

SUN'IY INTELLEKT YORDAMIDA MOLIVAVIY XAVFLARNI ANIQLASH VA BOSHQARISH: ALGORITM, SAMARADORLIK VA O'ZBEKISTON MOLIVA SEKTORI UCHUN TATBIQ MODELI

Kendjayeva Dildora Xudayberganovna (ORCID: 0000-0002-4337-3080)

Toshkent amaliy fanlar universiteti, "Kompyuter injiniringi" kafedrası katta o'qituvchisi,

Gavhar ko'chasi 1-uy, Toshkent 100149, O'zbekiston

E-mail: shainaxon@gmail.com

Abdulxalilova Surayyo Ahad qizi

Toshkent amaliy fanlar universiteti, Axborot texnologiyalari fakulteti talabasi

E-mail: surayyo3006@gmail.com

Annotatsiya: Ushbu maqolada sun'iy intellekt (AI) texnologiyalarining moliyaviy xavflarni aniqlash va boshqarishdagi ilmiy-amaliy ahamiyati kompleks tarzda tahlil qilinadi. Mashinali o'qitish (machine learning), chuqur o'qitish (deep learning) va tabiiy tilni qayta ishlash (NLP) algoritmlarining kredit riski, bozor riski, firibgarlik riski va likvidlik riski kabi asosiy moliyaviy xavf turlarini aniqlashdagi samaradorligi ko'rib chiqiladi. Tadqiqot natijalariga ko'ra, AI asosidagi risk tizimlari an'anaviy uslublarga qaraganda firibgarlikni aniqlash aniqligini 95–99% darajasiga, kredit skoringni esa 88–96% darajasiga yetkazish imkonini beradi. JP Morgan, Visa, Mastercard va Markaziy banklar tajribasi asosida qiyosiy tahlil o'tkazilgan. O'zbekiston moliya sektori uchun to'rt bosqichli AI risk menejment integratsion modeli taklif etiladi.

Kalit so'zlar: sun'iy intellekt, moliyaviy xavf, risk menejment, mashinali o'qitish, chuqur o'qitish, kredit riski, firibgarlik aniqlash, bozor riski, fintech, raqamli iqtisodiyot, XGBoost, LSTM, O'zbekiston.

Abstract: This article presents a comprehensive scientific-applied analysis of artificial intelligence (AI) technologies in identifying and managing financial risks. The effectiveness of machine learning, deep learning, and natural language processing (NLP) algorithms in detecting key financial risk categories — credit risk, market risk, fraud risk, and liquidity risk — is examined. Research findings indicate that AI-based risk systems achieve fraud detection accuracy of 95–99% and credit scoring accuracy of 88–96%, significantly outperforming traditional methods. A comparative analysis is conducted based on the experiences of JP Morgan, Visa, Mastercard, and central banks. A four-stage AI risk management integration model is proposed for Uzbekistan's financial sector.

Keywords: artificial intelligence, financial risk, risk management, machine learning, deep learning, credit risk, fraud detection, market risk, fintech, digital economy, XGBoost, LSTM, Uzbekistan.

Аннотация: В данной статье проведён комплексный научно-прикладной анализ технологий искусственного интеллекта (ИИ) в выявлении и управлении финансовыми рисками. Рассматривается эффективность алгоритмов машинного обучения, глубокого обучения и обработки естественного языка (NLP) в обнаружении ключевых категорий финансовых рисков: кредитного, рыночного, мошеннического и риска ликвидности. По результатам исследования, системы управления рисками на базе ИИ обеспечивают точность выявления мошенничества 95–99%, а кредитного скоринга — 88–96%, что существенно превышает показатели традиционных методов. Проведён сравнительный анализ на основе опыта JP Morgan, Visa, Mastercard и центральных банков. Для финансового сектора Узбекистана предложена четырёхэтапная модель интеграции ИИ в управление рисками.

Ключевые слова: искусственный интеллект, финансовый риск, управление рисками, машинное обучение, глубокое обучение, кредитный риск, обнаружение мошенничества, рыночный риск, финтех, цифровая экономика, XGBoost, LSTM, Узбекистан.

KIRISH

Zamonaviy global moliyaviy tizimning tobora ortib borayotgan murakkabligi, elektron to'lov infratuzilmasining kengayishi va moliyaviy ma'lumotlar hajmining eksponensial o'sishi an'anaviy risk menejment usullarining funksional imkoniyatlariga jiddiy talab qo'ymoqda. McKinsey Global Institute (2023) ma'lumotlariga ko'ra, har kuni jahon moliya bozorlarida 6 kvintillion baytdan ortiq ma'lumot ishlab chiqarilmoqda — bu hajm an'anaviy statistik usullar uchun qayta ishlash imkoniyatidan tashqariga chiqib ketadi. Biroq aynan shu sharoitda sun'iy intellekt (SI/AI) texnologiyalari moliyaviy xavflarni aniqlash va boshqarishda inqilobiy yechim sifatida namoyon bo'lmoqda.

Moliyaviy riskrini mashinali o'qitish orqali modellashtirish g'oyasi 2010-yillar boshidan kuchaya boshlagan. Khandani, Kim va Lo (2010) tomonidan iste'mol kredit risklarini ML algoritmlari yordamida modellashtirishga bag'ishlangan dastlabki fundamental tadqiqot mashinali o'qitishning moliyaviy sohadagi amaliy qo'llanilishiga ilmiy zamin yaratdi. Keyinchalik chuqur o'qitish (deep learning) va transformerga asoslangan modellarning rivojlanishi (Goodfellow et al., 2016; Vaswani et al., 2017) moliyaviy xavf modellashtirishni yangi bosqichga olib chiqdi.

Bugungi kunda AI asosidagi risk tizimlari global miqyosda jadal tarqalmoqda: Deloitte (2024) ma'lumotlariga ko'ra, yirik banklar va moliya institutlarining 76% dan ortig'i AI-ga asoslangan risk menejment vositalarini qo'llash bosqichida yoki allaqachon joriy etgan. O'zbekiston Respublikasida esa 2024-yilgi AI strategiyasi va «Raqqamli O'zbekiston — 2030» dasturi moliya sektorida AI texnologiyalarini kengaytirish uchun huquqiy va institutsional zamin yaratmoqda.

Tadqiqotning asosiy maqsadi: moliyaviy xavflarni aniqlash va boshqarishda qo'llaniladigan zamonaviy AI algoritmlarini tizimlashtirish, ularning samaradorligini an'anaviy usullar bilan qiyosiy tahlil qilish va O'zbekiston moliya sektori uchun kompleks tatbiq modelini ishlab chiqish.

Tadqiqot vazifalari: (1) moliyaviy xavf turlarini AI metodologiyasi prizmasidan tasniflash; (2) mashinali o'qitish va chuqur o'qitish algoritmlarining risk aniqlashdagi samaradorligini baholash; (3) global amaliyot tajribasini tahlil qilish; (4) O'zbekiston uchun bosqichli integratsiya modelini ishlab chiqish. Metodologik asos: tizimli tahlil, qiyosiy tahlil, adabiyotlar sharhi (SLR — Systematic Literature Review), empirik ma'lumotlar tahlili.

MOLIYAVIY XAVFLARNING TASNIFI VA AI METODOLOGIYASI

Moliyaviy xavf tushunchasi va zamonaviy tasnifi

Moliyaviy xavf — moliya institutlarining kutilmagan yo'qotishlarga duch kelishi ehtimoli. Basel III va Basel IV me'yoriy hujjatlari moliyaviy xavflarni kredit riski, bozor riski, operatsion risk va likvidlik riski asosiy to'rt kategoriyaga ajratadi. AI texnologiyalari bilan bog'liq kiberxavfni esa moliyaviy xavfning alohida tarkibiy qismi sifatida ko'rib chiqish zarurati tobora ortib bormoqda (BCBS, 2023). Ushbu tadqiqotda kiberxavf alohida oltinchi kategoriya sifatida tahlil qilinadi.

AI asosidagi risk menejmentning nazariy poydevori uchta asosiy paradigmaga tayanadi. Birinchisi — statistik o'rganish nazariyasi (Vapnik, 1995): mashinali o'qitish modellari misollar to'plami asosida umumlashgan qoidalarni avtomatik ravishda shakllantiradi, bu esa an'anaviy parametrik modellarning cheklangan umumlashtirish imkoniyatini bartaraf etadi. Ikkinchisi —

Bayes qaror nazariyasi: probabilistik modellar ma'lumotlardagi noaniqlikni eksplitsit tarzda hisobga oladi va risk baholashda ehtimollik bo'yicha taqsimlash imkonini beradi. Uchinchisi — representation learning: chuqur neyron tarmoqlar xom ma'lumotlardan yuqori darajali mavhum xususiyatlarni avtomatik o'rganadi, bu esa moliyaviy ma'lumotlar kabi murakkab, ko'p o'lchamli ma'lumotlar uchun ayniqsa qimmatlidir.

AI algoritmlarining moliyaviy xavf turlari bo'yicha tasnifi

Kredit riskini modellashtirish uchun eng keng tarqalgan yondashuvlar: gradient kuchaytirish (XGBoost, LightGBM, CatBoost) — strukturaviy moliyaviy ma'lumotlar uchun standart de-facto; logistik regressiya va regularizatsiya (Lasso, Ridge) — interpretatsiya talab qilinuvchi tartibga solish muhitlari uchun; Random Forest — nochiziqli bog'liqliklarni aniqlashda samarali. Firibgarlikni aniqlashda esa Izolatsiya o'rmoni (Isolation Forest) va Lokal anomaliya faktori (LOF) kabi anomaliya aniqlash usullari, LSTM (Long Short-Term Memory) neyron tarmoqlari va Graph Neural Networks (GNN) qo'llaniladi — ayniqsa murakkab moliyaviy firibgarlik sxemalarida ushbu texnologiyalar bir-birini to'ldiruvchi tizim sifatida ishlatiladi.

1-jadval. AI yordamida aniqlanadigan moliyaviy xavflar: turlar va algoritmlar

Xavf turi	AI usuli	Aniqlik darajasi	Amaliy misol
Kredit riski	Gradient Boosting, XGBoost	92–96%	FICO skoring tizimlarida
Firibgarlik riski	Anomaliya aniqlash, LSTM	97–99%	Visa/MasterCard fraud detection
Bozor riski	Transformerlar, LSTM	85–91%	JP Morgan LOXM tizimi
Likvidlik riski	Monte-Carlo ML simulyatsiyasi	88–93%	Markaziy banklar stress-testlari
Operatsion risk	NLP + Computer Vision	80–87%	Hujjat tekshiruvi avtomatizatsiyasi
Kiberxavf	Graph Neural Networks	94–98%	Real-vaqt tarmoq anomaliyalari

Manba: muallif tomonidan tuzilgan (Phua et al., 2010; Khandani et al., 2010; JP Morgan, 2023; Deloitte, 2024 asosida)

ADABIYOTLAR SHARHI

Moliyaviy xavflarni aniqlashda AI qo'llanilishiga oid adabiyotlar sharhi uchta asosiy yo'nalishda amalga oshirildi. Birinchi yo'nalish — kredit riski modellashtirishda mashinali o'qitish. Dumitrescu et al. (2022) o'z tadqiqotlarida XGBoost modelining an'anaviy logistik regressiya modeliga qaraganda kredit riskini aniqlashda AUC-ROC ko'rsatkichini 0.78 dan 0.91 gacha oshirganini ko'rsatdi. Luo et al. (2021) esa tranformerga asoslangan modellarning kredit skoring vazifalari uchun xronologik ma'lumotlarni qayta ishlashda LSTM modelidan 7–12% yuqori aniqlik berganini tasdiqladi.

Ikkinchi yo'nalish — firibgarlikni aniqlash. Phua et al. (2010) ning klassik sharhi firibgarlikni aniqlashda data mining usullarining asosiy qiyinchiliklarini — sinf nomutanosibligi, ma'lumotlar shovqini va dinamik moslashuvchanlik zaruratini — belgilab berdi. Zamonaviy tadqiqotlar (Van Belle et al., 2022) esa Graph Neural Networks asosidagi tizimlarda noto'g'ri ijobiy koeffitsientni 18% dan 3.2% gacha kamaytirish mumkinligini ko'rsatdi.

Uchinchi yo'nalish — izohlash mumkin bo'lgan AI (XAI) va tartibga solish. Broeders & Prenio (2018) tartibga solingan moliya sektorida AI modellarining «qora quti» muammosini qayd etdi: Basel IV talablari bo'yicha banklarning risk modellari tushuntiriladigan va auditlanadigan bo'lishi kerak. Kendjayeva (2024) ning oldingi tadqiqotida XAI usullarini moliyaviy tizimlar bilan integratsiyalashning konseptual asoslari yoritilgan bo'lib, SHAP metodining kredit riski modellashtirish amaliyotida qo'llanilishi tahlil qilingan.

Adabiyotlar sharhining asosiy xulosasi: zamonaviy AI algoritmlarining moliyaviy xavflarni aniqlashdagi texnik imkoniyatlari yuqori bo'lsa-da, uchta muammo hali to'liq hal etilmagan: (1) tartibga solingan muhitda AI modellarining izohlash imkoniyati; (2) AI risk tizimlarini yaratish uchun sifatli, etiketlangan ma'lumotlar yetishmasligi; (3) ma'lumotlar driftiga (data drift) barqaror modellar ishlab chiqish. Ushbu maqola ushbu bo'shliqlarni O'zbekiston kontekstida to'ldirish maqsadini ko'zlaydi.

METODOLOGIYA

Ushbu tadqiqotda kombinatsiyalashgan metodologik yondashuv qo'llanildi. Birinchi bosqich — tizimli adabiyotlar sharhi (SLR): Scopus, Web of Science va IEEE Xplore bazalarida 2018–2024 yillar oralig'ida chop etilgan 95 dan ortiq maqola o'rganildi; skrining mezonlari: asosiy mavzu — AI va moliyaviy risk; tillar: ingliz, rus, o'zbek; chiqarib tashlash: maqola emasligi (konferensiya tezislari, bloglar).

Ikkinchi bosqich — qiyosiy tahlil: AI asosidagi va an'anaviy risk boshqaruvi tizimlari 7 mezon bo'yicha solishtirildiki, bu mezonlar Basel IV talablariga mos holda tanlandi. Uchinchi bosqich — amaliyot tadqiqotlari (case studies): JP Morgan Chase, Visa, Mastercard, Markaziy banklar va O'zbekiston tijorat banklari tajribasi o'rganildi. To'rtinchi bosqich — konseptual modellashtirish: O'zbekiston moliya sektori uchun bosqichli tatbiq modeli ishlab chiqildi va ekspert bahosi asosida tekshirildi.

TADQIQOT NATIJALARI VA MUHOKAMA

AI va an'anaviy risk tizimlarining qiyosiy tahlili

Tadqiqot natijalari AI asosidagi risk tizimlarining an'anaviy uslublarga nisbatan bir qator muhim ustunliklarini tasdiqlamoqda. Qiyosiy tahlil 7 ta asosiy mezon bo'yicha amalga oshirildi va 2-jadvalda aks ettirilgan.

2-jadval. AI asosidagi va an'anaviy risk tizimlarining qiyosiy tahlili

Mezon	An'anaviy usullar	AI asosidagi tizimlar	Farq (delta)
Xavfni aniqlash tezligi	Soatlar / kunlar	Millisekundlar	~10 000x tez
Firibgarlikni aniqlash aniqligi	60–70%	95–99%	+25–35 p.p.
Kredit skoring aniqligi	70–75%	88–96%	+15–21 p.p.
Noto'g'ri musbat (False Positive)	15–20%	2–5%	–10–15 p.p.
Operatsion xarajatlar	Bazaviy	35–50% kam	Sezilarli tejash
Ma'lumot qamrovi	Cheklangan (strukturaviy)	Keng (strukturasisiz ham)	Ko'p manbali

Masshtablilik	Past	Yuqori (cloud-native)	Global miqyos
----------------------	------	-----------------------	---------------

Manba: muallif tomonidan tuzilgan (Deloitte, 2024; McKinsey, 2023; BCBS, 2023 ma'lumotlari asosida)

Global amaliyot tajribasi: yetakchi misollar

JP Morgan Chase LOXM tizimi: JP Morgan 2017-yildan boshlab LOXM (Learning-based Optimization for eXecution Management) deb ataladigan chuqur o'qitishga asoslangan algoritmik savdo va risk monitoring tizimidan foydalanmoqda. Tizim bozor riskini real vaqt rejimida baholab, pozitsiya hajmini avtomatik sozlaydi. Kompaniyaning 2023-yilgi yillik hisobotiga ko'ra, LOXM qo'llanilishi portfel risk-tuzatilgan daromadini 18% oshirdi va market impact ni 23% kamaytirdi.

Visa Real-Time Fraud Detection: Visa kompaniyasining AI asosidagi firibgarlikni aniqlash tizimi sekundiga 65 000 dan ortiq tranzaksiyani real vaqtda tahlil qiladi. 2023-yilgi ma'lumotlarga ko'ra, tizim firibgarlik yo'qotishlarini 40% ga kamaytirdi — bu yiliga taxminan 25 mlrd AQSh dollariga teng. Tizim millisekundlar ichida 500 dan ortiq xususiyatni (feature) hisobga oladi va adaptiv neyron tarmoq arxitekturasidan foydalanadi.

Markaziy banklar va stress-testlar: Yevropadagi bir qator markaziy banklar (Germaniya Bundesbank, Niderlandiya DNB) ML asosidagi stress-test simulyatsiya tizimlarini joriy etgan. Bunday tizimlar Monte-Carlo ML simulyatsiyasini an'anaviy deterministic stress-test bilan birlashtiradi va likvidlik inqirozlarini 87% aniqlik bilan oldindan bashorat qila oladi.

O'zbekiston banklaridagi hozirgi holat: O'zbekiston Respublikasi Markaziy banki 2021-yildan boshlab bank nazoratida raqamli platformalarni kengaytirmoqda. Asaka bank, Ipak Yo'li bank va Xalq banki kabi yirik tijorat banklar avtomatlashtirilgan kredit baholash tizimlarini test rejimida ishlatmoqda. Biroq to'liq AI asosidagi, izohlash mumkin bo'lgan (XAI-compliant) risk tizimlariga o'tish hali amalga oshmagan.

O'zbekiston uchun tatbiq modeli: to'rt bosqichli yondashuv

Adabiyotlar sharhi, qiyosiy tahlil va O'zbekiston moliya sektorining hozirgi holati tahlili asosida to'rt bosqichli integratsion model taklif etilmoqda. Model «Raqamli O'zbekiston — 2030» strategiyasining ustuvor yo'nalishlari va 2024-yilgi AI Strategiyasining talablariga to'liq muvofiqdir.

3-jadval. O'zbekiston moliya sektori uchun AI risk menejment integratsion modeli

Bosqich	Muddat	Asosiy faoliyat	Kutilgan natija
1 — Pilot	2025–2026	Fraud detection, kredit skoring (3–5 bank)	Asos texnologiyasi ishga tushiriladi
2 — Kengaytirish	2026–2027	Bozor & likvidlik riski, RegTech integratsiyasi	AI risk tizimi barcha tijorat banklarida
3 — Ekosistema	2027–2028	Fintech platformalari, CBDC risk menejmenti	Milliy AI risk ekosistemasini yaratiladi
4 — Innovatsiya	2028–2030	XAI, Federated Learning, real-vaqt boshqaruvi	Mintaqaviy yetakchi darajasiga erishiladi

Manba: muallif tomonidan ishlab chiqilgan (Prezident PF-6079, 2020; IIII-358, 2024 asosida)

AI joriy etishning asosiy to'siqlari va yechimlar

Tadqiqot AI asosidagi risk tizimlarini joriy etishda quyidagi asosiy to'siqlarni aniqladi: (1) Ma'lumotlar sifati va yetishmovchiligi: O'zbekiston moliya bozorida etiketlangan tarixiy ma'lumotlar hajmi yirik global banklar ma'lumotlariga qaraganda 5–10 marta kam. Yechim: synthetic data augmentation va transfer learning texnikalari; (2) Texnologik infratuzilma: hozirgi banklarning IT infratuzilmasi real-vaqt AI inferencesi uchun etarlicha optimallashtirmagan. Yechim: cloud-native arxitekturalarga bosqichma-bosqich o'tish; (3) Kadrlar taqchilligi: O'zbekistonda ML muhandisligi va risk modellashtirishni birlashtiradigan interdisiplinar mutaxassislar yetishmasligi jiddiy muammodir. Yechim: oliy ta'lim muassasalari va moliya institutlari hamkorligi asosida maxsus o'quv dasturlari; (4) Tartibga solinish noaniqligi: AI risk modellarining bank nazoratchilik talablariga muvofiqligini ta'minlash uchun Markaziy bank tomonidan alohida regulyatsiyon ko'rsatmalar zarur.

MUHOKAMA

Tadqiqot natijalarini mavjud adabiyotlar bilan qiyoslash bir qator muhim kuzatuvlarni ko'rsatdi. Birinchidan, AI risk tizimlarining texnik samaradorligi haqida mavjud adabiyot bilan to'liq mos keladi: ushbu tadqiqot ham firibgarlikni aniqlash aniqligining 95–99% va kredit skoring aniqligining 88–96% darajasida ekanligini tasdiqlaydi. Bu ko'rsatkichlar Dumitrescu et al. (2022) va Van Belle et al. (2022) empirik xulosalariga mos keladi.

Ikkinchidan, O'zbekiston kontekstidagi o'ziga xoslik: global amaliyotda AI risk tizimlarini joriy etishdagi asosiy to'siq — ma'lumotlar yetishmovchiligi — O'zbekistonda ayniqsa o'tkir. Bu holat ta'lim, amaliyot va regulyatsiyon strategiyasini bir vaqtda shakllantirishni talab qiladi. Uchinchidan, izohlash imkoniyati (explainability) — Basel IV va O'zbekiston bank nazorati talablari uchun kritik. XAI usullari (SHAP, LIME) nafaqat texnik, balki huquqiy muvofiqliklni (regulatory compliance) ta'minlash vositasi sifatida ko'rib chiqilishi zarur (Kendjayeva, 2024).

Metodologik cheklov sifatida shuni ta'kidlash lozimki, ushbu tadqiqot asosan ikkilamchi manbalar tahlili (adabiyotlar sharhi va global amaliyot) asosida qurilgan. O'zbekiston banklarida birlamchi eksperimental tadqiqot o'tkazish kelajak tadqiqotlar uchun muhim yo'nalish bo'lib qolmoqda.

XULOSA

Ushbu tadqiqot sun'iy intellekt texnologiyalarining moliyaviy xavflarni aniqlash va boshqarishdagi imkoniyatlari hamda O'zbekiston moliya sektori uchun tatbiq perspektivalari bo'yicha quyidagi asosiy xulosalarni berdi:

1. AI asosidagi risk tizimlari an'anaviy uslublarga nisbatan sezilarli ustunlikka ega: firibgarlikni aniqlash aniqligini 95–99%, kredit skoringni 88–96% darajasiga yetkazadi va xavfni aniqlash tezligini ~10 000 marta oshiradi — bu global moliya institutlari tajribasi bilan tasdiqlangan.

2. Har bir moliyaviy xavf turi o'ziga xos AI algoritm arxitekturasini talab qiladi: kredit riski uchun gradient kuchaytirish (XGBoost, LightGBM), firibgarlik uchun GNN va anomaliya aniqlash, bozor riski uchun LSTM va transformerlar optimal hisoblanadi.

3. O'zbekiston moliya sektori uchun taklif etilgan to'rt bosqichli tatbiq modeli (pilot → kengaytirish → ekosistema → innovatsiya, 2025–2030) mamlakatning AI strategiyasi va «Raqamli O'zbekiston — 2030» dasturi bilan to'liq muvofiqlashtirilgan.

4. Muvaffaqiyatli integratsiya uchun uchta shart bir vaqtda bajarilishi zarur: sifatli ma'lumotlar infratuzilmasi, izohlash mumkin bo'lgan AI (XAI) talablariga javob beradigan modellar va bank nazoratchilik tomonidan moslashtirilgan regulyatsiyon doira.

Kelajak tadqiqotlar yo'nalishlari: O'zbekiston banklarida AI kredit skoring modelining pilot sinovini o'tkazish; federatsiyalashgan o'qitish (Federated Learning) asosida banklar o'rtasida

ma'lumot almashmasdan umumiy risk modeli yaratish; izohlash mumkin bo'lgan AI usullarini O'zbekiston bank nazoratiga moslashtirishning amaliy yo'llanmasini ishlab chiqish.

FOYDALANILGAN ADABIYOTLAR

1. Basel Committee on Banking Supervision (BCBS). (2023). Principles for the Sound Management of Operational Risk and the Role of Supervision. Bank for International Settlements. <https://www.bis.org/publ/bcbs195.pdf>
2. Broeders, D., & Prenio, J. (2018). Innovative technology in financial supervision (suptech): The experience of early users. FSI Insights on Policy Implementation, No. 9. Financial Stability Institute, BIS.
3. Deloitte. (2024). AI and Risk Management in Financial Services: Global Survey Report 2024. Deloitte Insights. <https://www2.deloitte.com/global/en/insights/industry/financial-services.html>
4. Dumitrescu, E., Hué, S., Hurlin, C., & Tokpavi, S. (2022). Machine learning for credit scoring: Improving logistic regression with non-linear decision-tree effects. European Journal of Operational Research, 297(3), 1178–1192. <https://doi.org/10.1016/j.ejor.2021.06.053>
5. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press. <https://www.deeplearningbook.org>
6. JP Morgan Chase. (2023). Annual Report 2023: Technology and Innovation in Risk Management. New York: JPMorgan Chase & Co.
7. Kendjayeva, D. Kh. (2023). Rol' iskusstvennogo intellekta v povyshenii effektivnosti ekonomicheskikh protsessov [Роль искусственного интеллекта в повышении эффективности экономических процессов]. Toshkent amaliy fanlar universiteti ilmiy-amaliy anjumani materiallari. Toshkent: TATU. [Google Scholar: scholar.google.com/citations?user=c0FaPIIAAAAJ]
8. Kendjayeva, D. Kh. (2024). Ob'yasnimyy iskusstvennyy intellekt (XAI): Obespechenie prozrachnosti i doveriya pol'zovateley v obrazovatel'nykh resheniyakh — kontseptual'naya model' [Объяснимый искусственный интеллект (XAI): обеспечение прозрачности и доверия пользователей в образовательных решениях — концептуальная модель]. Toshkent amaliy fanlar universiteti. [ORCID: 0000-0002-4337-3080]
9. Khandani, A. E., Kim, A. J., & Lo, A. W. (2010). Consumer credit-risk models via machine-learning algorithms. Journal of Banking & Finance, 34(11), 2767–2787. <https://doi.org/10.1016/j.jbankfin.2010.06.001>
10. Luo, C., Wu, D., & Wu, D. (2021). A deep learning approach for credit scoring using credit default swaps. Engineering Applications of Artificial Intelligence, 65, 465–470. <https://doi.org/10.1016/j.engappai.2016.12.002>
11. McKinsey Global Institute. (2023). The Economic Potential of Generative AI: The Next Productivity Frontier. McKinsey & Company. <https://www.mckinsey.com/capabilities/mckinsey-digital/our-insights>
12. Phua, C., Lee, V., Smith, K., & Gayler, R. (2010). A comprehensive survey of data mining-based fraud detection research. arXiv:1009.6119. <https://arxiv.org/abs/1009.6119>
13. Prezident Respubliki Uzbekistan. (2020). Ukaz № PF-6079 «Ob utverzhdenii strategii Tsifrovoy Uzbekistan – 2030» [Указ Президента Республики Узбекистан № УП-6079 от 5 октября 2020 г. «Об утверждении стратегии Цифровой Узбекистан – 2030»]. <https://lex.uz/docs/5031048>
14. Prezident Respubliki Uzbekistan. (2024). Postanovlenie № PP-358 «Ob utverzhdenii Strategii razvitiya tekhnologii iskusstvennogo intellekta do 2030 goda» [Постановление Президента Республики Узбекистан № ПП-358 от 14 октября 2024 г.]. <https://lex.uz/ru/docs/7158606>

- 
15. Russell, S., & Norvig, P. (2021). Artificial Intelligence: A Modern Approach (4th ed.). Pearson Education.
 16. Van Belle, V., Pelsmaekers, K., Suykens, J. A. K., & Van Gestel, T. (2022). Explainability in credit risk management. *Expert Systems with Applications*, 195, 116634. <https://doi.org/10.1016/j.eswa.2022.116634>
 17. Vapnik, V. N. (1995). *The Nature of Statistical Learning Theory*. Springer. <https://doi.org/10.1007/978-1-4757-3264-1>