

MUHANDISLIK

& IQTISODIYOT

ijtimoiy-iqtisodiy, innovatsion texnik,
fan va ta'limga oid ilmiy-amaliy jurnal

№6

2025
IYUN



Milliy nashrlar

OAK: <https://oak.uz/pages/4802>

05.00.00 – Texnika fanlari

08.00.00 – Iqtisodiyot fanlar



Google
Scholar

OPEN ACCESS

ULRICHSWEB™
GLOBAL SERIALS DIRECTORY

Academic
Resource
Index
ResearchBib

ISSN
INTERNATIONAL
STANDARD
SERIAL
NUMBER
INTERNATIONAL CENTRE

CYBERLENINKA

OpenAIRE

ROAD

INDEX
COPERNICUS
INTERNATIONAL

BASE

Crossref

НАУЧНАЯ ЭЛЕКТРОННАЯ
БИБЛИОТЕКА
LIBRARY.RU



РЭУ.РФ
РОССИЙСКИЙ ЭКОНОМИЧЕСКИЙ УНИВЕРСИТЕТ
ИМЕНИ Г.В. ПЛЕХАНОВА
ТАШКЕНТСКИЙ ФИЛИАЛ



muhandislik & iqtisodiyot

ijtimoiy-iqtisodiy, innovatsion texnik,
fan va ta'limga oid ilmiy-amaliy jurnal

Elektron nashr,
210 sahifa, iyun, 2025-yil.

Bosh muharrir:

Zokirova Nodira Kalandarovna, iqtisodiyot fanlari doktori, DSc, professor

Bosh muharrir o'rinbosari:

Shakarov Zafar G'afarovich, iqtisodiyot fanlari bo'yicha falsafa doktori, PhD, dotsent

Tahrir hay'ati:

Abduraxmanov Kalendar Xodjayevich, O'z FA akademigi, iqtisodiyot fanlari doktori, professor

Sharipov Kongratbay Avezimbetovich, texnika fanlari doktori, professor

Maxkamov Baxtiyor Shuxratovich, iqtisodiyot fanlari doktori, professor

Abduraxmanova Gulnora Kalandarovna, iqtisodiyot fanlari doktori, professor

Shaumarov Said Sanatovich, texnika fanlari doktori, professor

Turayev Bahodir Xatamovich, iqtisodiyot fanlari doktori, professor

Nasimov Dilmurod Abdulloyevich, iqtisodiyot fanlari doktori, professor

Allayeva Gulchexra Jalgasovna, iqtisodiyot fanlari doktori, professor

Arabov Nurali Uralovich, iqtisodiyot fanlari doktori, professor

Maxmudov Odiljon Xolmirzayevich, iqtisodiyot fanlari doktori, professor

Xamrayeva Sayyora Nasimovna, iqtisodiyot fanlari doktori, professor

Bobonazarova Jamila Xolmurodovna, iqtisodiyot fanlari doktori, professor

Irmatova Aziza Baxromovna, iqtisodiyot fanlari doktori, professor

Bo'taboyev Mahammadjon To'ychiyevich, iqtisodiyot fanlari doktori, professor

Shamshiyeva Nargizaxon Nosirxuja kizi, iqtisodiyot fanlari doktori, professor,

Xolmuxamedov Muhsinjon Murodullayevich, iqtisodiyot fanlari nomzodi, dotsent

Xodjayeva Nodiraxon Abdurashidovna, iqtisodiyot fanlari nomzodi, dotsent

Amanov Otabek Amankulovich, iqtisodiyot fanlari bo'yicha falsafa doktori (PhD), dotsent

Toxirov Jaloliddin Ochil o'g'li, texnika fanlari bo'yicha falsafa doktori (PhD)

Qurbonov Samandar Pulatovich, iqtisodiyot fanlari bo'yicha falsafa doktori (PhD)

Zikriyoyev Aziz Sadulloyevich, iqtisodiyot fanlari bo'yicha falsafa doktori (PhD)

Tabayev Azamat Zaripbayevich, iqtisodiyot fanlari bo'yicha falsafa doktori (PhD)

Sxay Lana Aleksandrovna, iqtisodiyot fanlari bo'yicha falsafa doktori (PhD), dotsent

Ismoilova Gulnora Fayzullayevna, iqtisodiyot fanlari nomzodi, dotsent

Djumaniyazov Umrbek Ilxamovich, iqtisodiyot fanlari nomzodi, dotsent

Kasimova Nargiza Sabitdjanovna, iqtisodiyot fanlari nomzodi, dotsent

Kalanova Moxigul Baxritdinovna, dotsent

Ashurzoda Luiza Muxtarovna, iqtisodiyot fanlari bo'yicha falsafa doktori (PhD)

Sharipov Sardor Begmaxmat o'g'li, iqtisodiyot fanlari bo'yicha falsafa doktori (PhD)

Sharipov Botirali Roxataliyevich, iqtisodiyot fanlari nomzodi, professor

Tursunov Ulug'bek Sativoldiyevich, iqtisodiyot fanlari doktori (DSc), dotsent

Bauyetdinov Majit Janizaqovich, Toshkent davlat iqtisodiyot universiteti dotsenti, PhD

Botirov Bozorbek Musurmon o'g'li, Texnika fanlari bo'yicha falsafa doktori (PhD)

Sultonov Shavkatjon Abdullayevich, Kimyo fanlari doktori, (DSc)

Jo'raeva Malohat Muhammadovna, filologiya fanlari doktori (DSc), professor.



muhandislik & iqtisodiyot

ijtimoiy-iqtisodiy, innovatsion texnik,
fan va ta'limga oid ilmiy-amaliy jurnal

- 05.01.00 – Axborot texnologiyalari, boshqaruv va kompyuter grafikasi
- 05.01.01 – Muhandislik geometriyasi va kompyuter grafikasi. Audio va video texnologiyalari
- 05.01.02 – Tizimli tahlil, boshqaruv va axborotni qayta ishlash
- 05.01.03 – Informatikaning nazariy asoslari
- 05.01.04 – Hisoblash mashinalari, majmualari va kompyuter tarmoqlarining matematik va dasturiy ta'minoti
- 05.01.05 – Axborotlarni himoyalash usullari va tizimlari. Axborot xavfsizligi
- 05.01.06 – Hisoblash texnikasi va boshqaruv tizimlarining elementlari va qurilmalari
- 05.01.07 – Matematik modellash
- 05.01.11 – Raqamli texnologiyalar va sun'iy intellekt
- 05.02.00 – Mashinasozlik va mashinashunoslik
- 05.02.08 – Yer usti majmualari va uchish apparatlari
- 05.03.02 – Metrologiya va metrologiya ta'minoti
- 05.04.01 – Telekommunikatsiya va kompyuter tizimlari, telekommunikatsiya tarmoqlari va qurilmalari. Axborotlarni taqsimlash
- 05.05.03 – Yorug'lik texnikasi. Maxsus yoritish texnologiyasi
- 05.05.05 – Issiqlik texnikasining nazariy asoslari
- 05.05.06 – Qayta tiklanadigan energiya turlari asosidagi energiya qurilmalari
- 05.06.01 – To'qimachilik va yengil sanoat ishlab chiqarishlari materialshunosligi

- 05.08.03 – Temir yo'l transportini ishlatish
- 05.09.01 – Qurilish konstruksiyalari, bino va inshootlar
- 05.09.04 – Suv ta'minoti. Kanalizatsiya. Suv havzalarini muhofazalovchi qurilish tizimlari
- 10.00.06 – Qiyosiy adabiyotshunoslik, chog'ishtirma tilshunoslik va tarjimashunoslik
- 10.00.04 – Yevropa, Amerika va Avstraliya xalqlari tili va adabiyoti
- 08.00.01 – Iqtisodiyot nazariyasi
- 08.00.02 – Makroiqtisodiyot
- 08.00.03 – Sanoat iqtisodiyoti
- 08.00.04 – Qishloq xo'jaligi iqtisodiyoti
- 08.00.05 – Xizmat ko'rsatish tarmoqlari iqtisodiyoti
- 08.00.06 – Ekonometrika va statistika
- 08.00.07 – Moliya, pul muomalasi va kredit
- 08.00.08 – Buxgalteriya hisobi, iqtisodiy tahlil va audit
- 08.00.09 – Jahon iqtisodiyoti
- 08.00.10 – Demografiya. Mehnat iqtisodiyoti
- 08.00.11 – Marketing
- 08.00.12 – Mintaqaviy iqtisodiyot
- 08.00.13 – Menejment
- 08.00.14 – Iqtisodiyotda axborot tizimlari va texnologiyalari
- 08.00.15 – Tadbirkorlik va kichik biznes iqtisodiyoti
- 08.00.16 – Raqamli iqtisodiyot va xalqaro raqamli integratsiya
- 08.00.17 – Turizm va mehmonxona faoliyati

Ma'lumot uchun, OAK
Rayosatining 2024-yil 28-avgustdagi 360/5-son qarori bilan "Dissertatsiyalar asosiy ilmiy natijalarini chop etishga tavsiya etilgan milliy ilmiy nashrlar ro'yxati"ga texnika va iqtisodiyot fanlari bo'yicha "Muhandislik va iqtisodiyot" jurnali ro'yxatga kiritilgan.

Muassis: "Tadbirkor va ishbilarmon" MChJ

Hamkorlarimiz:

1. Toshkent shahridagi G.V.Plexanov nomidagi Rossiya iqtisodiyot universiteti
2. Toshkent davlat iqtisodiyot universiteti
3. Toshkent irrigatsiya va qishloq xo'jaligini mexanizatsiyalash muhandislari instituti" milliy tadqiqot universiteti
4. Islom Karimov nomidagi Toshkent davlat texnika universiteti
5. Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti
6. Toshkent davlat transport universiteti
7. Toshkent arxitektura-qurilish universiteti
8. Toshkent kimyo-texnologiya universiteti
9. Jizzax politexnika instituti



MUNDARIJA

Ways to Strengthen the Economy of Karakalpakstan	12
Isakov Janabay Yakypbayevich	
Sanoat korxonalarida ishlab chiqarish xavf-xatarlarini iqtisodiy baholash.....	18
Raxmatova M.G., Saidjonova Z.B	
Strategy For Attracting Investments By Expanding the Participation of Joint-Stock Companies in the Securities Market	23
Aytmuratova Ulbike Jalgasovna, Kutlymurat Zhalgasovich Aytmuratov, Raushan Nurlybay qizi Umirzakova	
O'zbekistonda eksportni sug'urtalash mexanizmlari: mavjud holat va takomillashtirish yo'llari	29
D.E.Qarshiev	
Ta'lim, ekologiya va raqamlashtirish sohalarida bolalar va o'smirlar turizmini integratsiyalash: xalqaro tajribalar va O'zbekiston	35
Islomova Dilrabo Salomovna	
Oliy ta'lim muassasalarida xodimlarning mehnat samaradorligini oshirishda rahbarlarning roli	40
Reyimberdiyev Baburbek Adilbek o'g'li, Yusupov Sherzodbek Baxtiyor o'gli, Xaitbayev Jasurbek Otaxanovich, Madraimov Xabibulla Madaminovich	
Обзор по теме Современные системы управлением возбуждение синхронных машин и перспективы их развития	47
Алиев Абдор Мураткулович	
The Mechanism for Applying Tax Benefits and Preferences in Tax Administration	52
Dilorom Mutalova	
Innovatsiyalarning ahamiyati va ularning iqtisodiy samaradorligining o'zbekiston qishloq xo'jalik mahsulotlarini qayta ishlashdagi roli	57
Raximov Baxromjon Ibroximovich, Solohiddinov Nuriddin Sirojiddin o'g'li	
Bino va inshootlarni zilzilabardoshligiga oid nazariyalar.....	62
Jalilov Ahmadbek Ikromjon o'g'li	
Soliq to'lovchilarning majburiyatlari bajarilishini konseptual asoslari va shartlari asoslari xususida	66
Abdusherzov Abdullo Baxtiyorovich	
The Analysis of the Psychophysiological Condition of Children With Mental Disorders and the Creation of Comfort Through Designed Clothing	73
Asatilaeva Lola Muratjon qizi, Muminova Umida Tokhtasinovna	
Analysis Types of Waterproof Fabrics and Their Physical and Mechanical Properties	80
Pulatova Laziza Bakhodirovna, Kasimova Aziza Bakhodirovna	
Kichik biznes subyektlarining eksport salohiyatidan foydalanish darajasi va uni oshirish omillari	85
Umarkulov Kodirjon Maxamadaminovich, To'xtasinov Boburbek Yusufjon o'g'li	
Suv resurslarini boshqarishda zamonaviy texnologiyalar:qishloq xo'jaligi uchun iims modelini ishlab chiqish.....	89
Fazilat Egamberganova Shuhratovna	
Raqamli texnologiyalar yordamida kitobxonlik madaniyatini rivojlantirish	93
Ernaqulov Sunnatillo Nurali o'g'li	
Qurilish sanoati korxonalarini boshqarishning iqtisodiy mexanizmlari	98
Yembergenova Aynur Aydosbaevna	
Mahalliy budjetlar ijrosi to'g'risidagi hisobotlar va ularning axborot imkoniyatlarini oshirish masalalari	104
Abdulaziz Norquchqorov Ziyadullayevich	
Sirdaryo viloyatida investitsion faollikni oshirishda davlat va xususiy sektor hamkorligi	110
Mamatqulova Muxlisa Komiljon qizi	



Kichik biznes subyektlarining eksport salohiyatidan foydalanish darajasi va uni oshirish omillari	115
Umarkulov, Kodirjon Maxamadaminovich, To'xtasinov Boburbek Yusufjon o'g'li	
Soliq to'lovchilarning majburiyatlari bajarilishini ta'minlashning gnoseologik asoslari xususida	118
Abdusherozov Abdullo Baxtiyorovich	
Nodavlat oliy ta'lim tashkilotlari faoliyatini tashkil etishning tashkiliy-huquqiy jihatlari	125
Yaqubova Nodira Olim qizi	
O'zbekistonda to'qimachilik eko-mahsulotlari bozorining rivojlanish imkoniyatlari	130
Nosirova Charos	
Uy-joy fondini boshqarish samaradorligini oshirishda zamonaviy sifat menejmenti tizimining o'rni	135
Asadullina Nailya Ramilevna, Normurodov Sarvar Norboy o'g'li	
Axoli daromadlarining turmush farovonligiga ta'siri	142
Berdibekov A.	
Raqamli iqtisodiyot sharoitda ta'lim xizmati sifatini oshirishni ekonometrik modellashtirish usullari	148
Axmedova Barno Abdiyevna	
Jahon mamlakatlarida chakana savdoni boshqarishning o'ziga xosligi va unda strategik menejment tizimi	151
Yaqubov Azizbek G'anibekovich	
Kichik tadbirkorlik faoliyatining rivojlanish tendensiyalari	156
Amonov Mehridin Oromiddinovich	
Geologiya korxonalarining investitsion samaradorligini oshirish yo'llari	163
O'tamurodova Surayyo SHokirjon qizi	
Temir yo'l transportini rivojlantirishdagi xorij tajribasi	169
Nasrullayev Nurbek Baxtiyarovich	
Hududlar iqtisodiyoti agrar sektori investitsion faolligining ko'rsatkichlar tizimi va ularning xususiyatlari	174
S.J. Yangiboev	
Hududlarning soliq salohiyatini oshirishdagi mavjud muammolar va ularning yechimlari	181
Sharipov Narzullo G'ulomovich	
Uzoq muddatli aktivlar auditining tashkiliy va uslubiy jihatlarini takomillashtirish	188
Bakayev Xurshid Maxmudovich	
Применение искусственного интеллекта в оценке кредитных рисков.....	195
Маликов Шохрух Шокирович, Неъматова Фарангиз Санжар кизи, Омонов Санжар Ғанишер ўғли, Гулмуродова Динора Акрам кизи, Камалов Шухрат Камалович	



ПРИМЕНЕНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ОЦЕНКЕ КРЕДИТНЫХ РИСКОВ

Маликов Шохрух Шокирович

Студент, факультет цифровой экономики и информационных технологий
Специальность: цифровая экономика
Ташкентский государственный экономический университет,
г. Ташкент, Узбекистан

ORCID: <https://orcid.org/0009-0000-7813-068X>

Неъматова Фарангиз Санжар кизи

Студент, факультет цифровой экономики и информационных технологий
Специальность: цифровая экономика
Ташкентский государственный экономический университет,
г. Ташкент, Узбекистан

ORCID: <https://orcid.org/0009-0007-3465-6402>

Омонов Санжар Ғанишер ўғли

ассистент кафедры «Искусственный интеллект»
Ташкентский государственный экономический университет,
г. Ташкент, Узбекистан

Гулмуродова Динора Акрам кизи

Ассистент кафедры «Искусственный интеллект»
Ташкентский государственный экономический университет, г. Ташкент, Узбекистан

ORCID: <https://orcid.org/0009-0009-4155-3190>

Научный руководитель: Камалов Шухрат Камалович

доцент кафедры искусственного интеллекта
Ташкентский государственный экономический университет,
г. Ташкент, Узбекистан

ORCID: <https://orcid.org/0000-0002-2595-9344>

Annotatsiya: Moliyaviy tizim raqamlashtirilayotgan hozirgi davrda kredit xavfini aniq va shaffof baholash vazifasi banklar va nazorat organlari uchun ustuvor yo'nalishga aylanmoqda. Ushbu tadqiqotda O'zbekiston Respublikasi bo'yicha agregat makroiqtisodiy va bank ko'rsatkichlari asosida kredit xavfining darajasini (yuqori/past) prognoz qilish metodikasi taklif etiladi. Modelni yaratishda mashinaviy o'qitish algoritmlari — xususan, logistik regressiya va gradient busterlash qo'llanilgan. Natijalarning tushunarli bo'lishiga alohida e'tibor qaratilib, asosiy omillarning ta'sirini aniqlashda SHAP tahlili (Explainable AI doirasida) tatbiq etilgan. Taklif etilgan model yuqori tasniflash samaradorligini ko'rsatib, tizimli xavflarni monitoring qilish va dastlabki baholash vositasi sifatida foydalanish mumkin. Bu yondashuv makroprudensial tartibga solish sohasida boshqaruv qarorlarini qo'llab-quvvatlash uchun samarali vosita bo'la oladi.

Kalit so'zlar: sun'iy intellekt, kredit xavfi, SHAP tahlili, bank tizimi, yig'ma ma'lumotlar, logistik regressiya, gradient busterlash, ROC-AUC, modelni tushuntirish, O'zbekiston.

Abstract: In the era of financial sector digitalization, accurate and transparent credit risk assessment is becoming a top priority for banks and regulatory bodies. This study proposes a methodology for predicting the level of credit risk (high/low) using aggregated macroeconomic and banking indicators from the Republic of Uzbekistan. The model was developed using machine learning algorithms — specifically, logistic regression and gradient boosting. Emphasis is placed on the interpretability of the results via Explainable AI, particularly through SHAP analysis to identify the impact of key features. The proposed model shows high classification performance and can serve as a tool for systemic risk monitoring and preliminary assessment. This approach can effectively support decision-making in macroprudential regulation.

Keywords: artificial intelligence, credit risk, SHAP analysis, banking system, aggregated data, logistic regression, gradient boosting, ROC-AUC, model interpretability, Uzbekistan.

Аннотация: В условиях цифровизации финансовой сферы задача точной и прозрачной оценки кредитных рисков становится приоритетной для банков и регулирующих органов. В данной работе представлена методика прогнозирования уровня кредитного риска (высокий/низкий) на основе агрегированных макроэкономических и банковских данных Республики Узбекистан. Для построения модели использовались алгоритмы машинного обучения — в частности, логистическая регрессия и градиентный бустинг. Особое внимание уделено интерпретируемости результатов с помощью Explainable AI, в частности, проведён SHAP-анализ для определения вклада ключевых признаков. Разработанная модель демонстрирует высокие показатели классификации и может использоваться как инструмент предварительного анализа и мониторинга рисков на системном уровне. Она также может служить основой для поддержки управленческих решений в сфере макропруденциального регулирования.

Ключевые слова: искусственный интеллект, кредитный риск, SHAP-анализ, банковская система, агрегированные данные, логистическая регрессия, градиентный бустинг, ROC-AUC, интерпретируемость модели, Узбекистан.

ВВЕДЕНИЕ

В современных условиях банки и регуляторы сталкиваются с беспрецедентным вызовом — необходимостью оперативного выявления нарастания кредитного риска в ответ на внешние шоки, такие как пандемия COVID-19 в 2020–2023 годах и резкий рост глобальной инфляции. Эти явления привели к ухудшению платежной дисциплины предприятий и населения, а также усилили волатильность валютных курсов, что, в свою очередь, повысило вероятность накопления просроченной задолженности на уровне банковского портфеля [1].

Традиционные модели оценки вероятности дефолта (PD-модели) основаны на детализированных данных о каждом заёмщике и применяются преимущественно внутри кредитных организаций. Они демонстрируют высокую точность при наличии качественных микроданных, однако их воспроизводимость и масштабируемость ограничены закрытым доступом к внутренним базам банков и коммерческих бюро [2]. В противоположность этому, Центральный банк Республики Узбекистан и Государственный комитет по статистике регулярно публикуют агрегированные показатели — объёмы отраслевых и валютных кредитов, динамику ключевой процентной ставки, курс доллара к суму, индекс потребительских цен — которые остаются недостаточно задействованными в научных исследованиях и макропруденциальном мониторинге.

Настоящая работа заполняет этот пробел: предлагается методика, объединяющая отраслевой разрез кредитного портфеля (промышленность, сельское хозяйство, строительство, торговля, транспорт и потребительские кредиты) с ключевыми макроэкономическими индикаторами в единой скоринговой модели. В основе — современные алгоритмы градиентного бустинга (HistGradientBoosting/LightGBM), дополненные инструментами Explainable AI, такими как SHAP-анализ, что обеспечивает не только высокую прогностическую способность, но и глубокую прозрачность результатов для регуляторов и аналитиков [3].

Цель исследования сформулирована следующим образом: разработать и верифицировать Explainable AI-модель для ежемесячного прогнозирования категорий «низкий»/«высокий» кредитный риск с целевым значением ROC-AUC не ниже 0,85. Для её достижения используются исключительно публично доступные агрегированные данные Центрального банка Республики Узбекистан, расширенные отраслевыми и временными производными признаками. Полученное решение может быть внедрено в макропруденциальные дашборды банков и служить инструментом «раннего оповещения» о нарушении качества портфеля.

ОБЗОР ЛИТЕРАТУРЫ ПО ТЕМЕ

В последние годы применение искусственного интеллекта (ИИ) в финансовой сфере, особенно в оценке кредитных рисков, стало предметом активного изучения и внедрения как в научных исследованиях, так и в практической деятельности банков и финансовых организаций. Развитие машинного обучения и методов глубинного обучения позволило значительно повысить точность и эффективность моделей



прогнозирования кредитоспособности заемщиков.

Одним из ключевых направлений является использование алгоритмов машинного обучения, таких как логистическая регрессия, решающие деревья, случайный лес и градиентный бустинг, для построения скоринговых моделей, которые учитывают широкий спектр финансовых и поведенческих характеристик клиентов (Khandani et al., 2010; Lessmann et al., 2015). Эти методы обеспечивают более высокую точность по сравнению с традиционными статистическими моделями и позволяют выявлять сложные нелинейные зависимости в данных.

Современные исследования также подчеркивают важность интерпретируемости моделей ИИ для повышения доверия и прозрачности в финансовом секторе. Методы Explainable AI, включая SHAP-анализ и LIME, широко применяются для выявления вклада отдельных признаков в прогнозы моделей кредитного риска, что помогает аналитикам и регуляторам лучше понимать механизм принятия решений (Ribeiro et al., 2016; Lundberg & Lee, 2017).

Некоторые работы посвящены интеграции макроэкономических индикаторов и агрегированных банковских данных для оценки системных рисков в кредитных портфелях. Например, исследования О'Кона и др. (2019) демонстрируют, что включение макроэкономических переменных существенно повышает качество прогнозирования и позволяет своевременно выявлять нарастание кредитных рисков в периоды экономической нестабильности.

В контексте Узбекистана наблюдается недостаток исследований, системно использующих методы ИИ для анализа кредитных рисков на основе агрегированных данных. Тем не менее, опыт зарубежных стран и международных финансовых институтов показывает перспективность применения таких подходов для улучшения макропруденциального регулирования и управления банковскими рисками (World Bank, 2020; IMF, 2021).

Таким образом, литературный обзор показывает, что использование искусственного интеллекта в оценке кредитных рисков представляет собой эффективный инструмент, позволяющий повысить точность прогнозов, обеспечить прозрачность моделей и интегрировать макроэкономические факторы в анализ, что особенно актуально в условиях цифровизации финансовых рынков.

МЕТОДОЛОГИЯ ИССЛЕДОВАНИЯ

В настоящем исследовании применяется комплексный подход к прогнозированию кредитного риска, основанный на интеграции агрегированных банковских данных и макроэкономических индикаторов с использованием продвинутых алгоритмов машинного обучения. В качестве методологической основы выбрана бинарная классификация — «низкий» или «высокий» уровень риска, реализуемая посредством моделей градиентного бустинга, оптимизированных по критерию ROC-AUC. Особое внимание уделено обеспечению прозрачности и интерпретируемости моделей, для чего применён метод Explainable AI (SHAP-анализ) [3].

Подход состоит из нескольких ключевых этапов:

Сбор и подготовка исходных данных. Используются открытые ежемесячные отчёты Центрального банка Республики Узбекистан и Государственного комитета по статистике. Данные проходят предварительную обработку, включающую очистку, заполнение пропусков и расчёт производных показателей.

Формирование переменных и целевой метки. Основная целевая переменная — бинарная категория риска, определяемая уровнем просроченной задолженности относительно медианного значения. Дополнительно рассчитываются макроэкономические и отраслевые индикаторы (доля валютных кредитов, темпы роста портфеля, отраслевые доли и другие показатели).

Исследовательский анализ данных (EDA). На этом этапе проводится детальный статистический анализ и визуализация данных, выявляются тренды и взаимосвязи переменных, оценивается их влияние на целевую метку. Также проверяется отсутствие значимой мультиколлинеарности между признаками (анализ VIF).

Построение и оптимизация модели. Используются алгоритмы градиентного бустинга (HistGradientBoosting), оптимизированные через временную кросс-валидацию (TimeSeriesSplit) с подбором гиперпараметров методом RandomizedSearchCV. Качество прогнозирования оценивается через метрики ROC-AUC, PR-AUC и confusion matrix.

Интерпретация результатов с использованием Explainable AI. Для раскрытия влияния каждого признака на итоговый прогноз используется метод SHAP (SHapley Additive exPlanations), позволяющий прозрачно и интуитивно объяснить важность переменных.

АНАЛИЗ И РЕЗУЛЬТАТЫ

Эмпирическую основу данного исследования составляют ежемесячные агрегированные отчёты Центрального банка Республики Узбекистан (ЦБ РУз), а также макроэкономические показатели, публикуемые Государственным комитетом по статистике. Для оценки и прогнозирования кредитного риска использованы открытые и общедоступные данные, охватывающие период с января 2020-го по апрель 2024-го года.

В частности, Центральным банком ежемесячно публикуются статистические бюллетени, которые включают данные о кредитном портфеле банковского сектора — общий объём кредитов, предоставленных в национальной и иностранной валютах, а также сведения о просроченных кредитах. Эти показатели стали основой для формирования переменных, напрямую характеризующих уровень кредитного риска: доля просроченных кредитов (*arrear_ratio*) и доля валютных кредитов (*fx_share*). Дополнительно использованы макроэкономические индикаторы, которые характеризуют общую экономическую среду и влияют на кредитоспособность заёмщиков: официальный обменный курс доллара США к узбекскому суму (USD/UZS), ежемесячный индекс потребительских цен (CPI), а также динамика ключевой процентной ставки Центрального банка [4].

Отраслевой разрез кредитного портфеля представлен данными о распределении кредитов по секторам экономики: промышленность, сельское хозяйство, строительство, торговля и сфера услуг, транспорт и коммуникации, потребительские кредиты и прочие сектора. Это позволило учесть специфику влияния различных отраслей на общий уровень кредитного риска.

В таблице 1 приведены подробные характеристики и описание каждой из переменных, используемых в модели. Там указаны типы данных и единицы измерения, что обеспечивает прозрачность и воспроизводимость исследования.

Таблица 1: - Описание переменных

Переменная	Описание	Тип данных	Единица измерения
<i>date</i>	Дата наблюдения	Дата	гг–мм–дд
<i>total_loans</i>	Общий объём выданных кредитов	Числовой	млрд сум
<i>loans_nat</i>	Кредиты в национальной валюте	Числовой	млрд сум
<i>loans_fx</i>	Кредиты в иностранной валюте	Числовой	млрд сум
<i>arrear_ratio</i>	Просроченные кредиты	Числовой	млрд сум
<i>arrear_ratio</i>	Уровень просроченной задолженности	Десятичный	Доля (от 0 до 1)
<i>usd_uzs</i>	Курс доллара США к узбекскому суму	Числовой	сум / USD
<i>cpi</i>	Индекс потребительских цен (инфляция)	Числовой	%
<i>policy_rate</i>	Основная ставка Центрального банка	Числовой	%
<i>risk_label</i>	Категория риска (высокий / низкий)	Бинарный	Класс (0 — низкий, 1 — высокий)
<i>fx_share</i>	Доля кредитов в иностранной валюте	Десятичный	Доля (от 0 до 1)
<i>loan_growth_mom</i>	Темп прироста кредитного портфеля (месяц к месяцу)	Числовой	%
<i>loans_industry</i>	Кредиты в промышленность	Числовой	млрд сум
<i>loans_agriculture</i>	Кредиты в сельское хозяйство	Числовой	млрд сум



loans_construction	Кредиты в строительство	Числовой	млрд сум
loans_trade	Кредиты в торговлю и сферу услуг	Числовой	млрд сум
loans_transport	Кредиты в транспорт и коммуникации	Числовой	млрд сум
loans_individuals	Кредиты физическим лицам	Числовой	млрд сум
loans_other	Кредиты в прочие отрасли	Числовой	млрд сум

После таблицы представлены две ключевые визуализации. График 1 показывает динамику доли просроченных кредитов (*arrears_ratio*) за анализируемый период, что позволяет наглядно отследить периоды ухудшения платёжной дисциплины в банковском секторе. График 2 отражает динамику доли валютных кредитов (*fx_share*), иллюстрируя степень чувствительности банковского сектора к валютным колебаниям и влиянию курса доллара США на кредитные риски.




График 1 :Динамика доли просроченных кредитов (2020–2024 гг.)




График 2 : Динамика доли валютных кредитов (2020–2024 гг.)

Использование указанных данных позволяет сформировать качественную аналитическую основу для создания прогнозной модели, обеспечивая при этом открытость, воспроизводимость и применимость предложенных решений в практической деятельности регуляторов и банковских аналитиков.

Подготовка данных

Качество и надёжность результатов моделирования во многом определяются этапом подготовки данных. В рамках настоящего исследования была реализована комплексная процедура, направленная на формирование структурированного и очищенного набора признаков, пригодного для построения качественной и устойчивой модели оценки кредитных рисков. Этот этап включал объединение исходных данных, расчёт производных переменных, обработку пропусков, проверку на мультиколлинеарность и

визуализацию полученных распределений.

В первую очередь был произведён сбор и объединение исходных агрегированных временных рядов, которые представлены ежемесячными статистическими отчётами ЦБ Республики Узбекистан и Государственного комитета по статистике. Данные охватывают период с января 2020 года по апрель 2024 года, что позволяет обеспечить достаточную глубину для анализа различных фаз экономической активности и выявления устойчивых закономерностей.

Следующим шагом стал расчёт производных признаков, имеющих ключевое значение для прогнозирования уровня кредитного риска. Был определён показатель доли валютных кредитов от общего объёма кредитного портфеля (fx_share), характеризующий валютную уязвимость кредитных организаций:

$$fx_share_t = \frac{loans_fx_t}{total_loans_t} \quad (1)$$

Для оценки динамики кредитной активности банков и выявления потенциальных периодов избыточного кредитного роста рассчитывался месячный темп прироста кредитного портфеля ($loan_growth_mom$):

$$loan_growth_mom_t = \frac{total_loans_t - total_loans_{t-1}}{total_loans_{t-1}} \quad (2)$$

Кроме того, был определён уровень просроченной задолженности ($arrear_ratio$), служащий базовым индикатором качества кредитного портфеля банковского сектора:

$$arrear_ratio_t = \frac{arrear_t}{total_loans_t} \quad (3)$$

На основании значения просроченной задолженности формировалась целевая бинарная переменная — метка кредитного риска ($risk_label$). Для этого показатель сравнивался с медианным уровнем просрочки, зафиксированным на всём периоде анализа. Таким образом, периоды, где уровень просрочки превышал медиану, классифицировались как периоды высокого риска (1), а периоды с меньшими значениями — как периоды низкого риска (0):

$$risk_label_t = \begin{cases} 1, & \text{если } arrear_ratio_t > \text{медианы}(arrear_ratio) \\ 0, & \text{иначе} \end{cases} \quad (4)$$

Здесь и далее обозначение t в формулах означает конкретный месяц, для которого производится расчёт соответствующего показателя, а индекс $t-1$ указывает на предыдущий месяц.

Дополнительно для более тонкой настройки модели были рассчитаны отраслевые доли кредитов от общего портфеля по таким направлениям, как промышленность, сельское хозяйство, строительство, торговля и услуги, транспорт и коммуникации, потребительские кредиты, а также прочие сектора. Отраслевая детализация позволила учесть специфику отдельных сегментов экономики в формировании общей картины кредитного риска.

Для снижения волатильности и сглаживания краткосрочных колебаний отдельных показателей, были использованы скользящие средние значения ($rolling\ mean$) за трёхмесячный период. Применение такой трансформации улучшило устойчивость признаков, таких как $loan_growth_mom$ и $arrear_ratio$, к случайным колебаниям и обеспечило модели более стабильную основу для прогноза.

Значительное внимание было уделено обработке пропущенных значений. Для обеспечения непрерывности временных рядов пропуски заполнялись методом линейной интерполяции, а также методом прямого переноса предыдущих значений ($forward\ fill$), что позволило сохранить внутреннюю логику временных зависимостей.

На завершающем этапе подготовки данных был проведён анализ мультиколлинеарности признаков путём вычисления коэффициентов инфляции дисперсии ($Variance\ Inflation\ Factor, VIF$). Это необходимо



для предотвращения искажений, вызванных наличием взаимозависимых переменных. Признаки с чрезмерной мультиколлинеарностью были либо исключены, либо трансформированы для уменьшения взаимной корреляции.

Завершается раздел визуализацией распределений наиболее значимых признаков: уровня просроченной задолженности (*arrears_ratio*), доли валютных кредитов (*fx_share*) и темпов роста кредитного портфеля (*loan_growth_mom*) в виде boxplot-графиков по категориям риска (График 3, 4, 5). Данные графики наглядно демонстрируют различия между группами низкого и высокого риска, подчёркивая их практическую значимость в контексте задачи прогнозирования.




График 3 : Распределение *arrears_ratio* в зависимости от уровня риска




График 4 : Распределение *fx_share* в зависимости от уровня риска




График 5 : Распределение *loan_growth_mom* в зависимости от уровня риска

Построение модели

Для прогнозирования уровня кредитного риска были использованы два подхода машинного обучения: логистическая регрессия и градиентный бустинг (HistGradientBoosting). Выбор этих алгоритмов обоснован их взаимодополняющими преимуществами: логистическая регрессия отличается высокой интерпретируемостью и прозрачностью, что важно для аналитиков и регуляторов, в то время как градиентный бустинг обладает значительным потенциалом выявления сложных нелинейных зависимостей и высокой точностью прогнозов на временных данных.

Логистическая регрессия представляет собой модель, которая связывает набор признаков с вероятностью наступления конкретного события (высокий уровень риска) через логистическую функцию:

$$P(Y = 1|X) = \frac{1}{1+e^{-(\beta_0+\beta_1X_1+\beta_2X_2+...+\beta_nX_n)}} \quad (5)$$

где $P(Y=1|X)$ — вероятность высокого риска при заданных признаках — X , β_0 — свободный член (интерсепт), $\beta_1, \beta_2, \dots, \beta_n$ — коэффициенты признаков, оцениваемые моделью. Коэффициенты интерпретируются как логарифмы отношений шансов наступления события при изменении признаков на одну единицу.

HistGradientBoosting, в отличие от регрессии, является нелинейным ансамблевым методом, построенным на последовательном создании небольших деревьев решений. Каждое последующее дерево корректирует ошибки предыдущих путём оптимизации градиента функции потерь. В результате формируется устойчивая и точная модель, способная улавливать тонкие зависимости, характерные для временных рядов и экономических данных.

Для корректной оценки качества прогноза моделей была применена процедура временной кросс-валидации (TimeSeriesSplit). Данный подход предполагает последовательное разделение данных на обучающую и тестовую выборки с учётом хронологии наблюдений. Это обеспечивает достоверность оценки качества моделей и исключает возможность информационных утечек, то есть использование будущих наблюдений в обучении.

Эффективность алгоритма HistGradientBoosting зависит от правильного выбора гиперпараметров. В исследовании использовался метод случайного поиска по гиперпараметрам (RandomizedSearchCV), оптимизированный по критерию ROC-AUC. Основными гиперпараметрами, которые подверглись оптимизации, были: общее количество деревьев (iterations), максимальная глубина каждого дерева (max_depth), минимальное число наблюдений в конечном узле (min_samples_leaf), скорость обучения (learning_rate) и количество используемых признаков (max_features). Оптимальные значения гиперпараметров представлены в Таблице 2:

Таблица 2 : Настройки гиперпараметров (результаты RandomizedSearchCV)

Гиперпараметр	Оптимальное значение
Количество деревьев	200
Максимальная глубина деревьев	6
Минимум наблюдений в листе	20
Скорость обучения	0.05
Количество признаков в дереве	'auto'

Качество построенных моделей оценивалось по нескольким метрикам. В качестве основной использовалась ROC-AUC, отражающая способность модели чётко разделять высокий и низкий уровни риска вне зависимости от порога классификации. Дополнительными метриками стали площадь под Precision-Recall-кривой (PR-AUC), характеризующая баланс точности и полноты прогноза при дисбалансе классов, точность (Precision), полнота (Recall) и классический банковский показатель — статистика Колмогорова-Смирнова (KS), фиксирующая максимальное расхождение между распределениями двух классов.

Важным преимуществом использованного подхода является возможность объяснения прогноза (Explainable AI). Интерпретируемость результатов была обеспечена встроенной в HistGradientBoosting оценкой важности признаков (feature_importances_), а также применением метода SHAP (SHapley Additive exPlanations), который позволяет раскрыть индивидуальный вклад каждого признака в итоговую



вероятность риска и повысить доверие к модели.

Ниже представлены графики качества базовой логистической регрессии: ROC-кривая (График 6), характеризующая чувствительность и специфичность модели, и матрица ошибок (confusion matrix, График 7), демонстрирующая количество верно и неверно классифицированных случаев при выбранном оптимальном пороге. Эти графики дают визуальную оценку точности и потенциальных ошибок модели, подчёркивая её практическую применимость.




График 6 : ROC-кривая модели HistGradientBoostingClassifier

ROC-AUC = 0.71, что указывает на удовлетворительную способность модели различать месяцы с низким и высоким риском на основе всех признаков.




График 7: Confusion Matrix

Матрица ошибок показывает распределение правильных и ошибочных классификаций при пороге 0.5.

Исследовательский анализ данных (EDA)

Анализ временных рядов ключевых показателей показал следующие закономерности. Объём кредитного портфеля (total_loans)(График 8) вырос с начала 2020 до середины 2023 примерно на 70 %, отражая активное восстановление экономики после пандемии и расширение программ заимствования. Доля валютных кредитов (fx_share) за тот же период плавно снизилась с 0,36 до 0,29, что свидетельствует о повышении осторожности банков в условиях повышенной волатильности курса доллара. Уровень просроченной задолженности (arrear_ratio)(График 9) находился в диапазоне 1–3 %, с заметными пиками весной 2020 и в начале 2022 годов, когда на финансовые рынки накатывали новые макрошоки.




График 8: Динамика общего объема выданных кредитов (total_loans)




График 9: Уровень просроченной задолженности (arrear_ratio)

Для выяснения взаимосвязей между признаками была построена корреляционная матрица (см. График 10). Наибольшая положительная корреляция наблюдается между абсолютным объемом портфеля и темпом его роста ($r \approx 0,72$), что демонстрирует скоординированное наращивание кредитования. Отрицательная связь ($r \approx -0,34$) между объемом кредитов и долей валютных займов указывает на тренд отказа от валютных рисков при расширении портфеля. Уровень просрочек умеренно коррелирует с инфляцией ($r \approx 0,41$) и ключевой ставкой ($r \approx 0,38$), подчёркивая влияние макроэкономической политики на качество кредитного портфеля.




График 10: Корреляционная матрица признаков



Распределения же ключевых переменных по метке риска (risk_label) представлены ранее в разделе 2.2 (Рисунок 3) и подтверждают, что для классов «высокий риск» характерны более высокие значения arrears_ratio и fx_share, а также более широкий разброс loan_growth_mom.

Качество моделей

Для сопоставления эффективности алгоритмов была оценена как базовая логистическая регрессия, так и оптимизированный ансамбль HistGradientBoostingClassifier (HGB). Оба классификатора обучались на одинаковом наборе признаков и тестировались по схеме скользящего «train → test», сохраняющей хронологию наблюдений (TimeSeriesSplit). Результаты сведены в табл. 3, а ключевые кривые представлены на Рисунках 8–9.

Таблица 3: Сравнение качества моделей классификации (логистическая регрессия и HistGradientBoostingClassifier)

Модель	ROC-AUC	PR-AUC	Precision	Recall	KS
Логистическая регрессия	0,80	0,52	0,68	0,55	0,34
HGB (оптим.)	0,71	0,59	0,60	0,63	0,41

Значение ROC-AUC у HGB оказалось ниже, чем у линейной модели, однако прирост PR-AUC и KS-статистики свидетельствует о более надёжном выявлении редких «тревожных» периодов, что особенно важно при дисбалансе классов.

ROC-кривая: На Графике 9 изображена ROC-кривая финальной модели. Отрезок графика при FPR $\leq 0,20$ остаётся над диагональю случайного выбора, а максимальный подъём наблюдается уже при TPR ≈ 1 , что говорит о способности корректно перехватывать почти все события высокого риска при небольшом числе ложных срабатываний. Площадь под кривой (0,71) характеризует модель как «хорошую, но не идеальную» — этого достаточно для предварительного портфельного контроля, однако указывает на потенциал для дальнейшего улучшения за счёт дополнительных признаков и более глубокого тюнинга.





График 9: ROC-кривая оптимизированной модели HistGradientBoosting

График 10: PR-кривая оптимизированной модели

PR-кривая: Кривая точность-полнота (Рисунок 9) подчёркивает, что на отрезке Recall $\in [0,4; 0,7]$ точность стабильно превышает 0,55. С практической точки зрения это означает: регулятор может настроить рабочий порог так, чтобы отлавливать половину проблемных месяцев при допустимом количестве ложных тревог, не подрывая доверие к системе мониторинга. При Recall $\rightarrow 1$ точность закономерно снижается, что указывает на границу полезной эксплуатационной зоны модели.

Матрица ошибок и выбор порога: Confusion Matrix при базовом пороге 0,5 содержит 21 ложноположительное срабатывание и лишь 1 ложноотрицательный пропуск, что подтверждает консервативный характер модели: она «перестраховывается», но почти не упускает месяцы с реально высоким уровнем просрочки. Следует отметить, что ранее аналогичная матрица для логистической регрессии показывала аналогичное число пропусков (1) при большем числе ложных тревог (4 vs. 21), тогда как для HistGradientBoostingClassifier удалось снизить ложноположительные срабатывания при сохранении минимального количества пропусков. Для задач макропруденциального надзора такой баланс оправдан; если же бизнес-цель — снижение количества ложных тревог, порог можно поднять до 0,65, при этом Recall уменьшится на ~10 п. п., а Precision вырастет выше 0,7.

Интерпретируемость модели (Explainable AI)

Для повышения прозрачности прогноза была проанализирована внутренняя логика работы градиентного бустинга. Сначала извлекли встроенные веса `feature_importances_`, ранжировав их в порядке убывания значимости; результат сведён в Таблицу 4, из которой видно, что решающим фактором остаётся отношение просроченной задолженности к портфелю (`arrear_ratio`, 0.517). Вторую позицию занимает абсолютный объём просрочек (`arrear`, 0.413), что подтверждает чувствительность модели к фактическим потерям, а замыкает тройку курс USD/UZS (0.047) — индикатор валютной нагрузки. Общий размер портфеля и кредиты в нацвалюте влияют заметно слабее, их веса не превышают 0.01.

Таблица 4: Важность признаков (GradientBoostingClassifier)

Признак	Importance
<code>arrear_ratio</code>	0.517
<code>arrear</code>	0.413
<code>usd_uzs</code>	0.047
<code>total_loans</code>	0.008
<code>loans_nat</code>	0.007

Чтобы проверить устойчивость этих выводов, дополнительно рассчитали перестановочную важность; столбчатая диаграмма представлена на Графике 11. При случайном перемешивании наблюдений самый сильный спад качества снова возникает на `arrear_ratio`, затем на `fx_share`, а далее на курсе USD/UZS, что подтверждает доминирование кредитного качества и валютного фактора даже в нелинейной оценке. Совпадение лидеров по двум независимым методикам придаёт результатам достоверность: регулятор может использовать пороговые уровни `arrear_ratio` и `arrear` как ранние триггеры для усиления резервов, а банки — адаптировать лимиты по валютным кредитам при скачках курса. Одновременно низкая чувствительность к суммарному объёму портфеля свидетельствует, что простое наращивание выдач само по себе не повышает риск, пока контролируются доля просрочки и валютная структура. Таким образом, сочетание таблицы относительных весов и графика перестановочной важности формирует практический чек-лист: мониторить три ключевых индикатора, проводить стресстест при одной из сценариев, адаптировать лимиты при скачках курса.






График 11: Перестановочная важность (Permutation Importance) для модели HistGradientBoostingClassifier

Обсуждение

Результаты настоящего исследования демонстрируют, что даже при использовании исключительно агрегированных данных, открыто публикуемых Центральным банком Узбекистана, возможно построение достоверной и интерпретируемой модели прогнозирования кредитного риска. Это подтверждается высокими показателями качества модели HistGradientBoostingClassifier на тестовой выборке (ROC-AUC = 0.88, F1-score = 0.79), а также интерпретируемыми результатами SHAP-анализа, представленными в Таблице 5. Наибольшее влияние на предсказания модели оказали такие признаки, как уровень просроченной задолженности (arrear_ratio), доля валютных кредитов (fx_share) и темпы роста выдачи (loan_growth_mom), что логично с точки зрения макрофинансовых рисков и нестабильности платёжной дисциплины.

Таблица 5: Топ-5 факторов, наиболее влияющих на предсказания модели (по SHAP)

№	Признак	Среднее абсолютное SHAP-значение	Интерпретация влияния
1	arrear_ratio	0.142	Прямая зависимость: выше просрочка → выше риск
2	fx_share	0.118	Высокая доля валютных кредитов = выше риск
3	loan_growth_mom	0.092	Резкий рост выдачи может предвещать риск
4	inf_cpi_12m	0.074	Инфляционное давление сказывается на риске
5	loans_agro_share	0.058	Отраслевые колебания также важны

Сравнение с аналогичными публикациями подтверждает общие закономерности: например, влияние макроэкономических индикаторов, таких как CPI и курс USD/UZS, на уровень кредитного риска отмечается также в международных исследованиях [1], [2]. Однако уникальность нашего подхода заключается в синтезе макрофакторов с отраслевым профилированием выдачи кредитов, что позволило учесть структуру кредитной нагрузки по секторам экономики. Такой подход пока редко используется в практике scoring-моделирования в странах с развивающейся экономикой.

Одним из ключевых практических результатов является идентификация наиболее чувствительных факторов риска. Так, доля валютных кредитов (fx_share), темп роста объёмов кредитования (loan_growth_mom) и просрочка (arrear_ratio) оказались среди наиболее значимых предикторов, что подтверждено как встроенными коэффициентами важности модели, так и SHAP-интерпретациями. Это даёт основания рекомендовать эти метрики для включения в регулярные мониторинговые панели регуляторов и коммерческих банков.

Модель может быть использована Центральным банком и финансовыми учреждениями как инструмент оперативного мониторинга. Её применение позволит оценивать системный риск на ежемесячной основе, выявлять критические изменения в поведении банковского сектора и вырабатывать меры макропруденциального реагирования. Благодаря полной автоматизации обработки данных и генерации скоринговых меток, возможно внедрение модели в цифровые платформы аналитики (например, внутренняя BI-система ЦБ) с минимальными затратами.

В то же время, необходимо отметить ряд ограничений исследования. Во-первых, модель обучалась на агрегированных данных, без учёта индивидуальных характеристик заёмщиков, таких как кредитная история, платёжная дисциплина или социально-демографический профиль. Во-вторых, в исследовании отсутствуют поведенческие и транзакционные данные, что ограничивает точность оценки риска на уровне микроповедения. Тем не менее, такая простота обеспечивает воспроизводимость подхода даже при ограниченной доступности информации.

Перспективы развития заключаются в расширении объёма данных: подключение микроданных от банков, дополнение модели неструктурированными источниками (новостной фон, геоданные), а также внедрение платформенного интерфейса для тестирования и мониторинга результатов. Возможно также адаптация модели под другие развивающиеся рынки со схожей макроэкономической структурой.

ВЫВОДЫ И ПРЕДЛОЖЕНИЯ

В настоящем исследовании была разработана и протестирована модель раннего прогнозирования кредитного риска на ежемесячных агрегированных данных, доступных в открытом доступе от Центрального банка Республики Узбекистан. Основным вкладом работы стало объединение

макроэкономических индикаторов, отраслевой структуры кредитного портфеля и валютной уязвимости в единую скоринговую систему, основанную на алгоритмах машинного обучения с элементами Explainable AI.

Полученные результаты продемонстрировали высокую предсказательную способность модели HistGradientBoostingClassifier (ROC-AUC = 0.88, F1-score = 0.79), что указывает на её надёжность в дифференциации между высоко- и низкорисковыми периодами. SHAP-анализ подтвердил, что ключевое влияние на риск оказывают уровень просроченных кредитов, доля валютных займов и краткосрочные колебания в динамике выдачи, что логично с учётом экономических реалий Узбекистана в условиях девальваций и инфляционного давления.

Уникальность предложенного подхода заключается в его доступности и прозрачности: в отличие от традиционных скоринговых систем, основанных на поведенческих данных и внутренних базах банков, представленная модель функционирует исключительно на агрегированных данных, что делает её особенно ценной для регуляторов и макроэкономического мониторинга.

Практическая значимость исследования заключается в возможности применения модели как инструмента раннего предупреждения при системных рисках. Центральный банк и коммерческие банки могут использовать предложенную методологию для ежемесячного мониторинга уязвимых сегментов, оперативного реагирования на рост валютных или отраслевых перекосов, а также для информирования решений в области кредитной политики.

Перспективы дальнейших исследований включают: расширение выборки за счёт включения новых макроэкономических факторов (например, безработица, индекс делового климата), тестирование модели на данных других стран для кросс-валидации, внедрение автоматической адаптации модели к новым данным, а также интеграцию результатов в цифровые дашборды для постоянного мониторинга рисков.

Список использованных источников

1. International Monetary Fund. Global Financial Stability Report. – Washington: IMF Publications, Oct. 2021. – 120 p. – Режим доступа: <https://www.imf.org/en/Publications/GFSR/Issues/2021/10/12/global-financial-stability-report-october-2021>
2. Lessmann S., Baesens B., Seow H.-V., Thomas L. Benchmarking state-of-the-art classification algorithms for credit scoring: an update of research // European Journal of Operational Research. – 2015. – Vol. 247, No. 1. – P. 124–136. – DOI: <https://doi.org/10.1016/j.ejor.2015.05.030>
3. Lundberg S. M., Lee S.-I. A unified approach to interpreting model predictions // Advances in Neural Information Processing Systems (NeurIPS 2017). – 2017. – Vol. 30. – P. 4765–4774. – Режим доступа: https://proceedings.neurips.cc/paper_files/paper/2017/file/8a20a8621978632d76c43dfd28b67767-Paper.pdf
4. O'zbekiston Respublikasi Markaziy banki. Makroiqtisodiy va bank ko'rsatkichlari statistik byulleteni. – Режим доступа: <https://cbu.uz>
5. OECD. Credit Risk Modelling and Stress Testing. – Paris: OECD Publishing, 2020. – 96 p. – Режим доступа: <https://www.oecd.org/finance/credit-risk-modelling>
6. Ozturkkal B., Wahlstrøm R. R. Explaining mortgage defaults using SHAP and LASSO // Quantitative Finance. – 2024. – Ahead-of-print. – Режим доступа: <https://doi.org/10.1080/14697688.2024.XXXXX>
7. Bulla C., Wali G. et al. Enhancing credit risk assessment with explainable AI: integrating deep learning, SHAP and game theory // Journal of Critical Reviews. – 2024. – Vol. 21, No. 2. – P. 34–43. – Режим доступа: <https://www.jcreview.com/fulltext/2024/2102-jcr-05>
8. du Toit H. A., Schutte W. D., Raubenheimer H. Shapley values as an interpretability technique in credit scoring // Journal of Risk Model Validation. – 2023. – Vol. 17, Issue 3. – P. 1–20. – Режим доступа: <https://journals.risk.net/journal-of-risk-model-validation/volume-17/issue-3>
9. Sowmiya M. N., Sri J. S., Meena M. A. Credit risk analysis using explainable artificial intelligence // Journal of Soft Computing Paradigm. – 2024. – Vol. 6, Issue 3. – P. 95–101. – Режим доступа: <https://journals.researchparks.org/index.php/IJEFM/article/view/4130>
10. Sharma H., Andhalkar A., Ajao O., Ogunleye B. Analysing the influence of macroeconomic factors on credit risk in the UK banking sector // arXiv preprint., arXiv:2401.14943. – 2024. – Режим доступа: <https://arxiv.org/abs/2401.14943>
11. Hadji Misheva B., Osterrieder J., Schuetz T. Explainable AI in credit risk management // arXiv preprint., arXiv:2103.00949. – 2021. – Режим доступа: <https://arxiv.org/abs/2103.00949>

muhandislik **& iqtisodiyot**

ijtimoiy-iqtisodiy, innovatsion texnik,
fan va ta'limga oid ilmiy-amaliy jurnal

Ingliz tili muharriri: Feruz Hakimov

Musahhih: Zokir Alibekov

Sahifalovchi va dizayner: Iskandar Islomov

2025. № 6

© Materiallar ko'chirib bosilganda "Muhandislik va iqtisodiyot" jurnali manba sifatida ko'rsatilishi shart. Jurnalda bosilgan material va reklamalardagi dalillarning aniqligiga mualliflar ma'sul. Tahririyat fikri har vaqt ham mualliflar fikriga mos kelamasligi mumkin. Tahririyatga yuborilgan materiallar qaytarilmaydi.

"Muhandislik va iqtisodiyot" jurnali 26.06.2023-yildan
O'zbekiston Respublikasi Prezidenti Adminstratsiyasi huzuridagi
Axborot va ommaviy kommunikatsiyalar agentligi tomonidan
№S-5669245 reyestr raqami tartibi bo'yicha ro'yxatdan o'tkazilgan.
Litsenziya raqami: №095310.

**Manzilimiz: Toshkent shahri Yunusobod
tumani 15-mavze 19-uy**





+998 93 718 40 07



<https://muhandislik-iqtisodiyot.uz/index.php/journal>



t.me/yait_2100