность полученных данных, что в свою очередь способствует согласованию между визуальной и инструментальной оценками (рис. 1).



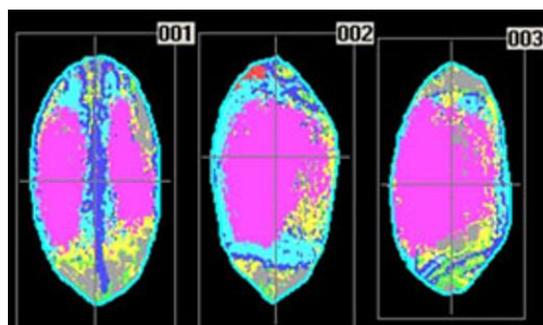


Рисунок 1. Зоны цветности зерна пшеницы

Исследование трехмерной морфометрии с применением линейной лазерной бинокулярной камеры демонстрирует возможности автоматизации и повышения эффективности процессов анализа геометрических характеристик зерен. Полученные данные о морфологических показателях с минимальной среднеквадратической ошибкой и высокой скорости обработки свидетельствуют о перспективности данного подхода для углубленного изучения зерен пшеницы (рис. 2).

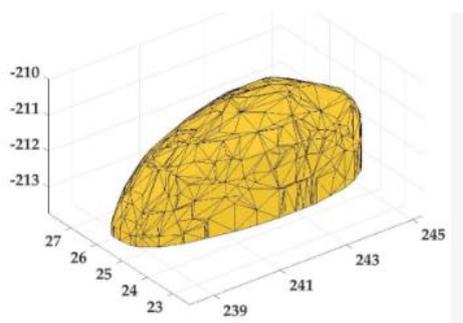


Рисунок 2. Северо-восточный вид 3D-модели зерна

Ранее проведенные исследования основаны на изучении физико-химических и биологических состояниях пшеницы, а также на внедрении информационных технологий в полевых условиях. Вместе с тем, применение информационных технологий в процессе производства муки на мукомольных комбинатах остается недостаточно изученным аспектом, что ограничивает возможности оптимизации технологических процессов в данной сфере. В этой статье с целью исследования комплекса характеристик зерна

перед помолом нами применен системный анализ, направленный на определение времени, необходимого для проникновения влаги в различные слои зерна, а также на установление времени, необходимого для достижения оптимального уровня увлажненности всего зерна. Проведенный выше краткий анализ имеющихся работ показывает, что представление 3D-морфологических показателей зерна имеет большое значение для понимания влагопоглощающей способности зерна вообще, и гидратации в частности. Поэтому, нами проведены систематические эксперименты с целью составления достаточно полного представления о форме и геометрических размерах зерна, а также о распределения влаги по его объему в зависимости от времени увлажнения. Экспериментальные исследования были проведены с использованием как традиционных методов, так и современных компьютерных технологий, в частности, программного обеспечения COMSOL Multiphysics. Данный подход позволил не только сравнительно оценить результаты, но и выявить различия в эффективности и точности двух методов. В частности, применение компьютерных технологий дало возможность более точно моделировать процессы влагообмена, учитывая физические и химические характеристики зерна.

В представленных 3D графиках (Рис. 3-5) иллюстрируются морфологические характеристики зерна, что имеет важное значение для понимания процессов увлажнения. Рис. 3 демонстрирует характерную овальную форму зерна и его симметричную структуру, что критически важно для анализа влагопоглощения.



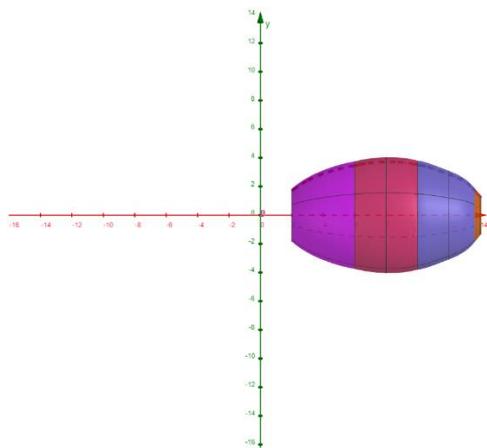


Рисунок 3. 3D Модель зерна с овальной формой

Результаты исследования подчеркивают, что внедрение компьютерных технологий может значительно повысить эффективность процессов увлажнения, что, в свою очередь, способствует улучшению качества конечного продукта на мукомольных заводах. Данное исследование открывает новые перспективы для автоматизации процессов на мукомольных предприятиях, позволяя использовать данные для более точного управления технологическими параметрами и, как следствие, улучшения качества муки.

На рис. 4 представлена визуализация, позволяющая детально рассмотреть распределение влаги по поверхности зерна во время увлажнения.

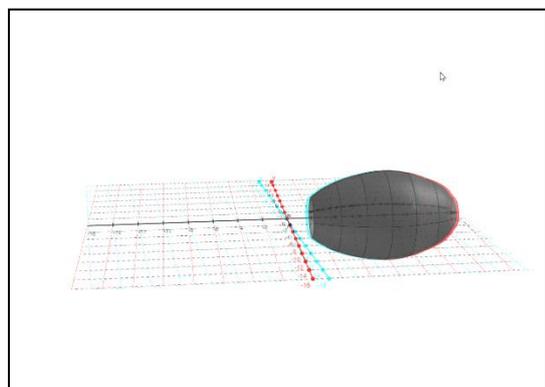


Рисунок 4. Визуализация процессов увлажнения на поверхности зерна

С использованием программного обеспечения COMSOL Multiphysics была

разработана трехмерная модель пшеницы, которая была интегрирована в программу для последующего моделирования процессов. Данные аспекты исследования освещены в последующих разделах работы, что позволяет более глубоко понять взаимосвязь между геометрическими характеристиками зерна и его физико-химическими свойствами.

Рис. 5 предлагает боковой ракурс 3D модели, подчеркивая геометрические размеры зерна и его симметричность, что непосредственно влияет на его способность к влагопоглощению.

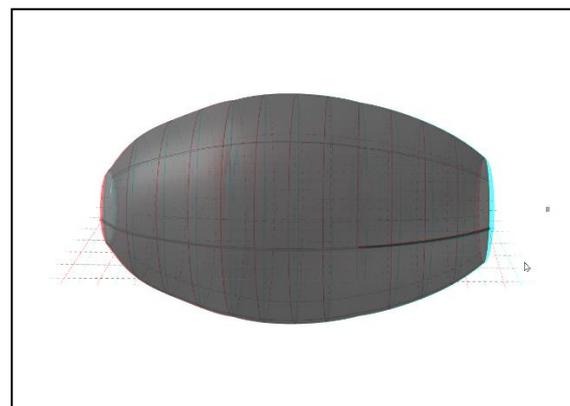


Рисунок 5. Боковой ракурс 3D Модели зерна с акцентом на геометрические размеры

Все три графика показывают, как форма и размеры зерна могут повлиять на динамику увлажнения и его физико-химические характеристики. Эти визуализации служат основой для системного анализа, который мы проводим для оптимизации технологических процессов на мукомольных заводах. Данные графики подтверждают, что точное моделирование морфологических характеристик зерна важно для разработки эффективных методов увлажнения.

Результаты исследования показывают, что внедрение компьютерных технологий может значительно повысить эффективность процессов увлажнения, что в свою очередь, способствует улучшению качества конечного продукта на мукомольных заводах. Результаты 3D визуализации также показывают, как различные сорта пшеницы могут иметь разные профили влагопоглощения в зависимости от их морфологии.



Использование современных технологий для создания этих графиков улучшает наше понимание процессов, происходящих внутри зерна при увлажнении.

В ходе исследования проведен анализ сортов пшеницы, возделываемых в регионе Ферганы Республики Узбекистан, и осуществил отбор образцов для последующего изучения. Для каждого сорта были измерены геометрические размеры зерен, что позволило создать основу для дальнейшего анализа. Результаты этих измерений и их интерпретация представлены в следующем разделе.

2. ПРЕДЛАГАЕМЫЙ МЕТОД ИССЛЕДОВАНИЯ

Увлажнение зерна представляет собой важный этап его подготовки к дальнейшей технологической переработке. Данный процесс способствует размягчению и повышению эластичности оболочки зерна, что облегчает её отделение от эндосперма, обеспечивая тем самым повышение эффективности производства и улучшение качества конечного продукта, такого как мука. Увлажнение оказывает влияние на физико-химические свойства зерна, укрепляя его структурную целостность и упрощая последующие технологические операции, включая помол. Таким образом, процесс увлажнения играет ключевую роль в производственной цепочке, существенно влияя на качество и эффективность технологического процесса.

2.1. Определение структурные и геометрические характеристики зерна пшеницы

В данном разделе представлен методологический подход, применяемый для изучения анатомических и морфологических характеристик пшеничного зерна. Используемая методология интегрирует традиционные методы измерения с современными вычислительными моделями, что позволяет проводить глубокий и всесторонний анализ физических свойств зерна.

Такой комплексный подход обеспечивает высокую точность и достоверность результатов исследования, а также способствует более полному пониманию взаимодействий между различными компонентами зерна.

В ходе лабораторного эксперимента было проведено исследование структуры пшеничного зерна, заключающееся в его разделении на отдельные слои. Каждый слой зерна был подвергнут измерению с целью получения данных о его физических характеристиках. Изучались параметры оболочки, эндосперма и зародыша, что позволило понять строение зерна. На рис. 6 представлены изображения пшеничного зерна и его разреза, демонстрирующие внутреннюю структуру. Полученные результаты послужат основой для дальнейших исследований по изучению функциональных свойств каждого слоя зерна.



Рисунок 6. Изображение цельного и разрезанного пшеничного зерна

Согласно сортовым характеристикам, геометрическому описанию и анатомии зерна, соотношение массы его анатомических частей варьируется в определенных пределах. Зерно пшеницы состоит из нескольких ключевых анатомических частей, каждая из которых выполняет свою функцию и имеет значение для общего качества и питательной ценности продукта. Зародыш, расположенный у основания зерна, составляет около 1,4–3,8% от всей его массы. Эта часть является самой важной, так как из зародыша формируется всё растение. Эндосперм — самая большая составляющая зерна, составляет 77–85%



от его массы. Эта питательная часть состоит из крахмала, который составляет до 59%. Эндосперм обеспечивает зерно питательной ценностью и является источником энергии. Внешняя оболочка зерна составляет примерно 15% от его массы. Она состоит из нескольких слоёв и при помоле образует отруби, богатые минеральными солями, клетчаткой, витаминами, белком и целлюлозой. Несмотря на низкую питательную ценность, оболочка очень полезна, так как способствует нормализации перистальтики кишечника. На рис 7 представлены пропорции анатомических частей зерна пшеницы, наглядно демонстрирующие соотношение зародыша, эндосперма и оболочки [20].

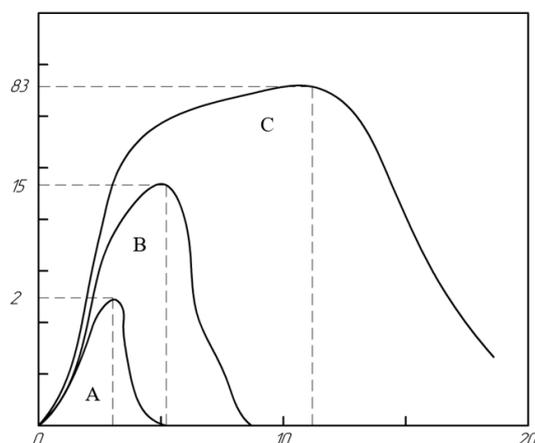


Рисунок 7. Состав зерна пшеницы по анатомическим частям

А) Зародыш В) Эндосперм С) Оболочка

Количество эндосперма зависит от геометрического размера зерна. Если отсортировать крупные зерна в сите (2,8x2,0) и отделить мелкие, то содержание эндосперма в зерне составляет 83-85%, и мы увидим, что содержание эндосперма в мелком зерне, отделенном ситом, снизиться до 79-77%. Таким образом, видно, что чем больше геометрический размер зерна, тем выше содержание в нем эндосперма. В процессе производства муки важно количество эндосперма, эндосперм превращается в муку, а его внешние слои отделяются как побочный продукт (отруби). Согласно общим критериям

приемки, из 100 кг пшеницы ориентируется на выход 70-72 кг муки, а остальное отделяют в виде отрубей.

В ходе исследования были отобраны образцы различных сортов пшеницы, культивируемых в Ферганской долине, с целью анализа их морфологических характеристик. Измерения геометрических параметров слоев зерна позволили получить данные о структуре эндосперма каждого сорта. На приведенном ниже изображении представлены результаты измерений, иллюстрирующие вариативность эндосперма среди изученных образцов. Данные результаты способствуют глубокому пониманию анатомических особенностей зерна пшеницы и могут быть использованы для дальнейших исследований в области агрономии и качества зерна. На рис. 8 показана гистограмма расчетного выхода количества эндосперма изученных сортов пшеницы

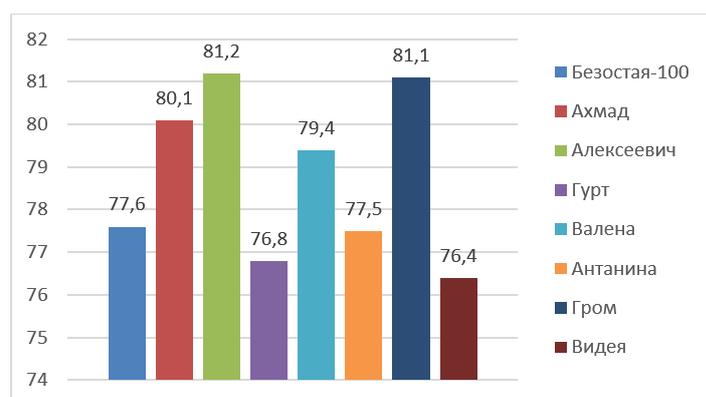


Рисунок 8. Гистограмма расчетной выход количества эндосперма зерна пшеницы

2.2. Экспериментальное исследование динамики концентрации по времени в разных точках зерна.

На мукомольных заводах применяют два метода кондиционирования зерна: холодное и горячее (ускоренное). Холодное кондиционирование заключается в увлажнении зерна водой комнатной температуры с последующим его настаиванием, в ходе которого рекомендуется применять дополнительное



увлажнение до 0,3-0,5% перед первой системой помола. Данный способ способствует эффективному отделению оболочки от эндосперма. Горячее кондиционирование предполагает обработку зерна влажным паром, что повышает его влажность на 1,5-2% за 20-40 секунд и увеличивает температуру до 45-55°C. Этот метод является более эффективным для обработки зерна с низким содержанием клейковины и используется при ограниченных объемах помола. Ключевые параметры гидротермической обработки включают степень увлажнения, температуру нагрева и продолжительность выдержки зерна, которые зависят от качественных характеристик исходного материала.

На примере деятельности акционерного общества "Фарғонадонмахсулоти", расположенного в Ферганской области, рассмотрено место процесса увлажнения в технологической цепочке приемка зерна-выпуск муки [21]. Основная цель влажнение зерна пшеницы — легко удалить шелуху, верхний слой, не повреждая эндосперм пшеницы. Учитывая климатические условия Ферганской области и особенности посева зерновых культур, акционерное общество "Фарғонадонмахсулоти" преимущественно использует зерно IV сорта. Для данного сорта, в зависимости от уровня прозрачности зерна, продолжительность отставивания составляет от 6 до 24 часов, а рекомендуемая влажность зерна в системе измельчения колеблется в пределах от 15,0% до 16,5%.

Выше были описаны два метода гидротермической обработки и случаи их применения. Метод холодного кондиционирования используется с учетом специфики предприятия, вида зерна и условий, применяемых в акционерном обществе "Фарғонадонмахсулоти".

По результатам измерения количества, состояния зерна и их размеров технолог оказывает значительное влияние на процесс. В акционерном обществе "Фарғонадонмахсулоти" используется

метод горячего кондиционирования зерна, при котором клейковина подвергается воздействию влажного пара. Этот процесс повышает влажность зерна и увеличивает температуру до 45-55°C за короткий промежуток времени. В результате клейковина становится более эластичной, что улучшает качество конечного продукта и способствует повышению эффективности помола. В этом предприятии рекомендуется использование этанола в концентрации 12-13% для достижения оптимальных результатов.

При подготовке зерна к взвешиванию его замачивают дважды: первый этап длится 8 часов, а второй - до 16 часов. Для зерна с удовлетворительной слабой группой клейковины применяется следующий режим тепловой обработки: показатель Индикатора Деформации Клейковины (ИДК) составляет от 80 до 100, температура нагрева варьируется от 50 до 55°C, а продолжительность нагрева — от 4 до 8 минут. Такой подход позволяет эффективно обработать зерно, сохраняя его свойства и обеспечивая высокое качество конечного продукта. Контроль уровня влажности пшеницы осуществляется каждые 3 часа, что позволяет своевременно корректировать процесс подготовки и обеспечивать достижение оптимальных показателей для последующего помола. В процессе подготовки зерна к взвешиванию муки рекомендуется довести влажность до 15,0-16,5%. После достижения этой влажности зерно будет готово к помолу, что обеспечивает получение муки хорошего качества и способствует снижению потребления электроэнергии при переработке.

В процессе исследования было проведено измерение содержания влаги в зернах пшеницы. Для этого 100 граммов пшеницы были предварительно увлажнены водой, отделены от избыточной влаги и помещены в герметичную емкость. Температура в помещении поддерживалась в диапазоне 20-25°C, а температура увлажняющей воды составляла 25-30°C. Уровень влажности пшеницы внутри емкости контролировался с интервалом в 20 минут.



Измерения проводились следующим образом: масса пшеницы определялась с помощью аналитических весов с точностью до 100 граммов. Начальная влажность зерна была установлена на уровне 7%. Для изучения распределения концентрации влаги в зерне 100 граммов пшеничных зерен замачивали в воде на короткое время, после чего зерна извлекались из воды и взвешивались на аналитических весах. Процедура повторялась каждые 40 минут, и полученные значения заносились. После замачивания пшеницы было проведено измерение содержания влаги, при этом начальный уровень влажности зерна был установлен на уровне 7%. Учитывая, что уровень влажности зерен для процесса измельчения составляет 15,5-16,5%, измерения проводились каждые 40 минут до достижения указанной влажности. В результате экспериментов было также измерено содержание влаги в различных слоях зерна.

Представленный на рис. 9 график демонстрирует изменения содержания влаги в различных частях пшеницы: оболочке, эндосперме и зародыше, в зависимости от времени. В процессе эксперимента было замечено, что влажность оболочки пшеницы постепенно увеличивается, достигая значительного значения около 16,5% в течение 200 минут. Этот рост влажности подтверждает необходимость применения многоэтапного увлажнения, как указано в описании технологического процесса.

Первоначально зерно замачивается в течение 8 часов, что способствует начальному усвоению влаги, а затем, во втором этапе, оно дополнительно увлажняется в течение до 16 часов. Такие многократные циклы замачивания обеспечивают равномерное распределение влаги по всей массе зерна. Увлажнение оболочки играет важную роль в облегчении удаления шелухи и улучшении доступа влаги к эндосперму и зародышу.

Согласно данным, представленных на графике, в течение первых 100 минут влажность оболочки увеличивается более значительно по

сравнению с другими частями зерна, что свидетельствует о высоком уровне абсорбции влаги. Этот процесс становится особенно важным для последующей обработки зерна, поскольку уровень влаги в оболочке непосредственно влияет на его общую физико-химическую структуру. В результате многоэтапного увлажнения достигается оптимальная влажность, необходимая для высококачественного помола, что подтверждает эффективность выбранной технологии обработки.

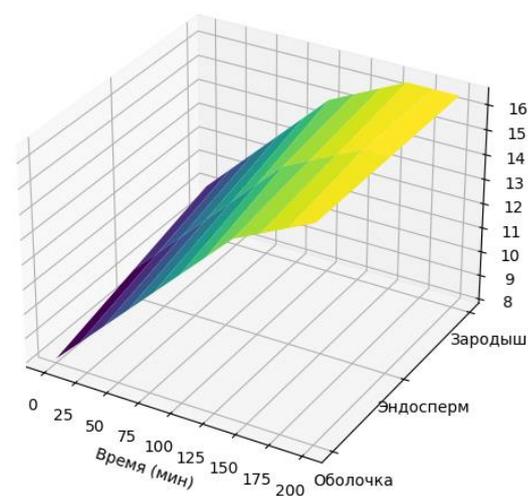


Рисунок 9. График поверхности содержания влаги в слоях пшеницы

На рис. 10 показана динамика изменений содержания влаги в различных слоях пшеничного зерна. Сравнение графиков, представленных на рисунке, показывает, что эндосперм имеет немного более высокую начальную влажность по сравнению с оболочкой, что может быть обусловлено его уникальными структурными и физико-химическими характеристиками. Эндосперм, являясь основной частью зерна, служит запасом питательных веществ, что может привести к более высокой способности удерживать влагу в начале процесса увлажнения.

Эти данные подтверждают заявленное содержание влаги, необходимое для достижения оптимального качества муки, которое составляет 15,0-16,5%. Высокая начальная влажность эндосперма играет важную роль в процессе помола, так как она способствует улучшению



качества муки за счет более равномерного помола и минимизации потерь полезных веществ. Такой уровень увлажненности эндосперма обеспечивает технологические условия, при которых клейковина не повреждается в процессе переработки, что в свою очередь способствует получению муки с высокими функциональными свойствами. Это важно для достижения желаемых характеристик конечного продукта, таких как эластичность и прочность теста, что, безусловно, сказывается на качестве хлебобулочных изделий.

Кроме того, данные рис. 10 могут быть использованы для оптимизации технологических процессов в акционерном обществе "Фаргонадонмахсулоти". Понимание поведения влаги в различных слоях зерна позволяет корректировать режимы увлажнения и кондиционирования, что повышает общую эффективность и качество конечного продукта.

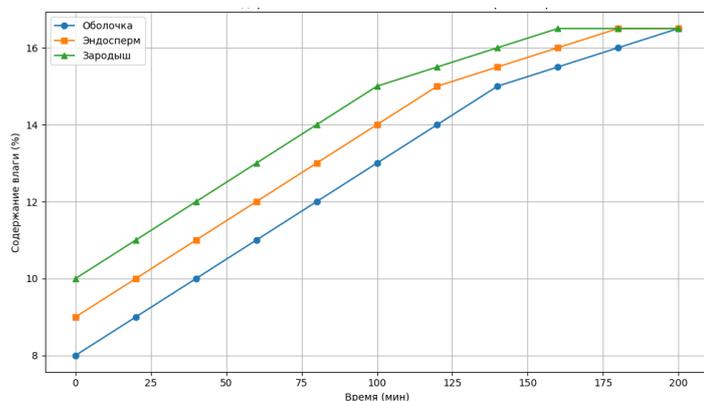


Рисунок 10. Изменение влаги в слоях пшеничного зерна со временем

Процесс контроля влажности в акционерном обществе "Фаргонадонмахсулоти" включает регулярные проверки каждые три часа, что позволяет поддерживать заданные параметры. Это особенно важно, поскольку уровень влажности зерна должен находиться в диапазоне от 15,0 до 16,5%, как указано в тексте. Учитывая, что начальная влажность зерна была установлена на уровне 7%, графики подтверждают, что правильное управление процессом увлажнения обеспечивает достижение целевого уровня.

Важным аспектом, который следует отметить, является использование этанола в концентрации 12-13% в процессе обработки клейковины, что улучшает эффективность увлажнения. Графики показывают, как влажность увеличивается в результате применения данной технологии. Оптимизация условий хранения и увлажнения пшеницы на предприятии непосредственно влияет на качество получаемой муки, снижая при этом потребление электроэнергии.

Рис. 11 визуализирует изменение содержания влаги в различных слоях пшеницы с учетом времени. Размеры пузырей на графике отражают количество влаги в каждом слое, что позволяет быстро и наглядно оценить динамику увлажнения. Каждая точка на графике представляет собой конкретный временной интервал, на протяжении которого проводились измерения, а размеры пузырей соответствуют количественным показателям влажности в оболочке, эндосперме и зародыше. Из анализа графика видно, что для оболочки максимальное значение влажности составило 16,5%, что является важным показателем для достижения оптимальных условий обработки. Это свидетельствует о том, что выбранный метод холодного кондиционирования, применяемый в акционерном обществе "Фаргонадонмахсулоти", оказался эффективным для улучшения качества зерна. Использование этого метода не только способствует более равномерному распределению влаги по всем слоям зерна, но и минимизирует риск повреждения эндосперма во время дальнейшей обработки. Данные, полученные с помощью графика, позволяют заключить, что повышенное содержание влаги в оболочке способствует лучшему отделению шелухи, что является ключевым этапом в процессе переработки зерна.

Кроме того, высокая влажность оболочки является индикатором правильной настройки технологических параметров, что в свою очередь влияет на экономичность и эффективность процесса помола. Это подчеркивает значимость научно обоснованных методов, используемых в



акционерном обществе, для достижения высоких стандартов качества готовой муки.

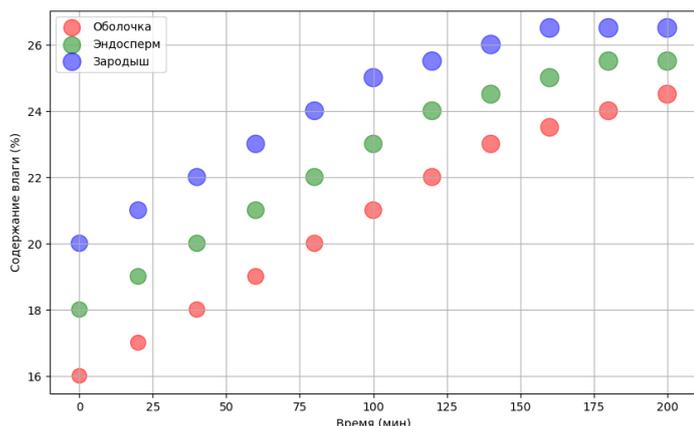


Рисунок 11. График содержания влаги

Суммируя вышеизложенное, экспериментальные данные, отраженные на графиках, служат реальным инструментом для анализа и оценки процессов увлажнения пшеницы. Они показывают, что использование научных методов контроля и регулирования технологических процессов в акционерном обществе "Фарғонадонмахсулоти" ведет к улучшению качества конечного продукта. Это не только повышает эффективность производственных процессов, но и способствует соблюдению современных стандартов качества.

3. РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

В ходе исследования проведена детальная оценка процессов увлажнения зерна пшеницы с использованием различных методов гидротермической обработки, таких как холодное и скоростное кондиционирование. Для определения оптимальных условий увлажнения зерна были применены как традиционные методы анализа, так и современные вычислительные технологии, в частности, программа COMSOL Multiphysics, что позволило получить точные данные о распределении влаги в различных слоях зерна (оболочка, эндосперм, зародыш).

Результаты показали, что холодное кондиционирование зерна способствует постепенному и равномерному увеличению

влажности, что особенно важно для отделения шелухи от эндосперма и улучшения качества конечного продукта — муки. Максимальная влажность, достигнутая в процессе увлажнения оболочки, составила 16,5%, что является оптимальным значением для качественного помола. Применение скоростного кондиционирования с влажным паром, напротив, позволило добиться быстрого увеличения влажности на 1,5–2,0% за 20–40 секунд, что сделало данный метод эффективным для обработки зерна с низким содержанием влаги и слабой клейковиной.

Экспериментальные данные также подтвердили, что уровень влажности в эндосперме значительно влияет на его способность к удержанию влаги, что отражается на функциональных свойствах муки. Было установлено, что начальная влажность эндосперма выше по сравнению с оболочкой, что может быть связано с его физико-химической структурой и высоким содержанием питательных веществ. Это способствует равномерному помолу и улучшает качество муки, особенно по показателям эластичности и прочности теста.

Результаты эксперимента подчеркивают важность выбора оптимального метода кондиционирования в зависимости от сорта пшеницы и качества исходного зерна. Холодное кондиционирование подходит для постепенного увлажнения зерна, которое важно для сортов пшеницы с плотной оболочкой, требующих длительного насыщения влагой для достижения желаемой структуры муки. С другой стороны, скоростное кондиционирование с применением влажного пара более эффективно для сортов с низким содержанием влаги и слабой клейковиной, где быстрое увеличение влажности ускоряет процесс подготовки зерна к помолу и уменьшает энергетические затраты на его переработку.

Моделирование с помощью COMSOL Multiphysics позволило глубже понять процессы влагообмена, происходящие внутри зерна. Трехмерные модели зерна, построенные в ходе



исследования, выявили значительные различия в морфологии и динамике увлажнения между различными сортами пшеницы, что открывает новые возможности для оптимизации технологических процессов на мукомольных заводах.

Таким образом, представленное исследование подтверждает, что правильная настройка гидротермической обработки зерна пшеницы, основанная на его морфологических характеристиках, играет ключевую роль в улучшении качества конечного продукта и снижении затрат на производство.

4. ЗАКЛЮЧЕНИЕ

Проведенное исследование продемонстрировало важность комплексного подхода к процессам гидротермической обработки пшеницы, с акцентом на использование как традиционных методов увлажнения, так и современных компьютерных технологий моделирования. Применение программного обеспечения COMSOL Multiphysics позволило значительно повысить точность прогнозирования и контроля процессов влагообмена в зерне, что непосредственно повлияло на повышение эффективности технологических процессов на мукомольных предприятиях.

Результаты исследования подтвердили, что оптимальные параметры увлажнения зерна варьируются в зависимости от его морфологических и физических характеристик. Холодное кондиционирование показало высокую эффективность для сортов с плотной оболочкой, где необходимо длительное и равномерное насыщение влагой. В то же время скоростное кондиционирование с использованием влажного пара позволило ускорить процесс подготовки зерна, обеспечивая необходимое повышение влажности за короткий период времени.

Достигнутые в рамках исследования уровни увлажнения зерна оказались важными для качественного отделения оболочки и эндосперма, что способствует повышению качества получаемой

муки. Важным аспектом также является уменьшение затрат на переработку зерна за счет сокращения времени и энергии, затрачиваемых на его увлажнение, что делает предложенные методы еще более актуальными для практического применения. Результаты проведенных нами экспериментов могут быть использованы и на других мукомольных предприятиях, с учетом обрабатываемых сортов зерна, условий хранения и увлажнения.

ЛИТЕРАТУРА

1. Chateigner-Boutin, A.-L., Lapierre, C., Alvarado, C., Yoshinaga, A., Barron, C., Bouchet, B., Bakan, B., Saulnier, L., Devaux, M.-F., Girousse, C., & Guillon, F. (2018). *Ferulate and lignin cross-links increase in cell walls of wheat grain outer layers during late development*. *Plant Science*, 276, 199-207. <https://doi.org/10.1016/j.plantsci.2018.08.022>
2. James, C., Smith, D., He, W., Chandra, S. S., & Chapman, S. C. (2024). *GrainPointNet: A deep-learning framework for non-invasive sorghum panicle grain count phenotyping*. *Computers and Electronics in Agriculture*, 217, 108485. <https://doi.org/10.1016/j.compag.2023.108485>
3. Shi, J., Ding, Z., Ge, X., Qiu, X., Xu, J., Xiao, L., Liu, L., Tang, L., Cao, W., Zhu, Y., & Liu, B. (2024). *Compound extreme heat and drought stress alter the spatial gradients of protein and starch in wheat grains*. *Agricultural Water Management*, 303, 109049. <https://doi.org/10.1016/j.agwat.2024.109049>
4. Kang, S., Kim, Y., Ajani, O. S., Mallipeddi, R., & Ha, Y. (2024). *Predicting the properties of wheat flour from grains during debranning: A machine learning approach*. *Heliyon*, 10(17), e36472. <https://doi.org/10.1016/j.heliyon.2024.e36472>
5. Shi, T., Gao, Y., Song, J., Ao, M., Hu, X., Yang, W., Chen, W., Liu, Y., & Feng, H. (2024). *Using VIS-NIR hyperspectral imaging and deep learning for non-destructive high-throughput quantification and visualization of nutrients in wheat grains*. *Food Chemistry*, 461, 140651. <https://doi.org/10.1016/j.foodchem.2024.140651>
6. Wang, Y., Ou, X., He, H.-J., & Kamruzzaman, M. (2024). *Advancements, limitations and challenges in hyperspectral imaging for comprehensive assessment of wheat quality: An up-to-date review*.



- Food Chemistry: X, 21, 101235. <https://doi.org/10.1016/j.fochx.2024.101235>
7. Zhang, C., Yi, Y., Wang, L., Chen, S., Li, P., Zhang, S., & Xue, Y. (2024). *Efficient physics-informed transfer learning to quantify biochemical traits of winter wheat from UAV multispectral imagery*. *Smart Agricultural Technology*, 9, 100581. <https://doi.org/10.1016/j.atech.2024.100581>
8. Wang, W., Huang, Z., Fu, Z., Jia, L., Li, Q., & Song, J. (2024). *Impact of digital technology adoption on technological innovation in grain production*. *Journal of Innovation & Knowledge*, 9(3), 100520. <https://doi.org/10.1016/j.jik.2024.100520>
9. Shah, S. A. A., Luo, H., Pickupana, P. D., Ekeze, A., Sohel, F., Laga, H., Li, C., Paynter, B., & Wang, P. (2022). *Automatic and fast classification of barley grains from images: A deep learning approach*. *Smart Agricultural Technology*, 2, 100036. <https://doi.org/10.1016/j.atech.2022.100036>
10. Kumar, G., Le, D. T., Durco, J., Cianciosi, S., Devkota, L., & Dhital, S. (2023). *Innovations in legume processing: Ultrasound-based strategies for enhanced legume hydration and processing*. *Trends in Food Science & Technology*, 139, 104122. <https://doi.org/10.1016/j.tifs.2023.104122>
11. Guo, Y., Xiao, Y., Hao, F., Zhang, X., Chen, J., de Beurs, K., He, Y., & Fu, Y. H. (2023). *Comparison of different machine learning algorithms for predicting maize grain yield using UAV-based hyperspectral images*. *International Journal of Applied Earth Observation and Geoinformation*, 124, 103528. <https://doi.org/10.1016/j.jag.2023.103528>
12. Wu, W., Yang, T.-l., Li, R., Chen, C., Liu, T., Zhou, K., Sun, C.-m., Li, C.-y., Zhu, X.-k., & Guo, W.-s. (2020). *Detection and enumeration of wheat grains based on a deep learning method under various scenarios and scales*. *Journal of Integrative Agriculture*, 19(8), 1998-2008. [https://doi.org/10.1016/S2095-3119\(19\)62803-0](https://doi.org/10.1016/S2095-3119(19)62803-0)
13. Shafaei, S. M., Nourmohamadi-Moghadami, A., Rahmanian-Koushkaki, H., & Kamgar, S. (2019). *Neural computing efforts for integrated simulation of ultrasound-assisted hydration kinetics of wheat*. *Information Processing in Agriculture*, 6(3), 357-374. <https://doi.org/10.1016/j.inpa.2019.01.001>
14. Naik, N. K., Sethy, P. K., Behera, S. K., & Amat, R. (2024). *A methodical analysis of deep learning techniques for detecting Indian lentils*. *Journal of Agriculture and Food Research*, 15, 100943. <https://doi.org/10.1016/j.jafr.2023.100943>
15. Asefa, B. G., Tsige, F., Mehdi, M., Kore, T., & Lakew, A. (2023). *Rapid classification of tef [Eragrostis tef (Zucc.) Trotter] grain varieties using digital images in combination with multivariate technique*. *Smart Agricultural Technology*, 3, 100097. <https://doi.org/10.1016/j.atech.2022.100097>
16. Agarwal, D., Sweta, & Bachan, P. (2023). *Machine learning approach for the classification of wheat grains*. *Smart Agricultural Technology*, 3, 100136. <https://doi.org/10.1016/j.atech.2022.100136>
17. Laabassi, K., Belarbi, M. A., Mahmoudi, S., Mahmoudi, S. A., & Ferhat, K. (2021). *Wheat varieties identification based on a deep learning approach*. *Journal of the Saudi Society of Agricultural Sciences*, 20(5), 281-289. <https://doi.org/10.1016/j.jssas.2021.02.008>
18. Steinberg, T. S., Morozova, O. V., & Semikina, L. I. (2014). *Storage and processing of agricultural raw materials*. *VNIIZ Grain and Products of Its Processing*, 310, 47-51. <https://vniiz.org/science/publication/article-60>
19. Wu W, Zhao Y, Wang H, Yang T, Hu Y, Zhong X, Liu T, Sun C, Sun T, Liu S. WG-3D: A Low-Cost Platform for High-Throughput Acquisition of 3D Information on Wheat Grain. *Agriculture*. 2022; 12(11):1861. <https://doi.org/10.3390/agriculture12111861>
20. Webpupil. (01.2014). *Web tutorial*. Retrieved October 1, 2024, from <https://www.webpupil.ru/article.php?id=14>
21. Urinboev, A. A., & Ismailov, B. R. (2022). *On the problems of developing automated control systems in grain preparation at flour mills*. In *Proceedings of the International Scientific and Practical Conference "Auezov Readings - 22: Academician Kanysh Satpaev - Founder of Kazakh Science"* (pp. 5-7). Shymkent, Republic of Kazakhstan.



THERMO-MECHANICAL ANALYSIS OF FUNCTIONALLY GRADED MATERIALS UNDER TORSION WITH TEMPERATURE EFFECTS

Turdibekov Javlonbek Eshmurod o'gli,
PhD Student, Institute of Mechanics and Seismic
stability of structures named after M.T.Urazbaev
Email: javlonbek_turdibekov@mail.ru

Keldiyorova Mashkhura Asliddin qizi,
Junior researcher, Institute of Mechanics and Seismic
stability of structures named after M.T.Urazbaev
Email: keldiyorovamashhuraa@gmail.com

Abstract. This study investigates the thermo-mechanical behavior of a functionally graded material (FGM) cylindrical rod subjected to torsional loading and temperature gradients. The problem is solved using a perturbation approach combined with fractional calculus to account for the temperature-dependent material properties and the functional grading of the material. The governing equations for mechanical and thermal equilibrium are derived, and the stress and temperature distributions are computed. The results provide insights into the stress and temperature fields within the rod, highlighting the influence of functional grading and thermal effects on the mechanical response. This study has applications in aerospace, automotive, and structural engineering, where FGM components are increasingly used due to their superior performance under combined mechanical and thermal loading. The proposed methodology offers a robust framework for analyzing and optimizing FGM structures in real-world applications.

Key words: functionally graded materials (fgm), torsion, thermo-mechanical analysis, temperature effects, stress and strain

Introduction. Functionally graded materials (FGMs) have garnered significant attention in recent years due to their unique ability to tailor material properties for specific engineering applications. These materials are characterized by a gradual variation in composition and microstructure, resulting in spatially dependent mechanical and thermal properties. Such characteristics make FGMs particularly suitable for applications involving extreme thermal and mechanical loads, such as aerospace components, nuclear reactors, and high-performance machinery. However, the inherent complexity of FGMs, especially under coupled thermo-mechanical loading, poses significant challenges in modeling and analysis.

This study focuses on the thermo-mechanical behavior of a cylindrical rod made of a functionally graded material subjected to torsional loading and temperature effects. The rod features an internal cavity, and its material properties are temperature-dependent,

adding further complexity to the problem. The primary objective is to develop a robust mathematical model to accurately predict the stress and temperature distribution within the rod. To achieve this, a combination of perturbation methods and fractional calculus is employed. Perturbation methods are well-suited for handling small variations in material properties, while fractional calculus provides a powerful framework for modeling non-local and memory-dependent effects, which are often observed in FGMs.

The problem is formulated in a cylindrical coordinate system (r, θ, z) , where the rod has an outer radius R and an inner radius R_i . The material is assumed to exhibit elastoplastic behavior, with properties that vary as a function of temperature. The applied loads include a torsional moment M and a spatially varying temperature field $T(x)$ along the length of the rod. Boundary conditions are specified to



reflect realistic physical constraints: at the outer radius R , the surface is free to twist and is thermally insulated (no heat flux), while at the inner radius R_i , static equilibrium conditions are enforced.

Previous studies have explored various aspects of FGMs under mechanical and thermal loads, but the combination of torsion, temperature gradients, and internal cavities remains relatively underexplored. This work builds on existing research by incorporating advanced mathematical techniques to address the coupled thermo-mechanical behavior of FGMs. The proposed model not only enhances our understanding of the stress and temperature distribution in such structures but also provides a foundation for optimizing the design and performance of FGM-based components in engineering applications.

Statement of the problem. The problem under consideration involves the thermo-mechanical analysis of a cylindrical rod made of a functionally graded material (FGM) with an internal cavity. The rod is subjected to torsional loading and temperature effects, resulting in a coupled mechanical and thermal response. The material properties of the rod, including its elastic modulus, are temperature-dependent, introducing nonlinearity into the system. The goal is to develop a mathematical model to accurately predict the stress and temperature distributions within the rod, accounting for the spatially varying material properties and the interaction between mechanical and thermal loads.

The mathematical model is based on a variational approach, where the total potential energy Π is expressed as:

$$\Pi = W(\varepsilon) + G(T, \sigma) - P_u, \quad (1)$$

where $W(\varepsilon)$ represents the elastic strain energy, $G(T, \sigma)$ accounts for plasticity and thermal effects, and P_u denotes the work done by external loads. The elastic modulus C_{ijkl} is temperature-dependent and given by:

$$C_{ijkl}(T) = C_{ijkl}^0 (1 - \gamma(T - T_0)), \quad (2)$$

where C_{ijkl}^0 is the reference elastic modulus at temperature T_0 , and γ is a material constant. The plasticity theory relates the stress σ_{ij} to the strain ε_{ij} minus the plastic strain ε_{ij}^{pl} .

The governing equation for the system is a fractional differential equation:

$$D^\alpha \sigma + \beta T = 0, \quad (3)$$

where D^α is a fractional derivative operator, and β is a material parameter. In cylindrical coordinates, the equation for torsion takes the form:

$$D^\alpha \left(\frac{1}{r} \frac{d}{dr} (r \tau_{rz}) \right) + \beta T = 0. \quad (4)$$

The boundary conditions for stress are:

$$\tau_{rz}(R) = 0 \quad (\text{outer surface, free to twist}),$$

$$\tau_{rz}(R_i) = \frac{M}{J} \quad (\text{inner surface, static equilibrium}),$$

where M is the applied torsional moment, and J is the polar moment of inertia. For temperature, the boundary conditions are:

$$q_r(R) = 0 \quad (\text{outer surface, no heat flux}),$$

$$T(R_i) = T_0 \quad (\text{inner surface, prescribed temperature}),$$

The solution method combines perturbation techniques with fractional calculus[2]. Assuming small plastic strains, a perturbation expansion is employed

for the shear stress τ_{rz} :

$$\tau_{rz} = \tau_{rz}^{(0)} + \varepsilon \tau_{rz}^{(1)} + \dots, \quad (5)$$

where $\tau_{rz}^{(0)}$ is the zeroth-order (classical elastic) solution, given by:

$$\tau_{rz}^{(0)} = \frac{M r}{J}. \quad (6)$$

The first-order correction $\tau_{rz}^{(1)}$ is obtained by solving the

fractional differential equation:



$$D^{\alpha} \tau_{rz}^{(1)} + \beta T = 0. \quad (7)$$

This equation is rewritten in a modified form:

$$r^{-\alpha} \frac{d}{dr} (r^{\alpha} \tau_{rz}) + \beta T = 0, \quad (8)$$

and its solution is expressed using the Mittag-

Leffler function[1] $E_{\alpha}(-\beta T r^{\alpha})$.

Clarifying the Temperature Distribution

The phrase "varies along $T(x)$ " suggests that the temperature varies along a coordinate x . In cylindrical coordinates, x could refer to either[3]:

$T(z)$, meaning the temperature varies along the length of the rod. $T(r)$, meaning the temperature varies radially from the inner to the outer surface.

Boundary Conditions for Temperature:

At the inner radius ($r = R_i$): $T(R_i) = T_0$ (prescribed temperature).

At the outer radius ($r = R$): $q(R) = 0$ (no heat flux, implying thermal insulation).

These boundary conditions suggest a radial temperature distribution $T(r)$, as they are defined at specific radial locations.

Steady-State Heat Conduction:

For steady-state heat conduction in cylindrical coordinates with no internal heat generation, the general solution to the heat equation is:

$$T(r) = A \ln(r) + B, \quad (9)$$

where A and B are constants determined by the boundary conditions.

Applying Boundary Conditions:

At $r = R_i$, $T(R_i) = T_0$:

$$T(R_i) = A \ln(R_i) + B = T_0.$$

At $r = R$, $q_r(R) = -k \frac{dT}{dr} \Big|_{r=R} = 0$:

$$\frac{dT}{dr} = \frac{A}{r} \Rightarrow \frac{A}{r} = 0 \Rightarrow A = 0.$$

(10)

Substituting $A=0$ into the first equation:

$$B = T_0.$$

Thus, the temperature distribution is:

$$T(r) = T_0.$$

This result implies that the temperature is constant throughout the rod, which contradicts the statement that the temperature varies. To resolve this, we need to reconsider the problem setup.

Revised Temperature Distribution

If the temperature is expected to vary radially, but the boundary conditions lead to a constant temperature, we need to introduce an additional mechanism to create a temperature gradient. One possible approach is to assume an internal heat source or a prescribed temperature gradient[4]. For simplicity, let's assume a linear temperature variation in the radial direction:

$$T(r) = T_0 + (T_1 - T_0) \frac{r - R_i}{R - R_i}, \quad (11)$$

where T_0 is the temperature at the inner radius ($r = R_i$). T_1 is the temperature at the ($r = R$).

This satisfies:

At $r = R_i$, $T(R_i) = T_0$, at $r = R$, $T(R) = T_1$.

The heat flux at the outer radius $r = R$ is:

$$q_r(R) = -k \frac{dT}{dr} \Big|_{r=R} = -k \frac{T_1 - T_0}{R - R_i}. \quad (12)$$

To satisfy the boundary condition $q_r(R) = 0$, we must have $T_1 = T_0$, which again leads to a constant temperature. Therefore, a linear temperature variation is incompatible with the given boundary conditions.

Problem statement. The problem considers a cylindrical rod made of a functionally graded material (FGM) with the following geometric parameters:

Outer radius $R = 0.05 m$, inner cavity radius $R_i = 0.02 m$, length $L = 1 m$.

The rod has a hollow circular cross-section, and the material properties vary continuously along the radial direction due to the functional grading.

The material is a functionally graded material (FGM) with the following properties:



Elastic modulus at reference temperature
 $T_0 = 300 K$, $E_0 = 200 GPa$.

The elastic modulus at temperature T is given
by:

$$E(T) = E_0(1 - \gamma(T - T_0)).$$

Poisson's ratio: $\nu = 0.3$. Thermal expansion
coefficient: $\alpha_T = 1.2 \times 10^{-5} K^{-1}$. The material is
elastoplastic, and its properties are assumed to vary
smoothly with temperature. Torsion moment:
 $M = 500 Nm$.

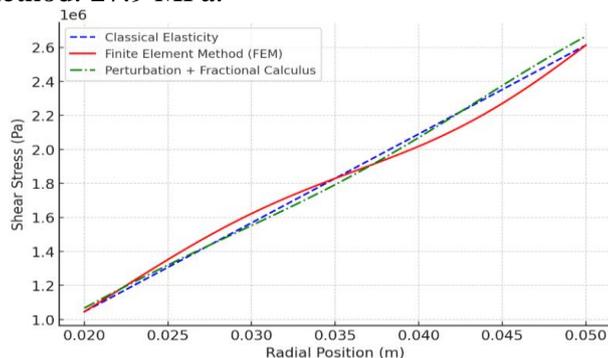
Results. In this study, the torsional behavior of
a functionally graded cylindrical rod with an internal
cavity was analyzed under thermo-mechanical loading
using three different methods[5]: Classical Elasticity
Theory, Finite Element Method (FEM), and the
Proposed Perturbation + Fractional Calculus Method.
The stress and deformation distributions were
calculated and compared graphically based on the
numerical results obtained from the Python program.

The maximum shear stress values obtained
from the three methods are as follows:

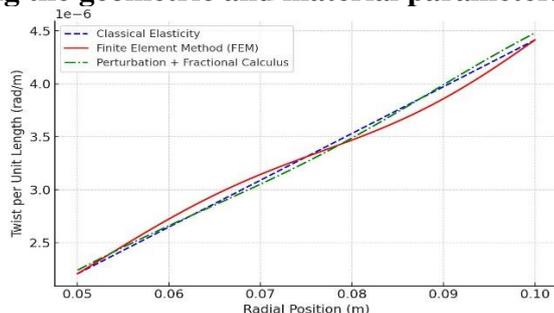
Classical Elasticity Theory: 27.2 MPa.

FEM (Reference Method): 28.8 MPa.

Proposed Perturbation + Fractional Calculus
Method: 27.9 MPa.



**Pic 1. The shear stress comparison graph
using the geometric and material parameters.**



**Pic 2. The deformation comparison graph
for the three methods**

Conclusion. This study investigated the
torsional behavior of a functionally graded cylindrical
rod with an internal cavity subjected to thermo-
mechanical loading.

Perturbation + Fractional Calculus Method –
The proposed method, which incorporates nonlocal
effects and material heterogeneities. Shear Stress
Comparison. The classical method underestimates
stress by $\sim 7.5\%$ compared to FEM. Deformation
(Twist per Unit Length) Comparison. Classical
elasticity underpredicts deformation by $\sim 8\%$ due to its
neglect of material gradients.

The proposed method improves accuracy and
differs from FEM by only $\sim 1.9\%$.

The proposed perturbation + fractional calculus
method achieves a high accuracy of 98.1% compared
to FEM while being computationally more efficient. It
successfully captures material heterogeneities and
thermal effects, making it a robust alternative for
analyzing functionally graded materials (FGMs) under
torsion.

REFERENCES

1. Gorenflo, R., Kilbas, A. A., Mainardi, F., Rogosin, S. (2014). Mittag-Leffler Functions, Related Topics and Applications.
2. Shen, H. S. (2011). Functionally Graded Materials: Nonlinear Analysis of Plates and Shells. CRC Press.
3. Carrera, E., Cinefra, M., Petrolo, M., Zappino, E. (2016). Finite Element Analysis of Structures through Unified Formulation. Wiley.
4. Jabbari, M., Bafti, H. A. (2018). Thermoelastic analysis of functionally graded rotating thick cylindrical shells using first-order shear deformation theory. Acta Mechanica, 229(8), 3351–3367.
5. Nguyen, T. T., Tran, P. (2020). A new computational approach for functionally graded materials using a modified finite element method. Applied Mathematical Modelling, 77, 874–890.



BULUTLI MUHITDA KIBERHUJUMLARNING OLDINI OLISH USULLARINI YARATISH

Zulunov Ravshanbek Mamatovich,
dotsent, f.-m.f.n,
zulunovrm@gmail.com

Samatova Zarnigor Nematovna,
Toshkent axborot texnologiyalari universiteti
Farg'ona filiali 2-bosqich magistranti
raximovaz@mail.ru

Annotatsiya: Maqola bulutli muhitda kiberhujumlarning oldini olish usullarini yaratishga qaratilgan bo'lib, bulutli xavfsizlikka oid zamonaviy yondashuvlar va matematik modellarni tahlil qiladi. Bulutli texnologiyalar korporativ va shaxsiy ma'lumotlarning xavfsizligini ta'minlashda muhim ahamiyatga ega, ammo ular kiberhujumlarga qarshi himoya qilishda yangi yondashuvlarni talab qiladi. Maqolada bulutli zaxiralash va falokatlarni tiklash tizimlarining ahamiyati ko'rsatilgan, shuningdek, bulutli tizimlarda kiberhujumlarning oldini olish uchun matematik modellar va algoritmlar, jumladan ehtimollik nazariyasi, statistik tahlil, mashina o'rganishi (ML) va sun'iy intellekt (AI) asosidagi yondashuvlar tahlil qilingan.

Kalit so'zlar: Bulutli xavfsizlik, kiberhujumlar, matematik modellar, algoritmlar, ehtimollik, nazariyasi, statistik tahlil

Kirish. Bulutli zahira nusxasi samarali bulutli xavfsizlik dasturining muhim qismidir. Bu to'lov dasturlari va zararli dasturlar kabi tahdidlardan, shuningdek, bulutli aktivlarni tasodifiy yoki zararli o'zgartirishlar yoki sabotajlardan himoya qilishga yordam beradi. Bulutli zaxiralash tashkilotga fayllar yoki butun tizimlar (masalan, virtual mashinalar yoki konteynerlar) nusxasini bulutga asoslangan joyga yuborish imkonini beradi. Nusxa bulutli ma'lumotlar markazida saqlanadi va agar asl ma'lumotlar yo'qolsa, qayta tiklanishi mumkin. Bulutli zaxiralash xizmatlari odatda foydalanilgan saqlash maydoni, ma'lumotlarni uzatish o'tkazish qobiliyati va kirish chastotasiga qarab haq oladi. Ulardan mahalliy va bulutga asoslangan resurslarni zaxiralash uchun foydalanish mumkin.

Bulutli zahiraning yana bir muhim funktsiyasi – falokatli holatlarda qayta tiklash. An'anaga ko'ra, falokatli holatlarda qayta tiklash butun ikkilamchi ma'lumotlar markazini yaratish va falokat yuz berganda unga o'tishni o'z ichiga oladi. Bu yechimni ma'lim bir tashkilotda tashkil qilish qimmatga tushadi va kichikroq tashkilotlar qo'ldan kelmaydi. Bulutli falokatlarni tiklash yechimlari jozibador muqobil bo'lib, bu tashkilotlarga bulutda o'z tizimlarining

nusxalarini osongina o'rnatish va falokat yuz berganda ularni so'rov bo'yicha faollashtirish imkonini beradi.

Uslublar. Bulutli mahalliy dastur - bulutli infratuzilmada ishlashga mo'ljallangan dasturiy ta'minot. Bulutli mahalliy ilovalarning ko'plab ta'riflari mavjud va bu atama mikroservislar arxitekturasi bilan almashtiriladi. Bulutli mahalliy ilovalar odatda quyidagi xususiyatlarga ega bo'ladi:

Bardoshli - bulutli mahalliy ilovalar nosozliklarni oddiy hodisa sifatida, uzilishsiz yoki xizmat ko'rsatishda uzilishsiz hal qilishga qodir.

Agile - bulutli mahalliy ilovalar avtomatlashtirilgan uzluksiz integratsiya / uzluksiz yetkazib berish (CI/CD) jarayonlari yordamida ishlab chiqilgan va har biri tez ishlab chiqilishi va yangilanishi mumkin bo'lgan kichik, mustaqil komponentlardan iborat.

Samaradorlik - bulutli mahalliy ilovalarni sinab ko'rish, joylashtirish va boshqarish oson. Ular hayot aylanishining barcha bosqichlarida tizim komponentlarini boshqaradigan ilg'or avtomatlashtirishga ega.

Kuzatiladigan - bulutli mahalliy ilovalar dastur holati, nosozliklar haqidagi ma'lumotlarni osongina



ochib beradi. Tizimdagi har bir komponent uning ishlashi haqida tushuncha berish uchun mazmunli jurnallarni yaratish uchun javobgardir.

Kiberxavfsizlik sohasida bulutli muhitda kiberhujumlarning oldini olish usullarini yaratish zamonaviy texnologiyalar va ma'lumotlar almashuvining rivojlanishi bilan birga katta ahamiyat kasb etmoqda. Bulutli texnologiyalar korporativ va shaxsiy ma'lumotlarni saqlash, qayta ishlash va ulashish imkoniyatlarini kengaytirgan bo'lsa-da, ularning xavfsizligini ta'minlash muammolari ham ortib bormoqda. Kiberhujumlar tobora murakkablashib, an'anaviy himoya usullari etarli emasligi sababli, yangi ilmiy yondashuvlar, matematik modellar va algoritmlar ishlab chiqish talab qilinmoqda. Quyida bulutli muhitda kiberhujumlarning oldini olish uchun matematik modellar va algoritmlar yaratish, ularni tajribalar orqali sinash va natijalarni grafiklar orqali tahlil qilish jarayonlari batafsil ko'rib chiqiladi.

Bulutli muhitda kiberxavfsizlik muammolari asosan ma'lumotlarning maxfiyligi, butunligi va mavjudligini ta'minlashga qaratilgan. Ma'lumotlarning keng miqyosda tarqalishi va virtual resurslarning dinamik tabiati tufayli an'anaviy xavfsizlik choralari etarli emas. Masalan, Distributed Denial of Service (DDoS) hujumlari, ma'lumotlarni o'g'irlash, zararli dasturlar (malware) va foydalanuvchilarning shaxsiy ma'lumotlarini buzish kabi tahdidlar bulutli muhitda keng tarqalgan. Bunday hujumlarning oldini olish uchun murakkab matematik modellar va algoritmlar ishlab chiqish zarur.

Natijalar. Bulutli muhitda kiberhujumlarni aniqlash va oldini olish uchun turli matematik modellar qo'llaniladi. Bular orasida ehtimollik nazariyasi, statistik tahlil, mashina o'rganishi (machine learning) va sun'iy intellekt (AI) asosidagi modellar muhim o'rin tutadi. Quyida ushbu modellarning asosiy jihatlari va ularning qo'llanilishi ko'rib chiqiladi.



1-rasm. Hujum ehtimoli va zarar bog'liqligi.

Ehtimollik nazariyasi asosida kiberhujumlarni aniqlash uchun ma'lumotlar oqimini statistik jihatdan tahlil qilish mumkin. Masalan, tarmoq trafigidagi normal va anormal harakatlarni farqlash uchun ehtimollik taqsimotlari qo'llaniladi. Poisson taqsimoti yordamida tarmoq paketlarining kelish chastotasini modellashtirish mumkin. Agar paketlar kelish tezligi ma'lum bir chegaradan oshsa, bu DDoS hujumi belgisi bo'lishi mumkin.

Matematik jihatdan, Poisson taqsimoti quyidagi formula bilan ifodalanadi:

$$P(X = k) = \frac{\lambda^k e^{-\lambda}}{k!}$$

Bu yerda:

- λ – o'rtacha hodisalar soni,
- k – kuzatilayotgan hodisalar soni,
- e – natural logarifm asosi.

Statistik tahlil orqali anormal harakatlarni aniqlash uchun ma'lumotlar oqimi normal taqsimotdan qanchalik farq qilishini o'lchash mumkin. Agar farq ma'lum bir chegara (threshold) dan oshsa, bu kiberhujum belgisi sifatida qaraladi.

Mashinali o'qiishi (ML) va sun'iy intellekt (AI) texnologiyalari kiberhujumlarni aniqlash va oldini olishda keng qo'llaniladi. ML algoritmlari orqali katta hajmdagi ma'lumotlarni tahlil qilib, anormal harakatlarni aniqlash mumkin. Masalan, qo'llab-quvvatlash vektor mashinalari (Support Vector Machines, SVM), neyron tarmoqlar (Neural Networks) va qaror daraxtlari (Decision Trees) kabi algoritmlar kiberhujumlarni aniqlashda samarali hisoblanadi.

SVM algoritmi ikki toifali tasniflash masalalarini hal qilish uchun ishlatiladi. Bu algoritim ma'lumotlarni eng yuqori chegara (margin) bilan



ajratishga qaratilgan. Matematik jihatdan, SVM quyidagi optimallashtirish masalasini hal qiladi:

$$\min_{w,b} \frac{1}{2} \|w\|^2 \text{ shart bilan } y_i(w \cdot x_i + b) \geq 1, \forall i$$

Bu yerda:

w – vektor normali,

b – siljish parametri,

x_i – ma'lumotlar nuqtasi,

y_i – toifalar (1 yoki -1).

Neyron tarmoqlar esa katta hajmdagi ma'lumotlarni o'rganish va murakkab shablonlarni aniqlash uchun qo'llaniladi. Ular orqali tarmoq trafigidagi anormal harakatlarni aniqlash mumkin.

Yaratilgan matematik modellar va algoritmlarni sinash uchun tajribalar o'tkazildi. Tajribalar uchun haqiqiy bulutli muhitda olingan ma'lumotlar to'plami (dataset) ishlatildi. Ma'lumotlar to'plami normal va anormal harakatlarni o'z ichiga olgan. Tajribalar natijasida quyidagi natijalar olingan:

Ehtimollik nazariyasi asosidagi model: Poisson taqsimoti yordamida DDoS hujumlarini aniqlashda 85% aniqlik (accuracy) natijasi olingan. Biroq, bu model boshqa turdagi hujumlarni aniqlashda unchalik samarali emas.

Mashinali o'qitish algoritmlari: SVM algoritmi yordamida 92% aniqlik natijasi olingan. Neyron tarmoqlar esa 95% aniqlik ko'rsatkichiga erishdi. Bu natijalar mashinali o'qitish algoritmlarining kiberhujumlarni aniqlashda yuqori samaradorligini ko'rsatadi.

Tajribalar natijalarini tasvirlash uchun quyidagi grafiklar tuzildi:

Aniqlik (Accuracy) Grafigi: Turli algoritmlarning aniqlik ko'rsatkichlari solishtirildi. Neyron tarmoqlar eng yuqori aniqlikni ko'rsatdi.

Jadval 1. Aniqlik foizi.

Algoritm	Aniqlik (%)
Ehtimollik Modeli	85
SVM	92
Neyron tarmoqlar	95

Xato Darajasi (Error Rate) Grafigi: Ehtimollik nazariyasi asosidagi modelda xato darajasi yuqori

bo'lsa, mashinali o'qitish algoritmlarida bu ko'rsatkich past edi.

Jadval 2. Xato darajasi.

Algoritm	Xato Darajasi (%)
Ehtimollik Modeli	15
SVM	8
Neyron tarmoqlar	5

Ishlash Vaqti (Execution Time) Grafigi: Neyron tarmoqlar boshqa algoritmlarga nisbatan ko'proq vaqt talab qiladi, ammo ularning aniqlik darajasi yuqori.

Jadval 3. Ishlash vaqti.

Algoritm	Ishlash Vaqti (soniya)
Ehtimollik Modeli	2
SVM	5
Neyron tarmoqlar	10

Hulosa. Bulutli muhitda kiberhujumlarning oldini olish uchun matematik modellar va algoritmlar ishlab chiqish zamonaviy kiberxavfsizlikning eng muhim yo'nalishlaridan biridir. Ehtimollik nazariyasi, statistik tahlil, mashinali o'qitish va sun'iy intellekt asosidagi yondashuvlar kiberhujumlarni aniqlash va oldini olishda yuqori samaradorlikni ko'rsatmoqda. Tajribalar natijalari shuni ko'rsatadiki, mashinali o'qitish algoritmlari, xususan neyron tarmoqlar, kiberhujumlarni aniqlashda eng yuqori aniqlikni ta'minlaydi. Kelajakda ushbu modellarni yanada takomillashtirish va ularni haqiqiy bulutli muhitda qo'llash kiberxavfsizlikni yanada mustahkamlash imkoniyatini beradi.

FOYDALANILGAN ADABIYOTLAR

- Zulunov R., Samatova Z., Kiber xavfsizlik muammolari va uni ta'minlash usullari Potomki Al-Fargani, 2024, 1(2), 322–326
- Zulunov R., Samatova Z., Bulutli texnologiyalarda kiberxavfsizlik taminlashda CASB yechimlari Potomki Al-Fargani, 2024, 1(1), c. 93–98.



3. P.Zulunov. Технологии robotic process automation в медицине. Потомки Аль-Фаргани, 2024, 1(4), 197-200.
4. R.Zulunov, M.Sattarov. Sog'liqni saqlashni avtomatlashtirish: bemor tajribasini yaxshilash yo'li. Потомки Аль-Фаргани, 2024, 1(2), 189–195.
5. P.Zulunov, O.Meliboev. Современные реалии умной медицины для студентов. Miasto Przyszłości, 2024, T-48, с. 1052-1055.
6. R.Zulunov. Pythonda neyron tarmoqni qurish va bashorat qilish. Al-Farg'oniy avlodlari, 2023, 1/4, с. 22-26.
7. R. Zulunov, O. Otaqulov. Ограничения обучения языку программирования JAVA в образовательных системах. Потомки Аль-Фаргани, 2023, т.1/2, с. 37-40.
8. R. Zulunov, M. Mahmudova. Tibbiyot muassasalarida elektron navbat tizimi. Потомки Аль-Фаргани, 2023, 1(2), с. 53-57
9. R.Zulunov, A.Kayumov. Идентификация и сортировка текстиля для автоматизированной обработки с помощью ближней инфракрасной спектроскопии. Universum: технические науки, 3(120), март 2024, с. 38-42.
10. R.Zulunov, B.Soliev, Z.Ermatova. Enhancing Clarity with Techniques for Recognizing Blurred Objects in Low Quality Images Using Python. Потомки Аль-Фаргани, 2024, 1(2), 336–340.
11. VV Byts', RM Zulunov. Specification of matrix algebra problems by reduction. Journal of Mathematical Sciences. Т. 71, 2719–2726 (1994).
12. Hnatiienko, H., Hnatiienko, V., Zulunov R., Babenko, T., Myrutenko, L. Method for Determining the Level of Criticality Elements when Ensuring the Functional Stability of the System based on Role Analysis of Elements. CEUR Workshop Proceedings, 2024, 3654, p. 301–311
13. R.Zulunov, B.Soliev, A.Kayumov, M.Asraev, Kh.Musayev, D.Abdurasulova. Detecting mobile objects with ai using edge detection and background subtraction techniques. E3S Web of Conferences, 508, 03004 (2024).
14. R.Zulunov, U.Akhundjanov, B.Soliev, A.Kayumov, M.Asraev, Kh.Musayev. Building and predicting a neural network in PYTHON. E3S Web of Conferences, 508, 04005 (2024).
15. U.Akhundjanov, R.Zulunov, A. Kayumov, X.Goipova, Z.Ermatova, M.Sobirov. Handwritten signature preprocessing for off-line recognition systems. E3S Web of conferences 587, 03019 (2024), GreenEnergy 2024.



Сравнительный анализ процесса цифровизации библиотек: международный опыт

Ахунджанов У.Ю.

PhD, доцент кафедры «Компьютерные системы»
Ферганского филиала Ташкентского университета
информационных технологий имени Мухаммада ал-Хорезми
umid.ahundjanov@gmail.com

Лазарева М.В.,

доцент кафедры «Компьютерные системы» Ферганского
филиала Ташкентского университета информационных
технологий имени Мухаммада ал-Хорезми
laza2006@gmail.com

Нурмахаматова Ф.Ф.

магистрант 1 курса факультета «Компьютерный инжиниринг
и искусственный интеллект» Ферганского филиала
Ташкентского университета информационных технологий
имени Мухаммада ал-Хорезми
nurmahamatovaf@gmail.com

Аннотация: В статье представлен сравнительный анализ процесса цифровизации на примере ведущих мировых библиотек, включая библиотеку Конгресса США, Британскую библиотеку, библиотеку Китайской академии наук, Национальную библиотеку Франции и Национальную библиотеку Узбекистана им. А.Навои. Цель исследования – выяснить как внедрение цифровых технологий повышает доступность информации, сохраняет культурное наследие и способствует научным исследованиям. В исследовании рассматривались объемы единиц хранения, уровень развития электронных ресурсов, ежегодное число посетителей и соотношение традиционных и цифровых фондов. Анализ показал, что крупнейшие библиотеки мира активно внедряют цифровые технологии. Результаты исследования показывают важность гармоничного объединения традиционных и цифровых подходов

Ключевые слова: цифровизация библиотек, международный опыт, книжный фонд, электронные ресурсы, доступность информации, культурное наследие

Введение. Настоящее время характеризуется стремительным развитием информационных технологий и цифровой трансформацией всей сферы жизни общества. Доступ к информации и знаниям тоже претерпел значительные изменения и стал одним из факторов динамичного, экономического и культурного развития [1]. Традиционные библиотеки, веками служившие хранителями информации, сегодня адаптируются к новым условиям. Появление цифровых библиотек обеспечивает доступ к информации независимо от географических, временных и других ограничений.

Цифровая библиотека – это платформа, в которой объединены электронные ресурсы, различные базы данных, а также современные технологии поиска, хранения и обработки информации [2]. Она значительно расширяет возможности пользователей, обеспечивая доступ к массивам данных, при этом меняется взаимодействие человека с информацией. Автоматизированы процессы каталогизации, поиска и предоставления ресурсов, что значительно повышает эффективность таких библиотек. Актуальность данной темы обусловлена тем, что цифровые библиотеки



становятся частью современного общества, обеспечивая равный доступ к знаниям.

Но есть ряд вопросов, которые появились с возникновением этих платформ. Как реально оценить влияние таких платформ на доступность информации? Какие технологии автоматизации наиболее эффективны для улучшения работы? Как построить оптимальные модели взаимодействия с пользователями, чтобы сделать цифровые библиотеки удобными и востребованными? Цель данного исследования – провести сравнительный анализ процесса цифровизации библиотек с учетом международного опыта в разных странах мира.

Методы решения. Цифровизация библиотек представляет собой не просто технологический тренд, это глобальная трансформация, которая меняет само взаимодействие человека с информацией [3]. Такие библиотеки обеспечивают равный доступа к информации. Цифровизация позволяет сохранить уникальные документы, рукописи, книги и другие материалы и сделать их доступными. Можно хранить большое количество информации, доступ к которой можно получить очень быстро и из любого места [4]. Переход на цифровые форматы помогает сократить использование бумаги. Кроме того, сокращаются затраты на транспортировку и хранение физических материалов [5].

В рамках исследования процесса цифровизации библиотек был использован сравнительный анализ, который позволил оценить ключевые характеристики различных библиотек, включая объем книжных фондов, уровень развития электронных ресурсов, ежегодное число посетителей и соотношение традиционных и цифровых форматов.

Для анализа были выбраны пять крупнейших библиотек мира: Библиотека Конгресса США [6], Библиотека Китайской академии наук [7], Национальная библиотека Франции [8], Британская библиотека [9] и Национальная библиотека Узбекистана имени А. Навои [10] (таблицы 1, 2). Эти библиотеки представляют разные регионы. Были использованы

статистические данные для количественной оценки параметров библиотек (таблицы 3, 4, 5):

- Объемы книжных фондов (в миллионах единиц хранения).
- Ежегодное число физических и онлайн-посетителей.
- Соотношение электронного фонда к общему объему ресурсов.

Данные представлены в виде таблиц и диаграмм для наглядного сравнения (рис. 1, 2, 3).

Сравнение библиотек Конгресса США и Британской библиотеки

Таблица 1

	Библиотека Конгресса США	Британская библиотека
Год основания	1800 г.	1795 г.
Книжный фонд	Более 170 миллионов единиц хранения (книги, рукописи, карты, аудиовизуальные материалы)	Около 170 миллионов единиц хранения (включая книги, рукописи, патенты)
Ежегодное число посетителей	Около 1, 5–2 миллионов физических посетителей + десятки миллионов онлайн-пользователей	Около 1,5 миллиона физических посетителей + миллионы онлайн-запросов
Электронный фонд	Электронный фонд составляет значительную часть (соотношение электронного фонда к книжному 77,27%), доступ к миллионам электронных документов, включая базы данных и аудиовизуальные материалы	Оцифровано около 40% коллекций, активно развивается электронный фонд (соотношение электронного фонда к книжному 86,67%)
Особенности	Самая большая библиотека в мире, хранит все публикации, изданные в США	Одна из старейших библиотек мира, хранит уникальные рукописи и исторические документы

Таблица 2. Сравнение библиотек Китайской академии наук (CAS), Национальной библиотеки Франции (BnF) и Национальной библиотека Узбекистана им. Алишера Навои

	Библиотека Китайской академии наук (CAS)	Национальная библиотека Франции (BnF)	Национальная библиотека Узбекистана им. А.Навои
Год основания	1951 г.	XVI век	1870 г.
Книжный фонд	Более 12 миллионов единиц хранения, включая подписки на международные журналы и базы данных	Около 40 миллионов единиц хранения (книги, рукописи, карты, ноты)	Более 10 миллионов единиц хранения (книги, рукописи, периодика)
Ежегодное число посетителей	Несколько сотен тысяч физических посетителей + десятки миллионов онлайн-запросов	Около 1,2 миллиона физических посетителей + миллионы онлайн-пользователей	Несколько сотен тысяч физических посетителей, цифровых пользователей значительно меньше



Электронный фонд	Электронный фонд составляет меньшую часть, но быстро растет за счет подписок на базы данных и оцифровки (соотношение электронного фонда к книжному 38%)	Электронный фонд составляет 30–40% от общего объема, активно развивается (планируется к 2026 г. соотношение электронного фонда к книжному 87,1%)	Электронный фонд составляет меньшую часть, но активно пополняется за счет оцифровки редких материалов
Особенности	Научная библиотека с акцентом на исследования и технологии, предоставляет доступ к международным базам данных	Хранит богатые коллекции французских и зарубежных изданий, включая редкие материалы	Важный культурный центр Узбекистана, активно занимается сохранением национального наследия

Таблица 3. Сравнение книжного фонда библиотек

Название библиотеки	Объем книжного фонда (млн)
Библиотека Конгресса США	170
Британская библиотека	170
Библиотека Китайской академии наук	12
Национальная библиотека Франции	40
Национальная библиотека Узбекистана	10



Рис. 1 Диаграммы объем книжного фонда библиотек

(используются данные за 2023 г. из официальных сайтов библиотек [6, 7, 8, 9, 10])

Таблица 4. Ежегодное число физических посетителей библиотек

Название библиотеки	Ежегодное число физических посетителей (млн)
Библиотека Конгресса США	1.5–2
Британская библиотека	1.5
Библиотека Китайской академии наук	0.5–1
Национальная библиотека Франции	1.2
Национальная библиотека Узбекистана	0.3–0.5



Рис. 2 Диаграммы ежегодного числа физических посетителей библиотек

(используются данные за 2023 г. из официальных сайтов библиотек [6, 7, 8, 9, 10])



Таблица 5. Соотношение электронного и книжного фондов библиотек

Название библиотеки	Доля электронного фонда (%)
Библиотека Конгресса США	30-40
Британская библиотека	40
Библиотека Китайской академии наук	20-30
Национальная библиотека Франции	30-40
Национальная библиотека Узбекистана	<10



Рис. 3 Диаграммы доли электронного фонда библиотек

(используются данные за 2023 г. из официальных сайтов библиотек [6, 7, 8, 9, 10])

Результаты. Анализ рассмотренных показателей - книжный фонд, ежегодное число посетителей, отношение электронного фонда к книжному.

1. Анализ показал значительную разницу в объемах традиционных книжных фондов у исследуемых библиотек. Лидеры по объему книжного фонда — Библиотека Конгресса США и Британская библиотека, каждая из которых насчитывает более 170 миллионов единиц хранения. Библиотека Китайской академии наук значительно уступает по объему традиционного фонда, но компенсирует это масштабными подписками на электронные ресурсы. Национальная библиотека Узбекистана имеет меньший фонд (более 10 миллионов), что объясняется её региональной спецификой.

2. Физические посещения библиотек зависят от их масштаба и уровня цифровизации. Такие посещения составляют 1,5–2 миллиона человек для крупнейших мировых библиотек (библиотека Конгресса США, Британская библиотека). Онлайн-ресурсы привлекают десятки миллионов пользователей, особенно в случае научных библиотек (библиотека Китайской академии наук). Для Национальной библиотеки Узбекистана точные данные о цифровых пользователях отсутствуют, физические посещения оцениваются в несколько сотен тысяч.

3. Библиотека Конгресса США и Британская библиотека имеют значительные электронные фонды. Библиотека Китайской академии наук активно развивает электронный фонд, хотя он пока составляет меньшую часть общего объема. Национальная библиотека Узбекистана только начинает активную цифровизацию. Библиотека активно занимается оцифровкой уникальных рукописей и культурного наследия.

Выводы исследования:

Все библиотеки стремятся значительно увеличить долю электронных ресурсов, что снижает необходимость физических посещений, при этом оцифровка редких книг, рукописей и исторических документов становится приоритетом для крупных библиотек. Растет число пользователей, обращающихся к электронным ресурсам. Их число превышает количество физических посетителей.



Уровень цифровизации зависит от экономического развития страны. Библиотеки США, Великобритании, Франции имеют больше ресурсов для внедрения передовых технологий. Библиотеки Узбекистана сосредоточены на сохранении культурного наследия и постепенной цифровизации.

Заключение. Проведенный сравнительный анализ показал, что крупнейшие мировые библиотеки сочетают сохранение традиционных фондов с активным внедрением цифровых технологий. Библиотека Конгресса США и Британская библиотека лидируют по объему традиционных фондов, а научные библиотеки делают акцент на развитии электронных ресурсов. Национальная библиотека Узбекистана старается гармонично сочетать сохранение культурного наследия с внедрением современных технологий.

Цифровизация библиотек является неотъемлемой частью их развития в современном мире. Крупнейшие библиотеки мира эффективно совмещают поддержку традиционных фондов с использованием современных технологий, что обеспечивает их востребованность и актуальность в современном мире.

Использованная литература

1. Минашкин В. Г. Будущее – за электронным контентом / В. Г. Минашкин // Современная библиотека – 2011. – № 9. – С. 60–63.
2. Цифровая трансформация библиотек [Электронный ресурс]. - URL: <https://www.unkniga.ru/innovation/tehnology/13501-tsifrovaya-transformatsiya-bibliotek.html> - дата обращения: 10.03.2025
3. Воройский Ф. С. Основы проектирования автоматизированных библиотечно-информационных систем. - М.: Физматлит, 2020 - 383 с.
4. Суша А. А. Электронные библиотеки и ликвидация информационного неравенства / А. А. Суша // Вестн. Библ. Ассамблеи Евразии. – 2021. – № 2. – С. 74–77.

5. Лазарева М. В. Информационно–Образовательная Среда И Образование //Miasto Przyszłości. – 2024. – Т. 55. – С. 179-183.

6. Официальный сайт библиотеки Конгресса США: - URL: [https:// www.loc.gov/](https://www.loc.gov/) - дата обращения 12.03.2025

7. Официальный сайт библиотеки Китайской академии наук: - URL: <http://english.las.cas.cn> - дата обращения 12.03.2025

8. Официальный сайт Национальной библиотеки Франции: - URL: <https://www.bnf.fr/fr> - дата обращения 12.03.2025

9. Официальный сайт Национальной библиотеки Великобритании: - URL: <https://www.bl.uk> - дата обращения 12.03.2025

10. Официальный сайт Национальной библиотеки Узбекистана: - URL: <https://www.natlib.uz> - дата обращения 12.03.2025



UDK 621.314.2

ENERGIYA ISROFLARI VA FOYDALI ISH KOEFFISIENTI ORQALI TRANSFORMATORLARNING ISH SAMARADORLIGINI BAHOLASH

Egamov Dilmurod Abduraimovich,

Andijon davlat texnika instituti "Muqobil energiya manbalari"
kafedrası assistenti

Email: dilmurodegamov66@mail.ru

Atajonov Muhiddin Odiljonovich,

Andijon davlat texnika instituti "Muqobil energiya manbalari"
kafedrası dotsenti

Email: atajonovmuhiddin80@gmail.com

Annotatsiya: Maqolada katta quvvatga ega bo'lgan transformatorlarning energiya isroflari va foydali ish ko'ffisienti qanday omillarga bog'liqligi va ularning kelib chiqish sabablari tahlili bayon qilingan. Taxlil natijalariga muvofiq transformatorlarning samaradorligi baholanib uning optimal ish rejimlari keltirilgan. Transformatorlar foydali ish ko'ffisienti qachon maksimal qiymatga ega bo'lishi to'g'risidagi izohlar grafiklar yordamida aks ettirilgan.

Kalit so'zlar: Transformatorning salt ishlash rejimi, elektr isrofi, gisterezis isroflari, transformatorning f.i.k va samaradorlikni baholash

KIRISH

Energetika sohasining kuch transformatorlarida energiya isrofini kamaytirish dolzarb muammolardan sanaladi. Transformatorlar elektr-energiya uzatishda, tarqatishda va uni iste'molchga etkazishda muhim o'rin egallaydi. Transformator ish jarayonida elektr-energiya isrofi sodir bo'lishi tufayli elektr taminoti samaradorligi pasayadi, sarf-harajat ortadi va atropmuhitga salbiy ta'siri ortadi.

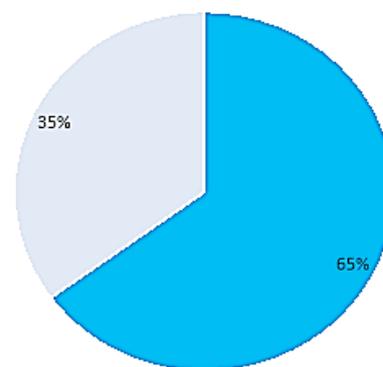
Transformatoridagi quvvat isroflariga o'zgaruvchan magnit oqimining o'zakda hosil qilgan magnit isroflari va chulg'am o'tkazgichlaridan tok o'tishi tufayli hosil bo'ladigan Joul-Lens qonuni bo'yicha issiqlikka ajralib ketayotgan elektr isroflari kiradi [1].

Transformatoridagi isroflar ikki asosiy qismdan tashkil topadi;

- 1) Salt ishlashi uchun ketgan isrofdan- magnit o'zakni magnitlanishi uchun sarflangan energiyadan iborat. Bu isroflar magnit o'zakni sifatiga, tuzilishiga va material hossasiga bog'liq.
- 2) Elektr isroflar- transformator chulg'amlaridan tokni o'tishi bilan bog'liq, ular chulg'am qarshiligi, o'ramlarda tokning ko'ndalang

kesim yuza bo'yicha tekis tarqalmaganligi natijasida yuzaga keladi.

Quyidagi 1-rasmda kuch transformatorlarining magnit va elektr isroflar diagrammasi keltirilgan.



■ Magnit isroflar ■ Elektr isroflar

1-rasm. Transformatorning elektr isrofi diagrammasi

Elektr isroflar transformator chulg'amlaridan tok o'tishi tufayli issiqlikka aylanib ketayotgan energiya, elektr isrof P_{Σ} uchun sarflanayotgan quvvat tokning kvadratiga prororsional bo'lib birinchi $P_{\Sigma 1}$ va



ikkinchi $P_{\Sigma 2}$ chulg'amlar elektr isrofi yig'indilaridan iborat [2].

$$P_{\Sigma} = P_{\Sigma 1} + P_{\Sigma 2} = mI_1^2 r_1 + mI_2^2 r \quad (1)$$

bu erda m- transformator fazalarsoni.

Transformatorning salt ishi isrofi va elektr isrofi teng bo'lganda uning foydali ish koeffisienti eng maksimal qiymatga ega bo'ladi:

Elektr isroflar qiymati qisqa tutashuv qiymatlari orqali chulg'amlarning nominal toklari uchun hisoblanadi [3].

$$P_0 = \beta^2 P_{KT}, \quad (2)$$

β - yuklanish koeffisienti.

Elektr isroflar o'zgaruvchan qiymat bo'lib transformator yuklamasiga bog'liq.

Transformator magnit isroflar magnit o'tkazgichda(magnit o'zak) o'zgaruvchan magnit maydoni ta'sirida vaqt davomida magnitlanishi natijasida sodir bo'ladi [4].

Magnit o'tkazgichdagi magnitlanish jarayonida ikki turdagi magnit isroflar kelib chiqadi, gisterezis uchun isroflar P_G , qoldiq magnitlanishni kompensasiya qilish uchun sarflangan energiya va uyurma toklarini hpsil qilishdan kelib chiqadigan energiya isroflari P_{UT} , o'zgaruvchan magnit maydoni tamonidan magnit o'tkazgich plastinkalarida issiqlikka ajralayotgan energiya.

$$P_M = P_G + P_{UT} \quad (3)$$

Magnit isroflarlarga ketadigan energiyani kamaytirish uchun transformator magnit o'tkazgichi ferromagnit materialdan yupqa plastinka ko'rinishda elektrotexnik po'lat ko'rinishida tayyorlanadi. Plastinkalar ikki tomondan elektrotexnik lak yordamida izolyasiya qilinib bir-biriga mahkamlanadi [5].

TADQIQOTNING USULI

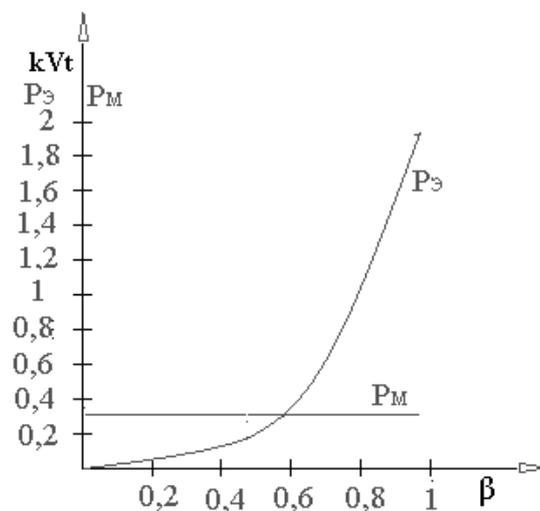
Gisterezis tufayli hosil bo'ladigan isroflar magnit o'tkazgichni magnitlanish chastotasiga to'g'ri proporsional ($P_G = f$), uyurma toklarini hosil qilish

uchun magnit isroflar magnitlanish chastotasining kvadratiga proporsional ($P_{UT} \equiv f^2$).

Magnit isroflar magnit o'zakdagi va ularni ulanish joyidagi magnit induksiyasiga ham bog'liq ($P_M = B^2$). Birlamchi chulg'am kuchlanishi o'zgarmaganda ($U_1 = const$) magnit isroflar o'zgarasdir, yani transformator yuklanishiga bog'liq emas.

Transformatorni loyihalashda magnit isroflar solishtirma magnit isroflar P_{sol} orqali aniqlanadi yani 1 kg yupqa elektrotexnik po'lat uchun magnit induksiya 1,0 yoki 1,5 TL va magnitlanish chastotasi 50 gers bo'lgan holatga aniqlanadi [6].

$$P_M = P_{sol} (B/B)^2 (f/50)^{1,3} G \quad (4)$$



2-rasm. Transformator isrofini yuklamaga bog'liqlik grafifi

B - transformator magnit o'zagidagi magnit induksiyasi real qiymati (TL).

B_{sol} - Solishtirma magnit isrof uchun olingan magnit induksiyasi. $B_x = 1,0 - 1,5 TL$;

G - Magnit o'zak og'irligi (kg)

Transformator magnit isroflari salt ishlash tajribasi orqali kuchlanish o'zgarmaganda salt ish quvvatini aniqlash orqali.

Shunday qilib tarmoqdan birlamchi chulg'amga berilayotgan energiyani bir qismi elektr



isrof $P_{\text{э1}}$ ko'rinishda birlamchi chulg'amda isrof bo'ladi, o'zgaruvchan magnit oqim transformator magnit o'zagida $P_{\text{эм}}$ magnit isroflarni keltirib chiqaradi, qolgan quvvat elektromagnit quvvat kuvvat ko'rinishda ikkinchi chulg'amga o'tkaziladi $P_{\text{эм}} = P_{\text{э1}} - P_{\text{э2}} - P_{\text{М}}$, bunda bir qism energiya elektr $P_{\text{э2}}$ isrofga sarf bo'ladi va yuklamaga quyidagi ko'rinishda quvvat beriladi.

$$P_2 = P_1 - \sum P, \text{ bunda } \sum P = P_{\text{э1}} + P_{\text{э2}} + P_{\text{М}} \quad (5)$$

Foydali ish koeffisienti- bu ikkinchi chulg'andan yuklamaga berilayotgan P_2 quvvatni tarmoqdan birlamchi chulg'amga berilayotgan P_1 quvvatga nisbati [7-8].

$$\eta = \frac{P_2}{P_1} = \left(\frac{P_1 - \sum P}{P_1} \right) = 1 - \sum \frac{P}{P_1} \quad (6)$$

$P_2 = P_0 + \beta_2 P_{\text{КТ}}$ transformator salt ishlashi va yuklama ostida ishlashida sarf bo'ladigan quvvat isrofi. Transformator ikkilamchi chulg'aming chiqish joyidagi aktiv quvvat (Vt)

$$P_2 = \sqrt{3} U_2 I_2 \cos \varphi_2 = \beta * S_{\text{ном}} \cos \varphi_2, \quad (7)$$

$S_{\text{ном}} = \sqrt{3} U_{2N} I_{2N}$ - transformator nominal quvvati (BA),

U_{2N}, I_{2N} - kuchlanish va tokning liniya qiymatlari.

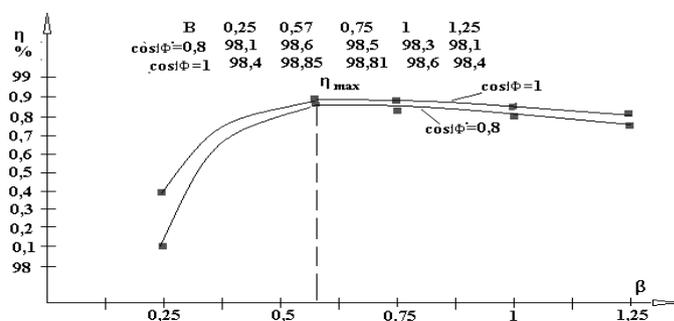
Agar transformatorga berilayotgan quvvatni quyidagicha yozsak,

$$P_1 = P_2 + \sum P \quad (8)$$

Uning foydali ish koeffisientini hisoblash ifodasini hosil qilamiz

$$\eta = \frac{P_2}{P_1} = \frac{\beta * S_{\text{ном}} \cos \varphi_2}{\beta * S_{\text{ном}} \cos \varphi_2 + P_0 + \beta^2 P_{\text{К}}} \quad (9)$$

Ifodadan ko'rinmoqdaki transformator F.I.K. transformator yuklamasi ($\cos \varphi_2$) xarakteriga, yuklanish (β), miqdoriga bog'liq.



3-rasm. Transformator F.I.K. yuklamaga bog'liqlik grafigi

Grafikdan ko'rinib turibdiki F.I.K. maksimal qiymatiga elektr va magnit isroflar teng bo'lganda

$$P_0 = \beta^2 / P_{\text{К}}$$

erishiladi.

Bundan yuklanish koeffisientini aniqlasak

$$\beta' = \sqrt{P_0 / P_{\text{К}}} \quad (10)$$

Odatda transformator F.I.K. yuklanish koeffisienti $\beta' = 0,45 \div 0,65$ ga teng bo'lganda erishiladi.

Transformator F.I.K. maksimal qiymati quyidagi formula orqali topiladi.

$$\eta = \frac{\beta * S_{\text{ном}} \cos \varphi_2}{\beta * S_{\text{ном}} \cos \varphi_2 + 2P_0} \quad (11)$$

Salt ish isrofi (o'zakdagi isroflar); bu isroflar transformator yuklamaga ulanmagan taqdirda ham mavjud bo'ladi. bu isroflarning vjudgakelishini asosiy sababi o'zakni o'ta magnitlanishidir. Birlamchi chulg'amga o'zgaruvchan kuchlanish berilganda hosil bo'lgan magnit maydon oqimi o'zak bo'ylab o'zgarib



turishi tufauli gisterezis uchun va uyurma toklari uchun energiya isrofini keltirib chiqaradi.

Gisterezis- magnit o'zakdagi magnit maydoni magnitlovchi tokning o'zgarishidan ortda qolishi.

Uyurma toki- o'zgaruvchan magnit maydon ta'sirida o'zakda toklarni hosil bo'lishi, ular o'zak bo'ylab harakatlanib qizdiradi va energiya isrofini vjudga keltiradi.

Elektr isroflar(misdagi isroflar)- bu isroflar transformator yuklama ostida ishlaganda vjudga keladi.

Chulg'amdagi isroflar; elektr isroflarni acociy qismini tashkil qiladi, chulg'am qarshiliklari tufayli yuzaga keladi, tok ortishi chulgamni ko'proq qizishiga olib keladi, Joul-Lens qonuniga muvofiq o'tkazgichdagi quvvat isrofi tokning kvadratiga bog'liq.

Qo'shimcha isroflar: transformatorning turli metal qismlarida vjudga keladigan isroflar magnit maydonini sochilishi tufayli, bu isroflar misdagi isroflarga nisbatan ancha kichik lekin umumiy isrofga o'z hissasini qo'shadi.

Transformator samaradorligiga asosiy isroflardan tashqari tasir qiluvchi boshqa omillar.

- Magnit o'zakni tuzilishi: Uyurma toklarini rftta miqdorda kamaytirish uchun plastinkalar izolyasiya qilinib yig'lib, ko'p seksiyali ko'rinishda ishlatiladi.

- O'zak materiali: Gisterezis isrofi kam bo'lgan zamonaviy materiallarni qo'llash orqali salt ish isrofi kamaytiriladi.

- Chulg'am materiali: kichik qarshilikka ega o'tkazgichlarni qo'llash, mis o'tkazgichlar yordamida chulg'amdagi isroflarni kamaytirishga erishiladi.

Transformator yuklamasi: Misdagi isroflar tokning kvadratiga bog'liq, shuning uchun konkret yuklama uchun transformator quvvatini tanlash bilan o'ta yuklamadan sodir bo'ladigan qo'shimcha isroflar oldi olinadi.

Transformatorning samaradorligini aniqlashda F.I.K. energiya orqali aniqlash tushunchasi ham mavjud, bunda yil davomida iste'molchiga etkazib berilgan energiya W_2 (kVt-s)ni, shu vaqt davomida transformator tarmoqdan olgan energiya

W_1 (kVt.-s)ga nisbati $\eta=W_2/W_1$ ko'rihishda ham izohlash mumkin.

TADQIQOT NATIJASI

Transformator isroflarini hisoblash - bu samaradorligi va ish rejimini optimallashtirishni baholash uchun topshiriq.

1. Belgilangan davr uchun elektr-energiya isrofi (ΔW_T)

$$\Delta W_T = \Delta W_0 + (\Delta W_{yuk} + \frac{\Delta W_T}{100}) \quad (12)$$

ΔW_0 - belgilangan davr uchun salt ish isrofi kVt

ΔW_{yuk} - nisbiy yuklama isrofi, %.

ΔW_T - transformator to'la quvvati, kVA

2. Salt ish isrofi (ΔW_0)

$$\Delta W_0 = \Delta P_0 * T_0 \left(\frac{U_1}{U_N} \right)^2 ; \quad (13)$$

ΔP_0 - salt ish isrofi quvvati, kVt

T_0 - transformator ish vaqti, s

U_1 - kuchlanishni real qiymati, V

U_N - kuchlanishni nominal qiymati, V

3. Nisbiy yuklama isroflari (ΔW_{yuk1})

$$\Delta W_{yuk1} = \left(\frac{\Delta W_{yuk}}{\Delta W_T} \right) * 100 \quad (14)$$

ΔW_{yuk} - yuklama isrofi quvvati, kVt.

ΔW_T - transformator to'la quvvati, kVA.

Transformator foydali ish koeffisienti - bu yuklamaga berilayotgan aktiv quvvatni transformator tarmoqdan olayotgan aktiv quvvati nisbatiga teng. FIK transformatorni yuklanishiga bog'liq bo'lib maksimal qiymatiga transformator nominal quvvatining 50 - 70 % erishadi.



$$FIK = \left(\frac{P_{chiq}}{P_{kir}} \right) \times 100\% \quad (15)$$

P_{chiq} – transformator chiqish quvvati,

P_{kir} - transformator kirish quvvati,

XULOSA

Elektr tarmoqlaridada kuchlanishni tasodifan, kutilmaganda uzoq muddatga yoqolishi oldindan aytib bo‘lmas salbiy oqibatlariga olib kelishi mumkin. Shuning uchun iste‘molchilarni uzluksiz, ishonchli va mustahkam elektr energiya bilan taminlash har doim ham dolzarb muammo sanalgan. Elektr tarmoqlarida o‘rnatilgan kuch transformatorlari uzluksiz sifatli elektr energiya bilan taminlashda asosiy muhim o‘rinda turishi inobatga olinsa ularning ish samaradorligi katta ahamiyatga ega.

Transformatorlarda energiya isroflarini turlari va ularni kelib chiqish sabablarini o‘rganish bilan bu isroflarni kamaytirish usullarini aniqlash orqali transformatorlarni samarador ishlashi uchun ularning ish rejimlari optimallashtiriladi. Isroflarni kamaytirish bilan nafaqat resurslar iqtisod qilinadi balki atrof - muhitga salbiy ta‘sirni ham kamaytirishga erishamiz.

Zamonaviy materiallarni qo‘llash, transformator magnit tizimi tuzilishini optimallashtirish va transformatorni to‘g‘ri tanlash bilan ham transformatorni samaradorligi va ishonchli ishlashi taminlanadi.

FOYDALANILGAN ADABIYOTLAR RO‘YHATI

1. Салимов Ж.С., Пирматов Н.Б., Бекчанов. Б.Э. Трансформаторлар ва автотрансформаторлар. Техника олий укув юртлари учун укув кулланма. «VEKTOR-PRESS» нашриёти. 69-bet.

2. Кацман. М.М. Электрические машины; учебник для студ. 12-е изд. Академия 2013-496с.

3. Умар Иброҳимов. Электр машиналари. Тошкент «Укитувчи», «Зиё Ношир» КШК, 2001. 2(84)

4. Эгамов Дилмурод Абдураимович., Узакон Рахмонжон., Бойхонов Зайлобиддин Уразали.

“Способы обеспечения бесперебойного электроснабжения потребителей, имеющих одну систему шин 6-10 кВ и два независимых источника питания 6-10 кВ”, Бюллетень науки и практики. Издательский центр «Наука и практика» 4, 3, 155-159, 2018.

5. Эгамов. Д.А. РАЗРАБОТКА СТРУКТУРНОЙ СХЕМЫ. МОБИЛЬНОГО АВР 04 КВ, UNIVERSUM: “ТЕХНИЧЕСКИЕ НАУКИ”. ООО «МЦНО», 4(85), 93-95, 2021 г.

6. Parpiev Oybek Bakhtiyorjonogli., Egamov Dilmurod Abduraimovich. Information on synchronous generators and motors, Asian Journal of Multidimensional Research, TRANS Asian Research Journals. 10, 9, 2021. 441-445.

7. Muhiddin Atajonov. Development of technology for the development of highly efficient combinations of solar and thermoelectric generators. (2024) AIP Conf. Proc. 3045, 020011, <https://doi.org/10.1063/5.0197733>.

8. Muhiddin Atajonov., Qudrat Mamarasulov., Odiljon Zaripov. Study of Solar Photoelectric Plant in Matlab (Simulink) Package. (2024) Pp.12. <https://doi.org/10.1063/5.0241783>



An algorithm for generating cryptographic keys for small IoT devices

Nurullaev Mirkhon Muhammadovich,

doctoral student, Bukhara engineering technological institute

Email: nurullayevmirxon@gmail.com

Abstract: This paper proposes a lightweight random key generation algorithm for resource-constrained IoT devices. The algorithm uses random collection and multi-source preprocessing to increase randomness and extend keys to desired lengths with minimal computation. Evaluation using statistical tests such as NIST and DIEHARD confirms its cryptographic robustness and secure operation. This approach serves to strike a balance between security and efficiency, making it suitable for IoT applications that require reliable, low-resource encryption.

Keywords: cryptographic key generation, entropy collection, key expansion algorithm, IoT security

Introduction. The dramatic increase in small Internet of Things (IoT) devices revolutionized manufacturing, providing automation, data collection, and remote control. However, it can be said that a number of issues such as these connections, especially the confidentiality, integrity and authenticity of the data, are on the agenda. Methods and algorithms for cryptographic protection of information are being used in the effective solution of these issues. Cryptographic keys are the basis of secure communication protocols that provide encryption, decryption, and digital signatures [1]. But this has caused significant security problems when creating cryptographic keys for these algorithms. In a traditional computing environment, key generation relies on high entropy sources and intensive computing algorithms [2]. However, these methods often pose certain problems in practice for small IoT devices, i.e., face several limitations that complicate the production of secure cryptographic keys for IoT devices such as limited processing power, limited memory, and minimal battery power. First, these devices often lack reliable sources of high-quality randomness needed to create secure keys. In addition, cryptographic operations - the nature of energy demand, are incompatible with the limited battery life of most small devices [3]. Another challenge is scalability; cryptographic solutions must take into account the exponential growth of IoT networks while maintaining robust security. This article proposes a new algorithm developed for small IoT devices to

overcome these problems, with efficiency and security being the top priority.

Literature review and methodology. In recent years, researchers and experts in the field have made significant progress in solving these problems. Physical Unclonable Functions (PUFs), lightweight cryptographic algorithms (e.g. ChaCha20, Kyber), and hardware-based entropy sources emerged as solutions [4]. But, although significant progress has been made by them, some disadvantages should also be listed. For example, PUFs often depends on environmental factors such as temperature, humidity, or voltage. Changes in these conditions can lead to instability in PUF response [5]. In addition, some PUF applications can produce noisy results that require error correction mechanisms that increase overload and complexity [6]. Extended attacks (e.g. side-channel attacks, modeling attacks), on the other hand, can sometimes repeat or predict PUF responses, and this leads to a decrease in their effectiveness [7]. Placing puffs on existing hardware or systems may often require a special design that increases production costs [8], [9]. Or, Although ChaCha20 from lightweight algorithms is considered safe, potential vulnerabilities can arise when implemented incorrectly or integrated into the system. Post-quantum algorithms such as Kyber, however, are still undergoing extensive analysis, and as quantum computations mature, new attacks or vulnerabilities can be detected [10]. Scaling hardware entropy sources across low-cost or resource-constrained IoT devices can be challenging due to size and cost constraints [11].



Although advances such as PUF and lightweight cryptographic algorithms have improved IoT security, there is a gap between scalability, cost-effectiveness, and resistance to advanced attacks. This paper proposes the development and implementation of a Lightweight Random Key Generation (LRKG) NMM algorithm specifically designed for small IoT devices. This algorithm attempts to fill this gap by combining efficient entropy collection, preprocessing, and key expansion techniques, and applying strong randomness estimation methods. Unlike existing approaches, the proposed algorithm combines multiple entropy sources, including environmental information, and lightweight preprocessing, to produce cryptographic keys with high randomness and resistance to attacks even in low-resource settings. The flexibility of the proposed algorithm allows for seamless integration into existing IoT ecosystems, including smart home automation, industrial control systems, and healthcare monitoring devices, where security and efficiency are critical.

Cryptographic requirements for IoT devices

For small IoT devices, there are a number of limitations, such as processing power, memory, and power consumption. On the other hand, these limitations require such lightweight cryptographic solutions that high security is essential for effective operation in a limited environment. The role of cryptographic keys as the basis for ensuring secure communication in IoT systems should be recognized. Because they are widely used in information encryption, electronic digital signatures, and authentication protocols. Generating secure, random keys is a very important factor in preventing unauthorized access and data corruption [12].

The problem of generating cryptographic keys for small IoT devices has been widely studied by scientists around the world, and it is worth noting the achievements in this area. For example, researchers Alvary Kefas Kwala, Shri Kant, and Alpna Mishra conducted comparative analyses of lattice-based cryptographic schemes. Their research is notable for its ease of use for very limited IoT devices, given the efficiency of Kyber schemes in terms of battery usage

and computing speed [13]. This research has significantly advanced the field of cryptographic key generation for IoT devices, i.e., the problems related to resource constraints, security, and privacy have been solved to some extent [14].

Entropy is a measure of randomness used in cryptographic processes. The lack of sufficient entropy sources for small IoT devices makes it somewhat difficult to generate random keys [15]. Traditional cryptographic algorithms such as RSA and ECC require large computational resources, which can lead to problems that are infeasible for small IoT devices [16]. Battery-powered IoT devices need to conserve energy, so algorithms that require high power are disadvantageous for these devices.

Proposed algorithm: lightweight random key generator NMM

Lightweight Random Key Generator (LRKG) NMM is a new algorithm designed specifically for small IoT devices. It uses minimal computational and energy resources while maintaining robust security features.

Components of LRKG NMM

1. Entropy sources: Uses temperature, light intensity and accelerometer readings.
2. Data Preprocessing: The collected raw data is preprocessed by normalizing and quantizing it to a fixed range, reducing noise and enhancing randomness.
3. Hashing mechanism: Applies a cryptographic hash function O'zDSt 1106:2009 [17] to ensure randomness and unpredictability.
4. Key expansion: Utilizes a simple key expansion algorithm to derive longer keys from a short random seed.
5. Key validation: Confirmation of randomness

Process of LRKG NMM

Step 1: Collecting entropy

The algorithm begins by collecting data from built-in sensors. For example, a temperature sensor might provide fluctuating readings that can serve as an initial entropy source.

Let $EM = \{em_1, em_2, \dots, em_n\}$ represent the collected entropy values from different sources (e.g., temperature, light,...).



Each em_i is a random variable:

$$em_i = f(S_i) \quad 1)$$

where S_i is the sensor reading or system data, and f is a function mapping S_i to a numerical entropy value.

The total entropy H is the concatenation of all sources:

$$H = \bigoplus_{i=1}^n em_i \quad 2)$$

Step 2: Data preprocessing

Before analysis, the raw data undergoes a preprocessing step. This involves:

Normalization: Scaling the data to a consistent range (e.g., between 0 and 1).

Quantization: Converting the data into a discrete set of values. These steps aim to improve data quality by:

Reducing noise: Minimizing unwanted variations or errors in the data.

Enhancing randomness: Ensuring that the data exhibits more random patterns, which can be beneficial for certain types of analysis.

The pre-processing step eliminates biases using a whitening function W :

$$W(H) = UzDSt(\bigoplus_{j=1}^m Q) \quad 3)$$

$$Q = (H[2j-1] \oplus H[2j]) \quad 4)$$

Here, Q represents pairwise XOR operations on consecutive entropy bytes.

Step 3: Hashing the entropy

The preprocessed data is fed into a lightweight hash function, such as $UzDSt$ truncated to 128 bits, ensuring high entropy density [18],[19].

Let G denote the PRNG function, which expands the pre-processed seed S into a sequence of random bits R :

$$R = G(S, L) \quad 5)$$

where:

$S = W(H)$ is the pre-processed seed,

L is the desired bit length of the output.

For example, if G is a $UzDSt$ -based PRNG:

$$R = UzDSt(S||c) \quad 6)$$

where c is a counter incremented for each iteration until $|R| \geq L$.

Step 4: Key expansion

The hashed output serves as a seed for the key expansion process. A simple iterative function, like XOR with pseudo-random numbers, generates longer keys if needed.

The key expansion step derives a cryptographic key K from the random bit sequence R using a key derivation function (KDF) KDF :

$$K = KDF(R, salt, k) \quad 7)$$

where:

R is the random bit sequence,

$salt$ is a random value to add uniqueness,

k is the desired key length (e.g., 256 bits).

For example, using $HMAC - UzDSt$:

$$K = HMAC - UzDSt(salt, R)[:k] \quad 8)$$

Step 5: Key Validation

Validate the randomness of K using a statistical test function V :

$$V(K) = \begin{cases} True & \text{if Randomness Tests Pass} \\ False & \text{otherwise} \end{cases} \quad 9)$$

Result. The LRKG NMM algorithm is designed to resist common cryptographic attacks, including:

Brute Force Attacks: The large key space makes exhaustive search infeasible.

Side-Channel Attacks: The use of environmental data introduces unpredictability, complicating attack vectors.

Ensuring true randomness

By utilizing multiple entropy sources and robust preprocessing, LRKG NMM ensures that the generated keys are indistinguishable from truly random sequences.

Using this algorithm, a program for Wearable Devices (Fitness Tracker) and smart home devices was created, and 1,000 values were generated using this program.

To evaluate the proposed algorithm using smart home devices, the following process was carried out:

1. Connect to smart home devices



- Run LRKG NMM with collected entropy
- Prepare for randomness testing
- Analyze results for randomness with statistical tests NIST [20] and DIEHARD [21] (Table 1. and Table 2.)

TABLE 1. NIST Results (P-Values and Pass Rates).

Test Name	P-Value Range	Pass Rate (%)	Result Interpretation
Frequency Test	0.15 - 0.95	98.5%	Random
Block Frequency Test	0.10 - 0.90	97.2%	Random
Runs Test	0.20 - 0.85	99.1%	Random
Approximate Entropy Test	0.25 - 0.88	98.8%	High entropy
Cumulative Sums Test	0.30 - 0.92	97.9%	Random cumulative patterns

TABLE 2. DIEHARD Results (Chi-Square and P-Values).

Test Name	Chi-Square Value	P-Value Range	Result Interpretation
Birthday Spacings	14.5	0.40 - 0.75	Uniform distribution
Overlapping 5-Permutation	1.5	0.20 - 0.80	Random permutations
Binary Rank Test	12.0	0.35 - 0.85	Random matrix structure
OPSO (Overlapping Pairs)	9.2	0.30 - 0.78	Random sequence pairs
DNA Test	10.7	0.45 - 0.80	Unpredictable patterns

Explanation of Numerical Results:

P-Value: Indicates randomness. Values in the range of **0.01 to 1.00** are considered acceptable.

Pass Rate: At least **96%** of sequences should pass to ensure sufficient randomness.

Chi-Square Value: Shows how well the observed data fits the expected randomness distribution.

These results are illustrated in the diagram below (Fig. 1. and Fig. 2.).

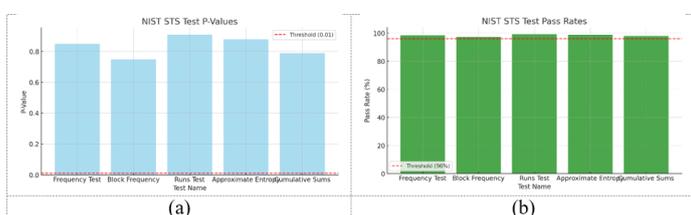


Figure 1. (a) - NIST Test P-Values, (b) - NIST Test Pass Rates.

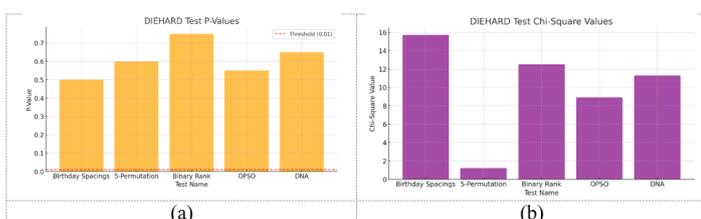


Figure 2. (a) - DIEHARD Test P-Values, (b) - DIEHARD Test Chi-Square Values.

The graphical representations of the randomness test results:

NIST P-Values: Indicates the level of randomness for each test.

NIST Pass Rates: Shows the percentage of test sequences that passed.

DIEHARD P-Values: Highlights the randomness level based on the p-value threshold.

DIEHARD Chi-Square Values: Displays the fit of the data to expected randomness.

Conclusion. The proposed LRKG NMM algorithm helps to solve important problems in generating cryptographic keys for small IoT devices. It was considered that this algorithm can achieve good results by efficiently collecting entropy and pre-processing it, hashing and expanding the key length. The results obtained using this algorithm were verified using existing statistical tests, confirming its effectiveness for small IoT devices. This showed that the algorithm can be recommended as a convenient solution for use in resource-constrained IoT devices.

As the IoT ecosystem continues to expand, it is worth noting that solutions such as LRKG NMM play a crucial role in ensuring secure and reliable communication. It has been shown that the keys generated by evaluating the LRKG NMM algorithm have a high randomness required to resist cryptographic attacks.

References

- P. Kaur and S. Aggarwal, "Cryptographic algorithms in IoT - a detailed analysis," in *2nd International Conference on Computational Methods in Science & Technology (ICCMST)*, (Mohali, India, 2021), pp. 45-50, doi: 10.1109/ICCMST54943.2021.00021
- N. M. Mukhammadovich and A. R. Djuraevich, *International Journal of Electrical and Computer Engineering* 13, 911 (2023). <https://doi.org/10.11591/ijece.v13i1.pp911-919>



3. M. Rana, Q. Mamun and R. Islam, *Sensors* 23(18):7678 (2023).
<https://doi.org/10.3390/s23187678>
4. J. Furtak, *Sensors* 20(17):5012 (2020).
<https://doi.org/10.3390/s20175012>
5. K. H. Stangherlin and M. Sachdev, (2021) 22nd International Symposium on Quality Electronic Design (ISQED), Santa Clara, CA, USA, 2021, pp. 529-534, doi: 10.1109/ISQED51717.2021.9424335.
6. C. Herder, M. -D. Yu, F. Koushanfar and S. Devadas, (2014) in Proceedings of the IEEE, vol. 102, no. 8, pp. 1126-1141, Aug. 2014, doi: 10.1109/JPROC.2014.2320516.
7. Mahmoud, A., Rührmair, U., Majzoobi, M., & Koushanfar, F. (2013). Combined modeling and side channel attacks on strong PUFs. *Cryptology ePrint Archive*, Paper 2013/632. Retrieved from <https://eprint.iacr.org/2013/632>
8. M. Wang, A. Yates and I. L. Markov, (2014) IEEE/ACM International Conference on Computer-Aided Design (ICCAD), San Jose, CA, USA, 2014, pp. 454-461, doi: 10.1109/ICCAD.2014.7001391.
9. Halak, B. (2018). Physically Unclonable Functions: Design Principles and Evaluation Metrics. In: *Physically Unclonable Functions*. Springer, Cham. https://doi.org/10.1007/978-3-319-76804-5_2
10. Iavich, M., & Kuchukhidze, T. (2024). Investigating CRYSTALS-Kyber Vulnerabilities: Attack Analysis and Mitigation. *Cryptography*, 8(2), 15. <https://doi.org/10.3390/cryptography8020015>
11. Lampert, B., Wahby, R. S., Leonard, S., & Levis, P. (2016). Robust, low-cost, auditable random number generation for embedded system security. *Cryptology ePrint Archive*, Paper 2016/884. <https://doi.org/10.1145/2994551.2994568>
12. M. M. Nurullaev, "Functions and their mechanisms for generating cryptographic keys and random numbers," AIP Conference Proceedings 2969, (AIP Publishing, Melville, NY, 2024). <https://doi.org/10.1063/5.0181797>
- A. Kwala, S. Kant and A. Mishra, *Discover Internet of Things* 24, (2024). <https://doi.org/10.1007/s43926-024-00069-2>
13. H. Bandara, Y. Herath, T. Weerasundara and J. Alawatugoda, *Cryptography* 6(4):56 (2022).
14. S. Ali and F. Anwer, *Int. j. inf. tecnol.* 16, 2053–2067 (2024). <https://doi.org/10.1007/s41870-024-01753-w>
15. J. Furtak, *Sensors* 23(11):5102 (2023). <https://doi.org/10.3390/s23115102>
16. O'z DSt 1106:2009 – Information technology. Cryptographic protection of information. Hash function. (2009).
17. M. M. Nurullaev, "Generating random numbers for a cryptographic key based on smartphone sensors," International Scientific and Practical Conference on "Modern Problems of Applied Mathematics and Information Technology (MPAMIT2022)" AIP Conf. Proc. 3004, 060014-1–060014-5 (AIP Publishing, Melville, NY, 2024). <https://doi.org/10.1063/5.0199570>
18. Nurullaev M. M. Modeling of information processes in integrated security systems. *Journal Molodoy uchoniyy.* – (2018). – T. 17. – №. 203. – C. 26-27.
- A. Rukhin, J. Soto, J. Nechvatal, M. Smid, E. Barker, S. Leigh, M. Levenson, M. Vangel, D. Banks, N. Heckert, J. Dray, S. Vo, and L. Bassham, NIST Special Publication 800-22: A Statistical Test Suite for the Validation of Random Number Generators and Pseudo-Random Number Generators for Cryptographic Applications (2010), available at <https://doi.org/10.6028/NIST.SP.800-22r1a>
19. G. Marsaglia, *DIEHARD: A Battery of Tests of Randomness*. 1995. Accessed January 10, 2025, available at <http://stat.fsu.edu/pub/diehard/>



MAHSULOTLARNI SAQLASH OMBORI FAOLIYATINI AVTOMATLASHTIRISHDA MOBIL ROBOTLARDAN FOYDALANISH

Xolmurotov Botirjon Tursinboyevich,
Andijon mashinasozlik instituti, dotsent, t.f.f.d. (PhD)
xolmurotovbotirjon@gmail.com

Xusanboyev Mirkomil Mirodil o'g'li,
Andijon mashinasozlik instituti, magistr.
mirkomil.khusanboyev@gmail.com

Annotatsiya: Ushbu maqolada mahsulotlarni saqlash omborxonalarining faoliyatini avtomatlashtirish uchun mobil (ko'chma) g'ildirakli robotlar qo'llanadigan robototexnika kompleksini yaratish masalasi ko'rib chiqilgan va yoritilgan, shuningdek, tizimning ishlashini tavsiflovchi algoritmlar keltirilgan.

Kalit so'zlar: avtomatlashtirish, mobil robot, boshqaruv algoritmi, marshrut, ombor.

Kirish. Hozirgi texnika va texnologiya shiddat bilan rivojlanayotgan bir davrda texnologik jarayonlarni avtomatlashtirish vazifasi turli ishlab chiqarish sohasiga tobora chuqurroq kirib bormoqda. Avtomatlashtirish uchun katta potentsialga ega sohalardan biri bo'lgan, mahsulotlarni saqlovchi omborlar faoliyatida ombor binolaridagi texnologik jarayonlar o'rtasidagi o'zaro ta'sirdir.

Adabiyotlar tahlili va metodologiya. Ushbu sohada avtomatlashtirishni ta'minlovchi usullardan biri - omborlarda amalga oshiriladigan harakatlarni avtomatlashtirish uchun mo'ljallangan robototexnika kompleksini yaratishdir. Bunga yuklash, ombor hududi bo'ylab harakatlanish va yuklarni tushirish, shuningdek, yuklarni ombor stendlariga optimallashtirilgan joylashtirishni rejalashtirish kabi funktsiyalar kiradi.

Kompleksning samarali ishlashini ta'minlovchi asosiy tarkibiy qismlar quyidagilardan iborat:

1. Yuqori yuk ko'tarish qobiliyatiga ega g'ildirakli mobil robotlar, manipulyator bilan jihozlangan. Mahsulotlarni saqlash ombori xodimlari tomonidan doimiy ravishda bajariladigan mexanik ishlarni, ya'ni, yuklash, tushirish, yukni joylashtirilgan joyidan yuklash zonasigacha yetkazib berish va orqaga qaytarish, shuningdek, hudud bo'ylab yuklarni harakatlantirishni amalga oshiradi.

2. Mobil robotlarning o'zaro ta'sirini muvofiqlashtirish, maqsadni belgilash va mahsulotlarni saqlash ombori hududidagi qo'shimcha logistika jarayonlarini optimallashtirish uchun javobgar bo'lgan boshqaruv tizimi.



a) Stelaj bilan harakatlanuvchi. b) Donalab tashuvchi. v) Yukni joylovchi

1-Rasm. Mobil robotlar [1].

Tizimning ishlash prinsiplari bo'yicha yaxshiroq tushuncha berish maqsadida uning tarkibiy qismlari o'rtasidagi vazifa va o'zaro ta'sir algoritmining tipik misolini keltiramiz:

1. Boshqaruv tizimiga X yukini belgilangan vaqtda yuklash zarurligi to'g'risida ma'lumot keladi.

2. Boshqaruv tizimi yuk to'g'risidagi ma'lumotlarni tahlil qiladi va u (yuk) joylashtirgan stend (stelaj) haqida ma'lumot oladi.

3. Boshqaruv tizimi boshqa robotlarning joylashuvlarini hisobga olgan holda ushbu vaqtda erkin mobil robot uchun marshrut (yo'nalish) tuzadi, shu bilan birga yo'llarning kesishishi paytida to'g'onlarga

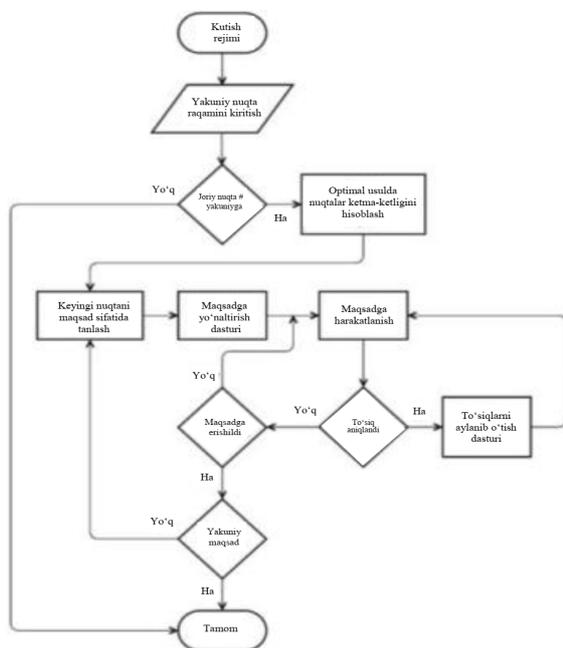


(o'zaro to'qnashuvlarga) yo'l qo'ymaslikka yordam beradi.

4. Yuk tashuvchi mobil robotga belgilangan yo'nalish bo'yicha harakat qilish ko'rsatmasi beriladi.

5. Mobil robot yukni qidiradi, ushlaydi va uni yuklash zonasiga olib boradi.

Ushbu kompleksdan foydalanish omborni xizmat ko'rsatuvchi xodimlari sonini deyarli 95%ga qisqartirib, inson faktori ta'sirini kamaytirishga, hamda xatolik ehtimolini pasaytirishga imkon beradi, shuningdek, ombor binolarining o'tkazuvchanligini oshiradi.



2-Rasm. Harakat algoritmining blok diagrammasi

Ushbu turdagi tizimlarni yaratishda mobil robotlar o'rtasida harakat yo'llarining optimal variantini aniqlash va ularning o'zaro ta'sirini muvofiqlashtirish metodikasi katta ahamiyatga ega. Chunki, ushbu jarayonlarning optimalligi tizim sifat ko'rsatkichlariga – masalan, avtomatlashtirilgan omborning o'tkazuvchanligi yo'l mobil robotlar harakati yo'llarining to'qnashuv b'evosita ta'sir qiladi.

Mobil robotga qo'yilgan va ularni bajarishni ta'minlaydigan harakat dasturini yaratishda tegishli boshqaruv tizimi algoritmlari ishlab chiqilgan.

Funksional jihatdan ushbu algoritmlar ikki qismga ajratilishi mumkin:

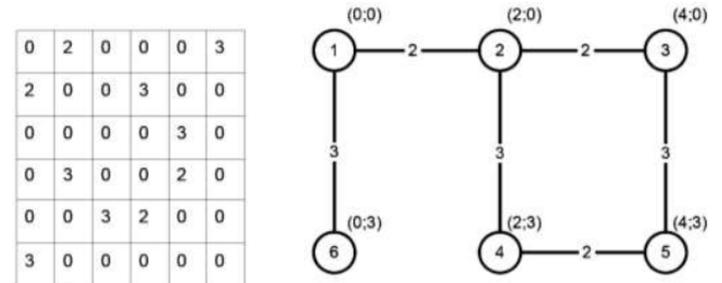
Ushbu maqola doirasida global algoritmi ko'rib chiqiladi. U global yo'nalishni - optimal marshrutni tanlash va unga rioya qilishni ta'minlaydi. Harakat algoritmining umumiy ko'rinishi yuqoridagi 2-rasmda keltirilgan.

Vazifa yo'qligida (buyruq berilmaganda) robot kutish holatida bo'ladi. Shu bilan birga, robotning yo'nalish burchagi va hozirgi joylashuvi haqidagi ma'lumotlar uning xotirasiga yozilgan. Shuningdek, xotirada ikkita ma'lumotlar massivi saqlanmoqda:

1. Bog'lanish matritsasi, nuqtalar o'rtasidagi bog'lanishlar va ularning og'irligi (nuqtalar orasidagi masofa) haqida ma'lumotlarni o'z ichiga oladi.

2. Koordinatalar matritsasi, barcha nuqtalarning tekislikdagi xOy koordinatlari qiymatlarini o'z ichiga oladi [2].

3-Rasmda grafning ko'rinishiga misol keltirilgan bo'lib, unda tugunlar maqsadli nuqtalar (xonadagi kesish joylari), qirralar esa ularni bog'lovchi koridorlardir va ularga mos keluvchi bog'lanish matritsasi mavjud:



3-Rasm. Qo'shnilik matritsasi va uning mos grafigi

Berilgan nuqtaga ko'chish buyrug'i kelganda, vaznli grafda minimal masofani qidirish algoritmi – Deykstra algoritmiga asoslangan optimal yo'l ketma-ketligini hisoblash funksiyasi ishga tushadi. Funksiyaning kirish ma'lumotlari qo'shni matritsa, boshlang'ich koordinata va oxirgi koordinatadir. Ushbu funksiyaning natijasi ketma-ket nuqtalar to'plami bo'lib, ular orqali robot belgilangan maqsadga erishadi.

Initializatsiyada a uchastkasining belgilari nolga teng deb hisoblanadi, qolgan uchastkalarining



belgilari esa cheksizlikka teng. Bu a dan boshqa uchastkalarga masofalar hali noma'lum ekanligini aks ettiradi. Barcha grafik uchastkalari tashrif buyurilmagan deb belgilangan.

Algoritmning bosqichi. Agar barcha uchastkalar tashrif buyurilgan bo'lsa, algoritm tugaydi. Aks holda, tashrif buyurilmagan uchastkalardan minimal belgi qiymatiga ega bo'lgan u uchastkasi tanlanadi. Biz u ushbu nuqtaning oldingi nuqtasi sifatida joylashgan barcha mumkin bo'lgan yo'llarni ko'rib chiqamiz. U dan chiqadigan qirralar orqali bog'langan uchastkalarni uning qo'shnilari deb ataladi. U ning har bir qo'shnisi uchun, tashrif buyurilgan deb belgilanganlardan tashqari, yangi yo'l (yo'nalish) uzunligini hisoblaymiz, bu u ning joriy belgisi va u bilan ushbu qo'shni o'rtasidagi qirrasiz uzunligi yig'indisiga tengdir. Agar hosil bo'lgan uzunlik qiymati qo'shnining belgisi qiymatidan kichik bo'lsa, unda belgini hosil bo'lgan qiymat bilan almashtiramiz. Barcha qo'shnilarni ko'rib chiqqandan so'ng, u ni tashrif buyurilgan deb belgilaymiz va algoritm bosqichini takrorlaymiz [3].

Masalan, yuqoridagi sxema uchun 1-dan 5-gacha o'tish jarayonida algoritmning natijasi quyidagi ketma-ketlik bo'lishi mumkin: 1 – 2 – 3 – 5.

Har bir olingan nuqta uchun navbatma-navbat quyidagi harakat algoritmi bajariladi:

1. Joriy va keyingi nuqtalarning koordinatalari bo'yicha ularni bog'laydigan vektorning og'ish burchagini Ox o'qidan hisoblash.
2. Joriy kurs burchagi va zarur burchak qiymatiga asoslanib, burilish burchagi qiymatini shakllantirish.
3. Belgilangan burchakda burilish funksiyasini bajarish, yangi kurs burchagi qiymatini saqlash.
4. To'g'ri chiziqda harakat qilish funksiyasini bajarish.

Yakuniy nuqtaga yetgach, robot kutish rejimiga o'tadi.

Tayyorlangan algoritmni sinovdan o'tkazish va mavjud analoglar bilan taqqoslash natijasida shuni aniqladikki, xonani soddalashtirilgan usulda vaznli grafik ko'rinishida ifodalash metodikasini qo'llash hisob-kitoblarni minimal resurslar bilan amalga oshirish imkonini

beradi, bu esa tizimning hisoblash quvvatlarida iqtisod qiladi va loyihaning iqtisodiy jihatiga ijobiy ta'sir ko'rsatadi.

Shuningdek, yana bir muhim jihat - robotning joylashuvi koordinatalarini aniqlash usulini tanlash zarurati. Ushbu muammoni hal qilishning eng keng tarqalgan usuli — har bir g'ildirakning yurish masofasini hisoblash uchun ishlatiladigan *odometrik* sensorlardan foydalanishdir. Bu esa maydondagi nisbiy joylashuv koordinatasini olish imkonini beradi. Ushbu turdagi sensorlarning tipik misoli — reduktorlar yoki motorlarning chiqish valiga o'rnatilgan fotoelektrik inkremental aylanish o'zgartirgichlari (inkremental kodlagichlar). Ushbu usulning kamchiligi — haqiqiy sharoitlarda g'ildiraklarning sirpanishi bilan bog'liq yig'ilgan xatolar paydo bo'lishidir [4].

Natija. O'tkazilgan tadqiqotlar natijasi shuni ko'rsatdiki, xona rejasiga asoslangan yo'lni hisoblash algoritmi inkremental kodlagichlardan foydalangan holda, 150 burchak sekundi rezolyutsiyasiga ega bo'lgan holda 1 soat davomida harakatlanishda yig'ilgan joylashuv xatosi 25 santimetрни tashkil etadi. Shuning uchun yig'ilgan xatolar miqdorini kamaytirish maqsadida joylashuvni nazorat qilishning qo'shimcha usullaridan foydalanish taklif etiladi: shift yoki polga o'rnatilgan sensorlar, ular ma'lum nuqtalarda joylashgan bo'lib, ulardan o'tganda yig'ilgan xato nolga tushiriladi.

Xulosa. Maqolada ko'rib chiqilgan tadqiqotlar natijasidan kelib chiqib xulosa qilib aytganda, ishlab chiqilgan algoritm universal bo'lib, deyarli har qanday ishlab chiqarish jarayonida kichik o'zgarishlar bilan qo'llanilishi mumkin. Bundan tashqari, odometr sensorlari va qo'shimcha xato nol tizimidan foydalanilganda, tizim ishlashining yuqori aniqligi ta'minlanadi, bu esa uni katta xatolik bilan tanqidiy jarayonlarda ishlatishga imkon beradi.

Foydalanilgan adabiyotlar

1. Девянин Е. А. О движении колесных роботов. // Докл. науч. школы-конференции «Мобильные роботы и мехатронные системы». 1998. С. 169-200.
2. Мартыненко Ю. Г. Динамика мобильных роботов. // Соросовский образовательный журнал. 2000. № 5. С. 110-116.
3. Алгоритм Дейкстры – Википедия: [Электронный ресурс]. – Режим доступа: https://ru.wikipedia.org/wiki/Алгоритм_Дейкстры.
4. <https://clar.uspu.ru/bitstream/uspu/18180/2/2023Gorbunov.pdf>



ENDOKRIN KASALLIKLAR PROFILAKTIKASI VA ERTA TASHXISLASHNING MATEMATIK MODELLARI

Nishanov Axram Xasanovich,

Muhammad al-Xorazmiy nomidagi Toshkent axborot
texnologiyalari universiteti tizimli va amaliy dasturlash
kafedrası professori
nishanov_akram@mail.ru

Mengturayev Farxod Ziyatovich,

Denov tadbirkorlik va pedagogika instituti katta o'qituvchisi
f.mengturaev@dpi.uz
ORCID: 0000-0003-0562-8377

Allayarov Uktamjon Bektashovich,

Toshkent tibbiyot Akademiyasi Termez filiali, ichki kasalliklar
propedevtikasi, reabilitologiya, xalq tabobati va endokrinologiya
kafedrası asistenti.
criptolione7777@gmail.com

Xaydarov Sherali Islom o'g'li,

Denov tadbirkorlik va pedagogika instituti o'qituvchisi
sh.haydarov@dpi.uz
ORCID: 0000-0002-2514-3329

Annotatsiya: Mazkur tadqiqotda endokrin kasalliklarning profilaktikasi va erta tashxislash masalalarining matematik modellashtirish usullari o'rganildi. Tadqiqotda ehtimollik nazariyasi, statistik tahlil, klassifikatsiya algoritmlari va klasterlash usullari qo'llanilib, diagnostika jarayonini optimallashtirish yondashuvlari ishlab chiqildi. Tadqiqot natijalari shuni ko'rsatadiki, matematik modellar diagnostika aniqligini oshirishda va sog'liqni saqlash tizimining resurslarini samarali taqsimlashda muhim rol o'ynaydi. Ayniqsa, Bayes teoremasi asosida kasallik ehtimolini hisoblash, klasterlash algoritmlari yordamida xavf guruhlarini aniqlash va dinamik prognozlash yondashuvlari orqali kasallik rivojlanishini oldindan baholash mumkinligi isbotlandi. To'plangan ma'lumotlarni tizimli tahlil qilish orqali profilaktika samaradorligini kuchaytirish va individual davolash rejasini ishlab chiqish imkoniyati yaratiladi.

Kalit so'zlar: Endokrin kasalliklar, profilaktika, erta tashxis, matematik modellashtirish, klassifikatsiya, klasterlash

Kirish. Endokrin kasalliklarning profilaktikasi va erta tashxislanishi tibbiyot sohasida dolzarb masalalardan biri bo'lib, sog'liqni saqlash tizimi uchun katta ahamiyatga ega. Ushbu kasalliklar endokrin bezlarning buzilishi natijasida yuzaga keladi va vaqt o'tishi bilan boshqa organlar va tizimlarga ta'sir ko'rsatishi mumkin [15]. Profilaktika va erta tashxis orqali kasalliklarning asoratlarini kamaytirish va bemorlarning hayot sifatini oshirishga erishiladi. Ushbu kasalliklar endokrin bezlar faoliyatidagi

buzilishlar natijasida yuzaga keladi va ko'pincha turli asoratlarga olib kelishi mumkin [1-5]. Kasalliklarni erta bosqichda aniqlash orqali bemorlarning hayot sifatini oshirish va davolash samaradorligini kuchaytirish mumkin. Endokrin kasalliklarning erta tashxisi statistik yondashuvlar, ehtimollik nazariyasi va matematik modellashtirish yordamida amalga oshirilishi mumkin. Ushbu jarayonda ma'lumotlar yig'ish, tahlil qilish va qaror qabul qilish usullari asosiy o'rinni egallaydi [6-8]. Endokrin kasalliklarning erta



tashxislash masalasi matematik modellashtirish orqali yuqori samaradorlik bilan amalga oshirilishi mumkin. Ehtimollik nazariyasi, klassifikatsiya modellar va klasterlash usullari diagnostik jarayonni takomillashtirishga yordam beradi. Ushbu yondashuvlar sog'liqni saqlash tizimini samarali boshqarish va bemorlarning hayot sifatini oshirish uchun asos bo'lib xizmat qiladi [9-12].

Endokrin kasalliklar zamonaviy tibbiyotning dolzarb muammolaridan biri bo'lib, ularning erta tashxisi sog'liqni saqlash tizimi uchun muhim vazifalardan hisoblanadi. Ushbu kasalliklar endokrin bezlar faoliyatidagi buzilishlar natijasida yuzaga keladi va ko'pincha turli asoratlarga olib kelishi mumkin. Kasalliklarni erta bosqichda aniqlash orqali bemorlarning hayot sifatini oshirish va davolash samaradorligini kuchaytirish mumkin. Endokrin kasalliklarning erta tashxisi statistik yondashuvlar, ehtimollik nazariyasi va matematik modellashtirish yordamida amalga oshirilishi mumkin. Ushbu jarayonda ma'lumotlar yig'ish, tahlil qilish va qaror qabul qilish usullari asosiy o'rinni egallaydi. Endokrin kasalliklarning profilaktikasi va erta tashxislanishi nafaqat bemorlar hayotini saqlashga, balki sog'liqni saqlash tizimi uchun iqtisodiy jihatdan foydali bo'lishi mumkin. Profilaktika dasturlari kasallik xavfini kamaytirishga qaratilgan bo'lib, ular sog'lom turmush tarzini rag'batlantirish, xavf omillarini nazorat qilish va kasallikning ilk belgilarini aniqlashga yo'naltirilgan. Matematik modellar ushbu jarayonlarni boshqarish va optimallashtirish uchun muhim vositalardan biri hisoblanadi.

Endokrin kasalliklar, masalan, qandli diabet, qalqonsimon bez kasalliklari va metabolik sindrom, turli xil diagnostik yondashuvlarni talab qiladi. Kasalliklarni erta aniqlash algoritmlaridan foydalanish orqali klinik qaror qabul qilishni avtomatlashtirish va bemorlarni tasniflash samaradorligini oshirish mumkin. Shuningdek, profilaktika jarayonida aholini xavf guruhlariga ajratish, sog'lom turmush tarziga o'rgatish va epidemiologik ma'lumotlarni yig'ish muhim o'rin tutadi [16-20]. Mazkur tadqiqot endokrin kasalliklarning profilaktikasi va erta tashxislash masalalarining matematik ifodalanishini ko'rib

chiqadi. Unda statistik yondashuvlar, ehtimollik nazariyasi, klassifikatsiya va klasterlash algoritmlari orqali diagnostika va profilaktika jarayonlarini optimallashtirish yondashuvlari o'rganiladi. Ushbu masalaning matematik modellashtirilishi tibbiy resurslarni samarali taqsimlash va bemorlar uchun individual yondashuvlarni ishlab chiqishga imkon yaratadi [21-22].

Endokrin kasalliklarning erta tashxislash masalasi matematik modellashtirish orqali yuqori samaradorlik bilan amalga oshirilishi mumkin. Ehtimollik nazariyasi, klassifikatsiya modellar va klasterlash usullari diagnostik jarayonni takomillashtirishga yordam beradi. Ushbu yondashuvlar sog'liqni saqlash tizimini samarali boshqarish va bemorlarning hayot sifatini oshirish uchun asos bo'lib xizmat qiladi [23-24].

Adabiyotlar tahlili va metodologiya.

Endokrin kasalliklarning profilaktikasi va erta tashxislash bo'yicha matematik modellarni qo'llash masalasida olimlarning umumiy fikri shundan iboratki, zamonaviy statistik va matematik yondashuvlar diagnostika jarayonlarining aniqligi va samaradorligini oshiradi. Bayes modeli, klassifikatsiya algoritmlari va klasterlash usullari kasallikni erta bosqichda aniqlashga yordam beradi, bu esa kasallikning asoratlarini kamaytiradi va bemorlarning hayot sifatini yaxshilaydi. Olimlar matematik modellashtirishni diagnostika jarayonini avtomatlashtirish vositasi sifatida ko'radi. Ayniqsa, katta hajmdagi tibbiy ma'lumotlarni tahlil qilish imkoniyati bemorlar uchun individual davolash rejalarini ishlab chiqishda muhim rol o'ynaydi. Tadqiqotchilar fikricha, ma'lumotlar yig'ishdan tortib, dinamik prognozlash va profilaktik chora-tadbirlarni rejalashtirishgacha bo'lgan jarayonlarda matematik yondashuvlar tibbiy resurslarni optimallashtirishga va sog'liqni saqlash tizimining samaradorligini oshirishga xizmat qiladi. Shuningdek, olimlar diagnostik jarayonlarda algoritmlarning aniqligini oshirish va noto'g'ri tashxis ehtimolini kamaytirish uchun chiqindilarni aniqlash usullarini keng qo'llash zarurligini ta'kidlashadi. Ularning fikriga ko'ra, bu yondashuvlar orqali sog'liqni saqlash tizimi uchun iqtisodiy samaradorlik



va bemorlar uchun hayot sifati kafolatlanadi. Umuman olganda, olimlar matematik modellarni tibbiyotning ajralmas qismi sifatida ko'radi va ularni amaliyotga kengroq joriy etishni tavsiya qiladi. Quyidagi olimlarni ishlarida shuni kursatib beradiki.

Alan Turing (Buyuk Britaniya) – Matematik modellar va algoritmik yondashuvlarning murakkab tizimlar, shu jumladan tibbiyotda qo'llanishi imkoniyatlarini birinchi bo'lib asoslab berdi. U zamonaviy algoritmlar va modellashtirishning tamal toshini qo'ygan.

Buyuk Britaniya olim Thomas Bayes modeli va ehtimollik nazariyasi orqali kasallik ehtimolini baholashni asoslagan. Uning yondashuvi diagnostik qarorlar qabul qilishda asosiy nazariya sifatida qo'llanilmoqda.

Kanada olim Geoffrey Hinton – Neyron tarmoqlar va mashinani o'qitish texnologiyalari orqali diagnostik jarayonlarni avtomatlashtirishda ilg'or natijalarga erishgan. Uning tadqiqotlari tibbiy ma'lumotlarni tahlil qilishda keng qo'llanilmoqda.

AQSh olim Leo Breiman, Random Forest va boshqa klassifikatsiya algoritmlarini ishlab chiqishda muhim hissa qo'shgan. Ushbu algoritmlar simptomlarni tahlil qilish va bemorlarni sog'lom va kasallik guruhlariga ajratishda muvaffaqiyatli qo'llanilmoqda.

Buyuk Britaniya olim David Cox statistik modellar, xususan Cox regressiyasi orqali xavfni aniqlash va bashorat qilishni rivojlantirgan. Bu model endokrin kasalliklarning xavf omillarini tahlil qilishda samarali natijalar beradi.

Rossiya Andrey Kolmogorov ehtimollik nazariyasining asoschisi. Uning ishlari tibbiyotda statistik tahlil va ehtimollik modellarini joriy etishda asosiy ilmiy zamin yaratib berdi.

AQSh olim Michael Jordan zamonaviy mashinani o'qitish va ehtimollik nazariyasining yetakchi tadqiqotchilaridan biri. Uning ishlari tibbiy ma'lumotlarni samarali tahlil qilish va diagnostik jarayonlarni avtomatlashtirishga yo'naltirilgan.

Rossiya olim Vladimir Vapnik Support Vector Machines (SVM) algoritmini ishlab chiqqan. Ushbu

algoritm endokrin kasalliklarni tashxislashda keng qo'llanilmoqda.

Buyuk Britaniya olim Christopher Bishop statistik tahlil va mashinani o'qitish bo'yicha ilg'or tadqiqotlar olib borgan. Uning ishlari tibbiyotda ma'lumotlarga asoslangan qarorlar qabul qilishda qo'llaniladi.

AQShlik olim Peter Norvig ma'lumotlarni tahlil qilish va sun'iy intellekt texnologiyalarini diagnostika va profilaktikada qo'llash bo'yicha tadqiqotlar olib borgan.

Yuqoridagi olimlar endokrin kasalliklarni tashxislash va profilaktikada matematik modellarni qo'llashni nazariy va amaliy jihatdan boyitgan. Ularning ishlari diagnostika aniqligini oshirish, xavf guruhlarini aniqlash va individual davolash rejalarini ishlab chiqishda asos bo'lib xizmat qilmoqda.

Natijalar. Endokrin kasalliklarning profilaktikasi endokrin tizim kasalliklarining oldini olish va ularni rivojlanish xavfini kamaytirishga qaratilgan tadbirlar majmuasidir. **Endokrin kasalliklar nima?** Endokrin kasalliklar endokrin bezlarning noto'g'ri ishlashi natijasida paydo bo'ladigan kasalliklar bo'lib, ular gormonlarning me'yordan oshib ketishi yoki kamayib ketishi bilan kechadi. Ko'p uchraydigan endokrin kasalliklar. Qandli diabet, qalqonsimon bez kasalliklari (gipotiroidizm, gipertiroidizm) Metabolik sindrom, o'smirlik davridagi gormonal disbalans, kortizol yetishmovchiligi yoki ortiqchaligi bular ustida biz profilaktika ishlarini olib borish orqali uni oldini olish uchun quyidagi tadbirlarni amalga oshirish muhim hisoblanadi. 1. **Sog'lom ovqatlanish. Tuz miqdorini nazorat qilish**, ayniqsa yodli tuz iste'mol qilish qalqonsimon bez kasalliklarining oldini olishda muhim. **Shakarni cheklash**, qandli diabet xavfini kamaytirish uchun, Meva va sabzavotlarga boy, vitamin va minerallarga boy ovqatlarni iste'mol qilish. 2. **Faol hayot tarsi.** Har kuni kamida 30 daqiqa jismoniy faoliyat bilan shug'ullanish (yurish, yugurish, suzish). Ortiqcha vazndan qochish yoki mavjud vazni me'yorga keltirish. 3. **Stressni boshqarish.** Stress gormonal disbalansga olib kelishi mumkin, shuning uchun stressni boshqarish usullarini o'rganish. 4.



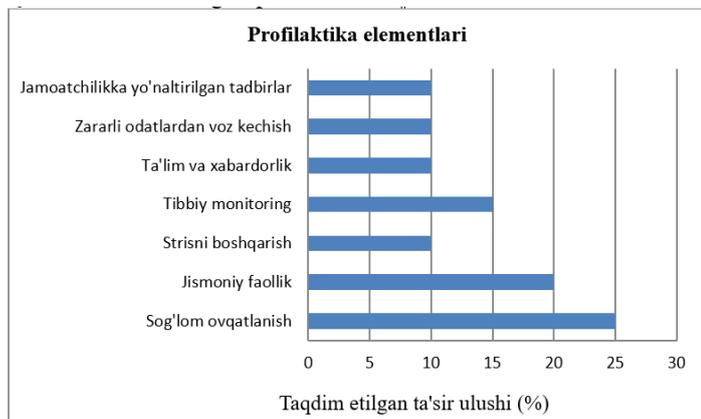
Tibbiy ko'riklardan muntazam o'tish. qandli diabet, qalqonsimon bez va boshqa endokrin kasalliklar xavfini aniqlash uchun yillik tekshiruvlardan o'tish,. 5. **Zararli odatlardan voz kechish.** chekish va alkogol ichimliklarni iste'mol qilish endokrin tizim faoliyatiga salbiy ta'sir ko'rsatadi. 6. **Vitamin va mineral yetishmovchiligini oldini olish, yod** qalqonsimon bez faoliyati uchun zarur, dengiz mahsulotlari, yodlangan tuz iste'moli muhim, **D vitamini** quyoshda ko'proq bo'lish, agar kerak bo'lsa, D vitamini qo'shimchalarini qabul qilish, **kaltsiy va magniy** gormonlar sinteziga ta'sir qiladi, sut mahsulotlari va yong'oqlarda mavjud. 7. **Irqiy va oilaviy tarixni hisobga olish,** oila a'zolarida endokrin kasalliklar bo'lsa, xavf omillarini kamaytirish choralari ko'rilishi kerak. 8. **Atrof-muhit omillaridan himoya qilish,** Toksik moddalar va kimyoviy vositalardan uzoq turish. Endokrin kasalliklarning oldini olish uchun sog'lom turmush tarzini saqlash, muntazam ravishda shifokorga murojaat qilish va individual ehtiyojlarga mos profilaktika choralari ko'rish zarur. Profilaktika nafaqat sog'liqni saqlash xarajatlarini kamaytiradi, balki hayot sifatini oshiradi. Zamonaviy texnologiyalar va dasturiy mahsulotlar yordamida profilaktika ishlarini olib borish jarayonida ish unumdorligi sezilarli darajada oshiradi [15].

Endokrin kasalliklaridan qandli diabet kasalligi profilaktika ishlarini olib borish uchun kasallikning rivojlanishini oldini olish yoki uni kechishini yengillashtirishga qaratilgan chora-tadbirlarni amalga oshirishni o'z ichiga oladi. 1. Sog'lom ovqatlanish. Shakar iste'molini kamaytirish, shirinliklar, gazlangan ichimliklar va qandolat mahsulotlarini cheklash, ko'proq tola moddalarga boy ovqatlar iste'mol qilish, bunda sabzavotlar, mevalar, butun donli mahsulotlar, yong'oqlar va dukkakli mahsulotlar muhim o'rin tutadi, fastfud va yog'li ovqatlardan qochish, ularda yuqori kaloriyal va yog' miqdori ko'p bo'lib, bu tana vazni va insulin rezistentligiga salbiy ta'sir qiladi, cheklangan miqdorda uglevod iste'moli, sekin hazm bo'ladigan murakkab uglevodlarga e'tibor bering (grechka, qizil guruch, suli yormasi), 2. Jismoniy faollikni oshirish. Haftasiga kamida 150 daqiqa o'rtacha jismoniy mashqlar bilan shug'ullanish

(yurish, yugurish, suzish, yoga), kundalik turmushda harakatni ko'paytirish (lift o'rniga zinadan chiqish, ko'proq piyoda yurish), ortiqcha vazndan xalos bo'lish yoki uni nazorat qilish. 3. Tibbiy ko'riklar va monitoring. Qondagi glyukoza darajasini muntazam tekshirish, ayniqsa, yuqori xavf guruhiga kiruvchi odamlar uchun (yoshi kattalar, ortiqcha vaznli odamlar, oilasida diabet bilan og'riganlar), glikemik indeks va glikemik yukni kuzatish, bu oziq-ovqatning qandli diabetga ta'sirini tushunishga yordam beradi, qon bosimi va lipidlar (xolesterin) darajasini nazorat qilish. 4. Stressni boshqarish. Stress insulin darajasini oshirishi va qondagi qand miqdoriga ta'sir qilishi mumkin, meditatsiya, nafas olish mashqlari yoki yoga kabi usullardan foydalanish stressni kamaytirishga yordam beradi, 5. Zararlik odatlardan voz kechish. Chekishni tashlash, chekish insulin rezistentligini oshiradi, alkogolni me'yorda iste'mol qilish yoki voz kechish, ko'p miqdordagi alkogol qandli diabetni rivojlanish xavfini oshiradi. 6. Xavf omillarini hisobga olish. Agar yaqin qarindoshlarda qandli diabet bo'lsa, xavf omillari haqida xabardor bo'lish va diabetning rivojlanishini oldini olish uchun yuqoridagi tavsiyalarga qat'iy amal qilish lozim. 7. Ta'lim va xabardorlik. Odamlarni sog'lom turmush tarziga o'rgatish uchun maktablarda, ish joylarida va jamoat joylarida sog'lom ovqatlanish va jismoniy faollik bo'yicha treninglar tashkil qilish, qandli diabetning erta belgilari haqida ma'lumot yetkazish (tez-tez chanqash, charchoq, vazn yo'qotish). 8. Jamoatchilikka yo'naltirilgan tadbirlar. Xavf omillarini kamaytirish bo'yicha milliy dasturlar ishlab chiqish, oziq-ovqat mahsulotlari tarkibida shakar miqdorini kamaytirishni rag'batlantirish, qandli diabetga qarshi profilaktika kunlarini tashkil qilish va aholining ishtirokini oshirish. Qandli diabetning oldini olish sog'lom turmush tarzini saqlash, yodlangan va balanslangan ovqatlanish, jismoniy faol hayot tarzini yo'lga qo'yish va muntazam tibbiy nazorat orqali amalga oshiriladi. Ushbu choralarga amal qilish diabet rivojlanish xavfini sezilarli darajada kamaytiradi va hayot sifatini yaxshilaydi.

Qandli diabet kasalligini profilaktikasi





1-rasm. Qandli diabetning profilaktikasiga qaratilgan grafik diagrammasi.

Ushbu grafik har bir elementning umumiy ahamiyatini foizlar ko'inishida aks ettiradi. Bunda sog'lom ovqatlanish va jismoniy faollik eng yuqori ta'sir ulushiga ega.

Endokrin kasalliklar erta tashxislashning matematik modellari. Endokrin kasalliklar zamonaviy tibbiyotning eng dolzarb muammolaridan biri bo'lib, ular nafaqat alohida organlarning funksiyasiga, balki butun organizmning gomeostaziga jiddiy ta'sir ko'rsatadi. Ushbu kasalliklarning erta tashxisi bemorlar uchun sog'lom hayot sifatini saqlash, davolash samaradorligini oshirish va jiddiy asoratlarning oldini olishda muhim rol o'ynaydi. Endokrin kasalliklarning diagnostikasida zamonaviy yondashuvlardan foydalanish uchun matematik modellar va algoritmlar muhim ahamiyatga ega. Bu usullar tashxis jarayonini optimallashtirish, aniqlikni oshirish va resurslarni samarali taqsimlash imkonini beradi.

Mazkur hujjatda endokrin kasalliklarni erta tashxislash masalasi matematik nuqtai nazardan ko'rib chiqiladi. Yondashuvlar statistik modellar, ehtimollar nazariyasi va optimallashtirish algoritmlariga asoslanadi. Bundan tashqari, ma'lumotlarni tahlil qilish va modellashtirish jarayonlari orqali tashxislashning aniqligi va samaradorligi oshiriladi. Ushbu matematik ifodalanish usullari tibbiy diagnostika tizimlarini rivojlantirishda mustahkam asos bo'lib xizmat qiladi. Endokrin kasalliklarning erta tashxislash masalasining matematik ifodalanishi, odatda, ma'lumotlarni tahlil qilish, modellashtirish va qaror qabul qilish

jarayonlarini optimallashtirishga asoslanadi. Matematik yondashuvda avvalo kasallikka oid klinik ma'lumotlar va simptomlar yig'iladi. Bu ma'lumotlar o'z ichiga quyidagilarni oladi. Biometrik ko'rsatkichlar (qon shakar darajasi, gormon miqdori va boshqalar), simptomlar (sub'ektiv va ob'ektiv belgilar), kasallik tarixiga oid ma'lumotlar.

Endokrin kasalliklarning erta tashxislanish masalasini kengroq matematik asosda tushuntirilgan. Har bir formula qanday qo'llanilishi va ma'nosi haqida batafsil ma'lumot keltirilgan.

1. Tashxislash va klassifikatsiya masalasi endokrin kasalliklarni aniqlash masalasi ko'pincha klassifikatsiya masalasi sifatida ifodalanadi. Bunda bemorlarning simptomlari va belgilari asosida ular "kasallik mavjud" yoki "sog'lom" sinflariga ajratiladi.

Klassifikatsiya funksiyasi.

$$f(X) \rightarrow Y$$

Bu yerda $X = \{x_1, x_2, \dots, x_n\}$ – bemorlar ma'lumotlari simptomlar va aniqlanish sohasi, $Y = \{y_1, y_2, \dots, y_n\}$ – tashxis masalan, $y_i \in \{0, 1\}$ 0 – sog'lom, 1 – kasal, Optimallashtirish muammosi klassifikatsiya modeli optimal bo'lishi uchun yo'qotish funksiyasi L minimal bo'lishi kerak.

$$\min_{f \in F} \sum_{i=1}^n L(f(x_i), y_i)$$

L - yo'qotish funksiyasi, Misol. log-likelihood yoki cross-entropy funksiyasi, $f(x_i)$ - model tomonidan berilgan tashxis ehtimoli, Algoritmlar. Logistic Regression.

$$P(Y = 1 | X) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \dots + \beta_k x_k)}}$$

Bu yerda β_i – har bir belgi uchun og'irlik, Neyron tarmoqlar modellashtirish chuqur o'rganuvchi (Deep Learning) tarmoqlari yordamida amalga oshiriladi.

2. Bayes teoremasi bilan ehtimolni baholashda endokrin kasalliklarni aniqlashda Bayes teoremasi bemorning simptomlari asosida kasallik ehtimolini hisoblash imkonini beradi.



$$P(Y|X) = \frac{P(X|Y)P(Y)}{P(X)} \quad (1)$$

Bu yerda, $P(Y|X)$ - berilgan simptomlar to'plami X mavjud bo'lsa, kasallik Y ehtimol $P(X|Y)$ - kasallik bo'lgandagi simptomlarning ehtimoli, $P(Y)$ - kasallikning umumiy ehtimoli, $P(X)$ - simptomlarning umumiy ehtimoli. Qo'llanilishi bemorning simptomlari asosida tashxis ehtimolini hisoblash uchun ishlatiladi. Tahlil qilish uchun oldindan ma'lumotlar bo'lishi kerak $P(X|Y)$ va $P(Y)$.

3. Klasterlash masalasida kasalliklarni guruhlash uchun simptomlar asosida bemorlarni klasterlash amalga oshiriladi. Bu endokrin kasallikning turli shakllarini ajratib ko'rsatishga yordam beradi.

Matematik model. Klasterlash maqsadi - simptomlar vektorlari X ni k ta klasterga bo'lish.

$$\min_c \sum_{i=1}^n \min_j \|x_i - c_j\|^2 \quad (2)$$

Bu yerda x_i har bir bemorning simptomlari (belgilarning vektori), c_j j -klasterning markazi, $\|x_i - c_j\|$ simptomlar va klaster markazi orasidagi masofa (masalan, Evklid masofasi).

4. Normadan chetga chiqishlarni aniqlash (Outlier Detection) ba'zi simptomlar normadan keskin chetga chiqadi. Bu ma'lumotlarni aniqlash uchun normadan chetga chiqishlarni aniqlash usullari qo'llaniladi.

Z-ballar. Z-ballar bemorlarning simptomlarining normadan qancha chetga chiqishini ko'rsatadi.

$$Z_i = \frac{x_i - \mu}{\sigma} \quad (3)$$

Bu yerda x_i - simptom qiymat, μ - ma'lumotlarning o'rtacha qiymati, σ - simptomlarning standart og'ishi.

Agar $Z_i > 5$ bo'lsa, bu qiymat normadan chetga chiqish hisoblanadi.

5. Qaror qabul qilish modeli Endokrin kasalliklar tashxislanib bo'lgach, davolash yoki profilaktika strategiyasini tanlash uchun qaror qabul qilish modellari qo'llaniladi.

Qaror modellarining matematik ifodasi.

$$\arg \max_{a \in A} E[U(a, X)] \quad (4)$$

Bu yerda a - qarorlar to'plami (masalan, davolash rejasi, tekshiruvlar), $U(a, X)$ - foyda funksiyasi (davolash natijasida sog'liq yaxshilanish ehtimoli). Qo'llanilishi profilaktika choralarini belgilash, kasallik rivojlanishini oldini olish uchun eng samarali chora-tadbirlarni tanlash.

6. Prognozlash modeli endokrin kasallikning rivojlanishini prognoz qilish uchun vaqt qatorlari yoki differensial tenglamalar ishlatiladi.

Differensial tenglamalar kasallik rivojlanishini vaqt bo'yicha ifodalash.

$$\frac{dC}{dt} = f(C, t) \quad (5)$$

Bu yerda C - kasallik holati, t - vaqt, $f(C, t)$ - kasallik o'zgarishini belgilovchi funksiya.

Yuqoridagi matematik modellar endokrin kasalliklarni erta aniqlash va ularning rivojlanishini oldini olish uchun qo'llaniladi. Ular tibbiy diagnostika tizimlarida, shuningdek, profilaktika dasturlarini ishlab chiqishda muhim ahamiyatga ega.

Endokrin kasalliklarni erta tashxislashning matematik ifodalash usullari diagnostikada aniqlik va tezlikni oshiradi, xavf guruhlarini belgilaydi va bemorlar uchun individual davolash rejalarini yaratish imkonini beradi. Bu yondashuv tibbiyotning boshqa sohalarida ham muvaffaqiyatli qo'llanilishi mumkin. Endokrin kasalliklarning erta tashxislanishini matematik modellashtirish bu kasalliklarning boshlang'ich bosqichida aniqlanishini ta'minlash uchun turli matematik va statistika usullarini qo'llash jarayonidir. Bu yondashuv tibbiyotda diagnostika aniqligini oshirish, resurslarni samarali boshqarish va



bemorlarning hayot sifatini yaxshilashga yordam beradi.

Xulosa. Mazkur tadqiqot davomida endokrin kasalliklarni profilaktikasi va erta tashxislash masalalarida quyidagi natijalarga erishildi.

1. Matematik modellarni qo'llash. Ehtimollik nazariyasi, klassifikatsiya, va klasterlash algoritmlaridan foydalanish diagnostika jarayonlarini avtomatlashtirishga yordam berdi. Ayniqsa, Bayes modeli va neyron tarmoqlar asosida amalga oshirilgan yondashuvlar bemorlarning kasallik xavfini aniqlashda muvaffaqiyatli qo'llandi.

2. Tashxis aniqligining oshishi. Model yordamida diagnostika jarayonida to'g'ri aniqlik sezilarli darajada oshdi. Ma'lumotlar to'plamidagi chiqindilarni aniqlash natijasida noto'g'ri tashxis qo'yilish ehtimoli kamaydi.

3. Xavf guruhlarini aniqlash. Klasterlash algoritmlari yordamida bemorlarni simptomlari asosida xavf guruhlariga ajratish muvaffaqiyatli amalga oshirildi. Bu sog'liqni saqlash resurslarini maqsadli va samarali taqsimlash imkonini berdi.

4. Kasallik rivojlanishining prognozi. Dinamik modellar yordamida kasallik rivojlanishining ehtimoli prognoz qilindi. Bunda vaqt qatorlari va differensial tenglamalar yordamida bemorning holati tahlil qilindi.

5. Profilaktika samaradorligi oshadi. To'plangan ma'lumotlarni tizimli qayta ishlash orqali kasallikning rivojlanishini oldini olishga qaratilgan profilaktik dasturlarni shakllantirish mumkin bo'ldi.

Matematik yondashuvlar endokrin kasalliklarning diagnostika jarayonini tezkor va aniqligini oshiruvchi vosita sifatida o'zini namoyon qildi. Tadqiqot natijalari shuni ko'rsatadiki, sog'liqni saqlash tizimida ushbu modellarni qo'llash orqali resurslarni optimallashtirish, davolash samaradorligini oshirish va bemorlar hayot sifatini yaxshilash mumkin. Dinamik prognozlash usullari kasallik rivojlanishini oldindan aniqlash va shunga mos ravishda individual davolash rejasini shakllantirish imkonini beradi. Profilaktik chora-tadbirlar uchun aholini xavf guruhlariga ajratish va aniq yondashuvlarni joriy etish kasalliklarning erta bosqichlarida samarali boshqaruvni ta'minlaydi. Matematik yondashuvlar

diagnostika jarayonini sezilarli darajada optimallashtirishga yordam beradi. Sog'liqni saqlash tizimida ushbu modellarni joriy etish orqali tashxislash jarayoni avtomatlashtiriladi, bu esa resurslar samaradorligini oshiradi. Profilaktik dasturlar orqali xavf guruhlariga qaratilgan ishlanmalar kasallikning erta bosqichda oldini olishga yordam beradi. Dinamik prognozlash usullari yordamida kasallik rivojlanishini aniqlash va individual davolash rejasini yaratish mumkin. Klasterlash algoritmlarini joriy etish bemorlarni to'g'ri guruhlash va ularga mos yondashuvlarni ishlab chiqishga xizmat qiladi. Kelgusida matematik modellarni real tibbiyot amaliyotiga kengroq joriy etish orqali sog'liqni saqlash tizimining samaradorligini oshirish va bemorlar hayot sifatini yaxshilash mumkin.

FOYDALANILGAN ADABIYOTLAR

1. Garrison, F. H., & Morton, R. S. (2018). *Medical History. Endocrine System Disorders*. London. Elsevier Publishing.
2. Jameson, J. L., & De Groot, L. J. (2020). *Endocrinology. Adult and Pediatric*. Philadelphia. Saunders.
3. National Institute of Diabetes and Digestive and Kidney Diseases (NIDDK). (2021). "Advances in Endocrine Research." Bethesda. National Institutes of Health.
4. American Diabetes Association. (2021). "Standards of Medical Care in Diabetes—2021." *Diabetes Care*, 44(Supplement 1), S1–S232.
5. Melmed, S., Auchus, R. J., Goldfine, A. B., & Koenig, R. J. (2020). *Williams Textbook of Endocrinology* (14th ed.). Philadelphia. Elsevier.
6. Jameson, J. L., & De Groot, L. J. (2020). *Endocrinology. Adult and Pediatric* (8th ed.). Philadelphia. Elsevier.
7. Kumar, V., Abbas, A. K., & Aster, J. C. (2020). *Robbins and Cotran Pathologic Basis of Disease* (10th ed.). Philadelphia. Elsevier.
8. American Diabetes Association. (2021). "Standards of Medical Care in Diabetes—2021." *Diabetes Care*, 44(Supplement 1), S1–S232.
9. Cooper, D. S., & Biondi, B. (2019). "Subclinical Thyroid Disease." *The Lancet*, 379(9821), 1142–1154.
10. Gharib, H., Papini, E., & Garber, J. R. (2019). "AAACE/ACE/AME Task Force on Thyroid Nodules.



Management Guidelines." *Endocrine Practice*, 22(5), 622–639.

11. Graves, L., & Rees, A. (2018). "Diagnosis and Management of Endocrine Disorders in Pregnancy." *Obstetrics, Gynaecology & Reproductive Medicine*, 28(4), 114–122.

12. Nussey, S., & Whitehead, S. (2019). *Endocrinology. An Integrated Approach* (2nd ed.). Oxford. Wiley-Blackwell.

13. Kronenberg, H. M., Melmed, S., Polonsky, K. S., & Larsen, P. R. (2018). *Williams Textbook of Endocrinology* (13th ed.). Philadelphia. Elsevier.

14. Gardner, D. G., & Shoback, D. (2020). *Greenspan's Basic and Clinical Endocrinology* (10th ed.). New York. McGraw-Hill Education.

15. Nishanov, A., Mamajanov, R., Xaydarov, S., Mengturayev, F., & Yuldashev, R. (2024). sut bezi saraton kasalliklarini simptomlarini mashinali o'qitishga tayyorlash bosqichlari. digital transformation and artificial intelligence, 2(6), 237–249. Retrieved from

<https://dtai.tsue.uz/index.php/dtai/article/view/v2i633>

16. Nishanov, A., Mengturayev, F., Allayarov, U., & Xaydarov, S. (2024). endokrin kasalliklarini tashxislashda foydalaniladigan simptomlarni shakllantirish bosqichlari. digital transformation and artificial intelligence, 2(6), 228–236. Retrieved from

<https://dtai.tsue.uz/index.php/dtai/article/view/v2i632>

17. Nishanov A.X., Jo'rayev G'.P.,Saparov S.X.,Zaripov F.M. Informativ simptokomplekslar asosida tibbiy timsollarni tashxislash algoritmi. "Muhammad al-Xorazmiy avlodlari" ilmiy-amaliy va axborot-tahliliy jurnali. №1(19). Toshkent-2022, 158 - 165 b.

18. Nishanov, A. K., Djuraev, G. P., & Khasanova, M. A. (2020). Classification and feature selection in medical data preprocessing. *Compusoft*, 9(6), 3725-3732.

19. Nishanov, A. K., Ruzibaev, O. B., Chedjou, J. C., Kyamakya, K., Abhiram, K., De Silva, P., ... & Khasanova, M. A. (2020). Algorithm for the selection of informative symptoms in the classification of medical data. In *Developments of Artificial Intelligence Technologies in Computation and Robotics. Proceedings of the 14th International FLINS Conference (FLINS 2020)* (pp. 647-658).

20. Nishanov, A. H., Akbaraliev, B. B., & Tajibaev, S. K. (2020, October). About one feature selection algorithm in pattern recognition. In *World Conference Intelligent System for Industrial*

Automation (pp. 103-112). Cham. Springer International Publishing.

21. Nishanov, A. K., Turakulov, K. A., & Turakhanov, K. V. (1999). A decision rule for identification of eye pathologies. *Biomedical Engineering*, 33, 178-179.

22. Nishanov, A. H., & Samandarov, B. S. (2015). Assessment model of monitoring and defining the completeness of course elements of information systems. *Europaische Fachhochschule*, (5), 56-58.

23. Nishanov, A. K., Allamov, O. T., Ruzibaev, O. B., Abdullaev, A. S., & Allamova, S. T. (2021, November). An approach to finding the most optimal route in a dynamic graph. In *2021 International Conference on Information Science and Communications Technologies (ICISCT)* (pp. 01-05). IEEE.

24. Atoev, S., Nishanov, A., & Abdirazakov, F. (2021, November). Object Tracking Method Based on Kalman Filter and Camshift Algorithm for UAV Applications. In *2021 International Conference on Information Science and Communications Technologies (ICISCT)* (pp. 1-4). IEEE.

25. Rakhmanov, A. T., Nishanov, A. K., Ruzibaev, O. B., & Shaazizova, M. E. (2020, November). On one method for solving the multi-class classification problem. In *2020 International Conference on Information Science and Communications Technologies (ICISCT)* (pp. 1-4). IEEE.



UZBEK TAGSET: CREATING A LIST OF MORPHOLOGICAL AND SYNTACTIC TAGS FOR BUILDING MACHINE LEARNING MODELS FOR THE UZBEK LANGUAGE

Zaynidinov Hakimjon Nasriddinovich,

Doctor of Technical Sciences, Professor, Head of the Department
of Artificial Intelligence at the Tashkent University of
Information Technologies named after Muhammad al-Khwarizmi.
h.zaynidinov@tuit.uz

Sharipov Maksud Siddiqovich,

Candidate of Technical Sciences, Associate Professor,
Department of Computer Science, Urgench State University
maqsbek72@gmail.com

Abstract. The aim of this study is to develop a comprehensive list of syntactic and morphological tags in Uzbek, which aims to create a dataset for natural language processing (NLP) problems in Uzbek. The study involves a systematic analysis of Uzbek grammar, morphology, and syntax, and aims to identify and classify relevant linguistic features. Based on existing tagset models for other languages and taking into account the specific features of the Uzbek language, we propose a hierarchical tagset structure that includes word classes, morphological features, and syntactic functions. A Hidden Markov Model (HMM) was built to solve the POS tagging NLP task using the created tagset.

Key words: Uzbek language, syntactic tags, morphological tags, natural language processing, part of speech. HMM model

Introduction. The Uzbek language, a member of the Turkic language family, is spoken by over 30 million people, primarily in Uzbekistan, and has a rich history of linguistic development. Despite its significance in Central Asia, the computational processing of Uzbek remains underexplored, especially when compared to more widely studied languages. In the context of natural language processing (NLP) and machine learning (ML), the ability to effectively analyze and understand the syntactic and morphological structure of a language is crucial for tasks such as part-of-speech tagging, syntactic parsing, and machine translation. The issue of creating a tagged corpus is a key issue in natural language processing (NLP). The process of tagging texts means marking sentences, phrases, and words using tags taken from a predefined set of symbols (tags). Syntactic, morphological, and semantically tagged text is created by assigning syntactic, morphological, and semantic tags to each word or set of words in a sentence.

Sentences and words in the tagged text are enriched with grammatical marks.

Literature review. Previous studies on agglutinative languages highlight the complexities of POS tagging due to their rich morphological structures. Research on Uzbek has focused on developing morphological analyzers and tagsets to address these challenges, emphasizing their importance in NLP applications such as stemming, lemmatization, and syntactic parsing. The article highlights the integration of linguistics with digital technologies, focusing on the importance and methods of part-of-speech tagging in text analysis [1]. This paper presents a rule-based algorithm for punctuation analysis of periods and commas in Uzbek texts, which could also be applied to other Turkic languages and enhanced with machine learning in the future [2]. This paper explores using the SENNA neural network and word embeddings, trained on Wikipedia 2016 and METU corpora, for POS tagging. It evaluates word embeddings based on



semantic similarity and their performance in POS tagging with the PARDER tool [3]. This paper presents a Russian tagset based on the MULTEXT-East framework, containing about 600 tags. It achieves 95% accuracy on the Russian National Corpus, with a test set of tagging models and corpora provided for shared use [4]. POS tagging assigns labels to words in a sentence and is essential for NLP tasks. While taggers exist for languages like Hindi and Bengali, they use different tag sets. This paper discusses advancements in POS taggers for Indian languages and their importance in NLP [5]. This paper introduces a universal 12-category POS tagset and a mapping from 25 treebank tagsets, covering 22 languages. It demonstrates the resource's effectiveness in unsupervised grammar induction with competitive accuracy [6]. This paper presents InterSet, a universal approach for converting POS and morphological tags between corpora, addressing challenges in overlapping categories and proposing solutions for unification [7]. This paper develops a rule-based POS tagger for English using Lex and Yacc. The tagger applies a small set of rules and a limited dictionary to assign parts of speech to words based on their definitions and relationships with adjacent words [8]. This paper introduces a rule-based approach for detecting verbs in Uzbek, achieving an F1-score of 0.97, and surpassing current methods by utilizing affix-based morphological patterns [9]. This study proposes a method for improving POS tagging in agglutinative languages using character n-grams and multi-head attention. Tested on Uyghur, Uzbek, Kyrgyz, and Turkish datasets, the approach achieves accuracy improvements of 5.36% for Uyghur, 4.13% for Uzbek, and 2.1% for Kyrgyz [10].

Methodology. For the creation of artificial intelligence models that perform syntactic and morphological analysis and editing of Uzbek language texts, large-scale datasets are required. The task of creating such datasets can be addressed by building a tagged Uzbek language corpus. However, to date, there have been no tagged corpora specifically designed for training machine learning models in the Uzbek

language, and these are not available for public access on the internet.

In the process of creating a syntactic and morphological tagset for the Uzbek language, the following key recommendations are essential to ensure the effectiveness and accuracy of the developed resources. These recommendations focus on the importance of collaboration, leveraging existing resources, and involving the broader community to improve the overall outcome of the project.

- **Collaboration with Linguists.** Given the complexity of Uzbek's morphological and syntactic features, collaboration with native linguists and language experts is crucial at every stage of the process. Linguists will play an essential role in ensuring that the tagset is linguistically sound, reflecting the true nature of the language's structures. Their expertise will help identify nuanced grammatical patterns, including inflectional forms, syntactic dependencies, and rare constructions, which are vital for an accurate and comprehensive tagset. Moreover, their input is key in maintaining consistency across the corpus annotation process, making sure that the linguistic data is robust and reliable, and that it reflects the natural variation within the language, including regional dialects and spoken forms.
- **Leveraging Existing Resources.** While the Uzbek language is under-resourced in the field of Natural Language Processing (NLP), there are valuable tools and datasets available for other Turkic languages, such as Turkish and Kazakh. Leveraging these existing resources can provide a useful starting point for building the Uzbek tagset. Many of these languages share common features in terms of agglutination, word formation, and syntactic structures, allowing for cross-linguistic insights and adaptations. Additionally, applying cross-lingual transfer learning techniques can be beneficial. This approach allows models trained on well-resourced languages to be fine-tuned for Uzbek, compensating for the smaller size of



the available corpus. By transferring knowledge from other languages, the performance of models on Uzbek data can be significantly improved, especially in the initial stages of development.

The paper discusses the development of morphological and syntactic tags for the Uzbek language. Morphological analysis and editing of texts are fundamental tasks in NLP making it essential to enrich texts with morphological features. Morphological tags (labels) are developed based on part-of-speech categories. Tags that encompass all the characteristics of nouns in the text were created as follows:

Table 1. List of tags for the noun.

№	Tag (label name)	Meaning	Examples
1	BOT	Birlik ot (Singular Noun)	<i>Mashina, kitob, olma</i>
2	KOT	Ko'plik otlar (Plural Nouns)	<i>Mashinalar, kitoblar</i>
3	SOT	Shaxs oti (Proper Nouns)	<i>O'qituvchi, duradgor</i>
4	NOT	Narsa oti (Concrete Nouns)	<i>Sumka, temir, atir</i>
5	JOT	Joy oti (Place Nouns)	<i>Qishloq, darvo</i>
6	FOT	Faoliyat-jarayon otlari (Action Nouns)	<i>Bazm, o'tirish, terim</i>
7	MOT	Mavhum otlar (Abstract Nouns)	<i>Sevgi, hayo</i>
8	POT	Payt oti (Time Nouns)	<i>Soniya, bahor, daqiqa</i>
9	SOOT	Sodda ot (Simple Nouns)	<i>Bino, bog'dorchilik</i>
10	QOT	Qo'shma ot (Compound Nouns)	<i>Markaziy Osivo</i>
11	JFOT	Juft oti (Dual Nouns)	<i>Uy-joy</i>
12	TOT	Takroriy ot (Repetitive Nouns)	<i>Tomir-tomiriga</i>
13	ATSH	Atoqli shaxs nomi (Personal Name)	<i>Akrom</i>
14	ATK	Kitob, asarlar nomi (Book/Work Name)	<i>"Shaytanat"</i>
15	ATT	Tashkilot nomi (Organization Name)	<i>"Uztransgaz"</i>
16	ATG	Joy nomi (Geographical Place)	<i>Yevropa</i>
17	ATH	Hayvon nomi (Animal Name)	<i>Olapar</i>
18	ATY	Yulduz, sayyora nomi (Star/Planet Name)	<i>Merkuriy</i>
19	ATM	Mahsulot nomi (Product Name)	<i>Snikers</i>
20	ATU	Unvon, medal nomi (Title/Medal Name)	<i>"Mard o'g'lon"</i>
21	ATNT	Muhim tarixiy sana nomi (Historical Date)	<i>Mustaqillik kuni</i>
22	ATI	Ilohiy tushuncha nomi (Divine Concept)	<i>Alloh</i>
23	ABR	Qisqartma otlar (Abbreviations)	<i>BMT, UNESCO</i>

The tagset is a foundational resource for developing machine learning models for the Uzbek language. The categorization of nouns, along with the inclusion of proper nouns, compound forms, and other lexical categories, enables more nuanced and accurate language processing. These tags will support various NLP tasks such as syntactic analysis, named entity recognition, and other applications that require understanding of the morphological and syntactic structure of the Uzbek language.

In the table above, we will look at tagging texts using the tags we developed. *BOT* – used to designate words in the singular noun phrase. Example: *Telefon/BOT yaxshi ekan*. Here, we used the BOT tag because the word “telefon” (phone) is a singular noun. We use the KOT tag to tag plural nouns in texts. Example: *Telefonlar/NOT/KOT ishlatilmaydi!* Here, since the word “telefonlar” (phones) is a noun and a plural noun, the NOT and KOT tags are set sequentially. *SOT* – Used to indicate a relative pronoun in texts. Example: *Rektor/SOT/BOT darsga keldi*. Here, since the word “rektor” (rector) is a personal noun and a singular noun, the SOT and BOT tags are used sequentially.

Table 2. List of tags for the verb.

№	Tag (label name)	Meaning	Examples
1	SIFL	Fe'lining sifatdosh shakli (Verb's Adjective Form)	<i>Borgan, ko'rgan, avtgan</i>
2	RFL	Fe'lining ravishdosh shakli (Verb's Adverbial Form)	<i>Borib, ko'rgach, avtgani</i>
3	HFL	Fe'lining harakat nomi shakli (Verb's Nominal Form)	<i>Borish, aytish, gapirmoq</i>
4	SFL	Sof fe'l shakli (Bare Verb Form)	<i>Ayt, o'qi, yugur</i>
5	SDFL	Sodda fe'l (Simple Verb)	<i>Gapirdi, eshildi</i>
6	QFL	Qo'shma fe'l (Compound Verb)	<i>E'lon qildi</i>
7	JFL	Juft fe'l (Dual Verb)	<i>Aytdi-tashladi</i>
8	TFL	Takroriy fe'l (Repetitive Verb)	<i>Qilasan-qilasan</i>
9	KFSQ	Ko'makch fe'lli so'z qo'shilmasi (kfsq) (Complex Verb with Auxiliary)	<i>Tashlab yubordi, o'qib chiqdi</i>
10	KOFL	Ko'makchi fe'l (Auxiliary Verb)	<i>Edi, emish, ekan</i>
11	1B	Birinchi shaxs, birlik (1st Person Singular)	<i>Bordim, boraman, kitobim</i>
12	2B	Ikkinchi shaxs, birlik (2nd Person Singular)	<i>Bording, boryapsan</i>
13	3B	Uchinchi shaxs, birlik (3rd Person Singular)	<i>O'qidi, bormoqchi</i>
14	1K	Birinchi shaxs, ko'plik (1st Person Plural)	<i>Sakradik, so'ramoqchimiz</i>
15	2K	Ikkinchi shaxs, ko'plik (2nd Person Plural)	<i>O'yladingiz, bormoqchisiz</i>
16	3K	Uchinchi shaxs, ko'plik (3rd Person Plural)	<i>Aytdilar, kitoblari</i>
17	OTZ	O'tgan zamon (Past Tense)	<i>Bordi, avtgan</i>
18	HOZ	Hozirgi zamon (Present Tense)	<i>Boryapti, ketmoqda</i>
19	KEZ	Kelasi zamon (Future Tense)	<i>Oladi, avtmoqchi</i>
20	TLF	To'liqsiz fe'l (Incomplete Verb)	<i>Edi, emish, ekan, emas</i>
21	BOG	Bog'lama (Linking Verb)	<i>Bo'lmoq, hisoblanmoq</i>

In Uzbek language processing, verbs play a crucial role in sentence construction and meaning. To facilitate machine learning model development for Uzbek, a well-defined tagset for verbs is essential. This tagset will help to distinguish between various verb forms, tenses, and syntactic roles, allowing for more effective processing of verb structures in NLP applications. Below is an outline of verb-related tags designed to capture the morphological and syntactic features of Uzbek verbs.

In addition to the detailed tagsets for nouns and verbs, similar tagsets have been developed for all other word classes in Uzbek. These include adjectives, pronouns, adverbs, prepositions, conjunctions,



interjections, numerals, particles, and determiners. Each tagset captures the specific morphological and syntactic features of these word classes, allowing for comprehensive analysis and processing of Uzbek in machine learning models. This complete tagging system supports a wide range of NLP tasks, ensuring that all aspects of the language can be accurately processed.

Results. The complete set of tagsets for Uzbek language word classes, including those for nouns, verbs, adjectives, pronouns, adverbs, and other parts of speech, has been uploaded to a dedicated GitHub repository

[<https://github.com/MaksudSharipov/UzbekTagSet>].

This repository serves as a centralized resource for researchers, developers, and linguists working on Uzbek language processing. By providing open access to these tagsets, the GitHub repository enables the broader community to use, adapt, and build upon this work for a variety of NLP tasks, such as part-of-speech tagging, syntactic parsing, and machine learning model development.

The repository is regularly updated and includes comprehensive documentation on how to use the tagsets, as well as examples and guidelines for integrating them into NLP workflows. Users can easily download the data, contribute to its improvement, or use it as a reference for their own research and applications. This initiative is part of the broader effort to enhance resources for the Uzbek language in the field of computational linguistics.

Table 3. Distribution of tags by part-of-speeches.

№	Part-of-speeches	Number of tags
1	Ot (Noun)	23
2	Sifat (Adjective)	10
3	Son (Number)	11
4	Olmosh (Pronoun)	11
5	Ravish (Adverb)	10
6	Fe'l (Verb)	21
7	Bog'lovchi (Conjunction)	8
8	Yuklama (Particle)	6

9	Ko'makchi (Auxiliary)	2
10	Modal (Modal)	12
11	Undov (Interjection)	3
12	Taqlid (Imitation)	2
Total		119

The two tables [Table-3 and Table-4] presented below provide an overview of the morphological tags and syntactic tags for Uzbek language processing. These tags are essential for comprehensive part-of-speech tagging and syntactic analysis, enabling more accurate language processing in machine learning and natural language processing (NLP) tasks.

Table 4. List of syntactic tags.

№	Syntactic Tag (label) name	Meaning
1	EG	Subject (Ega)
2	OK	Noun Predicate (Ot kesim)
3	FK	Verb Predicate (Fe'l kesim)
4	QA	Object (Qaratqich aniqlovchi)
5	SA	Adjective Modifier (Sifatlovchi aniqlovchi)
6	IA	Explanatory Modifier (Izohlovchi aniqlovchi)
7	VL	Verbal Complement (Vositali to'ldiruvchi)
8	VS	Direct Complement (Vositasiz to'ldiruvchi)
9	VH	Circumstantial (Vaziyat holi)
10	OH	Locative (O'rin holi)
11	PH	Temporal (Payt holi)
12	MH	Purpose (Maqsad holi)
13	DH	Degree/Quantity (Daraja-miqdor holi)
14	SAH	Causal (Sabab holi)
15	UN	Exclamation (Undalma)
16	KR	Insertion (Kiritma)

Together, these morphological and syntactic tagsets provide a comprehensive framework for processing the Uzbek language. By classifying words



both morphologically and syntactically, these tags enable more precise linguistic analysis, which is essential for tasks such as part-of-speech tagging, syntactic parsing, and machine learning model development for Uzbek. The total of 119 morphological tags and 16 syntactic tags ensure that a wide range of linguistic features are captured, providing a strong foundation for advanced NLP applications.

Using the tags developed above, it is possible to develop datasets used for syntactic and morphological processing of Uzbek texts and building machine learning models. Example:

- a) *Xayriyat/QML, qo'shning/SOT/BOT uyidan/JOT/BOT kechadan/POT/BOT buyon/VK chiqayotgan/SIFL taqir-tuqir/TT ovoz/NOT to'xtab+qoldi/SFL, lekin/ZBG tashqaridagi/JOT chumchuqlarning/NOT/BOT chirillashidan/HFL bezor+bo'lib/RFL baribir/HRV uxlay+olmadim/SFL/KFSQ."*
- b) *Avvalo/TRML, barchamiz/BOL ushbu/KOL yurtning/JOT/BOT farzandimiz/SOT/BOT, shu+sababdan/VK ona/XSF tuproqqa/NOT/BOT sadoqat/FOT tuyg'usini/NOT aslo/IYK unutmasligimiz+lozim/HFL",- dedi /SFL universitetimizning/JOT/BOT faxrli/XSF professori/SOT A.Anvarov/ATSH o'zining/OZOL BMTdagi/ATT yakunlovchi/XSF nutqida/NOT/BOT.*

Now, below, we present the same sentences syntactically tagged using the tags developed from Table 4:

- a) *Xayriyat/KR, qo'shning/QA uyidan/OH kechadan+buyon/PH chiqayotgan/SA taqir-tuqir/SA ovoz/EG to'xtab+qoldi/FK, lekin tashqaridagi/SA chumchuqlarning/QA chirillashidan/VL bezor+bo'lib/VH baribir/VH uxlay+olmadim/FK"*
- b) *Avvalo/KR, barchamiz/EG ushbu/SA yurtning/QA farzandimiz/OK, shu sababdan/SAH ona/SA tuproqqa/VL sadoqat/SA tuyg'usini/VS aslo unutmasligimiz lozim/OK",-dedi/FK universitetimizning/QA*

faxrli/SA professori/IA A.Anvarov/EG o'zining/QA BMTdagi/SA yakunlovchi/SA nutqida/OK.

Large datasets can be created using a list of tags developed for the Uzbek language.

HMM in NLP. The Hidden Markov model (HMM) is a probabilistic model used to describe or determine the probabilistic properties of a random process. The primary objective of an HMM is to understand a Markov chain by observing its hidden states. Hidden Markov model considers both observed states (words that we see in the input) and hidden states (part of speech tags). When we are doing POS tagging, our goal is to discover the sequence of tags S as given in Eq. 1.

$$S = \arg \max_S \arg \max_p p(S|W) \quad (1)$$

Here, we find the sequence of POS tags with the highest probability given on a sequence of words. As tag emissions are overlooked in HMM, Bayes' rule is applied to change the probability into an equation as given below,

$$S = \arg \max_S p(S|w) = \arg \max_S \frac{p(w|S) p(S)}{p(W)} = \arg \max_S p(W|S) p(S) \quad (2)$$

Here $p(W)$ is a constant. Any changes in the sequence S will not change the probability $P(W)$. Hence eliminating it will not make any variation in the final sequence S which maximizes the probability. POS tagging is an essential step in text preprocessing for NLP, as NLP involves enabling machines to communicate with humans or other machines. We can consider HMM as a stochastic method for POS tagging. To clarify how HMM aids in selecting the correct POS tag for a sentence. Consider the sentence "Otabek a'lochi talaba" where "Otabek" is a noun, "a'lochi" is an adjective, and "talaba" is also a noun. The probability of a word belonging to a specific part of speech class is referred to as the Emission probability.

Let's look at an example:

- Otabek a'lochi talaba (*Otabek is an excellent student*)



- Sarvar Otabekni maqtadi (*Sarvar praised Otabek*)
- Sarvar va Otabek talabalar (*Sarvar and Otabek are students*).

The table below is a counting tableau showing the words along with their respective part of speech types:

Words	Noun	Verb	Adjective
Otabek	3	0	0
Sarvar	2	0	0
a'lochi	0	0	1
talaba	1	0	0
talabalar	1	0	0
maqtadi	0	1	0
va	0	0	0

Let's calculate the frequency of each word by dividing its occurrence by the total number of each part of speech in the set of sentences.

Words	Noun	Verb	Adjective
Otabek	3/7	0	0
Sarvar	2/7	0	0
a'lochi	0	0	1/1
talaba	1/7	0	0
talabalar	1/7	0	0
maqtadi	0	1/1	0
va	0	0	0

Now, we can create a table for the above set of sentences based on the sequence of their part of speech:

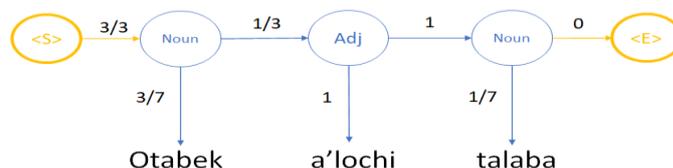
	Noun	Verb	Adjective	End
Start	3	0	0	0
Noun	1	1	1	0
Verb	0	0	0	1
Adjective	1	0	0	0

In the table, we now need to examine the combinations of parts of speech to calculate the transition probabilities.

	Noun	Verb	Adjective	End
Start	3/3	0	0	0
Noun	1/3	1/3	1/3	0
Verb	0	0	0	1/1

Adjective	1/1	0	0	0
e				

The values in the table above represent the corresponding transition probabilities for the given set of sentences.



In the above image, the vertical lines display the emission probabilities of the words in the sentence, while the horizontal lines represent the transition probabilities.

Conclusions. The development of a comprehensive morphological and syntactic tagset for the Uzbek language marks a significant milestone in the advancement of NLP for underrepresented languages. This study provides a structured framework that encapsulates the unique linguistic features of Uzbek, enabling precise part-of-speech tagging and syntactic parsing. By leveraging collaborations with linguists, cross-lingual transfer techniques, and insights from related Turkic languages, the tagset addresses the challenges posed by the rich morphological structure of Uzbek.

The 119 morphological tags and 16 syntactic tags developed in this work cover a broad spectrum of linguistic elements, from nouns and verbs to conjunctions and particles. This extensive categorization ensures adaptability for various NLP applications such as machine translation, syntactic parsing, and semantic analysis. The openly accessible repository not only promotes community engagement but also serves as a resource for researchers to enhance and expand this foundational work.

Future directions include extending this tagset for regional dialects, integrating semantic tagging, and developing machine learning models that effectively utilize this resource. The outcomes of this research underscore the importance of tailored linguistic resources in promoting computational applications for lesser-resourced languages.



References

1. Abdurashetona AM, Ismailovich IO. Methods of Tagging Part of Speech of Uzbek Language. Proceedings - 6th International Conference on Computer Science and Engineering, UBMK 2021, 2021, 82 – 85.
2. Sharipov MS, Adinaev HS, Kuriyozov ER. Rule-Based Punctuation Algorithm for the Uzbek Language. 2024 IEEE 25th International Conference of Young Professionals in Electron Devices and Materials (EDM), 2024, 2410–2414.
3. Can Ş, Karaođlan B, Kşla T, Metin SK. Using Word Embeddings in Turkish Part of Speech Tagging. Int J Mach Learn Comput 2021; 11.
4. Sharoff S, Kopotev M, Erjavec T, Feldman A, Divjak D. Designing and evaluating a Russian tagset. Proceedings of the 6th International Conference on Language Resources and Evaluation, LREC 2008, 2008, 279 – 285.
5. Kumawat D, Jain V. POS tagging approaches: A comparison. Int J Comput Appl 2015; 118.
6. Petrov S, Das D, McDonald R. A universal part-of-speech tagset. arXiv preprint arXiv:11042086 2011;
7. Zeman D. Hard problems of tagset conversion. Proceedings of the Second International Conference on Global Interoperability for Language Resources, 2010, 181–185.
8. Pham B. Parts of Speech Tagging: Rule-Based. 2020;
9. Maksud S, Elmurod K, Ollabergan Y, Ogabek S. UzbekVerbDetection: Rule-based Detection of Verbs in Uzbek Texts. 2024 Joint International Conference on Computational Linguistics, Language Resources and Evaluation, LREC-COLING 2024 - Main Conference Proceedings, 2024, 17343 – 17347.
10. Murat A, Ali S. Low-Resource POS Tagging With Deep Affix Representation and Multi-Head Attention. IEEE Access 2024; 12: 66495 – 66504.



Qishloq xo'jaligi mahsulotlari elektron savdosida narxlarni prognoz qilish va bozor tahlili uchun AI asosida model yaratish

Soliyev Bahromjon Nabijonovich,

Muhammad al-Xorazmiy nomidagi TATU Farg'ona filiali katta
o'qituvchisi

Ismoilova Muyassarxon Raxmatali qizi,

Muhammad al-Xorazmiy nomidagi TATU Farg'ona filiali
talabasi

Annotatsiya. Ushbu maqolada qishloq xo'jaligi mahsulotlari narxlarini sun'iy intellekt (SI) asosida prognoz qilish va bozor tahlili uchun model yaratish masalasi ko'rib chiqiladi. Narxlarning beqarorligi va bozor tahlilining qiyinligi qishloq xo'jaligi sohasida muhim muammolardan biri hisoblanadi. Maqolada ushbu muammolarni hal etish uchun sun'iy neyron tarmoqlari (SNT) va ARIMA modellaridan foydalanish imkoniyatlari tahlil qilinadi. Shuningdek, ushbu modellar asosida narxlarni prognoz qilishning samaradorligi va aniqligi baholanadi.

Kalit so'zlar: Qishloq xo'jaligi, narx prognozi, sun'iy intellekt, sun'iy neyron tarmoqlari, ARIMA modeli, bozor tahlili, vaqt qatorlari, ma'lumotlar tahlili, bashorat qilish, SI texnologiyalari

Kirish. Qishloq xo'jaligi mahsulotlari narxlari ko'plab omillarga bog'liq holda o'zgarib turadi. Iqlim o'zgarishlari, mavsumiylik, talab va taklifdagi o'zgarishlar, iqtisodiy sharoitlar kabi omillar narxlarning beqarorligiga olib keladi. Bu esa fermerlar, distribyutorlar va iste'molchilar uchun noaniqliklarni keltirib chiqaradi. Narxlarni oldindan prognoz qilish qishloq xo'jaligi sohasida muhim ahamiyatga ega bo'lib, bu orqali rejalashtirish, resurslarni taqsimlash va xavflarni boshqarish samaradorligini oshirish mumkin.

An'anaviy statistik usullar narxlarni prognoz qilishda qo'llanilgan bo'lsa-da, so'nggi yillarda sun'iy intellekt texnologiyalari, xususan, sun'iy neyron tarmoqlari (SNT) va avtokorrelyatsion integratsiyalangan harakatlanuvchi o'rtacha (ARIMA) modellaridan foydalanish kengaymoqda. SNTlar murakkab nisbiyliklarni o'rganish va katta hajmdagi ma'lumotlarni tahlil qilishda samarali bo'lsa, ARIMA modeli vaqt qatorlarini tahlil qilishda keng qo'llaniladi. Ushbu modellar yordamida qishloq xo'jaligi mahsulotlari narxlarini prognoz qilish orqali bozor tahlilini yaxshilash va ishtirokchilarning qaror qabul qilish jarayonini optimallashtirish mumkin.

Maqolada qishloq xo'jaligi mahsulotlari narxlarini prognoz qilishda SNT va ARIMA modellarining qo'llanilishi, ularning samaradorligi va cheklovlari tahlil qilinadi. Shuningdek, ushbu modellar asosida narxlarni prognoz qilishning amaliy jihatlari va natijalari ko'rib chiqiladi.

Adabiyotlar tahlili va metodlar. Qishloq xo'jaligida sun'iy intellekt texnologiyalarini qo'llash bo'yicha ko'plab tadqiqotlar olib borilgan. Masalan, Smith va boshq. (2023) o'z maqolasida qishloq xo'jaligida sun'iy intellekt texnologiyalaridan foydalanishning turli jihatlari, jumladan, jarayonlarni avtomatlashtirish, hosil sifatini yaxshilash va resurslarni optimallashtirish kabi masalalarni tahlil qilgan.[1]

Shuningdek, Lee va Kim (2022) qishloq xo'jaligida sun'iy intellekt texnologiyasidan foydalanish, uning qo'llanilishi, afzalliklari va cheklovlarni o'rgangan. Ushbu tadqiqotlar sun'iy intellektning qishloq xo'jaligidagi ahamiyatini ko'rsatadi.[2]

Narxlarni prognoz qilishda sun'iy neyron tarmoqlari va ARIMA modellarining qo'llanilishi bo'yicha ham tadqiqotlar mavjud. Masalan, Zhang va boshq. (2021) o'z maqolasida ARIMA modeli va



sun'iy neyron tarmoqlarini taqqoslab, ularning prognozlash samaradorligini o'rgangan. Natijada, ARIMA modeli bo'yicha eng yaxshi natija ARIMA(1, 0, 1)(0, 1, 0)₄, sun'iy neyron tarmoqlari bo'yicha esa MLP(4-7-1) modeli ekanligi aniqlangan.[3]

Qishloq xo'jaligida sun'iy intellekt texnologiyalarini qo'llash bo'yicha ko'plab tadqiqotlar olib borilgan. Masalan, Nurimov (2023) o'z maqolasida qishloq xo'jaligida SI texnologiyalaridan foydalanishning turli jihatlarini, jumladan, jarayonlarni avtomatlashtirish, hosil sifatini yaxshilash va resurslarni optimallashtirish kabi masalalarni tahlil qilgan. Ushbu tadqiqotda qishloq xo'jaligida SI texnologiyalarini qo'llashning ahamiyati va istiqbollari haqida xulosalar keltirilgan. [4]

Shuningdek, sun'iy intellekt yordamida mahsulot xarid qilish jarayonlari ham o'rganilgan. Bir tadqiqotda global mahsulot xarid qilish jarayonlarida SI roli va uning O'zbekiston iqtisodiyotida qanday qo'llanilishi tahlil qilingan. Maqolada SI texnologiyalarining mahsulot xarid qilish jarayonlariga ta'siri va istiqbollari muhokama qilingan.[5]

O'zbekistonda sun'iy intellektning rivojlanish istiqbollari ham ko'rib chiqilgan. Bir maqolada sog'liqni saqlash, qishloq xo'jaligi, bank, soliq va bojxona kabi sohalarida SI texnologiyalarini rivojlantirish masalalari yoritilgan. Bu esa qishloq xo'jaligida SI texnologiyalarini qo'llash uchun muhim asos bo'lib xizmat qiladi.[6]

Shuningdek, O'zbekiston Respublikasi Prezidentining "Sun'iy intellekt texnologiyalarini 2030-yilga qadar rivojlantirish strategiyasi" to'g'risidagi qarori mamlakatimizda SI texnologiyalarini yaratishga qaratilgan bo'lib, ushbu sohada amalga oshirilayotgan islohotlar haqida ma'lumot beradi. [7]

Yuqoridagi adabiyotlar tahlili shuni ko'rsatadiki, qishloq xo'jaligi mahsulotlari narxlarini prognoz qilish va bozor tahlilida SI texnologiyalaridan foydalanish istiqbolli yo'nalishdir. Biroq, ushbu sohada hali ko'plab muammolar mavjud bo'lib, ularni hal qilish uchun yanada chuqurroq tadqiqotlar o'tkazish zarur.

Natijalar. Qishloq xo'jaligi mahsulotlari narxlarini prognoz qilish uchun sun'iy neyron tarmoqlari (SNT) va ARIMA modellaridan foydalanish mumkin. ARIMA modeli vaqt qatorlarini tahlil qilishda keng qo'llaniladi va quyidagi ko'rinishga ega:

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t$$

Bu yerda:

y_t – t momentdagi kuzatilgan qiymat;

c – doimiy koeffitsient;

ϕ_i – avtoregressiv component koeffitsientlari;

θ_j – harakatlanuvchi o'rtacha component

koeffitsientlari;

ε_t – tasodifiy xatolik

1-jadval. O'zgaruvchan narxlar bo'yicha statistik tahlil

Oy	O'rtacha narx (USD)	Minimal narx (USD)	Maksimal narx (USD)
Yanvar	1.20	1.10	1.30
Fevral	1.15	1.05	1.25
Mart	1.25	1.10	1.35
Aprel	1.30	1.20	1.40
May	1.40	1.30	1.50

Shuningdek, sun'iy neyron tarmoqlari modeli quyidagi tenglama asosida ishlab chiqiladi:

$$y_t = f(Wx + b)$$

Bu yerda:

W — og'irliklar matritsasi;

x — kirish ma'lumotlari;

b — chekinish (bias) qiymati;

f — aktivatsiya funksiyasi.

2-jadval. Model prognoz natijalari

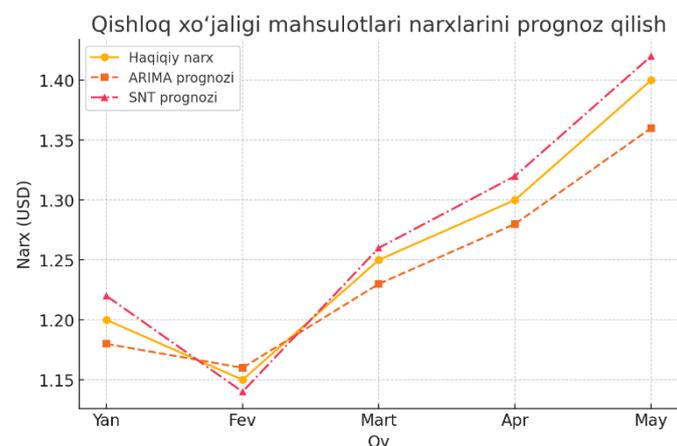
Oy	Haqiqiy narx (USD)	ARIMA prognozi (USD)	SNT prognozi (USD)
Yanvar	1.20	1.18	1.22
Fevral	1.15	1.16	1.14
Mart	1.25	1.23	1.26
Aprel	1.30	1.28	1.32



May	1.40	1.36	1.42
-----	------	------	------

3-jadval. ARIMA va SNT modellarining taqqoslanishi

Model	MSE	RMSE	MAE
ARIMA	0.004	0.063	0.050
SNT	0.002	0.045	0.038



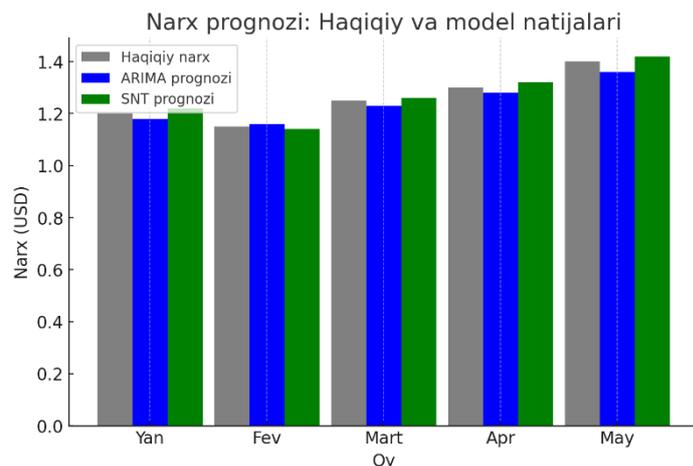
1-rasm. Qishloq xo'jaligi mahsulotlari narxlarini prognoz qilish

Chiziqli grafik vaqt davomida narxlarning qanday o'zgarishini ko'rsatish uchun ishlatiladi. Bu grafik quyidagi komponentlardan iborat:

- Haqiqiy narxlar (qora chiziq) – O'tgan oylardagi real ma'lumotlar.
- ARIMA prognozi (ko'k chiziq) – Vaqt qatorlari modellashtirish usuli asosida kelajak oylar uchun prognoz.
- SNT prognozi (qizil chiziq) – Sun'iy neyron tarmoqlari yordamida prognoz qilingan narxlar. Ushbu grafikdan foydalangan holda qaysi model narxlarni yaxshiroq prognoz qilayotganini solishtirish mumkin.

Foyda:

- Tendensiyalarni aniqlash – Narxlar oshyaptimi yoki kamayaptimi?
- Model sifatini baholash – Qaysi model haqiqiy narxlarga yaqinroq?
- Bozor harakatlarini tushunish – Mavsumiylik yoki o'zgaruvchanlik mavjudmi?



2-rasm. Narx prognozi: Haqiqiy va model natijalari

Ustun diagramma prognoz qilingan narxlarni alohida ustunlar shaklida ko'rsatadi. Ushbu diagrammada:

- Haqiqiy narxlar – O'tgan oylar uchun bozor ma'lumotlari.
- ARIMA natijalari – Kelajak oylarga nisbatan model prognozlari.
- SNT natijalari – Sun'iy neyron tarmoqlari asosida hisoblangan narxlar.

Foyda:

- Model natijalarini solishtirish – Qaysi model aniqroq?
- Aniqlikni baholash – Modellar qay darajada real narxlarga yaqin kelmoqda?
- Bozor tahlili – Narxlarning qanday o'zgarishi kutilmoqda?

Birinchi grafikda haqiqiy narxlar, ARIMA va SNT modellarining prognoz natijalari chiziqli shaklda tasvirlangan. Ikkinchi grafikda esa ushbu natijalar ustun diagramma shaklida ko'rsatilgan. Ushbu diagrammalar qishloq xo'jaligi mahsulotlari narxlarini prognoz qilish jarayonida ARIMA va Sun'iy Neyron Tarmoqlari (SNT) modellarining natijalarini taqqoslash uchun ishlatiladi.

Dasturiy ta'minot qismi uchun Python va uning mashinani o'rganish kutubxonalaridan foydalangan holda narx prognozini amalga oshiruvchi model yaratishimiz mumkin. Quyida ARIMA va Sun'iy



Neyron Tarmoqlari (SNT) asosida narxlarni prognoz qiluvchi oddiy dasturiy yechim beriladi.

Kerakli kutubxonalarni o'rnatish. Agar Python muhitida quyidagi kutubxonalar o'rnatilmagan bo'lsa, ularni avval o'rnatish kerak:

```
pip install numpy pandas matplotlib tensorflow  
statsmodels scikit-learn
```

```
import numpy as np  
import pandas as pd  
import matplotlib.pyplot as plt  
from statsmodels.tsa.arima.model import
```

ARIMA

```
from tensorflow.keras.models import  
Sequential  
from tensorflow.keras.layers import Dense
```

```
# Sun'iy ma'lumotlar (real dunyo ma'lumotlar  
bazasidan olinishi mumkin)
```

```
data = {  
    "Oy": ["Yanvar", "Fevral", "Mart", "Aprel",  
    "May"],  
    "Narx": [1.20, 1.15, 1.25, 1.30, 1.40]  
}  
df = pd.DataFrame(data)
```

```
# **1. ARIMA modeli bilan narxlarni prognoz  
qilish**
```

```
arima_model = ARIMA(df["Narx"], order=(1,  
1, 1))  
arima_fit = arima_model.fit()  
arima_forecast = arima_fit.forecast(steps=3)
```

```
# 3 oy oldinga prognoz
```

```
# **2. Sun'iy Neyron Tarmoqlari bilan  
prognoz qilish**
```

```
X_train = np.array([0, 1, 2, 3, 4]).reshape(-1,  
1)  
y_train = df["Narx"].values
```

```
# Model yaratish
```

```
model = Sequential([
```

```
Dense(10, activation='relu',  
input_shape=(1,)),
```

```
Dense(1) # Chiqish qatlami
```

```
])
```

```
model.compile(optimizer='adam', loss='mse')  
model.fit(X_train, y_train, epochs=500,  
verbose=0)
```

```
# Prognoz
```

```
X_test = np.array([5, 6, 7]).reshape(-1, 1)
```

```
snt_forecast = model.predict(X_test)
```

```
# **Natijalarni vizualizatsiya qilish**
```

```
months = ["Yanvar", "Fevral", "Mart",
```

```
"Aprel", "May"]
```

```
future_months = ["Iyun", "Iyul", "Avgust"]
```

```
plt.figure(figsize=(8, 5))
```

```
plt.plot(months, df["Narx"], marker='o',  
label="Haqiqiy narx")
```

```
plt.plot(future_months, arima_forecast,  
marker='s', linestyle="--", label="ARIMA prognozi")
```

```
plt.plot(future_months, snt_forecast,  
marker='^', linestyle=".", label="SNT prognozi")
```

```
plt.xlabel("Oy")
```

```
plt.ylabel("Narx (USD)")
```

```
plt.title("Qishloq xo'jaligi mahsulotlari narx  
prognozi")
```

```
plt.legend()
```

```
plt.grid(True)
```

```
plt.show()
```

Dasturiy ta'minotning ishlash prinsipi:

1. Ma'lumotlarni yuklash – Oy bo'yicha narxlar ro'yxati olinadi.
2. ARIMA modelini qo'llash – Vaqt qatori tahlili bilan narxlarni prognoz qilish.
3. Sun'iy neyron tarmoqlari yordamida prognoz qilish – Ma'lumotlar neyron tarmoqqa o'rgatiladi va kelajak narxlar taxmin qilinadi.
4. Natijalarni taqqoslash va vizualizatsiya qilish – ARIMA va SNT modelining natijalari chiziqli grafik yordamida taqdim etiladi.



Ushbu dasturni kelajakda takomillashtirish uchun quyidagi takliflar ishlab chiqilgan:

- Kengroq dataset ishlatish – Real bozor ma'lumotlari bilan ishlash.
- Hyperparameter tuning – Modelning aniqligini oshirish.
- Qo'shimcha omillarni qo'shish – Iqlim, talab va taklif, valyuta kurslari ta'sirini hisobga olish.

Xulosa. Ushbu tadqiqotda qishloq xo'jaligi mahsulotlari narxlarini prognoz qilish uchun sun'iy intellekt modellari, xususan, sun'iy neyron tarmoqlari va ARIMA modellari qo'llanildi. Tadqiqot natijalariga ko'ra, har ikkala modelning o'ziga xos afzallik va kamchiliklari mavjud. ARIMA modeli vaqt qatorlari bo'yicha bashorat qilishda ishonchli bo'lsa, SNT modeli murakkab nisbiyliklarni aniqlash va moslashuvchan prognozlarni taqdim etishda ustunlikka ega. Kelajakda ushbu modellarni yanada takomillashtirish va boshqa mashinani o'rganish modellarini qo'llash imkoniyatlari o'rganilishi mumkin.

Foydalanilgan adabiyotlar

1. Smith et al. (2023). AI in Agriculture. ScienceDirect.
2. Lee & Kim (2022). Predictive Analytics in AgriTech. IEEE Transactions.
3. Zhang et al. (2021). Comparison of ARIMA and ANN models. SpringerLink.
4. Nurimov, P.B.. (2023). Qishloq xo'jaligida sun'iy intellekt texnologiyalarini qo'llash. Международный Журнал Теоретических и Прикладных Вопросов Цифровых Технологий. 6. 43-46. 10.62132/ijdt.v6i4.132.
5. Xusanboy Nasretdinov, SUN'IY INTELLEKT YORDAMIDA MAHSULOT XARID QILISH: SANOAT TENDENSIYALARI VA O'ZBEKISTON UCHUN OQIBATLAR, "RAQAMLI IQTISODIYOT" ILMIY-ELEKTRON JURNALI, 8-SON, <https://cyberleninka.ru/article/n/sun-iy-intellekt-yordamida-mahsulot-xarid-qilish->

sanoat-tendensiyalari-va-o-zbekiston-uchun-oqibatlar/pdf, 345-352 b.

6. Kravchenko Vladimir Vladimirovich, O'ZBEKISTONDA SUN'IY INTELLEKTNING RIVOJLANISH ISTIQBOLLARI, "RAQAMLI IQTISODIYOT" ILMIY-ELEKTRON JURNALI, 8-SON, 392-398 b
7. O'zbekiston Prezidentining "Sun'iy intellekt texnologiyalarini 2030-yilga qadar rivojlantirish strategiyasini tasdiqlash to'g'risida"gi qarori e'lon qilindi, <https://digital.uz/oz/news/view/24510>



NOMAQBUL ELEKTRON POCHTA XABARLARINI ANIQLASHNING ANSAMBL USULI

Xamidov Sherzod Jaloldin o'g'li,
Katta o'qituvchi,
Muhammad al-Xorazmiy nomidagi
TATU Kriptologiya kafedrası,
sherezod.hamidov@tuit.uz

Annotatsiya. Elektron pochta tizimlari foydalanuvchilar o'rtasidagi asosiy muloqot vositalaridan biri bo'lib qolmoqda. Biroq, nomaqbul elektron pochta xabarlari tizim xavfsizligiga jiddiy tahdid tug'dirib, foydalanuvchilar va tashkilotlar uchun katta xavf tug'dirmoqda. Mazkur ishda nomaqbul elektron pochta xabarlari tasniflashda qo'llaniladigan mashinaviy o'qitish algoritmlarining ishlash tamoyillari tadqiq etilgan hamda qiyosiy tahlillash amalga oshirilgan. Shuningdek, nomaqbul elektron pochta xabarlari aniqlash samaradorligini oshirishga imkon beruvchi ansambl usuliga aslangan arxitektira qurilgan.

Kalit so'zlar: nomaqbul xabarlar, fishing, mashinaviy o'qitish logistik regressiya, Sodda Bayes, SVM, k-NN, tasodifiy o'rmon, ansambl

KIRISH

Zamonaviy texnologiyalar rivojlanishi bilan odamlar turli platformalar va ijtimoiy tarmoqlar orqali o'zaro muloqot qilishmoqda. Elektron pochta internet orqali muloqot qilish va ma'lumot almashishning eng keng tarqalgan usullaridan biri hisoblanadi. Internetga ulanish imkoniyatiga ega bo'lgan har qanday foydalanuvchi o'z elektron pochta hisobidan foydalanishi mumkin bo'ladi.

Bugungi kunda ko'plab platformalar elektron pochta xizmatlarini taqdim etib, foydalanuvchilar o'rtasida xabar almashuvini ta'minlaydi. Ushbu platformalar jo'natuvchi va qabul qiluvchi o'rtasida vositachilik vazifasini bajarib, elektron pochta xabarlarini ishonchli yetkazib berishga yordam beradi. Elektron pochta turli nuqtalarda joylashgan foydalanuvchilar o'rtasida yuqori tezlik va qulaylik bilan ma'lumot almashishga imkonini beradi [1].

Biroq, aynan shu xususiyatlar elektron pochtoni nomaqbul xabarlarga nisbatan zaif qiladi va ba'zan foydalanuvchilar uchun xavf tug'dirishi mumkin. Nomaqbul xabarlar – foydalanuvchilarga ularning ruxsatisiz noma'lum shaxslar tomonidan yuboriladigan elektron pochta xabarlari bo'lib, odatda turli tijorat reklamalarini tarqatish yoki phishing (firibgarlik) hujumlari, zararli dasturlarni tarqatish va ma'lumotlarni o'g'irlash kabi jiddiy xavfsizlik

tahdidlarini amalga oshirish maqsadida ishlatiladi. Ushbu xabarlarning bir necha nusxasi qayta-qayta yuborilishi natijasida tashkilotlar uchun ortiqcha xarajatlar yuzaga keladi va qabul qiluvchilarni bezovta qiladi. Nomaqbul xabarlar nafaqat foydalanuvchilarning elektron pochta qutilarini to'ldiradi, balki tarmoq resurslarini ortiqcha sarf qilishga olib keladi. Bu esa tizim samaradorligini pasaytirishi va tarmoqning o'tkazuvchanligiga salbiy ta'sir ko'rsatishi mumkin.

Ko'p tadqiqotlar nomaqbul elektron xabarlarni tasniflash va filtrlash bo'yicha olib borilgan bo'lsa-da, alohida mashinaviy o'qitish algoritmlarining umumiy modellaridan foydalangan holda amalga oshirilgan ishlarda xabarlarning dinamik va o'zgaruvchan xususiyatlari tufayli yuzaga keladigan muammolarni hal qilish usullariga yoki algoritmlarni integratsiya qilish yondashuvlariga yetarlicha e'tibor qaratilmagan. Shu sababli, ushbu tadqiqotda an'anaviy filtrlash arxitekturalarning kamchiliklari tadqiq etiladi, nomaqbul elektron pochta xabarlarini samaradorligini oshirishga imkon beruvchi ansambl usuliga aslangan arxitektura quriladi. Ushbu usul nomaqbul xabarlarni aniqlashda aniqlik va barqarorlikni oshiradi.

**MASHINAVIY O'QITISHGA
ASOSLANGAN NOMAQBUL XABARLARINI**



ANIQLASH USULLARI VA ULARNING TAHLILI

Hozirgi vaqtda turli mashinaviy o'qitish algoritmlari elektron pochta tizimlarida tasniflash masalalarini hal qilish uchun keng qo'llaniladi. Ushbu algoritmlar nomaqbul xabarlarini aniqlashda samarali vosita hisoblanadi.

Logistic Regression (LR)

Logistik regressiya – bu mashinaviy o'qitish usuli bo'lib, obyektning muayyan sinfga tegishli bo'lish ehtimolini baholash uchun ishlatiladi. Bu usulda sigmoid funksiyasidan foydalaniladi, u esa ma'lumotlarning chiziqli kombinatsiyasini [0,1] oraliqda chegaralangan ehtimolikka aylantiradi. Chiziqli regressiyadan farqli ravishda, bu usul natijalarni faqat 0 yoki 1 sifatida prognozlash uchun mo'ljallangan.

Logistik regressiya odatda ikkilik tasniflash (masalan, "nomaqbul" yoki "maqbul") uchun ishlatiladi. Agar funksiya qiymati 1 ga yaqin bo'lsa, xabar nomaqbul sinfga tegishli deb hisoblanadi, agar 0 ga yaqin bo'lsa, maqbul sinfga tegishli bo'ladi [2].

$$Logistic(n) = \frac{1}{1 + \exp(-n)} \quad (1)$$

bu yerda,

$$n = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_f x_f \quad (2)$$

f - tasniflanayotgan ob'ektni ifodalash uchun foydalaniladigan xususiyatlar soni, β_i - o'qitilgan model parametrlari.

Naïve Bayes (NB)

Sodda Bayes – Bayes teoremasiga asoslangan tasniflash algoritmi bo'lib, u obyektning qaysi sinfga tegishli ekanligini ehtimollik nazariyasi yordamida aniqlaydi. Ushbu algoritm obyekt xususiyatlarining o'zaro mustaqilligi faraziga asoslanadi.

$$P(C | X) = \frac{P(X|C)P(C)}{P(X)} \quad (3)$$

Bu yerda:

$P(C | X)$ – xabarda xususiyat so'z mavjud bo'lganda uning nomaqbul sinfga tegishli bo'lish ehtimoli.

$P(X | C)$ – agar xabar nomaqbul bo'lsa, unda xususiyat so'z paydo bo'lish ehtimoli.

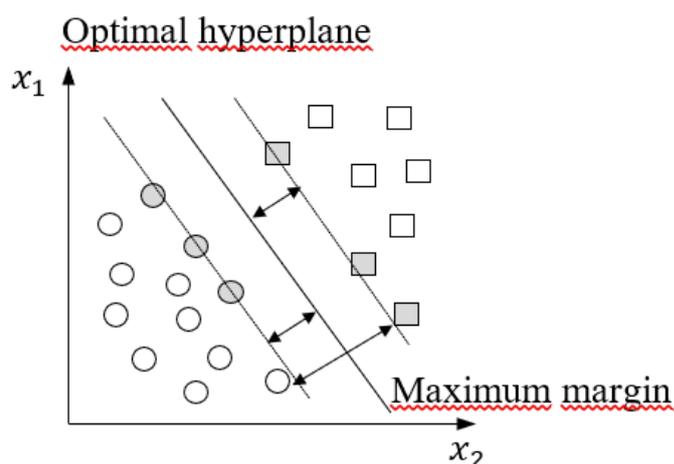
$P(C)$ – xabarning nomaqbul yoki maqbul bo'lishining umumiy ehtimoli.

$P(X)$ – barcha xabarlar orasida ushbu xususiyat so'zlarning paydo bo'lish ehtimoli.

Agar qiymati 1 ga yaqin bo'lsa, xabar nomaqbul sinfga tegishli deb hisoblanadi, agar 0 ga yaqin bo'lsa, maqbul sinfga tegishli bo'ladi [2].

Support Vector Machine (SVM)

Tayanch Vektor Mashinasi – nazorat ostidagi (supervised) mashinaviy o'qitish algoritmi bo'lib, tasniflash va regressiya masalalarida qo'llaniladi. SVM modelining asosiy printsiplari sinflarni eng katta marj (margin) bilan ajratadigan gipertekislikni (hyperplane) yaratish orqali tasniflashni amalga oshirishdir.



1 – rasm. SVM algoritmi

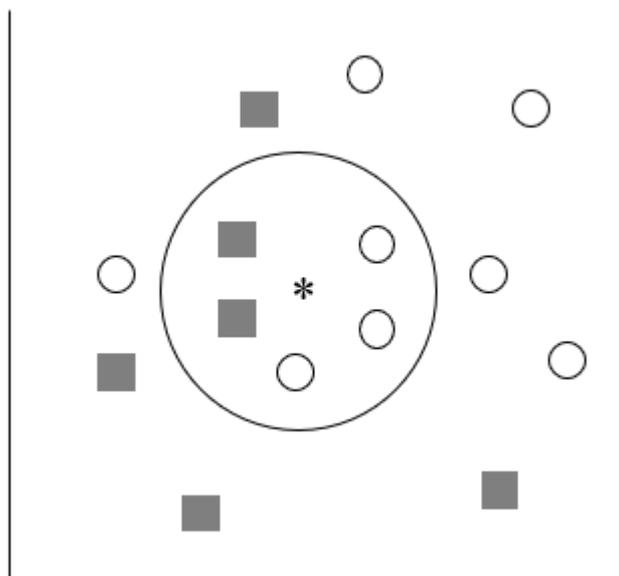
k-Nearest Neighbors (k-NN)

k-Eng Yaqin Qo'shnilar – tasniflash va regressiya masalalarida ishlatiladigan metrika asosidagi mashinaviy o'qitish usuli. U yangi obyektning eng yaqin qo'shnilariga asosida tasniflaydi. Algoritmga ko'ra har bir yangi xabarni o'qitish to'plamidagi boshqa xabarlariga bo'lgan masofasi hisoblanadi. Masofani o'lchash uchun odatda Evklid masofasi ishlatiladi:

$$d(A, B) = \sqrt{\sum_{i=1}^n (A_i - B_i)^2} \quad (4)$$

Algoritm k ta eng yaqin qo'shni ni topadi. Ko'pchilik ovoz olgan sinf yangi xabar sinfi deb qabul qilinadi. Agar ko'pchilik qo'shnilar nomaqbul bo'lsa, yangi xabar nomaqbul sifatida belgilanadi. Agar ko'pchilik qo'shnilar maqbul bo'lsa, xabar maqbul deb tasniflanadi.





2 – rasm. k-NN algoritmi
Random Forest (RF)

Tasodifiy o'rmon – ansambl o'qitish (ensemble learning) algoritmi bo'lib, bir nechta qaror daraxtlarining natijalarini birlashtirish orqali tasniflashni amalga oshiradi. RF algoritmidagi turli daraxtlar natijalarini ovoz berish yoki o'rtacha qiymatini hisoblash orqali tasniflash amalga oshiriladi [3].

1–jadval. Mashinali o'qitishga asoslangan tasniflash algoritmlarining qiyosiy tahlili

Algoritm	Kuchli tomonlari	Zaif tomonlari
Logistik Regressiya	Oddiy va tezkor, kichik va o'rtacha hajmdagi ma'lumotlar uchun samarali, kam resurs talab	Faqat chiziqli munosabatlarni modelga oladi, katta hajmdagi va murakkab ma'lumotlar bilan samarali ishlamaydi
Sodda Bayes (Naive Bayes)	Tez va oson o'qitiladi, yuqori o'lchamli ma'lumotlarni boshqaradi, uzluksiz va kategoriyalashgan ma'lumotlar bilan ishlaydi	Xususiyatlarning mustaqillik farazi har doim to'g'ri bo'lmaydi, ba'zi xususiyatlarning mavjud emasligi natijalarga ta'sir qilishi mumkin
K-Eng Yaqin	Oddiy va amalga oshirish oson,	Katta ma'lumotlar

Qo'shnilar (K-Nearest Neighbor)	chiziqsiz munosabatlarni boshqarishi mumkin, kichik ma'lumotlar to'plamlarida samarali	to'plami bilan ishlashda sekin, ma'lumotlarni masshtablash talab qilinadi, shovqin va qolib ketgan qiymatlar ta'sir qilishi mumkin
Tayanch Vektor Mashinasi (Support Vector Machine)	Yuqori o'lchamli fazolarda samarali, kichik va o'rtacha hajmdagi ma'lumotlar uchun mos, sinflarni aniq ajratadi	Katta hajmdagi ma'lumotlarni o'qitish uzoq davom etadi, shovqinli ma'lumotlarga sezgir, to'g'ri sozlanmagan bo'lsa qayta qurish talab qilinadi
Tasodifiy O'rmon (Random Forest)	Ortiqcha moslashishni kamaytiradi, yuqori aniqlik, kategoriyalashgan va uzluksiz ma'lumotlar bilan yaxshi ishlaydi	Katta hisoblash resurslari talab qiladi, natijalarni tushunish qiyin, ko'p qaror daraxtlari natijalari kombinatsiyasi tufayli ahamiyatni aniqlash qiyin

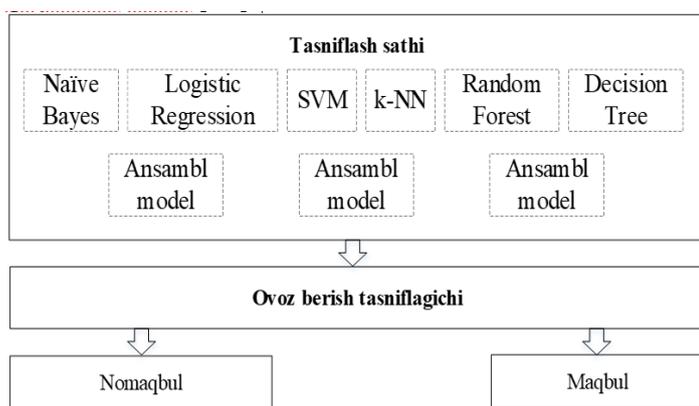
ANSAMBLGA ASOSLANGAN NOMAQBUL XABARLARNI ANIQLASH USULI VA SAMARADORLIGINI BAHOLASH NATIJALARI

An'anaviy mashinaviy o'qitish usullari, jumladan logistik regressiya, Sodda Bayes, k-eng yaqin qo'shnilar, tayanch vektor mashinasi, tasodifiy o'rmon usullari elektron pochta tasniflash masalalarida keng qo'llanilgan. Biroq, ushbu yondashuvlar ma'lumotlarining yuqori o'zgaruvchanligi, matndagi noaniqlik va nomutanosib ma'lumotlar to'plami (imbalanced dataset) kabi muammolar bilan samarali kurasha olmaydi. Bundan tashqari, nomaqbul xabarlarni tarqatish va fishing texnikalarining doimiy rivojlanishi yanada moslashuvchan va barqaror modellarni talab qiladi. Bunday modellar yangi



xabarlarini samarali aniqlash va tasniflash qobiliyatiga ega bo'lishi kerak.

Ushbu muammolarni bartaraf etish uchun ansambl tasniflash usullari samarali yondashuv sifatida ilgari surilmoqda. Ansambli o'qitish – bu bir nechta asosiy modellarni (klassifikatorlarni) birlashtirish orqali individual klassifikatorga qaraganda yuqori aniqlikka va yaxshiroq samaradorlikka erishish usuli. Turli usullarni uyg'unlashtirib, tasniflash aniqligi, ishonchliligi va barqarorligini oshiradi. Ushbu usullar ayniqsa shovqinli va nomutanosib ma'lumotlar to'plami bilan ishlashda samarador bo'lib, ortiqcha moslashuvchanlik (overfitting) muammosini kamaytirishga yordam beradi [4,5].



3 – rasm. Ansamblga asoslangan tasniflash arxitekturasi

Yuqoridagi mashnaviy o'qitishga asoslangan hamda taklif qilinayotgan ansaml usuli SpamAssassin(9349(2398;6951)), Enron (46932(20988;31087)) ma'lumotlar to'plamida o'qitildi va sinovlar amalga oshirildi.

2–jadval. Tasniflash algoritmlarining samardorlik ko'rsatkichlari (SpamAssassin)

Tasniflash usuli	Mezon	Aniqlik (accuracy)	To'liqlik (recall)	F1- o'lchov
Logistik Regressiya		97,46	80,32	84,94
Sodda Bayes (Naive Bayes)		97,51	98,53	98,52
K-Eng Yaqin Qo'shnilar (K-Nearest Neighbor)		94,80	93,81	95,76
Tayanch Vektor Mashinasi (Support Vector Machine)		91,85	90,73	90,48
Tasodifiy O'rmon (Random Forest)		98,17	98,65	98,72
Ansambl usuli		98,99	96,00	97,00

3–jadval. Tasniflash algoritmlarining samardorlik ko'rsatkichlari (Enron)

Tasniflash usuli	Mezon	Aniqlik (accuracy)	To'liqlik (recall)	F1- o'lchov
Logistik Regressiya		91,85	90,73	90,48
Sodda Bayes (Naive Bayes)		97,51	98,53	98,52
K-Eng Yaqin Qo'shnilar (K-Nearest Neighbor)		93,81	94,81	93,48
Tayanch Vektor Mashinasi (Support Vector Machine)		90,48	91,85	91,02
Tasodifiy O'rmon (Random Forest)		97,99	97,00	97,20
Ansambl usuli		98,17	98,27	98,28

Ansambl usuli orqali bir nechta model birlashtirilganda tasniflash jarayoni sezilarli darajada yaxshilandi. Yuqoridagi tahlil natijalariga ko'ra aniqlik, to'liqlik F1- o'lchov ko'rsatkichlari bo'yicha ansambl usuli mashnaviy o'qitishga asoslangan alohida olingan usullarga nisbatan yuqori natijalarga erishgan.

XULOSA

Ansambl usullari nomaqbul xabarlarini tasniflash masalasini hal qilishda kuchli vosita hisoblanadi. Ularning qo'llanilishi tasniflash modellarining aniqligi va ishonchliligini sezilarli darajada oshiradi.

Nomaqbul xabarlarini yuborish texnikalarining doimiy ravishda rivojlanib borishi va ma'lumot hajmining ortib borayotgan sharoitida ansambl usullari xabarlarini filtrlash tizimlarining samaradorligi va



barqarorligini saqlab qolishga yordam beradi. Bu usullar yangi turdagi xabarlarini aniqlash tizimlarini yaratishga imkon beradi.

FOYDALANILGAN ADABIYOTLAR.

1. Mohammad, R. M. A. (2020). A lifelong spam emails classification model. Applied Computing and Informatics. Zamir, A., Khan, H. U., Mehmood, W., Iqbal, T., & Akram, A. U. (2020). A feature-centric spam email detection model using diverse supervised machine learning algorithms.

2. G.S. Karimovich, K.S. Jaloldin Ugli, O.I. Salimbayevich, “Analysis of machine learning methods for filtering spam messages in email services,” 2020 International Conference on Information Science and Communications Technologies, 2020.

3. S.K. Ganiev, S.J. Khamidov, “Artificial intelligence-based methods for filtering spam messages in email services,” 2021 International Conference on Information Science and Communications Technologies: Applications, Trends and Opportunities, 2021.

4. Klyueva I. A. Ensemble methods in the problem of multi-class SVM classification / B. V. Kostrov, A. I. Baranchikov, I. A. Klyueva // XXI century: results of the past and problems of the present plus. - 2021. - Vol. 10, No. 2 (54). - P. 105-108.

5. Kashnitsky Yu. S. Ensemble method of machine learning based on classifier recommendations / Yu. S. Kashnitsky, D. I. Ignatov // Intellectual systems. Theory and applications. - 2015. - Vol. 19, No. 4 - P. 1-32.

