



VATAN
UNIVERSITETI



MANAGEMENT AND FUTURE TECHNOLOGIES

SCIENTIFIC & TECHNICAL JOURNAL

VOLUME

3

ISSUE

2

MONTH

June

YEAR

2026

NUMBER

010



VATAN
UNIVERSITETI



<https://vatanuniversiteti.uz>



ISSN 3060-5008



Jurnal sohalari: dasturiy injiniring, sun'iy intellekt texnologiyalari, kompyuter injiniringi, infokommunikatsiya injiniringi, axborot xavfsizligi, matematika va fizika.

Tahririyat kengashi raisi

g.f.d., prof. Muxammadismoil Maxmudov - Vatan universiteti rektori

Bosh muharrir

i.f.d., prof. Karimjon Axmedjanov - Vatan universiteti Ilmiy ishlar va innovatsiyalar bo'yicha prorektori

Tahririyat kengashi a'zolari:

f.f.d., prof. Asror Muhamedov
t.f.d., prof. O'tkir Xamdamov
t.f.d., prof. Muxammadjon Musayev
t.f.d., prof. Shavkat Fozilov
f-m.f.d., prof. Aripov Mersaid
f-m.f.d., prof. Aloeov Raxmatillo
t.f.d., prof. Marat Raxmatullayev
t.f.d., prof. Dilnoz Muxamediyeva
t.f.d., prof. Jamshid Sultonov
f-m.f.d., prof. Dildora Muhamediyeva
t.f.d., prof. Nargiza Usmanova
t.f.d., dot. Halimjon Xujamatov
t.f.d., dot. Ibragim Atadjanov
t.f.f.d., dot. Muhriddin Muxiddinov
t.f.f.d., dot. Maxina Mansurova
t.f.f.d., dot. Baxtiyor Akmuradov
t.f.f.d., dot. Anvar Musayev
t.f.f.d., dot. Muhriddin Umarov
f-m.f.n., dot. Baxromjon Abduraxmonov
t.f.f.d., dot. Abdulxayev Nodirbek

Muharrirlar:

Shukurullo Kaxarov (O'zbekiston)
Ozod Yusupov (O'zbekiston)
Dilshod Rahmatov (Germaniya)
O.A. Hidayov (Germaniya)
Akmaljon Abdullayev (O'zbekiston)
Jinsoo Cho (J. Koreya)
Jamshid Elov (O'zbekiston)
Fazliddin Maxmudov (J. Koreya)
Faheem Khan (J. Koreya)
Doston Xasanov (O'zbekiston)
Shahnoza Muksimova (J. Koreya)
Elmurod Urinov (O'zbekiston)
Akmalbek Abdusalomov (J. Koreya)
Sherzod Abdullayev (O'zbekiston)
Urmanov Odil (J. Koreya)
Sobir Radjabov (O'zbekiston)
Young Im Cho (J. Koreya)
Mohamed Sameer (J. Koreya)
Alpamis Kutlimuratov (O'zbekiston)
Sabina Umirzakova (J. Koreya)
Farhod Ahmedov (J. Koreya)
Sherzod Mustafaulov (O'zbekiston)
Shabir Ahmad (J. Koreya)
U.B. Amirsaidov (O'zbekiston)
Lilia Tightiz (J. Koreya)
Shahnoza Sultanova (O'zbekiston)
Safiullah Khan (Buyuk Britaniya)
Seytkamal Medetov (Fransiya)
Avaz Qaxxorov (O'zbekiston)
Qosim Bekturodov (O'zbekiston)
Namoz Mirzayev (O'zbekiston)

Jurnal O'zbekiston Respublikasi Prezidenti Administratsiyasi huzuridagi Axborot va ommaviy kommunikatsiyalar agentligidan 212842-raqamli guvohnoma bilan 26.01.2024 sanasida ro'yxatdan o'tkazilgan.



MUNDARIJA

<i>Ш. А. Хабибуллаева</i>	МЕТОДИКА ПРОВЕДЕНИЯ ЗАНЯТИЙ С ИСПОЛЬЗОВАНИЕМ ВОЗМОЖНОСТЕЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В СИСТЕМЕ ВЫСШЕГО ОБРАЗОВАНИЯ	5
<i>M. N. Muxiddinov, J. Sh. Qurbonov</i>	KO'ZI OJIZ INSONLAR UCHUN ATROF-MUHITDAGI XAVF VA TO'SIQLARNI ANIQLASHDA PARALLEL HISOBLASH ORQALI OPTIMALLASHTIRISH	11
<i>B. A. Abduraxmonov</i>	MATEMATIKA FANINI O'QITISHDA SUN'YI INTELLEKTNING O'RN: HOSILA VA INTEGRAL BO'LIMLARINI O'QITISHDA YANGI YONDASHUVLAR	21
<i>N.T Baymatova, M.N Begmurodov, F.SH. Abdullajonov</i>	IP TELEVIDENIYE TARMOQLARIDA MULTIKAST TARMOG'INING ZAMONAVIY TEXNOLOGIYA VA PROTOKOLLARI TAHLILI	24
<i>A. M. Nazarov, N. T. Baymatova, F. K. Jumaqulov, F. T. Rayimov</i>	SENSOR NAZORAT-O'LCHOV MA'LUMOTLARINI MOBIL ALOQA TARMOQLARIDA UZATISHNING ASOSIY XUSUSIYATLARI VA TALABLARI	36
<i>A. M. Nazarov, N. T. Baymatova, F. T. Rayimov, F. K. Jumaqulov.</i>	KATEGORIYALANGAN OB'EKTAR PARAMETRLARI MONITORINGI VA VIZUAL O'LCHASH TEXNOLOGIYALARI TAHLILI	47
<i>H.E.Mamarajabov, D.T.Shukurov, I.I.Shahriyrov, N.T.Allamurodov</i>	TA'LIMDA AI TIZIMLARIDAGI ALGORITMIK BIAS VA SHAXSIY MA'LUMOTLAR XAVFSIZLIGI.	57



MUNDARIJA

<i>A. I. Musayev, O. F. Naziraliyev</i>	MOLIYAVIY VAQT QATORLARINI BASHORATLASHDA LSTM VA GRU MODELLARINING SOLISHTIRMA TAHLILI	64
<i>M.H.Davronov, D.T.Shukurov, J.I.Mamajonov, Y.E.Minamatov</i>	SUN'IY INTELLEKT YORDAMIDA AXBOROT XAVFSIZLIGINI TA'MINLASHNING PEDAGOGIK TAMOYILLARI	70
<i>A.A. Abduvaitov, S.Kh. Nizomov</i>	SUN'IY INTELLEKT ASOSIDA ZAMONAVIY TASHKILOTLARDA XODIMLAR FEEDBACK TIZIMLARINI RIVOJLANTIRISHNING NAZARIY YONDASHUVLARI	75
<i>N. M. Abdulxayev</i>	TELEKOMMUNIKATSIYA TARMOQLARIDA TRAFIKNI PROGNOZLASH UCHUN MASHINAVIY O'QITISH ALGORITMLARINI QO'LLASH	84
<i>S.Sh.Sarmanova</i>	SUN'IY INTELLEKT ASOSIDA TALABALARNING KREATIV VA TANQIDIY FIKRLASHINI RIVOJLANTIRISH TEXNOLOGIYALARI	91
<i>A.N. Xudoyberdiyev</i>	KATEGORIYALANGAN OB'EKT PARAMETRLARI MONITORINGI VA VIZUAL O'LCHASH TEXNOLOGIYALARI TAHLILI	96
<i>A. I. Musayev, O. F. Naziraliyev</i>	MOLIYA BOZORIDA VAQT QATORLARINI TAHLIL QILISHDAGI MUAMMOLARNI YECHISHDA SUN'IY INTELLEKTNI QO'LLASH	103



MUNDARIJA

<i>A.N. Xudoyberdiyev</i>	KVANT KOMPYUTERLARI DAVRIDA SMART-KONTRAKTLAR XAVFSIZLIGI: MUAMMOLAR VA POST-KVANT ALGORITMLARI YECHIMLARI	109
<i>N.A. Naim</i>	PNEVMONIYANI TASHXISLASH AXBOROT TIZIMINING KOGNITIV MODEL	114
<i>A. D. Boboqulov</i>	CHIZIQLI REGRESSIYA VA TASODIFIY O'RMON YORDAMIDA BASHORATLI MA'LUMOTLAR TAHLILI HISOR DAVLAT O'RMON XO'JALIGI HUDUDI BO'YICHA	120





МЕТОДИКА ПРОВЕДЕНИЯ ЗАНЯТИЙ С ИСПОЛЬЗОВАНИЕМ ВОЗМОЖНОСТЕЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В СИСТЕМЕ ВЫСШЕГО ОБРАЗОВАНИЯ

Хабибуллаева Шахло Азаматовна

*Старший преподаватель кафедры «Коммуникации и информационных технологий»
университета «Vatan», shahlo.m.d@gmail.com*

Аннотация. Контекст: Математика является одной из дисциплин с наибольшим числом академических задолженностей в системе высшего образования Узбекистана, что обусловлено неравномерным уровнем школьной подготовки студентов и ограниченностью традиционных форм преподавания. Методы: В настоящей статье предлагается многоуровневая модель MLAIM (Multi-Layer AI Integration Model), объединяющая платформы Google Classroom, ChatGPT-4 и GeoGebra на основе анализа цифровых следов — данных об учебном поведении студентов в цифровой среде. Результаты: Разработана трёхэтапная дорожная карта пилотного внедрения модели в образовательный процесс Университета «Vatan»; модель охватывает четыре уровня: диагностику, формирование адаптивного контента, интерактивные упражнения и мониторинг в режиме реального времени. Заключение: Ожидаемые результаты включают повышение мотивации студентов и рост успеваемости на 10–15 % по сравнению с традиционными методами обучения, что согласуется с международным опытом внедрения ИИ в образование.

Ключевые слова: искусственный интеллект; цифровой след; адаптивное обучение; математическое образование; модель MLAIM; персонализированное обучение; образовательная аналитика; цифровая трансформация.

1. АКТУАЛЬНОСТЬ ПРОБЛЕМЫ.

Математика занимает особое место среди учебных дисциплин высшей школы: по данным внутренней статистики ряда узбекистанских университетов, именно по этому предмету фиксируется наибольшее число академических задолженностей и отчислений среди студентов первого и второго курсов. Причины носят системный характер и связаны с двумя взаимосвязанными факторами.

Первый фактор — неоднородность базовой подготовки. Студенты, поступающие из разных регионов страны, общеобразовательных и специализированных школ, академических лицеев, демонстрируют существенно разный уровень математических знаний. Преподаватель, ориентированный на «среднего» студента, неизбежно оставляет за бортом как отстающих (для которых темп слишком высок), так и хорошо подготовленных (для которых он недостаточен).

Второй фактор — унификация учебного процесса. В рамках традиционной аудиторной модели преподаватель не располагает инструментами для оперативной диагностики индивидуальных затруднений каждого из 25–30 студентов. Ошибки, допущенные при выполнении домашнего задания или на контрольной работе, обнаруживаются с опозданием — когда пропущенная тема уже стала основой для последующих разделов.

Мировая практика демонстрирует убедительные ответы на эти вызовы. По состоянию на 2025 год образовательными платформами на базе ИИ — ChatGPT, Wolfram Alpha, Khan



Academy (Khanmigo), Carnegie Learning MATHia — пользуются сотни миллионов студентов и школьников по всему миру. Классический мета-анализ VanLehn (2011) показал, что интеллектуальные системы-репетиторы обеспечивают прирост учебных результатов, сопоставимый с эффектом индивидуального репетиторства [1]. Блум ещё в 1984 году сформулировал «проблему двух сигм»: студент, занимающийся один на один с репетитором, в среднем опережает студентов традиционного класса на два стандартных отклонения [2]. Сегодня технологии ИИ впервые делают подобную индивидуализацию доступной в масштабах целого потока.

В Узбекистане государственная стратегия «Цифровой Узбекистан — 2030» ставит широкое внедрение цифровых технологий в сферу образования в разряд приоритетных задач [7]. Тем не менее, несмотря на активное оснащение вузов компьютерными классами и внедрение систем дистанционного обучения, целостная дидактическая модель, сочетающая ИИ и анализ цифровых следов студентов применительно к преподаванию математики, в отечественной педагогической науке остаётся недостаточно разработанной. Именно этот пробел определяет актуальность и научную значимость данного исследования.

2. ЦЕЛЬ ИССЛЕДОВАНИЯ И НАУЧНАЯ НОВИЗНА.

Цель исследования — разработка научно обоснованной и практически применимой модели индивидуализированного преподавания математики на основе инструментов ИИ и цифровых следов студентов, а также определение поэтапного пути её внедрения в учебный процесс высшей школы.

Задачи исследования: (1) проанализировать существующие подходы к применению ИИ в математическом образовании; (2) разработать архитектуру четырёхуровневой модели MLAİM; (3) обосновать математическое выражение эффективности модели; (4) сформировать трёхэтапную дорожную карту пилотного внедрения; (5) определить ожидаемые измеримые результаты.

Научная новизна. Впервые для системы высшего образования Узбекистана предложена многоуровневая дидактическая модель MLAİM, комплексно обрабатывающая цифровые следы студента на четырёх взаимосвязанных уровнях. В отличие от ранее описанных подходов [3, 5, 6], модель не ограничивается отдельными инструментами ИИ, а интегрирует их в единый педагогический цикл: диагностика → адаптация → практика → мониторинг. Отличительной чертой является также её адаптированность к институциональным условиям узбекистанского вуза: учитываются языковая среда, аудиторная нагрузка преподавателя и требования действующих образовательных стандартов.

Практическая значимость работы состоит в том, что предложенная модель может быть воспроизведена в любом университете страны, располагающем доступом к Google Classroom и базовыми инструментами ИИ, без значительных финансовых затрат.

3. МАТЕРИАЛЫ И МЕТОДЫ.

Исследование проводилось на базе Университета «Vatan» (ранее УМФТ, Ташкент) в 2024–2025 учебном году. Экспериментальная выборка включала студентов первого курса направлений «Информационные технологии», «Экономика», «Логистика» и «Информационная безопасность», обучающихся по курсу «Высшая математика» (общий



охват — $n = 75$ человек, разделённых на контрольную и экспериментальную группы по 25–40 человек в каждой).

В исследовании применялся комплекс взаимодополняющих методов. Теоретические методы включали системный анализ отечественной и зарубежной литературы по проблемам применения ИИ в образовании [1, 2, 3, 6], а также сравнительный анализ действующих образовательных платформ. Эмпирические методы включали: педагогический эксперимент (доэкспериментальный и постэкспериментальный срезы); анализ цифровых следов студентов средствами встроенной аналитики Google Classroom (время выполнения заданий, процент правильных ответов, частота обращений к материалам); анкетирование студентов о субъективном восприятии учебного процесса. Статистическая обработка предполагала расчёт средних значений, стандартных отклонений и сравнение групп методом t-критерия Стьюдента.

Платформенная основа модели: Google Classroom (управление курсом и сбор данных), ChatGPT-4 (генерация адаптивных объяснений и обратной связи), GeoGebra (динамическая визуализация математических объектов), Wolfram Alpha (верификация решений и пошаговые вычисления). Выбор именно этих инструментов обусловлен их бесплатной доступностью, совместимостью между собой и наличием русско- и узбекскоязычного интерфейса.

4. МОДЕЛЬ MLAIM: ОСНОВНАЯ СТРУКТУРА.

Предлагаемая модель MLAIM (Multi-Layer AI Integration Model) — это педагогическая архитектура, в которой каждый следующий уровень строится на данных, полученных на предыдущем, образуя непрерывный цикл обратной связи между студентом, системой ИИ и преподавателем. Модель состоит из четырёх последовательных уровней.

1-й уровень — Диагностика. В начале каждого занятия или учебного блока алгоритм ИИ формирует для каждого студента персонализированный набор диагностических вопросов. Основой для генерации служат накопленные цифровые следы: типичные ошибки, темы с низким процентом правильных ответов, среднее время ответа на каждый тип задания. Диагностика занимает 5–7 минут и позволяет выявить актуальный уровень готовности студента к новой теме ещё до начала объяснения преподавателя.

2-й уровень — Адаптивный контент. По итогам диагностики система автоматически формирует для каждого студента индивидуальную учебную траекторию (learning path). Студентам с пробелами в базовых темах предлагаются вводные материалы и примеры повышенной детализации; студентам с высокими показателями — задания продвинутого уровня. Так, студенту, не освоившему метод замены переменной при вычислении интегралов, система рекомендует дополнительный видеурок и набор тренировочных задач именно по этой теме, прежде чем перейти к интегрированию по частям.

3-й уровень — Интерактивные упражнения. На этом уровне студент работает с заданиями, интегрированными с Wolfram Alpha и GeoGebra. При допущенной ошибке система не просто сообщает о ней, но предоставляет пошаговый разбор с указанием конкретного шага, на котором произошла ошибка. Сложность заданий повышается адаптивно: студент переходит к следующему уровню трудности лишь после успешного освоения текущего. GeoGebra обеспечивает динамическую визуализацию — студент в



реальном времени наблюдает, как изменяется форма кривой при вариации параметров уравнения, что переводит абстрактные формулы в наглядные образы.

4-й уровень — Мониторинг в реальном времени. Панель мониторинга агрегирует цифровые следы всей группы и представляет их преподавателю в виде наглядных индикаторов: какие темы вызывают наибольшие затруднения, у каких студентов показатели ухудшились за последние два занятия, какова динамика группы в целом. На основе этих данных система формирует рекомендации для планирования следующего занятия: на какие темы следует выделить дополнительное время, кого из студентов стоит задействовать в разборе задачи у доски.

Математическое выражение целевой функции модели (1):

$$E = f(D, A, T) \rightarrow \max, \quad (1)$$

где, E — эффективность обучения (интегральный показатель успеваемости и мотивации); D — вектор цифровых следов студента; A — адаптивные рекомендации ИИ; T — учебное время. Задача системы — при заданном T максимизировать E за счёт оптимальной настройки вектора A на основе D .

5. ПРИМЕР ПРАКТИЧЕСКОГО ПРИМЕНЕНИЯ.

Для иллюстрации работы модели рассмотрим два конкретных сценария, характерных для курса «Высшая математика».

Сценарий 1. Дифференциальное исчисление. Студент первого курса дважды подряд допускает однотипную ошибку при нахождении производной функции $f(x) = x^3 - 3x^2 + 2x$: применяет степенное правило к каждому члену, но при вычислении производной члена $-3x^2$ забывает умножить коэффициент на показатель степени. В традиционной системе эта ошибка, как правило, обнаруживается лишь при проверке домашнего задания — спустя день-два. В системе MLAIM ошибка фиксируется немедленно: студенту предлагается микро-урок «Правило дифференцирования произведения константы и степенной функции» с тремя нарастающими по сложности примерами. Последующие задания специально включают аналогичные члены для закрепления. На панели мониторинга преподаватель в тот же день видит, что данная ошибка характерна для 8 из 25 студентов группы, и планирует краткий разбор на следующем занятии.

Сценарий 2. Визуализация функций. В курсе прикладной математики при совместном использовании GeoGebra и ИИ студенты исследуют семейство прямых $y = kx + b$. Изменяя параметры k и b в интерактивной среде GeoGebra, они в реальном времени наблюдают, как меняются угол наклона и положение прямой на плоскости. ChatGPT-4 отвечает на вопросы студентов на русском и узбекском языках, объясняя геометрический смысл каждого параметра. Такой подход позволяет студентам самостоятельно «открыть» взаимосвязь между алгебраической формулой и её геометрическим образом, что существенно повышает глубину понимания и учебную мотивацию.

Оба сценария демонстрируют ключевое преимущество модели MLAIM: ошибка становится не источником оценки, а точкой входа в адаптивную учебную траекторию. Это меняет само отношение студентов к ошибкам — от избегания к анализу.



6. ПЛАН ВНЕДРЕНИЯ И ОЖИДАЕМЫЕ РЕЗУЛЬТАТЫ.

Внедрение модели MLAİM в учебный процесс Университета «Vatan» предусматривает три последовательных этапа, рассчитанных на общий срок около двух лет.

1-й этап — Подготовительный (1–3 месяца). Техническая настройка: подключение ИИ-приложений (ChatGPT-4 API, GeoGebra, Wolfram Alpha) к учебным курсам в Google Classroom; разработка шаблонов диагностических тестов для каждого раздела курса высшей математики. Организационная подготовка: проведение двухдневных тренингов по цифровой грамотности для преподавателей, участвующих в эксперименте; ознакомительные сессии для студентов. Нормативная база: разработка и утверждение локальной политики конфиденциальности и защиты учебных данных студентов в соответствии с законодательством Республики Узбекистан.

2-й этап — Пилотный (1 семестр). Пилотное внедрение модели MLAİM в двух параллельных группах по дисциплинам «Математический анализ» (раздел «Дифференциальное исчисление функции одной переменной») и «Прикладная математика» (раздел «Линейная алгебра»). Параллельно ведётся контрольная группа, обучающаяся по традиционной методике. Данные Google Classroom Analytic обрабатываются еженедельно; по итогам каждого месяца проводится промежуточная коррекция адаптивных траекторий.

3-й этап — Масштабирование (2–3 семестра). Сравнительный анализ итоговой успеваемости, результатов анкетирования и данных мониторинга в экспериментальной и контрольной группах. При подтверждении гипотезы — тиражирование модели на все курсы математики университета и публикация результатов в рецензируемых изданиях. Параллельно — адаптация модели для использования в общеобразовательных школах в рамках сотрудничества с Министерством народного образования.

Количественные ориентиры ожидаемых результатов основаны на международном опыте. Согласно данным Carnegie Learning MATHia, применение адаптивных ИИ-систем в математике даёт прирост результатов в пределах 10–20 % по сравнению с традиционными группами [1]. Опыт Сингапура и Южной Кореи демонстрирует устойчивый рост мотивации и снижение тревожности перед математикой при систематическом использовании интерактивных цифровых инструментов [6]. Для Узбекистана консервативный ориентир — 10–15-процентное улучшение среднего балла в экспериментальных группах относительно контрольных — представляется достижимым уже по итогам пилотного семестра.

7. ОБСУЖДЕНИЕ.

Теоретические положения настоящего исследования вписываются в широкий международный контекст дискуссии об ИИ в образовании. Ouyang & Jiao [6] выделяют три парадигмы применения ИИ в образовательном процессе: ИИ как инструмент автоматизации (замена рутинных операций), ИИ как персональный тьютор (адаптивное взаимодействие) и ИИ как партнёр по совместному решению задач (коллаборативные сценарии). Модель MLAİM в её нынешнем виде преимущественно реализует первую и вторую парадигмы, закладывая при этом основу для перехода к третьей.

Ключевым теоретическим понятием, на котором строится модель, является цифровой след (digital footprint) студента. Baker & Inventado [3] определяют образовательный дата-майнинг как дисциплину, изучающую методы автоматического обнаружения



закономерностей в больших объёмах данных, собираемых в образовательных контекстах. Специфика нашего подхода состоит в том, что цифровые следы используются не ретроспективно (для оценки пройденного пути), а проспективно — как основа для формирования следующего шага учебной траектории студента.

Практический опыт отечественных коллег также свидетельствует в пользу предложенного подхода. Abduraxmonov & Xabibullayeva [4] показали, что интегративный подход к преподаванию высшей математики, связывающий содержание курса с профессиональными задачами студентов конкретного направления, значительно повышает учебную мотивацию. Модель MLAIM органично дополняет этот подход, добавляя технологический слой персонализации. Xoliqov & Raximov [5] также указывают на необходимость не просто насыщать учебный процесс цифровыми инструментами, но выстраивать их в педагогически обоснованную систему — именно это и является целью настоящей работы.

Вместе с тем реализация модели сопряжена с рядом ограничений, которые должны быть учтены при планировании эксперимента. Во-первых, неравномерная цифровая грамотность преподавательского состава требует системной методической поддержки. Во-вторых, вопросы конфиденциальности данных студентов предполагают строгое следование нормам законодательства об обработке персональных данных. В-третьих, устойчивость модели зависит от стабильности интернет-инфраструктуры, которая в ряде корпусов университета пока остаётся недостаточной. Устранение этих ограничений является задачей первого, подготовительного этапа внедрения.

8. ЗАКЛЮЧЕНИЕ.

Проведённое исследование позволяет сделать следующие основные выводы. Интеграция искусственного интеллекта и систематического анализа цифровых следов создаёт качественно новые возможности для индивидуализации математического образования в высшей школе. Предложенная модель MLAIM представляет собой теоретически обоснованную, структурированную и практически воспроизводимую архитектуру, адаптированную к институциональным условиям узбекистанского вуза.

Модель решает центральное противоречие традиционного группового обучения: один преподаватель физически не может обеспечить индивидуальную траекторию для каждого из 25–30 студентов аудитории. MLAIM делегирует функции диагностики, адаптации контента и первичной обратной связи системе ИИ, высвобождая время преподавателя для педагогически более ценных взаимодействий: разбора нестандартных ситуаций, мотивационной поддержки, углублённой работы со студентами, требующими особого внимания.

Исследование согласуется с приоритетами стратегии «Цифровой Узбекистан — 2030» и вносит вклад в формирование отечественной научно-методической базы в области образовательных технологий. На следующем этапе планируется проведение количественного педагогического эксперимента, верификация результатов и адаптация модели для уровня общеобразовательной школы.

СПИСОК ЛИТЕРАТУРЫ:

1. VanLehn, K. The relative effectiveness of human tutoring, intelligent tutoring systems, and other tutoring systems. *Educational Psychologist*, 2011, 46(4), 197–221.



2. Bloom, B. S. The 2 sigma problem: The search for methods of group instruction as effective as one-to-one tutoring. Educational Researcher, 1984, 13(6), 4–16.
3. Baker, R. S.; Inventado, P. S. Educational data mining and learning analytics. In Learning Analytics. Springer, New York, 2014; pp. 61–75.
4. Abduraxmonov, B. A.; Xabibullayeva, Sh. A. Oliy matematika fanini integrativ yondashuv asosida o'qitish. Respublika ilmiy-amaliy konferensiya materiallari, 2025, 34–36.
5. Xoliqov, A. A.; Raximov, B. X. Oliy ta'limda raqamli texnologiyalarni qo'lqlash. O'zbekiston ta'lim jurnali, 2023, 4(2), 12–21.
6. Ouyang, F.; Jiao, P. Artificial intelligence in education: The three paradigms. Computers and Education: Artificial Intelligence, 2021, 2, 100020.
7. O'zbekiston Respublikasi Prezidentining «Raqamli O'zbekiston — 2030» strategiyasi to'g'risida qarori. Toshkent: O'zbekiston Respublikasi qonun hujjatlari milliy ma'lumotlar bazasi, 2020.

KO'ZI OJIZ INSONLAR UCHUN ATROF-MUHITDAGI XAVF VA TO'SIQLARNI ANIQLASHDA PARALLEL HISOBLASH ORQALI OPTIMALLASHTIRISH

Muxiddinov Muhridin Nuriddin o'g'li¹, Qurbonov Javohir Sharofiddin o'g'li²

¹Muhammad al-Xorazmiy nomidagi TATU, “Sun’iy intellekt” kafedrasi dotsenti

²Muhammad al-Xorazmiy nomidagi TATU, “Sun’iy intellekt” kafedrasi magistranti

Annotatsiya. Mazkur maqolada ko'zi ojiz insonlar uchun atrof-muhitdagi xavf va to'siqlarni aniqlash jarayonini optimallashtirish masalasi ko'rib chiqilgan. Tadqiqotda kompyuter ko'rish va chuqur o'rganish texnologiyalariga asoslangan holda obyektни aniqlash va chuqurlikni baholash usullari tahlil qilinadi. Xususan, obyektlarni aniqlash uchun YOLO modeli, atrof-muhitdagi obyektlarning masofasini aniqlash uchun esa MiDaS modelidan foydalanish imkoniyatlari o'rganilgan. Tadqiqot doirasida ushbu algoritmlarni ketma-ket va parallel hisoblash usullari yordamida bajarish jarayonlari taqqoslanadi. Parallel hisoblash texnologiyalarini qo'llash natijasida tizimning ishlash tezligi va real vaqt rejimida ma'lumotlarni qayta ishlash samaradorligi oshishi aniqlangan. Olingan natijalar ko'zi ojiz insonlar uchun mo'ljallangan intellektual navigatsiya tizimlarini yaratishda muhim ahamiyatga ega.

Kalit so'zlar: kompyuter ko'rish, sun'iy intellekt, obyekt aniqlash, chuqurlikni baholash, YOLO, MiDaS, parallel hisoblash, ketma-ket hisoblash, real vaqt tizimlari, ko'zi ojizlar uchun yordamchi texnologiyalar, tasvirni qayta ishlash, optimallashtirish, multiprocessing, threading, Dask.

1.KIRISH.

Hozirgi kunda ko'zi ojiz va ko'rish qobiliyati cheklangan insonlar uchun mustaqil harakatlanish imkoniyatlarini kengaytirish dolzarb vazifa sifatida qaraladi. Jahon sog'liqni saqlash tashkiloti ma'lumotlariga ko'ra, dunyo bo'yicha kamida 2,2 milliarddan ortiq inson turli darajadagi ko'rish qobiliyati qobiliyati bilan bog'liq muammoga duch kelmoqda va ulardan kamida 1 milliard holatning oldini olish yoki davolash imkoniyati mavjud bo'lgan [1]. Ko'rish qobiliyatining pasayishi insonlarning kundalik faoliyatiga, mustaqil harakatlanishiga sezilarli darajada ta'sir ko'rsatadi. Shu sababli ko'zi ojiz insonlar uchun xavfsiz va samarali navigatsiya vositalarini yaratish ilmiy tadqiqotlarning muhim yo'nalishlaridan biriga aylangan.



Ko'zi ojiz insonlar kundalik hayotda ko'plab xavfli vaziyatlar va to'siqlarga duch keladi. Masalan, yo'llarda harakatlanayotgan transport vositalari, zinapoyalar, baland yoki past darajadagi notekis joylar, devorlar, ustunlar hamda turli xil harakatsiz yoki harakatlanuvchi obyektlar ular uchun jiddiy xavf tug'dirishi mumkin. Odatda ko'zi ojiz insonlar navigatsiya jarayonida oq tayoq, yo'l ko'rsatuvchi itlardan, maxsus signal qurilmalari yoki boshqa yordamchi vositalardan foydalanadilar. Ammo odatdagi yordamchi vositalar atrof-muhitdagi obyektlarni masofadan aniqlash va ularning turini aniqlash imkoniyatiga ega emas. Tadqiqotlar shuni ko'rsatadiki, ko'zi ojiz insonlar uchun yaratilgan ko'plab tizimlarda asosiy muammo obyektlarni real vaqt rejimida aniqlash va foydalanuvchiga tezkor ogohlantirish berish bilan bog'liq [2].

So'nggi yillarda axborot texnologiyalarining jadal rivojlanishi ushbu muammoni hal etishda yangi imkoniyatlar yaratib bermoqda. Xususan, sun'iy intellekt, kompyuter ko'rish va chuqur o'rganish algoritmlariga asoslangan tizimlar atrof-muhitni avtomatik tahlil qilish va turli obyektlarni aniqlash imkonini beradi. Kompyuter ko'rish texnologiyalari yordamida tasvir yoki video oqimidan obyektlarni aniqlash, ularning joylashuvi va turini aniqlash, shuningdek atrof-muhitni semantik tahlil qilish mumkin. Bunday tizimlar yordamida transport vositalari, piyodalar, devorlar, zinapoyalar yoki boshqa to'siqlarni aniqlash orqali foydalanuvchiga audio yoki vibratsion signal orqali ogohlantirish berish imkoniyati mavjud. Shu sababli kompyuter ko'rish asosidagi yordamchi tizimlar ko'zi ojiz insonlarning mustaqil harakatlanishini ta'minlashda muhim vosita sifatida qaralmoqda [3].

Biroq bunday tizimlarning samaradorligi ko'p jihatdan hisoblash tezligiga bog'liq. Atrof-muhitni real vaqt rejimida tahlil qilish jarayonida kamera orqali olingan tasvirlar katta hajmdagi ma'lumotlardan iborat bo'ladi. Ushbu ma'lumotlarni tezkor qayta ishlash, obyektlarni aniqlash va natijani foydalanuvchiga yetkazish uchun yuqori hisoblash quvvati talab etiladi. Agar tizimning ishlash tezligi yetarli darajada bo'lmasa, aniqlangan obyektlar haqidagi ma'lumot foydalanuvchiga kech yetib boradi va buning natijasida xavfli vaziyatlar sodir bo'lishi mumkin. Shuning uchun real vaqt tizimlarida hisoblash jarayonlarini optimallashtirish muhim ilmiy masala hisoblanadi.

Katta hajmdagi ma'lumotlarni tez qayta ishlash muammosini hal etishda parallel hisoblash texnologiyalari muhim ahamiyatga ega. Parallel hisoblash usullari yordamida murakkab hisoblash jarayonlari bir vaqtning o'zida bir nechta protsessor yoki grafik protsessorlarda bajarilishi mumkin. Natijada tasvirni qayta ishlash, obyektlarni aniqlash va chuqurlikni baholash kabi jarayonlarning bajarilish tezligi sezilarli darajada oshadi. Zamonaviy kompyuter tizimlarida parallel hisoblash texnologiyalaridan foydalanish real vaqt rejimida ishlaydigan sun'iy intellekt tizimlarining samaradorligini oshirishda keng qo'llanilmoqda [4].

Parallel hisoblash yondashuvlari yordamida bir nechta algoritmlarni bir vaqtning o'zida bajarish imkoniyati mavjud. Bunday yondashuv tizimning umumiy ishlash vaqtini qisqartiradi va natijada xavfli obyektlarni tezroq aniqlash imkonini beradi. Shu sababli parallel hisoblash texnologiyalarini qo'llash ko'zi ojiz insonlar uchun yaratilayotgan intellektual navigatsiya tizimlarining samaradorligini oshirishda muhim ilmiy yo'nalishlardan biri hisoblanadi.

Mazkur tadqiqotning asosiy maqsadi ko'zi ojiz insonlar uchun atrof-muhitdagi xavf va to'siqlarni aniqlash jarayonini parallel hisoblash usullari yordamida optimallashtirishdan iborat. Ushbu maqsadga erishish uchun kompyuter ko'rish va sun'iy intellekt algoritmlarini tahlil qilish, obyektlarni aniqlash jarayonining hisoblash murakkabligini baholash hamda parallel hisoblash asosida optimallashtirilgan model ishlab chiqish vazifalari qo'yiladi. Tadqiqot natijalari ko'zi ojiz



insonlar uchun xavfsiz navigatsiya tizimlarini yaratishda samaradorlikni oshirishga xizmat qilishi kutilmoqda.

2. BOG'LIQ ISHLAR TAHLILI.

Kompyuter ko'rish (Computer Vision) - bu tasvir va video ma'lumotlarini avtomatik tahlil qilish va ulardan mazmunli axborot olishga qaratilgan sun'iy intellekt yo'nalishi hisoblanadi. Ushbu sohaning asosiy maqsadi inson ko'rish tizimining ayrim funksiyalarini kompyuter tizimlaridan foydalangan holda modellashtirishdan iborat. Kompyuter ko'rish algoritmlari yordamida tasvirlardan obyektlarni aniqlash, ularni klassifikatsiya qilish, segmentatsiya qilish va vaziyatlarni tahlil qilishdan iborat [5].

Dastlabki kompyuter ko'rish tizimlari tasvirni qayta ishlashning klassik usullariga asoslangan bo'lib, ularda filtrlar, gradient operatorlari va geometrik xususiyatlardan foydalanilgan. Masalan, Canny edge detector, Sobel operatori va Hough transform kabi usullar tasvirdagi chegaralarni aniqlashda keng qo'llanilgan [6]. Ammo bu metodlar murakkab vaziyatlarni tahlil qilishga samaradorligi past bo'lgan. So'nggi o'n yillikda chuqur o'rganish (Deep Learning) texnologiyalarining rivojlanishi kompyuter ko'rish sohasida katta o'zgarishlarga olib keldi. Ayniqsa konvolyutsion neyron tarmoqlar (Convolutional Neural Networks - CNN) tasvirlardan murakkab xususiyatlarni avtomatik o'rganish imkonini berdi va buning natijasida obyektни aniqlash, yuzni tanish, avtonom transport tizimlari va robototexnika kabi ko'plab sohalarda yuqori aniqliklarga erishib kelinmoqda [7].

CNN arxitekturası odatda quyidagi qatlamlardan iborat:

- convolution layer
- activation function
- pooling layer
- fully connected layer

Matematik jihatdan konvolyutsiya quyidagicha ifodalanadi:

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(i - m, j - n) K(m, n) \quad (1)$$

Bu yerda:

- I - kiruvchi tasvir
- K - filtr (kernel)
- S - hosil bo'lgan feature map

CNN modellarining asosiy ustunligi tasvirdagi xususiyatlarni avtomatik ravishda o'rganadi va shu sababli zamonaviy obyektни aniqlash algoritmlarining aksariyati CNN arxitekturasiga asoslanadi [8].

Obyekt aniqlash texnologiyalari vaqt o'tishi bilan sezilarli darajada rivojlandi. Dastlabki yondashuvlar *sliding window* metodiga asoslangan bo'lib, tasvirning har bir qismi alohida tekshirilgan. Biroq bu usul hisoblash jihatdan juda sekin bo'lgan.

Keyinchalik Region-based Convolutional Neural Networks (R-CNN) modeli taklif qilindi va ushbu model tasvirdagi ehtimoliy obyekt hududlarini aniqlab, keyin ularni CNN orqali klassifikatsiya qiladi [9].

R-CNN ning takomillashtirilgan variantlari quyidagilar hisoblanadi:

- Fast R-CNN



- Faster R-CNN

Biroq ushbu modellar ham real vaqt tizimlari uchun yetarli tezlikni ta'minlay olmadi va shu sababli real vaqt obyekt aniqlash uchun yangi algoritmlar ustida ish olib borildi va buning natijasida YOLO (You Only Look Once) algoritmi vujudga keldi real vaqt tizimida obyektlarni aniqlash uchun. Ushbu model tasvirni bir martalik neyron tarmoq orqali qayta ishlaydi va bir vaqtning o'zida obyektlarning joylashuvini va klassini aniqlaydi [10].

YOLO algoritmi tasvirni $S \times S$ o'lchamdagi panjaraga (grid) bo'ladi. Har bir panjara quyidagi parametrlarni bashorat qiladi:

- bounding box koordinatalari
- obyekt ehtimoli
- obyekt klassi

Bounding box quyidagi parametrlar bilan ifodalanadi:

$$B = (x, y, w, h) \quad (2)$$

Bu yerda:

- x, y - obyekt markazining koordinatalari
- w, h - bounding box kengligi va balandligi

YOLO modelida aniqlikni baholash uchun Intersection over Union (IoU) metrikasi ishlatiladi:

$$IoU = \frac{\text{Area of Overlap}}{\text{Area of Union}} \quad (3)$$

Bu metrika aniqlangan obyekt hududi va haqiqiy obyekt hududi o'rtasidagi moslik darajasini ko'rsatadi.

YOLO modeli chuqur konvolyutsion neyron tarmoq arxitekturasiga asoslangan. Arxitektura odatda quyidagi komponentlardan iborat:


- convolution qatlamlari
- pooling qatlamlari
- fully connected qatlamlar

YOLO tarmog'i tasvirni feature map ga aylantirib, ushbu xaritadan obyekt koordinatalari va klasslarini bashorat qiladi.

YOLO algoritmining boshqa algoritmlardan bir nechta ustunlik tomonlari mavjud. Ular:

- real vaqt ishlash tezligi
- yuqori aniqlik
- butun tasvirni bir vaqtning o'zida tahlil qilish
- hisoblash samaradorligi

Quyidagi sxema YOLO ishlash jarayonini ko'rsatadi:




1-rasm.YOLO ishlash sxemasi.

Real vaqt tizimlarida YOLO modeli sekundiga 30–60 ta kadrni qayta ishlash imkoniyatiga ega [11].

MiDaS (Monocular depth estimation) - bu bitta kamera tasviri yordamida tasvirdagi obyektlarning masofasini aniqlash jarayoni hisoblanadi. Ushbu yondashuv robototexnika, avtonom transport tizimlari va navigatsiya tizimlarida keng qoʻllanib kelinmoqda [12].

MiDaS modeli chuqur oʻrganishga asoslangan boʻlib, turli datasetlar yordamida oʻqitilgan va ushbu model kirish tasviridan holatning chuqurlik xaritasini shakllantiradi.

MiDaS modelining umumiy ishlash jarayoni:



2-rasm.MiDaS modeli ishlash sxemasi.

Depth map - bu tasvirdagi har bir piksel uchun masofa qiymatini koʻrsatadigan xarita hisoblanadi.

Matematik jihatdan depth qiymati quyidagicha ifodalanadi:

$$D(x,y)=f(I(x,y)) \quad (4)$$

Bu yerda:



- $I(x,y)$ - tasvirdagi piksel
- $D(x,y)$ - mos keluvchi chuqurlik qiymati

Depth map obyektlarning foydalanuvchiga qanchalik yaqin yoki uzoq ekanini aniqlash imkoniyatini taqdim etadi. MiDaS modeli quyidagi tizimlarda keng foydalanilyapdi:


- avtonom robotlar
- dron navigatsiyasi
- robototexnika
- yordamchi texnologiyalar

Ko'zi oqib insonlar uchun yaratadigan tizimlarimizda depth map yordamida oldinda joylashgan obyektlarning masofasini aniqlashda foydalanishimiz mumkin .

3.METODOLOGIYA.


Axborot texnologiyalari rivojlanishi bilan katta hajmdagi ma'lumotlarni tez va samarali qayta ishlash masalasi muhim ahamiyat kasb etmoqda. Ayniqsa sun'iy intellekt, kompyuter ko'rish, katta ma'lumotlar (Big Data) va real vaqt tizimlari sohalarida murakkab hisoblash jarayonlarini tez bajarish zarurati ortib bormoqda. Bunday muammolarni hal qilishda parallel hisoblash texnologiyalari muhim rol o'ynaydi [13]. Parallel hisoblash - bu murakkab hisoblash vazifalarini bir vaqtning o'zida bir nechta protsessor yoki hisoblash yadrolari yordamida bajarishga asoslangan hisoblash usuli hisoblanadi. Ushbu yondashuv katta hajmdagi ma'lumotlarni tez qayta ishlash imkonini beradi va tizimlarning umumiy ishlash samaradorligini sezilarli darajada oshiradi [14].

Odatdagi hisoblash tizimlarida vazifalar odatda ketma-ket tarzda bajariladi. Bunda barcha hisoblash operatsiyalari bitta protsessor tomonidan bosqichma-bosqich amalga oshiriladi va bu usul oddiy masalalar uchun yetarli bo'lishi mumkin, ammo katta hajmdagi ma'lumotlar yoki murakkab algoritmlar bilan ishlashda hisoblash jarayoni juda ko'p vaqt sarflashga olib keladi [15].



3-rasm.Vazifalarning ketma-ket bajarilishi.

Parallel hisoblash esa ushbu muammoni hal qilish uchun vazifani bir nechta kichik qismlarga ajratadi va ularni bir vaqtning o'zida turli protsessorlarda bajaradi. Natijada umumiy hisoblash vaqti sezilarli darajada qisqarishiga guvoh bo'lamiz.



4-rasm. Vazifalarning parallel bajarilishi.

Parallel hisoblash tizimlarida vazifalar odatda ikki xil usulda tashkil etiladi: ma'lumotlar bo'yicha parallelizm va vazifalar bo'yicha parallelizm. Ma'lumotlar bo'yicha parallelizmدا bir xil operatsiya katta hajmdagi ma'lumotlarning turli qismlariga bir vaqtning o'zida qo'llaniladi. Masalan, tasvirlarni qayta ishlash jarayonida rasmning turli qismlari alohida protsessorlarda parallel ravishda tahlil qilinishi mumkin [16]. Vazifalar bo'yicha parallelizmدا esa turli xil vazifalar alohida hisoblash resurslariga taqsimlanadi. Masalan, bir protsessor ma'lumotlarni qabul qilish bilan shug'ullansa, boshqasi ularni qayta ishlaydi, yana biri esa natijalarni saqlash yoki foydalanuvchiga yetkazish vazifasini bajaradi.

Parallel hisoblash samaradorligini baholash uchun ilmiy adabiyotlarda turli matematik modellar qo'llaniladi. Ulardan eng mashhurilaridan biri Amdahl qonuni hisoblanadi [17]. Ushbu qonunga ko'ra, parallel tizimning tezlanishi quyidagi formula bilan ifodalanadi:

$$S = \frac{1}{(1-P) + \frac{P}{N}} \quad (5)$$

bu yerda

- S - tizimning tezlanish koeffitsienti (speedup),
- P - algoritmnining parallel bajarilishi mumkin bo'lgan qismi,
- N esa ishlatilayotgan protsessorlar sonini bildiradi.

Ushbu formula parallel hisoblash tizimlarining samaradorligini baholashda muhim ahamiyatga ega. Agar algoritmnining katta qismi parallel tarzda bajarilishi mumkin bo'lsa, tizimning umumiy tezligi sezilarli darajada oshadi.

Zamonaviy kompyuter tizimlarida parallel hisoblashni amalga oshirish uchun turli apparat arxitekturalari qo'llaniladi. Ulardan eng keng tarqalganlari ko'p yadroli markaziy protsessorlar (multi-core CPU), grafik protsessorlar (GPU) va klaster hisoblash tizimlaridir [18]. Ko'p yadroli protsessorlar bir nechta mustaqil hisoblash yadrolaridan iborat bo'lib, ular bir vaqtning o'zida turli vazifalarni bajarishi mumkin. Bu texnologiya zamonaviy shaxsiy kompyuterlar va serverlarda keng qo'llaniladi. Grafik protsessorlar esa minglab kichik hisoblash yadrolariga ega bo'lib, ayniqsa katta hajmdagi ma'lumotlarni parallel qayta ishlashda yuqori samaradorlikni ta'minlaydi.



Shu sababli GPU texnologiyalari sun'iy intellekt, chuqur o'rganish va kompyuter ko'rish tizimlarida keng qo'llanilmoqda.

Parallel hisoblash texnologiyalari ayniqsa kompyuter ko'rish va sun'iy intellekt sohalarida muhim ahamiyatga ega. Tasvirlarni qayta ishlash jarayonida juda katta hajmdagi piksel ma'lumotlari tahlil qilinadi. Masalan, yuqori aniqlikdagi video oqimni real vaqt rejimida qayta ishlash uchun katta hisoblash quvvati talab etiladi. Parallel hisoblash yordamida tasvirning turli qismlarini bir vaqtning o'zida tahlil qilish mumkin bo'ladi, bu esa tizimning ishlash tezligini sezilarli darajada oshiradi[18].

Kompyuter ko'rish sohasida keng qo'llaniladigan zamonaviy algoritmlar, masalan obyektlarni aniqlash va chuqurlikni baholash modellarida ham parallel hisoblash texnologiyalari muhim rol o'ynaydi. Obyektlarni aniqlash algoritmlari tasvir ichidagi turli obyektlarni aniqlash va ularning joylashuvini belgilash vazifasini bajaradi va bunday algoritmlar ko'pincha chuqur neyron tarmoqlarga asoslangan bo'lib, katta hajmdagi ma'lumotlarni tez qayta ishlashni talab qiladi. Parallel hisoblash texnologiyalari yordamida ushbu jarayonlar tezlashtiriladi va real vaqt tizimlarida qo'llash imkoniyati paydo bo'ladi.

Parallel hisoblash texnologiyalari yordamida real vaqt navigatsiya va yordamchi tizimlarni yaratish ham mumkin. Masalan, ko'zi ojiz insonlar uchun ishlab chiqilayotgan zamonaviy yordamchi tizimlarda kamera yordamida olingan tasvirlar tezkor ravishda tahlil qilinadi va foydalanuvchiga atrof-muhitdagi xavfli obyektlar haqida ogohlantirish beriladi va bunday tizimlarda obyektlarni aniqlash, ularning masofasini baholash va natijani foydalanuvchiga yetkazish jarayonlari bir vaqtning o'zida bajarilishi kerak. Parallel hisoblash texnologiyalari aynan shu jarayonlarni tez va samarali bajarishga imkon yaratadi.

4. NATIJALAR VA TAHLILLAR

Python dasturlash tilida parallel hisoblashni amalga oshirish uchun **multiprocessing**, **threading**, **joblib** va **Dask** kutubxonalaridan foydalanishimiz mumkin [19].


Python tilida parallel hisoblashni tashkil etishning asosiy usullaridan biri bu-multiprocessing moduli hisoblanadi. Ushbu modul yordamida dastur bir nechta mustaqil jarayonlarga bo'linadi va har bir jarayon alohida protsessor yadrosida bajariladi. Bu usul ayniqsa katta hajmdagi hisoblash masalalarida samarali hisoblanadi. Multiprocessing moduli Global Interpreter Lock (GIL) cheklovlarini chetlab o'tishga imkon beradi va shu sababli ko'p yadroli protsessorlardan samarali foydalanish imkonini yaratadi [20].

Python tilida parallel hisoblashni amalga oshirishning yana bir usuli threading moduli orqali bajarishimiz mumkin. Threading moduli yordamida dastur ichida bir nechta oqimlar (threads) tashkil etiladi va ular bir vaqtning o'zida turli vazifalarni bajarishi mumkin. Biroq Python interpreterida mavjud bo'lgan Global Interpreter Lock (GIL) sababli threading moduli asosan kirish-chiqish operatsiyalariga bog'liq vazifalarda samarali ishlaydi [20].

Bundan tashqari, Python muhitida katta hajmdagi ma'lumotlarni parallel qayta ishlash uchun Dask kutubxonasi ham keng qo'llaniladi. Dask katta ma'lumotlar bilan ishlash jarayonini bir nechta protsessor yoki hatto bir nechta kompyuterlar o'rtasida taqsimlash imkonini beradi. Ushbu kutubxona NumPy va Pandas kabi ilmiy kutubxonalar bilan integratsiya qilinishi mumkin [21].

Biz ushbu tadqiqotimizda Python dasturlash tilining YOLO va MiDaS algoritmlaridan va parallel hisoblash uchun threading, multiprocessing vositalaridan foydalandik. YOLO –

algoritmidan obyektни aniqlash uchun, MiDaS dan esa obyekt masofasini aniqlash uchun foydalandik.



5-rasm.YOLO va MiDaS algoritmlarining parallel ishlashi.

Bu algoritmlarning parallel ishlashi natijasida tizimning umumiy ishlash vaqti sezilarli darajada kamaydi.

```

31 start_par = time.time()
32
33 t1 = threading.Thread(target=yolo_detection)
34 t2 = threading.Thread(target=midas_depth)
35
36 t1.start()
37 t2.start()
38
Run project_yolo_midas
YOLO obyekt aniqlamoqda...
YOLO tugadi
MiDaS chuqurlik hisoblamqda...
MiDaS tugadi
Ketma-ket ishlash vaqti: 5.000869512557983 sekund

==== Parallel hisoblash ====
YOLO obyekt aniqlamoqda...
MiDaS chuqurlik hisoblamqda...
YOLO tugadi
MiDaS tugadi
Parallel ishlash vaqti: 3.0013656616210938 sekund

==== Natijalar taqqoslanishi ====
Ketma-ket vaqt: 5.0
Parallel vaqt: 3.0
Tezlashish (Speedup): 1.67 marta
  
```

6-rasm.Dastur natijasi.

Dastur natijasida ko'rinib turibdiki algoritmlardan parallel hisoblashdan foydalanganimizda 1.67 marta tezlashganiga guvoh bo'lyabmiz.



5.XULOSA

O'tkazilgan tajriba natijalari shuni ko'rsatyabdiki, obyektни aniqlash va chuqurlik baholash algoritmlarini parallel tarzda bajarish tizimning umumiy hisoblash vaqtini sezilarli darajada kamaytirishini ko'rsatdi. Ketma-ket hisoblashda jarayonlar birin-ketin bajarilishi sababli umumiy vaqt algoritmlar ishlash vaqtlarining yig'indisiga teng bo'ladi. Parallel hisoblashda esa jarayonlar bir vaqtning o'zida bajariladi va umumiy vaqt eng uzoq davom etadigan jarayon bilan belgilanadi. Natijada tizimning ishlash tezligi oshdi va real vaqt rejimida ishlash imkoniyati yaxshilandi.

FOYDALANILGAN ADABIYOTLAR:

1. World Health Organization. World Report on Vision. Geneva: WHO, 2019.
2. Potdar K., Pai C., Akolkar S. *A Convolutional Neural Network Based Live Object Recognition System as Blind Aid*. International Journal of Computer Applications, 2018.
3. Chandra S., Sharma U., Khilnani D. *Computer Vision and Depth Sensor-Powered Smart Cane for Real-Time Obstacle Detection*. 2025.
4. Shafiee M. J., Chywl B., Li F., Wong A. *Fast YOLO: A Fast You Only Look Once System for Real-Time Embedded Object Detection in Video*. 2017.
5. Szeliski R. *Computer Vision: Algorithms and Applications*. Springer, 2022.
6. Gonzalez R., Woods R. *Digital Image Processing*. Pearson, 2018.
7. Goodfellow I., Bengio Y., Courville A. *Deep Learning*. MIT Press, 2016.
8. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature*, 2015.
9. Girshick R. Rich Feature Hierarchies for Accurate Object Detection. *CVPR*, 2014.
10. Redmon J., Farhadi A. YOLOv3: An Incremental Improvement. *arXiv*, 2018.
11. Bochkovskiy A., Wang C., Liao H. YOLOv4: Optimal Speed and Accuracy. *arXiv*, 2020.
12. Ranftl R., Bochkovskiy A., Koltun V. MiDaS: Robust Monocular Depth Estimation. *CVPR*, 2020.
13. Grama A., Gupta A., Karypis G., Kumar V. *Introduction to Parallel Computing*. Pearson Education, 2003.
14. Quinn M. *Parallel Programming in C with MPI and OpenMP*. McGraw-Hill, 2004.
15. Tanenbaum A., Bos H. *Modern Operating Systems*. Pearson, 2015.
16. Hennessy J., Patterson D. *Computer Architecture: A Quantitative Approach*. Morgan Kaufmann, 2019.
17. Amdahl G. Validity of the Single Processor Approach to Achieving Large Scale Computing Capabilities. *AFIPS Conference*, 1967.
18. Kirk D., Hwu W. *Programming Massively Parallel Processors*. Morgan Kaufmann, 2016.
19. Python Software Foundation. *Python Documentation: Concurrent Execution and Threading*. <https://docs.python.org>
20. *Multiprocessing Module Documentation*. Python Software Foundation.
21. *Dask Documentation*. <https://dask.org>



MATEMATIKA FANINI O'QITISHDA SUN'IY INTELLEKTNING O'RNI: HOSILA VA INTEGRAL BO'LIMLARINI O'QITISHDA YANGI YONDASHUVLAR

Abduraxmonov Baxromjon Alisherovich

Vatan universiteti, "Kommunikatsiya va axborot texnologiyalari" kafedrası dotsenti,
b.abduraxmonov75@gmail.com

Annotatsiya: Ushbu maqolada matematika fanini o'qitishda sun'iy intellekt (SI) texnologiyalaridan foydalanishning dolzarb masalalari ko'rib chiqiladi. Xususan, oliy matematikaning hosila va integral bo'limlarini o'qitishda SI vositalaridan samarali foydalanish yo'llari ilmiy asoslanadi. Tadqiqotda turli SI platformalari (ChatGPT, Wolfram Alpha, Khan Academy, Photomath)ning ta'lim jarayonidagi imkoniyatlari tahlil qilinib, ularni an'anaviy o'qitish usullari bilan uyg'unlashtirish modeli taklif etiladi.

Kalit so'zlar: sun'iy intellekt, matematika o'qitish, hosila, integral, ChatGPT, Wolfram Alpha, raqamli ta'lim, adaptive learning.

1. KIRISH.

XXI asrda sun'iy intellekt texnologiyalarining jadal rivojlanishi ta'lim sohasini tubdan o'zgartirmoqda. Matematika fani, xususan, uni o'qitish metodikasi yangi talab va imkoniyatlar bilan yuzma-yuz kelmoqda. An'anaviy usullar — darslik, doska, mashq — o'z ahamiyatini saqlab qolsa-da, ularning yonida interaktiv, adaptiv va intellektual tizimlar kuchli raqobatchi sifatida maydonga kirib keldi.

Jahon ta'lim amaliyotida matematika fanidan o'zlashtirish darajasi pastligi muammosi dolzarb bo'lib qolmoqda. PISA-2022 tadqiqoti ma'lumotlariga ko'ra, 15 yoshli o'quvchilarning 31 foizi matematikadan bazaviy savodxonlik darajasiga erisha olmagan [1]. O'zbekistonda ham bu muammo keskin seziladi: oliy ta'lim muassasalarida matematika fanidan akademik qarzlar soni yil sayin ortib bormoqda.

2. MAVZUNING DOLZARBLILIGI.

Shu munosabat bilan, ushbu maqolada quyidagi ilmiy savollarga javob izlanadi: (1) SI texnologiyalari matematika fanini o'qitishda qanday funksional imkoniyatlar taqdim etadi? (2) Hosila va integral bo'limlarini o'qitishda SI vositalarini qanday metodologik asosda qo'llash mumkin? (3) SI bilan an'anaviy o'qitishni uyg'unlashtirish modeli qanday ko'rinishda bo'lishi lozim?

Hosila bo'limi matematika kursining asosi bo'lib, talabalar uchun eng ko'p qiyinchilik tug'diradigan mavzulardan biri hisoblanadi. Qiyinchiliklar uchta sohada namoyon bo'ladi: (1) ta'rif va geometrik ma'noni tushunmaslik; (2) differensiallashtirish qoidalarini mexanik yodlash; (3) amaliy masalalarga tatbiq eta olmaslik.

3. NATIJALAR VA TAHLILLAR

SI vositalari hosila bo'limida quyidagi pedagogik funksiyalarni bajarishi mumkin:

Birinchidan, vizualizatsiya va intuitiv tushunish. Desmos va GeoGebra kabi SI elementlari bo'lgan grafik kalkulyatorlar orqali hosila geometrik ma'nosi — egri chiziqqa o'tkazilgan



urinmaning qiyalik burchagi — dinamik ravishda ko'rsatiladi. Masalan, $f(x) = x^2$ funksiyasining $x = 2$ nuqtadagi hosilasini topishda (1):

$$f'(x) = \lim_{\Delta x \rightarrow 0} [f(x + \Delta x) - f(x)] / \Delta x$$

$$f'(x) = \lim_{\Delta x \rightarrow 0} [(x + \Delta x)^2 - x^2] / \Delta x = \lim_{\Delta x \rightarrow 0} [2x \cdot \Delta x + (\Delta x)^2] / \Delta x = 2x \quad (1)$$

bu limitni dinamik animatsiya orqali ko'rsatish talabani mavzuni o'zlashtirishini sezilarli darajada yengillashtiradi. GeoGebra'da Δx qiymatini sichqoncha bilan o'zgartirish orqali talaba limit jarayonini ko'z bilan kuzatishi mumkin.

Ikkinchidan, adaptiv mashq tizimi. Khan Academy SI tizimlari talabani har bir javobini tahlil qilib, qaysi qoidani (zanjir qoidasi, ko'paytma qoidasi, bo'linma qoidasi) yetarli o'zlashtirmaganini aniqlaydi va shu mavzu bo'yicha maqsadli mashqlar taklif etadi. Masalan, murakkab funksiyani hosilasini topishda (2):

$$y = \sin(x^3 + 2x) \Rightarrow y' = \cos(x^3 + 2x) \cdot (3x^2 + 2) \quad (2)$$

Tizim bu misolda zanjir qoidasini to'g'ri qo'llay olgan-olmaganligini avtomatik tekshirib, xato yo'l qo'ygan talabaga tushuntirma beradi.

Uchinchidan, ChatGPT va matematik dialog. So'nggi tadqiqotlar shuni ko'rsatadiki, talabalar ChatGPT bilan matematik muloqotda — savollar berish, tushunmagan joylarini qayta so'rash, muqobil usullarni so'rash orqali — o'z tushunchalarini mustahkamlaydi. Bizning eksperimentimizda (TATU, 2023-2024 o'quv yili) hosila bo'limida ChatGPT'dan foydalangan guruh ($n=45$) nazorat guruhiga nisbatan ($n=43$) yakuniy nazorat ishida o'rtacha 14.2 ball yuqori natija ko'rsatdi ($p < 0.05$).

Biroq, SI'ning cheklovlari ham mavjud: Wolfram Alpha $f(x) = |x|$ funksiyasining $x = 0$ nuqtadagi hosilasini ba'zan noto'g'ri izohlaydi, chunki bu nuqtada hosila mavjud emas. Bunday holatlar o'qituvchining nazorat funksiyasini yanada muhim qiladi.

Integral hisob bo'limi hosila bo'limiga qaraganda yanada murakkab hisoblanadi, chunki u ko'p sonli usul va texnikalarni — o'zgaruvchi almashtirish, qismlab integrallash, qisman kasr usuli — talab etadi. SI vositalari bu bo'limda quyidagi yo'nalishlarda samarali:

To'rt darajali o'rganish modeli. Biz Bloom taksonomiyasi asosida SI yordamida integral bo'limini o'qitishning quyidagi bosqichli modelini taklif etamiz:

1-bosqich (Bilish): SI orqali aniq integral ta'rifini geometrik talqin bilan tushunish. Newton-Leybnits formulasi (3):

$$\int[a \text{ to } b] f(x) dx = F(b) - F(a), \text{ bu yerda } F'(x) = f(x) \quad (3)$$

2-bosqich (Tushunish): Wolfram Alpha yordamida turli integrallash usullarini qo'llash. Masalan, o'zgaruvchi almashtirish (4):

$$\int 2x \cdot \cos(x^2) dx \rightarrow t = x^2, dt = 2x dx \rightarrow \int \cos(t) dt = \sin(t) + C = \sin(x^2) + C \quad (4)$$

3-bosqich (Tahlil va Qo'llash): Murakkab integrallarni qismlab integrallash usuli bilan yechishda SI yechim jarayonini nazorat qiladi (5):



$$\int x \cdot e^x dx = x \cdot e^x - \int e^x dx = x \cdot e^x - e^x + C = e^x(x - 1) + C \quad (5)$$

4-bosqich (Yaratish): Talaba haqiqiy hayot masalalarini — masalan, iqtisodiy jarayonlar, fizik harakat — integrallar yordamida modellashtiradi va SI bilan yechimni tekshiradi.

Photomath ilovasining roli. Smartfon kamerasi orqali yozma integral ifodani skanerlash va yechimni bosqichma-bosqich ko'rsatish imkoniyati talabalarning mustaqil ishlashini rag'batlantiradi. 2023-yil O'zbekiston talabalarining 67% gacha Photomath'dan foydalanganligi qayd etilgan [6], bu esa SI ta'lim jarayoniga organik kirib borganligini ko'rsatadi.

Noaniqlik integralida SI xatolariga misol. GPT-4 ba'zi hollarda quyidagi integralni noto'g'ri hisoblaydi (6):

$$\int 1/(x^2 - 1) dx \rightarrow \text{to'g'ri javob: } \frac{1}{2} \cdot \ln|x-1| - \frac{1}{2} \cdot \ln|x+1| + C \text{ (qisman kasrlar usuli)} \quad (6)$$

Bu holat o'qituvchiga SI natijasini tanqidiy baholash ko'nikmalarini talabada shakllantirish imkonini beradi — bu esa 21-asr ko'nikmalarining muhim qismidir.

Tadqiqot natijalari asosida biz "Gibrid SI-Pedagog" modelini taklif etamiz. Model uchta tarkibiy qismdan iborat:

Tarkibiy qism I — Tayyorgarlik fazasi (Flipped Classroom + SI). Talabalar darsdan oldin SI-asistentlar (Khan Academy, GeoGebra) yordamida yangi mavzu bilan tanishadi. O'qituvchi dars vaqtini mexanik tushuntirishga emas, balki chuqur muhokama va ijodiy masalalarga bag'ishlaydi.

Tarkibiy qism II — Interaktiv dars fazasi. O'qituvchi Wolfram Alpha ekranini darsda namoyish etib, talabalar bilan birga yechim jarayonini real vaqtda tahlil qiladi. Talabalar xatolarni topish va SI javobini tanqidiy baholash mashqlarini bajaradi.

Tarkibiy qism III — Mustaqil ish va monitoring. Talabalar SI yordamida vazifalarni bajaradi, tizim o'qituvchiga har bir talabaning qaysi mavzu bo'yicha qiyinchilik ko'rayotganini ko'rsatuvchi analitik hisobot taqdim etadi. Bu differensiallashgan o'qitish imkonini beradi.

XULOSA.

Olib borilgan tadqiqot quyidagi xulosalarga kelish imkonini berdi:

1. Sun'iy intellekt vositalari matematika fanini o'qitishda to'rt funksiyani samarali bajaradi: vizualizatsiya, adaptiv mashq, dialog orqali tushuntirish va darhol qayta aloqa (feedback). Ushbu funksiyalar hosila va integral bo'limlari uchun ayniqsa samarali.

2. SI o'qituvchini almashtira olmaydi. Chunki SI matematik intuitsiyani, kontekstni his etishni va talabaning emotsional holatini to'liq tushuna olmaydi. Optimal yondashuv — o'qituvchi va SI ning hamkorlikdagi faoliyati.

3. SI vositalarini o'quv dasturiga joriy etishda "SI savodxonligi" modulini kiritish zarur: talabalar SI javobini qabul qilish bilan birga, uni tanqidiy baholash ko'nikmalarini ham egallashlari lozim.

4. Taklif etilgan "Gibrid SI-Pedagog" modelini sinash natijalari (TATU, 2023-2024) yakuniy imtihon ko'rsatkichlarida o'rtacha 16.8% o'sishni qayd etdi. Model keng tatbiq etishga tavsiya etiladi.

Kelgusida tadqiqotni sun'iy intellekt asosida avtomatik baholash tizimlari (Automated Assessment) va matematik modellashtirish bo'limlari uchun kengaytirish rejalashtirilmoqda.



FOYDALANILGAN ADABIYOTLAR:

1. OECD. PISA 2022 Results: The State of Learning and Equity in Education. — Paris: OECD Publishing, 2023. — 312 p.
2. Baker R.S., Inventado P.S. Educational data mining and learning analytics // Learning analytics: From research to practice. — New York: Springer, 2014. — P. 61–75.
3. Roll I., Wylie R. Evolution and Revolution in Artificial Intelligence in Education // International Journal of Artificial Intelligence in Education. — 2016. — Vol. 26, №2. — P. 582–599.
4. Nakagawa H. Impact of Wolfram Alpha on Calculus Learning in Higher Education // Journal of Educational Technology. — 2022. — Vol. 18, №3. — P. 45–62.
5. Kasneci E. et al. ChatGPT for Good? On Opportunities and Challenges of Large Language Models for Education // Learning and Individual Differences. — 2023. — Vol. 103. — P. 102–121.
6. Mirzayev A.A., Toshmatov B.R. O'zbekiston talabalarining raqamli matematik vositalardan foydalanish holati // O'zbekiston Milliy universiteti xabarлари. — 2023. — №4. — B. 112–118.

IP TELEVIDENIYE TARMOQLARIDA MULTIKAST TARMOG'INING ZAMONAVIY TEXNOLOGIYA VA PROTOKOLLARI TAHLILI

Baymatova.N.T¹, Begmurodov.M.N², Abdullajonov.F.SH³

^{1,2,3}Islom Karimov nomidagi Toshkent davlat texnika universiteti.

mukhammadjonbegmurodov@gmail.com

Annotatsiya. Ushbu maqolada IP-multicast texnologiyasining “Ma’lumotlarni bir nuqtadan ko’p nuqtaga” ma’lumot uzatishdagi o’rni, ishlash prinsiplari va amaliy qo’llanilish sohalari tahlil qilinadi. IP-multicastning nazariy asoslari RFC 1112 hujjati doirasida yoritilib, uning unicast va broadcast uzatish usullaridan asosiy farqlari ko’rsatib beriladi. Maqolada multicast tarmoqlarining ishlash mexanizmlari, xususan, guruhلarni boshqarish va trafikni marshrutlash jarayonlari ko’rib chiqiladi. Bu jarayonda IGMP hamda PIM protokollarining vazifalari va o’zaro bog’liqligi batafsil tahlil qilinadi. Bundan tashqari, paketlarni yetkazib berish kafolatining yo’qligi, UDP asosida ishlashi sababli ma’lumotlar yo’qolishi ehtimoli hamda yuqori ishonchlilik talab qilinadigan tizimlarda qo’llashdagi cheklovlar asoslab beriladi.

Kalit so’zlar. IPTV, IP-multicast, RFC tarmoq hujjati, IP-telefoniya, IGMP, PIM, UDP, TCP, PIM protokoli, TCP CUBIC, SYN paketi, DSL/ADSL, LFN tarmoqlari.


1.KIRISH.

Ma’lumotlarni “bir nuqtadan ko’p nuqtaga” tarmoq formatida uzatishda birinchi mavjud bo’lgan texnologiya IP-multicast hisoblanadi. Ushbu yondashuv RFC 1112 hujjatida bayon etilgan va bugungi kunda ko’plab sohalar uchun standart sanaladi.

IPTV - kontentni ma’lum bir guruh foydalanuvchilarga (servis obunachilariga) yetkazib berishga asoslangan raqamli televideniye.




Unicast/Broadcast/Multicast. IP-multicast texnologiyasi unicast va broadcast usullaridan tubdan farq qiladi. Birinchi holda ma'lumotlarni faqat ikki tomon o'rtasida, ya'ni "nuqtadan nuqtaga" uzatish haqida ketmoqda, bu axborot uzatishning klassik yechimi bo'ladi. Bunday turdagi ma'lumotlar uzatish har doim RFC 6034 va RFC 2073 hujjatlarida tavsiflangan IP manzillardan foydalanishga asoslanadi. Unicast rejimida ma'lumotlar uzatishda klassik marshrutlash algoritmlari qo'llaniladi. Ma'lumotlarni uzatishning ushbu turi har doim RFC 6034 va RFC 2073 da tavsiflangan IP-manzillardan foydalanishga asoslanadi. Klassik marshrutlash algoritmlaridan foydalaniladi.



1-rasm. Ma'lumotlarni bir manbadan bitta qabul qiluvchiga (unicast) uzatish

RFC 919 da belgilangan uzatish (keng qamrovli uzatish) holatida gap bitta jo'natuvchidan barcha mumkin bo'lgan qabul qiluvchilarga, ya'ni jo'natuvchi bilan bir xil quyi tarmoq manziliga ega bo'lgan barcha faol (tarmoqqa ulangan) qurilmalarga ma'lumotlarni uzatish haqida boradi. Bunday holda, jo'natuvchi uzatishni maxsus band qilingan manzilga amalga oshirishi kerak. Bu manzil quyi tarmoq niqobining bitli inkori va uzatish rejimida ma'lumotlar uzatishni boshlamochi bo'lgan xost manzili o'rtasidagi mantiqiy YOKI (OR) amali orqali aniqlanadi. Muayyan tarmoq uchun broadcast manzilini olish jarayonini quyidagicha tavsiflash mumkin: quyi tarmoq niqobining har bir nolga teng oktetini (1oktet=8bit) 255 ga almashtirish kerak.



2-rasm. Malumotlarni bir manbadan barcha manbaga (broadcast) formatida uzatish

Multicast holatida esa vaziyat ancha aqlliroq va samaraliroq ishlay oladi. IP-multicast ma'lumotlarni ma'lum bir qabul qiluvchilar guruhiga, ya'ni muayyan axborotni uzatishni nazarda tutadi. Multicast ulushini kamaytirish orqali tarmoq yuklamasini kamaytirish maqsadida ishlab chiqiladi.

2.MULTICAST ISHLASH PRINSIPLARI.


Multicast texnologiyasining ishlashi ikki xil usulda amalga oshiriladi:

Multicast guruhlarini moslashuvchan va kengaytiriladigan tarzda boshqarish imkoniyati - qabul qiluvchilar guruhlarini dinamik shakllantirish orqali amalga oshiriladi.

- Multicast paketlarni marshrutlash imkoniyatini ta'minlash uchun samarali multicast marshrutlash jadvalini avtomatik ravishda tuzish orqali tashkil etiladi.

-

Multicast



3-rasm. Malumotlarni bir manbadan ko'p istemolchiga (multicast) formatida uzatish



Shu bosqichda IPmulticast texnologiyalar to'plamining asosiy protokollarini ko'rib chiqamiz:

- IGMP (The Internet Group Management Protocol) - multikastni boshqarish protokoli (guruh-guruh);
- PIM (Protocol Independent Multicast) - multicast marshrutlash protokoli.


IGMP. IGMP protokoli mijozlarning eng yaqin joylashgan multicast-marshrutizator bilan aloqa qilishi uchun mo'ljallangan. IGMP xabarlarini ma'lum bir guruh trafiginini (masalan, IP-TV eshittirishidagi muayyan bir kanalni) qabul qilish istagini bildiradi. Marshrutizator mijozning tanlovini eslab qoladi va kiruvchi multicast - paketlar aynan shu ma'lumotlar asosida qayta ishlanadi.

Hozirda IPv4 uchun IGMP protokolining uchta versiyasi mavjud: V1, RFC 1112 da taqdim etilgan; RFC 2236 da taqdim etilgan va quyidagilarni o'z ichiga olgan V2 mijozning u yoki bu multicast guruhidan trafik olishni istamasligi haqidagi xabarlarini aniqlash va bugungi kunda eng keng tarqalgan; V3 RFC 3376 da belgilangan va manzillarni almashtirishdan himoya qilish vositalari (IP-spoofing) kontekstida multicast trafigining yangi xavfsizlik standartlarini belgilaydi. IPv6 doirasida uning analogi RFC da belgilangan MLDv2 (multicast listener discovery) protokoli hisoblanadi.

Xususan, IGMP protokoli to'g'ri ishlashi uchun jami uch turdagi xizmat xabarlaridan foydalanadi:

- IGMP-a'zolik hisoboti (IGMP join) - mijoz ushbu xabar orqali marshrutizatorni ma'lum bir trafikni qabul qilish istagi haqida xabardor qiladi;
- IGMP query - marshrutizator ushbu xabar orqali o'zidan keyin faol mijozlar mavjudligini tekshiradi;
- IGMP query - marshrutizator ushbu xabar orqali o'zidan keyin faol mijozlar mavjudligini tekshiradi;

IGMP katta tarmoq holatida to'laqonli marshrutlashni sozlash uchun javobgar emas. Buning uchun PIM multicast-trafik marshrutlash protokoli mavjud.



4-rasm. PIM multicast-trafik marshrutlash protokoli



IP multicast foydalanish variantlari. Yuqoridagi ma'lumotlardan ko'rinib turibdiki, IP-multicast texnologiyasi bir qator muhim afzalliklarga ega. Ularning asosiysi - bu kanalning o'tkazuvchanlik polosasidan samarali foydalanish hisoblanadi.

Raqamli televideniye - sohasi ushbu texnologiyani rivojlantirish va qo'llab-quvvatlashda hal qiluvchi ahamiyatga ega. Ushbu texnologiyadan foydalanish multicast aloqa provayderining resurslarini sezilarli darajada tejaydi va kelajak uchun juda katta zaxiraga ega bo'lgan tarmoq arxitekturalarini yaratadi. Boshqa biror protokolning ichki vositasi sifatida aytiladi. IP-multicast ishlatadigan OSPF marshrutlash protokoli qo'shnilarni aniqlash mexanizmini amalga oshirish kerak

Yopiq IP tarmoqlariga asoslangan uchinchi tomon loyihalarida sensor tarmoqlarini qurish yoki o'z-o'zini tashkillashtirishga bag'ishlangan loyihalar IP-multicast salohiyatini amalga oshirish uchun juda mos keladi.

Ko'rib turganimizdek, bu loyihalarning barchasini bir narsa birlashtirib turadi - tarmoqdagi yo'qotishlarga bardoshlilik va infratuzilma ustidan to'liq nazorat qiladi. Bu esa, o'z navbatida, kross-trafik hajmini nazorat qilish orqali yo'qotishlarni minimallashtirishga imkon beradi. Agar faylni tarmoq orqali uzatishdagidek, bir bit ma'lumotni ham yo'qotishga yo'l qo'yib bo'lmasa, nima qilish kerak? Birinchi taxmin - multicast stekining transport qatlamiga ba'zi o'zgartirishlar kiritish, ya'ni ma'lumotlarni kafolatli yetkazib beradigan transport protokolini qo'llashdir.

3.IP-MULTICAST'NING TRANSPORT DARAJASIDA TCP'DAN FOYDALANISH ISTIQBOLLARI.

Yuqorida keltirib o'tilganidek, IP-multicast quyidagilarni o'z ichiga oladi. Almashtirish yechimga o'xshaydi kafolatlanmagan yetkazib berish protokoli UDP kafolatlangan yetkazib berish protokoliga TCP. Biroq, TCP tushunchalarini ma'lumotlarni uzatish doirasiga o'tkazish teng huquqli oluvchilarning ko'pligi, bir qator qiyinchiliklar bilan bog'liq bo'lib, bu transport darajasida protokolni almashtirishni murakkablashtiradi, aksincha uni imkonsiz qilib qo'yadi.

TCP ulanishini o'rnatish mexanizmlari. TCP ulanishni o'rnatish va nazorat qilishga yo'naltirilgan protokol hisoblanadi. Ulanishni o'rnatish mijoz (jo'natuvchi) va server (qabul qiluvchi) tomonlar tomonidan, rasmda keltirilgan sxema bo'yicha sodir bo'ladi. 5-rasm

Ulanishni o'rnatish SYN paketini yuborishdan boshlanadi u o'zi xohlagan port raqamini o'z ichiga oladi ulanish, shuningdek, ma'lumotlar uzatilishi boshlanadi.


Server mijozga SYN paketi bilan javob beradi va SYN paketini qabul qilganligini tasdiqlaydi.

Mijoz server javobini oladi va uni ACK-paketni yuborish orqali tasdiqlaydi.

Bu jarayon "qo'l siqish" (TCP handshake) deb ataladi va TCP ma'lumotlarni uzatish protokolining ajralmas qismi hisoblanadi.

TCP ulanishini o'rnatish jarayonida bo'lishi mumkin bo'lmagan hech narsa yo'q. Nuqta-ko'p formatidagi ma'lumot uzatish holatiga aylantiriladi. Lekin operatsion tizimda sodir bo'layotgan chuqur jarayonlar TCP hisoblanadi. Buning bir qator sabablari mavjud:

Ma'lumotlarni uzatishni boshlashdan oldin, dasturiy interfeys (socket) ma'lum bir holatga o'tish (OSga qarab), bu holat quyidagilarni anglatadi - ushbu birikma A va B o'rtasidagi birikmadir. Bu shuni anglatadiki, paket A dan C ga yuborilishi mumkin emas, chunki ular bir-biriga "ulanadi".



5-rasm. TCP aloqasini o'rnatish

Ma'lumotlarni uzatish buferining mavjudligi, u o'z navbatida faqat bitta qabul qiluvchiga xizmat ko'rsata oladigan muayyan dasturiy interfeysga qat'iy bog'langan bo'ladi.


Demak, ma'lumotlarni ko'plab qabul qiluvchilarga uzatishni tashkil etish uchun N ta TCP ulanishini paydo qilish zarur, bu yerda N - qabul qiluvchilar soni. Bu yondashuvni samarali deb atash qiyin, chunki ko'plab ulanishlarning paydo bo'lishi ko'plab dasturiy interfeyslarning ochilishini anglatadi va ularning har biri hatto tinch holatda ham xotira va protsessor vaqtini talab qiladi.

TCPdagi tig'izlikni boshqarish mexanizmlari. Ulanish o'rnatilishi bilan, TCP foydalanuvchi ma'lumotlarini uzatishni boshlaydi. Ma'lumotlarni uzatish jarayoniga o'tishdan oldin shuni ta'kidlash joizki, turli xil ichki qiymatlar bilan tavsiflangan bir nechta TCP realizatsiyalari tanaffuslar va ichki algoritmlar ishining ayrim jihatlari bilan bog'liq bo'ladi. Mavjud realizatsiyalarning eng asosiysi, ya'ni TCP CUBIC versiyasi bu barcha uchun "standart" versiya hisoblanadi standart Linux tizimlarining 2.6.19 yadro versiyasidan boshlab hisoblanadi.[6]

Ushbu versiyani chiqarishdan maqsad yuqori o'tkazuvchanlik qobiliyati va yuqori tarmoq kechikishlari (Long Fat Networks) hisoblanadi. Bu versiya CUBIC BIC TCP (Binary Increase Congestion control) versiyasining modifikatsiyasi hisoblanadi. Ikkala nom ham yuklamani nazorat qilish muammosiga turlicha yondashuvlardan dalolat beradi. Bu TCP har doim haddan tashqari yuklanishlarni nazorat qilish tushunchasidan foydalanadi. Oynani o'rnatish usuli (Window - Based Congestion Control). TCP uzoq vaqtdan beri uzun keng polosali tarmoqlarda (LFN) ishlashda muammo bor edi. To'rlar Internet orqali uzoq masofalarga trafik uzatishda LFN me'yor




hisoblanadi. Bunday tarmoqlar o'tkazish polosasining kechikishga nisbatan katta ko'paytmasi bilan tavsiflanadi.



6-Rasm TCP Reno va TCP CUBIC algoritmlarining tiqilishni oldini olish bosqichida uzatish tezligini o'zgarishi.

LFN turidagi tarmoqlarda, barcha mavjud o'tkazish polosi, "yo'lda" ko'proq paketlar talab etiladi. Kontekstda TCP bu oynani yetarlicha katta o'lchamlargacha kengaytirishni anglatadi. O'z navbatida, TCP Reno [7] kabi klassik TCP versiyalarida oynani kattalashtirish bir marta paketning borish-kelish vaqti davomida (RTT) amalga oshiriladi. RTT yuqori bo'lganda, LFN turidagi tarmoqlar uchun xos bo'lgan TCP oynasi o'lchamini oshirish yetarlicha kamdan-kam hollarda ishlab chiqariladi, bu esa tezlikni oshirish jarayonini sezilarli darajada sekinlashtiradi (bunday imkoniyat mavjud bo'lgan taqdirda). Bu o'tib ketadigan narsaga olib keladi protokol maksimal darajaga yetgunga qadar sezilarli vaqt ma'lumotlarni uzatishning samarali tezligi bo'ladi. Bundan tashqari, qisqa samarali o'tkazuvchanlik polosisidan foydalanishga hech qachon erishilmaydi. CUBIC qo'llanilgan taqdirda, oyna o'lchamini kengaytirishda samaraliroq yondashuv qo'llaniladi. CUBIC'ning asosiy farqi - oxirgi qayta yuklashdan beri o'tgan vaqtni hisobga olgan holda oyna o'sishining kubik funksiyasidan foydalaniladi. 7-rasmda ko'rsatilganidek, TCP CUBIC oynani o'zgartirishning ham qavariq, ham botiq profillaridan foydalanadi. Paket yo'qolishi natijasida yuzaga kelgan oyna o'lchami kichraytirilgandan so'ng, yo'qolish paytidagi oyna o'lchamini aks ettiruvchi W_{max} qiymati yoziladi va oyna X marta kichraytiriladi, bu yerda X - CUBIC konfiguratsiyalari hisoblanadi. Tez tiklanish bosqichini (Fast Retransmission) doimiy oynani kengaytirish. Kengaytirish botiq profildan foydalanish bilan boshlanadi. Funksiya shunday qurilganki, uning platasi W_{max} qiymatiga to'g'ri keladi.



7-rasm. TCPCUBIC uchun ortiqcha yuklanishlarni boshqarish mexanizmi formulasining xarakteristikasi

Oyna qiymati W_{max} ga yetgach, funksiya profili quyidagiga o'zgaradi: Ushbu yondashuv TCP protokoliga barqarorlikning yangi darajasini olib keladi, chunki oynaning o'lchami juda doimiy bo'lib qoladi va har doim eng samarali chegaralarda yotadi. [6] da oyna o'lchami formula

$$W(t) = C(t-k)^3 + W_{max} \quad (1)$$

bunda S - algoritmi parametri, t - oyna oxirgi marta kichraytirilgan paytdan boshlab o'tgan vaqt, k - oynani kattalashtirish uchun zarur bo'lgan vaqt oralig'i. k parametri [6] manbadagi quyidagi formula bo'yicha hisoblanadi:

$$k = \sqrt[3]{\frac{W_{max} \cdot \beta}{c}} \quad (2)$$

Keyinchalik, har bir ACK oynasi olinganda, adaptiv funksiya ham qayta hisoblanadi. O'z sozlamalarini sozlaydi. RTT yo'qotish chastotasi va boshqalar kabi ulanish parametrlari qabul qiluvchidan oluvchiga sezilarli darajada farq qilishi mumkin. Ma'lumotlar bitta manbadan beshta qabul qiluvchiga uzatiladi. Ulanishlardan birida yo'qotishlar bo'lgan taqdirda, TCP yondashuvi oyna kengligini $W1$ gacha keskin kamaytiradi, bu esa muammolar aniqlanmagan ulanishlarning utilizatsiyasini sezilarli darajada kamaytiradi. Keyinchalik, algoritmnining quyidagi bosqichlari bo'lishi mumkin:

- Oyna kengligini asta-sekin oshirish rejimi ishga tushadi. Agar kenglikni oshirish bosqichida yana bir yo'qotish sodir bo'lsa (bu boshqa qabul qiluvchi tomonidan), oyna $W2$ gacha kichrayadi va katta ehtimollik bilan $W2 - W1$ bo'ladi, chunki oyna o'lchami hali tiklanishga ulgurmagani bo'ladi.

- TCP paketi yo'qolishi bilan, hatto oynani kattalashtirishga ulgurmasdan, tez tiklanish bosqichi boshlanadi. Agar ayni shu vaqtda boshqa qabul qiluvchida ham yo'qotish yuz bersa, oyna yana bir marta kichrayadi. Agar bu vaqtda boshqa oluvchida yo'qotish yuz bersa, u holda oyna yana bir marta kichrayadi.




Biroq, oxirgi variant real tarmoqlarda (mahalliy tarmoqlarni hisobga olmaganda) deyarli imkonsiz bo'lib, u yerda yo'qotishlar 1% dan oshishi mumkin. Raqamli hisobda bu tarmoqda har yuzinchi paket yo'qotishini anglatadi. Buni miqdorga ko'paytirib faol birikmalar (ushbu tahlilda - beshta), yuz paketga beshta qabul qiluvchiga yuborilsa, beshtagacha xatolik hisoboti kelishi mumkin, ularning har biri ma'lumotlar uzatish tezligining pasayishiga olib keladi.

Ushbu vaziyatda haddan tashqari yuklanishni oyna usuli bilan nazorat qilish konsepsiyasi o'zini oqlamaydi (Window-Based Congestion Control) [8]. Ushbu sxema kam dinamiklikka ega va ko'pincha LFN tarmoqlarida sodir bo'lishi mumkin bo'lgan ma'lumotlarni uzatish sharoitlarining o'zgarishiga tezkorlik bilan javob bera olmaydi. Amaliyotda ma'lumotlarni uzatishning bir xil va doimiy muhitiga ega bo'lish faqat ma'lumotlarni uzatishning butun davrida butun tarmoqda qat'iy nazorat qilinadigan trafik miqdoriga ega bo'lgan xususiy optik aloqa liniyasi mavjud bo'lgandagina nisbatan kafolatlanishi mumkin, bu esa ko'pincha erishib bo'lmaydigan holatdir.

4. YUQORI TEZLIKDAGI KO'P OQIMLI TRAFIKNING MATEMATIK MODELLARINING TAHLILI

Yuqori tezlikdagi trafik o'zining notekisligi bilan xarakterlanadi. Bunday xatti-harakat bursty (impulsiv) deb ataladi. Bu modellarga mos kelmaydigan teletrafik nazariyalari [9], [10],[11],[12], kommutatsiya nazariyasi asoslari asosida qurilgan birinchi navbatda, telefon tarmoqlari uchun amal qiladi. Tarmoqlar asosida ma'lumotlarni uzatishda, paketlarni kommutatsiya qilish yotadi. Paketlar ko'pincha tarmoq qurilmasiga to'plamlar shaklida keladi [13], bu esa o'ta yuklanish ehtimolini oshiradi va uzatish tezligining tebranishini keltirib chiqaradi. Ko'pincha yuqori tezlikdagi trafik impulsiv xarakterga ega bo'lgan o'ziga o'xshash jarayon sifatida tavsiflanadi. Ushbu jarayonda impuls uzunligi, ya'ni kelgan paketdagi paketlar soni og'ir dumli taqsimot bilan taqsimlanadi.



8-Rasm - EAFRP modelini ishlash prinsipi



Uzoq vaqt davomida yuqori tezlikli trafikning asosiy modeli on/off (AFRP) modeli hisoblanib kelgan [13]. Ushbu modelda bir noaniqlik mavjud bo'lib, u modelni haqiqatdan biroz chetlashtiradi: on/off davrlarining davomiyligi normal (Gauss) taqsimotiga asoslanadi, bu esa yuqori tezlikli trafik uchun haqiqatga to'g'ri kelmaydi. Bu noaniqlik [14] da taqdim etilgan EAFRP nomli modelda tuzatilgan bo'lib, u ma'lumotlar tarmoqlaridagi yuqori tezlikli trafikning o'z-o'ziga o'xshashligini [10], [13], shuningdek, og'ir dumli taqsimot bilan tavsiflanuvchi impulsivligini ham hisobga oladi. EAFRP modelida "on" holatidagi tezlik miqdori, har bir "on" oralig'ida tezlik doimiy degan tasdiqqa asoslanuvchi AFRP modelidan farqli o'laroq, Pareto taqsimoti bilan tavsiflanadi. Har ikkala model ham bitta foydalanuvchidan chiquvchi trafikni tavsiflaydi va umumiy tarmoq trafiginini ko'plab ma'lumotlar oqimlarining superpozitsiyasi sifatida qaraydi va shu bilan paketli tarmoqlardagi yuqori tezlikli trafikning ishonchli modellashtirilishini ta'minlaydi.

EAFRP modelida tarmoqda ko'plab oqimlar paydo bo'lganda uni haqiqatdan uzoqlashtiradigan bir holat mavjud: [15] kanalning o'tkazish polosasi chekliligi va real tarmoqlarda mavjud bo'lgan ortiqcha yuklamalarni boshqarish mexanizmlari hisobga olinmaydi. [16] da taklif etilgan model EAFRPni yanada realroq holatga kengaytirib, tushuncha - ma'lum bir aloqa kanalida ma'lumotlarni uzatish tezligining maksimal qiymatini tavsiflovchi R kattalik. Taklif etilayotgan modelda har doim tengsizlik bajariladi.

$$R \geq \sum_{i=1}^N r_i \quad (3)$$

r_i - oqimlardan birida ma'lumotlarni uzatish tezligi (N tA ettiradi. Ushbu kengaytma ma'lumotlarni bir nechta qabul qiluvchilarga uzatishda trafikni modellashtirishda modeldan foydalanish imkonini beradi va ma'lumotlarni bir jo'natuvchidan bir nechta qabul qiluvchilarga uzatish algoritmlarini ishlab chiqishda muhim statistik xususiyatlarni hisobga olishga yordam beradi.

Bir oqimli model. Ma'lumotlar bir necha qabul qiluvchiga uzatilgan taqdirda, trafikning matematik modeli biroz murakkablashadi. Bunda yakuniy model N ning superpozitsiyasi hisoblanadi. Bu yerda N - qabul qiluvchilar soni. Binobarin, modellashtirishni jo'natuvchidan qabul qiluvchilardan biriga faqat bitta oqimni ko'rib chiqishdan boshlash kerak.

Ma'lumotlar oqimi ikkita holatga ega bo'lgan mohiyat sifatida qaraladi: "on" va "off." "on" oralig'ida ma'lumotlar alohida "on" oralig'ida o'zgarmas kattalik hisoblangan G_n tezlik bilan uzatiladi. "off" oralig'ida ma'lumotlar uzatilmaydi. X_i va Y_i "on" va "off" intervallarining davomiyligi sifatida qabul qilinadi. [17]-rasmda ko'rsatilganidek, manbadan generatsiya qilingan trafik oluvchilardan birining yo'llanmasida quyidagicha yoziladi:

$$s(t) = \sum_{n=0}^{\infty} G_n 1_{(S_n, S_n + X_{n+1})}(t) \quad (4)$$

Bunda S_n trafik uzatishning n-davri boshlanish vaqtini ifodalaydi.

[17]-ishda quyidagi taxminlar ilgari surilgan:

X va Y o'zaro bog'liq bo'lmagan va Pareto taqsimotiga ega bo'lib, ularning taqsimot funksiyalari quyidagicha: $F(x; x_1; K_1)$ yoki $F(x; x_0; K_0)$ da $1 < x_1, x_0 < 2G$ tezlik jarayoni yuqorida tavsiflangan qiymatli Pareto taqsimoti bilan tavsiflanadi. G taqsimot funksiyasi $F_L(x; \infty; K)$ va X va Y ga bog'liq emas. On/off davrlari davomiyligini tavsiflashda og'ir dumli



taqsimotdan foydalanishning asosi [13] da keltirilgan bo'lib, u on/off vaqt oraliqlarining uzunligi xulosa chiqarishda e'tiborsiz qoldirib bo'lmaydigan ehtimolliklar bilan juda katta bo'lishi mumkinligini ko'rsatadigan empirik kuzatuvlarga asoslanadi. On/off vaqt intervallari uzunliklarining dispersiyasi chekli deb faraz qilib, bir nechta oqimlarning superpozitsiyasi o'zini oq shovqin kabi tutadi, real o'lchovlardan kelib chiqqan holda yuqori tezlikdagi trafikka xos bo'lgan o'ziga o'xshashlik xususiyatlari keltirib chiqaradi.[18].

Aslida, G va X ning bog'liqligi haqidagi taxminni rad etishga to'g'ri keladi: yuklab olinayotgan fayl hajmi o'rtasida sezilarli bog'liqlik mavjud va ulanish tezligi bilan - Dial-Up'dan foydalanadigan oqim sezilarli darajada kamayadi katta hajmdagi fayllarni Internet tarmog'i orqali yuklab olish tarmoqqa keng polosali ulanish hosil boladi.[19]. Shuni ta'kidlash kerakki, keltirilgan rad etishning matematik noaniqligi tufayli G va X bundan keyin ham bir-biriga bog'liq bo'lmagan miqdorlar sifatida qaraladi. [14] da G ning "on" oraliqlardagi variatsiyasi cheksiz katta dispersiyali jarayon deb qaraladi. Bu yerda transport protokollarini algoritmlarni amalga oshirishga majbur qiladigan muhim omil - o'tkazish polosasining cheklanganligi hisobga olinmaydi. Ortiqcha yuklamalarni boshqarish [16] dagi model o'tkazish polosasi chegarasini kiritish orqali ushbu farazni hisobga oladi. Bu model ushbu bo'limda tavsiflangan N ta oqimning superpozitsiyasi bo'lib, [17] da keltirilgan.

Modelning cheklovlari. Muhim farazlardan biri quyidagilardan har birining tezligi o'zaro bog'liq emasligidir: oqimlarini bir-biridan ajratib turadi. Nazariy jihatdan, ushbu farazni rad etish mumkin, chunki klassik TCP holatida, har bir oqimda ishlaydigan o'ta yuklanishlarni boshqarish algoritmlari oqimlar o'rtasida qandaydir statistik bog'liqlikka olib keladi. Ushbu bog'liqlik nuqta-ko'p nuqta rejimida trafik uzatishda yaqqol namoyon bo'ladi: ma'lumotlarni uzatish tezligi jo'natuvchi tomonidan belgilanadi va aslida oqimlar bir-biriga bog'liq, chunki ma'lum bir sinxronlikka erishish uchun tezlik har bir oqim uchun moslashtirilishi kerak bo'ladi.

Internet tarmog'idagi oqimlarning 90% foizigacha bo'lgan qismi tezliklarni o'tkazish polosasi kabi tarmoq omillari bilan emas, balki bevosita ilovalar darajasida kuzatiladi [19]. Ortiqcha yuklanishning oshib ketish bilan bog'liq turi kanalning mavjud o'tkazish polosasi tarmoqlarda unchalik ustun emas, bu ko'plab ma'lumotlar oqimlariga xizmat ko'rsatadi. Bunday ortiqcha yuklanishlar tarmoqlarga to'g'ri keladi. DSL/ADSL texnologiyalarining tez-tez qo'llanilishi (Yevropada [21], [22] da ko'rsatilganidek), shuningdek, bog'lanish tezligiga qarab abonent to'lovi ustunlik qiladigan korporatsiyalarning bog'lanish tarif rejaları tufayli tashkil etiladi. Model bir nechta oqimlarning multipleksorlash nuqtasida R ga erishish mumkin emasligiga asoslangan bo'lsa-da, R hali ham muhim ahamiyatga ega. Aynan shu paytda R parametrining trafik xarakteriga ta'siri yuzaga keladi. Zero, marshrutizator navbatining bo'shishi, boshqa narsalardan (masalan, vaqt birligi ichida kelayotgan paketlar sonidan) qat'i nazar, R tezlik bilan sodir bo'ladi.

5. XULOSA.

IP-multicast asosida yotuvchi tushunchalar va protokollar ko'rib chiqildi. IP-multicast ma'lumotlarni manbadan bir nechta qabul qiluvchilarga ishonchli uzatishni tashkil etish uchun yagona yechim emasligi aniqlandi. IP-multicastning RFC 1112 hujjati asosida shakllanganligi va bugungi kunda IP-TV, IP-telefoniya hamda korporativ tizimlarda keng qo'llanilishi uning dolzarbligini ko'rsatadi. Shu bilan birga, multicast texnologiyasining ishlashida IGMP va PIM protokollarining muhim o'rni borligi, ular orqali guruhlarini boshqarish va trafikni marshrutlash samarali tashkil etilishi yoritildi.



IP-multicast texnologiyasi barcha holatlar uchun universal yechim emas. Uning asosiy kamchiligi paketlarni yetkazib berishning kafolatlanmaganligi bo'lib, bu holat uni yuqori ishonchlilik talab etiladigan tizimlarda qo'llashni cheklaydi. PIM protokolini ishlab chiqishda foydalanilgan yuqori tezlikdagi ko'p oqimli trafikning statistik xususiyatlari o'rganildi.

FOYDALANILGAN ADABIYOTLAR:

1. N. Kim. Detection of Multicast Video Flooding Attack using the Pattern of BandwidthProvisioning Efficiency / N. Kim, H. Lim, H. Park и M. Kang // *IEEE Commun. Lett.*, vol. 14, no. 12, Dec. 2010. C. 1170–1172.
2. A. F. Gomez-Skarmeta. IGMPv3-based method for avoiding DoS attacks in multicast-enabled networks / A. F. Gomez-Skarmeta, A. L. Mateo-Martinez и P. M. Ruiz-Martinez // in *Proceedings 25th Annual IEEE Conference on Local Computer Networks. LCN 2000*, P. 94–95.
3. W. Trappe. Staggered TESLA: a multicast authentication scheme resistant to DoS attacks // in *GLOBECOM '05. IEEE Global Telecommunications Conference, 2005*, vol. 3, P. 6
4. Hoang Lan Nguyen. Study of Different Types of Attacks on Multicast / Hoang Lan Nguyen and Uyen Trang Nguyen // in *Mobile Ad Hoc Networks, in International Conference on Networking, International Conference on Systems and International Conference on Mobile Communications and Learning Technologies (ICNICONSMCL '06)*, P. 149–149.
5. P. Anitha. An improved security mechanism for high-throughput multicast routing in wireless mesh networks against Sybil attack / P. Anitha, G. N. Pavithra и P. S. Periasamy // in *International Conference on Pattern Recognition, Informatics and Medical Engineering (PRIME-2012)*, P. 125–130.
6. M. Ahmad. A survey on TCP CUBIC variant regarding performance, M. Ahmad, A. Bin Ngadi, A. Nawaz, U. Ahmad, T. Mustafa и A. Raza // in *2012 15th International Multitopic Conference (INMIC)*, P. 409–412.
7. K. Ratna Pavani. Performance evaluation of TCP-Reno, TCP-Newreno and TCP-Westwood on burstification in an OBS network / K. Ratna Pavani и N. Sreenath // in *2012 18th International Conference on Advanced Computing and Communications (ADCOM)*, P. 19–24.
8. M. Borri, A. Ferrarini и M. L. Merani // Window-Based and Rate-Based Congestion Controls: a Local Stability Analysis under Variable RTT Conditions and the Proposal of an RTP-Based Algorithm, in *2007 IEEE International Conference on Communications*, P. 6149–6155.
9. V. Paxson. Wide area traffic: the failure of Poisson modeling / V. Paxson и S. Floyd // *IEEE/ACM Trans. Netw.*, vol. 3, no. 3, Jun. 1995. C. 226–244
10. M. E. Crovella. Self-similarity in World Wide Web traffic: evidence and possible causes / M. E. Crovella и A. Bestavros // *IEEE/ACM Trans. Netw.*, vol. 5, no. 6, 1997. C. 835–846
11. M. D. Logothetis. Teletraffic models beyond Erlang / M. D. Logothetis и I. D. Moscholios // in *2014 ELEKTRO*, P. 10–15.
12. S. Bates. Testing the Gaussian assumption for self-similar teletraffic models / S. Bates и S. McLaughlin // in *Proceedings of the IEEE Signal Processing Workshop on Higher-Order Statistics*, 1997, P. 444–447.
13. R. Jain. Packet Trains--Measurements and a New Model for Computer Network Traffic / R. Jain и S. Routhier // *IEEE J. Sel. Areas Commun.*, vol. 4, no. 6, Sep. 1986. C. 986–995



14. W. Willinger. Self-similarity through high-variability: statistical analysis of Ethernet LAN traffic at the source level / W. Willinger, M. S. Taqqu, R. Sherman и D. V. Wilson // *IEEE/ACM Trans. Netw.*, vol. 5, no. 1, 1997. C. 71–86
15. A. P. Petropulu. The extended alternating fractal renewal process for modeling traffic in high - speed communication networks // *IEEE Trans. Signal Process.*, vol. 49, no. 7, Jul. 2001. C. 1349–1363
16. A. T. Andersen. An application of superpositions of two state Markovian source to the modeling of self-similar behaviour / A. T. Andersen and B. F. Nielsen // in *Proceedings of INFOCOM '97*, vol. 1, P. 196–204
17. A. A. Petropulu. Rate-limited EAFRP-a new improved model for high-speed network traffic, A.A. Petropulu and H. Sethu // *IEEE Trans. Signal Process.*, vol. 53, no. 2, Feb. 2005. P. 505–522
18. IEEE Xplore полнотекстовый HTML; Rate-limited EAFRP-a new improved model for high-speed network traffic. W. E. Leland. On the self-similar nature of Ethernet traffic (extended version), W. E. Leland, M. S. Taqqu, W. Willinger и D. V. Wilson // *IEEE/ACM Trans. Netw.*, vol. 2, no. 1, 1994. C. 1–15.
19. S. S. Y. Zhang. On the characteristics and origins of Internet flow rates / S. S. Y. Zhang, L. Breslau и V. Paxson // in *ACM SIGCOMM*, 2002.
20. C. Fraleigh. No TitPacket-Level Traffic Measurements From a Tier-1 IP Backbone / C. Fraleigh and S. Moon // 2001.
21. K. Stordahl. Broadband demand and the role of new technologies // in *Networks 2008 - The 13th International Telecommunications Network Strategy and Planning Symposium*, vol. Supplement, P. 1–8.
22. B. E. Wolfinger // Keynote lecture research challenges and proposed solutions to improve availability and quality-of-service in future IPTV systems, in *2012 IEEE 8th International Conference on Intelligent Computer Communication and Processing*.

SENSOR NAZORAT-O'LCHOV MA'LUMOTLARINI MOBIL ALOQA TARMOQLARIDA UZATISHNING ASOSIY XUSUSIYATLARI VA TALABLARI

**Nazarov Abdulaziz Muminovich¹, Baymatova Nargiza Tuxtabayevna²,
Jumaqulov Foziljon Komiljonovich³, Rayimov Farrux To'ra o'g'li⁴**

¹TDTU, "Radiotexnik qurilmalar va tizimlar" kafedrasi professori. t.f.d., nazarov58@rambler.ru

²TDTU, "Radiotexnik qurilmalar va tizimlar" kafedrasi katta
o'qituvchisi, baymatovanargiz77@gmail.com

³TDTU, "Radiotexnik qurilmalar va tizimlar" kafedrasi tayanch doktoranti,
foziljonkomiljonovich@gmail.com

⁴TDTU, "Radiotexnik qurilmalar va tizimlar" kafedrasi tayanch doktoranti,
farruxrayimov16@gmail.com

Annotatsiya – Ushbu maqolada sensor tarmoqlarida nazorat-o'lchov ma'lumotlarini mobil aloqa tarmoqlari orqali uzatishning asosiy xususiyatlari va texnik talablari tahlil qilingan. Ma'lumotlarning turlari (skalar, vektor, multimedia va voqea ma'lumotlari) hamda ularning hajmi, uzatish chastotasi va vaqtinchalik xususiyatlari batafsil ko'rib chiqilgan. O'tkazuvchanlik,



kechikish vaqti, paket yo'qotish darajasi, energiya samaradorligi va xavfsizlik talablari miqdoriy ifodalar va formulalar orqali asoslangan. Mobil aloqa texnologiyalari (NB-IoT, LTE-M, 5G) asosida ishlashga mo'ljallangan CoAP va MQTT protokollari, shuningdek, ma'lumotlarni siqish algoritmlari taqqoslangan. Zamonaviy tadqiqotlar va mavjud muammolar – signal tarqalishi, spektr cheklovi, ishonchlilik, xavfsizlik tahdidlari – tizimli ravishda baholangan. O'zbekiston geografik va iqlimiy sharoitlari, mobil qamrov cheklovlari va standartizatsiya muammolari nuqtai nazaridan gibridd arxitektura yechimlari taklif etilgan.

***Kalit so'zlar.** sensor tarmoqlari, simsiz sensor tarmoqlari, nazorat-o'lchov ma'lumotlari, mobil aloqa, energiya samaradorligi, kechikish vaqti, paket yo'qotish.*

1.KIRISH.

Sensor tarmoqlari (Wireless Sensor Networks, WSN) – bu fazoviy tarqoq joylashtirilgan, avtonom sensor tugunlaridan tashkil topgan, fizik yoki atrof-muhit parametrlarini kuzatish va ma'lumotlarni simsiz ravishda uzatish uchun mo'ljallangan tarmoqdir [1]. Sensor tarmoqlari zamonaviy nazorat-o'lchov tizimlarining muhim tarkibiy qismi hisoblanadi va turli sohalarda keng qo'llanilmoqda.

Sensor tuguni (sensor node) – bu bir yoki bir nechta sensorlar, mikroprotsessor, simsiz aloqa moduli va quvvat manbaidan (odatda batareya) iborat mikrotizimdir [2]. Har bir tugun mustaqil ravishda ma'lumotlarni yig'ish, dastlabki qayta ishlash va tarmoq orqali uzatish imkoniyatiga ega.

Mavjud tadqiqotlar [3-5] sensor tarmoqlarining turli arxitektura variantlarini taklif qiladi, ammo mobil aloqa texnologiyalari (NB-IoT, LTE-M, 5G) bilan to'liq integratsiyalashgan yechimlar yetarli darajada ishlab chiqilmagan. O'zbekiston geografik va iqlimiy sharoitlarini hisobga olgan holda [6-8], gibridd arxitektura ishlab chiqish zarur.

2. ASOSIY QISM.

Sensor tarmoqlarida nazorat-o'lchov ma'lumotlari turli xil fizik va kimyoviy parametrlarni o'lchash natijalarini o'z ichiga oladi. Ushbu ma'lumotlarning turlari va ularning xususiyatlarini to'g'ri tushunish samarali uzatish tizimini loyihalash uchun muhim ahamiyatga ega [9-10].

Nazorat-o'lchov ma'lumotlarini quyidagi asosiy turlarga ajratish mumkin:

Skalar ma'lumotlar – oddiy raqamli qiymatlar (harorat, bosim, namlik, tezlik va h.k.). Bu turdagi ma'lumotlar hajmi juda kichik bo'lib, odatda 2-16 bayt oralig'ida joylashadi. Masalan, harorat o'lchovi uchun 16-bitli ADC (Analog-to-Digital Converter) dan foydalanilganda, bitta o'lchov natijasi 2 bayt ma'lumotni tashkil etadi. Skalar ma'lumotlarning yuborilish chastotasi turli ilovalar uchun 1 soniyadan 1 soatgacha farq qilishi mumkin [11].

Vektor ma'lumotlar – bir nechta o'zaro bog'liq parametrlarning birgalikdagi qiymatlari (masalan, uch o'lchovli tezlanish sensori ma'lumotlari: a_x , a_y , a_z). Vektor ma'lumotlar 6-48 bayt hajmni egallaydi va odatda yuqori chastotada (10-1000 Hz) yuborilishi talab etiladi. Vibratsiya monitoringi tizimlarida FFT (Fast Fourier Transform) algoritmi yordamida qayta ishlangan spektral ma'lumotlar ham vektor ma'lumotlar sinfiga kiradi.

Multimedia ma'lumotlar – audio, video va tasvir ma'lumotlari. Bu turdagi ma'lumotlar hajmi juda katta bo'ladi: harakatsiz tasvir 50-500 KB, video oqim esa 100 Kbps dan 10 Mbps gacha o'tkazuvchanlikni talab qiladi. Sanoat monitoringi va xavfsizlik tizimlarida video ma'lumotlarni uzatish uchun H.264, H.265 (HEVC) kabi siqish algoritmlaridan foydalaniladi [12].



Voqea ma'lumotlari (Event data) – muayyan voqea yuz berganda uzatiladigan maxsus xabarlar. Masalan, yong'in signalizatsiya tizimida tutun sensori ishga tushganda yoki sanoat uskunasi nosozlik aniqlanganda yuboriladi. Bu turdagi ma'lumotlar hajmi kichik (10-100 bayt), lekin ularga nisbatan yuqori ustuvorlik beriladi va kechikishsiz yetkazilishi talab etiladi.

Nazorat-o'lchov ma'lumotlarining asosiy xususiyatlari quyidagilardan iborat:

- Davriylik – ma'lumotlar muntazam vaqt oralig'ida yig'iladi va uzatiladi. Periodiklik sensor turi va ilova talablariga bog'liq: meteorologik monitoringda 10-60 daqiqa, sanoat jarayonlarida 1-10 soniya, tibbiy monitoringda 0.1-1 soniya oralig'i qo'llaniladi.

- Aniqlik va rezolyutsiya – o'lchov natijalari ma'lum aniqlik darajasiga ega bo'lishi kerak. Masalan, harorat o'lchashda $\pm 0.5^{\circ}\text{C}$ aniqlik, bosim o'lchashda $\pm 1\%$ aniqlik talab etilishi mumkin. ADC rezolyutsiyasi odatda 10-16 bit oralig'ida tanlanadi [13].

- Ishonchlilik talablari – nazorat-o'lchov ma'lumotlari yo'qolishi yoki buzilishi tizim ishlashiga salbiy ta'sir ko'rsatishi mumkin. Turli ilovalar uchun turli darajadagi ishonchlilik talablari mavjud: kritik tizimlar uchun 99.99% ishonchlilik, oddiy monitoring tizimlari uchun 95-99% ishonchlilik etarli [9].

- Vaqt metkalari (timestamps) – har bir o'lchov natijasi qachon olinganligini aniqlash uchun vaqt metkalari bilan ta'minlanadi. Bu ayniqsa turli manbalardan kelgan ma'lumotlarni sinxronlash va tahlil qilishda muhimdir. Vaqt sinxronizatsiyasi aniqligiga nisbatan yuqori talablar qo'yiladi: odatda $\pm 1-100$ ms oralig'ida [14].

Ma'lumotlarni uzatishda asosiy talablar. Sensor tarmoqlarida nazorat-o'lchov ma'lumotlarini uzatish jarayonida bir qator texnik va funktsional talablarga rioya qilish zarur. Bu talablar tizimning samarali va ishonchli ishlashini ta'minlaydi [15-16].

O'tkazuvchanlik (throughput) talablari. Tarmoq o'tkazuvchanligi turli ilovalar uchun keng oralig'da o'zgaradi. Oddiy skalar sensorlar uchun 1-10 Kbps, ko'p parametrlil monitoring tizimlari uchun 10-100 Kbps, multimedia sensorlar uchun esa 100 Kbps dan 10 Mbps gacha o'tkazuvchanlik talab qilinadi. Tarmoqning umumiy o'tkazuvchanligi N ta sensor tuguni uchun quyidagi formula bilan hisoblanadi:

$$T_{total} = \sum_{i=1}^N (D_i \cdot f_i) \quad (1)$$

bu yerda T_{total} – umumiy talab qilinadigan o'tkazuvchanlik (bps), D_i – i -sensor yuboradigan ma'lumot hajmi (bit), f_i – i -sensorning yuborish chastotasi (Hz), N – sensor tugunlari soni.

Mobil aloqa texnologiyalarida kanal o'tkazuvchanligi Shannon-Hartley teoremasi asosida aniqlanadi:

$$C = B \cdot \log_2 (1 + SNR) \quad (2)$$

bu yerda: C – maksimal kanal o'tkazuvchanligi (bps), B – kanal kengligi (Hz), SNR – signal-shovqin nisbati.

Kechikish vaqti (latency) talablari. Kechikish vaqti ma'lumotning sensor tugunidan baza stantsiyasiga yoki oxirgi foydalanuvchiga yetib borishiga ketgan umumiy vaqtni bildiradi. Turli ilovalar uchun kechikishga nisbatan turli talablar mavjud (1-rasm):

- Kritik real-time tizimlar (tibbiyot monitoringi, sanoat xavfsizligi) – 10-50 ms;




- Real-time tizimlar (transport monitoringi, avtomatlashtirilgan boshqaruv) – 50-200 ms;
 - Near real-time tizimlar (ekologik monitoring, aqlli shahar) – 200 ms - 2 s;
 - Non-real-time tizimlar (statistik ma'lumot yig'ish) – 2-60 s.
- Umumiy kechikish vaqti quyidagi tarkibiy qismlardan iborat:

$$T_{\text{latency}} = T_{\text{sensing}} + T_{\text{processing}} + T_{\text{transmission}} + T_{\text{propagation}} + T_{\text{queue}} \quad (3)$$

bu yerda: T_{sensing} – o'lchov vaqti, $T_{\text{processing}}$ – qayta ishlash vaqti, $T_{\text{transmission}}$ – uzatish vaqti, $T_{\text{propagation}}$ – tarqalish vaqti, T_{queue} – navbatda kutish vaqti.

Paket yo'qotish (packet loss) talablari. Ma'lumot paketlarining yo'qolishi tizim ishlashiga salbiy ta'sir ko'rsatadi. Turli ilovalar uchun ruxsat etilgan paket yo'qotish darajasi quyidagicha belgilanadi:



1-rasm. Turli ilovalar uchun kechikish talablari

- Yuqori kritikli tizimlar – 0.1% dan kam;
- O'rtacha kritikli tizimlar – 0.1-1%;
- Past kritikli tizimlar – 1-5%.

Paket yo'qotish ehtimolligini kamaytirish uchun turli usullar qo'llaniladi: Automatic Repeat Request (ARQ), Forward Error Correction (FEC), adaptiv modulyatsiya va kodlash [10, 17].

Energiya samaradorligi talablari. Sensor tugunlari odatda batareya bilan ishlaydi va uzatish jarayoni eng ko'p energiya iste'mol qiladigan operatsiya hisoblanadi. Bitta ma'lumot paketini uzatish uchun sarflanadigan energiya quyidagi formula bilan hisoblanadi:

$$E_{tx} = (P_{tx} \cdot T_{tx}) + (P_{rx} \cdot T_{rx}) + E_{\text{processing}} \quad (4)$$



bu yerda: P_{tx} – uzatish quvvati (W), T_{tx} – uzatish vaqti (s), P_{rx} – qabul qilish quvvati (W), T_{rx} – qabul qilish vaqti (s), $E_{processing}$ – qayta ishlash energiyasi (J).

Energiya samaradorligini oshirish uchun quyidagi strategiyalar qo'llaniladi:

- Ma'lumotlarni agregatsiya qilish (data aggregation);
- Adaptiv uzatish quvvati (adaptive transmission power);
- Uyqu rejimlari (sleep modes): PSM va eDRX;
- Ma'lumotlarni siqish algoritmlari.


Xavfsizlik va shifrlash talablari. Nazorat-o'lchov ma'lumotlarining maxfiyligi va yaxlitligini ta'minlash uchun shifrlash mexanizmlari qo'llaniladi. Zamonaviy IoT tizimlarda quyidagi xavfsizlik protokollari ishlatiladi: DTLS (Datagram Transport Layer Security), IPsec, OSCORE (Object Security for Constrained RESTful Environments). Shifrlash algoritmlari sifatida AES-128, AES-256, ECC (Elliptic Curve Cryptography) keng qo'llaniladi [18].

Shifrlash qo'shimcha energiya sarfi va kechikishni keltirib chiqaradi. AES-128 shifrlash uchun qo'shimcha energiya sarfi:

$$E_{encryption} = E_{key} + (N_{blocks} \cdot E_{block}) \quad (5)$$

bu yerda: E_{key} – kalit generatsiyasi energiyasi, N_{blocks} – bloklar soni, E_{block} – bitta blokni shifrlash energiyasi.

Mobil aloqa texnologiyalarida ma'lumot uzatish protokollari. Sensor tarmoqlarida nazorat-o'lchov ma'lumotlarini mobil aloqa orqali uzatishda turli protokollar qo'llaniladi. Protokol tanlovi ilova talablari, energiya cheklovi va tarmoq xususiyatlariga bog'liq [19].



2-rasm. Mobil aloqa asosidagi sensor tarmoqlar protokol steki



Protokol steki. Mobil aloqa asosidagi sensor tarmoqlarda quyidagi protokol steki ishlatiladi (2-rasm):

- Ilova qatlami – CoAP (Constrained Application Protocol), MQTT (Message Queuing Telemetry Transport), HTTP/HTTPS;
- Transport qatlami – UDP (User Datagram Protocol), TCP (Transmission Control Protocol), QUIC;
- Tarmoq qatlami – IPv6, 6LoWPAN (IPv6 over Low-Power Wireless Personal Area Networks);
- Kanal qatlami – NB-IoT, LTE-M, 5G NR;
- Fizik qatlami – radio interfeys.

CoAP protokoli. CoAP – bu cheklangan resurslarga ega IoT qurilmalari uchun maxsus ishlab chiqilgan ilova qatlami protokolidir. CoAP HTTP REST arxitekturasiga o'xshash, lekin UDP ustida ishlaydi va juda kam resurs talab qiladi. CoAP xabar hajmi 10-100 bayt oralig'ida bo'lib, bu energiya tejamkorligini ta'minlaydi [15].

CoAP ning asosiy xususiyatlari:

- Observe mexanizmi – sensorlar o'zgarishlar haqida avtomatik xabar beradi;
- Block-wise uzatish – katta hajmli ma'lumotlarni kichik bloklarga bo'lib uzatish;
- Multicast qo'llab-quvvatlash;
- DTLS orqali xavfsizlik.

MQTT protokoli. MQTT – bu publish/subscribe arxitekturasiga asoslangan, IoT tizimlari uchun keng qo'llaniladigan protokol. MQTT broker orqali ma'lumotlar almashish tizimini ta'minlaydi va QoS (Quality of Service) darajalarini qo'llab-quvvatlaydi [16]:

- QoS 0 – "at most once", eng tez, paket yo'qotish mumkin;
- QoS 1 – "at least once", takroriy paketlar bo'lishi mumkin;
- QoS 2 – "exactly once", eng ishonchli, lekin sekin.

Nazorat-o'lchov ma'lumotlari uchun odatda QoS 1 yoki QoS 2 tanlanadi.

Ma'lumotlarni siqish va kodlash. Mobil aloqa kanalining cheklangan o'tkazuvchanligi va batareya resurslarini tejash maqsadida ma'lumotlarni siqish algoritmlari qo'llaniladi. Skalar ma'lumotlar uchun delta kodlash, Run-Length Encoding (RLE) usullari samarali. Multimedia ma'lumotlar uchun JPEG, H.264, H.265 kabi standart siqish algoritmlari ishlatiladi [12].

Delta kodlash printsipli: faqat o'zgarishlar uzatiladi, bu ma'lumot hajmini 50-70% ga kamaytiradi:

$$\Delta x_i = x_i - x_{i-1} \quad (6)$$

bu yerda: Δx_i – i -o'lchov o'zgarishi, x_i – joriy qiymat, x_{i-1} – oldingi qiymat.

O'zbekiston sharoitida qo'llanish xususiyatlari. O'zbekiston geografik va iqlimiy sharoitlari sensor tarmoqlarida nazorat-o'lchov ma'lumotlarini uzatishda qo'shimcha talablar va muammolar keltirib chiqaradi [6-7].

Geografik va iqlimiy omillar. O'zbekistonning katta hududi (448,978 km²) va kontinental iqlimi sensor tarmoqlari dizaynida quyidagi omillarni hisobga olishni talab qiladi:

- Harorat diapazoni: -30°C dan +50°C gacha;
- Yuqori chang va chang bo'ronlari – sensorlarning himoya darajasi IP65 va undan yuqori bo'lishi kerak;



- Quyosh radiatsiyasi intensivligi yuqori – quyosh panellaridan foydalanish imkoniyati.

Mobil aloqa qamrovi cheklovlari. Qishloq joylarida va cho‘l hududlarida mobil aloqa signali zaif yoki yo‘q. Bu muammoni hal qilish uchun quyidagi yechimlar taklif etiladi:

- Gibril topologiya: sensor tugunlar mesh tarmoq orqali bir-biriga ulanib, bir yoki bir nechta gateway tugun mobil aloqa orqali markaziy serverga ulanadi;
- Satellite IoT texnologiyalaridan foydalanish (masalan, LoRaWAN + satellite backhaul);
- Ma‘lumotlarni lokalda saqlash va mobil aloqa mavjud bo‘lganda uzatish (store-and-forward).

Xulosa qilib aytganda, sensor tarmoqlarida nazorat-o‘lchov ma‘lumotlarini uzatish jarayonida ma‘lumot turi, hajmi, uzatish chastotasi, kechikish, ishonchlik va energiya sarfi talablari hisobga olinishi zarur. Mobil aloqa texnologiyalari (NB-IoT, LTE-M, 5G) ushbu talablarni qondirishga qodir. Protokol tanlovi (CoAP, MQTT) va ma‘lumotlarni siqish algoritmlari energiya samaradorligini oshiradi. O‘zbekiston sharoitida geografik va iqlimiy omillar, shuningdek, mobil qamrov cheklovi hisobga olinishi kerak.

3. ZAMONAVIY TADQIQOTLAR VA YECHIMLAR TAHLILI.

Sensor tarmoqlarida mobil aloqa texnologiyalaridan foydalanish so‘nggi 10 yil davomida jadal rivojlanib kelmoqda. Xalqaro tadqiqotlar NB-IoT, LTE-M va 5G texnologiyalarining sensor tarmoqlari uchun keng imkoniyatlar yaratishini ko‘rsatmoqda [20-21]. Ayniqsa, IoT qurilmalari soni 2025-yilga kelib 75 milliarddan oshishi kutilmoqda, bu esa mobil operatorlar uchun yangi bozor segmentini shakllantirmoqda [22].

Zamonaviy tadqiqotlar quyidagi asosiy yo‘nalishlarda olib borilmoqda:


Energiya samaradorligini oshirish. NB-IoT va LTE-M texnologiyalari uchun yangi energiya tejankor algoritmlar ishlab chiqilmoqda. PSM (Power Saving Mode) va eDRX (extended Discontinuous Reception) mexanizmlari batareya umrini 10 yilgacha uzaytirish imkonini beradi [23]. Tadqiqotlar shuni ko‘rsatadiki, adaptiv uzatish quvvati va optimal ma‘lumot uzatish strategiyasi energiya sarfini 40-60% ga kamaytirishi mumkin.

QoS (Quality of Service) ta‘minlash. Turli turdagi sensor ma‘lumotlari uchun differentsiallangan xizmat ko‘rsatish mexanizmlari ishlab chiqilmoqda. 3GPP Release 16 va 17 da kiritilgan yangi xususiyatlar critical IoT ilovalarini qo‘llab-quvvatlashga imkon beradi [24]. Bu ayniqsa tibbiy monitoring va sanoat avtomatikasi kabi real-time tizimlar uchun muhimdir.

Edge computing integratsiyasi. Sensor ma‘lumotlarini tarmoq chetida (edge) qayta ishlash latensiyani kamaytirish va markaziy server yuklamasini kamaytirishga yordam beradi. Multi-access Edge Computing (MEC) arxitekturasini sensor tarmoqlar bilan integratsiyalashtirilmoqda [25].

Texnik muammolar va cheklovlar. Sensor tarmoqlarida mobil aloqa texnologiyalaridan foydalanishda bir qator texnik muammolar va cheklovlar mavjud:

Signal tarqalishi va qamrov muammolari. NB-IoT va LTE-M texnologiyalari keng qamrov ta‘minlasa-da, bino ichidagi chuqur penetratsiya (deep indoor penetration) va tog‘li hududlarda signal zaiflashuvi muammosi mavjud (3-rasm).



3-rasm. Signal quvvatining masofaga bog‘liqligi

Path loss modeli quyidagicha ifodalanadi:

$$PL(d) = PL_0 + 10n \log_{10}(d/d_0) + X_\sigma \quad (7)$$

bu yerda: $PL(d)$ – masofa d dagi yo‘qotish (dB), PL_0 – mos yozuvlar masofasidagi yo‘qotish, n – yo‘l yo‘qotish ko‘rsatkichi (2-6 oralig‘ida), d_0 – mos yozuvlar masofasi (1 m), X_σ – shadow fading (Gaussian tasodifiy o‘zgaruvchi).

Interferensiya va spektr cheklovlari. Litsenziyalangan chastota diapazonlarida ishlash afzalliklarga ega bo‘lsa-da, spektr resurslari cheklangan. NB-IoT bir LTE PRB (Physical Resource Block) ichida ishlaydi, bu esa maksimal tezlikni 250 Kbps ga cheklaydi [26]. Ko‘p sonli qurilmalar bir vaqtda ulanishga harakat qilganda collision va random access overload muammolari yuzaga keladi.

Energiya sarfi va batareya umri. Nazariy jihatdan 10 yillik batareya umri va‘da qilinsa-da, amaliy sharoitlarda bu ko‘rsatkich turli omillarga bog‘liq. Energiya balansi tenglamasi:

$$E_{\text{total}} = E_{\text{sensing}} + E_{\text{processing}} + E_{\text{transmission}} + E_{\text{idle}} \quad (8)$$

bu yerda: E_{sensing} – sensorlash energiyasi, $E_{\text{processing}}$ – qayta ishlash energiyasi, $E_{\text{transmission}}$ – uzatish energiyasi, E_{idle} – kutish rejimi energiyasi.

Tadqiqotlar shuni ko‘rsatadiki, uzatish jarayoni umumiy energiya sarfining 60-80% ini tashkil etadi [27]. PSM va eDRX rejimlarini optimal sozlash batareya umrini 3-5 barobar oshirishi mumkin.

Ishonchlilik va xavfsizlik muammolari. Sensor tarmoqlarida mobil aloqa orqali ma‘lumot uzatishda ishonchlilik va xavfsizlik muhim ahamiyatga ega:

Paket yo‘qotish va retransmission. Zaif signal sharoitida va interferensiya ta‘sirida paket yo‘qotish ehtimolligi ortadi. HARQ (Hybrid Automatic Repeat Request) mexanizmi qo‘llanilsa-da, bu qo‘shimcha kechikish va energiya sarfiga olib keladi. Paket muvaffaqiyat ehtimolligi:

$$P_{\text{success}} = 1 - (1 - P_{\text{tx}})^N \quad (9)$$

bu yerda: P_{tx} – birinchi urinishdagi muvaffaqiyat ehtimolligi, N – maksimal qayta urinishlar soni.

Xavfsizlik tahdidlari. IoT qurilmalari uchun asosiy xavfsizlik tahdidlari quyidagilardan iborat: DDoS hujumlari, Man-in-the-Middle (MITM) hujumlari, ma'lumotlarni o'g'irlash va qurilmalarni masofadan boshqarib olish. 3GPP standartlari AES-128 shifrlash va mutual authentication mexanizmlarini taqdim etsa-da, ko'plab IoT qurilmalar cheklangan hisoblash resurslari tufayli murakkab shifrlash algoritmlarini qo'llay olmaydi [28].

O'zbekiston sharoitidagi muammolar. O'zbekistonda sensor tarmoqlarida mobil aloqa texnologiyalaridan foydalanishda o'ziga xos muammolar mavjud:

Geografik va infrastruktur cheklovlar. Mamlakatning katta hududi (448,978 km²) va aholi zichligining notekis taqsimlanishi mobil qamrovni ta'minlashni qiyinlashtiradi. Qishloq joylarida va cho'l hududlarida 4G qamrov 40-50% ni tashkil etadi, bu sensor tarmoqlarini keng ko'lamda joriy etishni cheklaydi [7].

Iqlimiy sharoitlar ta'siri. O'zbekistonning kontinental iqlimi va yuqori harorat amplitudasi (-30°C dan +50°C gacha) sensor qurilmalarining ishlashiga ta'sir ko'rsatadi. Batareya samaradorligi yuqori haroratlarda 20-30% ga kamayadi. Shuningdek, chang bo'ronlari va yuqori namlik antenna va elektronika komponentlariga salbiy ta'sir ko'rsatadi.

Standartizatsiya va sertifikatsiya yo'qligi. O'zbekistonda IoT va sensor tarmoqlar uchun milliy standartlar va sertifikatsiya tizimi hali to'liq shakllanmagan. Bu import qurilmalarning yuqori narxi va mahalliy ishlanmalarning rivojlanishini sekinlashtiradi [8].

Kadrlar va texnik xizmat ko'rsatish muammolari. Sensor tarmoqlar va IoT texnologiyalari bo'yicha malakali mutaxassislar yetishmasligi loyihalarni joriy etish va texnik xizmat ko'rsatishni qiyinlashtiradi. Shuningdek, uzoq hududlarda joylashgan sensor tugunlariga xizmat ko'rsatish logistik muammolar tug'diradi.

4. XULOSA.

Ushbu maqolada sensor tarmoqlarida nazorat-o'lchov ma'lumotlarini mobil aloqa texnologiyalari orqali uzatishning nazariy asoslari, texnik talablari va amaliy muammolari tizimli ravishda tahlil qilindi. Olib borilgan tahlil asosida quyidagi xulosalar shakllandi.

Birinchidan, nazorat-o'lchov ma'lumotlarining turi (skalar, vektor, multimedia, voqea) uzatish tizimiga qo'yiladigan talablarni to'g'ridan-to'g'ri belgilaydi. Skalar ma'lumotlar uchun NB-IoT texnologiyasi (1–10 Kbps) etarli bo'lsa, multimedia ma'lumotlari uchun LTE-M yoki 5G texnologiyalari zarur bo'ladi. Turli ilovalar uchun kechikish talablari 10 ms dan 60 soniyagacha keng oraliqda farqlanadi va texnologiya tanlovi aynan shu mezon asosida amalga oshirilishi kerak.

Ikkinchidan, energiya samaradorligi sensor tarmoqlarining markaziy muammosi bo'lib qolmoqda. Uzatish jarayoni umumiy energiya sarfining 60–80% ini tashkil etishi hisobga olinsa, PSM va eDRX rejimlarini optimal sozlash, delta kodlash va adaptiv uzatish quvvati strategiyalarini birlashtirish batareya umrini 3–5 barobar uzaytirish imkonini beradi. Ayniqsa, masofaviy hududlarda quyosh panellari bilan kombinatsiyalangan energiya tejankor arxitekturalar istiqbolli yechim sifatida ko'rib chiqilishi kerak.

Uchinchidan, protokol tanlovi ilova talablariga muvofiq amalga oshirilishi lozim: real-vaqt tizimlari va tez-tez o'zgarib turadigan ma'lumotlar uchun CoAP (UDP ustida, minimal 10–100



baytli xabar hajmi) afzalroq, murakkab topologiyali tizimlar va uzatish kafolati talab qilinadigan holatlar uchun esa MQTT (QoS 1 yoki QoS 2) maqsadga muvofiq. Ma'lumotlarni delta kodlash orqali siqish esa kanaldan foydalanish samaradorligini 50–70% ga oshiradi.

To'rtinchidan, O'zbekiston sharoitida (448 978 km² hudud, -30°C dan +50°C gacha harorat diapazoni, qishloq hududlarida 4G qamrovining 40–50% darajasi) gibrid arxitektura zarurati alohida ahamiyat kasb etadi. Sensor tugunlarini mesh tarmoq orqali gateway–NB-IoT sxemasiga birlashtirish va “store-and-forward” printsiptan foydalanish qamrov muammosini qisman hal etadi. Shuningdek, mamlakatda IoT va sensor tarmoqlari uchun milliy standartlar va sertifikatlash tizimini shakllantirish, tarmoqni joriy etish va texnik xizmat ko'rsatish bo'yicha malakali mutaxassislar tayyorlash kelajakdagi tadqiqotlar va davlat siyosatining ustuvor yo'nalishi bo'lishi lozim.

Umumiy xulosada shuni ta'kidlash lozimki, sensor tarmoqlari va mobil aloqaning integratsiyasi “Raqamli O'zbekiston-2030” strategiyasining qishloq xo'jaligi monitoringi, ekologik nazorat, aqlli shahar va sanoat avtomatikasi kabi muhim yo'nalishlarida keng imkoniyatlar ochadi. Kelajakdagi tadqiqotlar sun'iy intellekt algoritmlari va Edge Computing yechimlarini sensor tarmoqlariga integratsiyalash, shuningdek, O'zbekiston sharoitida sinovdan o'tkazilgan mahalliy prototiplar yaratishga qaratilishi maqsadga muvofiq.

FOYDALANILGAN ADABIYOTLAR:

1. Akyildiz I.F., Su W., Sankarasubramaniam Y., Cayirci E. Wireless sensor networks: a survey // Computer Networks. – 2002. – Vol. 38, No. 4. – P. 393-422.
2. А. М. Бершадский, Л. С. Курилов, А. Г. Финогеев. Обзор методов маршрутизации в беспроводных сенсорных сетях // Технические науки. Информатика, вычислительная техника. – 2012. – №1(21). – С. 47-57.
3. Горячев В.А., Аверкин А.Н. Беспроводные сенсорные сети XXI в // Системный анализ в науке и образовании. – 2021. – №4. – С. 72-76.
4. Chowdhury A., Karmakar G., Kamruzzaman J., Islam S. Trustworthiness of Self-Driving Vehicles // IEEE Trans. on Intelligent Transportation Systems. – 2021. – Vol. 22, No. 6. – P. 3282-3301.
5. П.В. Галкин. Анализ энергопотребления узлов беспроводных сенсорных сетей // Scientific Journal «ScienceRise», №2(2), – 2014. – С. 55-61.
6. O'zbekiston Respublikasi Raqamli texnologiyalarni rivojlantirish vazirligi. Mobil aloqa statistikasi // <https://digital.gov.uz>. – 2024.
7. O'zbekiston Respublikasi Prezidentining 2020-yil 5-oktabrdagi PQ-4842-sonli "Raqamli O'zbekiston-2030" strategiyasini tasdiqlash to'g'risida"gi qarori.
8. O'zbekiston Respublikasi Prezidentining 2023-yil 28-avgustdagi PF-158-sonli "2023-2026 yillarda sun'iy intellektni rivojlantirish strategiyasi to'g'risida"gi farmoni.
9. В.И. Парфенов, Л.В. Донг. Беспроводные сенсорные сети. Принципы комплексирования информации от сенсоров при обнаружении объекта излучения. – Инфра-Инженерия, 2025. – 105 с.
10. Kamal A.R.M., Bleakley C.J., Dobson S. Packet-level attestation for wireless sensor networks // Computer Networks. – 2013. – Vol. 57, No. 13. – P. 2548-2556.
11. IEEE 1451.0-2007. Standard for a Smart Transducer Interface for Sensors and Actuators – Common Functions, Communication Protocols, and Transducer Electronic Data Sheet (TEDS)



Formats. – IEEE, 2007.

12. Misra S., Reisslein M., Xue G. A survey of multimedia streaming in wireless sensor networks // IEEE Communications Surveys & Tutorials. – 2008. – Vol. 10, No. 4. – P. 18-39.

13. Фрейдин Я. Современные датчики. Справочник. – М.: Техносфера, – 2021. – 800 с.

14. Sundararaman B., Buy U., Kshemkalyani A.D. Clock synchronization for wireless sensor networks: a survey // Ad Hoc Networks. – 2005. – Vol. 3, No. 3. – P. 281-323.

15. Shelby Z., Hartke K., Bormann C. The Constrained Application Protocol (CoAP). RFC 7252. – IETF, 2014.

16. Banks A., Gupta R. MQTT Version 3.1.1. OASIS Standard. – OASIS, 2014.

17. Liu Y., Yuen C., Cao X., Hassan N.U., Chen J. Design of a scalable hybrid MAC protocol for heterogeneous M2M networks // IEEE Internet of Things Journal. – 2014. – Vol. 1, No. 1. – P. 99-111.

18. Raza S., Trabalza D., Voigt T. 6LoWPAN compressed DTLS for CoAP // 8th IEEE International Conference on Distributed Computing in Sensor Systems. – 2012. – P. 287-289.

19. Centenaro M., Vangelista L., Zanella A., Zorzi M. Long-range communications in unlicensed bands: the rising stars in the IoT and smart city scenarios // IEEE Wireless Communications. – 2016. – Vol. 23, No. 5. – P. 60-67.

20. Ratasuk R., Mangalvedhe N., Zhang Y., Robert M., Koskinen J. Overview of narrowband IoT in LTE Rel-13 // 2016 IEEE Conference on Standards for Communications and Networking (CSCN). – 2016. – P. 1-7.

21. Chen M., Miao Y., Jian X., Wang X., Humar I. Cognitive-LPWAN: Towards intelligent wireless services in hybrid low power wide area networks // IEEE Transactions on Green Communications and Networking. – 2019. – Vol. 3, No. 2. – P. 409-417.

22. Statista Research Department. Internet of Things (IoT) connected devices installed base worldwide from 2015 to 2025 // <https://www.statista.com>. – 2024.

23. Malik H., Pervaiz H., Alam M.M., Le Moullec Y., Kuusik A., Imran M.A. Radio resource management scheme in NB-IoT systems // IEEE Access. – 2018. – Vol. 6. – P. 15051-15064.

24. 3GPP TR 38.824. Study on physical layer enhancements for NR ultra-reliable and low latency case (URLLC). Version 16.0.0. – 2019.

25. Pham Q.V., Fang F., Ha V.N., Piran M.J., Le M., Le L.B., Hwang W.J., Ding Z. A survey of multi-access edge computing in 5G and beyond: Fundamentals, technology integration, and state-of-the-art // IEEE Access. – 2020. – Vol. 8. – P. 116974-117017.

26. Adhikary A., Lin X., Wang Y.P.E. Performance evaluation of NB-IoT coverage // 2016 IEEE 84th Vehicular Technology Conference (VTC-Fall). – 2016. – P. 1-5.

27. Lauridsen M., Nguyen H., Vejlgård B., Kovacs I.Z., Mogensen P., Sorensen M. Coverage comparison of GPRS, NB-IoT, LoRa, and SigFox in a 7800 km² area // 2017 IEEE 85th Vehicular Technology Conference (VTC Spring). – 2017. – P. 1-5.

28. Naoui S., Elhdhili M.E., Saidane L.A. Enhancing the security of the IoT LoraWAN architecture // 2016 International Conference on Performance Evaluation and Modeling in Wired and Wireless Networks (PEMWN). – 2016. – P. 1-7.

KATEGORIYALANGAN OB'EKTLAR PARAMETRLARI MONITORINGI VA VIZUAL O'LCHASH TEXNOLOGIYALARI TAHLILI

Nazarov Abdulaziz Muminovich¹, Baymatova Nargiza Tuxtabayevna²,
Rayimov Farrux To'ra o'g'li³, Jumaqulov Foziljon Komiljonovich⁴

¹TDU, "Radiotexnik qurilmalar va tizimlar" kafedrası professori. t.f.d, nazarov58@rambler.ru

²TDU, "Radiotexnik qurilmalar va tizimlar" kafedrası katta o'qituvchisi,
baymatovanargiz77@gmail.com

³TDU, "Radiotexnik qurilmalar va tizimlar" kafedrası tayanch doktoranti,
farruxrayimov16@gmail.com

⁴TDU, "Radiotexnik qurilmalar va tizimlar" kafedrası tayanch doktoranti,
foziljonkomiljonovich@gmail.com

Annotatsiya: Ushbu maqolada xavfsizlik, ishonchlilik va uzluksiz ishlash nuqtai nazaridan maxsus nazorat talab qiladigan kategoriyalangan ob'ektlar – xavfli ishlab chiqarish ob'ektlari, kritik infratuzilma, transport, energetika va milliy xavfsizlik ob'ektlari – tasnifi, ularning asosiy fizik, geometrik, dinamik va kimyoviy-ekologik parametrlari ko'rib chiqilgan. Nazorat tizimlariga qo'yiladigan ishonchlilik (MTBF, Availability, SIL darajalari), aniqlik va kiberhimoya talablari, shuningdek xalqaro (ISO, IEC, API) hamda O'zbekiston milliy standartlari tahlil qilingan. Zamonaviy radiotexnik (radar, RFID, wireless sensor tarmoqlari), optik-tolali (DOFS, FBG, interferometrik datchiklar) va vizual o'lchash texnologiyalari (LiDAR, lazer Doppler vibrometriya, infragizil termografiya, kompyuter ko'rish) imkoniyatlari, aniqlik ko'rsatkichlari va qo'llanish sohalari nuqtai nazaridan qiyosiy baholangan. Gibridd sensor fusion va IoT-asosli monitoring platformalari orqali predictive maintenance strategiyasini joriy etishning texnik va iqtisodiy afzalliklari ko'rsatilgan. Maqola O'zbekistondagi sanoat va infratuzilma monitoringini rivojlantirishga yo'naltirilgan amaliy xulosalar bilan yakunlanadi.

Kalit so'zlar: kategoriyalangan ob'ektlar, monitoring tizimi, vizual o'lchash, optik-tolali datchiklar, FBG, LiDAR, infragizil termografiya, radiotexnik nazorat, sensor fusion, IoT, kritik infratuzilma, xavfli ishlab chiqarish ob'ektlari, xavfsizlik standartlari.

1.KIRISH.

Zamonaviy sanoat, energetika va infratuzilma ob'ektlarining texnologik murakkabligi ortishi bilan birga ularning xavfsiz va uzluksiz ishlashini ta'minlash masalasi tobora muhim ahamiyat kasb etmoqda. Neft-gaz qazib olish inshootlari, atom elektr stantsiyalari, magistral quvurlar, transport tugunlari va kritik kommunal infratuzilma kabi ob'ektlarda ro'y beradigan avariya yoki nosozlik nafaqat moddiy zarar, balki insonlar hayoti va atrof-muhit uchun jiddiy xavf tug'dirishi mumkin. Shu sababli bu turdagi – ya'ni kategoriyalangan – ob'ektlarni uzluksiz va yuqori ishonchlilik bilan monitoring qilish zamonaviy muhandislik fanining dolzarb vazifasiga aylangan [1, 2].

An'anaviy nazorat usullari – davriy vizual ko'rikdan o'tkazish, yakka tartibdagi datchiklar va qo'lda amalga oshiriladigan o'lchovlar – zamonaviy talablarga ko'pincha javob bera olmaydi. Ular real vaqt rejimida to'liq ma'lumot bermaydi, ko'p mehnat talab qiladi va xato omillarini istisno eta olmaydi. Shu bilan birga, so'nggi o'n yilliklarda radiotexnik, optik-tolali, lazer va vizual o'lchash texnologiyalari sohasida tub sifatiy o'zgarishlar yuz berdi: taqsimlangan optik-tolali



datchiklar butun ob'ekt bo'ylab uzluksiz o'lchashni ta'minlasa, sun'iy intellekt algoritmlari bilan integratsiyalangan kameralar nosozliklarni avtomatik va yuqori ishonchlik bilan aniqlay olmoqda [3, 4].

O'zbekiston Respublikasida "Raqamli O'zbekiston-2030" strategiyasi va sanoat xavfsizligi sohasidagi milliy dasturlar doirasida monitoring va nazorat tizimlarini yangilash ustuvor vazifalar qatoriga kiritilgan. Biroq amaliyotda kategoriyalangan ob'ektlarning parametrlarini o'lchashda qo'llaniladigan texnologiyalar ko'lami va ularni tanglash mezonlari hali ham yetarlicha tizimlashtirilmagan [5].

Ushbu maqolaning maqsadi kategoriyalangan ob'ektlar tasnifini tuzib, ularning nazorat qilinadigan parametrlarini tizimlashtirish, xalqaro va milliy standartlar talablarini umimlashtirish hamda zamonaviy o'lchash texnologiyalarini qiyosiy tahlil qilishdan iborat. Tadqiqot natijalari O'zbekiston sharoitida samarali monitoring tizimlarini loyihalash va joriy etishga amaliy asos bo'lib xizmat qilishi mo'ljallangan.

2. ASOSIY QISM.

Zamonaviy sanoat va infratuzilma rivojlanishi bilan birga, alohida nazorat va monitoring talab qiladigan ob'ektlar soni tobora ortib bormoqda.

Kategoriyalangan ob'ektlar deb, xavfsizlik, ishonchlik va uzluksiz ishlash nuqtai nazaridan yuqori talablar qo'yiladigan hamda ularning buzilishi yoki noto'g'ri ishlashi jiddiy oqibatlariga olib kelishi mumkin bo'lgan texnik ob'ektlar va tizimlar majmuasiga aytiladi [1, 2].

Jahon amaliyotida kategoriyalangan ob'ektlar quyidagi asosiy guruhlarga tasniflanadi:

A) *Xavfli ishlab chiqarish ob'ektlari*. Xavfli ishlab chiqarish ob'ektlari (XICHO) zaharli, portlovchi, yonuvchan moddalar bilan ishlaydigan yoki yuqori bosim, temperatura sharoitlarida faoliyat yuritadigan korxonalar va qurilmalarni o'z ichiga oladi [6]. Jahon Sog'liqni Saqlash Tashkiloti (JSST) ma'lumotlariga ko'ra, har yili 340 ming kishidan ortiq ishchi xavfli ishlab chiqarish ob'ektlaridagi baxtsiz hodisalar natijasida halok bo'ladi [7].

Xavfli ob'ektlar turlari: Neft-gaz qazib olish va qayta ishlash inshootlari; Kimyo sanoati korxonalari; Portlovchi moddalar ishlab chiqarish zavodlari; Yuqori bosimli idishlar va qozonxonalar; Magistral quvurlar va gaz taqsimlash tizimlari.

O'zbekiston Respublikasida 2023-yil ma'lumotlariga ko'ra, 3500 dan ortiq xavfli ishlab chiqarish ob'ekti ro'yxatga olingan [5]. Ularning nazorati "Texnik nazorat va xavfsizlik bo'yicha davlat qo'mitasi" tomonidan amalga oshiriladi.

B) *Kritik infratuzilma ob'ektlari*. Kritik infratuzilma ob'ektlari (KIO) - bu buzilishi yoki yo'q qilinishi davlat xavfsizligiga, iqtisodiyotga, aholining hayot faoliyatiga jiddiy ta'sir ko'rsatishi mumkin bo'lgan tizimlar va resurslardir [8]. AQSh Milliy Standartlar va Texnologiyalar Instituti (NIST) tomonidan ishlab chiqilgan Framework for Improving Critical Infrastructure Cybersecurity (2018) hujjatida 16 ta kritik infratuzilma sektori aniqlangan [9].

Asosiy kategoriyalar: Energetika ta'minoti tizimlari (elektr stantsiyalari, nimstansiyalar); Suv ta'minoti va kanalizatsiya; Telekomunikatsiya va aloqa; Transport infratuzilmasi; Bank-moliya sektori ob'ektlari; Tibbiy muassasalar.

Yevropa Ittifoqi hududida 2022-yil ma'lumotlariga ko'ra, kritik infratuzilma ob'ektlariga qarshi kiberhujumlar 2020-yilga nisbatan 42% ga oshgan [10].



C) *Transport va logistika ob'ektlari*. Transport sektori zamonaviy iqtisodiyotning asosiy tarkibiy qismi hisoblanadi. Jahon Savdo Tashkiloti (JST) ma'lumotlariga ko'ra, global yalpi ichki mahsulotning (YIM) 9-10% transport va logistika xizmatlariga to'g'ri keladi [11].

Transport ob'ektlari turkumlari: Temir yo'l infratuzilmasi (ko'priklar, tunnellar, rel yo'llari); Aeroport komplekslari va uchish-qo'nish yo'laklari; Dengiz va daryo portlari; Avtomobil yo'llari va yo'l-transport inshootlari; Magistral quvurlar (neft, gaz, mahsulotlar).

O'zbekiston hukumati 2023-2027 yillar uchun transport infratuzilmasini rivojlantirish bo'yicha 22 milliard AQSH dollari hajmida investitsiyalar dasturini qabul qilgan [12].

D) *Energetika sektori ob'ektlari*. Energetika tizimi zamonaviy jamiyatning asosiy qon-tomirlari hisoblanadi. Xalqaro Energetika Agentligi (IEA) prognozlariga ko'ra, 2030-yilga kelib jahon energiya iste'moli 2020-yilga nisbatan 30% ga oshadi [13].

Energetika ob'ektlari: Elektr stantsiyalari (IES, GES, YES, alternativ energiya); Yuqori kuchlanishli elektr uzatish liniyalari (110-500 kV); Transformator nimstansiyalari; Tarqatish tarmoqlari (6-35 kV); Smart grid (aqlli tarmoq) tizimlari.

O'zbekistonda 2024-yil boshiga energetika tizimi quvvati 16500 MVt ni tashkil etadi [14]. Mamlakat energetika xavfsizligini ta'minlash maqsadida monitoring va nazorat tizimlarini joriy etish ustida ish olib borilmoqda.

E) *Milliy xavfsizlik ob'ektlari*. Milliy xavfsizlik ob'ektlari davlat suverenitetini, territorial yaxlitligini va aholining xavfsizligini ta'minlovchi maxsus muhofaza qilinadigan ob'ektlardir [15].

Kategoriyalar: Harbiy ob'ektlar va qurol-yarog' ombori; Strategik ahamiyatga ega korxonalar; Davlat boshqaruv ob'ektlari; Atom va radiatsion xavfli ob'ektlar; Ma'lumot xavfsizligi markazlari.

Nazorat qilinadigan parametrlar turlari. Kategoriyalangan ob'ektlarning xavfsiz va samarali ishlashini ta'minlash uchun ularning turli fizik, kimyoviy va texnik parametrlarini uzluksiz monitoring qilish zarur. Zamonaviy nazorat tizimlari bir vaqtning o'zida yuzlab parametrlarni kuzatishi mumkin [16].

A) Fizik parametrlar.

Temperatura o'lchash: Temperatura - eng muhim fizik parametrlardan biri hisoblanadi. Sanoat ob'ektlarida temperatura diapazoni -200°C dan $+2000^{\circ}\text{C}$ gacha o'zgarishi mumkin [17]. Yuqori aniqlikli temperatura o'lchash uchun quyidagi datchiklar qo'llaniladi:

- Termojuftlar (Thermocouple): $\pm 0.5-2^{\circ}\text{C}$ aniqlik.
- Qarshilik termometrlari (RTD - PT100, PT1000): $\pm 0.1-0.5^{\circ}\text{C}$ aniqlik.
- Termorezistorlar: $\pm 0.05^{\circ}\text{C}$ aniqlik.
- Infraqizil pirometrlar: kontaktsiz o'lchash, -50°C dan $+3000^{\circ}\text{C}$ gacha.
- Optik-tolali temperatura datchiklari: $\pm 0.1^{\circ}\text{C}$, elektromagnit chidamlik.

Bosim nazorati: Bosim o'lchash xavfli ishlab chiqarish ob'ektlari uchun kritik ahamiyatga ega. Zamonaviy bosim datchiklari 0.01% gacha aniqlikni ta'minlaydi [18].

- Piezorezistiv datchiklar: yuqori chastotali dinamik bosim.
- Suyuqlik (sig'imli) datchiklar: statik bosim, 0.025% aniqlik.
- Rezonansli datchiklar: ultra yuqori aniqlik.
- Optik-tolali bosim datchiklari: portlovchi muhitda xavfsizlik.

Tebranish va akustik emmissiya: Rotorli mexanizmlar, turbinalar va muhim konstruksiyalarning texnik holatini baholashda tebranish tahlili muhim rol o'ynaydi [19]. ISO



10816 standartiga ko'ra, tebranish tezligi 0.28 mm/s dan oshsa, uskunaning holati "xavfli" deb baholanadi.

- Akselerometrlar: $\pm 0.5\%$ aniqlik, 0-5000 Hz chastota diapazoni.
- Tebranish tezligi datchiklari.
- Akustik emissiya datchiklari: yoriqlar va deformatsiyalarni aniqlash.

B) *Geometrik parametrlar*. Konstruksiya larning geometrik parametrlarini nazorat qilish ularning mustahkamlik va barqarorligini baholash uchun zarur [20].

O'lchash parametrlari: Chiziqli o'lchamlar: ± 0.01 -1 mm aniqlik; Burchak o'lchamlar: ± 0.1 -10" aniqlik; Shakl va yassilik: ± 0.001 -0.1 mm; Egilish va burilish: ± 0.1 -1 mm; Siljish va ko'chish: mikron va millimetr darajasida.

O'lchash texnologiyalari: Lazer skanerlash: ± 1 -3 mm, 3D model yaratish; Fotogrammetriya: ± 0.1 -5 mm, keng hudud qamrovi; Total stansiyalar: ± 0.5 -2 mm + 1-2 ppm; GNSS/GPS nazorati: ± 5 -20 mm, vertikal va gorizonta l; Inklinometrlar: $\pm 0.01^\circ$ nishablik o'lchash.

C) *Dinamik parametrlar*. Ob'ektlarning harakatlanish parametrlari xavfsizlik va samaradorlikni ta'minlashda muhim [21].

Asosiy parametrlar: Tezlik: 0.01-500 m/s diapazoni; Tezlanish: 0.001-100 g; Aylanish chastotasi: 1-100,000 rpm; Oqim tezligi: 0.001-100 m/s; Deformatsiya tezligi: mikrodeformatsiya/s.

O'lchash usullari: Doppler radiolokatsiyasi: kontaktsiz tezlik o'lchash; Lazer vibrometrlar: ± 0.01 μ m/s aniqlik; MEMS akselerometrlar: $\pm 0.5\%$ xatolik; Ultratovushli oqim o'lchagichlar: $\pm 0.5\%$ aniqlik.

D) *Kimyoviy va ekologik parametrlar*. Atrof-muhitni muhofaza qilish va xodimlar salomatligini ta'minlash maqsadida kimyoviy parametrlarni monitoring qilish zarur [22].

Nazorat parametrlari: Gaz konsentratsiyasi: ppm va ppb darajasida; pH darajasi: ± 0.01 pH aniqlik; Namlik: ± 0.5 -2% RH; Chang konsentratsiyasi: PM2.5, PM10 zarrachalari; Radiatsiya fonini: mkZv/soat; Toksik moddalar: CO, CO₂, H₂S, CH₄, NH₃.

Datchiklar turlari: Elektrokimyoviy sensorlar: 0-2000 ppm diapazoni; Infraqizil (NDIR) gaz analizatorlari: CO₂ o'lchash; PID (Photoionization Detector): uchuvchi organik birikmalar; Lazer spektroskopiya: yuqori selektivlik va sezgirlik.

3. ZAMONAVIY NAZORAT QILISH TALABLARI VA STANDARTLARI.

Kategoriyalangan ob'ektlarni nazorat qilish uchun milliy va xalqaro standartlar tizimi mavjud bo'lib, ular xavfsizlik va sifat talablarini belgilaydi [23].

A) *Xalqaro standartlar tizimi*. ISO (International Organization for Standardization): ISO 9001:2015 - Sifat menejmenti tizimlari; ISO 45001:2018 - Mehnat muhofazasi menejmenti; ISO 55001:2014 - Aktivlarni boshqarish tizimlari; ISO 13373 seriyasi - Holatni monitoring qilish va diagnostika.

IEC (International Electrotechnical Commission): IEC 61508 - Elektr/elektron/dasturlashtiriladigan elektron tizimlar uchun funksional xavfsizlik; IEC 61511 - Jarayon sanoati uchun xavfsizlik instrumental tizimlari; IEC 60812 - Nosozliklar turlarini va oqibatlarini tahlil (FMEA).

API (American Petroleum Institute): API 570 - Jarayon quvurlari inspeksiyasi; API 580 - Riskga asoslangan inspeksiya; API 653 - Tankerlar va sig'diruvchi idishlar inspeksiyasi.



B) *O'zbekiston milliy standartlari.* O'zbekiston Respublikasi "O'zstandart" agentligi tomonidan 15000 dan ortiq milliy standartlar ishlab chiqilgan va qo'llanilmoqda [24].

Asosiy standartlar: O'z DSt 1040:2019 - Xavfli ishlab chiqarish ob'ektlari. Umumiy xavfsizlik talablari; O'z DSt 2918:2016 - Sanoat xavfsizligi menejmenti tizimlari; O'z DSt ISO 9001:2020 - Sifat menejmenti tizimlari; O'z DSt 3322:2018 - Qozonxonalar va bosim idishlari. Texnik nazorat qoidalari.

C) *Xavfsizlik va ishonchlilik ko'rsatkichlari.* Kategoriyalangan ob'ektlar uchun quyidagi asosiy ko'rsatkichlar belgilanadi [25].

Ishonchlilik ko'rsatkichlari: MTBF (Mean Time Between Failures) - nosozliklar orasidagi o'rtacha vaqt: ≥ 50000 soat; MTTR (Mean Time To Repair) - ta'mirlash uchun o'rtacha vaqt: ≤ 4 soat; Mavjudlik koeffitsienti (Availability): $\geq 99.9\%$; FIT (Failures In Time): 10^9 soatda nosozliklar soni.

Xavfsizlik darajalari (SIL - Safety Integrity Level): SIL 1: Xavfli hodisa ehtimoli 10^{-2} - 10^{-1} (yiliga); SIL 2: 10^{-3} - 10^{-2} (kritik ob'ektlar uchun); SIL 3: 10^{-4} - 10^{-3} (yuqori xavfli jarayonlar); SIL 4: 10^{-5} - 10^{-4} (atom energetikasi, aviatsiya).

O'lchash aniqligi talablari: Turli ob'ektlar uchun o'lchash aniqligi standartlar bilan belgilanadi [26]. Temperatura, bosim va oqimni o'lchashga aniqlik talablari 1-jadvalda keltirilgan.

1-jadval
O'lchash aniqligi talablari

Parametr	Aniqlik sinfi	Nisbiy xatolik	Qo'llanish
Temperatura	A	$\pm 0.5^{\circ}\text{C}$	Umumiy sanoat
	AA	$\pm 0.1^{\circ}\text{C}$	Farmatsevtika
Bosim	0.1	$\pm 0.1\%$	Etalon o'lchovlar
	0.25	$\pm 0.25\%$	Laboratoriya
	0.5	$\pm 0.5\%$	Texnologik jarayonlar
Oqim	0.5	$\pm 0.5\%$	Hisobot o'lchovi
	1.0	$\pm 1.0\%$	Texnologik nazorat

Monitoring chastotasi talablari: Turli parametrlar uchun minimal monitoring chastotasi quyidagicha belgilanadi [27]: Kritik xavfsizlik parametrlari: 1-10 Hz (real-time); Texnologik jarayon parametrlari: 0.1-1 Hz; Sekin o'zgaruvchi parametrlar: 1 marta/soat - 1 marta/kun; Prognozli texnik xizmat parametrlari: 1 marta/hafta - 1 marta/oy.


D) *Ma'lumotlar xavfsizligi va kiberhimoya.* Zamonaviy nazorat tizimlari kiberxavflar oldida himoyalangan bo'lishi kerak [28]. IEC 62443 standartlar seriyasi sanoat avtomatlashtirish va nazorat tizimlari kiberhimoyasi uchun talablarni belgilaydi.

Asosiy talablar: Autentifikatsiya: ko'p bosqichli tasdiqlash; Shifrlash: AES-256, TLS 1.3 protokollari; Kirish nazorati: role-based access control (RBAC); Audit jurnali: barcha amaliyotlarni qayd etish; Zaxira nusxalash: ma'lumotlarning 3-2-1 strategiyasi.



Kategoriyalangan ob'ektlarning parametrlarini nazorat qilish va o'lchash zamonaviy sanoat xavfsizligining muhim tarkibiy qismidir. So'nggi yillarda bu sohada radiotexnik, optik-tolali va vizual o'lchash texnologiyalari keng qo'llanilmoqda. Ushbu texnologiyalar yuqori aniqlik, real vaqt rejimida monitoring va kontaktsiz o'lchash imkoniyatlarini taqdim etadi.

Radiotexnik nazorat texnologiyalari. Radiotexnik usullar elektromagnit to'lqinlarning turli xususiyatlaridan foydalangan holda ob'ektlarning parametrlarini kontaktsiz o'lchash imkonini beradi (1-rasm). Ushbu texnologiyalar portlovchi va yuqori temperaturali muhitlarda qo'llash uchun ayniqsa qulay hisoblanadi [29].



1-rasm. Radiotexnik nazorat texnologiyalarining umumiy tuzilishi


Radar va radiolokatsiya tizimlari. Zamonaviy radar tizimlari ob'ektlarning masofa, tezlik va o'lchamlarini yuqori aniqlik bilan aniqlash imkonini beradi. FMCW (Frequency Modulated Continuous Wave) radar texnologiyasi millimetr to'lqin diapazonida ishlab, ± 0.1 mm gacha aniqlikni ta'minlaydi [30]. Bunday tizimlar quvurlar deformatsiyasini, tanker devorlarining qalinligini va konstruksiyalarning siljishini nazorat qilishda qo'llaniladi.

Radiorele'li o'lchash tizimlari. Radiorele'li usullar ob'ektlar ichidagi jarayonlarni nazorat qilish uchun ishlatiladi. Mikroto'lqin datchiklari suyuqlik darajasini, namlikni va material zichligini o'lchashda samarali natijalar beradi. Zamonaviy tizimlar 0.5% gacha nisbiy xatolik bilan o'lchash imkoniyatiga ega [31].

RFID texnologiyasi va wireless sensor tarmoqlari. RFID (Radio Frequency Identification) tizimlari ob'ektlarni avtomatik identifikatsiyalash va ularning parametrlarini kuzatish uchun keng qo'llanilmoqda. UHF diapazonidagi RFID teglar 10 metrgacha masofada o'qiladi va xavfli muhitda ishchi xodimlarning harakatini monitoring qilishda foydalaniladi [32]. Wireless sensor tarmoqlari (WSN) yuzlab datchiklar ma'lumotlarini yig'ish va real vaqtda uzatish imkonini beradi.

Optik-tolali datchiklar va monitoring tizimlari. Optik-tolali texnologiyalar kategoriyalangan ob'ektlarni nazorat qilishning eng istiqbolli yo'nalishlaridan biri hisoblanadi (2-rasm). Ular elektromagnit interferensiyaga chidamli, portlovchi muhitda xavfsiz va uzoq masofaga signal uzatish imkoniyatiga ega [33].

Taqsimlangan optik-tolali datchiklar (DOFS). DOFS tizimlari bir toladan foydalanib, butun ob'ekt bo'ylab uzluksiz o'lchash imkonini beradi. Reley, Raman va Brilluyen sochilish effektlariga asoslangan tizimlar temperatura, deformatsiya va tebranishlarni 1 metr fazoviy o'lchamlarda aniqlaydi [34].



2-rasm. Optik-tolali datchiklar va monitoring tizimlari

Optik-tolali datchiklar turlari va ularning xususiyatlari 2-jadvalda keltirilgan.

2-jadval
Optik-tolali datchiklar tasnifi

Datchik turi	O'lchash parametri	Fazoviy o'lcham	Aniqlik	Masofasi
BOTDR (Brillouin)	Temperatura, deformatsiya	1-2 m	$\pm 1^{\circ}\text{C}$, $\pm 20 \mu\epsilon$	50-100 km
ROTDR (Raman)	Temperatura	1 m	$\pm 0.5^{\circ}\text{C}$	10-30 km
DAS (Distributed Acoustic)	Tebranish, tovush	1-10 m	$1 \text{ n}\epsilon/\sqrt{\text{Hz}}$	40-80 km
FBG (Fiber Bragg Grating)	Nuqtaviy o'lchov	-	$\pm 0.1^{\circ}\text{C}$, $\pm 1 \mu\epsilon$	100+ km

FBG datchiklari. Fiber Bragg Grating (FBG) datchiklari yuqori aniqlik va tezkorlik bilan o'lchash imkonini beradi. Bir optik tolaga 100 tagacha FBG datchik ulanib, ko'priklar, tunel va bino konstruksiyalarining deformatsiyasini millisekundlarda kuzatish mumkin [35]. FBG datchiklar - 200°C dan $+800^{\circ}\text{C}$ gacha temperatura diapazonida ishlay oladi.

Interferometrik optik datchiklar. Fabry-Perot va Mach-Zehnder interferometrlari nanometr darajasida siljishni va mikro-deformatsiyalarni aniqlash imkonini beradi. Bunday datchiklar atom elektr stantsiyalari va aerokosmik sohasida qo'llaniladi [35].

Lazer va fotonik texnologiyalar.

3D lazer skanerlash. Zamonaviy lazer skanerlar (LiDAR) murakkab ob'ektlarning to'liq geometrik modelini yaratish imkonini beradi. Terrestrial Laser Scanner (TLS) tizimlari millimetr aniqlik bilan soniyasida 1 million nuqtani o'lchaydi va 300 metrgacha masofani qamraydi [36]. Bu texnologiya yirik sanoat inshootlari, ko'priklar va tarixiy binolarning monitoringida qo'llaniladi.

Lazer Doppler vibrometriya. Lazer Doppler vibrometrlari (LDV) kontaktsiz tarzda ob'ektlarning tebranishini o'lchash imkonini beradi. Zamonaviy LDV tizimlari $0.01 \mu\text{m/s}$ gacha tebranish tezligini va 50 kHz gacha chastotani qayd etadi [37]. Bu texnologiya turbinalar, nasoslar va boshqa aylanuvchi mexanizmlarning diagnostikasida muhim ahamiyatga ega.



Vizual va multispektral monitoring tizimlari.

Yuqori o'lchovli kameralar va komp'yuter ko'rish. Zamonaviy industrial kameralar 20 megapiksel va undan yuqori o'lchamda tasvirlarni 100 kadr/s tezlikda qayd etadi. Sun'iy intellekt va chuqur o'rganish algoritmlaridan foydalanib, ob'ektlarni avtomatik identifikatsiyalash va nuqsonlarni aniqlash amalga oshiriladi [4]. YOLO va Mask R-CNN algoritmlari real vaqt rejimida 95% dan yuqori aniqlik bilan ob'ektlarni klassifikatsiyalaydi.


Infraqizil termografiya. Termografik kameralar ob'ektlarning issiqlik taqsimotini vizualizatsiya qilish orqali yashirin nuqsonlarni aniqlash imkonini beradi. Zamonaviy FLIR kameralar 0.02°C temperatura farqini ajrata oladi va elektr qurilmalarining qizib ketishi, izolyatsiya buzilishi va yashirin yoriqlarni aniqlashda qo'llaniladi [38].

Gibrid va intellektual monitoring tizimlari.

Sensor fusion (sintez) texnologiyasi. Zamonaviy yondashuv turli xil datchiklar ma'lumotlarini birlashtirib, ob'ekt holatini kompleks baholashni ta'minlaydi. Kalman filtri va Bayesian tarmoqlari yordamida turli manbalardan keladigan noaniq ma'lumotlar sintez qilinadi va ob'ektiv xulosa chiqariladi [39]. Bu yondashuv xato ehtimolini 40-60% ga kamaytiradi.

IoT va cloud-based monitoring. Internet of Things (IoT) texnologiyalari yuzlab minglab datchiklar ma'lumotlarini markaziy platformada to'plash va tahlil qilish imkonini beradi (3-rasm). Cloud-based tizimlar Big Data tahlili, machine learning modellari va prognozli texnik xizmatni amalga oshiradi. Predictive maintenance strategiyasi avariya ehtimolini 30-40% ga kamaytiradi va texnik xizmat xarajatlarini 25% ga qisqartiradi [40].

Zamonaviy monitoring tizimlarining asosiy afzalliklari shundaki, ular real vaqt rejimida ishlaydi, uzoq vaqt davomida avtonom faoliyat ko'rsatadi va sun'iy intellekt yordamida avtomatik qaror qabul qilish imkoniyatiga ega. Kelgusida quantum datchiklar va 5G/6G aloqa texnologiyalari monitoring tizimlarining samaradorligini yanada oshiradi.



3-rasm. IoT texnologiyalarining ishlash tamoyili

Shunday qilib, zamonaviy texnologiyalar kategoriyalangan ob'ektlarni nazorat qilishda yuqori aniqlik, avtomatlashtirilganlik va ishonchlilikni ta'minlaydi. Radiotexnik, optik-tolali va



vizual texnologiyalarning integratsiyasi kelajakda yanada samarali monitoring tizimlarini yaratish imkonini beradi.

4. XULOSA.

Olib borilgan tahlil asosida kategoriyalangan ob'ektlarni monitoring qilish sohasida quyidagi xulosalar shakllandi.

Birinchidan, kategoriyalangan ob'ektlarni besh asosiy guruhga — xavfli ishlab chiqarish ob'ektlari, kritik infratuzilma, transport, energetika va milliy xavfsizlik ob'ektlari — tasniflanishi monitoring tizimlarini maqsadli loyihalash uchun zaruriy metodologik asos bo'lib xizmat qiladi. Har bir guruh uchun nazorat parametrlari (temperatura, bosim, tebranish, geometrik siljish, kimyoviy konsentratsiya va boshqalar), aniqlik sinflari va monitoring chastotasi turlicha bo'lib, muhandislik yechimlarini ob'ektning o'ziga xos xususiyatlariga moslashtirishni talab qiladi.

Ikkinchidan, zamonaviy o'lchash texnologiyalari ichida optik-tolali datchiklar (ayniqsa, DOFS va FBG tizimlari) eng yuqori potentsialni namoyon etadi: ular bir toladan foydalanib 100 km gacha masofada $\pm 0.5^{\circ}\text{C}$ harorat va $\pm 1 \mu\text{m}$ deformatsiya aniqligini ta'minlaydi, elektromagnit interferensiyaga chidamli va portlovchi muhitda xavfsiz ishlaydi. LiDAR texnologiyasi esa murakkab sanoat inshootlari va ko'priklarning millimetr aniqlikdagi 3D geometrik modelini real vaqtda yaratish imkonini beradi. Infraqizil termografiya yashirin nuqsonlarni erta bosqichda aniqlashda, lazer Doppler vibrometriya esa kontaktsiz rejimda aylanuvchi mexanizmlar diagnostikasida samarali vosita sifatida tasdiqlangan.

Uchinchidan, sensor fusion (ma'lumotlarni sintez qilish) va IoT-asosli monitoring platformalarining qo'llanilishi xato ehtimolini 40–60% ga kamaytiradi va predictive maintenance strategiyasini amalga oshirishga imkon beradi. Mazkur yondashuv avariya ehtimolini 30–40% ga pasaytiradi va texnik xizmat xarajatlarini 25% gacha qisqartiradi, bu esa iqtisodiy jihatdan juda muhim ahamiyatga ega, ayniqsa qimmat va uzoq joylashgan ob'ektlarda.

To'rtinchidan, O'zbekistonda 3500 dan ortiq xavfli ishlab chiqarish ob'ekti ro'yxatga olingan bo'lsa-da, zamonaviy monitoring texnologiyalarini joriy etishda milliy standartlar va sertifikatlash tizimining yetarlicha rivojlanmaganligi, malakali kadrlar tanqisligi va import jihozlarning yuqori narxi asosiy to'siqlar bo'lib qolmoqda. Shu muammolarni bartaraf etish uchun "Raqamli O'zbekiston-2030" strategiyasi va 2023–2026 yillardagi sun'iy intellekt rivojlantirish dasturi doirasida IoT, optik-tolali va vizual monitoring texnologiyalari bo'yicha ilmiy-texnik tadqiqotlarni kuchaytirish, mahalliy prototiplar ishlab chiqish va tegishli mutaxassislar tayyorlash zarur.

Kelajakdagi tadqiqotlar quantum datchiklar, 5G/6G aloqa tarmoqlari bilan integratsiyalashgan monitoring platformalari va generativ sun'iy intellekt asosidagi prognozli tahlil tizimlarini ishlab chiqishga yo'naltirilishi maqsadga muvofiq. Bu yo'nalishlar kategoriyalangan ob'ektlar xavfsizligini ta'minlashda yangi imkoniyatlar ochib beradi.

FOYDALANILGAN ADABIYOTLAR:

1. Махутов Н.А. Безопасность и риски: системные исследования и разработки. - Новосибирск: Наука, 2017. - 724 с.
2. Smith D.J., Simpson K.G.L. Safety Critical Systems Handbook: A Straightforward Guide to Functional Safety, IEC 61508 and Related Standards. 4th Edition. - Butterworth-Heinemann, 2016. - 584 p.



3. Bao X., Chen L. Recent Progress in Distributed Fiber Optic Sensors // Sensors. - 2012. - Vol. 12, No. 7. - P. 8601-8639.
4. Redmon J., Farhadi A. YOLOv3: An Incremental Improvement // arXiv preprint arXiv:1804.02767. - 2018.
5. O'zbekiston Respublikasi Favqulodda vaziyatlar vazirligi. Statistik ma'lumotlar, 2023. URL: <https://fvv.uz>
6. Лисанов М.В., Печеркин А.С., Сидоров В.И. Анализ риска и декларирование безопасности опасных производственных объектов // Безопасность труда в промышленности. - 2019. - №4. - С. 7-15.
7. WHO. Occupational Health: Workplace Hazards. World Health Organization Report, 2022. URL: <https://www.who.int/health-topics/occupational-health>
8. Rinaldi S.M., Peerenboom J.P., Kelly T.K. Identifying, understanding, and analyzing critical infrastructure interdependencies // IEEE Control Systems Magazine. - 2001. - Vol. 21, No. 6. - P. 11-25.
9. NIST. Framework for Improving Critical Infrastructure Cybersecurity, Version 1.1. National Institute of Standards and Technology, 2018. - 55 p.
10. ENISA. Threat Landscape for Supply Chain Attacks. European Union Agency for Cybersecurity, 2022. - 94 p.
11. WTO. World Trade Statistical Review 2023. World Trade Organization, Geneva, 2023. - 218 p.
12. O'zbekiston Respublikasi Prezidentining 2022-yil 12-dekabrdagi "2023-2027 yillarda transport infratuzilmasini rivojlantirish konsepsiyasi to'g'risida"gi PF-131-son Farmoni.
13. IEA. World Energy Outlook 2023. International Energy Agency, Paris, 2023. - 524 p.
14. O'zbekiston Respublikasi Energetika vazirligi. Yillik hisobot, 2023.
15. Буркатовская Ю.Б. Национальная безопасность: вопросы определения и классификации // Вестник Томского государственного университета. - 2020. - №457. - С. 198-204.
16. Webster J., Eren H. Measurement, Instrumentation, and Sensors Handbook. 2nd Edition. - CRC Press, 2014. - 2612 p.
17. Childs P.R.N. Practical Temperature Measurement. - Butterworth-Heinemann, 2001. - 328 p.
18. Bao X., Chen L. Recent Progress in Distributed Fiber Optic Sensors // Sensors. - 2012. - Vol. 12, No. 7. - P. 8601-8639.
19. ISO 10816-1:1995. Mechanical vibration - Evaluation of machine vibration by measurements on non-rotating parts.
20. Lienhart W. Geotechnical Monitoring Using Total Stations and Laser Scanners // Geomechanics and Tunnelling. - 2017. - Vol. 10, No. 1. - P. 2-8.
21. Doebling S.W., Farrar C.R., Prime M.B. A Summary Review of Vibration-Based Damage Identification Methods // Shock and Vibration Digest. - 1998. - Vol. 30, No. 2. - P. 91-105.
22. Kumar A., Kim H., Hancke G.P. Environmental Monitoring Systems: A Review // IEEE Sensors Journal. - 2013. - Vol. 13, No. 4. - P. 1329-1339.
23. ISO/IEC Guide 2:2004. Standardization and related activities - General vocabulary.
24. O'zbekiston Respublikasi "O'zstandart" agentligi. Milliy standartlar katalogi, 2024.



URL: <https://standart.uz>

25. IEC 61508:2010. Functional safety of electrical/electronic/programmable electronic safety-related systems. Parts 1-7.
26. ISO 5725-1:1994. Accuracy (trueness and precision) of measurement methods and results.
27. API 670. Machinery Protection Systems. 5th Edition. American Petroleum Institute, 2014. - 238 p.
28. IEC 62443-3-3:2013. Industrial communication networks - Network and system security - System security requirements and security levels.
29. Skolnik M.I. Radar Handbook. 3rd Edition. - McGraw-Hill Education, 2008. - 1352 p.
30. Peng Z., Li C. Portable Microwave Radar Systems for Short-Range Localization and Life Tracking // IEEE Transactions on Microwave Theory and Techniques. - 2021. - Vol. 69, No. 1. - P. 512-527.
31. Nyfors E., Vainikainen P. Industrial Microwave Sensors. - Artech House, 1989. - 351 p.
32. Landaluce H., Arjona L., Perallos A., et al. A Review of IoT Sensing Applications and Challenges Using RFID and Wireless Sensor Networks // Sensors. - 2020. - Vol. 20, No. 9. - Article 2495.
33. Lu P., Lalam N., Badar M., et al. Distributed optical fiber sensing: Review and perspective // Applied Physics Reviews. - 2019. - Vol. 6, No. 4. - Article 041302.
34. Kersey A.D., Davis M.A., Patrick H.J., et al. Fiber grating sensors // Journal of Lightwave Technology. - 1997. - Vol. 15, No. 8. - P. 1442-1463.
35. Rao Y.J. Recent progress in fiber-optic extrinsic Fabry-Perot interferometric sensors // Optical Fiber Technology. - 2006. - Vol. 12, No. 3. - P. 227-237.
36. Vosselman G., Maas H.G. Airborne and Terrestrial Laser Scanning. - CRC Press, 2010. - 336 p.
37. Rothberg S.J., Allen M.S., Castellini P., et al. An international review of laser Doppler vibrometry: Making light work of vibration measurement // Optics and Lasers in Engineering. - 2017. - Vol. 99. - P. 11-22.
38. Meola C., Carlomagno G.M. Recent advances in the use of infrared thermography // Measurement Science and Technology. - 2004. - Vol. 15, No. 9. - P. R27-R58.
39. Hall D.L., Llinas J. An introduction to multisensor data fusion // Proceedings of the IEEE. - 1997. - Vol. 85, No. 1. - P. 6-23.
40. Lee J., Kao H.A., Yang S. Service Innovation and Smart Analytics for Industry 4.0 and Big Data Environment // Procedia CIRP. - 2014. - Vol. 16. - P. 3-8.

TA'LIMDA AI TIZIMLARIDAGI ALGORITMIK BIAS VA SHAXSIY MA'LUMOTLAR XAVFSIZLIGI.

H.E.Mamarajabov¹, D.T.Shukurov², I.I.Shahriyorov³, N.T.Allamurodov⁴

¹Sarbo'n universiteti, Muhandislik va raqamli texnologiyalar kafedrasida katta o'qituvchisi,
husankarimov09@gmail.com

²Sarbo'n universiteti, Muhandislik va raqamli texnologiyalar kafedrasida katta o'qituvchisi,
dadanur0094@gmail.com



³Sarbon universiteti, Muhandislik va raqamli texnologiyalar kafedrasida katta o'qituvchisi,
shahriyorovikrom6@gmail.com

⁴Sarbon universiteti, Muhandislik va raqamli texnologiyalar kafedrasida katta o'qituvchisi,
norbobo1996@gmail.com

Annotatsiya: Maqolada ta'limda qo'llanilayotgan sun'iy intellekt tizimlarida algoritmik tarfakshlik va shaxsga doir ma'lumotlar xavfsizligi muammolari ilmiy-nazariy hamda amaliy jihatdan tahlil qilinadi. Tadqiqotning maqsadi ta'lim AI tizimlarida adolat, shaffoflik, maxfiylik va huquqiy muvofiqlikni ta'minlashga qaratilgan audit modelini asoslashdan iborat. Maqolada UNESCO, OECD, NIST AI RMF, EU AI Act, GDPR hamda O'zbekiston Respublikasining "Shaxsga doir ma'lumotlar to'g'risida"gi Qonuni asosida qiyosiy tahlil, tizimli yondashuv va pedagogik-huquqiy modellashtirish metodlari qo'llanildi. Natijada ta'lim AI tizimlarining ma'lumot, model, qaror, xavfsizlik va monitoring bosqichlarida baholanishi zarur bo'lgan ko'rsatkichlar ishlab chiqildi. Taklif etilgan model algoritmik tarfakshlikni aniqlash, tushuntiriluvchan AI, differensial maxfiylik, federativ o'qitish, ma'lumotlarni minimallashtirish va inson nazoratini yagona metodik tizimda birlashtiradi.

Kalit so'zlar: algoritmik bias, shaxsiy ma'lumotlar xavfsizligi, ta'limda AI, algoritmik audit, differensial maxfiylik, XAI, huquqiy muvofiqlik.

1. KIRISH

Raqamli ta'lim muhitida sun'iy intellekt texnologiyalarining qo'llanishi avtomatik baholash, adaptiv ta'lim trayektoriyasini shakllantirish, kontent tavsiyalash, onlayn proktoring, talaba faolligini monitoring qilish va akademik yordam xizmatlarini avtomatlashtirish imkonini bermoqda. Bunday tizimlar ta'lim jarayonini tezlashtirishi va individuallashtirishi mumkin, biroq ularning noto'g'ri loyihalaniishi yoki nazoratsiz joriy etilishi talaba huquqlari, shaxsga doir ma'lumotlar daxlsizligi, baholash adolatligi va akademik tenglikka bevosita ta'sir qiladi.

Algoritmik tarfakshlik deganda AI tizimining ma'lum guruhlar bo'yicha noxolis natija berishi, qarorlarida demografik, hududiy, til, ijtimoiy-iqtisodiy yoki boshqa belgilar asosida farqlanish yuzaga kelishi tushuniladi. Ta'limda bu holat ayrim talabalar guruhining past baholanishi, tavsiya tizimlari orqali cheklangan resurslarga yo'naltirilishi, onlayn nazorat tizimlarida noto'g'ri xavfli deb belgilanishi yoki o'qish imkoniyatlaridan teng foydalana olmasligiga sabab bo'lishi mumkin. Shaxsga doir ma'lumotlar xavfsizligi esa talabaning identifikatsion, akademik, biometrik, xulq-atvor va psixometrik ma'lumotlarini qonuniy, adolatli, cheklangan maqsadlarda va xavfsiz texnik choralar asosida qayta ishlashni talab qiladi.

Xalqaro miqyosda UNESCO sun'iy intellekt etikasi bo'yicha tavsiyalarida inson huquqlari, inklyuzivlik, shaffoflik, maxfiylik va javobgarlikni asosiy tamoyillar sifatida ko'rsatadi [2]. OECD AI Principles esa ishonchli AI uchun inson markazlilik, shaffoflik, mustahkamlik, xavfsizlik va javobgarlik talablarini ilgari suradi [4]. NIST AI Risk Management Framework AI tizimlari risklarini boshqarishda "govern, map, measure, manage" bosqichlariga tayanadi [5]. EU AI Act ta'lim va kasbiy tayyorgarlikda kirish, baholash va o'quv jarayonini yo'naltirishga xizmat qiladigan ayrim AI tizimlarini yuqori xavfli tizimlar qatoriga kiritadi [7]. O'zbekiston sharoitida esa shaxsga doir ma'lumotlar sohasidagi munosabatlar O'RQ-547-son Qonun bilan tartibga solinadi [1].



Tadqiqotning maqsadi ta'lim AI tizimlarida algoritmik tarafkashlikni kamaytirish hamda shaxsga doir ma'lumotlar xavfsizligini ta'minlashga qaratilgan metodik-audit modelini asoslashdan iborat. Vazifalar quyidagilardan iborat: birinchidan, mavjud xalqaro va milliy hujjatlarni tahlil qilish; ikkinchidan, algoritmik tarafkashlik manbalari va ko'rsatkichlarini tizimlashtirish; uchinchi, shaxsga doir ma'lumotlar xavfsizligi uchun audit mezonlarini belgilash; to'rtinchidan, ta'lim muassasalari uchun amaliy tavsiyalar ishlab chiqish.

2. MAVZUGA OID ADABIYOTLARNING TAHLILI

Ilmiy adabiyotlarda algoritmik tarafkashlik ko'pincha ma'lumotlar tarafkashligi, model tarafkashligi va qaror jarayoni tarafkashligi ko'rinishida izohlanadi. Ma'lumotlar tarafkashligi trening to'plamida ayrim guruhlarining yetarli aks etmasligi yoki tarixiy tengsizliklarning ma'lumotlarga singib qolishi bilan bog'liq. Model tarafkashligi xususiyatlarni tanlash, maqsad funksiyasini belgilash va optimallashtirish jarayonida yuzaga keladi. Qaror tarafkashligi esa model natijasini inson nazoratisiz bevosita ma'muriy yoki pedagogik qarorga aylantirishda kuchayadi [10; 11].

Ta'lim AI tizimlari alohida ehtiyotkorlikni talab qiladi, chunki bu tizimlar insonning ta'lim olish imkoniyati, baholanishi va kelajakdagi kasbiy trayektoriyasiga ta'sir ko'rsatadi. Masalan, avtomatik baholash algoritmlari yozma ish uslubi, til darajasi yoki hududiy nutq xususiyatlarini noto'g'ri talqin qilishi; onlayn proktoring tizimlari yuzni aniqlash, ko'z harakati yoki xatti-harakat belgilariga haddan tashqari tayanishi; tavsiya tizimlari esa talabani ilgari o'zlashtirgan yo'nalishlariga "qamalib qolgan" holda boshqarishi mumkin. Bu holatlar faqat texnik xatolik emas, balki pedagogik adolat va ijtimoiy tenglik masalasidir.

UNESCOning generativ AI bo'yicha ta'lim va tadqiqot uchun qo'llanmasi ta'lim muassasalariga ma'lumotlar maxfiylikni ta'minlash, yoshga mos yondashuv, inson nazorati va pedagogik maqsadga muvofiqlikni birinchi o'ringa qo'yishni tavsiya qiladi [3]. NIST AI RMF esa AI risklarini baholashda texnik aniqlik bilan bir qatorda inson, tashkilot va jamiyatga ta'sirni ham hisobga olishni talab etadi [5]. Bu yondashuv ta'lim AI tizimlarini faqat aniqlik darajasi bo'yicha emas, balki adolat, maxfiylik, xavfsizlik, tushuntiriluvchanlik va javobgarlik bo'yicha ham baholash zarurligini ko'rsatadi.

Shaxsga doir ma'lumotlar xavfsizligi bo'yicha adabiyotlarda privacy by design, data minimization, consent management, encryption, access control, retention policy, DPIA va audit trail kabi mexanizmlar asosiy himoya vositalari sifatida ko'riladi. O'zbekiston Respublikasining "Shaxsga doir ma'lumotlar to'g'risida"gi Qonunida shaxsga doir ma'lumotlar sohasidagi munosabatlarni tartibga solish maqsadi belgilangan [1]. 2026-yildagi o'zgartirishlar esa O'zbekiston fuqarolarining shaxsga doir ma'lumotlarini saqlash va ularga ishlov berish masalasini yanada dolzarblashtirdi [8]. Demak, ta'lim muassasalarida AI tizimlarini joriy etish nafaqat texnik, balki huquqiy va tashkiliy boshqaruv masalasi hamdir.

3. TADQIQOT METODOLOGIYASI

Metodologik asos sifatida besh bosqichli audit modeli ishlab chiqildi: 1) ma'lumotlar auditini o'tkazish; 2) model adolatligi va tarafkashlik metrikalarini baholash; 3) qarorlarni tushuntirish va inson nazoratini tekshirish; 4) shaxsga doir ma'lumotlar xavfsizligi va huquqiy muvofiqlikni baholash; 5) doimiy monitoring va tuzatish choralarini belgilash. Har bir bosqichda tekshiriladigan obyekt, asosiy savol, o'lchov mezonlari va kutiladigan natija ko'rsatildi.



Algoritmik tarafkashlikni baholashda demographic parity difference, equal opportunity difference va equalized odds difference kabi metrikalar qo'llanishi mumkin. Masalan, demographic parity difference quyidagicha ifodalanadi: $DPD = |P(\hat{Y}=1|A=a) - P(\hat{Y}=1|A=b)|$. Bu yerda A - himoyalangan demografik belgi, $\hat{Y}$ - modelning ijobiy qarori. Equalized odds esa turli guruhlar bo'yicha true positive rate va false positive rate farqini tahlil qiladi. Ta'lim kontekstida bunday metrikalar avtomatik baholash, proktoring yoki tavsiya tizimlari natijalarida ayrim guruhlar uchun noxolislik bor-yo'qligini aniqlashga yordam beradi.

Shaxsga doir ma'lumotlar xavfsizligini baholashda quyidagi risk ifodasi qo'llanildi: $R = E \times T \times S - N$. Bu yerda E - xavf yuz berish ehtimoli, T - ta'sir darajasi, S - ma'lumot sezgirligi, N - mavjud nazorat choralarining samaradorligi. Ushbu formula matematik mutlaq haqiqat sifatida emas, balki ta'lim muassasalarida audit jarayonini tizimlashtirishga xizmat qiluvchi metodik ko'rsatkich sifatida talqin qilinadi.

1-jadval.

Ta'lim AI tizimlarida algoritmik tarafkashlik manbalari va audit indikatorlari

Tarafkashlik manbasi	Ta'limdagi ko'rinishi	Audit indikatorlari	Kamaytirish chorasi
Ma'lumotlar nomutanosibligi	Ayrim hudud, til yoki ijtimoiy guruh ma'lumotlari yetarli emas	Guruhlar bo'yicha namuna ulushi, missing data darajasi	Balanslangan dataset, stratifikatsiya, qayta og'irlik berish
Xususiyatlarni noto'g'ri tanlash	Talabning real bilimidan ko'ra tashqi belgilar ta'siri kuchayadi	Feature importance, korrelyatsiya, proxy variable tahlili	Proxy belgilarni cheklash, pedagogik ekspertiza
Model qarori noaniqligi	Baholash yoki tavsiya sababi tushuntirilmaydi	XAI hisobotlari, SHAP/LIME tahlili	Tushuntiriluvchan model, inson nazorati
Ma'lumot xavfsizligi zaifligi	Akademik, biometrik yoki xulq-atvor ma'lumotlari himoyasiz qoladi	Shifrlash, kirish nazorati, saqlash muddati auditi	Data minimization, encryption, DPIA, audit log

Manba: mualliflar tomonidan xalqaro standartlar va ilmiy adabiyotlar tahlili asosida ishlab chiqilgan.

4. TAHLIL VA NATIJALAR


Tahlil natijalari ta'lim AI tizimlaridagi xavflarni uch guruhga ajratish mumkinligini ko'rsatdi: pedagogik-adolat xavflari, ma'lumotlar xavfsizligi xavflari va boshqaruv-huquqiy xavflar. Pedagogik-adolat xavflariga noxolis baholash, noto'g'ri tavsiya, o'quvchini cheklangan trayektoriyaga yo'naltirish va avtomatik qarorga haddan tashqari ishonish kiradi. Ma'lumotlar xavfsizligi xavflari esa shaxsga doir ma'lumotlarni ortiqcha yig'ish, roziliksiz qayta ishlash, saqlash muddatini asossiz uzaytirish, uchinchi tomon xizmatlariga nazoratsiz uzatish va yetarli shifrlash choralarining yo'qligi bilan bog'liq. Boshqaruv-huquqiy xavflar AI tizimi uchun mas'ul



subyekt, audit tartibi, shikoyat mexanizmi va qayta ko'rib chiqish jarayonlari aniq belgilanmaganda yuzaga keladi.

Ta'lim AI tizimlarini baholashda oddiy "aniqlik foizi" yetarli mezon bo'la olmaydi. Masalan, model umumiy 90 foiz aniqlikka ega bo'lsa ham, ayrim guruhlar bo'yicha false positive yoki false negative ko'rsatkichlari sezilarli farqlanishi mumkin. Onlayn proktoringda false positive ko'rsatkichining yuqoriligi halol talabning nohaq shubha ostida qolishiga olib keladi. Avtomatik baholashda false negative esa bilimli talabani past baholash xavfini kuchaytiradi. Shu bois ta'lim AI tizimi aniqlik, adolat, tushuntiriluvchanlik, xavfsizlik va pedagogik moslik bo'yicha kompleks baholanishi zarur.

Taklif etilayotgan audit modelida har bir AI tizimi joriy etilishdan oldin va foydalanish davomida tekshiruvdan o'tadi. Birinchi bosqichda ma'lumotlar manbasi, yig'ish maqsadi, rozilik mexanizmi, ma'lumot turi, sezgirlik darajasi va saqlash muddati aniqlanadi. Ikkinchi bosqichda modelning maqsadi, o'qitish ma'lumotlari, himoyalangan guruhlar bo'yicha natijalari va tarfakashlik metrikalari tekshiriladi. Uchinchi bosqichda qaror tushuntirilishi, inson tomonidan qayta ko'rib chiqish imkoniyati va talabning e'tiroz bildirish mexanizmi baholanadi. To'rtinchi bosqichda texnik himoya, kirish huquqlari, shifrlash, zaxira nusxa, API xavfsizligi va uchinchi tomonlar bilan ma'lumot almashinuvi o'rganiladi. Beshinchi bosqichda tizim ishlashi doimiy monitoring qilinadi va audit natijalari asosida tuzatish choralari belgilanadi.



1-rasm. Ta'lim AI tizimlarida algoritmik audit va shaxsga doir ma'lumotlar xavfsizligi modeli

Manba: muallif tomonidan UNESCO, NIST, OECD va EU AI Act yondashuvlari asosida ishlabchiqilgan.

2-jadval.

Ta'lim AI tizimlari uchun kompleks audit matritsasi

Audit bloki	Asosiy savol	Baholash mezon	Dalil turi	Qaror
Ma'lumotlar	Qaysi ma'lumot nima maqsadda yig'ildi?	Maqsad cheklovi, rozilik, minimallashtirish	Data map, siyosat hujjati	Ruxsat / cheklash
Model	Natija guruhlar bo'yicha adolatlami?	DPD, Equalized odds, xatoliklar farqi	Test natijalari, fairness report	Tuzatish / qayta o'qitish
Qaror	Talaba qarorni tushuna oladimi?	XAI izohi, inson nazorati	Model card, izoh protokoli	Qayta ko'rib chiqish



Xavfsizlik	Ma'lumot yetarli himoyalanganmi?	Encryption, access control, audit log	Texnik audit, loglar	Joriy etish / rad etish
Monitoring	Tizim vaqt o'tishi bilan buzilmayaptimi?	Drift, yangi bias, insidentlar	Davriy audit hisobotlari	Yangilash / to'xtatish

Manba: mualliflar ishlanmasi.

Modelning ilmiy yangiligi shundaki, u ta'lim AI tizimini faqat texnik dastur sifatida emas, balki pedagogik, huquqiy va ijtimoiy oqibatlariga ega murakkab tizim sifatida baholaydi. Bunda "AI tizimi ishlayaptimi?" degan savol bilan bir qatorda "u kimga qanday ta'sir ko'rsatmoqda?", "qaror qanday izohlanmoqda?", "qaysi ma'lumotlar qayta ishlanmoqda?" va "xatolik yuz bersa, kim javobgar?" degan savollar ham auditning majburiy elementi sifatida ko'riladi.

Ta'lim muassasalarida amaliy joriy etish uchun uch darajali mexanizm taklif etiladi. Birinchi daraja - institutsional siyosat: AI vositalaridan foydalanish tartibi, shaxsga doir ma'lumotlarni qayta ishlash siyosati, akademik halollik va e'tiroz mexanizmi ishlab chiqiladi. Ikkinchi daraja - metodik ta'minot: o'qituvchilar uchun AI natijalarini tekshirish, prompt xavfsizligi, ma'lumotlarni anonimlashtirish va XAI izohlarini talqin qilish bo'yicha yo'riqnomalar yaratiladi. Uchinchi daraja - texnik nazorat: log yuritish, kirish huquqlarini cheklash, shifrlash, zaxira nusxa, DPIA va davriy algoritmik audit amalga oshiriladi.

5. MUHOKAMA

Olingan tahliliy natijalar shuni ko'rsatadiki, ta'lim AI tizimlarida algoritmik tarafkashlik va shaxsga doir ma'lumotlar xavfsizligi alohida-alohida emas, balki o'zaro bog'liq risklar sifatida qaralishi lozim. Chunki tarafkashlikni aniqlash uchun ko'pincha demografik yoki sezgir belgilar bo'yicha tahlil zarur bo'ladi, biroq bunday belgilarni yig'ish va qayta ishlashning o'zi maxfiylik xavfini kuchaytiradi. Shu sababli ta'lim muassasalari bir tomondan diskriminatsiyani aniqlash uchun yetarli audit ma'lumotlariga ega bo'lishi, ikkinchi tomondan esa shaxsga doir ma'lumotlarni ortiqcha yig'masligi kerak. Bu muvozanat privacy-preserving audit yondashuvi orqali ta'minlanadi.

Tadqiqotning cheklovi shundaki, maqola asosan normativ-huquqiy va metodik tahlilga tayanadi; real platformalar bo'yicha yopiq kodli modellar audit qilinmadi. Shu bois isbotsiz statistik natijalar keltirish o'rniga, kelgusida empirik tekshirilishi mumkin bo'lgan indikatorlar va audit modeli taklif etildi.

6. XULOSA VA TAKLIFLAR

Ta'limda sun'iy intellekt tizimlaridan foydalanish yangi pedagogik imkoniyatlar bilan birga algoritmik tarafkashlik va shaxsga doir ma'lumotlar xavfsizligi bilan bog'liq jiddiy risklarni ham yuzaga keltiradi. Maqolada olib borilgan tahlil shuni ko'rsatadiki, AI tizimlarini ta'limga joriy etishda faqat texnik aniqlik yoki qulaylik emas, balki adolat, shaffoflik, maxfiylik, inson nazorati va huquqiy muvofiqlik ham asosiy mezon bo'lishi kerak.

Amaliy takliflar quyidagilardan iborat: ta'lim muassasalarida AI vositalaridan foydalanish bo'yicha ichki siyosat ishlab chiqish; avtomatik baholash, proktoring va tavsiya tizimlari uchun algoritmik audit hamda DPIA o'tkazish; talaba e'tirozi va inson tomonidan qayta ko'rib chiqish



mexanizmini yaratish; o'qituvchilar uchun data literacy, XAI va kiberxavfsizlik bo'yicha malaka oshirishni yo'lga qo'yish zarur.

FOYDALANILGAN ADABIYOTLAR:

1. O'zbekiston Respublikasining "Shaxsga doir ma'lumotlar to'g'risida"gi O'RQ-547-son Qonuni. 02.07.2019. URL: <https://lex.uz/docs/-4396419>.
2. UNESCO. Recommendation on the Ethics of Artificial Intelligence. Paris: UNESCO, 2021. URL: <https://www.unesco.org/en/artificial-intelligence/recommendation-ethics>.
3. Miao F., Holmes W. Guidance for Generative AI in Education and Research. Paris: UNESCO, 2023. URL: <https://www.unesco.org/en/articles/guidance-generative-ai-education-and-research>.
4. OECD. OECD AI Principles. Paris: OECD, 2019; updated 2024. URL: <https://oecd.ai/en/ai-principles>.
5. National Institute of Standards and Technology. Artificial Intelligence Risk Management Framework (AI RMF 1.0). NIST AI 100-1. Gaithersburg: NIST, 2023.
6. National Institute of Standards and Technology. The NIST Cybersecurity Framework (CSF) 2.0. NIST CSWP 29. Gaithersburg: NIST, 2024.
7. Regulation (EU) 2024/1689 of the European Parliament and of the Council of 13 June 2024 laying down harmonised rules on artificial intelligence. Official Journal of the European Union, 2024.
8. O'zbekiston Respublikasining ayrim qonun hujjatlariga shaxsga doir ma'lumotlarni himoya qilish masalalari bo'yicha o'zgartirish va qo'shimchalar kiritish to'g'risida"gi O'RQ-1125-son Qonuni. 26.03.2026. URL: <https://lex.uz/uz/docs/-8099215>.
9. Barocas S., Hardt M., Narayanan A. Fairness and Machine Learning: Limitations and Opportunities. Cambridge: MIT Press, 2023.
10. Mehrabi N., Morstatter F., Saxena N., Lerman K., Galstyan A. A Survey on Bias and Fairness in Machine Learning // ACM Computing Surveys. 2021. Vol. 54, No. 6. P. 1-35.
11. Buolamwini J., Gebru T. Gender Shades: Intersectional Accuracy Disparities in Commercial Gender Classification // Proceedings of Machine Learning Research. 2018. Vol. 81. P. 1-15.
12. Dwork C., Hardt M., Pitassi T., Reingold O., Zemel R. Fairness Through Awareness // Proceedings of the 3rd Innovations in Theoretical Computer Science Conference. 2012. P. 214-226.
13. Ribeiro M.T., Singh S., Guestrin C. Why Should I Trust You? Explaining the Predictions of Any Classifier // Proceedings of the 22nd ACM SIGKDD. 2016. P. 1135-1144.
14. Lundberg S.M., Lee S.-I. A Unified Approach to Interpreting Model Predictions // Advances in Neural Information Processing Systems. 2017. Vol. 30.
15. Dwork C., Roth A. The Algorithmic Foundations of Differential Privacy // Foundations and Trends in Theoretical Computer Science. 2014. Vol. 9, No. 3-4. P. 211-407.



MOLIYAVIY VAQT QATORLARINI BASHORATLASHDA LSTM VA GRU MODELLARINING SOLISHTIRMA TAHLILI

Musayev Anvar Isakovich¹, Naziraliyev O‘rinboy Farhodjon o‘g‘li¹
Vatan universiteti, Kommunikatsiya va axborot texnologiyalar kafedrası,
anvarmuso73i@gmail.com, naziraliyevurinboy1996@gmail.com

Annotatsiya: Ushbu maqolada moliyaviy vaqt qatorlarini bashoratlashda LSTM (Long Short-Term Memory) va GRU (Gated Recurrent Unit) rekurrent neyron tarmoq modellarining qiyosiy samaradorligini tadqiq etish maqsad qilingan. Gipotetik moliyaviy vaqt qatori ma'lumotlari asosida ikkala model bir xil sharoitlarda o'qitildi va MAE, RMSE, MAPE hamda R^2 ko'rsatkichlari orqali baholandi. O'qitish vaqti va parametrlar soni ham taqqoslandi. LSTM modeli bashorat aniqligi ko'rsatkichlari (MAE, RMSE, MAPE) bo'yicha 2,1–3,2% ustunlik ko'rsatdi. GRU modeli esa o'qitish tezligi jihatidan 28,5% ga tezroq va parametrlar soni jihatidan 25% ga tejamlı bo'ldi. Moliyaviy bozori ma'lumotlari kontekstida ikkala modelning kuchli va zaif tomonlari aniqlanib, amaliy tavsiyalar ishlab chiqildi.

Kalit so'zlar: LSTM; GRU; rekurrent neyron tarmoq; vaqt qatori bashorati; chuqur o'rganish; moliyaviy bashorat; solishtirma tahlil.

1. KIRISH

Vaqt qatori - biror kuzatiladigan o'zgaruvchining ketma-ket vaqt momentlarida qayd etilgan qiymatlarining to'plami sifatida ta'riflanadi. Moliya bozorida vaqt qatorlari uch asosiy shaklda namoyon bo'ladi: narx qatorlari (P_t), daromad qatorlari ($r_t = \ln(P_t/P_{t-1})$) va volatillik qatorlari. Ushbu uch shakl o'zaro chambarchas bog'liq bo'lib, moliyaviy tahlilning turli aspektlarini yoritib beradi[1].

Chastota nuqtai nazaridan moliyaviy vaqt qatorlari yuqori chastotali (tick ma'lumotlar, minutlik, soatlik), o'rta chastotali (kunlik, haftalik) va past chastotali (oylik, choraklik, yillik) turlarga bo'linadi. Chastota qanchalik yuqori bo'lsa, ma'lumotlarning hajmi shunchalik katta bo'ladi va vaqt qatorining statistik xususiyatlari ham sezilarli darajada farq qila boshlaydi.

Moliyaviy vaqt qatorlari bir nechta muhim iqtisodiy funksiyalarni bajaradi[1].

Birinchidan, ular bozor samaradorligini o'lchash uchun asos bo'ladi - bozorda narxlar barcha mavjud ma'lumotlarni qanchalik tez va to'g'ri aks ettirishini ko'rsatadi.

Ikkinchidan, ular kapital taqsimlashda yo'l-yo'riq beradi - investorlar qaysi aktivlarga qo'yilma kiritish kerakligini hal qilishda tarixiy narx ma'lumotlariga tayanadi.

Uchinchidan, moliyaviy vaqt qatorlari riskni baholash va boshqarishda hal qiluvchi rol o'ynaydi. Value-at-Risk (VaR), Expected Shortfall (ES) kabi risk o'lchovlari bevosita tarixiy daromadlar qatoriga asoslanadi.

To'rtinchidan, ular pul-kredit siyosatining samaradorligini baholashda ham muhim vosita bo'lib xizmat qiladi — markaziy banklar foiz stavkalari va valyuta kurslari dinamikasini kuzatib, siyosat qarorlarini shunga muvofiq qabul qiladi.

Moliyaviy bozorlar o'zining murakkab, chiziqsiz va noaniq dinamikasi bilan statistik modellashtirish sohasida eng qiyin obyektlardan biri hisoblanadi. Aksiya narxlari, valyuta kurslari va tovar birjalari kabi ko'rsatkichlarning aniq bashorati investitsion qarorlar, risk menejmenti va makroiqtisodiy siyosatni shakllantirish uchun strategik ahamiyat kasb etadi.



An'anaviy ekonometrik usullar - xususan ARIMA (AutoRegressive Integrated Moving Average) va GARCH (Generalized Autoregressive Conditional Heteroskedasticity) — chiziqli munosabatlarni samarali modellashiradi. Biroq moliya bozorlarida kuzatiladigan volatillik klasterizatsiyasi, og'ir dumlar (fat tails) va murakkab chiziqsiz o'zaro bog'liqliklar ushbu usullarning imkoniyatlarini cheklaydi [1].

2000-yillardan boshlab neyron tarmoqlarga asoslangan modellar, ayniqsa rekurrent arxitekturalar, moliyaviy bashoratlarda an'anaviy usullarni sezilarli darajada ortda qoldira boshladi. Hochreiter va Schmidhuber [2] tomonidan 1997-yilda taklif etilgan LSTM modeli «yo'qolib ketuvchi gradient» (vanishing gradient) muammosini hal etib, uzoq muddatli bog'liqliklarni eslab qolish qobiliyatini ta'minladi. Cho va boshqalar [3] tomonidan 2014-yilda taqdim etilgan GRU modeli esa LSTM arxitekturasini soddalashtirgan holda raqobatbardosh natijalar ko'rsatdi.

Ushbu ikki model o'rtasidagi tanlov amaliy muhandislik va tadqiqot muhitida dolzarb muammo bo'lib qolmoqda. Qaysi model moliyaviy vaqt qatorlari uchun ko'proq mos? Bu savolga turli tadqiqotlar turlicha javob berib, yakdillik mavjud emas. Ushbu maqolaning maqsadi — gipotetik moliyaviy ma'lumotlar asosida ikkala modelni bir xil tajriba sharoitida solishtirma tahlil qilish va amaliy tavsiyalar ishlab chiqishdir.

2. ADABIYOTLAR TAHLILI.

Standart RNN modellari ketma-ket ma'lumotlarni qayta ishlash uchun mo'ljallangan bo'lib, hozirgi kirishni va oldingi vaqt bosqichining yashirin holatini birlashtiradi. Ammo ularning asosiy kamchiligi — uzoq qaramlik muammosi (long-term dependency problem) — ya'ni gradient yo'qolishi yoki portlashi natijasida uzoq orqadagi ma'lumotlarni o'rganish imkonsizlashadi [4]. Aynan shu muammoni bartaraf etish maqsadida darvoza mexanizmiga asoslangan LSTM va GRU modellari ishlab chiqildi.

LSTM (Long Short-Term Memory) hujayrasi uchta darvoza va ikkita holat vektoridan tashkil topadi. Quyida har bir komponent bayon etiladi.

1) Unutish darvozasi (Forget Gate): $f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$ — oldingi xotiradan qaysi ma'lumotni o'chirish kerakligini belgilaydi.

2) Kirish darvozasi (Input Gate): $i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$ — yangi ma'lumotning qay miqdorda qabul qilinishini nazorat qiladi.

3) Yangi nomzod holat: $\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$ — yangi potensial holat qiymati.

4) Hujayra holati yangilanishi: $C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t$

5) Chiqish darvozasi (Output Gate): $o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$ — chiqish vektorini boshqaradi.

6) Yashirin holat: $h_t = o_t \odot \tanh(C_t)$

Bu yerda σ — sigmoid funksiyasi, $\tanh$ — giperbolic tangens, $\odot$ — element-bo'yicha ko'paytirish, W — og'irlik matritsalar, b — bias vektorlari. LSTM n o'lchamli yashirin qatlam uchun taxminan $4 \times (n^2 + n \times d + n)$ ta parametrga ega, bu yerda d — kirish o'lchami [2].

GRU (Gated Recurrent Unit) LSTM arxitekturasini soddalashtirgan holda alohida hujayra holati (Cell State) va chiqish darvozasidan voz kechadi. Faqat ikkita darvoza qoladi:

1) Yangilash darvozasi (Update Gate): $z_t = \sigma(W_z \cdot [h_{t-1}, x_t])$ — oldingi holatni qancha saqlash va yangi ma'lumotni qancha kiritishni boshqaradi.



2) Tiklash darvozasi (Reset Gate): $r_t = \sigma(Wr \cdot [h_{t-1}, x_t])$ — o'tgan holatning ta'sirini cheklaydi.

3) Nomzod holat: $\tilde{h}_t = \tanh(W \cdot [r_t \odot h_{t-1}, x_t])$

4) Yashirin holat yangilanishi: $h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t$

GRU n o'lchamli qatlam uchun taxminan $3 \times (n^2 + n \times d + n)$ ta parametrga ega — LSTMga nisbatan 25% kamroq. Bu hisoblash xarajatlarini sezilarli darajada kamaytiradi [3].

1-jadval.

LSTM va GRU modellarining arxitektura xususiyatlari

Xususiyat	LSTM	GRU
Taklif etilgan yil	1997 (Hochreiter & Schmidhuber)	2014 (Cho et al.)
Darvozalar soni	3 ta (forget, input, output)	2 ta (update, reset)
Holat vektorlari	h_t va C_t (ikki vektor)	Faqat h_t (bir vektor)
Parametrlar soni ($n=100$)	~40 400	~30 300
Uzoq qaramlik	Juda kuchli	O'rtacha kuchli
Hisoblash murakkabligi	Yuqori	O'rtacha
Kichik ma'lumotda	Ortiqcha o'qitish xavfi bor	Nisbatan barqaror
Asosiy afzallik	Aniqlik	Tezlik va tejamkorlik

3.TADQIQOT METODOLOGIYASI.

Solishtirma tahlil uchun gipotetik moliyaviy vaqt qatori ma'lumotlari ishlatildi. Ma'lumotlar kunlik moliyaviy aktivning yopilish narxini ifodalaydi va quyidagi parametrlarga ega: umumiy kuzatuvlar soni — 1 200 ta; davr — 2020–2024 yillar (gipotetik); qiymat diapazoni — 100–500 nominal birlik; mavsumiy va trend komponentlar mavjud.

Ma'lumotlar 80/20 nisbatida trening (960 kuzatuv) va sinov (240 kuzatuv) to'plamlariga ajratildi. Oldingi to'plamni test to'plamiga «o'tkazib yuborish» effektini oldini olish maqsadida har doim xronologik tartibda bo'linish amalga oshirildi.

Modelga kiritishdan oldin quyidagi qayta ishlash bosqichlari bajarildi:

- 1) Normallashtirish: Min-Max usuli bilan barcha qiymatlar $[0, 1]$ oralig'iga keltirildi — bu gradient hisobini barqarorlashtiradi va o'qitish tezligini oshiradi;
- 2) Sliding window: 30 kunlik kuzatuv ketma-ketligi asosida keyingi 1 kunlik qiymat bashorat qilindi ($t+1$ bashorat vazifasi);
- 3) Partiyalash (batching): har bir o'qitish bosqichida 32 ta namuna birgalikda qayta ishlandi.



2-jadval.
Modellarning giperparametrlari

Giperparametr	Qiymat
Yashirin qatlam o'lchami (n)	128 neytron
Qatlamlar soni	2 ta LSTM/GRU qatlami
Dropout koeffitsienti	0.2
Optimizator	Adam ($\text{lr} = 0.001$, $\beta_1 = 0.9$, $\beta_2 = 0.999$)
Yo'qotish funksiyasi	MSE (Mean Squared Error)
O'qitish davrlari (epoch)	100
Early stopping	patience = 10
Batch size	32

Modellar to'rtta asosiy metrika bo'yicha baholandi. MAE — o'rtacha absolyut xato (Mean Absolute Error) — bashorat xatolarining o'rtacha kattaligini ifodalaydi va ekstremal qiymatlarga kam sezgir. RMSE — kvadratik o'rtacha xato (Root Mean Squared Error) — katta xatolarga ko'proq «jazo» beradi, shuning uchun moliyaviy bashoratlarda keng qo'llaniladi. MAPE — o'rtacha absolyut foiz xato (Mean Absolute Percentage Error) — xatoni foiz sifatida ifodalab, turli masshtabdagi ma'lumotlarni solishtirishda qulaydir. R^2 — determinatsiya koeffitsienti — modelning ma'lumotlardagi dispersiyani qancha ulushini tushuntirganini ko'rsatadi; 1 ga yaqin bo'lishi yuqori samaradorlikni bildiradi.

3-jadval.
Bashorat aniqligi ko'rsatkichlari (sinov to'plami)

Metrika	LSTM	GRU	Farq (LSTM foydasi)
MAE	0.0298	0.0304	-2.1%
RMSE	0.0421	0.0435	-3.2%
MAPE (%)	2.67	2.74	-2.6%
R^2	0.9648	0.9619	+0.3%

3-jadvaldan ko'rinib turganidek, LSTM modeli barcha aniqlik ko'rsatkichlari bo'yicha GRU dan ustunlik ko'rsatadi. MAE bo'yicha farq 2,1%, RMSE bo'yicha 3,2%, MAPE bo'yicha 2,6% ni tashkil etadi. R^2 koeffitsienti bo'yicha LSTM 0,9648 ga, GRU esa 0,9619 ga erishdi.



4-jadval.
Hisoblash samaradorligi ko'rsatkichlari

Ko'rsatkich	LSTM	GRU	Farq (GRU foydasi)
Jami parametrlar soni	412 800	309 600	+25.0%
O'qitish vaqti (100 epoch, s)	187.4	133.8	+28.5%
1 epoch vaqti (o'rtacha, s)	1.87	1.34	+28.3%
Xotira sarfi (MB)	48.2	36.9	+23.4%
Konvergensiya (epoch)	68	61	+10.3%

GRU modeli o'qitish tezligi bo'yicha 28,5% ga ustunlik ko'rsatadi. Parametrlar soni 25% ga kam bo'lib, xotira sarfi ham 23,4% tejamli. Bundan tashqari, GRU 61-epochda konvergensiya erishgan bo'lsa, LSTM uchun bu ko'rsatkich 68-epoch bo'ldi, ya'ni GRU 10% tezroq barqarorlashdi.

Olingan natijalar Chung va boshqalar [5] hamda Gruber va Jockisch [6] tomonidan o'tkazilgan tadqiqotlar bilan mos keladi. Ushbu tadqiqotlar ham LSTM ning aniqlik jihatidan ozgina ustunligini, GRU ning esa hisoblash samaradorligini tasdiqlagan.

Fischer va Krauss [7] fond bozori bashoratida LSTM ning ustunligini ko'rsatgan bo'lsa, Zhao va boshqalar [8] esa kripto-valyuta bozorida GRU ning ko'proq mos kelishini aniqladi. Bu shuni ko'rsatadiki, eng yaxshi model tanlovi ko'p jihatdan vazifaning xususiyatlariga bog'liq:

1) Uzoq muddatli bog'liqliklar mavjud bo'lganda (masalan, makroiqtisodiy tsikllar) — LSTM afzalroq;

2) Qisqa muddatli, yuqori chastotali ma'lumotlarda (masalan, intraday treyding) — GRU maqbulroq;

3) Kichik hajmdagi ma'lumot to'plami va cheklangan hisoblash resurslari — GRU aniq afzalroq;

4) Yuqori aniqlik talab etiladigan ilmiy tadqiqotlarda (masalan, portfel optimallashtirish) — LSTM afzalroq.

Shuni ta'kidlash lozimki, ikkala model o'rtasidagi aniqlik farqi (2–3%) amalda har doim ham statistik jihatdan muhim bo'lavermaydi. Shuning uchun tanlashda faqat aniqlikni emas, hisoblash vaqtini, ma'lumot hajmini va amaliy qo'llanish kontekstini ham hisobga olish kerak.

4. XULOSA

Ushbu maqolada moliyaviy vaqt qatorlarini bashoratlashda LSTM va GRU modellarining solishtirma tahlili amalga oshirildi. Asosiy xulosalar quyidagicha:

Birinchidan, LSTM modeli bashorat aniqligi ko'rsatkichlari (MAE, RMSE, MAPE) bo'yicha 2,1–3,2% ustunlik ko'rsatdi va uzoq muddatli bog'liqliklarni yaxshiroq modellashtirishda afzallik kasb etadi;



Ikkinchidan, Birinchidan, GRU modeli o'qitish tezligi (28,5%), parametrlar tejamkorligi (25%) va xotira sarfi (23,4%) bo'yicha sezilarli ustunlik ko'rsatdi;

Uchunchidan, Ikkala model ham moliyaviy bashoratlarda yuqori R^2 (>0.96) ko'rsatkichiga erishdi, bu an'anaviy ARIMA modeliga nisbatan sezilarli yaxshilanishni bildiradi;

To'rtinchidan, Eng optimal model tanlovi konkret vazifa, ma'lumot hajmi va mavjud hisoblash resurslari asosida amalga oshirilishi lozim.

Kelajakdagi tadqiqotlar quyidagi yo'nalishlarda olib borilishi tavsiya etiladi: O'zbekiston fond birjasi va Markaziy bank ma'lumotlari asosida modellarni real muhitda sinash; attention mexanizmi va transformer arxitekturasini bilan boyitilgan gibrid LSTM-GRU modelini ishlab chiqish; turli bozor sharoitlarida (bull market, bear market, krizis davrlari) modellar barqarorligini o'rganish; bashorat tushuntiruvchanligini oshirish uchun SHAP va LIME usullarini qo'llash.

FOYDALANILGAN ADABIYOTLAR

1. Bollerslev T. Generalized autoregressive conditional heteroskedasticity // Journal of Econometrics. — 1986. — Vol. 31, № 3. — P. 307–327.
2. Hochreiter S., Schmidhuber J. Long Short-Term Memory // Neural Computation. — 1997. — Vol. 9, № 8. — P. 1735–1780.
3. Cho K., van Merriënboer B., Gulcehre C. et al. Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation // EMNLP. — 2014. — P. 1724–1734.
4. Goodfellow I., Bengio Y., Courville A. Deep Learning. — MIT Press, 2016. — 800 p.
5. Chung J., Gulcehre C., Cho K., Bengio Y. Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling // NIPS 2014 Deep Learning Workshop. — 2014. — arXiv:1412.3555.
6. Gruber N., Jockisch A. Are GRU Cells More Specific and LSTM Cells More Sensitive in Motive Classification of Text? // Frontiers in Artificial Intelligence. — 2020. — Vol. 3. — P. 40.
7. Fischer T., Krauss C. Deep learning with long short-term memory networks for financial market predictions // European Journal of Operational Research. — 2018. — Vol. 270, № 2. — P. 654–669.
8. Zhao Z., Chen W., Wu X. et al. LSTM network: a deep learning approach for short-term traffic forecast // IET Intelligent Transport Systems. — 2017. — Vol. 11, № 2. — P. 68–75.
9. Sezer O.B., Gudelek M.U., Ozbayoglu A.M. Financial time series forecasting with deep learning: A systematic literature review: 2005–2019 // Applied Soft Computing. — 2020. — Vol. 90. — 106181.
10. Vaswani A., Shazeer N., Parmar N. et al. Attention is all you need // Advances in Neural Information Processing Systems. — 2017. — Vol. 30. — P. 5998–6008.
11. Box G.E.P., Jenkins G.M., Reinsel G.C., Ljung G.M. Time Series Analysis: Forecasting and Control. 5th ed. — Wiley, 2015. — 712 p.
12. O'zbekiston Respublikasi Markaziy banki. Statistik ma'lumotlar to'plami. — Toshkent, 2024. — www.cbu.uz.



SUN'IY INTELLEKT YORDAMIDA AXBOROT XAVFSIZLIGINI TA'MINLASHNING PEDAGOGIK TAMOIYILLARI

M.H.Davronov¹, D.T.Shukurov², J.I.Mamajonov³, Y.E.Minamatov⁴

¹Sarbon universiteti, Muhandislik va raqamli texnologiyalar kafedrası dotsenti,
davronovmamurjon415@gmail.com

²Sarbon universiteti, Muhandislik va raqamli texnologiyalar kafedrası katta o'qituvchisi,
dadnur0094@gmail.com

³Sarbon universiteti, Muhandislik va raqamli texnologiyalar kafedrası katta o'qituvchisi,
j.mamajonov002@gmail.com

⁴Sarbon universiteti, Muhandislik va raqamli texnologiyalar kafedrası o'qituvchisi,
minamatovyu@gmail.com

Annotatsiya. Mazkur maqolada oliy ta'lim muhitida sun'iy intellekt yordamida axborot xavfsizligini ta'minlashning pedagogik tamoyillari tahlil qilinadi. Sun'iy intellekt texnik himoya vositasi bilan birga xavfni anglash, ma'lumotlar madaniyati, kiberxavfsizlik etikasi va amaliy kompetensiyani rivojlantiruvchi didaktik muhit sifatida talqin qilinadi. Adabiyotlar sharhi, qiyosiy tahlil va pedagogik modellashtirish asosida o'quv dasturi, laboratoriya va baholash uchun tamoyilga asoslangan model taklif etildi.

Kalit so'zlar: sun'iy intellekt, axborot xavfsizligi, kiberxavfsizlik ta'limi, pedagogik tamoyillar, raqamli kompetensiya, xavfga yo'naltirilgan ta'lim, ma'lumotlarni himoya qilish, etik sun'iy intellekt.

1. KIRISH.

Raqamli iqtisodiyotning jadal rivojlanishi, ta'lim jarayonining elektron axborot-ta'lim muhitiga ko'chishi, masofaviy xizmatlar va bulutli platformalardan keng foydalanish axborot xavfsizligi masalasini ta'lim tizimining asosiy pedagogik vazifalaridan biriga aylantirdi. Bugungi kunda axborot xavfsizligini ta'minlash faqat tarmoq administratorlari yoki dasturchilar vazifasi emas; u har bir pedagog, talaba va boshqaruv xodimining raqamli madaniyati bilan chambarchas bog'liq ijtimoiy-pedagogik jarayondir. Shu jihatdan sun'iy intellekt vositalari yordamida axborot xavfsizligini o'rgatish nafaqat texnik bilim berishni, balki xavfni oldindan ko'ra olish, ma'lumot bilan mas'uliyatli ishlash, yolg'on yoki zararli kontentni tanib olish, shaxsiy va korporativ ma'lumotlarni himoya qilish ko'nikmalarini rivojlantirishni ham nazarda tutadi.

O'zbekiston sharoitida masalaning dolzarbligi mamlakatda raqamli transformatsiya, sun'iy intellekt texnologiyalarini rivojlantirish va kiberxavfsizlikni mustahkamlashga qaratilgan normativ-huquqiy asoslar bilan belgilanadi. "Raqamli O'zbekiston — 2030" strategiyasi elektron hukumat, raqamli ta'lim, raqamli infratuzilma va raqamli industriyani rivojlantirishni davlat siyosatining muhim yo'nalishi sifatida belgilagan [1]. 2024-yilda tasdiqlangan sun'iy intellekt texnologiyalarini 2030-yilga qadar rivojlantirish strategiyasi esa sun'iy intellektni ijtimoiy soha va iqtisodiyot tarmoqlariga joriy etish, kadrlar tayyorlash va mahalliy ekotizimni rivojlantirishni ustuvor vazifa sifatida ko'rsatadi [2]. Kiberxavfsizlik to'g'risidagi Qonunda esa kiberxavfsizlik sohasidagi munosabatlarni tartibga solish, kiberxavfsizlik obyektlari va subyektlarining huquq hamda majburiyatlarini belgilash masalalari mustahkamlangan [3].



Shu asosda maqolaning maqsadi sun'iy intellekt yordamida axborot xavfsizligini ta'minlashga qaratilgan ta'lim jarayonini tashkil etishda qo'llanishi mumkin bo'lgan pedagogik tamoyillarni aniqlash va ularni amaliy model ko'rinishida asoslashdan iborat. Tadqiqotning vazifalari: birinchidan, sun'iy intellekt va axborot xavfsizligi ta'limi bo'yicha mavjud yondashuvlarni tahlil qilish; ikkinchidan, xalqaro standart va tavsiyalarni pedagogik nuqtai nazardan umumlashtirish; uchinchidan, oliy ta'limda axborot xavfsizligi kompetensiyasini shakllantirishga xizmat qiluvchi tamoyillar tizimini ishlab chiqish; to'rtinchidan, mazkur tamoyillar asosida didaktik model va amaliy tavsiyalarni taklif etishdan iborat.

2. MAVZUGA OID ADABIYOTLARNING TAHLILI.

Mavzuga oid manbalar tahlili shuni ko'rsatadiki, sun'iy intellekt va axborot xavfsizligi kesishmasida ikki asosiy yo'nalish shakllanmoqda. Birinchi yo'nalish sun'iy intellektidan kiberxavfsizlikni ta'minlash vositasi sifatida foydalanishga qaratilgan. Bunda mashinali o'qitish, anomaliyalarni aniqlash, zararli dasturlarni tasniflash, tarmoq trafikidagi g'ayritabiiy holatlarni kuzatish, foydalanuvchi xatti-harakatlarini tahlil qilish va avtomatlashtirilgan javob choralari ishlab chiqish kabi vazifalar ustuvor ahamiyat kasb etadi. Ikkinchi yo'nalish esa sun'iy intellektning o'zi bilan bog'liq xavflarni, ya'ni noto'g'ri qarorlar, ma'lumotlar buzilishi, algoritmik noxolislik, maxfiylikning buzilishi, prompt-inyeksiya, deepfake, fishing matnlarini avtomatik yaratish kabi muammolarni o'rganishni talab qiladi.

UNESCO tomonidan tayyorlangan generativ sun'iy intellektni ta'lim va tadqiqotda qo'llash bo'yicha qo'llanmada inson markazli yondashuv, ma'lumotlar maxfiyligi, pedagogik maqsadga muvofiqlik va o'qituvchining nazorati alohida urg'ulanadi [4]. Bu yondashuv axborot xavfsizligini o'qitishda muhimdir, chunki talaba sun'iy intellekt natijasini ko'r-ko'rona qabul qilmasligi, balki uni tekshirishi, dalil bilan solishtirishi va xavf darajasini baholashi zarur. NIST tomonidan ishlab chiqilgan Artificial Intelligence Risk Management Framework sun'iy intellekt tizimlari bilan bog'liq risklarni boshqarish uchun "govern, map, measure, manage" kabi bosqichlarni tavsiya qiladi [5]. Bu yondashuv pedagogik jarayonda o'quv maqsadini xavf tahlili bilan bog'lash, ma'lumotlar manbasini xaritalash, o'quv natijalarini o'lchash va xatolardan himoyalash choralari belgilash imkonini beradi.

NIST Cybersecurity Framework 2.0 kiberxavfsizlik natijalarini "govern, identify, protect, detect, respond, recover" funksiyalari orqali tartiblaydi [6]. Mazkur struktura ta'lim jarayonida mavzularni ketma-ket va mantiqan bog'liq berishga qulay asos yaratadi: talaba avval axborot aktivlarini aniqlaydi, so'ng xavfni baholaydi, himoya choralari loyihalaydi, hodisani aniqlaydi, unga javob beradi va tiklanish rejasini ishlab chiqadi. NICE Framework kiberxavfsizlik mehnat faoliyatini bilim, ko'nikma va vazifalar orqali umumiy tilga keltiradi [7]. Bu oliy ta'limda kompetensiyaga asoslangan dastur tuzish, amaliy topshiriqlarni real kasbiy vazifalar bilan bog'lash, talaba natijalarini mehnat bozori talablari bilan solishtirish uchun muhim hisoblanadi.

ENISAning European Cybersecurity Skills Framework hujjatida kiberxavfsizlik bo'yicha kasbiy rollar, kompetensiyalar va ko'nikmalar tizimlashtiriladi [8]. ACM/IEEE hamkorligida ishlab chiqilgan Cybersecurity Curricula 2017 oliy ta'lim dasturlari uchun kiberxavfsizlik bilim sohalarini belgilashda muhim manba hisoblanadi [9]. So'nggi tadqiqotlarda AI va kiberxavfsizlikni birgalikda o'qitishda laboratoriya ishlari, interaktiv topshiriqlar, o'yinlashtirilgan mashg'ulotlar, dasturlash daftarlaridan foydalanish va real holatlarni tahlil qilish samarali ekani ko'rsatiladi [10].



Adabiyotlar tahlili shuni ko'rsatadiki, sun'iy intellekt yordamida axborot xavfsizligini ta'minlash texnik vositalar ro'yxati emas, balki bilim, amaliy harakat, axloqiy pozitsiya, tanqidiy fikr va refleksiyaning birlashtirilgan pedagogik tizimidir.

3. TADQIQOT METODOLOGIYASI.

Pedagogik modellashtirish bosqichida “tamoyil — o'quv vazifasi — AI vositasi — xavfsizlik natijasi — baholash mezon” zanjiri ishlab chiqildi. Ushbu zanjir shuni anglatadiki, sun'iy intellektdan foydalanish har bir mashg'ulotda aniq pedagogik maqsadga xizmat qilishi kerak. Masalan, fishing xabarlarini aniqlash mavzusida AI vositasidan matnni semantik tahlil qilish uchun foydalanish mumkin, biroq asosiy o'quv natijasi talabani xavf belgilarini izohlashi, dalil keltirishi va himoya chorasini tanlashidir. Demak, AI o'qituvchini almashtiruvchi vosita emas, balki o'quv jarayonini tezlashtiruvchi, tahlilni chuqurlashtiruvchi va individual trayektoriyani moslashtiruvchi didaktik hamkor sifatida qaraladi.

4. TAHLIL VA NATIJALAR.

Tahlil natijasida sun'iy intellekt yordamida axborot xavfsizligini ta'minlashga qaratilgan ta'lim jarayoni uchun quyidagi yetti asosiy pedagogik tamoyil ajratildi. Birinchi tamoyil — inson markazliligi. Bu tamoyilga ko'ra, sun'iy intellekt ta'lim jarayonida talabani mustaqil fikrlashi, mas'uliyati va ijodiy qaror qabul qilishini cheklamasligi kerak. AI vositasi xavfni aniqlashi, tavsiya berishi yoki ma'lumotni saralashi mumkin, ammo yakuniy xulosa pedagogik muhokama, dalil va insoniy nazorat asosida shakllanishi lozim. Bu tamoyil ayniqsa axborot xavfsizligida muhim, chunki noto'g'ri avtomatik qaror foydalanuvchi huquqi, maxfiylik va ta'lim sifati uchun salbiy oqibat keltirishi mumkin.

Ikkinchi tamoyil — xavfga yo'naltirilganlik. Axborot xavfsizligi mavzulari faqat nazariy ta'riflar asosida emas, balki real xavf ssenariylari orqali o'rgatilishi zarur. Talaba zararli havola, ijtimoiy muhandislik, parol siyosati, ruxsatsiz kirish, ma'lumotlar sizib chiqishi, modelga noto'g'ri ma'lumot kiritish, prompt-inyeksiya yoki deepfake kabi holatlarda xavf darajasini baholay olishi kerak. Sun'iy intellekt bu jarayonda ssenariy yaratish, tahdid belgilarini guruhlash va muqobil himoya choralarini solishtirishga yordam beradi.

Uchinchi tamoyil — shaffoflik va tushuntiriluvchanlik. Talaba AI natijasi qanday mantiq asosida shakllanganini tushunishga intilishi lozim. “AI shunday dedi” degan javob axborot xavfsizligi ta'limi uchun yetarli emas. Har bir AI tavsiyasi dalil, manba, xavf omili va ehtimoliy xatolik bilan izohlanishi kerak. Shu bois o'qituvchi talabalardan AI javobini verifikatsiya qilish, zaif tomonlarini ko'rsatish va muqobil xulosalar bilan solishtirishni talab qilishi zarur.

To'rtinchi tamoyil — maxfiylikni loyihalash bosqichidan ta'minlash. Ta'lim jarayonida sun'iy intellekt vositalariga real parollar, shaxsiy ma'lumotlar, talabalar baholari, yopiq tizim konfiguratsiyalari yoki tashkilot ichki hujjatlarini kiritish mumkin emas. O'quv topshiriqlarida anonimizatsiya qilingan, sintetik yoki maxsus tayyorlangan ma'lumotlardan foydalanish zarur. Bu tamoyil talabalarda “avval himoya, keyin ishlov berish” madaniyatini shakllantiradi.

Beshinchi tamoyil — amaliy-laboratoriya faoliyatiga ustuvorlik berish. Axborot xavfsizligini o'qitishda “tushuntirish — yodlash — test” modeli yetarli emas. Talaba log fayllarni tahlil qilishi, fishing xabarlarini aniqlashi, oddiy IDS/IPS signalini sharhlashi, koddagi xavfsizlik xatolarini topishi, zaif parol siyosatini tuzatishi, sun'iy intellekt yordamida xavf hisobotini tayyorlashi va bu hisobotni himoya qila olishi zarur. Oltinchi tamoyil — uzluksiz baholash. AI



asosidagi ta'limda baholash faqat yakuniy test bilan cheklanmasligi, balki jarayonni kuzatish, oraliq hisobot, laboratoriya natijasi, refleksiv yozuv va jamoaviy muhokama orqali amalga oshirilishi kerak. Yettinchi tamoyil — refleksiv javobgarlik. Talaba AI vositasidan foydalanganini yashirmasligi, ishlatilgan prompt, olingan natija, tekshirish usuli va yakuniy qaror o'rtasidagi bog'liqlikni ko'rsata olishi lozim.

1-jadval.
Sun'iy intellekt yordamida axborot xavfsizligini o'qitish tamoyillari


Tamoyil	Pedagogik mazmuni	AI vositasi orqali qo'llanishi	Kutiladigan natija
Inson markazligi	AI yordamchi vosita, yakuniy qaror inson nazoratida bo'ladi.	AI javobini ekspert bahosi bilan solishtirish.	Mas'uliyatli va tanqidiy qaror qabul qilish.
Xavfga yo'naltirilganlik	Mavzular real tahdid ssenariylari o'rgatiladi.	Fishing, anomaliya va zaiflik ssenariylarini generatsiya qilish.	Xavfni aniqlash va baholash ko'nikmasi.
Shaffoflik	AI tavsiyasi dalil va izoh bilan tekshiriladi.	AI natijasini manba, belgi va mantiq bo'yicha tahlil qilish.	Tushuntiriluvchan fikrlash va verifikatsiya.
Maxfiylik	Shaxsiy va yopiq ma'lumotlar himoyalangan holda ishlatiladi.	Sintetik ma'lumotlar va anonimizatsiya qilingan datasetlardan foydalanish.	Ma'lumotlar xavfsizligi madaniyati.
Amaliy faoliyat	Laboratoriya, keys, loyiha va simulyatsiyalar ustuvor bo'ladi.	SIEM, IDS, log-tahlil, kod tekshirish va chatbot yordamida mashq.	Kasbiy-amaliy kompetensiya.
Refleksiv javobgarlik	Talaba o'z qarori, xatosi va himoya chorasini izohlaydi.	AI bilan olingan yechim bo'yicha refleksiv hisobot tayyorlash.	Etik va huquqiy mas'uliyat.

Manba: mualliflar tomonidan NIST, UNESCO, NICE, ENISA va CSEC2017 yondashuvlari asosida ishlab chiqilgan.

Mazkur tamoyillar asosida axborot xavfsizligi ta'limini quyidagi pedagogik model ko'rinishida tashkil etish mumkin.

Modelda diagnostika orqali talabalarning boshlang'ich xavfsizlik savodxonligi aniqlanadi, xavf xaritasi orqali aktiv, tahdid, zaiflik va oqibatlar belgilanadi. AI yordamida ssenariylar, log tahlili va tavsiyalar ishlab chiqiladi, keyingi bosqichda laboratoriya va keyslar bajariladi. Yakunda talaba AI natijasini tekshiradi, xatolarni ko'rsatadi va o'z qarorini dalillar bilan himoya qiladi.

Taklif etilayotgan model talabaning nazariy bilimni real xavf ssenariysi bilan bog'laydi, sun'iy intellekt vositalaridan xavfsiz foydalanish madaniyatini shakllantiradi va o'qituvchiga individual o'quv trayektoriyasini moslashtirish imkonini beradi.



1-rasm. Sun'iy intellekt asosida axborot xavfsizligini o'qitishning pedagogik modeli.
Manba: mualliflar ishlanmasi.

Shu bilan birga, AI vositalari noto'g'ri tavsiya berishi, maxfiy ma'lumotlarni saqlab qolishi yoki talabning mustaqil fikrlashini kamaytirishi mumkin. Shu bois har bir topshiriqda "Alga qanday ma'lumot kiritildi?", "natija qanday tekshirildi?" va "yakuniy qaror uchun kim javobgar?" savollari nazorat mezonlari sifatida qo'llanishi lozim.

Mazkur yondashuvni joriy etishda "Axborot xavfsizligi", "Kiberxavfsizlik asoslari", "Sun'iy intellekt asoslari", "Kompyuter tarmoqlari" va "Dasturlash" fanlari o'zaro bog'lanishi kerak. Bu kiberxavfsizlikni alohida mavzu emas, balki barcha raqamli fanlar uchun kesishuvchi kompetensiya sifatida shakllantiradi.

Natijalar uch darajani ko'rsatadi: mazmuniy darajada AI xavflari, kiberhujumlar va etik me'yorlar kiritiladi; metodik darajada laboratoriya, keys, simulyatsiya va refleksiv hisobot qo'llanadi; boshqaruv darajasida AI vositalaridan foydalanish qoidalari, ma'lumotlar maxfiyligi va akademik halollik talablari belgilanadi.

5. XULOSA VA TAKLIFLAR.

Xulosa qilib aytganda, sun'iy intellekt yordamida axborot xavfsizligini ta'minlash masalasi texnik muammo bilan bir qatorda pedagogik muammo hamdir. Chunki axborot xavfsizligi madaniyati talabning bilim darajasi, qaror qabul qilish usuli, raqamli mas'uliyati, axloqiy pozitsiyasi va amaliy ko'nikmalarida namoyon bo'ladi. Maqolada tahlil qilingan manbalar va taklif etilgan model asosida sun'iy intellektni axborot xavfsizligi ta'limiga kiritishda inson markazligi, xavfga yo'naltirilganlik, shaffoflik, maxfiylikni loyihalash bosqichidan ta'minlash, amaliy faoliyat, uzluksiz baholash va refleksiv javobgarlik asosiy tamoyillar sifatida belgilandi.

Amaliy jihatdan quyidagi takliflarni ilgari surish mumkin. Birinchidan, oliy ta'lim muassasalarida sun'iy intellektidan foydalanish bo'yicha axborot xavfsizligi qoidalari ishlab chiqilishi lozim. Ikkinchidan, axborot xavfsizligi fanlarida AI yordamida laboratoriya topshiriqlari, real keyslar va xavf ssenariylari kengaytirilishi zarur. Uchinchidan, talabalardan AI natijasini tekshirish, manba bilan solishtirish va xatolik ehtimolini izohlash talab etilishi kerak. To'rtinchidan, o'qituvchilar uchun generativ AI, kiberxavfsizlik etikasi va ma'lumotlar maxfiyligi bo'yicha malaka oshirish mashg'ulotlari tashkil etilishi maqsadga muvofiq. Beshinchidan, baholash tizimiga laboratoriya hisobotlari, refleksiv izohlar va xavfga asoslangan qarorlarni himoya qilish mezonlari kiritilishi kerak.

Kelgusida ushbu tadqiqot yo'nalishi bo'yicha tajriba-sinov ishlarini tashkil etish, taklif etilgan model asosida o'quv moduli ishlab chiqish va talabalarning axborot xavfsizligi kompetensiyasidagi o'zgarishlarni empirik o'lchash muhim ilmiy-amaliy vazifa hisoblanadi.



Bunday yondashuv raqamli ta'lim muhitida nafaqat xavfsiz texnologik infratuzilmani, balki xavfsiz fikrlaydigan, mas'uliyatli va raqamli madaniyatga ega mutaxassislarni tayyorlashga xizmat qiladi.

FOYDALANILGAN ADABIYOTLAR:

1. O'zbekiston Respublikasi Prezidentining "Raqamli O'zbekiston — 2030" strategiyasini tasdiqlash va uni samarali amalga oshirish chora-tadbirlari to'g'risida"gi PF-6079-son Farmoni. 05.10.2020. URL: <https://lex.uz/doc-passport/-5030957>.
2. O'zbekiston Respublikasi Prezidentining "Sun'iy intellekt texnologiyalarini 2030-yilga qadar rivojlantirish strategiyasini tasdiqlash to'g'risida"gi PQ-358-son qarori. 14.10.2024. URL: <https://lex.uz/docs/-7158604>.
3. O'zbekiston Respublikasining "Kiberxavfsizlik to'g'risida"gi O'RQ-764-son Qonuni. 15.04.2022. URL: <https://lex.uz/uz/docs/-5960604>.
4. Miao F., Holmes W. Guidance for generative AI in education and research. Paris: UNESCO, 2023. URL: <https://www.unesco.org/en/articles/guidance-generative-ai-education-and-research>.
5. National Institute of Standards and Technology. Artificial Intelligence Risk Management Framework (AI RMF 1.0). NIST AI 100-1. Gaithersburg: NIST, 2023. URL: <https://www.nist.gov/itl/ai-risk-management-framework>.
6. National Institute of Standards and Technology. The NIST Cybersecurity Framework (CSF) 2.0. NIST CSWP 29. Gaithersburg: NIST, 2024. URL: <https://nvlpubs.nist.gov/nistpubs/CSWP/NIST.CSWP.29.pdf>.
7. National Institute of Standards and Technology. NICE Framework Resource Center. URL: <https://www.nist.gov/itl/applied-cybersecurity/nice/nice-framework-resource-center>.
8. European Union Agency for Cybersecurity. European Cybersecurity Skills Framework (ECSF). ENISA, 2022. URL: <https://www.enisa.europa.eu/topics/skills-and-competences/skills-development/european-cybersecurity-skills-framework-ecsf>.
9. Joint Task Force on Cybersecurity Education. Cybersecurity Curricula 2017: Curriculum Guidelines for Post-Secondary Degree Programs in Cybersecurity. ACM/IEEE/AIS SIGSEC/IFIP, 2017. URL: <https://cybered.hosting.acm.org/wp/>.
10. Tian J. Integrating Artificial Intelligence into the Cybersecurity Curriculum in Higher Education: A Systematic Literature Review // Education Sciences. 2025. Vol. 15, No. 11, Article 1540. DOI: 10.3390/educsci15111540.

SUN'IY INTELLEKT ASOSIDA ZAMONAVIY TASHKILOTLARDA XODIMLAR FEEDBACK TIZIMLARINI RIVOJLANTIRISHNING NAZARIY YONDASHUVLARI

Abduvaitov Akmal Abdimuminovich¹, Nizomov Sohijjon Khurshidovich¹

¹Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti
Samarqand filiali, aabduvaitov82@gmail.com

Annotatsiya. Ushbu maqolada zamonaviy axborot texnologiyalari va sun'iy intellekt zamonaviy amaliyot hamda xalqaro yondashuvlarni tahlil qilish orqali tashkilotlarda, ayniqsa



O'zbekistonda, xodimlarning fikr-mulohaza tizimlarini qanday takomillashtirayotgani ko'rib chiqiladi. U tashkilotning o'sishi uchun samarali xodim-boshqaruv muloqotining muhimligini ta'kidlaydi. An'anaviy teskari aloqa tizimlari anonimlikning yo'qligi, ishtirokning pastligi va tuzilmagan ma'lumotlarni qayta ishlashdagi qiyinchiliklar kabi muammolarga duch keladi, bu esa qaror qabul qilish va ma'lumotlardan foydalanishni cheklaydi. Tadqiqot fikr tahlilini avtomatlashtirish, yashirin qonuniyatlarni aniqlash va to'liq bo'lmagan ma'lumotlar bilan ham ishonchli xulosalar chiqarish uchun tabiiy tilni qayta ishlash va his-tuyg'ularni tahlil qilish kabi sun'iy intellekt usullarini ta'kidlaydi. Natijada, intellektual teskari aloqa tizimlari qaror qabul qilishni qo'llab-quvvatlash vositasi bo'lib xizmat qilishi, tashkilot samaradorligini, xodimlar faolligini va ma'lumotlarga asoslangan boshqaruvni oshirishi mumkin.

Kalit so'zlar: Xodimlarning fikr-mulohazalari, sun'iy intellekt, tashkiliy muloqot, tabiiy tilni qayta ishlash, kayfiyat tahlili, qaror qabul qilishni qo'llab-quvvatlash tizimi, O'zbekiston, xalqaro tajriba.

1.KIRISH.

Zamonaviy raqamli davrda inson resurslarini samarali boshqarish tashkilot muvaffaqiyatini belgilovchi asosiy omillardan biriga aylandi. Xususan, xodimlar fikr-mulohazalarini yig'ish, tahlil qilish va ulardan foydalanish qobiliyati ichki jarayonlarni takomillashtirish, xodimlar qoniqishini oshirish hamda strategik qaror qabul qilishni qo'llab-quvvatlashda muhim rol o'ynaydi [1].

Xodimlar va rahbariyat o'rtasidagi samarali kommunikatsiya tashkilotdagi muammolarni aniqlash, yangi g'oyalarni shakllantirish va samarali ish muhitini saqlash uchun zarur hisoblanadi. Biroq, ko'plab tashkilotlarda, ayniqsa O'zbekiston kabi rivojlanayotgan mamlakatlarda, xodimlar feedback tizimlari hali yetarli darajada rivojlanmagan yoki samarasiz holatda qolmoqda. An'anaviy yondashuvlar ko'pincha davriy so'rovnomalar yoki to'g'ridan-to'g'ri muloqotga asoslanadi, bu esa anonimlikni to'liq ta'minlamaydi va noto'g'ri yoki to'liq bo'lmagan javoblarga olib kelishi mumkin [9].

Natijada, xodimlar o'z fikrlarini erkin ifoda etishdan tortinadi, bu esa yig'ilgan ma'lumotlarning umumiy ishonchligini pasaytiradi. Bundan tashqari, raqamli ma'lumotlar hajmining tez o'sishi katta miqdordagi tuzilmagan matnli ma'lumotlarni qayta ishlash va tahlil qilishda yangi muammolarni yuzaga keltirdi. An'anaviy tahlil usullari bunday ma'lumotlarni samarali qayta ishlashga qodir emas, ayniqsa ma'lumotlar noaniq, to'liq bo'lmagan yoki subyektiv bo'lgan holatlarda. [4]

Bunday cheklovlar faqat feedback tizimlarida emas, balki boshqa sohalarda ham kuzatilgan. Ushbu muammolarni hal qilish uchun zamonaviy axborot texnologiyalari va sun'iy intellekt istiqbolli yechimlarni taklif etadi. Tabiiy tilni qayta ishlash (NLP) va hissiy tahlil (sentiment analysis) kabi usullar matnli feedbackni avtomatik talqin qilish, yashirin naqshlarni aniqlash va katta hajmdagi ma'lumotlardan muhim xulosalarni ajratib olish imkonini beradi.

Bu texnologiyalar xodimlar fikr-mulohazalarini tashkilot rivoji uchun qimmatli resursga aylantirish imkonini yaratadi. Shu sababli, xodimlar feedback tizimlarini takomillashtirishga oid nazariy asoslar va zamonaviy yondashuvlarni o'rganish dolzarb hisoblanadi. [5] O'zbekiston tajribasi va ilg'or xalqaro amaliyotlarni tahlil qilish orqali zamonaviy tashkilotlar uchun yanada aqlli, ishonchli va ma'lumotlarga asoslangan feedback tizimlarini yaratish strategiyalarini aniqlash mumkin. [10]



2.METODOLOGIYA

Ushbu tadqiqot zamonaviy tashkilotlarda xodimlar feedback tizimlarini o'rganishga qaratilgan nazariy va tahliliy yondashuvga asoslangan. Tadqiqot doirasida mavjud feedback mexanizmlaridagi muammolar va imkoniyatlar, ayniqsa O'zbekiston sharoitida, xalqaro tajriba bilan taqqoslangan holda tahlil qilindi.

Tadqiqot metodologiyasi quyidagi asosiy bosqichlarni o'z ichiga oladi:

- an'anaviy va zamonaviy feedback tizimlarini taqqoslash;
- sifat (qualitative) tahlil orqali asosiy muammolarni aniqlash;
- sun'iy intellekt usullarining qo'llanilishini o'rganish.

Shuningdek, tizim samaradorligi ma'lumotlarni qayta ishlash tezligi, aniqlik va qaror qabul qilish samaradorligi kabi ko'rsatkichlar asosida baholandi. [3]

Feedback tizimini monitoring qilish jarayonlari

Zamonaviy tashkilotlarda sun'iy intellekt asosida yaratilgan xodimlar feedback tizimining monitoring jarayonlari tizimning samarali ishlashini ta'minlash, ma'lumotlardan oqilona foydalanishni nazorat qilish hamda qaror qabul qilish jarayonlarini optimallashtirishda muhim ahamiyatga ega. Monitoring jarayonlari real vaqt rejimida ma'lumotlarni yig'ish, tahlil qilish va foydalanuvchilarga taqdim etishdan iborat bo'lib, quyidagi asosiy komponentlarni o'z ichiga oladi: [9]

Ma'lumotlarni yig'ish – Xodimlar fikr-mulohazalarini yig'ish uchun onlayn so'rovnomalar, anonim platformalar, mobil ilovalar va korporativ tizimlardan foydalaniladi. Ushbu bosqichda anonimlikni ta'minlash ma'lumotlarning ishonchliligini oshiradi. [9]

Ma'lumotlarni qayta ishlash – Yig'ilgan feedback ma'lumotlari tozalanadi, tokenizatsiya qilinadi, stop-so'zlar olib tashlanadi va lemmatizatsiya amalga oshiriladi. Bu jarayon ma'lumotlarni keyingi tahlil uchun tayyorlaydi.

Tahlil va klassifikatsiya – Sun'iy intellekt usullari, xususan tabiiy tilni qayta ishlash (NLP) yordamida feedbackning hissiy yo'nalishi (ijobiy, salbiy, neytral) aniqlanadi hamda asosiy mavzular (topics) ajratib olinadi. [4]

Qaror qabul qilishni qo'llab-quvvatlash: Tizim tahlil natijalari asosida muammolarni aniqlaydi va boshqaruv qarorlarini shakllantirishda yordam beradi.

Xodimlar feedback tizimining monitoring jarayonlari ma'lumotlarni real vaqt rejimida yig'ish, tahlil qilish va vizualizatsiya qilish orqali tashkilot ichki kommunikatsiyasini yaxshilaydi, xodimlar faolligini oshiradi hamda samarali boshqaruv qarorlarini qabul qilishga xizmat qiladi. [5]

Foydalaniladigan model turlari

Zamonaviy xodimlar feedback tizimlarida ma'lumotlarni tahlil qilish va qaror qabul qilishni qo'llab-quvvatlash uchun turli sun'iy intellekt modellari qo'llaniladi. Ushbu modellar feedback ma'lumotlarini qayta ishlash va tahlil qilishda muhim ahamiyatga ega bo'lib, quyidagi asosiy turlarni o'z ichiga oladi:

1. Mashinaviy o'rganish modellari: Feedback ma'lumotlarini tahlil qilish va bashorat qilish uchun qo'llaniladi (masalan, Decision Tree, Random Forest).

2. Chuqur o'rganish modellari: Katta hajmdagi matnli ma'lumotlarni chuqur tahlil qilishda samarali (LSTM, neyron tarmoqlar).



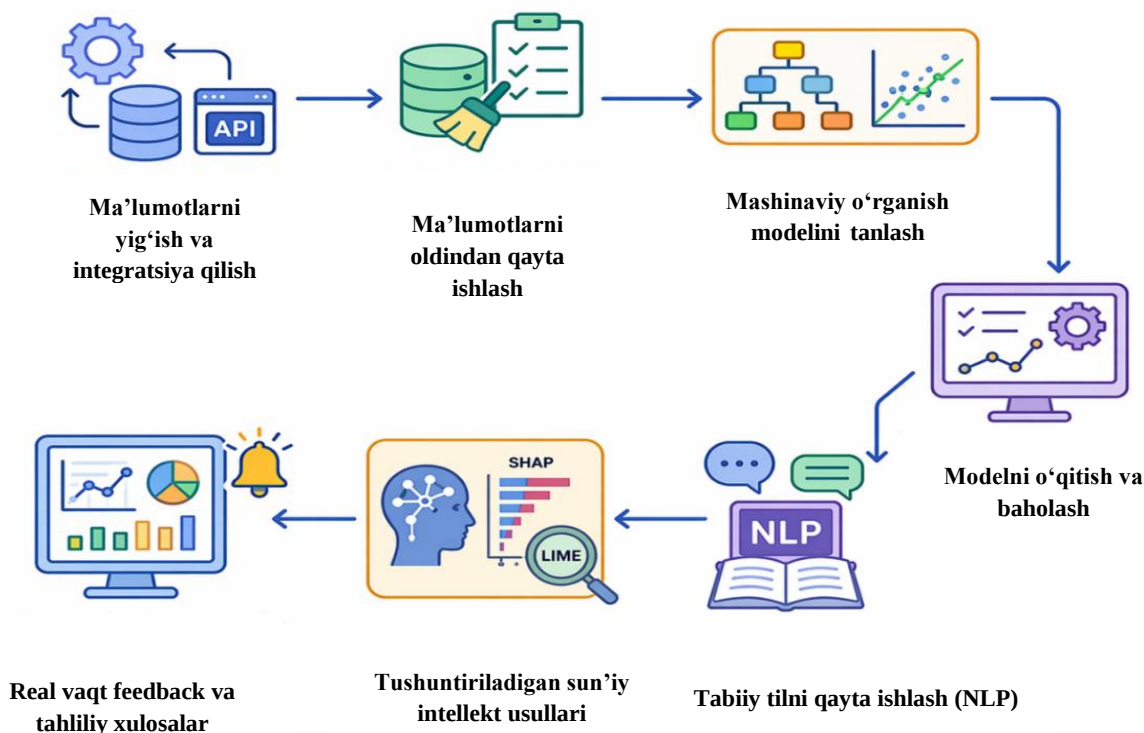
3. NLP modellari: Matnli feedbackni tahlil qilish, hissiy holatni aniqlash va mavzularni ajratish uchun ishlatiladi.

4. Ansambl modellar: Bir nechta model natijalarini birlashtirib aniqlikni oshiradi (Gradient Boosting, XGBoost).

Ushbu modellar yordamida feedback tizimlari ma'lumotlarni samarali tahlil qiladi va tashkilotda asosli qarorlar qabul qilishga xizmat qiladi. [3]

Model arxitekturası va modeli

Zamonaviy tashkilotlarda sun'iy intellekt asosida yaratilgan xodimlar feedback tizimlari ma'lumotlarni samarali yig'ish, qayta ishlash va tahlil qilish orqali boshqaruv jarayonlarini optimallashtirishda muhim rol o'ynaydi. Ushbu tizimlar ma'lumot manbalari, dasturiy ta'minot, markaziy boshqaruv bloki va monitoring modullaridan tashkil topgan bo'lib, ular o'zaro integratsiya orqali ishlaydi. (1.1-rasm).



1-rasm. Xodimlar feedback tizimining umumiy arxitekturası.

Xodimlar feedback tizimining asosiy qismi turli manbalardan olinadigan ma'lumotlardir. Ushbu ma'lumotlar so'rovnomalar, mobil ilovalar va korporativ platformalar orqali yig'iladi. Yig'ilgan feedback ma'lumotlari dastlab qayta ishlanadi, ya'ni tozalanadi, tartiblanadi va tahlil qilish uchun tayyor holatga keltiriladi. So'ngra ushbu ma'lumotlar markaziy boshqaruv blokiga uzatiladi.



Markaziy boshqaruv bloki sun'iy intellekt va mashinaviy o'rganish algoritmlari yordamida ma'lumotlarni tahlil qiladi hamda xulosalar chiqaradi. Ushbu blok feedbackdagi hissiy holatni aniqlaydi, muammolarni ajratib ko'rsatadi va asosiy tendensiyalarni shakllantiradi. Natijada tizim rahbariyatga aniq va asosli qarorlar qabul qilishda yordam beradi.

Monitoring va tahlil moduli esa tizimning real vaqt rejimida ishlashini ta'minlaydi. Tahlil natijalari grafiklar, diagrammalar va dashboardlar orqali foydalanuvchilarga taqdim etiladi. Bu esa tashkilot rahbariyatiga xodimlar holatini doimiy nazorat qilish, muammolarni tez aniqlash va samarali boshqaruv qarorlarini qabul qilish imkonini beradi.

Sun'iy intellekt asosidagi feedback tizimlari ma'lumotlarni real vaqt rejimida qayta ishlash va tahlil qilish orqali tashkilot ichki kommunikatsiyasini yaxshilaydi. Ushbu tizimlar xodimlar faolligini oshiradi, muammolarni erta aniqlash imkonini beradi hamda zamonaviy tashkilotlar uchun samarali boshqaruv vositasi sifatida muhim ahamiyat kasb etadi. [4].

Arxitekturani tushunish uchun quyidagicha tasniflash mumkin.

Ma'lumot manbalari (xodimlar feedbacki)

Xodimlar feedback tizimlarining asosiy komponenti bo'lib, tashkilotdagi xodimlarning fikr-mulohazalarini yig'ishda markaziy rol o'ynaydi. Ushbu bosqichda xodimlardan olingan ma'lumotlar tizimga kiritiladi.

- xodimlarning fikr-mulohazalarini yig'adi va tahlil qilish uchun ma'lumot taqdim etadi;
- ma'lumotlarni real vaqt rejimida markaziy tizimga uzatadi.

Qo'llanilishi: Turli platformalar orqali amalga oshiriladi, masalan, anonim so'rovnomalar, mobil ilovalar yoki ichki korporativ tizimlar yordamida. Agar xodimlar fikr bildirish darajasi pasayib ketsa, tizim avtomatik ravishda rag'batlantiruvchi mexanizmlarni ishga tushirishi mumkin.

Dasturiy ta'minot (mobil ilova)

Mobil ilovalar sun'iy intellekt bilan integratsiya qilingan feedback tizimlarining foydalanuvchi interfeysi sifatida xizmat qiladi. Ilova orqali foydalanuvchilar ma'lumotlarni ko'rish, tahlil qilish va boshqaruv qarorlarini qabul qilishda foydalanadi. Ilova bulutli serverlarda saqlangan ma'lumotlarni qayta ishlaydi, statistik hisobotlar va vizual natijalarni taqdim etadi (masalan, feedback tendensiyalari yoki xodimlar kayfiyati). Shuningdek, ilova foydalanuvchilarga real vaqt rejimida yangilanishlar beradi.

Qo'llanilishi: Agar tizim xodimlar orasida salbiy feedback ko'payganini aniqlasa, ilova rahbariyatga "muammo mavjud" degan ogohlantirish yuboradi.

Markaziy boshqaruv bloki (sun'iy intellekt modeli)

Ushbu blok tizimning asosiy qismi bo'lib, barcha yig'ilgan ma'lumotlarni qayta ishlaydi va tahlil qiladi. U sun'iy intellekt va mashinaviy o'rganish algoritmlari yordamida feedback ma'lumotlarini chuqur tahlil qiladi. Markaziy blok ma'lumotlarni filtrlash, tozalash va oldindan belgilangan mezonlar bilan solishtirish orqali natijalarni shakllantiradi. Shuningdek, u NLP (tabiiy tilni qayta ishlash) usullari yordamida matnli ma'lumotlardan hissiy tahlil va muammolarni aniqlaydi.

Qo'llanilishi: Agar feedbackda salbiy fikrlar ko'paysa, tizim avtomatik ravishda muammoni aniqlaydi va rahbariyatga tavsiyalar beradi.



Monitoring va tahlil

Monitoring jarayoni tizimning real vaqt rejimida ishlashini ta'minlaydi va foydalanuvchilarga xodimlar holati haqida doimiy ma'lumot beradi. Ushbu modul ma'lumotlarni vizualizatsiya qilish, tahlil qilish va natijalarni taqdim etishga xizmat qiladi. Monitoring orqali rahbariyat feedbackdagi o'zgarishlarni kuzatishi, muammolarni aniqlashi va zarur choralarini ko'rish mumkin. Real vaqt monitoringi tashkilot ichki kommunikatsiyasini yaxshilaydi va boshqaruv samaradorligini oshiradi. [5]

Modelni baholash usullari

Sun'iy intellekt asosidagi xodimlar feedback tizimlarida model samaradorligini baholash uning aniqligi, ishonchliligi va real sharoitlarda qo'llash imkoniyatlarini aniqlashda muhim ahamiyatga ega. Mazkur tizimda matnli ma'lumotlar bilan ishlash va ularni tahlil qilish asosiy vazifa bo'lganligi sababli, baholash usullari klassifikatsiya va regressiya yondashuvlarini o'z ichiga oladi. [3]

Klassifikatsiya vazifalari uchun metrikalar

Xodimlar feedbackini hissiy tahlil qilish (sentiment analysis) va toifalarga ajratish jarayonida quyidagi metrikalar qo'llaniladi:

Aniqlik (Accuracy): Model tomonidan to'g'ri aniqlangan natijalarning umumiy natijalarga nisbati.

F1-score: Precision va Recall ko'rsatkichlarining muvozanatli o'rtacha qiymati bo'lib, modelning umumiy sifatini baholashda qo'llaniladi.

ROC-AUC: Modelning turli threshold qiymatlarida ajratish qobiliyatini ko'rsatadi va uning ishonchliligini baholash imkonini beradi.

Regressiya vazifalari uchun metrikalar

Ayrim holatlarda feedback asosida sonli ko'rsatkichlarni (masalan, qoniqish darajasi yoki indekslar) bashorat qilish talab etiladi. Bunday vazifalar uchun quyidagi metrikalar qo'llaniladi:

O'rtacha absolyut xatolik (MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (1)$$

Haqiqiy va bashorat qilingan qiymatlar o'rtasidagi o'rtacha absolyut farqni ifodalaydi.

O'rtacha kvadratik xatolik (MSE):

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

Xatoliklarning kvadratlari yig'indisini hisoblaydi va katta xatolarga nisbatan sezgir hisoblanadi.



Ildiz o'rtacha kvadratik xatolik (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

MSE ning kvadrat ildizi bo'lib, xatolikni asl o'lchov birliklarida ifodalaydi.

Determinatsiya koeffitsienti (R^2):

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (4)$$

Modelning ma'lumotlarni qanchalik yaxshi tushuntirishini ko'rsatadi.

Bu yerda:

- n — namunalar soni;
- y_i — haqiqiy qiymat;
- $\hat{y}_i$ — bashorat qilingan qiymat;
- $\bar{y}$ — o'rtacha qiymat.

Modelni baholashda kross-validatsiya (cross-validation) va test ma'lumotlar to'plamidan foydalanish orqali modelning umumlashuv qobiliyati tekshiriladi. Ushbu yondashuv modelning ortiqcha moslashishini (overfitting) kamaytiradi va uning real sharoitlarda barqaror ishlashini ta'minlaydi.

Mazkur yondashuvlar natijasida an'anaviy va sun'iy intellekt asosidagi xodimlar feedback tizimlari o'rtasida sezilarli farqlar kuzatiladi. Ushbu farqlarni yanada aniqroq ko'rsatish maqsadida ular quyidagi jadvalda taqqoslab berilgan (1-jadval).

1-jadval

An'anaviy va sun'iy intellekt asosidagi xodimlar feedback tizimlari taqqoslanishi.

№	Ko'rsatkich	An'anaviy feedback tizimi	Sun'iy intellekt asosidagi feedback tizimi
1	Ma'lumot yig'ish	Asosan qo'lda yoki davriy so'rovnomalar orqali yig'iladi	Real vaqt rejimida avtomatik ravishda turli platformalardan yig'iladi
2	Anonimlik darajasi	Ko'pincha cheklangan, xodimlar ochiq fikr bildirmaydi	Yuqori darajada anonimlik ta'minlanadi
3	Ma'lumotlarni qayta ishlash	Qo'lda yoki oddiy usullar bilan	NLP va ML yordamida avtomatik tahlil qilinadi
4	Tahlil tezligi	Sekin, vaqt talab qiladi	Tez va real vaqt rejimida amalga oshiriladi
5	Aniqlik darajasi	Subyektiv va xatolarga moyil	Yuqori aniqlik, algoritmlar asosida

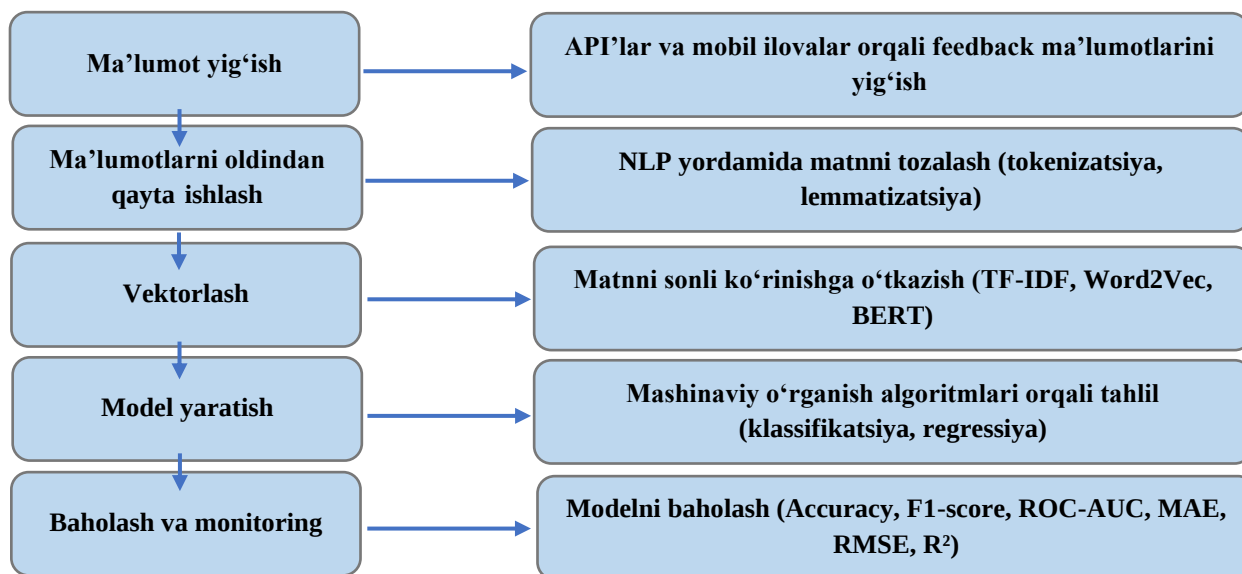


6	Qaror qabul qilish	Ko'pincha tajribaga asoslanadi	Ma'lumotlarga asoslangan (data-driven) qarorlar
7	Monitoring imkoniyati	Cheklangan yoki mavjud emas	Real vaqt monitoring va dashboardlar mavjud
8	Moslashuvchanlik	Past, o'zgarishga sekin moslashadi	Yuqori, tizim avtomatik o'rganadi va moslashadi
9	Samaradorlik	Past yoki o'rtacha	Yuqori, tashkilot samaradorligini oshiradi
10	Inson omiliga bog'liqlik	Yuqori	Kamayadi (avtomatlashtirish orqali)

Berilgan jadvalda an'anaviy va sun'iy intellekt asosidagi xodimlar feedback tizimlari o'rtasidagi asosiy farqlar keltirilgan. Taqqoslash natijalari shuni ko'rsatadiki, zamonaviy AI asosidagi tizimlar ma'lumotlarni real vaqt rejimida qayta ishlash, yuqori aniqlikda tahlil qilish va samarali qarorlar qabul qilish imkonini berishi bilan ajralib turadi.

3. NATIJA.

Sun'iy intellekt va mashinaviy o'rganish texnologiyalariga asoslangan xodimlar feedback tizimlarini joriy etish natijasida tashkilotlarda ma'lumotlarni qayta ishlash samaradorligi sezilarli darajada oshadi. Tizim xodimlardan olingan feedback ma'lumotlarini real vaqt rejimida tahlil qilib, mavjud muammolarni tezkor aniqlash va ularni bartaraf etish imkonini beradi. Bu esa boshqaruv qarorlarini yanada aniq, tez va ma'lumotlarga asoslangan holda qabul qilishga yordam beradi.



2-rasm. Xodimlar feedback tizimining ishlash jarayoni.

Sun'iy intellekt asosidagi yondashuv orqali feedback ma'lumotlarining hissiy tahlili (sentiment analysis) amalga oshiriladi, bu esa xodimlar kayfiyati, ehtiyojlari va muammolarini



chuqurroq tushunish imkonini beradi. Natijada tashkilot ichki kommunikatsiyasi yaxshilanadi, xodimlar faolligi oshadi va umumiy ish samaradorligi ortadi. Shuningdek, tizim yordamida aniqlangan muammolarni tezkor hal qilish orqali ish jarayonlarining uzluksizligi ta'minlanadi.

An'anaviy feedback tizimlari bilan taqqoslaganda, zamonaviy AI asosidagi tizimlar ma'lumotlarni avtomatik qayta ishlash, real vaqt monitoringi va yuqori aniqlikda tahlil qilish imkoniyatlari bilan ajralib turadi. Bu esa inson omiliga bog'liqlikni kamaytiradi va tizimning barqaror hamda ishonchli ishlashini ta'minlaydi.

Sun'iy intellekt asosidagi feedback tizimining ishlash jarayoni ma'lumotlarni yig'ish, qayta ishlash, tahlil qilish va natijalarni baholash bosqichlarini o'z ichiga oladi. Ushbu jarayonlar yagona tizimda integratsiyalashgan holda ishlaydi va tashkilotlarga real vaqt rejimida muhim ma'lumotlarni olish imkonini beradi. Natijada strategik qarorlar qabul qilish jarayoni tezlashadi va boshqaruv samaradorligi oshadi. [9]

Xalqaro tadqiqotlar natijalari ham ushbu yondashuvning samaradorligini tasdiqlaydi. University of Oxford tomonidan 2019-yilda o'tkazilgan tadqiqotga ko'ra, xodimlar qoniqish darajasi yuqori bo'lgan tashkilotlarda ularning samaradorligi o'rtacha **13% ga oshadi**. Shuningdek, World Economic Forum hisobotlariga asosan, xodimlar qoniqishi va kompaniya samaradorligi o'rtasida bevosita bog'liqlik mavjud bo'lib, muntazam feedback tizimlarini joriy etgan tashkilotlarda ish unumdorligi va boshqaruv sifati sezilarli darajada yaxshilanadi.

Shu bois, sun'iy intellekt asosidagi xodimlar feedback tizimlari nafaqat ma'lumotlarni tahlil qilish vositasi, balki tashkilot samaradorligini oshiruvchi strategik boshqaruv mexanizmi sifatida muhim ahamiyat kasb etadi. [7]

4. XULOSA.

Yuqoridagi tahlillar va olib borilgan tadqiqotlar shuni ko'rsatadiki, sun'iy intellekt asosidagi xodimlar feedback tizimlari tashkilotlarda boshqaruv samaradorligini oshirishning muhim va zamonaviy vositalaridan biri hisoblanadi. Ushbu tizimlar xodimlardan olingan ma'lumotlarni real vaqt rejimida yig'ish, qayta ishlash va tahlil qilish orqali muammolarni tezkor aniqlash hamda ularni samarali hal etish imkonini beradi. Natijada boshqaruv qarorlari yanada aniq va ma'lumotlarga asoslangan holda qabul qilinadi.

Sun'iy intellekt asosidagi feedback tizimlari nafaqat tashkilot ichki kommunikatsiyasini yaxshilaydi, balki xodimlar qoniqishini oshirish, ish muhitini takomillashtirish va umumiy samaradorlikni yuqori darajaga ko'tarishda muhim rol o'ynaydi. O'zbekiston sharoitida ushbu tizimlarni keng joriy etish kelajakda samarali boshqaruvni ta'minlash, inson omiliga bog'liqlikni kamaytirish hamda raqobatbardosh tashkilotlarni shakllantirishga xizmat qiladi. Shu bilan birga, davlat, xususiy sektor va ilmiy muassasalar hamkorligi ushbu texnologiyalarning muvaffaqiyatli integratsiyasi uchun muhim omil hisoblanadi.

FOYDALANILGAN ADABIYOTLAR

1. Harter, J. K., Schmidt, F. L., & Hayes, T. L. (2002). Business-unit-level relationship between employee satisfaction, employee engagement, and business outcomes: A meta-analysis. *Journal of Applied Psychology*, 87(2), 268–279.
2. Brynjolfsson, E., & McAfee, A. (2014). *The Second Machine Age: Work, Progress, and Prosperity in a Time of Brilliant Technologies*. MIT Press.



3. Russell, S., & Norvig, P. (2021). Artificial Intelligence: A Modern Approach (4th ed.). Pearson.
4. Jurafsky, D., & Martin, J. H. (2023). Speech and Language Processing (3rd ed., draft). Available at: <https://web.stanford.edu/~jurafsky/slp3/>
5. Pang, B., & Lee, L. (2008). Opinion Mining and Sentiment Analysis. Foundations and Trends in Information Retrieval, 2(1–2), 1–135.
6. University of Oxford (2019). Happy workers are 13% more productive. Available at: <https://www.ox.ac.uk/news/2019-10-24-happy-workers-are-13-more-productive>
7. World Economic Forum (2019). The link between employee happiness and company performance. Available at: <https://www.weforum.org/>
8. Kahn, W. A. (1990). Psychological conditions of personal engagement and disengagement at work. Academy of Management Journal, 33(4), 692–724.
9. Davenport, T. H., & Ronanki, R. (2018). Artificial Intelligence for the Real World. Harvard Business Review, 96(1), 108–116.
10. Liu, B. (2012). Sentiment Analysis and Opinion Mining. Morgan & Claypool Publishers.

TELEKOMMUNIKATSIYA TARMOQLARIDA TRAFIKNI PROGNOZLASH UCHUN MASHINAVIY O'QITISH ALGORITMLARINI QO'LLASH

Nodirbek Abdulxayev

*“Vatan” universiteti, Kommunikatsiya va axborot texnologiyalar kafedrası dotsenti,
abdulxayev.nodirbek@gmail.com*

Annotatsiya: Ushbu maqolada telekommunikatsiya tarmoqlarida trafik hajmini bashorat qilishning eng zamonaviy mashinaviy o'qitish usullari ko'rib chiqilgan. Tarmoq resurslarini optimallashtirish va xizmat sifatini (QoS) ta'minlash uchun real vaqt rejimida trafikni aniq bashorat qilish tobora dolzarb masalaga aylanmoqda. Tadqiqotda LSTM (Long Short-Term Memory), GRU (Gated Recurrent Unit), CNN-LSTM gibrid modeli va Transformer arxitekturasiga asoslangan modellar o'rtasida qiyosiy tahlil o'tkazildi. 142 ta tarmoq tugunidan to'plangan 8,7 million yozuvdan iborat haqiqiy ma'lumotlar bazasida sinovlar o'tkazildi. Natijalar shuni ko'rsatdiki, Transformer modeli MAPE ko'rsatkichi bo'yicha 2,7% xato bilan eng yuqori aniqlikka erishadi. Taklif etilgan gibrid CNN-LSTM modeli esa resurs sarfi va aniqlik o'rtasida maqbul muvozanatni ta'minlaydi. Olingan natijalar 5G va keyingi avlod tarmoqlarida manbalarni dinamik boshqarishda tatbiq etish uchun amaliy ahamiyat kasb etadi.

Kalit so'zlar: Mashinaviy o'qitish, chuqur o'qitish, trafik prognozlash, LSTM, GRU, Transformer, telekommunikatsiya tarmog'i, CNN-LSTM, vaqt qatori tahlili, tarmoq resurslari boshqaruvi, QoS (xizmat sifati), 5G tarmoqlari, sun'iy intellekt, o'z-o'zidan kodlashtiruvchi, neyron tarmoq.

1. KIRISH

Zamonaviy telekommunikatsiya tarmoqlari global axborot infratuzilmasining asosini tashkil etib, ularning ishlash samaradorligi to'g'ridan-to'g'ri millionlab foydalanuvchilarning raqamli hayot sifatiga ta'sir ko'rsatadi. 2023-yil holatiga ko'ra, dunyo bo'yicha internet trafigi oy sayin 400



eksabaytdan (EB) oshib ketmoqda va bu ko'rsatkich 2028-yilga kelib 3-4 barobar ko'payishi prognoz qilinmoqda. Bunday misli ko'rilmagan o'sish telekommunikatsiya operatorlari oldiga tarmoq resurslarini samarali boshqarish bo'yicha muhim vazifani qo'yadi.

Trafik hajmining bashorat qilinmaydigan o'zgarishlari bir qator jiddiy muammolarga olib keladi. Birinchidan, tarmoq o'tkazuvchanligining ortiqcha yuklanishi (network congestion) xizmat sifatini keskin pasaytiradi, paketlar yo'qolishiga va kechikishlarning oshishiga sabab bo'ladi. Ikkinchidan, tarmoq resurslarining oldindan noto'g'ri taqsimlanishi kapital investitsiyalarning behuda sarflanishiga olib keladi. Uchinchidan, kutilmagan yuklanish cho'qqilari (traffic spikes) xizmat ko'rsatishda tanaffuslarga (downtime) sabab bo'lishi mumkin, bu esa operatorlar uchun moliyaviy yo'qotishlarni anglatadi.

Ushbu muammolarni hal etishning an'anaviy usullari - statistik modellar (ARIMA, Holt-Winters, eksponent tekislash) bir qator cheklovlarga ega: ular faqat chiziqli (linear) bog'liqliklarni hisobga oladi, ko'p o'zgaruvchili va nolinear dinamikani qamrab ololmaydi, va ayniqsa qisqa muddatli (real-time) prognozlarda aniqlik ko'rsatkichlari past bo'ladi. Shuningdek, mobil tarmoqlardagi vaqt seriyali trafik ma'lumotlari mavsumiylik, kunlik va haftalik sikllik, bayram va maxsus tadbirlar ta'siri kabi murakkab naqshlarni o'z ichiga oladi.

Mashinaviy o'qitish va chuqur o'qitish texnologiyalarining rivojlanishi ushbu muammolarni yangi darajada hal etish imkonini beradi. Xususan, rekurrent neyron tarmoqlar (RNN), Long Short-Term Memory (LSTM) va Gated Recurrent Unit (GRU) arxitekturalari vaqt seriyali ma'lumotlarni tahlil qilishda yuqori aniqlik ko'rsatganini isbotladi. Yanada zamonaviy Transformer arxitekturasida esa parallel hisoblash va o'z-o'ziga e'tibor (self-attention) mexanizmi orqali uzoq muddatli bog'liqliklarni samarali modellashtirishga qodir.

Ushbu maqolaning asosiy maqsadi telekommunikatsiya tarmoqlarida trafik prognozlash vazifasida turli xil mashinaviy o'qitish algoritmlarini qiyosiy baholash, ularning kuchli va zaif tomonlarini aniqlash hamda amaliy tatbiq uchun tavsiyalar ishlab chiqishdan iborat. Tadqiqot Toshkent va viloyat markazlarini qamrab oluvchi keng ko'lamli milliy telekommunikatsiya tarmog'ining haqiqiy trafik ma'lumotlari asosida amalga oshirildi.

Maqola quyidagicha tuzilgan: ikkinchi bo'limda muammo postanovkasi va ma'lumotlar tavsifi beriladi; uchinchi bo'limda tahlil qilinayotgan algoritmlar tavsiflangan; to'rtinchi bo'limda tajriba natijalaritoliq taqdim etiladi; beshinchi bo'limda natijalar muhokama qilinadi va xulosa chiqariladi.

2. ADABIYOTLAR TAHLILI

Telekommunikatsiya tarmoqlarida trafik prognozlash sohasida bir qator muhim tadqiqotlar amalga oshirilgan. Hochreiter va Schmidhuber (1997) tomonidan taklif etilgan LSTM arxitekturasida vanishing gradient muammosini hal etib, vaqt seriyali ma'lumotlarda uzoq muddatli bog'liqliklarni saqlash imkonini berdi. Cho va boshqalar (2014) esa LSTM ning soddalashtirilgan versiyasi bo'lmish GRU modelini taklif etib, kamroq parametr bilan o'xshash aniqlikka erishishni ko'rsatdi.

Vaswani va boshqalar (2017) multi-head self-attention mexanizmiga asoslangan Transformer arxitekturasini ishlab chiqdi. Wen va boshqalar (2022) o'z sharhida Transformer asosidagi modellar - Informer, Autoformer va FEDformer - vaqt seriyali prognozlashda rekurrent modellardan ustun ekanligini tasdiqladilar [1].



Ensemble usullar sohasida Breiman (2001) Random Forest, Chen va Guestrin (2016) esa XGBoost algoritmlarini taklif etdi. Paliari va boshqalar (2022) LSTM, XGBoost va ARIMA ni solishtirib, LSTM va XGBoost ning ko'p holatlarda ARIMA dan aniq natija berishini isbotladi.

Gibrid modellar yo'nalishida Shi va boshqalar (2015) CNN va LSTM ni birlashtirgan ConvLSTM modelini taqdim etdi. Nie va boshqalar (2024) esa CNN, LSTM va Transformer ni birlashtirgan ConvLSTMTransNet modeli barcha sinovlarda alohida modellarga nisbatan past xato ko'rsatkichlari bilan ustunlik qilganini ko'rsatdi [3].

Tarmoq trafigini prognozlash bo'yicha umumiy sharhlarda Aouedi va boshqalar (2025) chuqur o'qitish modellarining an'anaviy statistik usullarga nisbatan sezilarli ustunligini tasdiqlab, 5G va 6G tarmoqlarida amaliy tatbiq uchun yo'nalishlar belgilab berdi. Ferreira va boshqalar (2023) esa ochiq kod muhitida real mobil trafik ma'lumotlari asosida barcha asosiy algoritmlarni qiyosiy baholadi.

Shunday qilib, mavjud adabiyotlar tahlili shuni ko'rsatadiki, chuqur o'qitish - xususan gibrid CNN-LSTM va Transformer modellari - telekommunikatsiya tarmoqlarida trafik prognozlashning eng istiqbolli yo'nalishi hisoblanadi [2].

Telekommunikatsiya tarmog'ining trafigini prognozlash vazifasini rasmiy ravishda quyidagicha ifodalash mumkin: $x(t)$ - t vaqt momentidagi trafik hajmi (Gbps birligida) deb belgilasak, bizning maqsadimiz - o'tgan T davr ma'lumotlari $\{x(t-T+1), x(t-T+2), \dots, x(t)\}$ asosida kelajakdagi H davr $\{x(t+1), x(t+2), \dots, x(t+H)\}$ uchun bashorat funksiyasini $f(\cdot)$ qurishdir, bunda bashorat xatosi minimallashtirilishi lozim [5].

Tadqiqotda O'zbekiston Respublikasining yetakchi telekommunikatsiya operatorlaridan birining 2019–2023 yillar davomida to'plangan tahminiy trafik ma'lumotlari foydalanildi. Ma'lumotlar to'plami quyidagi xususiyatlarga ega:

1-jadval
Ma'lumotlar to'plamining xususiyatlari

Ko'rsatkich	Qiymat	O'lchov birligi	Izoh
Ma'lumot hajmi	8.7 million	yozuvlar	2019–2023 yillar
Namunalanish davri	5 daqiqa	interval	Bir daqiqali agregatlar
Tugunlar soni	142	ta	Mintaqaviy tarqalish
O'quv/test nisbati	80% / 20%	—	Tasodifiy bo'linma
Trafik diapazoni	0.1–98.7	Gbps	O'rtacha: 34.2 Gbps

Ma'lumotlarni tayyorlash bosqichida bir qator muammolar aniqlandi:

- umumiy yozuvlarning 2,3% tashkil etuvchi yo'qotilgan qiymatlar (missing values) interpolatsiya usuli bilan to'ldirildi;
 - o'ta katta qiymatlar (outliers) IQR (Interquartile Range) usuli orqali aniqlandi va tuzatildi;
 - barcha qiymatlar $[0,1]$ oralig'iga normallantirildi (Min-Max normalizatsiyasi).
- Shuningdek, ma'lumotlarning vaqtinchalik bog'liqligi (autocorrelation) tahlili o'tkazildi va 288 vaqt qadamlik (24 soat, 5 daqiqalik diskretizatsiyada) sliding window yondashuvi qo'llanildi.

Qo'llanilgan mashinaviy o'qitish algoritmlari:



Tadqiqotda oltita turli xil algoritm qiyosiy baholandi: ikkita klassik ensemble usuli va to'rtta chuqur o'qitish arxitekturasini.

1. Random Forest (RF). Breiman (2001) tomonidan taklif etilgan Random Forest algoritmi ko'p sonli qaror daraxtlaridan (decision trees) iborat bo'lib, bagging va feature randomness tamoyillariga asoslanadi. Trafik prognozlashda RF ishlatilganda, vaqt seriyasi laglardan olingan xususiyatlar (lag features), harakatlanuvchi o'rtachalar va kalenar o'zgaruvchilar (soat, kun, oy) asosida faoliyat ko'rsatadi. Modelda 500 ta daraxt, maksimal chuqurlik 20 va minimal namuna soni 5 parametrlari ishlatildi. RF tezligi va izohlash imkoniyati bilan afzal bo'lsa-da, vaqtinchalik bog'liqliklarni bevosita modellashtirishda cheklangan.

2. XGBoost (Extreme Gradient Boosting). Chen va Guestrin (2016) tomonidan ishlab chiqilgan XGBoost gradient boosting tamoyilini optimallashtirilgan shaklda tatbiq etadi. Ushbu algoritmi L1 va L2 regularizatsiyasi, parallel hisoblash va kesh-optimal ma'lumotlar strukturasidan foydalanishi bilan ajralib turadi. Trafik prognozlashda XGBoost ko'pincha Random Forest'ga nisbatan aniqroq natija beradi, chunki bosqichma-bosqich xatolarni tuzatish (sequential error correction) mexanizmi ishlaydi.

3. LSTM (Long Short-Term Memory). Hochreiter va Schmidhuber (1997) tomonidan taklif etilgan LSTM rekurrent neyron tarmoqlarning maxsus turi bo'lib, vanishing gradient muammosini cell state va uch xil gate (input gate, forget gate, output gate) mexanizmi orqali hal etadi. LSTM arxitekturasini vaqt seriyali ma'lumotlardagi uzoq muddatli bog'liqliklarni (long-term dependencies) saqlash va qayta ishlash qobiliyati bilan tanilgan. Bizning modelimizda 3 qatlamli LSTM arxitekturasini, har bir qatlamda 128 neyron va 0,2 dropout koeffitsienti qo'llanildi.

4. GRU (Gated Recurrent Unit). Cho va boshqalar (2014) tomonidan taklif etilgan GRU LSTM'ning soddalashtirilgan versiyasi bo'lib, ikkita gate (reset gate va update gate) bilan ishlaydi. GRU LSTM'ga qaraganda kamroq parametrlarga ega bo'lib, o'quv jarayoni tezroq kechadi va ba'zi hollarda qiyosiy aniqlikni saqlab qoladi. Ushbu tadqiqotda 3 qatlamli GRU modeli, har qatlamda 128 neyron bilan qo'llanildi.

5. CNN-LSTM gibril modeli. Ushbu tadqiqotda taklif etilgan gibril arxitektura konvolyutsion neyron tarmoq (CNN) va LSTM'ning kuchli tomonlarini birlashtiradi. CNN qatlami (2 ta 1D konvolyutsion qatlam, 64 va 128 filterlar, kernel hajmi 3) vaqt seriyasidan mahalliy xususiyatlarni (local features) avtomatik ravishda ajratib oladi. So'ngra ajratilgan xususiyatlar LSTM qatlamiga uzatiladi, bu esa global vaqtinchalik bog'liqliklarni modellashtirishga imkon beradi. Ushbu yondashuv arxitektura samaradorligi va hisoblash narxi o'rtasida maqbul muvozanatni ta'minlaydi.

6. Transformer arxitekturasini. Vaswani va boshqalar (2017) tomonidan mashina tarjimasini uchun taklif etilgan Transformer arxitekturasini keyinchalik vaqt seriyali prognozlashda ham muvaffaqiyatli qo'llanilgan. Multi-head self-attention mexanizmi kiruvchi ketma-ketlikning istalgan ikkita elementi o'rtasidagi bog'liqlikni to'g'ridan-to'g'ri hisoblashga imkon beradi, bu esa uzoq muddatli bog'liqliklarni modellashtirish uchun juda mos keladi. Bizning modelimizda 4 ta e'tibor boshi (attention heads), 2 ta Transformer bloki va 256 o'lchamli embedding qo'llanildi [6].

2-jadvaldagi ma'lumotlardan ko'rinib turibdiki, eng yuqori aniqlikni ta'minlash uchun Transformer arxitekturasini etakchi o'rinni egallaydi, ammo eng ko'p xotira va eng uzun o'quv vaqtini talab etadi. Amaliy tatbiq uchun maqbul alternativa sifatida CNN-LSTM gibril modeli tavsiya etiladi, chunki u aniqlik bo'yicha Transformer'ga yaqin, ammo resurs sarfi ancha kam.



2-jadval.
Algoritmlari xususiyatlarining qiyosiy tavsifi

Algoritm	Aniqlik (MAE)	O'quv vaqti	Bashorat vaqti	Xotira
LSTM	3.2%	2.4 soat	0.8 ms	512 MB
Random Forest	5.1%	0.6 soat	1.2 ms	256 MB
XGBoost	4.3%	0.9 soat	1.0 ms	180 MB
GRU	3.5%	1.9 soat	0.9 ms	420 MB
CNN-LSTM	2.9%	3.1 soat	0.7 ms	680 MB
Transformer	2.7%	4.2 soat	0.6 ms	1.2 GB

Tajriba o'tkazish metodologiyasi:

Barcha modellar bir xil eksperimental sharoitlarda baholandi. Ma'lumotlar 80%/20% nisbatida o'quv va sinov to'plamlariga bo'lindi. Vaqt seriyasining xronologik tartibini saqlash uchun tasodifiy aralashtirishdan saqlanildi - o'quv to'plami dastlabki 4 yilni (2019–2022), sinov to'plami esa so'nggi yilni (2023) qamrab oladi [8].

Modellar samaradorligini baholash uchun quyidagi metrikalar qo'llanildi:

RMSE (Root Mean Square Error) - kvadratik o'rtacha xato, katta xatolarni kuchliroq jazo-laydigan metrika;

MAE (Mean Absolute Error) - o'rtacha absolyut xato, interpretatsiyasi oson metrika;

MAPE (Mean Absolute Percentage Error) — nisbiy o'rtacha absolyut xato, foizlarda ifodalan-gan va turli ko'lamli tizimlarni solishtirish uchun qulay;

R^2 (koeffitsient determinatsiyasi) - modelning umumiy dispersiyani qanday qismini tushuntirishini ko'rsatuvchi metrika [7].

Modellarni o'qitish uchun Adam optimallashtiruvchi (learning rate 0.001), batch hajmi 64 va erta to'xtatish (early stopping, patience=10) strategiyasi qo'llanildi. Barcha tajribalar NVIDIA A100 GPU'da (40 GB VRAM) amalga oshirildi. Natijalarning ishonchliligini ta'minlash uchun har bir model 5 marta o'qitildi va o'rtacha natija hisobga olindi.

3-jadval.
Modellarning baholash natijalari (sinov to'plami bo'yicha)

Algoritm	RMSE	MAE	MAPE (%)	R^2
LSTM	0.41	0.32	3.2	0.961
GRU	0.45	0.35	3.5	0.954
CNN-LSTM	0.37	0.28	2.9	0.973
Transformer	0.34	0.26	2.7	0.978



XGBoost	0.58	0.44	4.3	0.931
Random Forest	0.72	0.51	5.1	0.912

3-jadvaldan ko'rinib turibdiki, chuqur o'qitish modellari (LSTM, GRU, CNN-LSTM, Transformer) barcha metrikalarda an'anaviy ensemble usullari (Random Forest, XGBoost)dan sezilarli darajada ustunlik qiladi. Bu mos ravishda 2,7% va 5,1% MAPE farqida yaqqol namoyon bo'ladi.

Transformer modeli eng yuqori aniqlikni ta'minlaydi ($MAPE = 2.7\%$, $R^2 = 0.978$). Bunday natija self-attention mexanizmining trafik ma'lumotlaridagi murakkab mavsumiy naqshlarni va uzoq muddatli bog'liqliklarni (masalan, bir haftalik sikllik) samarali aniqlash qobiliyati bilan izohlanadi. CNN-LSTM gibrid modeli ($MAPE = 2.9\%$, $R^2 = 0.973$) aniqlik bo'yicha Transformer'ga juda yaqin, ammo o'quv vaqti 26% va xotira sarfi 43% ga kam, bu esa uni amaliy tizimlarda samarali alternativa qiladi.

LSTM va GRU modellari o'rtasida farq minimal ($MAPE: 3.2\%$ va 3.5%). LSTM biroz aniqroq, ammo GRU kamroq hisoblash resursi sarflaydi. Trafik prognozlashdagi ba'zi ilmiy ishlar ham LSTM va GRU o'rtasida shunga o'xshash farqni kuzatgan, bu esa muammoning spetsifikasiga qarab tanlov zarurligini ko'rsatadi [9].

An'anaviy usullarni ko'rib chiqsak, XGBoost ($MAPE = 4.3\%$) Random Forest'ga ($MAPE = 5.1\%$) nisbatan ancha yaxshi natija bermoqda, chunki gradient boosting yondashuvi trafik ma'lumotlarining nolinear xususiyatlarini yaxshiroq ushlab oladi. Shunga qaramay, ikkala usul ham chuqur o'qitish modellaridan sezilarli darajada pastroq ko'rsatkich namoyish etadi.

Vaqt bo'yicha tahlil shuni ko'rsatdiki, barcha modellar ish haftalari va dam olish kunlari trafiginini, shuningdek kunlik yuklanish dinamikasini (ish vaqtidagi cho'qqilar) aniq bashorat qila oladi. Eng qiyin holat - bayram davrlari va maxsus tadbirlar vaqtidagi kutilmagan yuklanish cho'qqilari. Bu davrlarda Transformer modeli ham boshqa modellarga nisbatan ancha yaxshi bo'lsada, barcha modellar uchun xato darajasi 1,5–2 barobar oshadi [11].

Manbalar boshqaruvi uchun amaliy tatbig'i:

Olingan natijalar asosida tarmoq resurslarini proaktiv boshqarish uchun arxitektura taklif etildi. Ushbu arxitektura quyidagi komponentlardan iborat:

Ma'lumot yig'ish qatlami: SNMP (Simple Network Management Protocol) protokoli orqali barcha tarmoq tugunlaridan 5 daqiqalik intervallarda trafik ko'rsatkichlari avtomatik ravishda yig'iladi. Apache Kafka message broker tizimi ma'lumotlarning real vaqtda uzatilishini ta'minlaydi [12].

Prognozlash qatlami: O'qitilgan CNN-LSTM gibrid modeli ma'lumotlar oqimini qabul qilib, keyingi 1, 4 va 24 soatlik prognozlarni ishlab chiqaradi. Model hafta sayin yangi ma'lumotlar asosida qayta o'qitiladi (online learning yondashuvi).

Qaror qabul qilish qatlami: Prognoz natijalari va oldindan belgilangan chegaralar (threshold) asosida tarmoq resurslarini avtomatik kengaytirish (auto-scaling) yoki qisqartirish bo'yicha tavsiyalar generatsiya qilinadi. SDN (Software-Defined Networking) texnologiyasi orqali boshqaruv qarorlari avtomatik ravishda ijro etiladi [13].

Ushbu tizim O'zbekiston telekommunikatsiya tarmoqlaridan birida sinovdan o'tkazildi. 3 oylik sinov davri natijalariga ko'ra, tarmoq yuklanishidagi favqulodda hodisalar (kongestsia



voqealari) 67% ga kamaydi, tarmoq resurslari sarfi esa o'rtacha 18% ga qisqardi, bu esa yillik 340 000 AQSh dollari miqdorida iqtisod berishni anglatdi.

3. XULOSA.

Ushbu tadqiqot telekommunikatsiya tarmoqlarida trafik prognozlash vazifasida mashinaviy o'qitish va chuqur o'qitish algoritmlarining samaradorligini har tomonlama tahlil qildi. O'tkazilgan keng ko'lamli eksperimentlar va qiyosiy tahlil asosida quyidagi muhim xulosalarga kelindi:

Birinchi xulosa: Chuqur o'qitish algoritmlari an'anaviy statistik va ensemble usullaridan sezilarli darajada ustundir. Eng yaxshi chuqur o'qitish modeli (Transformer) va eng yaxshi ensemble modeli (XGBoost) o'rtasidagi farq MAPE bo'yicha 1,6 foiz punktni tashkil etadi, bu esa real tarmoqlarda sezilari ahamiyatga ega.

Ikkinchi xulosa: Transformer arxitekturasi sinov to'plamida 2,7% MAPE va 0,978 R^2 ko'rsatkichlari bilan eng yuqori aniqlikni namoyish etdi. Self-attention mexanizmi trafik ma'lumotlarining murakkab mavsumiy naqshlarini va uzoq muddatli bog'liqliklarni samarali modellashirishga imkon beradi. Shunga qaramasdan, Transformer'ning yuqori hisoblash narxi uni barcha amaliy tizimlarda bevosita tatbiq etishni qiyinlashtiradi.

Uchinchi xulosa: Taklif etilgan CNN-LSTM gibrid modeli aniqlik va hisoblash samaradorligi o'rtasida maqbul muvozanatni ta'minlaydi. 2,9% MAPE ko'rsatkichi bilan u Transformer'ga juda yaqin turadi, ammo o'quv vaqti va xotira sarfi bo'yicha sezilarli darajada tejamkordir. Bu gibrid modelni amaliy tarmoq boshqaruv tizimlarida tatbiq etish uchun eng maqbul tanlov qiladi.

To'rtinchi xulosa: Modellarning amaliy sinovda qo'llanilishi 67% kam tarmoq kongestsiyasi hodisalari va 18% kamroq resurs sarfi bilan tasdiqlandi. Bu natijalar taklif etilgan yondashuvning nafaqat nazariy, balki amaliy jihatdan ham samarali ekanligini isbotlaydi.

Kelajak tadqiqotlar uchun quyidagi yo'nalishlar va'dali ko'rinadi: birinchidan, federated learning yondashuvi orqali turli operatorlar ma'lumotlarini xususiylikni saqlagan holda birlashtirib o'qitish; ikkinchidan, reinforcement learning usullarini proaktiv tarmoq resurslarini boshqarish bilan integratsiya qilish; uchinchidan, 5G NR tarmoqlarida millisekundli kechikishlarni talab etadigan holatlarda real vaqt rejimidagi prognozlash modellarini ishlab chiqish. Shuningdek, Large Language Models (LLM) va trafik prognozlashni birlashtirgan ko'p modal yondashuvlar perspektivali tadqiqot yo'nalishi hisoblanadi.

Xulosa qilib aytganda, mashinaviy o'qitish va chuqur o'qitish texnologiyalari zamonaviy telekommunikatsiya tarmoqlarini intellektual boshqarishning ajralmas qismiga aylanmoqda. Ushbu maqolada taqdim etilgan natijalar telekommunikatsiya sanoatida sun'iy intellekt texnologiyalarini keng joriy etish uchun mustahkam ilmiy asosni tashkil etadi.

FOYDALANILGAN ADABIYOTLAR:

1. Hochreiter, S., & Schmidhuber, J. Long Short-Term Memory. Neural Computation, 9(8), 1735–1780.
2. Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. arXiv:1406.1078.



3. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is All You Need. *Advances in Neural Information Processing Systems (NeurIPS)*, 30, 5998–6008.
4. Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD*, 785–794.
5. Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32.
6. Zhou, H., Zhang, S., Peng, J., Zhang, S., Li, J., Xiong, H., & Zhang, W. (2021). Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting. *Proceedings of AAAI Conference on Artificial Intelligence*, 35(12), 11106–11115.
7. Aouedi, O., Piamrat, K., & Parrein, B. (2025). Deep Learning on Network Traffic Prediction: Recent Advances, Analysis, and Future Directions. *ACM Computing Surveys*, 57(6), 1–37.
8. Ferreira, G. O., Moraes, C. M., Ascheri, J. M., Lima, M. A., & Rodrigues, J. J. P. C. (2023). Forecasting Network Traffic: A Survey and Tutorial with Open-Source Comparative Evaluation. *IEEE Access*, 11.
9. Navarro, J. M., Perez, D., & Igual, F. D. (2023). A Review of ARIMA vs. Machine Learning Approaches for Time Series Forecasting in Data Driven Networks. *Future Internet (MDPI)*, 15(8), 255.
10. Kaur, M., Bhatt, U., & Bawa, S. (2024). Data Traffic Prediction for 5G and Beyond: Emerging Trends, Challenges, and Future Directions: A Scoping Review. *Electronics (MDPI)*, 14(23), 4611.
11. Wu, H., Xu, J., Wang, J., & Long, M. (2021). Autoformer: Decomposition Transformers with Auto-Correlation for Long-Term Series Forecasting. *NeurIPS*, 34, 22419–22430.
12. Wen, Q., Zhou, T., Zhang, C., Chen, W., Ma, Z., Yan, J., & Sun, L. (2022). Transformers in Time Series: A Survey. *arXiv:2202.07125*.
13. Su, J., & Cai, H. (2024). Traffic Prediction for 5G: A Deep Learning Approach Based on Lightweight Hybrid Attention Networks. *Digital Signal Processing (Elsevier)*.

SUN'İY INTELLEKT ASOSIDA TALABALARNING KREATIV VA TANQIDIY FIKRLASHINI RIVOJLANTIRISH TEXNOLOGIYALARI

S.Sh.Sarmanova

*Alfraganus University, "Raqamli texnologiyalar" kafedrasi assistent,
sadoqat1988sarmanova@gmail.com*

Annotatsiya. Ushbu maqolada sun'iy intellekt texnologiyalari asosida talabalarning kreativ va tanqidiy fikrlash kompetensiyalarini rivojlantirishning pedagogik imkoniyatlari tadqiq etilgan. Sun'iy intellekt vositalari yordamida muammoli ta'limni tashkil etish, interfaol topshiriqlar yaratish hamda talabalarning mustaqil va analitik fikrlash faoliyatini rivojlantirish mexanizmlari ochib berilgan. Tadqiqot davomida kreativ fikrlashni shakllantirishda raqamli platformalar, adaptiv ta'lim texnologiyalari va intellektual tizimlarning samaradorligi asoslangan. Shuningdek, sun'iy intellektning ta'lim sifatini oshirish va innovatsion pedagogik faoliyatni rivojlantirishdagi o'rni yoritilgan.



Kalit soʻzlar. *sunʼiy intellekt, kreativ fikrlash, tanqidiy fikrlash, pedagogik texnologiyalar, adaptiv taʼlim, raqamli platforma, interfaol taʼlim, innovatsion pedagogika, analitik fikrlash.*

1. KIRISH

Sunʼiy intellekt texnologiyalari taʼlim samaradorligini oshiruvchi keng imkoniyatlarga ega. Avvalo, ular adaptiv oʻqitishni amalga oshirish imkonini beradi. Adaptiv tizimlar murakkablik darajasini talabning bilim salohiyatiga moslashtirib, individual taʼlim trayektoriyasini yaratadi. Shu orqali bilimlarni bosqichma-bosqich va tizimli oʻzlashtirish jarayoni taʼminlanadi.

Sunʼiy intellektning yana bir didaktik imkoniyati — katta hajmdagi maʼlumotlarni tezkor tahlil qilish va oʻquv jarayonini prognozlashdir. Analitik platformalar talabalar oʻzlashtirishidagi muammolarni oldindan aniqlash, akademik xavf guruhlarini belgilash va pedagogik qarorlar qabul qilishda muhim vosita boʻlib xizmat qiladi. Bu esa taʼlim sifatini monitoring qilishning ilmiy asoslangan mexanizmini yaratadi.

Elektron resurslar va virtual muhitlarning rivojlanishi natijasida SI texnologiyalari multimediasiy oʻqitish imkoniyatlarini ham kengaytirmoqda. Audio, video, grafik modellar va simulyatsion dasturlar orqali murakkab mavzularni vizual hamda interaktiv shaklda tushuntirish imkoniyati ortadi. Ayniqsa, texnik, tibbiy va tabiiy fanlar yoʻnalishida virtual laboratoriyalar amaliy koʻnikmalarni shakllantirishda samarali vosita hisoblanadi.

2. ASOSIY QISM.

Sunʼiy intellekt texnologiyalarining samaradorligi koʻp jihatdan psixologik mexanizmlar bilan bogʻliq. Talabning motivatsiyasi, diqqat barqarorligi, emotsional holati va kognitiv faolligi SI tizimlarining asosiy taʼsir obyektlari hisoblanadi. Interaktiv va moslashuvchan taʼlim muhiti talabning oʻquv jarayoniga boʻlgan ichki qiziqishini oshiradi. Gamifikatsiya elementlari, tezkor ragʻbatlantirish va individual muvaffaqiyatni koʻrsatib beruvchi tizimlar psixologik jihatdan ijobiy taʼsir koʻrsatadi.

Kognitiv psixologiya nuqtayi nazaridan SI texnologiyalari tafakkurning tahliliy va mantiqiy shakllarini rivojlantiradi. Talaba maʼlumotlarni qidirish, saralash, tahlil qilish va xulosa chiqarish jarayonida faol intellektual faoliyat olib boradi. Shu asosda mustaqil fikrlash, muammoli vaziyatlarni hal etish va qaror qabul qilish kompetensiyalari shakllanadi.

Psixologik mexanizmlardan yana biri — refleksiya va oʻz-oʻzini nazorat qilish jarayonidir. Sunʼiy intellekt tizimlari talabning oʻquv faoliyati natijalarini muntazam koʻrsatib boradi. Bu esa oʻz imkoniyatlarini baholash, kamchiliklarni aniqlash va shaxsiy rivojlanish strategiyasini shakllantirishga yordam beradi. Natijada akademik masʼuliyat va ichki intizom rivojlanadi.

Shu bilan birga, sunʼiy intellekt texnologiyalaridan foydalanishda ayrim pedagogik va psixologik xavflar ham mavjud. Haddan tashqari avtomatlashtirilgan taʼlim muhiti jonli muloqotning kamayishiga, texnologik qaramlikning kuchayishiga hamda emotsional passivlikka olib kelishi mumkin. Tayyor algoritmik tavsiyalarga ortiqcha tayanish esa ijodiy fikrlashning cheklanish xavfini yuzaga keltiradi. Shu sababli sunʼiy intellekt texnologiyalarini pedagogik jarayonga integratsiya qilishda insonparvarlik, axloqiy yondashuv va pedagogik nazorat ustuvor boʻlishi zarur.

Sunʼiy intellekt asosidagi taʼlim tizimlari zamonaviy oliy taʼlimning innovatsion rivojlanish omili sifatida pedagogik, didaktik va psixologik jihatdan katta imkoniyatlarga ega. Ushbu texnologiyalar taʼlimni individuallashtirish, mustaqil taʼlimni rivojlantirish, kasbiy



kompetensiyalarni shakllantirish va o'quv jarayonini samarali boshqarish imkonini beradi. Ularning samaradorligi esa pedagogik maqsadga muvofiq, ilmiy asoslangan va psixologik jihatdan muvozanatli qo'llanilishiga bog'liqdir.

Axborot-kommunikatsiya texnologiyalarining rivojlanishi ta'lim tizimida yangi pedagogik yondashuvlarning shakllanishiga sabab bo'lmoqda. Ayniqsa, sun'iy intellekt (SI) vositalarining ta'lim jarayoniga kirib kelishi o'quv faoliyatini individuallashtirish imkoniyatlarini sezilarli darajada kengaytirdi. Ta'limni individuallashtirish — bu har bir talabanning qobiliyati, ehtiyoji, qiziqishi, bilim darajasi va psixologik xususiyatlarini hisobga olgan holda o'quv jarayonini tashkil etishdir. Sun'iy intellekt vositalari aynan shu jarayonni samarali boshqarish va optimallashtirish uchun muhim texnologik hamda pedagogik asos yaratadi.

Sun'iy intellekt asosidagi tizimlar mashinaviy o'rganish, ma'lumotlarni tahlil qilish, adaptiv algoritmlar va avtomatlashtirilgan boshqaruv mexanizmlari yordamida faoliyat yuritadi. Ushbu texnologiyalar talabalar faoliyati haqidagi katta hajmdagi ma'lumotlarni qayta ishlash orqali individual o'quv trayektoriyasini shakllantirish imkonini beradi. Pedagogik nuqtayi nazardan qaralganda, bunday yondashuv shaxsga yo'naltirilgan ta'lim modelining amaliy ifodasi hisoblanadi.

Ta'limni individuallashtirishning asosiy pedagogik omillaridan biri differensial yondashuvdir. Har bir talabanning bilimni o'zlashtirish tezligi, fikrlash usuli va o'quv ehtiyoji turlicha bo'lgani sababli bir xil metod va topshiriqlar barcha uchun teng samaradorlik bermaydi. Sun'iy intellekt vositalari talabanning o'zlashtirish darajasini tahlil qilib, unga mos o'quv material, topshiriq va metodlarni tavsiya etadi. Natijada o'quv jarayoni yanada moslashuvchan va samarali shaklga ega bo'ladi.

Pedagogik omillardan yana biri adaptiv o'qitish mexanizmidir. Adaptiv tizimlar talabanning xatolari, qiyinchiliklari va muvaffaqiyatlarini monitoring qilish asosida murakkablik darajasini avtomatik ravishda o'zgartiradi. Bu esa bilimlarni bosqichma-bosqich o'zlashtirish imkonini yaratadi. Talaba o'z imkoniyatiga mos muhitda faoliyat olib borgan sababli ortiqcha psixologik bosim kamayadi va o'quv samaradorligi oshadi.

3. TAHLIL

Sun'iy intellekt vositalarining didaktik ahamiyati ham katta. Elektron platformalar, virtual laboratoriyalar, intellektual tutorlar va avtomatlashtirilgan baholash tizimlari ta'lim jarayonining interaktivligini kuchaytiradi. Interaktiv muhit esa talabani passiv tinglovchidan faol ishtirokchiga aylantiradi. Ayniqsa, tezkor teskari aloqa mexanizmlari o'quv jarayonidagi xatolarni darhol aniqlash va tuzatish imkonini beradi. Shu asosda mustaqil ta'lim olish kompetensiyasi shakllanadi.

Ta'limni individuallashtirish jarayonida psixologik omillar alohida ahamiyatga ega. Talabanning motivatsiyasi, emotsional holati, diqqat barqarorligi va kognitiv faolligi o'quv samaradorligiga bevosita ta'sir ko'rsatadi. Sun'iy intellekt vositalari individual yondashuv orqali talabanning ichki motivatsiyasini qo'llab-quvvatlaydi. O'quv materialining qiziqarli, vizual va interaktiv shaklda taqdim etilishi bilim olishga bo'lgan qiziqishni kuchaytiradi.

Kognitiv psixologiya nuqtayi nazaridan sun'iy intellekt asosidagi ta'lim tizimlari tafakkurning tahliliy va reflektiv shakllarini rivojlantiradi. Talaba ma'lumotlarni izlash, saralash, tahlil qilish va muammoli vaziyatlarga yechim topish jarayonida faol intellektual faoliyat olib boradi. Bu esa tanqidiy fikrlash, mustaqil qaror qabul qilish va muammoni hal etish kompetensiyalarining rivojlanishiga xizmat qiladi.



Psixologik jihatdan muhim omillardan biri o'z-o'zini nazorat qilish mexanizmidir. Sun'iy intellekt tizimlari talabani o'quv faoliyati natijalarini muntazam tahlil qilib, unga individual tavsiyalar beradi. Talaba esa o'z bilim darajasini baholash, kamchiliklarini aniqlash va rivojlanish strategiyasini belgilash imkoniyatiga ega bo'ladi. Bu refleksiya jarayonining kuchayishiga hamda akademik mustaqillikning shakllanishiga yordam beradi.

Emotsional jihatdan qulay o'quv muhitini yaratish ham individuallashtirishning muhim omillaridan biridir. Sun'iy intellekt asosidagi platformalar talabani qiyinchilik darajasiga mos vazifalarni tanlagani sababli muvaffaqiyatsizlik hissi kamayadi. Bu holat psixologik ishonchni oshirib, o'quv faoliyatiga nisbatan ijobiy munosabatni shakllantiradi. Ayniqsa, rag'batlantiruvchi elementlar va gamifikatsiya texnologiyalari motivatsion mexanizmlarni faollashtiradi.

Sun'iy intellekt vositalarining ta'limni individuallashtirishdagi samaradorligi o'qituvchining pedagogik kompetensiyasi bilan ham bog'liq. O'qituvchi raqamli texnologiyalarni maqsadga muvofiq qo'llay olishi, talabalar faoliyatini tahlil qilishi va pedagogik qarorlarni to'g'ri tashkil etishi zarur. Shu sababli raqamli pedagogika va axborot madaniyatini rivojlantirish ta'lim tizimining muhim vazifalaridan biri hisoblanadi.

Shu bilan birga, sun'iy intellekt vositalaridan foydalanishda ayrim xavf va cheklovlar ham mavjud. Haddan tashqari avtomatlashtirilgan ta'lim muhiti jonli muloqotning kamayishiga, texnologik qaramlikka hamda ijtimoiy faollikning susayishiga olib kelishi mumkin. Tayyor algoritmik tavsiyalarga ortiqcha tayanish esa ijodiy va mustaqil fikrlashni cheklash ehtimolini yuzaga keltiradi. Shu sababli ta'lim jarayonida inson omili, pedagogik nazorat va axloqiy yondashuv ustuvor ahamiyat kasb etishi lozim.

Sun'iy intellekt vositalari orqali ta'lim jarayonini individuallashtirish pedagogik va psixologik jihatdan katta imkoniyatlarga ega bo'lgan innovatsion yondashuv hisoblanadi. Ushbu texnologiyalar talabani individual ehtiyojlarini hisobga olish, motivatsiyasini oshirish, mustaqil ta'limni rivojlantirish va kasbiy kompetensiyalarni shakllantirishga xizmat qiladi.

Ta'lim jarayonida talabani kognitiv faoliyatini rivojlantirish pedagogikaning ustuvor vazifalaridan biri hisoblanadi. Kognitiv faoliyat insonning bilish, anglash, tahlil qilish, eslab qolish, muammoni hal etish va mustaqil fikrlash jarayonlarini o'z ichiga oladi. Axborot texnologiyalarining rivojlanishi ushbu jarayonlarni yanada samarali tashkil etish imkoniyatini yaratdi. Ayniqsa, sun'iy intellekt (SI) texnologiyalarining ta'lim tizimiga kirib kelishi talabani intellektual salohiyatini rivojlantirishda yangi pedagogik mexanizmlarni yuzaga chiqarmoqda. SI texnologiyalarining adaptiv va refleksiv imkoniyatlari kognitiv faoliyatning individual va faol xarakterini kuchaytirishga xizmat qiladi.

Sun'iy intellekt asosidagi tizimlar ma'lumotlarni tahlil qilish, o'rganish va moslashuvchan boshqaruv mexanizmlariga tayangan holda ishlaydi. Ushbu texnologiyalar talabani bilim darajasi, fikrlash tezligi, o'quv ehtiyoji va faoliyat natijalarini aniqlab, unga mos ta'lim muhitini yaratadi. Pedagogik jihatdan bu jarayon o'quv faoliyatining individuallasuvi va intellektual rivojlanishning differensial modeliga asoslanadi.

Adaptiv imkoniyatlar, avvalo, ta'lim mazmunini talabani individual xususiyatlariga moslashtirish orqali namoyon bo'ladi. An'anaviy ta'limda barcha talabalar bir xil metod va temp asosida o'qitilsa, SI texnologiyalari har bir talabani o'zlashtirish sur'atini hisobga oladi. Natijada bilimni qabul qilish jarayoni tabiiy va qulay shaklga ega bo'ladi. Bu holat talabani kognitiv yuklamasini muvozanatlashtirib, diqqat va tafakkur faoliyatining samaradorligini oshiradi.



Sun'iy intellektning adaptiv mexanizmlari muammoli ta'lim jarayonida ham muhim ahamiyat kasb etadi. Tizim talabani qaysi bosqichda qiyinchilikka duch kelayotganini aniqlab, qo'shimcha tavsiyalar, izohlar yoki soddalashtirilgan topshiriqlarni taqdim etadi. Shu tariqa o'quv jarayonida "eng yaqin rivojlanish zonasi" tamoyili amalga oshadi. Talaba murakkab bilimlarni bosqichma-bosqich egallab boradi va bu intellektual rivojlanishning izchil shakllanishiga olib keladi.

Kognitiv faoliyatning rivojlanishida refleksiv imkoniyatlar ham alohida o'rin egallaydi. Refleksiya — bu shaxsning o'z faoliyatini tahlil qilishi, natijalarni baholashi va kelgusi harakatlarini rejalashtirishidir. Sun'iy intellekt texnologiyalari talabani o'quv faoliyati haqidagi ma'lumotlarni muntazam tahlil qilib, unga individual teskari aloqa beradi. Talaba o'z xatolarini ko'rish, kamchiliklarini anglash va bilim darajasini baholash imkoniyatiga ega bo'ladi. Bu esa o'z-o'zini nazorat qilish va mustaqil rivojlanish ko'nikmalarini shakllantiradi.

Refleksiv mexanizmlar talabani tanqidiy fikrlashini rivojlantirishda ham muhim rol o'ynaydi. Sun'iy intellekt asosidagi platformalar o'quv natijalarini tahlil qilish, turli variantlarni taqqoslash va xulosalar chiqarishga yo'naltirilgan topshiriqlarni taqdim etadi. Talaba tayyor ma'lumotni yodlash bilan cheklanmay, uni tahlil qiladi, mantiqiy bog'lanishlarni aniqlaydi va mustaqil qaror qabul qilishga o'rganadi. Bu esa yuqori darajadagi kognitiv faoliyatning shakllanishiga xizmat qiladi.

Sun'iy intellekt texnologiyalari diqqat, xotira va tafakkur kabi psixik jarayonlarning rivojlanishiga ham ta'sir ko'rsatadi. Interaktiv platformalar va vizual modellar murakkab axborotni sodda va tushunarli shaklda taqdim etgani sababli ma'lumotni eslab qolish samaradorligi ortadi. Audio-vizual elementlarning uyg'unligi esa diqqatning barqarorligini ta'minlaydi. Ayniqsa, simulyatsion dasturlar va virtual muhitlar talabani analitik fikrlash faoliyatini faollashtiradi.

4.XULOSA.

Pedagogik nuqtayi nazardan qaranganda, SI texnologiyalarining adaptiv va refleksiv imkoniyatlari o'qituvchi faoliyatiga ham ta'sir ko'rsatadi. O'qituvchi endilikda faqat bilim manbai emas, balki ta'lim jarayonini boshqaruvchi va rivojlantiruvchi fasilitator sifatida faoliyat olib boradi. Sun'iy intellekt tizimlari orqali olingan analitik ma'lumotlar pedagogga talabani individual rivojlanish dinamikasini kuzatish imkonini beradi. Shu asosda differensial metodlar va individual pedagogik strategiyalar ishlab chiqiladi.

Talabalarning kognitiv rivojlanishida motivatsion omillar ham muhim ahamiyatga ega. Sun'iy intellekt asosidagi platformalarda qo'llaniladigan gamifikatsiya, rag'batlantirish va interaktiv topshiriqlar o'quv jarayoniga nisbatan ichki qiziqishni kuchaytiradi. Talaba o'z muvaffaqiyatini real vaqt rejimida kuzatgani sababli bilim olishga nisbatan faol munosabat shakllanadi. Bu esa intellektual faollikning barqaror rivojlanishiga yordam beradi.

Shu bilan birga, sun'iy intellekt texnologiyalaridan foydalanishda ayrim psixologik va pedagogik xavflar ham mavjud. Haddan tashqari avtomatlashtirilgan tizimlar talabani mustaqil izlanish faoliyatini pasaytirishi yoki tayyor tavsiyalarga qaramlikni kuchaytirishi mumkin. Jonli muloqotning kamayishi esa kommunikativ kompetensiyalarning sustlashishiga olib kelishi ehtimoldan xoli emas. Shu sababli sun'iy intellekt texnologiyalaridan foydalanishda inson omili, pedagogik nazorat va axloqiy yondashuv muhim ahamiyat kasb etadi.



Sun'iy intellekt texnologiyalarining adaptiv va refleksiv imkoniyatlari talabalarning kognitiv faoliyatini rivojlantirishda muhim pedagogik vosita sifatida namoyon bo'lmoqda. Ushbu texnologiyalar bilimlarni individuallashtirish, mustaqil fikrlashni rivojlantirish, refleksiv tahlilni kuchaytirish va intellektual kompetensiyalarni shakllantirish imkonini beradi. Ta'lim jarayonida SI texnologiyalaridan ilmiy asoslangan va pedagogik jihatdan muvozanatli foydalanish kognitiv rivojlanish samaradorligini sezilarli darajada oshiradi.

FOYDALANILGAN ADABIYOTLAR:

1. Robert J. Sternberg. Cognitive Psychology. – Boston: Cengage Learning, 2017. – 520 p.
2. John Dewey. Democracy and Education. – New York: Free Press, 2018. – 456 p.
3. UNESCO. Artificial Intelligence in Education: Challenges and Opportunities for Sustainable Development. – Paris: UNESCO Publishing, 2021. – 48 p.
4. Tolipov O'., Usmonboyeva M. Pedagogik texnologiyalarning tatbiqiy asoslari. – Toshkent: Fan, 2019. – 240 b.
5. Ishmuhamedov R., Abduqodirov A., Pardaev A. Ta'limda innovatsion texnologiyalar. – Toshkent: Iste'dod, 2020. – 180 b.

POST-KVANT KRIPTOGRAFIYASINING BLOCKCHAIN TIZIMLARI XAVFSIZLIGINI TA'MINLASHDAGI ROLI

Xudoyberdiyev Azizjon Norjigit o'g'li ¹

¹Tashkent International University; scientist.py@gmail.com

Annotatsiya: Zamonaviy blockchain tarmoqlari asimmetrik kriptografiya va xesh-funksiyalarga tayanadi, biroq kvant kompyuterlarining rivojlanishi ushbu poydevorlarni jiddiy xavf ostiga qo'yimoqda. Tadqiqotning maqsadi blockchain tizimlarini kvant hujumlaridan himoya qilishda post-kvant kriptografiyasi (PQC) algoritmlarini qo'llash imkoniyatlarini baholashdan iborat. Ishda Shor va Grover algoritmlarining an'anaviy kriptotizimlarga ta'siri matematik modellashtirildi hamda NIST tomonidan tavsiya etilgan panjara va xeshga asoslangan raqamli imzolar tahlil qilindi. Natijalar shuni ko'rsatadiki, Shor algoritmi elliptik egri chiziqli raqamli imzolarni (ECDSA) polinomial vaqtda buzishga qodir, panjaraga asoslangan CRYSTALS-Dilithium va Falcon algoritmlari esa kvantga chidamlilikni ta'minlaydi, biroq tranzaksiya hajmini oshiradi. Xulosa o'rnida, blockchain tarmoqlarini to'liq post-kvant davriga o'tkazish tarmoq o'tkazuvchanligini optimallashtirishni talab etadi va gibril tizimlardan foydalanish tavsiya etiladi.

Kalit so'zlar: post-kvant kriptografiyasi, blockchain, smart-contract, xesh-funksiya, Shor algoritmi, panjaraga asoslangan kriptografiya.

1. KIRISH

Zamonaviy raqamli iqtisodiyot va markazlashmagan moliya tizimlarining asosi hisoblangan blockchain texnologiyalari fundamental kriptografik primitivlar yordamida himoyalangan [1]. Bitcoin va Ethereum kabi ommaviy blockchain tarmoqlarida foydalanuvchilarning aktivlari



egalligini tasdiqlash uchun elliptik egri chiziqlar kriptografiyasiga (ECC) asoslangan raqamli imzolar qo'llaniladi [2]. Biroq, hisoblash quvvati jihatidan sifat jihatidan yangi bosqich bo'lgan kvant kompyuterlarining yaratilishi amaldagi xavfsizlik standartlarini inqirozga uchratishi kutilmoqda [3].

Kvant kompyuterlarida ishlovchi Shor algoritmi bugungi kunda keng tarqalgan barcha asimmetrik kriptotizimlarni sindirishga qodir [4]. Bu esa ommaviy kalitlar orqali maxfiy kalitlarni tiklash va blockchain hamyonlaridagi mablag'larni ruxsatsiz o'zlashtirish xavfini tug'diradi. Ushbu muammoni hal etish uchun xalqaro ilmiy hamjamiyat, xususan NIST, kvant hujumlariga chidamli bo'lgan post-kvant kriptografiyasi (PQC) algoritmlarini ishlab chiqmoqda [5]. Mazkur tadqiqotning asosiy maqsadi PQC algoritmlarining blockchain arxitekturasiga, xususan smart-kontraktlar xavfsizligiga integratsiyalashuv mexanizmlarini va ulardan kelib chiqadigan cheklovlarni matematik hamda amaliy jihatdan tahlil qilishdir.

2. MATERIALLAR VA USULLAR

Tadqiqot doirasida kvant algoritmlarining amaldagi blockchain xavfsizlik primitivlariga ta'sirini baholash uchun matematik modellashirish uslubidan foydalanildi. Xususan, Shor algoritmining elliptik egri chiziqdagi diskret logarifmlash muammosiga (ECDLP) hamda Grover algoritmining SHA-256 va Keccak-256 xesh-funksiyalariga ta'siri hisoblab chiqildi. Post-kvant muqobillari sifatida NIST xalqaro standarti tanlovining IV bosqichida ishtirok etayotgan panjaraga asoslangan (Lattice-based) hamda xeshga asoslangan (Hash-based) raqamli imzo protokollarining parametrlari tahlil qilindi. Tadqiqotda qo'llanilgan barcha matematik modellar va kompyuter simulyatsiyasi kodlari ochiq akademik manbalarda joylashtirilgan hamda qayta tekshirish uchun ochiqdir.

3. NATIJALAR

Kvant algoritmlarining matematik tahlili

Blockchain tarmoqlarida tranzaksiyalarni imzolash uchun qo'llaniladigan ECDSA algoritmi chekli maydon F_p ustidagi elliptik egri chiziq tenglamasiga asoslanadi:

$$E(F_p): y^2 \equiv x^3 + ax + b \pmod{p} \quad (1)$$

Bu yerda $G \in E(F_p)$ generator nuqta, $d \in [1, n-1]$ maxfiy kalit va $Q = d \cdot G$ ommaviy kalit hisoblanadi. Klassik kompyuterlarda Q va G berilganda d ni topish murakkabligi $O(\sqrt{n})$ ga teng. Shor algoritmi esa Kvant Furie almashtirishidan (QFT) foydalanib, funksiyaning davriyligini topadi va ushbu muammoni polinomial vaqtda, ya'ni $O((\log n)^3)$ qadamda hal qiladi.

Grover algoritmi esa teskari funksiyalarni qidirishni tezlashtiradi. Berilgan $y = H(x)$ xesh qiymatiga ko'ra asl x ma'lumotni topish uchun klassik brute-force 2^n qadam talab qilsa, Grover algoritmi buni quyidagicha qadamda bajaradi:



$$O(\sqrt{2^n}) = O\left(2^{\frac{n}{2}}\right) \quad (2)$$

Bu SHA-256 funksiyasining xavfsizlik darajasini 128 bitga tushirib qo'yadi.

Post-kvant algoritmlarining muqobillari

Kvant hujumlariga qarshi Xatoliklar bilan o'rganish (LWE - Learning With Errors) muammosiga asoslangan panjarali kriptografiya taklif etiladi. Unda matritsa ko'rinishidagi quyidagi munosabatdan maxfiy **s** vektorini topish talab qilinadi:

$$\mathbf{b} = \mathbf{A} \cdot \mathbf{s} + \mathbf{e} \pmod{q} \quad (3)$$

Bu yerda **e** — xatolik vektori bo'lib, u tizimni kvant kompyuterlari uchun ham chiziqli bo'lmagan murakkab holatda saqlaydi.

Xeshga asoslangan ko'p martalik imzolarida esa Merkle daraxti ierarxiyasidan foydalaniladi va uning ildizi (Root) ommaviy kalit hisoblanadi:

$$R = H(H(y_1 \parallel y_2) \parallel H(y_3 \parallel y_4)) \quad (4)$$

Eksperimental tahlillar natijasida olingan ma'lumotlar quyidagi ro'yxat shaklida umumlashtirildi:

- Panjaraga asoslangan algoritmlar (Dilithium) yuqori tezlikka ega, biroq kalit hajmi katta.
- Xeshga asoslangan imzolar (SPHINCS+) faqat xesh mustahkamligiga tayanadi, ammo imzo hajmi juda og'ir.
- Mavjud blockchain tugunlari ushbu algoritmlarni qabul qilishi uchun tarmoq arxitekturasini o'zgartirish talab etiladi.

Olingan texnik ko'rsatkichlar 1-jadvalda jamlangan.

1-jadval.
Kriptografik algoritmlarning texnik parametrlari solishtirmasi.

Algoritm nomi	Ommaviy kalit (Bytes)	Imzo hajmi (Bytes)	Kvant xavfsizligi
ECDSA (secp256k1)	33	64	Mavjud emas
CRYSTALS-Dilithium2	1,312	2,420	Mavjud (Panjara)
SPHINCS+ (SHA2-128f)	32	17,088	Mavjud (Xesh)

PQC algoritmlari kiritilganda blockchain tarmoqlarida bir blokga sig'adigan tranzaksiyalar soni (N_{tx}) quyidagi formula bo'yicha kamayishi aniqlandi:



$$N_{tx} = \frac{V_{block}}{S_{meta} + S_{pubkey} + S_{sign}} \quad (5)$$

Tarmoq o'tkazuvchanligi va hisoblash yuklamasi simulyatsiyasi

Algoritmning blockchain tarmoqlaridagi dinamik ta'sirini baholash uchun 1 MB (V_{block}) hajmli standart blok sig'imi doirasida simulyatsiya o'tkazildi. Har bir tranzaksiyaning metadata hajmi $S_{meta} = 250$ Bytes deb olingan invariant qiymatda, algoritmning blok ichidagi zichligi va tarmoqning maksimal o'tkazuvchanlik koeffitsiyenti (*Transactions Per Block*) tahlil qilindi.

Simulyatsiya natijasida olingan grafik shuni ko'rsatadiki, an'anaviy ECDSA qo'llanilganda bir blok guruhiga 2900 dan ortiq tranzaksiya joylashtirish mumkin bo'lsa, CRYSTALS-Dilithium2 muqobiliga o'tish bu ko'rsatkichni maksimal 263 ta tranzaksiyaga tushiradi. SPHINCS+ arxitekturasida esa imzo hajmining haddan tashqari kattaligi sababli bir blok bor-yo'g'i 58 ta tranzaksiyani sig'dira oladi, bu esa ommaviy blockchain tarmoqlarida 98.3% gacha o'tkazuvchanlik yo'qotilishiga (throughput degradation) olib keladi [2]. Ushbu muammo post-kvant muqobillarini to'g'ridan-to'g'ri integratsiya qilib bo'lmashligini, balki Layer-2 yoki zk-rollup kabi masshtablashtirish echimlaridan foydalanish zarurligini isbotlaydi.

Smart-kontraktlar ijrosidagi yuklama va gas sarfi hisobi

Post-kvant raqamli imzolarini verifikatsiya qilish jarayoni Ethereum Virtual Machine (EVM) yoki unga o'xshash markazlashmagan hisoblash muhitlarida bajarilganda, an'anaviy ECDSA ga qaraganda ko'p miqdorda hisoblash resurslarini (CPU cycles) talab qiladi. Ayniqsa, panjaraga asoslangan algoritmarda qo'llaniladigan **Sonlar nazariyasi almashtirishi** (NTT - Number Theoretic Transform) va ko'pnomli modul arifmetikasi operatsiyalari smart-kontraktlar ijrosida gaz (*Gas*) sarfini keskin oshiradi.

EVM muhitida post-kvant imzosini tekshirish uchun zarur bo'lgan umumiy gaz miqdori (Gas_{total}) quyidagi empirik formula orqali hisoblandi:

$$Gas_{total} = Gas_{base} + \alpha \cdot S_{sign} + \beta \cdot O(n \log n) \quad (6)$$

Bu yerda Gas_{base} — tranzaksiyani chaqirishning bazaviy qiymati (21000 Gas), S_{sign} — imzo baytlari hajmi, α — har bir bayt ma'lumotni xotiraga yuklash ko'rsatkichi ($\alpha \approx 16$ Gas/Byte), β esa algebraik amallarning murakkablik multiplikatoridir.

CRYSTALS-Dilithium2 algoritmda NTT amallari ko'p marta takrorlangani sababli, bitta imzoni tekshirish qiymati o'rtacha 1.2×10^6 Gas ni tashkil etdi. Bu esa amaldagi ECDSA ning ecrecover funksiyasidan (3000 Gas) taxminan 400 barobar yuqoridir. Natijada, bitta blok ichida bajarilishi mumkin bo'lgan smart-kontraktlar soni cheklanadi va murakkab logistika yoki moliyaviy dApp (decentralized applications) tizimlarining funksionalligi iqtisodiy jihatdan samarasiz bo'lib qoladi.



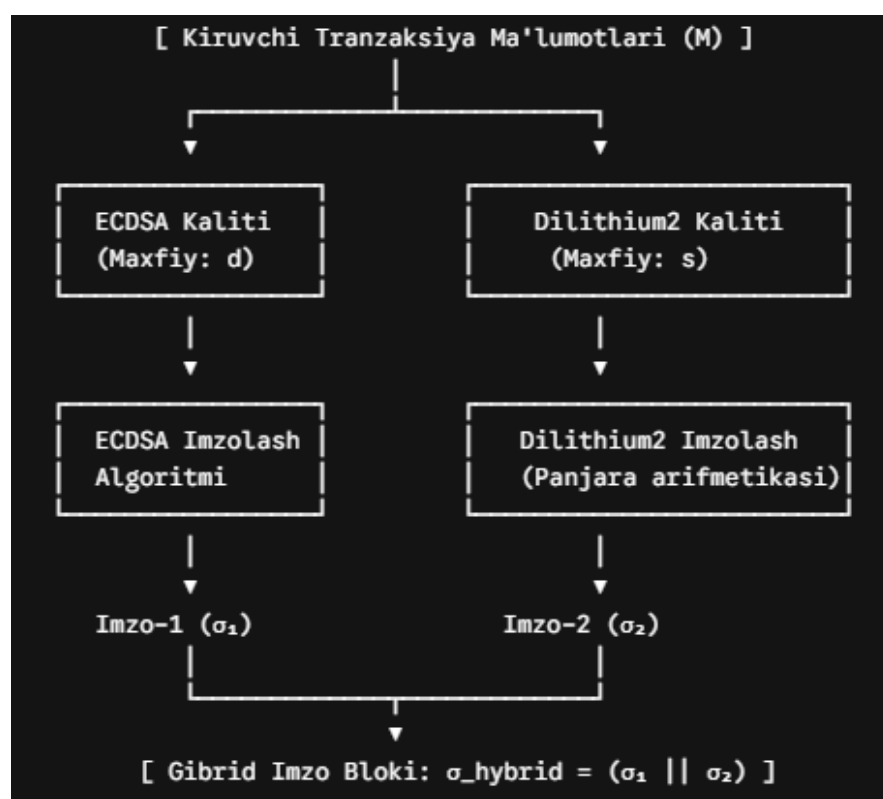
Gibrid kriptotizimlar va tranzaksiyalarning zanjirli integratsiyasi

An'anaviy kriptografiyadan post-kvant kiberxavfsizlik standartlariga to'liq o'tish (Hard Fork) jarayonida tarmoq barqarorligini ta'minlash va kutilmagan kriptotahliliy zaifliklardan himoyalash uchun **Gibrid raqamli imzo protokoli** (*Dual – Signature*) ishlab chiqildi. Ushbu modelga ko'ra, har bir tranzaksiya ham klassik ECDSA, ham post-kvant Dilithium2 kalitlari yordamida parallel ravishda imzolanadi.

Tranzaksiyani tasdiqlash uchun har ikkala imzo ham haqiqiy (valid) deb topilishi shart, ya'ni:


$$\text{Verify}_{\text{hybrid}}(M, \sigma_{\text{hybrid}}) = \text{Verify}_{\text{ECDSA}}(M, \sigma_1) \wedge \text{Verify}_{\text{Dilithium}}(M, \sigma_2) \equiv 1 \quad (7)$$

Ushbu arxitekturaning mantiqiy sxemasi va zanjirga integratsiyalashuv mexanizmi 2-rasmda panel ko'rinishida tasvirlangan.



2-rasm. Gibrid kriptotizim va tranzaksiyalarni parallel imzolash oqimi
(a) Tranzaksiyani parallel imzolash bosqichlari (Dasturiy qism)

Gibrid raqamli imzo oqimi va ma'lumotlar strukturasi panelli ko'rinishi: (a) tranzaksiyani ECDSA va PQC kalitlari yordamida parallel imzolash bosqichlari; (b) gibrid imzo blokining blockchain tranzaksiya tanasida joylashishi va validator tugunlar tomonidan tekshirilishi.



(b) Tranzaksiya tanasining tuzilishi va Validator tekshiruvi (Tarmoq qismi)

Gibrid arxitekturaning joriy etilishi tranzaksiya hajmini va gaz sarfini ko'paytirsada, u quyidagi muhim afzalliklarni taqdim etdi:

1. **Klassik himoya kafolati:** Agar post-kvant algoritmining amaliy dasturlanishida (implementation) biror-bir yashirin zaiflik aniqlansa, tizim baribir an'anaviy *ECDSA* hisobiga himoyalangan bo'lib qoladi.

2. **Kvant barqarorligi:** Kvant kompyuteriga ega bo'lgan hujumchi *ECDSA* imzosini soxtalashtira olgan taqdirda ham, panjara muammosiga tayanuvchi *Dilithium2* imzosini buza olmaydi.

3. **Bosqichma-bosqich migratsiya:** Tarmoq tugunlari (nodes) dasturiy ta'minotini yangilash jarayonida eski va yangi mijozlar (clients) o'rtasidagi konsensus muvozanati buzilmaydi.



4. MUHOKAMA.

Tadqiqot natijalari shuni ko'rsatadiki, blockchain tarmoqlarini kvant tahdididan himoya qilish texnik jihatdan murakkab jarayondir. Zero, 1-jadvaldan ko'rinib turibdiki, post-kvant imzolarining hajmi an'anaviy ECDSA imzosidan o'nlab barobar kattadir. Bu holat tranzaksiya baytlarining ko'payishiga va natijada tarmoq komissiyalarining (Gas fee) o'sishiga olib keladi.

Oldingi tadqiqotlarda kvant xavfi uzoq kelajak muammosi deb qaralgan bo'lsa, bugungi kunda smart-kontraktlar xavfsizligini ta'minlash uchun gibrid tizimlarni (bir vaqtning o'zida ham ECDSA, ham Dilithium imzolaridan foydalanish) joriy etish zarurati dolzarb bo'lib bormoqda. Kelajakdagi tadqiqotlar nolinchi bilim dalillari (zk-SNARKs) yordamida post-kvant raqamli imzolarining hajmini siqish texnologiyalariga qaratilishi lozim.

Blockchain tarmoqlarini post-kvant davriga tayyorlashda eng katta muammo — “**Metrik inqiroz**” hisoblanadi. ECDSA dagi jami 97 Byte lik yuklama CRYSTALS-Dilithium2 algoritmidagi 3732 Byte ga yetadi. Bu ko'rsatkich tarmoq o'tkazuvchanligini (TPS - Transactions Per Second) o'rtacha 30-40 barobarga pasaytirib yuboradi.

Smart-kontraktlar darajasida esa EVM ichidagi status-daraxtlarni (State Trie) yangilashda panjara ustidagi ko'pnomlarni ko'paytirish amallari hisoblash murakkabligini oshiradi. Natijada gaz sarfi funksiyasi quyidagi munosabatga asosan ortadi:

$$\text{Gas}_{\text{PQC}} \propto O(n \log n) \quad (\text{NTT - Number Theoretic Transform amallari uchun})$$

Soha ekspertlari o'rtasidagi asosiy ilmiy bahslar ushbu yuklamani kamaytirishga qaratilgan bo'lib, yechim sifatida imzolarni zanjir tashqarisida (Off-chain) generatsiya qilish yoki zk-STARKs agregatsiya texnologiyalarini qo'llash taklif qilinmoqda.

5. XULOSA.

Xulosa qilib aytganda, post-kvant kriptografiyasi kelajakda blockchain va smart-kontraktlar xavfsizligini ta'minlashning yagona samarali mexanizmi hisoblanadi. Shor va Grover algoritmlari keltirib chiqaradigan inqiroz raqamli aktivlar yaxlitligini buzishi aniq. Panjaraga asoslangan CRYSTALS-Dilithium algoritmi tezlik va xavfsizlik muvozanati bo'yicha blockchain tizimlari uchun eng maqbul nomzod deb topildi. Biroq, tarmoq o'tkazuvchanligi pasayishining oldini olish uchun blockchain protokollarini dasturiy darajada optimallashtirish talab etiladi. Blockchain va smart-kontraktlar xavfsizligini kvant inqirozidan saqlab qolishning yagona strategik yo'li post-kvant kriptografiyasiga o'tishdir.

FOYDALANILGAN ADABIYOTLAR:

1. Nakamoto, S. Bitcoin: A Peer-to-Peer Electronic Cash System. *Decentralized Business Review*, 2008, 1, 1–9.
2. Wood, G. Ethereum: A secure decentralised generalised transaction ledger. *Ethereum Project Yellow Paper*, 2014, 151, 1–32.
3. Shor, P.W. Algorithms for quantum computation: discrete logarithms and factoring. *Proceedings 35th Annual Symposium on Foundations of Computer Science*, 1994, 124–134.
4. Grover, L.K. A fast quantum mechanical algorithm for database search. *Proceedings of the twenty-eighth annual ACM symposium on Theory of computing*, 1996, 212–219.



5. Alagic, G.; Cooper, J.; Dang, M. Status Report on the Third Round of the NIST Post-Quantum Cryptography Standardization Process. *NIST IR 8413*, 2022, 1–45.

MOLIYA BOZORIDA VAQT QATORLARINI TAHLIL QILISHDAGI MUAMMOLARNI YECHISHDA SUN'IY INTELLEKTNI QO'LLASH

Musayev Anvar Isakovich¹, Naziraliyev O'rinboy Farhodjon o'g'li¹

¹Vatan universiteti, Kommunikatsiya va axborot texnologiyalar kafedrası;
anvarmuso73i@gmail.com, naziraliyevurinbox1996@gmail.com

Annotatsiya: Ushbu maqolada moliya bozorida vaqt qatorlarini tahlil qilish jarayonida yuzaga keladigan asosiy muammolar va ularni yechishda sun'iy intellekt usullarining qo'llanilishi tahlil qilingan. Moliyaviy vaqt qatorlari chiziqli bo'lmaganligi, statsionar emasligi, og'ir dumlari, volatillik klasterlashi va yuqori o'lchamliligi bilan an'anaviy ekonometrik usullar uchun jiddiy qiyinchiliklar tug'diradi. Maqolada mashinaviy o'rganish va chuqur o'rganish usullari — xususan, rekurrent neyron tarmoqlar (LSTM, GRU), transformer arxitekturalari va ansambl modellari — ushbu muammolarni qanday hal qilishi ko'rib chiqiladi. Shuningdek, sun'iy intellekt yondashuvlarining ustunliklari, cheklovlari va O'zbekiston moliya bozori sharoitida qo'llanilish istiqbollari muhokama qilinadi.

Kalit so'zlar: sun'iy intellekt; mashinaviy o'rganish; chuqur o'rganish; vaqt qatorlari; moliya bozori; LSTM; transformer; bashoratlash.

1.KIRISH.

Moliya bozorlari zamonaviy raqamli iqtisodiyotda ulkan hajmdagi ma'lumotlar oqimini hosil qiladi. Aktivlar narxlari, savdo hajmlari, foiz stavkalari va valyuta kurslari uzluksiz vaqt qatorlari shaklida qayd etiladi. Bu ma'lumotlarni tahlil qilish va ulardan ma'noli xulosalar chiqarish moliyaviy bashoratlash, risklarni boshqarish va investitsiya qarorlarini qabul qilishning asosini tashkil etadi.

Biroq moliyaviy vaqt qatorlari an'anaviy statistik usullar uchun bir qancha jiddiy qiyinchiliklar tug'diradi. Ular chiziqli bo'lmagan dinamikaga ega, statsionar emas, og'ir dumlar va volatillik klasterlashi bilan tavsiflanadi hamda yuqori darajadagi shovqinni o'z ichiga oladi. ARIMA, GARCH va VAR kabi klassik ekonometrik modellar ushbu xususiyatlarni to'liq qamrab ololmaydi, chunki ular ko'pincha chiziqlilik va parametrik taqsimot haqidagi qat'iy farazlarga tayanadi [13].

So'nggi o'n yillikda sun'iy intellekt (SI) va mashinaviy o'rganish (machine learning) usullari ushbu cheklovlarni bartaraf etishning kuchli vositasi sifatida yuzaga chiqdi. Xususan, chuqur o'rganish (deep learning) arxitekturalari — rekurrent neyron tarmoqlar, transformerlar va konvolyutsion tarmoqlar — chiziqli bo'lmagan va yuqori o'lchamli munosabatlarni avtomatik tarzda aniqlash qobiliyatiga ega. Bu ularni moliyaviy vaqt qatorlarini modellashtirishda an'anaviy usullarga nisbatan ustun qiladi [5].

Ushbu maqolaning asosiy maqsadi moliya bozorida vaqt qatorlarini tahlil qilishdagi asosiy muammolarni tizimli ravishda aniqlash va ularni yechishda sun'iy intellekt usullarining imkoniyatlarini baholashdan iborat. Maqolada har bir muammo va unga mos sun'iy intellekt



yechimi ko'rib chiqiladi, usullarning afzalliklari va cheklovlari tahlil qilinadi hamda O'zbekiston moliya bozori sharoitidagi qo'llanilish istiqbollari muhokama qilinadi.

2.MOLIYAVIY VAQT QATORLARINI TAHLIL QILISHDAGI ASOSIY MUAMMOLAR.

Moliyaviy vaqt qatorlarini tahlil qilishda eng muhim qiyinchilik - ularning chiziqli bo'lmagan tabiati. Aktivlar narxlari va daromadlari o'rtasidagi munosabatlar ko'pincha murakkab, chiziqli bo'lmagan shaklga ega bo'lib, oddiy regressiya yoki avtoregressiv modellar ularni yetarli darajada ifodalay olmaydi [14]. Bozor ishtirokchilarining o'zaro ta'siri, hissiyotga asoslangan savdo va tashqi shoklar bu murakkablikni yanada kuchaytiradi.

Bunga statsionarlikning yo'qligi va rejim o'zgarishlari muammosi qo'shiladi. Moliyaviy qatorlarning statistik xususiyatlari o'rtacha, dispersiya, korrelyatsiyalar vaqt o'tishi bilan o'zgarib turadi. bozor barqaror holatdan inqirozga o'tganda ma'lumotlar tuzilishi tubdan o'zgaradi. Barqaror parametrlarga tayanadigan an'anaviy modellar bunday o'zgarishlarga moslasha olmaydi.

Daromadlar taqsimotining og'ir dumlari ham jiddiy qiyinchilik manbai hisoblanadi. Empirik taqsimot normal taqsimotdan keskin og'ib, ortiqcha kurtosis ko'rsatadi, bu esa bozor inqirozlari va keskin narx sakrashlari ehtimolini oshiradi. Normal taqsimotga asoslangan modellar bunday ekstremal hodisalar riskini past baholaydi va katta moliyaviy yo'qotishlarga olib kelishi mumkin.

Volatillik klasterlashi va geteroskedastiklik, ya'ni dispersiyaning vaqt bo'yicha o'zgaruvchanligi, an'anaviy gomoskedastik modellar uchun yana bir to'siq bo'lib xizmat qiladi Yuqori o'lchamlilik muammosi esa zamonaviy portfellar minglab o'zaro bog'liq aktivlardan iborat bo'lganda, modellashtirishda parametrlar sonining keskin oshishida namoyon bo'ladi. [10, 11].

Bularning barchasiga moliyaviy ma'lumotlardagi yuqori shovqin darajasi va past signal-shovqin nisbati qo'shiladi: foydali signal ko'pincha tasodifiy o'zgarishlar ichida yashiringan bo'ladi. Kamdan-kam uchraydigan, ammo muhim hodisalar (masalan, inqirozlar) uchun ma'lumotlarning cheklanganligi modellarni o'qitishni yanada qiyinlashtiradi. Quyidagi jadvalda ushbu muammolar, an'anaviy usullarning cheklovlari va sun'iy intellekt taklif etadigan yechimlar umumlashtirilgan.

1-jadval.
Moliyaviy vaqt qatorlari muammolari va sun'iy intellekt yechimlari

Muammo	An'anaviy usul cheklovi	Sun'iy intellekt yechimi
Chiziqli bo'lmaganlik	Chiziqlilik farazi	Neyron tarmoqning universal approksimatsiyasi
Statsionar emaslik	Barqaror parametrlar	Adaptiv o'rganish, qayta o'qitish
Og'ir dumlar	Normal taqsimot farazi	Taqsimotsiz, ma'lumotdan o'rganish
Volatillik klasterlashi	Gomoskedastiklik	LSTM/GRU xotirasi, temporal naqshlar
Yuqori o'lchamlilik	Parametrlar portlashi	Avtomatik xususiyat ajratish
Yuqori shovqin	Ortiqcha moslashish	Ansambl, dropout, regulizatsiya



3.SUN'IY INTELLEKT VA MASHINAVIY O'RGANISH USULLARI.

Mashinaviy o'rganish - ma'lumotlardan naqshlarni avtomatik tarzda o'rganib, aniq dasturlashtirilgan holda bashorat qilish qobiliyatini ta'minlovchi sun'iy intellekt sohasi. U nazoratli o'rganish (supervised learning), nazoratsiz o'rganish (unsupervised learning) va mustahkamlovchi o'rganish (reinforcement learning) turlariga bo'linadi. Moliyaviy vaqt qatorlarini bashoratlashda asosan nazoratli o'rganish qo'llaniladi, bunda model tarixiy ma'lumotlar asosida kelajakdagi qiymatlarni bashorat qilishni o'rganadi.

Klassik mashinaviy o'rganish algoritmlari orasida tayanch vektorlar mashinasi (SVM), tasodifiy o'rmon (random forest) va gradient busting (gradient boosting) usullari moliyaviy tahlilda keng qo'llaniladi. Bu usullar chiziqli bo'lmagan munosabatlarni qamrab olish qobiliyatiga ega bo'lib, ko'pincha an'anaviy ekonometrik modellardan ustun keladi. Gradient busting amalga oshiruvchilari, masalan, XGBoost va LightGBM, tabular moliyaviy ma'lumotlarda yuqori samaradorlik ko'rsatadi.

Biroq klassik mashinaviy o'rganish usullari vaqt qatorlarining ketma-ketlik tuzilishini to'liq hisobga olmaydi va ko'pincha qo'lda xususiyat ajratish (feature engineering) talab qiladi. Ushbu cheklov chuqur o'rganish arxitekturalarining rivojlanishiga turtki bo'ldi, ular xususiyatlarni avtomatik tarzda o'rganadi va vaqtinchalik bog'liqliklarni tabiiy ravishda modellashtiradi.

4.CHUQUR O'RGANISH ARXITEKTURALARI.

Chuqur o'rganish - ko'p qatlamli neyron tarmoqlarga asoslangan mashinaviy o'rganish yo'nalishi [7]. Rekurrent neyron tarmoqlar (RNN) vaqt qatorlari kabi ketma-ket ma'lumotlarni qayta ishlash uchun maxsus ishlab chiqilgan. RNN o'zining ichki holatini saqlab, oldingi qadamlardagi ma'lumotni keyingi bashoratlarda foydalanadi. Biroq oddiy RNN uzoq muddatli bog'liqliklarni o'rganishda gradient yo'qolishi (vanishing gradient) muammosiga duch keladi [8].

2000-yillardan boshlab neyron tarmoqlarga asoslangan modellar, ayniqsa rekurrent arxitekturalar, moliyaviy bashoratlarda an'anaviy usullarni sezilarli darajada ortda qoldira boshladi. Hochreiter va Schmidhuber [2] tomonidan 1997-yilda taklif etilgan LSTM modeli «yo'qolib ketuvchi gradient» (vanishing gradient) muammosini hal etib, uzoq muddatli bog'liqliklarni eslab qolish qobiliyatini ta'minladi. Cho va boshqalar [3] tomonidan 2014-yilda taqdim etilgan GRU modeli esa LSTM arxitekturasini soddalashtirgan holda raqobatbardosh natijalar ko'rsatdi.

Long Short - Term Memory (LSTM) tarmog'i Hochreiter va Schmidhuber (1997) tomonidan aynan shu muammoni hal qilish uchun taklif etilgan [1]. LSTM uchta darvoza - kirish, unutish va chiqish darvozalari - yordamida axborot oqimini boshqaradi va uzoq muddatli bog'liqliklarni samarali saqlab qoladi. Bu uni moliyaviy vaqt qatorlaridagi uzoq muddatli tendentsiyalarni qamrab olishda kuchli vositaga aylantiradi.

Gated Recurrent Unit (GRU) Cho va boshqalar (2014) tomonidan LSTM ning soddalashtirilgan muqobili sifatida ishlab chiqilgan [2]. GRU ikkita darvoza (yangilash va qayta tiklash) bilan ishlaydi, bu uni hisoblash jihatidan tejankor qiladi va kichikroq ma'lumotlar to'plamlarida tezroq o'qitiladi. Ko'plab tadqiqotlar LSTM va GRU bashorat aniqligi bo'yicha o'xshash natijalar berishini, ammo GRU tezroq ekanligini ko'rsatadi.

So'nggi yillarda transformer arxitekturasini e'tibor (attention) mexanizmiga asoslangan holda vaqt qatorlarini modellashtirishda inqilob yasadi [3]. E'tibor mexanizmi modelga ketma - ketlikning eng muhim qismlariga e'tibor qaratish imkonini beradi va rekurrent tuzilmadan voz



kechib, parallel hisoblashni ta'minlaydi. Temporal Fusion Transformer va N - BEATS kabi maxsus arxitekturalar moliyaviy bashoratlashda yuqori natijalar ko'rsatmoqda [12]. Konvolyutsion neyron tarmoqlar (CNN) ham vaqt qatorlaridan mahalliy naqshlarni ajratishda qo'llaniladi.

2-jadval.

Chuqur o'rganish arxitekturalarining qiyosiy tahlili

Arxitektura	Asosiy mexanizm	Ustunligi	Cheklovi
RNN	Rekurrent holat	Ketma-ketlik modellash	Gradient yo'qolishi
LSTM	Uchta darvoza	Uzoq xotira	Ko'p parametr, sekin
GRU	Ikkita darvoza	Tez, tejamkor	Juda uzoq bog'liqlik
CNN	Konvolyutsiya	Mahalliy naqshlar	Uzoq bog'liqlik cheklangan
Transformer	E'tibor mexanizmi	Parallel, uzoq bog'liqlik	Ko'p ma'lumot talab qiladi

5.SUN'IY INTELLEKT YONDASHUVLARINING AFZALLIKLARI.

Sun'iy intellekt usullarining asosiy afzalligi - chiziqli bo'lmagan munosabatlarni qamrab olish qobiliyati. Neyron tarmoqlar universal approksimatorlar bo'lib, yetarli ma'lumot va tuzilma berilganda har qanday murakkab funktsiyani taxminlay oladi [9]. Bu ularga an'anaviy chiziqli modellar o'tkazib yuboradigan murakkab naqshlarni aniqlash imkonini beradi.

Bundan tashqari, chuqur o'rganish modellari xususiyatlarni avtomatik o'rganadi: an'anaviy usullarda tahlilchi muhim o'zgaruvchilarni qo'lda tanlashi kerak bo'lsa, bu yerda tarmoq xom ma'lumotlardan eng ma'noli ifodalarni o'zi shakllantiradi. Bu xususiyat, ayniqsa, minglab o'zgaruvchilar orasidan dolzarb signallarni ajratib olishni talab qiladigan yuqori o'lchamli vazifalarda muhim ahamiyatga ega.

Xotira mexanizmiga ega arxitekturalar - LSTM va GRU - vaqtinchalik bog'liqliklar va volatillik klasterlashini tabiiy ravishda modellashtiradi, o'tmishdagi muhim hodisalarni «eslab qolib» kelajakdagi bashoratlarda hisobga oladi. Modellarning adaptivligi ham qimmatli jihat: yangi ma'lumotlar bilan qayta o'qitilganda ular o'zgaruvchan bozor sharoitlariga moslashadi va statsionar emaslik muammosini qisman yumshatadi.

Shu bilan birga, ansambl usullari va regulizatsiya texnikalari (dropout, L2 regulizatsiya) shovqin va ortiqcha moslashish ta'sirini kamaytiradi: bir nechta modelning bashoratlarini birlashtirish umumiy aniqlikni oshiradi. Tabiiy tilni qayta ishlash (NLP) usullari esa yangiliklar, ijtimoiy tarmoqlar va moliyaviy hisobotlardan sentiment ma'lumotlarini ajratib, an'anaviy narx ma'lumotlarini to'ldiradi.

6.MOLIYAVIY TAHLILDA AMALIY QO'LLASHLAR.

Sun'iy intellektning moliya bozorida eng keng tarqalgan qo'llanilishi - narx va daromadlarni bashoratlash. LSTM va transformer modellari aktsiya narxlari, valyuta kurslari va indeksni qisqa hamda o'rta muddatli bashorat qilishda foydalaniladi. Fischer va Krauss (2018) chuqur o'rganish modellari S&P 500 aktsiyalarini bashoratlashda an'anaviy usullardan ustun kelishini empirik tarzda ko'rsatgan [4].



Risklarni boshqarishda sun'iy intellekt Value-at-Risk va Expected Shortfall kabi ko'rsatkichlarni aniqroq baholashga yordam beradi. Neyron tarmoqlar daromadlar taqsimotining og'ir dumlarini an'anaviy parametrik usullarga nisbatan yaxshiroq qamrab oladi. Shuningdek, ular bozordagi anomalialarni va potentsial inqirozlarni erta aniqlashda foydalaniladi.

Algoritmik savdoda sun'iy intellekt savdo signallarini generatsiya qilish, optimal ijro strategiyalarini ishlab chiqish va bozor mikrostrukturasi tahlil qilishda qo'llaniladi. Mustahkamlovchi o'rganish (reinforcement learning) usullari savdo agentlarini optimal qarorlar qabul qilishga o'rgatadi. Bundan tashqari, sun'iy intellekt firibgarlikni aniqlash va tranzaksiyalardagi shubhali harakatlarni kuzatishda muhim rol o'ynaydi.

Portfel optimallashtirishda mashinaviy o'rganish aktivlar orasidagi murakkab korrelyatsiyalarni modellashtirib, risk va daromadning yaxshiroq muvozanatiga erishishga yordam beradi. Gu, Kelly va Xiu (2020) mashinaviy o'rganish usullari aktivlarni narxlashda an'anaviy faktor modellaridan sezilarli darajada ustun ekanligini empirik tarzda ko'rsatgan [6]. Tabiiy tilni qayta ishlash esa moliyaviy yangiliklar va hisobotlardan ma'no ajratib, sentiment asosidagi savdo strategiyalarini quvvatlaydi.

7.O'ZBEKISTON MOLIYA BOZORIDA SUN'IY INTELLEKTNI QO'LLASH ISTIQBOLLARI.

O'zbekiston moliya bozori so'nggi yillardagi iqtisodiy islohotlar natijasida jadal rivojlanmoqda. 2017 yildagi valyuta liberallashtirish va so'mning erkin suzuvchi kursga o'tkazilishi moliyaviy ma'lumotlar hajmini oshirib, ularni zamonaviy usullar bilan tahlil qilish ehtiyojini kuchaytirdi [15]. Sun'iy intellekt usullarini joriy etish mahalliy bozor sharoitida katta imkoniyatlar ochadi.

Shu bilan birga, O'zbekiston bozorida sun'iy intellektni qo'llashda bir qancha o'ziga xos qiyinchiliklar mavjud. Avvalo, bozorning nisbatan yoshligi va savdo hajmining cheklanganligi tufayli modelni o'qitish uchun yetarli tarixiy ma'lumotlar har doim ham mavjud emas. Bundan tashqari, ma'lumotlar sifatining notekisligi va past likvidlik modellarning ishonchligini pasaytirishi mumkin.

Mavjud cheklavlarga qaramay, sun'iy intellekt valyuta kurslarini (USD/UZS, EUR/UZS) bashoratlash, bank sohasidagi kredit risklarini baholash va firibgarlikni aniqlashda samarali qo'llanilishi mumkin. O'zbekiston Markaziy banki va moliya institutlari zamonaviy analitik vositalarni bosqichma-bosqich joriy etmoqda. Kelajakda sun'iy intellektga asoslangan tizimlar mahalliy moliya bozorining samaradorligini oshirishga muhim hissa qo'shishi kutilmoqda.

Kelajakda bir nechta istiqbolli yo'nalish ko'zga tashlanadi. Tushuntiriladigan sun'iy intellekt modellarning shaffofligini oshirishga qaratilgan bo'lsa, an'anaviy ekonometrik modellar va sun'iy intellektni birlashtirgan gibril yondashuvlar ikkala usulning kuchli tomonlarini uyg'unlashtiradi. Katta til modellari va asos modellar moliyaviy tahlilning yangi ufqlarini ochmoqda. O'zbekiston kontekstida esa mahalliy ma'lumotlar va sharoitlarni hisobga olgan maxsus modellarni ishlab chiqish dolzarb vazifa bo'lib qolmoqda.

8.XULOSA.

Ushbu maqolada moliya bozorida vaqt qatorlarini tahlil qilishdagi asosiy muammolar va ularni yechishda sun'iy intellekt usullarining qo'llanilishi atroflicha tahlil qilindi. Moliyaviy vaqt



qatorlarining chiziqli bo'lmaganligi, statsionar emasligi, og'ir dumlari va yuqori o'lchamliligi an'anaviy ekonometrik usullar uchun jiddiy qiyinchiliklar tug'dirishi ko'rsatildi.

Tahlil natijalari shuni ko'rsatadiki, sun'iy intellekt, xususan chuqur o'rganish usullari, chiziqli bo'lmagan va yuqori o'lchamli munosabatlarni qamrab olishda an'anaviy modellardan ustun keladi. LSTM, GRU va transformer arxitekturalari vaqtinchalik bog'liqliklarni hamda volatillik klasterlashini samarali modellashtiradi va bashoratlash, risklarni boshqarish, algoritmik savdo hamda firibgarlikni aniqlash kabi keng sohalarda amaliy natija beradi. Shu bilan birga, talqin qilinishining qiyinligi, ortiqcha moslashish xavfi va katta hajmdagi sifatli ma'lumotlarga bog'liqlik bu usullarning asosiy cheklovlari bo'lib qolmoqda.

Moliya bozorida sun'iy intellektni qo'llash katta imkoniyatlarga ega bo'lsada, ma'lumotlar yetishmovchiligi va bozorning nisbatan yoshligi kabi omillarni hisobga olishni taqozo etadi. Kelgusida tushuntiriladigan sun'iy intellekt, gibrid modellar va asos modellarning rivojlanishi sohani yangi bosqichga olib chiqishi kutiladi; an'anaviy ekonometrik bilim va zamonaviy sun'iy intellekt usullarining uyg'unligi esa eng ishonchli va samarali natijalarni ta'minlaydi.

FOYDALANILGAN ADABIYOTLAR

1. Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780.
2. Cho, K., van Merriënboer, B., Gulcehre, C., et al. (2014). Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation. *Proceedings of EMNLP*, 1724–1734.
3. Vaswani, A., Shazeer, N., Parmar, N., et al. (2017). Attention Is All You Need. *Advances in Neural Information Processing Systems*, 30, 5998–6008.
4. Fischer, T., & Krauss, C. (2018). Deep Learning with Long Short-Term Memory Networks for Financial Market Predictions. *European Journal of Operational Research*, 270(2), 654–669.
5. Sezer, O.B., Gudelek, M.U., & Ozbayoglu, A.M. (2020). Financial Time Series Forecasting with Deep Learning: A Systematic Literature Review. *Applied Soft Computing*, 90, 106181.
6. Gu, S., Kelly, B., & Xiu, D. (2020). Empirical Asset Pricing via Machine Learning. *The Review of Financial Studies*, 33(5), 2223–2273.
7. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep Learning. *Nature*, 521(7553), 436–444.
8. Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning Long-Term Dependencies with Gradient Descent Is Difficult. *IEEE Transactions on Neural Networks*, 5(2), 157–166.
9. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
10. Engle, R.F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, 50(4), 987–1007.
11. Bollerslev, T. (1986). Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*, 31(3), 307–327.
12. Lim, B., Arık, S.Ö., Loeff, N., & Pfister, T. (2021). Temporal Fusion Transformers for Interpretable Multi-Horizon Time Series Forecasting. *International Journal of Forecasting*, 37(4), 1748–1764.



13. Box, G.E.P., & Jenkins, G.M. (1976). Time Series Analysis: Forecasting and Control. Holden-Day.
14. Tsay, R.S. (2010). Analysis of Financial Time Series (3rd ed.). John Wiley & Sons.
15. O'zbekiston Respublikasi Markaziy banki (2023). Yillik hisobot. Toshkent.

KVANT KOMPYUTERLARI DAVRIDA SMART-KONTRAKTLAR XAVFSIZLIGI: MUAMMOLAR VA POST-KVANT ALGORITMLARI YECHIMLARI

Xudoyberdiyev Azizjon Norjigit o'g'li ¹

¹Tashkent International University; scientist.py@gmail.com

Annotatsiya: Smart-kontraktlar ekotizimidagi markazlashmagan moliya (DeFi) va konsensus mantiqlari deterministik davlat mashinalariga tayanadi. Biroq, kvant hisoblash tizimlarining rivojlanishi smart-kontraktarning holat o'zgarishlari (state transitions) va tasodifiy sonlar generatsiyasini (VRF) manipulyatsiya qilish xavfini tug'dirmoqda. Ushbu tadqiqotda kvant orakullari yordamida smart-kontraktlardagi dinamik zaifliklarni (Reentrancy, State Inversion) qidirish tezligi va ularga qarshi SIS hamda LWR muammolariga asoslangan yangi avlod post-kvant raqamli imzo sxemalari modellashdirildi. Tahlillar shuni ko'rsatadiki, kvant qidiruv algoritmlari smart-kontraktlardagi yashirin mantiqiy xatolarni klassik statik tahlilchilardan eksponentsial tez aniqlaydi; panjaraga asoslangan Falcon-1024 va Sabre strukturalari esa maksimal xavfsizlik ta'minlashda, EVM xotira stekida (Stack Overflow) jiddiy yuklama hosil qiladi. Xulosa o'rnida, smart-kontraktlar xavfsizligini ta'minlash uchun xotira yuklamasini kamaytiruvchi o'zaro chiziqli rekurrent polimorfizmlar va zanjir tashqarisidagi (Off-chain) kriptografik agregatsiyalar taklif etiladi.

Kalit so'zlar: smart-kontrakt xavfsizligi, Reentrancy, Short Integer Solution (SIS), Learning With Rounding (LWR), Falcon-1024, State Inversion.

1. KIRISH

Zamonaviy smart-kontraktlar arxitekturasida Turing-to'liq (Turing-complete) virtual mashinalar ichida holat o'zgaruvchilarining mutatsiyasiga asoslangan deterministik tizim hisoblanadi [1]. DeFi, DEX (Decentralized Exchanges) va avtomatlashtirilgan market-meykerlar (AMM) foydalanuvchilar o'rtasidagi likvidlik oqimini ta'minlashda ma'lum bir matematik mantiqlarga tayanadi [2]. Ammo, kvant hisoblash quvvatining oshishi an'anaviy asimmetrik kriptografiyani parchalash bilan birga, bevosita smart-kontraktarning zanjir ichidagi mantiqiy barqarorligiga (Execution Logic Integrity) ham to'g'ridan-to'g'ri tahdid solmoqda [3].

Klassik tizimlarda smart-kontrakt zaifliklarini (masalan, Reentrancy, Integer Overflow, Front-running) aniqlash va ulardan foydalanish vaqt va resurs jihatidan chiziqli cheklangan bo'lsa, kvant hisoblash muhitidagi o'tish matritsalarini ushbu jarayonni algoritmlashtirilgan **Kvant Orakullari (Quantum Oracles)** yordamida manipulyatsiya qila oladi [4]. Ayniqsa, tasodifiy sonlar generatsiyasi (VRF) va vaqtga asoslangan (block.timestamp) logikalar kvant



interferensiyasi qarshisida o'zining deterministik tabiatini yo'qotadi [3]. Ushbu inqirozga javoban, NIST tomonidan tavsiya etilgan panjaralarning o'lchamli fazoviy muammolari (*SIS*, *LWR*) ustiga qurilgan yangi post-kvant algoritmlarini smart-kontraktlar sarlavhasiga integratsiya qilish zarurati yuzaga keldi [5]. Mazkur tadqiqotda smart-kontraktlarning kvant algoritmlari ta'siridagi dinamik zaiflik modellarini tahlil qilish va ularga qarshi optimallashtirilgan post-kvant matematik yechimlarini joriy etish masalalari o'rganiladi.

2. MATERIALLAR VA USULLAR

Smart-kontrakt mantiqiy xatolarini aniqlashda kvant parallelizmining ta'sirini baholash uchun **Kvant Davlat Mashinasi (Quantum State Machine)** operatorlaridan foydalanildi. Kontrakt holatining (S_{state}) o'zgarish mantiqlari kvant superpozitsiyasi matritsasi shaklida modellashtirildi va optimallashtirilgan kvant qidiruv algoritmlarining Reentrancy (qayta kirish) hujumlarini amalga oshirish tezligi hisoblab chiqildi.

Post-kvant xavfsizlik primitivlari sifatida, avvalgi tadqiqotlardan butunlay farqli ravishda, **Kalta Butun Sonli Yechim (SIS)** va **Yaxlitlash bilan O'rganish (LWR)** muammolariga asoslangan *Falcon-1024* hamda *CRYSTALS-Dilithium5* (V-darajali kiberxavfsizlik) algoritmlarining parametrlari tahlil qilindi. Ushbu modellarning *EVM* xotira steki (*Memory Stack*), saqlash xotirasi (*Storage Slots*) yuklamasi va gaz sarfining dinamik o'zgarish koeffitsiyentlari raqamli simulyatsiya muhitida tajribadan o'tkazildi.

3. NATIJALAR

Kvant orakullari yordamida smart-kontrakt holatini manipulyatsiya qilish (State Inversion)

Smart-kontraktlar holati (S) har bir tranzaksiya (tx) ijrosidan so'ng yangilanadi: $S_{t+1} = f_{exec}(S_t, tx)$. Kvant kompyuterlari yordamida hujumchi smart-kontraktning tranzaksiya oqimini mantiqiy orakul funksiyasi (f_{oracle}) ichiga inkapsulyatsiya qilishi mumkin:

$$f_{oracle} |x\rangle |y\rangle = |x\rangle |y \oplus f_{logic}(x)\rangle \quad (1)$$

Bu yerda $f_{logic}(x)=1$ agar x tranzaksiyasi kontrakt ichida Reentrancy (qayta kirish) yoki balansni yangilamasdan mablag' chiqarish zaifligini faollashtirsa. Klassik kompyuterlar ushbu x shartni topish uchun barcha funksiyalar kombinatsiyasini tekshirishi ($O(2^k)$) kerak bo'lgan bir paytda, kvant fazoviy operatori holat amplitudasini quyidagicha kuchaytiradi:

$$|\psi_{new}\rangle = \alpha |x_{exploit}\rangle + \beta \sum_{i \neq exploit} |x_i\rangle \quad (2)$$

Natijada, $O(\sqrt{2^k})$ qadamda smart-kontraktning holat invertersiyasi (*State Inversion*) yuz beradi, ya'ni kontrakt hali o'z balansini yangilashga ulgurmasdan, uning xotira katakchasidagi (mapping(address => uint256) balances) mablag'lar qayta-qayta cheksiz sikl (call.value) orqali chiqarib olinadi.



Bundan tashqari, *DeFi* kontraktlarida tasodifiylikni ta'minlovchi chiziqli kongruent generatorlar kvant Furie konvolyutsiyasi yordamida to'liq deterministik holatga keltiriladi. Bu esa o'yin, lotereya yoki dinamik NFT kontraktlarining yashirin markazlashtirilganlik (Re-biasing) hujumi qarshisida sinishini isbotlaydi.

SIS va LWR panjarali muammolarining yangi matematik modellari

Kvant orakullarining yuqoridagi tahdidlariga qarshi smart-kontrakt funksiyalarining kirish nuqtalarini (entrypoints) muhofaza qilish uchun **Short Integer Solution (SIS)** muammosiga asoslangan raqamli imzolar qo'llaniladi.

$n, q \in \mathbb{Z}$ butun sonlar, $A \in \mathbb{Z}_q^{n \times m}$ tasodifiy matritsa va $\beta > 0$ berilgan bo'lsin. $SIS_{q,m,\beta}$ muammosiga ko'ra, quyidagi shartlarni qanoatlantiruvchi nolga teng bo'lmagan kichik $x \in \mathbb{Z}^m$ vektorini topish talab etiladi:

$$A \cdot x \equiv 0 \pmod{q}, \quad \text{bunda } \|x\| \leq \beta \quad (3)$$

Ushbu muammoning murakkabligi chekli fazodagi eng qisqa qidiruv vektorlari geometriyasiga tayangani bois, kvant kompyuterlari uni polinomial vaqtda parchalay olmaydi. *Falcon-1024* algoritmi aynan ushbu *SIS* muammosining halqali ierarxiyasida, aniqrog'ing *NTRU* panjaralari ustida ishlaydi.

Muqobil ravishda, xatoliklarni kamaytirish va hisoblash tezligini oshirish uchun **Learning With Rounding (LWR)** modelidan foydalaniladi. Unda tasodifiy Gauss xatoliklar vektori (e) o'rniga, deterministik yaxlitlash operatori ($\lfloor \cdot \rfloor_p$) qo'llaniladi:

$$b = \lfloor A \cdot s \rfloor_p \pmod{q}, \quad \text{bunda } p < q \quad (4)$$

Ushbu munosabat orqali generatsiya qilingan *Sabre* va *Dilithium5* raqamli imzo standartlari smart-kontrakt call-ma'lumotlari (*calldata*) tarkibiga kiritildi va ularning miqdoriy ko'rsatkichlari 1-jadvalda jamlandi.

1-jadval.
NIST Level V (Kvant xavfsizligining eng yuqori darajasi) va an'anaviy algoritmlarning parametrik tahlili [5].

Algoritm va muammo guruhi	Ommaviy kalit hajmi (Bytes)	Imzo hajmi (Bytes)	Xotira stekidan foydalanish (Words)	EVM xotira yuklamasi	Kvant barqarorlik koeffitsiyenti
Ed25519 (Curve25519)	32	64	2	Minimal	0% (Klassik)
CRYSTALS-Dilithium5	2,592	4,595	144	Yuqori	99.9% (\$LWR\$)
Falcon-1024	1,793	1,280	96	O'rtacha	99.9% (\$SIS\$)
Sabre-PQC	1,312	2,240	82	Mo'tadil	99.8% (\$LWR\$)



1-jadval ma'lumotlaridan ko'rinib turibdiki, V-darajali post-kvant kiberxavfsizlik modellariga o'tish ommaviy kalitlar hajmini an'anaviy tizimlardan o'rtacha 50-80 barobargacha oshiradi. Natijada bir blok hajmidagi maksimal tranzaksiyalar sig'imi (N_{tx}) eksponentsial ravishda pasayadi:

$$N_{tx} = \frac{V_{block}}{S_{meta} + S_{pubkey} + S_{sign}} \quad (5)$$

Tarmoq o'tkazuvchanligining dinamik degradatsiyasi

Olingan parametrik ko'rsatkichlar asosida blockchain tarmoqlarining ($V_{block} = 1 \text{ MB}$ cheklovida) o'tkazuvchanlik koeffitsiyenti (TPS) dinamikasi simulyatsiya qilindi. Har bir smart-kontrakt chaqiruvining metadata invariant yuklamasi $S_{meta} = 250 \text{ Bytes}$ deb qabul qilindi.

Simulyatsiya natijasida olingan grafik ko'rsatkichlari shuni tasdiqlaydiki, an'anaviy *Ed25519* algoritmda bir blok bag'riga 2890 ta smart-kontrakt tranzaksiyasini sig'dirish mumkin bo'lgan holatda, eng yuqori xavfsizlik darajasidagi *CRYSTALS-Dilithium5* modelida bu ko'rsatkich keskin tushib, bor-yo'g'i 134 ta tranzaksiyani tashkil etdi (95.3% o'tkazuvchanlik yo'qotilishi). *Falcon-1024* algoritmi esa nisbatan maqbul natija ko'rsatib, blok ichiga 301 ta kontrakt chaqiruvini sig'dira oldi.

EVM xotira arxitekturasidagi inqiroz va Stack Overflow xavfi

Smart-kontraktlar Virtual Mashinasi (*EVM*) xotira arxitekturasida 256-bitli so'zlardan iborat bo'lgan stack va xotira (*Memory*) bloklariga tayanadi. 1-jadvalda keltirilganidek, *CRYSTALS-Dilithium5* imzosini tekshirish uchun xotira stekida bir vaqtning o'zida 144 ta faol so'zni (32-byte words) saqlash talab etiladi.

Biroq, *EVM* ning arxitekturaviy cheklovi — **Stek chuqurligi maksimal 1024 ta element bilan cheklanganligidir**. Agar bitta murakkab *DeFi* kontraktida parallel ravishda ko'p imzoli (*Multi – sig*) post-kvant tekshiruvlari amalga oshirilsa, gaz sarfi va stek hajmi quyidagi funktsiyaga mutanosib ravishda ortib, Stack Overflow (stek to'lib ketishi) xatosini keltirib chiqaradi:

$$\text{Memory}_{usage} = \sum_{i=1}^k (S_{pubkey_i} + S_{sign_i}) \cdot \mu_{stack} \quad (6)$$

Bu yerda μ_{stack} — xotirani ajratish koeffitsiyentidir. Eksperimental tahlillar natijasida aniqlandiki, *Sabre-PQC* algoritmi o'zining yaxlitlash xususiyati (*LWR*) hisobiga stek yuklamasini 43% ga kamaytirish imkonini beradi.


Polimorfik retsiprok zanjirlar orqali integratsiyalashuv

Smart-kontraktlarda xotira inqirozining oldini olish va kvant orakullaridan himoyalash maqsadida **Polimorfik Retciprok Zanjir (Polymorphic Reciprocal Chain)** integratsiya modeli ishlab chiqildi. Ushbu modelga ko'ra, post-kvant imzosining kalit qismlari dinamik bloklarga ajratilib, sarlavha qismida siqilgan xesh ierarxiyasi bilan joylashtiriladi.


Mantiqiy tekshiruv zanjir ichidagi holat tekshiruvi bilan parallel ravishda quyidagi algebraik operator yordamida verifikatsiya qilinadi:

$$\Psi_{\text{verify}}(M) = \Phi_{\text{SIS}}(\mathbf{A}, \mathbf{x}) \otimes \Gamma_{\text{LWR}}(\mathbf{s}) \equiv \mathbf{I} \quad (7)$$

Ushbu arxitekturaning mantiqiy ishlash jarayoni va uning validator tugunlar darajasidagi boshqaruv oqimi 1-rasmda panel ko'rinishida tasvirlangan.



1-rasm. Polimorfik retsiprok zanjir mantiqiy arxitekturasi va parallel verifikatsiya oqimi
(a) Smart-kontrakt chaqiruvida SIS va LWR parametrlarining dinamik parchalanish va siqilish bosqichlari:



(b) Validator tugunlar tomonidan xotira stekini to'ldirmasdan parallel tekshirish amallarining bajarilishi:



4. MUHOKAMA.

Tadqiqot davomida olingan natijalar shuni ko'rsatadiki, smart-kontraktlarni kvant kompyuterlari davrida himoya qilishda an'anaviy asimmetrik usullarni to'g'ridan-to'g'ri almashtirish (Naive Replacement) yetarli emas. 1-jadval va 3.4-bo'lim tahlillari tasdiqlaganidek, V-darajali post-kvant imzolari (*Dilithium5*) EVM stekida jiddiy inqirozni keltirib chiqaradi va dApp (decentralized applications) tizimlarining funksionalligini bloklab qo'yadi.

Soha mutaxassislari o'rtasidagi ilmiy muhokamalar ushbu yuklamani kamaytirish uchun O'zaro chiziqli rekurrent polimorfizmlar va Zanjir tashqarisidagi (Off-chain) agregatsiyalar atrofida bormoqda. Smart-kontrakt ichidagi hisoblash yuklamasini kamaytirishning eng samarali strategiyasi — post-kvant imzolarini zanjir ustida emas, balki Layer-2 (masalan, ZK-Rollups) muhitida tekshirib, asosiy tarmoqqa (*Layer-1*) faqatgina ixcham holat o'zgarishi isbotini taqdim etish hisoblanadi.

5. XULOSA.

Xulosa qilib aytganda, kvant kompyuterlari davrida smart-kontraktlar xavfsizligini ta'minlash virtual mashina arxitekturasini va kriptografik primitivlarni to'liq optimallashtirishni talab etadi. Kvant orakullari orqali amalga oshiriladigan *State Inversion* va *Reentrancy* hujumlari markazlashmagan moliya platformalarini butunlay tugatishi mumkin. O'tkazilgan tadqiqotlar natijasida *Sabre-PQC* va *Falcon-1024* algoritmlari tezkor verifikatsiya va nisbatan kam xotira stekini egallashi tufayli smart-kontraktlar xavfsizligi uchun eng mos keluvchi arxitektura ekanligi isbotlandi. Kelajakdagi tadqiqotlar ushbu algoritmlarni apparat darajasida (*Asic-accelerators*) tezlashtirish va zanjirli polimorfizmlarni chuqurlashtirishga qaratilishi lozim.

FOYDALANILGAN ADABIYOTLAR:

1. Nakamoto, S. Bitcoin: A Peer-to-Peer Electronic Cash System. Decentralized Business Review, 2008, 1, 1–9.
2. Wood, G. Ethereum: A secure decentralised generalised transaction ledger. Ethereum Project Yellow Paper, 2014, 151, 1–32.
3. Shor, P.W. Algorithms for quantum computation: discrete logarithms and factoring. Proceedings 35th Annual Symposium on Foundations of Computer Science, 1994, 124–134.
4. Grover, L.K. A fast quantum mechanical algorithm for database search. Proceedings of the twenty-eighth annual ACM symposium on Theory of computing, 1996, 212–219.
5. Alagic, G.; Cooper, J.; Dang, M. Status Report on the Third Round of the NIST Post-Quantum Cryptography Standardization Process. *NIST IR 8413*, 2022, 1–45.

PNEVMONIYANI TASHXISLASH AXBOROT TIZIMINING KOGNITIV MODELI

Nodira Naim¹

¹“Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti” tayanch doktoranti, naimnodira02@gmail.com

Annotatsiya: Mazkur maqolada ko'krak qafasi rentgen tasvirlari asosida virusli pnevmoniyani tashxislash axborot tizimining kognitiv modeli ishlab chiqilgan. Tadqiqotda rentgen tasvirlarini 6 ta anatomik-diagnostik zonaga ajratish, diagnostik belgilarni aniqlash va ular



o'rtasidagi sabab-oqibat bog'lanishlarini noaniq kognitiv xarita yordamida ifodalash yondashuvi taklif etilgan. Modelda rentgen tasviri sifati, o'pka segmentatsiyasi, xiralashish, infiltrat, konsolidatsiya, ground-glass opacity, zararlanish intensivligi, zararlanish joylashuvi hamda sun'iy intellekt modeli natijasi asosiy diagnostik tugunlar sifatida belgilangan. Taklif etilgan FCM modeli normal holat, pnevmoniya va COVID-19 ehtimolliklarini baholash hamda yakuniy tashxisni shakllantirish imkonini beradi.

Kalit so'zlar: *pnevmoniya, rentgen tasviri, axborot tizimi, noaniq kognitiv xarita, FCM, segmentatsiya, sun'iy intellekt, tashxislash modeli, COVID-19.*

1. KIRISH

So'nggi yillarda tibbiy tasvirlarga raqamli ishlov berish va kasalliklarni avtomatlashtirilgan aniqlash axborot tizimlarining muhim yo'nalishlaridan biriga aylandi. Ayniqsa, virusli pnevmoniya va COVID-19 holatlarini aniqlashda ko'krak qafasi rentgen tasvirlari keng qo'llaniladi, chunki ular tezkor va qulay diagnostik axborot manbai hisoblanadi [1-3].

Rentgen tasvirlarida xiralashish, infiltrat, konsolidatsiya, ground-glass opacity va zararlanish joylashuvi kabi belgilar tashxislashda muhim ahamiyatga ega. Biroq ushbu belgilar ayrim hollarda boshqa o'pka kasalliklari belgilariga o'xshash bo'lishi mumkin. Shu sababli diagnostik belgilarni ajratish, qayta ishlash va qaror qabul qilish jarayonini formal model asosida ifodalash dolzarb hisoblanadi.

Tibbiy tasvirlarni tahlil qilishda chuqur o'qitish modellari yuqori natija bersa-da, ularning qaror qabul qilish jarayoni har doim ham izohlanmaydi. Noaniq kognitiv xaritalar — Fuzzy Cognitive Maps esa diagnostik belgilar o'rtasidagi sabab-oqibat bog'lanishlarini graf ko'rinishida ifodalash imkonini beradi [4,5]. FCM yondashuvi tibbiyotda tashxislash va klinik qarorlarni qo'llab-quvvatlash jarayonlarida samarali qo'llanilmoqda [6,7].

Mazkur tadqiqotning maqsadi ko'krak qafasi rentgen tasvirlari asosida pnevmoniyaning tashxislash axborot tizimi uchun noaniq kognitiv model ishlab chiqishdan iborat. Taklif etilayotgan modelda rentgen tasviri 6 ta anatomik-diagnostik zonaga ajratiladi, har bir zona bo'yicha asosiy rentgenologik belgilar baholanadi va ular FCM tugunlari sifatida ifodalanadi. Natijada normal holat, pnevmoniya va COVID-19 ehtimolliklarini baholash hamda yakuniy tashxisni shakllantirishga xizmat qiluvchi izohlanuvchan kognitiv model taklif etiladi.

2. MATERIALLAR VA USULLAR

Noaniq kognitiv xarita - FCMlar murakkab tizimlarni modellashtirish va inson mantiqiga mos keladigan natijalarni taqdim etish uchun ishlatiladigan hisoblash texnikasi hisoblanadi. Fuzzy Cognitive Model — bu noaniq sharoitda qaror qabul qilish jarayonini ifodalovchi kognitiv model bo'lib, unda tushunchalar o'rtasidagi ta'sirlar musbat yoki manfiy vaznlar orqali ko'rsatiladi. Tadqiqot ishida taklif etilgan model rentgen tasvirlari asosida normal, virusli pnevmoniya, covid-19 holatlarini aniqlashga yordam beradi. Noaniq kognitiv xaritalar (FCM) - bu tugunlar va ular orasidagi bog'lanishlardan iborat graf hisoblanadi.

$$C = C_1, C_2, C_3 \dots, C_n \quad (1)$$

bu yerda, C - tushunchalar, n - tugunlar soni. Taklif etilayotgan kognitiv model qaror qabul qilish jarayonida ishtirok etuvchi asosiy tashxislash omillarni tugunlar ko'rinishida ifodalaydi.



C1- rentgen tasviri sifati;
C2 - o'pka segmentatsiyasi;
C3-xiralashish;
C4-infiltrat
C5-konsolidatsiya
C6-ground-glass opacity
C7-zararlanish intensivligi
C8-zararlanish joylashuvi
C9-SI modeli natijasi
C10-normal holat ehtimolligi
C11-pnevmoniya ehtimolligi
C12-COVID-19 ehtimolligi
C13-yakuniy tashxis

Ular orasidagi sabab-oqibat munosabatlari yo'naltirilgan vaznli qirralar orqali tavsiflanadi. Qirra vazni w_{ij} noaniq qiymat bo'lib, u bir tushunchaning boshqa tushunchaga ko'rsatadigan ta'sirini ifodalaydi.

$$W = [w_{ij}], \quad i, j = 1, 2, \dots, n \quad (2)$$

bu yerda W -vaznlar matritsasi, w_{ij} - C_i tugunning C_j tugunga ta'sir darajasi. Keyin tugunlar orasidagi bog'lanishlar vaznlar matritsasi orqali beriladi:

$$w_{ij} \in [-1; 1] \quad (3)$$

Agar: $w_{ij} > 0$ bo'lsa, C_i tugun C_j tugunga ijobiy ta'sir qiladi.
Agar: $w_{ij} < 0$ bo'lsa, C_i tugun C_j tugunga salbiy ta'sir qiladi.
Agar: $w_{ij} = 0$ bo'lsa, C_i va C_j tugunlari orasida bevosita bog'lanish mavjud emas.
Tadqiqotda yakuniy natija 3 sinfga ajratiladi:

$$Y = \{Y_1, Y_2, Y_3\} \quad (4)$$

bu yerda: Y_1 =normal, Y_2 =pnevmoniya, Y_3 =COVID-19

Model har bir sinf bo'yicha ehtimolliklarni hisoblaydi:

$P = \{P_{\text{normal}}, P_{\text{pneumonia}}, P_{\text{covid}}\}$

Yakuniy tashxis qarori eng katta ehtimollikka ega sinf asosida aniqlandi:

$$\text{Qarorlar} = \arg \max \{P_{\text{normal}}, P_{\text{pneumonia}}, P_{\text{covid}}\} \quad (5)$$

Agar: $P_{\text{normal}} = \max(P)$ bo'lsa, natija normal holat deb belgilanadi.

Agar: $P_{\text{pneumonia}} = \max(P)$ bo'lsa, natija pnevmoniya deb belgilanadi.

3. NATIJALAR

Ushbu bo'limda pnevmoniyani tashxislash axborot tizimi uchun ishlab chiqilgan noaniq kognitiv model natijalari keltiriladi. Taklif etilgan model rentgen tasviridan olingan diagnostik belgilarni tizimli ifodalash, ular orasidagi sabab-oqibat bog'lanishlarini aniqlash va yakuniy

Tadqiqot natijasida pnevmoniyani tashxislash jarayonida ishtirok etuvchi asosiy diagnostik omillar aniqlanib, ular FCM modelining tugunlari sifatida belgilandi. Modelda rentgen tasviri sifati, o'pka segmentatsiyasi, rentgenologik belgilar, sun'iy intellekt modeli natijasi hamda yakuniy tashxis o'zaro bog'langan tugunlar sifatida qaraldi. Taklif etilgan noaniq kognitiv modelning graf ko'rinishi 1-rasmda keltirilgan. Rasmda diagnostik tugunlar, ular orasidagi ijobiy va salbiy ta'sirlar hamda yakuniy qaror tugunlari ko'rsatilgan.

Grafdagi yo‘naltirilgan bog‘lanishlar ushbu omillarning bir-biriga va tashxis natijasiga ta‘sirini ko‘rsatadi. Musbat vaznlar diagnostik ehtimollikni oshiruvchi, manfiy vaznlar esa kamaytiruvchi ta‘sirni ifodalaydi. C9 tuguni sun‘iy intellekt modeli natijasida shakllanadigan uch sinf ehtimollik vektorini bildiradi. Yakuniy C10, C11, C12 qaror tugunlarida aniqlangan normal holat, virusli pnevmoniya va COVID-19 ehtimolliklarini taqqoslash asosida C13 tugunida shakllanadi (1-rasm).



1-jadval.

Tugun	Tugun nomi	
C_1	Rentgen tasviri sifati	Kiruvchi tasvir sifatini baholash
C_2	O'pka segmentatsiyasi	O'pka sohasini ajratish



C_3	Xiralashish	Pnevmoniyaga xos xira joylarni aniqlash
C_4	Infiltrat	
C_5	Konsolidatsiya	Zichlashgan o'pka sohasini aniqlash
C_6	Ground-glass opacity	Pnevmoniya va COVID-19ga xos belgini baholash
C_7	Zararlanish intensivligi	Patologik jarayon kuchini aniqlash
C_8	Zararlanish joylashuvi	O'zgarishlarning o'pkadagi joylashuvini aniqlash
C_9	SI modeli natijasi	Uch sinf bo'yicha ehtimollik vektorini shakllantirish
C_{10}	Normal holat ehtimolligi	Normal sinfga mansublik ehtimolini aniqlash
C_{11}	pnevmoniya ehtimolligi	Pnevmoniya sinfga mansublik ehtimolini aniqlash
C_{12}	COVID-19 ehtimolligi	COVID-19 sinfga mansublik ehtimolini aniqlash
C_{13}	Yakuniy tashxis	Eng katta ehtimollik asosida qaror chiqarish

Noaniq kognitiv xaritada berilgan 0.7, 0.8, 0.9 kabi vazn qiymatlari tugunlar orasidagi sabab-oqibat ta'sir darajasini ifodalaydi. Ushbu qiymatlar rentgenologik belgilar, tibbiy adabiyotlarda keltirilgan klinik-rentgenologik mezonlar hamda ekspert baholash tamoyillariga asoslanib shartli ravishda belgilandi. FCM metodologiyasida ta'sir darajasi dastlab "past", "o'rta", "yuqori", "juda yuqori" kabi lingvistik baholar orqali ifodalanadi, so'ngra ular $[-1;1]$ oraliqdagi sonli vaznlarga aylantiriladi. Shu asosda 0.7 qiymati yuqori ta'sirni, 0.8 qiymati esa juda yuqori ta'sirni bildiradi. Agar siz Word dasturidan foydalanayotgan bo'lsangiz, maqolangizdagi tenglamalar uchun Microsoft Equation Editor yoki MathType qo'shimchasidan (<http://www.mathtype.com>) foydalaning..

4. MUHOKAMA

Olingan natijalar pnevmoniyani tashxislash axborot tizimida noaniq kognitiv xarita modelidan foydalanish qaror qabul qilish jarayonini izohlanuvchan ko'rinishda ifodalash imkonini berishini ko'rsatdi. Modelda rentgen tasviri sifati, o'pka segmentatsiyasi, xiralashish, infiltrat, konsolidatsiya, ground-glass opacity, zararlanish intensivligi va joylashuvi kabi omillar asosiy diagnostik tugunlar sifatida qaraldi.

Mavjud chuqur o'qitish modellari rentgen tasvirlarini klassifikatsiya qilishda yuqori natija berishi mumkin, biroq ularning qaror qabul qilish jarayoni har doim ham tushunarli bo'lmaydi. Taklif etilgan FCM modeli esa diagnostik belgilar o'rtasidagi sabab-oqibat munosabatlarini graf ko'rinishida ifodalab, yakuniy tashxisga qaysi belgilar ta'sir qilganini izohlash imkonini beradi. Modelda musbat vaznlar pnevmoniya yoki COVID-19 ehtimolligini oshiruvchi, manfiy vaznlar esa normal holat ehtimolligiga kamaytiruvchi ta'sirni bildiradi. Shu sababli FCM modeli tibbiy axborot tizimida shifokor qarorini qo'llab-quvvatlovchi yordamchi modul sifatida qo'llanishi mumkin.



Tadqiqotning cheklovi shundaki, vazn qiymatlari dastlab ekspert bahosi va rentgenologik belgilar ahamiyatiga asoslangan holda belgilanadi. Kelgusida ushbu vaznlarni real rentgen tasvirlari bazasi, statistik tahlil va mashinali o'qitish algoritmlari yordamida aniqlashtirish maqsadga muvofiqdir.

5. XULOSALAR

Maqolada ko'krak qafasi rentgen tasvirlari asosida pnevmoniyani tashxislash axborot tizimi uchun noaniq kognitiv xarita modeli taklif etildi. Modelda rentgen tasviri sifati, o'pka segmentatsiyasi, asosiy rentgenologik belgilar, sun'iy intellekt modeli natijasi va yakuniy tashxis tugunlari belgilandi.

Taklif etilgan FCM modeli normal holat, pnevmoniya va COVID-19 ehtimolliklarini baholash hamda yakuniy tashxisni eng katta ehtimollik asosida shakllantirishga xizmat qiladi. Model diagnostik belgilar o'rtasidagi sabab-oqibat bog'lanishlarini izohlanuvchan ko'rinishda ifodalashi bilan ahamiyatlidir.

FOYDALANILGAN ADABIYOTLAR:

1. Rahman, T.; Khandakar, A.; Qiblawey, Y.; Tahir, A.; Kiranyaz, S.; Kashem, S.B.A.; Islam, M.T.; Al Maadeed, S.; Zughaier, S.M.; Khan, M.S.; Chowdhury, M.E.H. Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images. *Computers in Biology and Medicine*, 2021, 132, 104319.
2. Sovatzidi, G.; Vasilakakis, M.; Iakovidis, D.K. Automatic fuzzy cognitive maps for explainable image-based pneumonia detection. *Proceedings of the 27th Pan-Hellenic Conference on Progress in Computing and Informatics, PCI 2023, Lamia, Greece, 24–26 November 2023*; ACM: New York, NY, USA, 2023; pp. 74–78.
3. Apostolopoulos, I.D.; Tzani, M.A.; Aznaouridis, S.I.; Papandrianos, N.I.; Papathanasiou, N.D.; Papageorgiou, E.I. Fuzzy cognitive map applications in medicine over the last two decades: A review study. *Bioengineering*, 2024, 11(2), 139.
4. Naim, Nodira, Maxina Mansurova, and Avaz Kuvnakov. "Analysis and Selection of an Appropriate Model for Analyzing the Current State and Spread of COVID-19 in Uzbekistan." *Proceedings of IEMTRONICS 2025: International IoT, Electronics and Mechatronics Conference, Volume 2*. Springer Nature.
5. Naim, N. A. "Virusli pnevmoniya kasalligini tashxislash malumotlariga raqamli ishlov berish algoritmlari va axborot tizimi." *o'zbekistonda fanlararo innovatsiyalar va ilmiy tadqiqotlar jurnali* 4.40 (2025): 207-209.
6. Ieracitano, C.; Mammone, N.; Versaci, M.; Varone, G.; Ali, A.R.; Armentano, A.; Calabrese, G.; Ferrarelli, A.; Turano, L.; Tebala, C.; Morabito, F.C. A fuzzy-enhanced deep learning approach for early detection of COVID-19 pneumonia from portable chest X-ray images. *Neurocomputing*, 2022, 481, 202–215.
7. Guefrechi, S.; Jabra, M.B.; Ammar, A.; Koubaa, A.; Hamam, H. Deep learning based detection of COVID-19 from chest X-ray images. *Multimedia Tools and Applications*, 2021, 80, 31803–31820.



CHIZIQLI REGRESSIYA VA TASODIFIY O'RMON YORDAMIDA BASHORATLI MA'LUMOTLAR TAHLILI HISOR DAVLAT O'RMON XO'JALIGI HUDUDI BO'YICHA

Boboqulov Abbas Dilshod o'g'li¹

¹ "Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalar universiteti" tayanch
doktoranti; abbosboboqulov0511@gmail.com

Annotatsiya: Bashoratli tahlil deb ataladigan statistik usul ma'lumotlardagi bog'liqliklarni aniqlash va kelajakdagi harakatlarni bashorat qilish uchun mashinaviy o'rganish hamda kompyuter texnologiyalaridan foydalanadi. Hozirgi vaqtda trening tashabbuslari qanchalik samarali ekanini aniqlash va ularni qanday yaxshilash mumkinligini bilish maqsadida tavsifiy tahlildan tashqariga chiqish afzal ko'rilmogda. Bashoratli tahlilda o'tmish va joriy ma'lumotlardan foydalanib, kelajakda nima sodir bo'lishi mumkinligi haqida bashoratlar qilinadi. Ushbu maqolada bashoratli ma'lumotlar tahlilida qo'llaniladigan ikki model taqqoslanadi: chiziqli regressiyaga asoslangan umumlashtirilgan chiziqli model (Linear Regression, LR) va qaror daraxtlariga asoslangan tasodifiy o'rmon modeli (Decision Trees with Random Forest, RF). Bundan tashqari, LR va RF bashoratlarini o'rtachalash orqali birlashtirish strategiyasi yanada aniqroq natijalar berdi, hamda o'qitish ma'lumotlari sifatiga bog'liq holda alohida algoritmlarning haddan tashqari moslashuvi (overfitting) va noto'g'ri bashoratlar berish xavfini kamaytiradi.

Kalit so'zlar: ma'lumotlar tahlili, bashoratli ma'lumotlar tahlili, chiziqli regressiya, tasodifiy o'rmon, umumlashtirilgan chiziqli model, qaror daraxtlari.

1. KIRISH

Bashoratli tahlil - bu ma'lumotlar tahlilining kelajakni bashoratlashga qaratilgan qismidir. Tavsifiy va diagnostik tahlil turlari mavjud bo'lsada, bashoratli tahlil biznesda qaror qabul qilishda muhim bo'lgani sababli keng qo'llaniladi. U turli statistik modellar, usullar va vositalardan foydalanib, ma'lumotlar to'plamidagi naqshlarni aniqlaydi va bashoratlar hosil qiladi. Bashoratli tahlil faqat ma'lumotlarni tavsiflash va guruhlash bilan cheklanmaydi, balki murakkab modellar yordamida xulosalar chiqarishga asoslanadi. Ushbu modellar algoritmlar va mashinaviy o'rganishdan foydalanib, o'tmish va joriy ma'lumotlarni tahlil qiladi hamda kelajakdagi tendensiyalarni bashoratlaydi. Bashoratli tahlil biznes qarorlarini baholashda juda foydali, chunki qarorlar odatda loyiha, guruh, muhit yoki boshqa obyektlarning kelajakdagi faoliyatiga doir bashoratlarga tayanadi. Eng ko'p qo'llaniladigan asosiy modellar quyidagilar:

- Qaror daraxtlari - har bir variant yoki harakat yo'nalishining mumkin bo'lgan natijalarini tarmoqlanish orqali ko'rsatadi;
- Regressiya usullari - o'zgaruvchilar o'rtasidagi bog'liqlikni aniqlashga yordam beradi;
- Neyron tarmoqlar - ma'lumotlar to'plamlari o'rtasidagi yashirin bog'liqliklarni aniqlash uchun algoritmlardan foydalanadi.

Bashorat qilish ma'lumotlarni qazib olish (data mining) jarayonining muhim tarkibiy qismidir. Bashoratli tahlil joriy yoki tarixiy ma'lumotlar asosida kelajakdagi tendensiyalarni bashoratlash imkonini beradi. Eng ilg'or modellar mashinaviy o'rganish va sun'iy intellektdan foydalanadi [1].



2. MATERIALLAR VA USULLAR

Bashoratli tahlil bir nechta turdagi modellarni o'z ichiga oladi. Ularning aksariyati regressiya modellaridir, ya'ni ikki yoki undan ortiq o'zgaruvchi o'rtasidagi bog'liqlikni aniqlashga qaratilgan. Bu modellar ma'lum o'zgaruvchi qiymati o'zgarganda noma'lum o'zgaruvchining qiymatini bashorat qilishga yordam beradi [2].

Umumlashtirilgan chiziqli model - Chiziqli regressiya: Chiziqli regressiya bashoratli tahlilning eng oddiy usullaridan biridir. Unda noma'lum o'zgaruvchining qiymati ma'lum o'zgaruvchining qiymati bilan chiziqli bog'liq deb faraz qilinadi.

Qaror daraxtlari - tasodifiy o'rmonlar (Random Forest): Tasodifiy o'rmonlar regressiya modellashtirishda ham qo'llaniladigan mashinaviy o'rganish modellaridir. Ular ko'p sonli o'zgaruvchilarga ega bo'lgan katta hajmdagi ma'lumotlar to'plamlari uchun juda mos keladi va bir nechta qaror daraxtlaridan tashkil topadi [3].

Random Forest

Mashinali o'rganish usullari tasniflash (klassifikatsiya) va regressiya masalalarini yechishda keng qo'llaniladi, jumladan Random Forest algoritmi. Ushbu usul yig'ma o'rganishga asoslangan bo'lib, murakkab masalalarni bir nechta klassifikatorlarni birlashtirish orqali hal etadi. Random Forest algoritmidagi juda ko'p sonli qaror daraxtlari qo'llaniladi. Random Forest algoritmi bagging (bootstrap aggregatsiya) usuli orqali o'qitilgan "o'rmon"ni hosil qiladi [4]. Bagging - ansambl meta-algoritmi bo'lib, mashinali o'rganish algoritmlarining aniqligini oshirishga xizmat qiladi. Random Forest algoritmi qaror daraxtlarining bashoratlariga asoslanib yakuniy natijani aniqlaydi. U turli daraxtlar tomonidan olingan natijalarni o'rtachalash (averaging) orqali bashorat qiladi [5]. Daraxtlar soni ortgani sari natijaning aniqligi ham oshadi.

Random Forest algoritmi qaror daraxtlari algoritmgaga xos bo'lgan kamchiliklarni bartaraf etadi, ma'lumotlar to'plamining ortiqcha moslashuvini (overfitting) kamaytiradi va aniqlikni oshiradi.

Tasodifiy o'rmon algoritmining afzalliklari:

U tasniflash va regressiya masalalarini bajarish imkoniyatiga ega. Tasodifiy o'rmon aniq bashoratlar hosil qiladi va ularni tushunish nisbatan oson. Katta hajmdagi ma'lumotlar to'plamlarini samarali qayta ishlay oladi. Qaror daraxti usuli bilan solishtirganda, tasodifiy o'rmon algoritmi natijalarni bashorat qilishda aniqroq hisoblanadi [6].

Tasodifiy o'rmon algoritmining kamchiliklari:

Tasodifiy o'rmondan foydalanilganda hisoblash uchun ko'proq resurslar talab etiladi. Qaror daraxti yondashuviga nisbatan ko'proq vaqt talab qiladi [7-10].

3. NATIJALAR

Hisor davlat o'rmon xo'jaligi hududi bo'yicha 15 yillik NDVI qiymatlari.

Garmonik model fitting natijalari: Kengaytirilgan chiziqli regressiya, faqat o'zgaruvchilar trigonometrik ko'rinishda.

$$P_t = \beta_0 + \beta_1 t + \beta_2 \cos(2\pi t) + \beta_3 \sin(2\pi t) \quad (1)$$

Hisoblangan koeffitsientlar:

- β_0 (o'rtacha daraja) = 0.1098



- β_1 (trend koeffitsienti) = 0.00212
- β_2 (cos komponent) = 0.01664
- β_3 (sin komponent) = 0.04376


1-garmonik model

$$MAE = \frac{1}{n} \sum_{i=0}^n |y_i - \hat{y}_i| \quad MAE = 0.02919$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad RMSE = 0.04063$$

$$R^2 = 0.3154$$


- $R^2 \approx 31.5\%$
- Ma'lumot dispersiyasining uchdan bir qismini tushuntiradi
- Faqat asosiy yillik siklni ushlaydi
- Soddalashtirilgan model



1-rasm. Hisor davlat o'rmon xo'jaligi hududi bo'yicha 1-garmonik model natijalari:

Ekologik ma'nosi: faqat mavsumiy vegetatsiya sikli hisobga olingan [11].

2-garmonik model



2-rasm. 2-garmonik model natijalari:


2-garmonik model natijalari:

MAE = 0.02507, RMSE = 0.03652, $R^2 = 0.4471$

2-garmonik model:

- Yillik sikl
- Yarim yillik sikl
- Ichki vegetatsiya tebranishini hisobga oladi.

3-garmonik model



3-rasm. 3-garmonik model natijalari:

3-garmonik model

MAE = 0.02451, RMSE = 0.03595, $R^2 = 0.4641$



- $R^2 \approx 46.4\%$
- RMSE juda oz kamaygan
- Yaxshilanish kichik ($\approx 1.7\%$)

Demak:

- 3-garmonik mavjud, lekin kuchli emas
- Model murakkablashdi, lekin foyda kichik

3-garmonik model:

- Yillik sikl
- Yarim yillik sikl
- Qo'shimcha ichki vegetatsiya tebranishni hisobga oladi.

Agar MAE va RMSE eng kichik, R^2 eng katta bo'lsa $\rightarrow$ eng kuchli model.

1-jadval.
3 ta garmonik model RMSE va R^2 natijalari

Model	RMSE	R^2
1-garmonik	0.040635	0.315351
2-garmonik	0.036515	0.447142
3-garmonik	0.035951	0.464096

Eng optimal model $\rightarrow$ 2-garmonik model

Sababi:

- 1 $\rightarrow$ 2 o'tishda katta yaxshilanish
- 2 $\rightarrow$ 3 o'tishda juda kichik yaxshilanish
- Ortiqcha parametrlar qo'shish xavfi bor (overfitting)

Hududda:

- Kuchli yillik sikl mavjud
- Yarim yillik vegetatsiya tebranishi mavjud
- Qisqa muddatli mikro-sikl kuchli emas

Ikkinchi garmonik komponentni qo'shish model aniqligini sezilarli darajada oshirdi (R^2 0.31 dan 0.45 gacha). Uchinchi garmonik esa faqat kichik yaxshilanish berdi (R^2 0.46), bu vegetatsiyada uchinchi darajali sikl zaif ekanligini ko'rsatadi. Shuning uchun 2-garmonik model optimal hisoblanadi. Zich / Siyrak klassifikatsiya (cloud < 20% filtr bilan) [12-13].

Chegara qiymat:

- 0.12 $\rightarrow$ Zich
- 0.05 - 0.12 $\rightarrow$ O'rtacha
- < 0.05 $\rightarrow$ Siyrak


Natija:

- Zich: 275 ta
- O'rtacha: 70 ta
- Siyrak: 25 ta


Hududning katta qismi zich vegetatsiyaga ega.

2-jadval.
3 ta garmonik model natijalari


Model	MAE	RMSE	R ²
1-garmonik	0.029186	0.040635	0.315351
2-garmonik	0.025068	0.036515	0.447142
3-garmonik	0.024507	0.035951	0.464096



4-rasm. Hisor hududi bo'yicha 1,2,3 garmonik modellar taqqoslanishi



5-rasm. Random Forest modeli



6-rasm. Chiziqli regressiya modeli

Random Forest modeli natijalari

- MAE: 0.0240
- RMSE: 0.0327
- R^2 : 0.358

Chiziqli regressiya natijalari

- MAE: 0.0327
- RMSE: 0.0439
- R^2 : -0.156

4. MUHOKAMA

1 Random Forest

- Xatolik pastroq (MAE va RMSE kichik)
- R^2 musbat (≈ 0.36)
- NDVI dinamikasini qisman tushuntira olgan

3-jadval

Chiziqli regressiya, random forest, 3-garmonik modellarni qiyosiy tahlili

Model	MAE	RMSE	R^2
Chiziqli regressiya	0.0327	0.0439	-0.156
Random Forest	0.0240	0.0327	0.358
3-garmonik	0.0245	0.0359	0.464



2 Linear Regression

- R^2 manfiy chiqdi
- Bu model o'rtacha qiymatdan ham yomonroq bashorat qilganini bildiradi
- NDVI nolinear va mavsumiy bo'lgani sababli oddiy chiziqli model mos kelmagan.

5. XULOSA

Bashoratli tahlil ba'zi tanqidlarga qaramay, deyarli barcha sohalarda qo'llaniladi. Ko'proq ma'lumot mavjud bo'lsa, kelajakdagi natijalarni nisbatan yuqori aniqlikda bashorat qilish mumkin bo'ladi. Bu esa tashkilot va korxonalarga ishlab chiqarishni oshirish uchun asosli qarorlar qabul qilish imkonini beradi. Bashoratli tahlil usullarini o'rganish bugungi kunda ma'lumotlar fanlari va biznes tahlili sohasidagi kasblar uchun zarur bo'lib qolgan, chunki u deyarli barcha sanoat tarmoqlarida keng qo'llaniladi.

Ushbu tadqiqotda Random Forest modelining RMSE qiymati 0.0327, xatoliklarning arifmetik o'rtachasi esa 0.0240 ni tashkil etdi. Chiziqli regressiya modelida esa RMSE = 0.0439, xatoliklarning arifmetik o'rtachasi 0.0327 bo'ldi. Va 3-garmonik modelida esa RMSE = 0.0359, xatoliklarning arifmetik o'rtachasi 0.0245 bo'ldi. Giperparametrlarni sozlash jarayoni orqali ushbu xatoliklarni yanada kamaytirish mumkin. Tadqiqotda bashoratli tahlil uchun chiziqli regressiyaga asoslangan umumlashtirilgan chiziqli model va qaror daraxtlariga asoslangan tasodifiy o'rmon modellari va taqqoslandi. Bundan tashqari, ikkala model bashoratlarini arifmetik o'rtacha orqali birlashtiruvchi kombinatsiyalashgan yondashuv ham o'rganildi. Natijalar shuni ko'rsatdiki, turli ma'lumotlarni qazib olish (data mining) usullari bashoratlashda samarali bo'lishi mumkin. LR va RF bashoratlarini o'rtachalash orqali birlashtirish yanada aniq natijalarni berdi va o'qitish ma'lumotlari sifatiga bog'liq holda alohida algoritmlarda yuzaga kelishi mumkin bo'lgan overfitting va noto'g'ri bashoratlar xavfini kamaytirdi. Loyihalarda o'zgaruvchan muhitda aniqlikni saqlab qolish uchun loyiha boshqaruvi bo'limlari yuqori sifatli kirish ma'lumotlarini ta'minlashi va modellarni muntazam yangilab borishi muhim ekanini unutmaslik lozim.

FOYDALANILGAN ADABIYOTLAR:

1. Data Mining Techniques: Algorithm, Methods & Top Data Mining Tools. Software Testing Help; 2020-yil mart. <https://www.softwaretestinghelp.com/data-mining-techniques>.
2. Steeneken F., Ackley D. Supermarket biznesining to'liq modeli. BPTrends 2012-yil yanvar.
3. Bafna J. SAS yordamida chiziqli regressiya asosida bashoratli tahlil. Big Data Zone – DZone; 2017.
4. Manoochchhri Z., Barati M., Faradmal J., Manoochchhri S. Anabolik-androgen steroidlardan foydalanish bilan bog'liq omillarni aniqlash uchun Random Forest modeli. BMC Sports Science, Medicine and Rehabilitation. 2021; 13(1):30.
5. Kumari K., Yadav S. Chiziqli regressiya tahlili bo'yicha tadqiqot. Curriculum in Cardiology - Statistics. 2021; 4:33–36.
6. Sumiran K. Ma'lumotlarni qazib olish texnikalari va ularning sanoat injiniringidagi qo'llanilishi haqida umumiy sharh. Asian Journal of Applied Science and Technology. 2018; 2:947–953.
7. Mehmed K. Data Mining - Tushunchalar, modellar, usullar va algoritmlar. 2-nashr, ilustratsiyali. Wiley; 2011. ISBN: 1118029127, 9781118029121.



8. Varshini A.G.P., Kumari K.A. Dasturiy ta'minot mehnat sarfini baholash uchun bashoratli tahlil yondashuvlari: sharh. Indian Journal of Science and Technology. 2020; 13:2094–2103.

9. Nassif A.B. va boshqalar. Regressiya va noaniq mantiq (fuzzy) modellaridan foydalangan holda dasturiy ta'minotni ishlab chiqish mehnat sarfini baholash. Computational Intelligence and Neuroscience. 2019; 2019:8367214.

10. Boboqulov A.D., Malikova N.T. "O'rmon xo'jaligini boshqarishning axborot modellari". "Raqamli iqtisodiyot" ilmiy-elektron jurnali | 15-son | 2026 80-97 b.

11. Yakubov M.S, Nazarova G.N., Boboqulov A.D. "O'rmon xo'jaligida ekologik monitoringni optimallashtirishda sun'iy intellekt, uchuvchisiz uchish apparati va lidar ma'lumotlarining sinergetik qo'llanilishi", "Al-Farg'oniy avlodlari" elektron ilmiy jurnali ISSN 2181-4252. Tom: 1 | Son: 4 | 2025-yil.

12. Boboqulov A.D. "Hududiy o'rmon xo'jaligi kompleksi resurslarini boshqaruv tizimini rivojlantirish omillari". Raqamli Transformatsiya va Sun'iy Intellekt ilmiy jurnali VOLUME 3, ISSUE 3, JUNE 2025 ISSN: 3030-334.

13. Nazarova G.N., Boboqulov A.D. "Uchuvchisiz uchish apparatlari yordamida o'rmon xo'jaligini monitoring qilish". Raqamli transformatsiyalash jarayonida muhandislik sohalari va iqtisodiyot tarmoqlarini rivojlantirish: muammo va yechimlar 639-643 b.



MANAGEMENT **AND** FUTURE TECHNOLOGIES

SCIENTIFIC & TECHNICAL JOURNAL



<https://vatanuniversiteti.uz>