

Thus, business tourism can serve as one of the key drivers of economic growth, generating not only direct revenue for the industry but also a significant multiplier effect for the national economy.

REFERENCES:

1. Global Business Travel Association. Business Travel Index Outlook: Annual Global Report and Forecast, 2025–2029. – GBTA, 2025.
2. Jones C., Li S. The economic significance of meetings and conferences: A satellite account approach // Annals of Tourism Research. – 2015. – Vol. 52. – P. 117–133. – DOI: 10.1016/j.annals.2015.03.004.
3. Hanly P.A. Measuring the economic contribution of the international association conference market: An Irish case study // Tourism Management. – 2012. – Vol. 33. – No. 6. – P. 1574–1582. – DOI: 10.1016/j.tourman.2011.12.010.
4. Dwyer L., Forsyth P., Spurr R. Evaluating tourism's economic effects: New and old approaches // Tourism Management. – 2004. – Vol. 25. – No. 3. – P. 307–317.
5. Kim S.S., Chon K., Chung K.Y. Convention industry in South Korea: An economic impact analysis // Tourism Management. – 2003. – Vol. 24. – No. 5. – P. 533–541. – DOI: 10.1016/S0261-5177(03)00006-2.
6. Getz D., Page S.J. Event Studies: Theory, Research and Policy for Planned Events. 4th ed. – London: Routledge, 2019. – DOI: 10.4324/9780429023002.
7. Taipakova B. Analysis of the interaction of MICE tourism development factors (the case of Astana city in Kazakhstan) // GeoJournal of Tourism and Geosites. – 2023. – Vol. 51. – No. 4, Suppl. – P. 1600–1609. – DOI: 10.30892/gtg.514spl01-1156.
8. Kenzhebekov N. et al. Foresight of tourism in Kazakhstan: Experience economy // Information. – 2021. – Vol. 12. – No. 3. – Art. 138. – DOI: 10.3390/info12030138.
9. National Statistics Bureau of the Agency for Strategic Planning and Reforms of the Republic of Kazakhstan. Official statistics portal [Electronic resource]. – Access mode: stat.gov.kz. – Date of access: 09.04.2026.

AUTHOR INFORMATION:

Темирбеков А.Г. — докторант образовательной программы «Инновационный менеджмент», кафедра «Менеджмент», Евразийский национальный университет имени Л.Н. Гумилёва (г. Астана, Республика Казахстан), e-mail: temirbekov.expo2017@gmail.com

Толысбаев Б.С. — доктор экономических наук, профессор кафедры «Менеджмент», Евразийский национальный университет имени Л.Н. Гумилёва (г. Астана, Республика Казахстан), e-mail: bauke.311@gmail.com

Майдырова А.Б. — доктор экономических наук, профессор кафедры экономики и предпринимательства, Евразийский национальный университет имени Л.Н. Гумилёва (г. Астана, Республика Казахстан), e-mail: maydirova2010@gmail.com

Темирбеков А.Г. — 8D04117 «Инновационный менеджмент» білім беру бағдарламасының докторанты, «Менеджмент» кафедрасы, Л.Н. Гумилёв атындағы Еуразия ұлттық университеті (Астана қ., Қазақстан Республикасы), e-mail: temirbekov.expo2017@gmail.com

Толысбаев Б.С. — экономика ғылымдарының докторы, «Менеджмент» кафедрасының профессоры, Л.Н. Гумилёв атындағы Еуразия ұлттық университеті (Астана қ., Қазақстан Республикасы), e-mail: bauke.311@gmail.com

Майдырова А.Б. — экономика ғылымдарының докторы, экономика және кәсіпкерлік кафедрасының профессоры, Л.Н. Гумилёв атындағы Еуразия ұлттық университеті (Астана қ., Қазақстан Республикасы), e-mail: maydirova2010@gmail.com

Temirbekov A.G. — Doctoral Student of the Educational Program 8D04117 "Innovation Management", Department of Management, L.N. Gumilyov Eurasian National University (Astana, Republic of Kazakhstan), e-mail: temirbekov.expo2017@gmail.com

Tolysbayev B.S. — Doctor of Economic Sciences, Professor at the Department of Management, L.N. Gumilyov Eurasian National University (Astana, Republic of Kazakhstan), e-mail: bauke.311@gmail.com

Maidyrova A.B. — Doctor of Economic Sciences, Professor at the Department of Economics and Entrepreneurship, L.N. Gumilyov Eurasian National University (Astana, Republic of Kazakhstan), e-mail: maydirova2010@gmail.com

МРНТИ 06.56.31; 20.53.19
УДК 334.012.64:004.8:343.72

DOI 10.58319/26170493_2026_2_144

ҚАЗАҚСТАНДАҒЫ ЖЕКЕ КӘСІПкерлікте Алаяқтық пен Экономикалық Тәуекелдерді Машиналық Оқыту Әдістері Арқылы Анықтау

Шайнұров А.С.¹, Жаныс А.Б.², Дюсембаева Л.К.³, Рыскулова Ж.О.⁴

¹Қорқыт Ата атындағы Қызылорда университеті; ²К.А. Тимирязев атындағы Ресей мемлекеттік аграрлық университеті – Мәскеу ауыл шаруашылығы академиясы; ³С. Сейфуллин атындағы Қазақ агротехникалық зерттеу университеті; ⁴Л.Н. Гумилев атындағы Еуразия ұлттық университеті

АНДАТПА. Бүгінгі экономикалық цифрландыру және кәсіпкерлік қызметтің кеңеюі жағдайында жеке кәсіпкерлік секторындағы алаяқтықты анықтау және экономикалық тәуекелдерді басқару ерекше өзекті болып табылады. Электрондық төлемдердің, қашықтан жүргізілетін қаржылық операциялардың және цифрлық қызметтердің өсуі бизнесті дамыту үшін жаңа мүмкіндіктер туғызады, сонымен қатар қаржылық бұзушылықтардың, салықтық теріс пайдаланудың және алаяқтықтың ықтималдығын арттырады. Бұл күдікті операцияларды уақтылы анықтауды және экономикалық шығындарды азайтуды қамтамасыз ете алатын заманауи аналитикалық құралдарға деген қажеттілікті арттырады.

Бұл зерттеудің мақсаты - Қазақстандағы жеке кәсіпкерлердің қызметінде алаяқтықты анықтау және экономикалық тәуекелдерді бағалау үшін машиналық оқыту әдістерін қолданудың орындылығын талдау. Зерттеудің әдіснамалық негізі салыстырмалы және жүйелік талдау әдістеріне, сондай-ақ логистикалық регрессия, шешім ағаштары, кездейсоқ ормандар, градиенттік күшейту және нейрондық желілерді қоса алғанда, машиналық оқыту алгоритмдеріне негізделген. Мақалада тәуекелдерді болжау модельдерін әзірлеу және бизнестегі аномальды мінез-құлықты анықтау үшін үлкен деректер мен кәсіпкерлік қызметтің сандық іздерін пайдалану ерекшеліктері қарастырылады.

Зерттеу нәтижелері машиналық оқыту технологияларын пайдалану қолмен тексеруге және бекітілген ережелерге негізделген дәстүрлі бақылау әдістерімен салыстырғанда алаяқтықты анықтаудың дәлдігін айтарлықтай жақсартатынын көрсетеді. Ақылды алгоритмдерді пайдалану қаржылық транзакцияларды бақылауды автоматтандыруды жеңілдетеді, жалған оң нәтижелерді азайтады және тәуекелдерді басқару тиімділігін арттырады. Дегенмен, бастапқы деректердің сапасына, құпия ақпаратты қорғауға және цифрлық қауіпсіздікке арналған нормативтік базаны жетілдіру қажеттілігіне қатысты мәселелер анықталды.

Зерттеудің практикалық маңыздылығы мемлекеттік органдардың, қаржы институттарының және бизнестің бизнестің ашықтығын арттыру, қаржылық бұзушылықтардың алдын алу және Қазақстан Республикасының экономикалық қауіпсіздігін нығайту үшін әзірленген тәсілдерді пайдалану мүмкіндігінде жатыр.

КІЛТ СӨЗДЕР: алаяқтық, экономикалық тәуекелдер, жеке кәсіпкерлік, машиналық оқыту, жасанды интеллект, тәуекелдерді болжау, цифрлық экономика, қаржылық қауіпсіздік, Қазақстан, деректерді талдау.

Выявление мошенничества и экономических рисков в индивидуальном предпринимательстве Казахстана с использованием методов машинного обучения

Шайнуров А.С.¹, Жаныс А.Б.², Дюсембаева Л.К.³, Рыскулова Ж.О.⁴

¹Кызылординский университет имени Кorkыт Ата; ²Российский государственный аграрный университет – МСХА имени К. А. Тимирязева; ³Казахский агротехнический исследовательский университет имени С. Сейфуллина; ⁴Евразийский национальный университет имени Л. Н. Гумилева.

АННОТАЦИЯ. В современном контексте цифровой экономики и расширения предпринимательской активности выявление мошенничества и управление экономическими рисками в секторе индивидуального предпринимательства приобретают особую актуальность. Рост электронных платежей, дистанционных финансовых операций и цифровых услуг создает новые возможности для развития бизнеса, но также увеличивает вероятность финансовых нарушений, налоговых злоупотреблений и мошенничества. Это повышает потребность в современных аналитических инструментах, способных обеспечить своевременное выявление подозрительных транзакций и минимизацию экономических потерь.

Целью данного исследования является анализ целесообразности применения методов машинного обучения для выявления мошенничества и оценки экономических рисков в деятельности индивидуальных предпринимателей в Казахстане. Методологическая основа исследования базируется на методах сравнительного и системного анализа, а также на алгоритмах машинного обучения, включая логистическую регрессию, деревья решений, случайные леса, градиентный бустинг и нейронные сети. В работе рассматриваются особенности использования больших данных и цифровых следов предпринимательской деятельности для разработки моделей прогнозирования рисков и выявления аномального поведения в бизнесе.

Результаты исследования показывают, что использование технологий машинного обучения значительно повышает точность выявления мошенничества по сравнению с традиционными методами контроля, основанными на ручной проверке и фиксированных правилах. Применение интеллектуальных алгоритмов облегчает автоматизацию мониторинга финансовых транзакций, снижает количество ложных срабатываний и повышает эффективность управления рисками. Однако были выявлены проблемы, связанные с качеством исходных данных, защитой конфиденциальной информации и необходимостью совершенствования нормативно-правовой базы в области цифровой безопасности.

Практическая значимость исследования заключается в потенциальном использовании разработанных подходов государственными органами, финансовыми учреждениями и предприятиями для повышения прозрачности бизнеса, предотвращения финансовых нарушений и укрепления экономической безопасности Республики Казахстан.

КЛЮЧЕВЫЕ СЛОВА: мошенничество, экономические риски, индивидуальное предпринимательство, машинное обучение, искусственный интеллект, прогнозирование рисков, цифровая экономика, финансовая безопасность, Казахстан, анализ данных.

Detection of fraud and economic risks in individual entrepreneurship in Kazakhstan using machine learning methods

Shainurov A.S.¹, Zhanys A.B.², Dyusembayeva L.K.³, Ryskulova Zh.O.⁴

¹Korkyt Ata Kyzylorda University; ²Russian State Agrarian University – Moscow Timiryazev Agricultural Academy; ³S. Seifullin Kazakh Agrotechnical Research University; ⁴L. N. Gumilyov Eurasian National University.

ABSTRACT. In today's context of economic digitalization and expanding entrepreneurial activity, fraud detection and economic risk management in the individual entrepreneurship sector are particularly pressing. The growth in electronic payments, remote financial transactions, and digital services creates new opportunities for business development, but also increases the likelihood of financial irregularities, tax abuse, and fraud. This increases the need for modern analytical tools capable of ensuring the timely detection of suspicious transactions and minimizing economic losses.

The aim of this study is to analyze the feasibility of applying machine learning methods to fraud detection and economic risk assessment in the activities of individual entrepreneurs in Kazakhstan. The methodological basis of the study is based on comparative and systemic analysis methods, as well as machine learning algorithms, including logistic regression, decision trees, random forests, gradient boosting, and neural networks. The paper examines the specifics of using big data and digital traces of entrepreneurial activity to develop risk prediction models and detect anomalous behavior in businesses.

The study's results demonstrate that the use of machine learning technologies significantly improves the accuracy of fraud detection compared to traditional control methods based on manual verification and fixed rules. The use of intelligent algorithms facilitates the automation of financial transaction monitoring, reduces false positives, and improves risk management efficiency. However, issues related to the quality of source data, the protection of confidential information, and the need to improve the regulatory framework for digital security were identified.

The practical significance of the study lies in the potential use of the developed approaches by government agencies, financial institutions, and businesses to increase business transparency, prevent financial violations, and strengthen the economic security of the Republic of Kazakhstan.

KEYWORDS: fraud, economic risks, individual entrepreneurship, machine learning, artificial intelligence, risk forecasting, digital economy, financial security, Kazakhstan, data analysis.

КІРІСПЕ. Қазақстан экономикасында жеке кәсіпкерлік пен шағын бизнес маңызды әлеуметтік-экономикалық рөл атқарады. Жеке кәсіпкерлер сауда, қызмет көрсету, логистика, қоғамдық тамақтану, онлайн-сату, ауыл шаруашылығы және цифрлық сервистер саласында кеңінен жұмыс істейді. Қазақстан Республикасы Стратегиялық жоспарлау және реформалар агенттігі Ұлттық статистика бюросының деректері бойынша, 2026 жылғы 1 сәуірдегі жағдай бойынша жұмыс істеп тұрған шағын және орта кәсіпкерлік субъектілерінің құрылымында дара кәсіпкерлердің үлесі 69,9% болды [2]. Бұл көрсеткіш жеке кәсіпкерліктің Қазақстандағы экономикалық белсенділіктің кең таралған ұйымдық-құқықтық нысаны екенін көрсетеді.

Зерттеу тақырыбының Қазақстан үшін өзектілігі бірнеше факторлармен анықталады. Біріншіден, елде кәсіпкерлік қызметтің цифрлануы жеделдеуде. Екіншіден, электрондық коммерция мен маркетплейстер

арқылы сату көлемі тұрақты өсуде. 2024 жылы Қазақстанда бөлшек электрондық коммерцияның ішкі нарықтағы көлемі, маркетплейстерді қоса алғанда, 3 156,4 млрд теңгені құрады, оның 84,9%-ы маркетплейстер арқылы жүзеге асырылған [3]. Үшіншіден, интернет-алаяқтық пен киберқылмыстар кәсіпкерлер мен тұтынушылар үшін нақты экономикалық қауіпке айналды. Қазақстан Республикасы Бас прокуратурасының 2024 жылғы криминалендік жағдай туралы деректерінде интернет-алаяқтық 5%-ға өсіп, 22 870 жағдайға жеткені көрсетілген [4].

Жеке кәсіпкер ірі компаниялармен салыстырғанда ішкі бақылау, құқықтық сүйемелдеу, қаржылық мониторинг және ақпараттық қауіпсіздік ресурстары бойынша шектеулі жағдайда жұмыс істейді. Сондықтан алаяқтық операциялар, жалған контрагенттер, реквизиттерді ауыстыру, фишинг, негізсіз қайтарымдар, салықтық қателер және құжаттық сәйкессіздік-

тер уақытылы анықталмаса, кәсіпкердің қаржылық тұрақтылығына тікелей әсер етеді [5; 12].

Осы тұрғыдан машиналық оқыту әдістері жеке кәсіпкерлік үшін тек техникалық құрал емес, тәуекелдерді басқару және кәсіпкерлік шешімдердің сапасын арттыру құралы ретінде қарастырылуы мүмкін. Әлемдік зерттеулерде машиналық оқыту қаржылық алаяқтықты анықтау, аномалияларды табу, транзакциялық мінез-құлықты талдау және тәуекелді операцияларды жіктеу міндеттерінде кеңінен қолданылатыны көрсетілген [6; 10].

Зерттеудің мақсаты — Қазақстандағы жеке кәсіпкерлер қызметінде алаяқтық белгілерін және экономикалық тәуекелдерді ерте анықтауға арналған машиналық оқытуға негізделген концептуалдық модель ұсыну.

Осы мақсатқа жету үшін келесі міндеттер қойылды:

- Қазақстандағы жеке кәсіпкерлік үшін алаяқтық пен экономикалық тәуекелдердің өзектілігін негіздеу.
- Жеке кәсіпкер қызметіндегі негізгі тәуекел көздерін анықтау.

- Дәстүрлі ережелік тәсілдер мен машиналық оқыту әдістерін салыстыру.

- Күмәнді операцияларды анықтауға арналған белгілер жүйесін ұсыну.

- Машиналық оқытуға негізделген тәуекел-индекс қалыптастыру моделін сипаттау.

- Дербес деректерді қорғау және зерттеудің қайталанушылық талаптарын анықтау.

Зерттеудің ғылыми жаңалығы жеке кәсіпкерлік субъектілеріне бейімделген көпфакторлы тәуекел-индекссті машиналық оқыту модельдерімен біріктіруде және бұл тәсілді Қазақстандағы цифрлық кәсіпкерлік ортасының ерекшеліктерімен байланыстыра сипаттауда көрінеді.

ЗЕРТТЕУ МАТЕРИАЛДАРЫ МЕН ӘДІСТЕРІ. Зерттеу әдістемесі жүйелік талдау, салыстырмалы талдау, экономикалық тәуекелдерді бағалау, машиналық оқыту және аномалияларды анықтау әдістеріне негізделеді. Зерттеу эмпирикалық нәтижелерді ойдан шығармайды: мақалада нақты жеке кәсіпкерлік деректері жарияланбайды, ал ұсынылған модель кейінгі кезеңде 6–12 айлық анонимделген операциялық деректер негізінде апробациялауға арналған. Мұндай тәсіл зерттеу этикасына және дербес деректерді қорғау талаптарына сәйкес келеді [5].

Зерттеу материалдары ретінде келесі дереккөздер типтері қарастырылады: банк операциялары, сатылымдар, қайтарымдар, контрагенттермен өзара әрекеттесу, онлайн-касса деректері, маркетплейс операциялары, электрондық шот-фактуралар және салықтық есеп жазбалары. Бұл деректер жиынтығы жеке кәсіпкер қызметіндегі қаржылық, операциялық, контрагенттік және кибертәуекелдерді кешенді талдауға мүмкіндік береді [6;13].

Нақты деректер жиынының құрылымы. Ұсынылған модельді болашақта эмпирикалық тексеру үшін жеке кәсіпкердің кемінде 6–12 айлық қаржылық-шаруашылық операциялары негізінде деректер жиыны қалыптастырылады. Мұндай кезең маусымдық ауытқуларды, қайталанатын операциялық үлгілерді және тәуекелдердің динамикасын бағалауға мүмкіндік береді [10; 13].

Деректер жиынында келесі негізгі белгілер пайдаланылады: операция сомасы, операция уақыты, төлем жиілігі, контрагенттің жаңалығы, қайтарым үлесі, құжаттық растаудың болуы, операцияның орташа мәннен ауытқуы, төлем мақсаты, реквизиттердің өзгеруі, бір контрагентке тәуелділік деңгейі және салықтық жазбалармен сәйкестік. Мұндай белгілер қаржылық алаяқтықты анықтау бойынша халықаралық зерттеу-

лерде қолданылатын көпфакторлы талдау қағидаларына сәйкес келеді [6; 10].

Кесте 1 – Апробацияға арналған деректер жиынының ұсынылатын құрылымы

Көрсеткіш	Сипаттамасы
Бақылау кезеңі	6–12 ай
Бақылау бірлігі	Жеке қаржылық немесе шаруашылық операция
Дереккөздер	банк операциялары, сатылымдар, қайтарымдар, контрагенттер, салықтық жазбалар, маркетплейс деректері
Белгілер түрі	сандық, категориялық, уақыттық және бинарлық белгілер
Нысаналы айнымалы	0 — қалыпты операция; 1 — күмәнді немесе алаяқтық белгісі бар операция
Белгілеу тәсілі	сараптамалық белгілеу немесе расталған тәуекел оқиғалары негізінде белгілеу
Қорғау тәсілі	анонимдеу, псевдонимдеу, деректерді минимизациялау

Деректерді алдын ала өңдеу. Модельді оқыту алдында деректер алдын ала өңделеді. Бірінші кезеңде қайталанатын жазбалар жойылады, бос мәндер анықталады, операция күндері бірыңғай форматқа келтіріледі және сандық белгілер нормаланады. Категориялық белгілер, мысалы, контрагент түрі, төлем мақсаты, операция арнасы және тауар санаты, кодталады. Уақыттық белгілерден қосымша айнымалылар жасалады: апта күні, ай, тоқсан, жұмыс уақыты немесе жұмыс уақытынан тыс операция белгісі [13; 15].

Деректерді алдын ала өңдеу келесі кезеңдерден тұрады:

- бос мәндерді анықтау және өңдеу;
- дубликат операцияларды алып тастау;
- сандық белгілерді масштабтау;
- категориялық белгілерді кодтау;
- уақыттық белгілерді қалыптастыру;
- күмәнді операциялар бойынша нысаналы айнымалыны құру;

- деректерді оқыту және тест жиынына бөлу.

Алаяқтықты анықтау міндетінде деректердің теңгерімсіздігі жиі кездеседі, себебі күмәнді немесе алаяқтық операциялардың үлесі қалыпты операцияларға қарағанда аз болады. Осыған байланысты модельді бағалау кезінде тек ассигуасу көрсеткішін қолдану жеткіліксіз. Мұндай жағдайда precision, recall, F1-score және PR-AUC көрсеткіштері маңыздырақ болып саналады [20; 21].

Машиналық оқыту модельдері. Деректерді талдау үшін бақылаулы оқыту және аномалияларды анықтау әдістері қарастырылады. Logistic Regression базалық түсіндірілетін модель ретінде қолданылады. Random Forest күрделі белгілер байланысын табуға мүмкіндік береді және қаржылық алаяқтықты анықтау міндеттерінде жиі пайдаланылады [17]. XGBoost градиенттік бустинг қағидасына негізделеді және құрылымдалған деректердегі классификация есептерінде жоғары нәтижелер көрсетуі мүмкін [18]. Isolation Forest белгіленбеген немесе толық белгіленбеген деректер жағдайында аномалиялық операцияларды анықтау үшін қолданылады [19]. SMOTE әдісі азшылық класындағы бақылаулар негізінде синтетикалық мысалдар құрып, теңгерімсіз деректер мәселесін азайтуға көмектеседі [20].

Әдістемелік қайталанушылық. Зерттеудің қайталанушылығын қамтамасыз ету үшін модельдеу процесін Python бағдарламалау тілінде жүргізу ұсынылады. Деректерді өңдеу, модель құру және нәтижелерді баға-

лау үшін ашық кітапханалар қолданылады. Бұл зерттеу және модельді жаңа деректерге бейімдеуіне мүмкіндік нәтижелерін басқа зерттеушілердің қайта тексеруіне береді [21; 25] (3 кесте).

Кесте 2 – Жеке кәсіпкерлік деректерін талдауға арналған алгоритмдер

Алгоритм	Қолдану мақсаты	Артықшылығы	Шектеуі
Logistic Regression	Күмәнді операция ықтималдығын бағалау	Түсіндіру жеңіл	Сызықтық байланыстарға тәуелді
Random Forest	Күрделі белгілер байланысын табу	Тұрақты, overfitting қаупі төмен	Интерпретациясы күрделірек
XGBoost	Жоғары дәлдікпен классификациялау	Көп жағдайда сапасы жоғары	Баптау параметрлері көп
Isolation Forest	Аномалияларды анықтау	Белгіленбеген деректерге жарайды	Нәтижені түсіндіру қиынырақ
SMOTE классификатор ⁺	Теңгерімсіз класстармен жұмыс	Сирек алаяқтық жағдайларын оқытуға көмектеседі	Синтетикалық деректер бұрмалау енгізуі мүмкін

Кесте 3 – Қайталанатын зерттеу үшін ұсынылатын Python құралдары

Құрал / кітапхана	Қолдану мақсаты
Python	жалпы бағдарламалау және модельдеу ортасы
pandas	кестелік деректерді өңдеу
numpy	сандық есептеулер
scikit-learn	машиналық оқыту модельдерін құру және бағалау
imbalanced-learn	теңгерімсіз деректермен жұмыс, SMOTE әдісі
xgboost	градиенттік бустинг моделін құру
matplotlib	графиктер мен confusion matrix визуализациясы
shap	модель шешімдерін түсіндіру, маңызды белгілерді талдау

Деректер жиыны оқыту және тест бөліктеріне бөлінеді. Негізгі нұсқада train/test split = 80/20 қолданылады, яғни деректердің 80%-ы модельді оқытуға, ал 20%-ы модельді тексеруге беріледі. Класстардың арақатынасы бұзылмауы үшін бөлу кезінде stratified split қолдану ұсынылады [21].

Кесте 4 – Модельдеу параметрлерінің ұсынылатын бастапқы нұсқасы

Модель	Негізгі параметрлер
Logistic Regression	max_iter = 1000, class_weight = "balanced"
Random Forest	n_estimators = 300, max_depth = None, class_weight = "balanced"
XGBoost	n_estimators = 300, learning_rate = 0.05, max_depth = 4
Isolation Forest	n_estimators = 300, contamination = [алақтық үлесіне сәйкес мән]

Бұл параметрлер соңғы нәтиже емес, бастапқы модельдеу конфигурациясы ретінде қарастырылады. Нақты деректермен жұмыс кезінде гиперпараметрлер кросс-валидация және модель сапасының метрикалары бойынша нақтылануы тиіс [18; 21].

Этикалық талаптар және дербес деректерді қорғау. Зерттеуде жеке кәсіпкерлердің қаржылық операциялары, контрагенттері, сатылымдары және төлем арналары туралы деректер қолданылатындықтан, дербес деректерді қорғау және ақпараттық қауіпсіздік талаптары ерекше маңызды. Деректерді жинау және өңдеу ҚР «Дербес деректер және оларды қорғау туралы» Заңына сәйкес жүргізілуі тиіс [5].

Зерттеу барысында келесі этикалық қағидалар сақталуы қажет:

- Анонимдеу — кәсіпкердің аты-жөні, ЖСН/БСН, банк шоты, телефон нөмірі, нақты мекенжайы және контрагенттердің жеке деректері деректер жиынынан алынып тасталады немесе кодталады.

- Псевдонимдеу — нақты контрагенттердің атаулары орнына ID-кодтар қолданылады.

- Деректерді минимизациялау — модельге қажет емес жеке ақпарат пайдаланылмайды.

- Қол жеткізуді шектеу — бастапқы деректерге тек зерттеуге жауапты тұлғалар ғана қол жеткізеді.

- Қауіпсіз сақтау — деректер шифрланған тасымалдағышта немесе қорғалған серверде сақталады.

- Нәтижелерді агрегаттау — мақалада нақты кәсіпкерді немесе контрагентті сәйкестендіруге болатын ақпарат жарияланбайды.

- Келісім алу — нақты кәсіпкер деректері пайдаланылса, деректерді ғылыми мақсатта өңдеуге жазбаша келісім алынуы қажет.

Анонимдеу нәтижесінде бастапқы деректер ғылыми талдау үшін жеткілікті ақпаратты сақтауы, бірақ нақты жеке тұлғаны немесе кәсіпкерлік субъектісін сәйкестендіруге мүмкіндік бермеуі тиіс [5].

НӘТИЖЕЛЕР ЖӘНЕ ТАЛҚЫЛАУ. Зерттеу нәтижесінде Қазақстандағы жеке кәсіпкерлік жағдайында алаяқтық пен экономикалық тәуекелдерді анықтауға арналған концептуалдық модель ұсынылды. Модель жеке кәсіпкердің операциялық деректерін жинау, алдын ала өңдеу, тәуекел белгілерін қалыптастыру, машиналық оқыту модельдерін қолдану, тәуекел индексі есептеу және басқарушылық шешім қабылдау кезеңдерінен тұрады.

Қазақстан жағдайындағы тәуекелдердің өзектілігі. Қазақстанда жеке кәсіпкерлік субъектілері цифрлық арналар арқылы клиенттермен, банктермен, маркетингтермен және мемлекеттік ақпараттық жүйелермен жиі байланысады. Электрондық коммерция көлемінің өсуі кәсіпкерлер үшін нарықтық мүмкіндіктерді кеңейтеді, бірақ бір мезгілде төлемдік алаяқтық, жалған тапсырыстар, негізсіз қайтарымдар, фишинг және реквизиттерді ауыстыру сияқты қауіптерді күшейтеді [3; 16].

OECD деректері бойынша, 2024 жылы Қазақстанда шағын және орта кәсіпкерлік барлық кәсіпорындардың 96,2%-ын құрап, жұмыспен қамтылған халықтың 48,0%-ын және елдің ЖІӨ-нің 39,3%-ын қамтамасыз етті [22]. Бұл деректер жеке кәсіпкерлік пен шағын бизнестегі тәуекелдерді басқару мәселесінің тек жеке бизнес үшін емес, жалпы экономикалық тұрақтылық үшін де маңызды екенін көрсетеді.

Жеке кәсіпкерлік жағдайында алаяқтықты анықтаудың дәстүрлі тәсілі көбінесе қарапайым ережелерге сүйенеді: ірі сома, жаңа контрагент, күмәнді уақыт, қайталанатын төлем, шектен тыс қайтарым немесе құжаттық растаудың болмауы. Мұндай тәсіл түсінікті

болғанымен, жасырын және күрделі байланыстарды табуда шектеулі [8; 9]. Машиналық оқыту әдістері деректерден үлгілерді автоматты түрде үйренеді. Олар бір ғана көрсеткішке емес, көптеген белгілердің комбинациясына сүйенеді. Мысалы, операция сомасы қа-

лыпты болуы мүмкін, бірақ жаңа контрагентпен, түнгі уақытта, бұрын болмаған тауар санатында және құжатсыз жасалса, модель оны жоғары тәуекел ретінде бағалай алады [6; 7; 14].

5-кесте – Дәстүрлі ережелік тәсілдер мен машиналық оқыту тәсілдерінің салыстырмасы

Салыстыру аспектісі	Дәстүрлі ережелік тәсілдер	Машиналық оқыту тәсілдері
Қағида құру	Қолмен, алдын ала белгіленген шектер арқылы	Деректерден автоматты түрде үлгілерді үйрену
Жасырын байланыстарды табу	Шектеулі	Жоғары
Бейімделгіштік	Төмен	Жаңа деректермен қайта оқытуға болады
Үлкен деректермен жұмыс	Қиын	Тиімді
Жалған дабылдарды азайту	Орташа	Дұрыс бапталса, төмендетуге болады
Түсіндірілетіндік	Жоғары	SHAP, feature importance арқылы түсіндіріледі
Анықтау уақыты	Көбіне кейінгі бақылау	Нақты уақытқа жақын

Бұл салыстыру машиналық оқыту дәстүрлі тәсілдерді толық алмастырмайтынын, бірақ оларды күшейтетінін көрсетеді. Практикалық жүйеде ең дұрыс шешім — ережелік сүзгілер мен машиналық оқыту модельдерін біріктіретін гибридік тәсіл [6; 8; 13].

Ұсынылған модель бес негізгі кезеңнен тұрады: дереккөздерді біріктіру, алдын ала өңдеу, белгілер қалыптастыру, машиналық оқыту моделін қолдану және басқарушылық шешім қабылдау.

Ұсынылған модель бес негізгі кезеңнен тұрады: дереккөздерді біріктіру, алдын ала өңдеу, белгілер қалыптастыру, машиналық оқыту моделін қолдану және басқарушылық шешім қабылдау.

Модельдің жалпы логикасы келесі түрде беріледі:

$$P(\text{fraud}) = f(X),$$

мұндағы $P(\text{fraud})$ — операцияның алаяқтық немесе күмәнді болу ықтималдығы, X — операция белгілерінің векторы, $f(X)$ — машиналық оқыту моделі.

Операция бойынша күтілетін экономикалық тәуекел келесі формуламен бағалануы мүмкін:

$$\text{Risk} = P(\text{fraud}) \times \text{Loss},$$

мұндағы Loss — операция бойынша ықтимал қаржылық шығын.

Жеке кәсіпкердің жалпы тәуекел индексі былай есептелуі мүмкін:

$$RI = w1R_{fin} + w2R_{tax} + w3R_{contr} + w4R_{oper} + w5R_{cyber},$$

мұндағы:

- R_{fin} — қаржылық тәуекел;
- R_{tax} — салықтық тәуекел;
- R_{contr} — контрагенттік тәуекел;
- R_{oper} — операциялық тәуекел;
- R_{cyber} — кибертәуекел;
- $w1, w2, w3, w4, w5$ — тәуекел салмақтары.

Модельді бағалау көрсеткіштері. Ұсынылған модельдің эмпирикалық апробациясы келесі кезеңде жеке кәсіпкердің 6–12 айлық анонимделген операциялық деректері негізінде жүргізіледі. Бұл мақалада нақты операциялық деректерге негізделген метрикалар берілмейді, себебі мақала мақсаты — Қазақстан жағдайына бейімделген концептуалдық модельді ұсыну. Нақты деректер алынғаннан кейін дәстүрлі

ережелік тәсілдер, Logistic Regression, Random Forest, XGBoost және Isolation Forest модельдері салыстырылады [17; 19].

6-кесте – Тәуекел индексін интерпретациялау

RI мәні	Тәуекел деңгейі	Басқарушылық әрекет
0–0,30	Төмен	Қалыпты мониторинг
0,31–0,60	Орташа	Қосымша тексеру
0,61–0,80	Жоғары	Құжат сұрату және қолмен тексеру
0,81–1,00	Критикалық	Операцияны тоқтату немесе растау сұрату

Модельдердің тиімділігі Precision, Recall, F1-score, ROC-AUC, PR-AUC және confusion matrix көрсеткіштері арқылы бағаланады.

Теңгерімсіз деректер жағдайында PR-AUC көрсеткіші ерекше маңызды, себебі ол сирек кездесетін күмәнді операцияларды анықтау сапасын нақтырақ көрсетеді [21].

7-кесте – Модель сапасын бағалау көрсеткіштері

Көрсеткіш	Экономикалық мағынасы
Precision	Модель күмәнді деп белгілеген операциялардың ішіндегі шын мәнінде күмәнді операциялар үлесі
Recall	Нақты күмәнді операциялардың қаншасын модель анықтағанын көрсетеді
F1-score	Precision мен recall арасындағы теңгерімді көрсетеді
ROC-AUC	Модельдің екі классты ажырату қабілетін көрсетеді
PR-AUC	Теңгерімсіз деректерде күмәнді операцияларды анықтау сапасын нақтырақ бағалайды
Confusion matrix	Дұрыс және қате жіктелген операциялар санын көрсетеді

Классификация сапасын нақты көрсету үшін confusion matrix қолданылады. Ол модельдің қалыпты және күмәнді операцияларды қаншалықты дұрыс анықтағанын көрсетеді [21].

8-кесте – Confusion matrix құрылымы

Нақты класс / Болжанған класс	Қалыпты операция	Күмәнді операция
Қалыпты операция	TN	FP
Күмәнді операция	FN	TP

Мұндағы TN — қалыпты операцияны дұрыс қалыпты

деп анықтау; FP — қалыпты операцияны қате күмәнді деп белгілеу; FN — күмәнді операцияны қате қалыпты деп өткізіп жіберу; TP — күмәнді операцияны дұрыс анықтау. Алаяқтықты анықтау міндетінде FN мәні өте қауіпті, себебі бұл модельдің нақты күмәнді операцияны өткізіп жібергенін білдіреді. Ал FP кәсіпкер үшін қосымша тексеру шығындарын арттырады. Сондықтан модельді таңдауда тек жалпы дәлдікке емес, recall, precision және F1-score көрсеткіштерінің теңгеріміне назар аудару қажет [21].

Модель сапасын бағалау үшін келесі формулалар қолданылады:

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP})$$

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN})$$

$$\text{F1-score} = 2 \times \text{Precision} \times \text{Recall} / (\text{Precision} + \text{Recall})$$

Бұл метрикалар модельдің жалған дабылдарды азайту, нақты күмәнді операцияларды өткізіп алмау және екі талап арасындағы теңгерімді сақтау қабілетін бағалауға мүмкіндік береді [21; 25].

Кәсіпкерлік білім беру және сапаны қамтамасыз ету тұрғысынан маңызы. Зерттеу нәтижелерінің практикалық маңызы тек қаржылық бақылаумен шектелмейді. Жеке кәсіпкерлер үшін цифрлық тәуекелдерді түсіну, деректерге негізделген шешім қабылдау және машиналық оқыту құралдарын сауатты қолдану кәсіпкерлік білім беру сапасының құрамдас бөлігіне айналып отыр. Сондықтан ұсынылған модель кәсіпкерлерді, бизнес-кеңесшілерді және экономика бағытындағы білім алушыларды цифрлық тәуекел-менеджмент негіздеріне оқытуда қолданылуы мүмкін [22; 23].

Бұл тұрғыдан мақала Education. Quality Assurance журналының бағытымен байланысады: зерттеу кәсіпкерлік шешімдердің сапасын арттыру, цифрлық құзыреттілікті дамыту және деректерге негізделген басқару мәдениетін қалыптастыру мәселелері [22; 23; 25].

ҚОРЫТЫНДЫ. Зерттеу нәтижесінде Қазақстандағы жеке кәсіпкерлік үшін алаяқтық пен экономикалық тәуекелдерді машиналық оқыту әдістері арқылы анықтау тақырыбы қазіргі кезеңде өте өзекті екені негізделді. Бұл өзектілік жеке кәсіпкерлердің шағын және орта кәсіпкерлік құрылымындағы жоғары үлесімен, электрондық коммерция көлемінің өсуімен және интернет-алаықтық жағдайларының артуымен байланысты [2; 3; 4].

Мақалада дәстүрлі ережелік тәсілдер мен машиналық оқыту әдістері салыстырылып, машиналық оқытудың негізгі артықшылықтары көрсетілді: жасырын байланыстарды анықтау, көп факторлы талдау, аномалиялық мінез-құлықты табу және тәуекел деңгейін сандық бағалау [6; 7; 13]. Ұсынылған модель жеке кәсіпкердің операцияларын талдау, күмәнді әрекеттерді анықтау және басқарушылық шешім қабылдау үшін қолданылуы мүмкін.

Ғылыми тұрғыдан алғанда, ұсынылған тәсіл алаяқтықты анықтауды тек техникалық классификация міндеті ретінде емес, жеке кәсіпкердің экономикалық тұрақтылығын қамтамасыз ететін тәуекел-менеджмент құралы ретінде қарастырады. Зерттеудің ғылыми жаңалығы жеке кәсіпкерлікке бейімделген тәуекел-индексті машиналық оқыту модельдерімен біріктіруде көрінеді.

Практикалық тұрғыдан модель кәсіпкерлерге, бизнес-кеңесшілерге, қаржылық бақылау мамандарына және кәсіпкерлік білім беру бағдарламаларына пайдалы болуы мүмкін. Болашақ зерттеулерде модельді нақты 6–12 айлық анонимделген операциялық деректер негізінде апробациялау, модельдердің F1-score, ROC-AUC, PR-AUC және confusion matrix көрсеткіштері бойынша салыстырмалы тиімділігін бағалау, сондай-ақ Қазақстандағы жеке кәсіпкерлерге бейімделген бағдарламалық прототип жасау қажет [17; 18; 19; 21].

СПИСОК ЛИТЕРАТУРЫ:

- Zhanys A.B., Tursinbaeva A.F. Internet Technology in Electronic Commerce // Journal of Physics: Conference Series. 2018. Vol. 1015, No. 3. Article 032154. DOI: 10.1088/1742-6596/1015/3/032154.
- Қазақстан Республикасы Стратегиялық жоспарлау және реформалар агенттігі Ұлттық статистика бюросы. Қазақстан Республикасындағы субъектілер санының негізгі көрсеткіштері. 2026 жылғы 1 сәуірдегі жағдай бойынша. URL: <https://stat.gov.kz/en/industries/business-statistics/stat-org/publications/480622/>
- Қазақстан Республикасы Стратегиялық жоспарлау және реформалар агенттігі Ұлттық статистика бюросы. E-commerce in the Republic of Kazakhstan, 2024. URL: <https://stat.gov.kz/en/industries/economy/local-market/publications/370122/>
- Қазақстан Республикасы Бас прокуратурасы. 2024 жылғы криминалендік жағдай туралы ақпарат. URL: <https://www.gov.kz/memleket/entities/prokuror/press/article/details/192800?lang=ru>
- Қазақстан Республикасының 2013 жылғы 21 мамырдағы № 94-V Заңы. Дербес деректер және оларды қорғау туралы. URL: <https://adilet.zan.kz/kaz/docs/Z1300000094>
- Ali A., Abd Razak S., Othman S.H., Eisa T.A.E., Al-Dhaqm A., Nasser M., Elhassan T., Elshafie H., Saif A. Financial Fraud Detection Based on Machine Learning: A Systematic Literature Review // Applied Sciences. 2022. Vol. 12, No. 19. Article 9637. DOI: 10.3390/app12199637.
- Hernandez Aros L., Bustamante Molano L.X., Gutierrez-Portela F., Moreno Hernandez J.J., Rodriguez Barrero M.S. Financial fraud detection through the application of machine learning techniques: a literature review // Humanities and Social Sciences Communications. 2024. Vol. 11. Article 1130. DOI: 10.1057/s41599-024-03606-0.
- West J., Bhattacharya M. Intelligent financial fraud detection: A comprehensive review // Computers & Security. 2016. Vol. 57. P. 47–66. DOI: 10.1016/j.cose.2015.09.005.
- Abdallah A., Maarof M.A., Zainal A. Fraud detection system: A survey // Journal of Network and Computer Applications. 2016. Vol. 68. P. 90–113. DOI: 10.1016/j.jnca.2016.04.007.
- Ahmed M., Mahmood A.N., Islam M.R. A survey of anomaly detection techniques in financial domain // Future Generation Computer Systems. 2016. Vol. 55. P. 278–288. DOI: 10.1016/j.future.2015.01.001.
- Phua C., Lee V., Smith K., Gayler R. A Comprehensive Survey of Data Mining-based Fraud Detection Research. arXiv:1009.6119, 2010. URL: <https://arxiv.org/abs/1009.6119>
- Reurink A. Financial fraud: A literature review // Journal of Economic Surveys. 2018. Vol. 32, No. 5. P. 1292–1325. DOI: 10.1111/joes.12294.
- Nassif A.B., Abu Talib M., Nasir Q., Dakalbab F.M. Machine Learning for Anomaly Detection: A Systematic Review // IEEE Access. 2021. Vol. 9. P. 78658–78700. DOI: 10.1109/ACCESS.2021.3083060.
- Randhawa K., Loo C.K., Seera M., Lim C.P., Nandi A.K. Credit Card Fraud Detection Using AdaBoost and Majority Voting // IEEE Access. 2018. Vol. 6. P. 14277–14284. DOI: 10.1109/ACCESS.2018.2806420.
- Bhattacharyya S., Jha S., Tharakunnel K., Westland J.C. Data mining for credit card fraud: A comparative study // Decision Support Systems. 2011. Vol. 50, No. 3. P. 602–613. DOI: 10.1016/j.dss.2010.08.008.
- Carta S., Fenu G., Recupero D.R., Saia R. Fraud detection for E-commerce transactions by employing a prudential Multiple Consensus model // Journal of Information Security and Applications. 2019. Vol. 46. P. 13–22. DOI: 10.1016/j.jisa.2019.02.007.
- Breiman L. Random Forests // Machine Learning. 2001. Vol. 45. P. 5–32. DOI: 10.1023/A:1010933404324.
- Chen T., Guestrin C. XGBoost: A Scalable Tree Boosting System // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2016. P. 785–794. DOI: 10.1145/2939672.2939785.
- Liu F.T., Ting K.M., Zhou Z.-H. Isolation Forest // Proceedings of the 2008 Eighth IEEE International Conference on Data Mining. 2008. P. 413–422. DOI: 10.1109/ICDM.2008.17.
- Chawla N.V., Bowyer K.W., Hall L.O., Kegelmeyer W.P. SMOTE: Synthetic Minority Over-sampling Technique // Journal of Artificial Intelligence Research. 2002. Vol. 16. P. 321–357. DOI: 10.1613/jair.953.
- Saito T., Rehmsmeier M. The Precision-Recall Plot Is More Informative than the ROC Plot When Evaluating Binary Classifiers on Imbalanced Datasets // PLOS ONE. 2015. Vol. 10, No. 3. e0118432. DOI: 10.1371/journal.pone.0118432.
- OECD. Financing SMEs and Entrepreneurs 2026: An OECD Scoreboard. Kazakhstan country profile. Paris: OECD Publishing, 2026. URL: <https://>

www.oecd.org/en/publications/financing-smes-and-entrepreneurs-2026_075d8058-en/full-report/kazakhstan_5434e382.html

23. OECD. OECD Digital Economy Outlook 2024. Volume 2: Strengthening Connectivity, Innovation and Trust. Paris: OECD Publishing, 2024.

24. Association of Certified Fraud Examiners. Occupational Fraud 2024: A Report to the Nations. Austin: ACFE, 2024.

25. Bishop C.M. Pattern Recognition and Machine Learning. New York: Springer, 2006.

REFERENCES:

1. Zhanyas A.B., Tursinbaeva A.F. Internet Technology in Electronic Commerce. Journal of Physics: Conference Series, 2018, vol. 1015, no. 3, article 032154. DOI: 10.1088/1742-6596/1015/3/032154.
2. Kazakhstan R. Strategiyalyk zhosparlau zhane reformalar agenttigi Ultyk statistika byurosy. Kazakhstan Respublikasyndagy subektler sanynyn negizgi korsetkishteri. 2026 zhylygy 1 sauirdegi zhagдай boiynsha [Main indicators of the number of entities in the Republic of Kazakhstan as of April 1, 2026]. Available at: <https://stat.gov.kz/en/industries/business-statistics/stat-org/publications/480622/>
3. Kazakhstan R. Strategiyalyk zhosparlau zhane reformalar agenttigi Ultyk statistika byurosy. E-commerce in the Republic of Kazakhstan, 2024. Available at: <https://stat.gov.kz/en/industries/economy/local-market/publications/370122/>
4. Kazakhstan R. Bas prokuraturasy. 2024 zhylygy kriminogendik zhagдай turaly akparat [Information on the criminogenic situation in 2024]. Available at: <https://www.gov.kz/memleket/entities/prokuror/press/article/details/192800?lang=ru>
5. Kazakhstan Respublikasynyn 2013 zhylygy 21 mamyrdaygy No. 94-V Zany. Derbes derekter zhane olardy korgau turaly [Law of the Republic of Kazakhstan on Personal Data and Their Protection]. Available at: <https://adilet.zan.kz/kaz/docs/Z1300000094>
6. Ali A., Abd Razak S., Othman S.H., Eisa T.A.E., Al-Dhaqm A., Nasser M., Elhassan T., Elshafie H., Saif A. Financial Fraud Detection Based on Machine Learning: A Systematic Literature Review. Applied Sciences, 2022, vol. 12, no. 19, article 9637. DOI: 10.3390/app12199637.
7. Hernandez Aros L., Bustamante Molano L.X., Gutierrez-Portela F., Moreno Hernandez J.J., Rodriguez Barrero M.S. Financial fraud detection through the application of machine learning techniques: a literature review. Humanities and Social Sciences Communications, 2024, vol. 11, article 1130. DOI: 10.1057/s41599-024-03606-0.
8. West J., Bhattacharya M. Intelligent financial fraud detection: A comprehensive review. Computers & Security, 2016, vol. 57, pp. 47–66. DOI: 10.1016/j.cose.2015.09.005.
9. Abdallah A., Maarof M.A., Zainal A. Fraud detection system: A survey. Journal of Network and Computer Applications, 2016, vol. 68, pp. 90–113. DOI: 10.1016/j.jnca.2016.04.007.
10. Ahmed M., Mahmood A.N., Islam M.R. A survey of anomaly detection techniques in financial domain. Future Generation Computer Systems, 2016, vol. 55, pp. 278–288. DOI: 10.1016/j.future.2015.01.001.
11. Phua C., Lee V., Smith K., Gayler R. A Comprehensive Survey of Data Mining-based Fraud Detection Research. arXiv:1009.6119, 2010. Available at: <https://arxiv.org/abs/1009.6119>
12. Reurink A. Financial fraud: A literature review. Journal of Economic Surveys, 2018, vol. 32, no. 5, pp. 1292–1325. DOI: 10.1111/joes.12294.
13. Nassif A.B., Abu Talib M., Nasir Q., Dakalbab F.M. Machine Learning for Anomaly Detection: A Systematic Review. IEEE Access, 2021, vol. 9, pp. 78658–78700. DOI: 10.1109/ACCESS.2021.3083060.
14. Randhawa K., Loo C.K., Seera M., Lim C.P., Nandi A.K. Credit Card Fraud Detection Using AdaBoost and Majority Voting. IEEE Access, 2018, vol. 6, pp. 14277–14284. DOI: 10.1109/ACCESS.2018.2806420.
15. Bhattacharyya S., Jha S., Tharakunnel K., Westland J.C. Data mining for credit card fraud: A comparative study. Decision Support Systems, 2011, vol. 50, no. 3, pp. 602–613. DOI: 10.1016/j.dss.2010.08.008.
16. Carta S., Fenu G., Recupero D.R., Saia R. Fraud detection for E-commerce transactions by employing a prudential Multiple Consensus model. Journal of Information Security and Applications, 2019, vol. 46, pp. 13–22. DOI: 10.1016/j.jisa.2019.02.007.
17. Breiman L. Random Forests. Machine Learning, 2001, vol. 45, pp. 5–32. DOI: 10.1023/A:1010933404324.
18. Chen T., Guestrin C. XGBoost: A Scalable Tree Boosting System. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2016, pp. 785–794. DOI: 10.1145/2939672.2939785.
19. Liu F.T., Ting K.M., Zhou Z.-H. Isolation Forest. Proceedings of the 2008 Eighth IEEE International Conference on Data Mining, 2008, pp. 413–422. DOI: 10.1109/ICDM.2008.17.
20. Chawla N.V., Bowyer K.W., Hall L.O., Kegelmeyer W.P. SMOTE: Synthetic Minority Over-sampling Technique. Journal of Artificial Intelligence Research, 2002, vol. 16, pp. 321–357. DOI: 10.1613/jair.953.
21. Saito T., Rehmsmeier M. The Precision-Recall Plot Is More Informative than the ROC Plot When Evaluating Binary Classifiers on Imbalanced Datasets. PLOS ONE, 2015, vol. 10, no. 3, e0118432. DOI: 10.1371/journal.pone.0118432.
22. OECD. Financing SMEs and Entrepreneurs 2026: An OECD Scoreboard. Kazakhstan country profile. Paris: OECD Publishing, 2026. Available at: https://www.oecd.org/en/publications/financing-smes-and-entrepreneurs-2026_075d8058-en/full-report/kazakhstan_5434e382.html
23. OECD. OECD Digital Economy Outlook 2024. Volume 2: Strengthening Connectivity, Innovation and Trust. Paris: OECD Publishing, 2024.
24. Association of Certified Fraud Examiners. Occupational Fraud 2024: A Report to the Nations. Austin: ACFE, 2024.
25. Bishop C.M. Pattern Recognition and Machine Learning. New York: Springer, 2006.

СВЕДЕНИЯ ОБ АВТОРАХ:

Шайнуров Абай Серикович, к.э.н., старший преподаватель кафедры «Экономика и управление», Кызылординский университет имени Коркыт Ата, Кызылорда, 120000, Казахстан. E-mail: kaup@mail.ru, <https://orcid.org/0000-0003-2009-9151>

Жаныс Арай Бошанкызы – к.п.н., доцент кафедры «Высшая математика», Российский государственный аграрный университет – МСХА имени К.А. Тимирязева, г. Москва, Россия. E-mail: zhanys@rgau-msha.ru. ORCID: 0000-0001-9242-414X.

Дюсембаева Лаззат Каиратовна, «Казахский агротехнический исследовательский университет имени С.Сейфуллина» НЕК АО, Институт Гуманитарно-педагогических наук, кафедра «Высшая математика», ORCID: <https://orcid.org/0000-0003-2950-8062>, Scopus ID: 5840530150

Рыскулова Жанар Ордабаевна, м.э.н., ст. преподаватель кафедры «Экономики и предпринимательства» Евразийского национального университета имени Л. Гумилева ryskulova_zho@enu.kz <https://orcid.org/0000-0002-8427-0571>

Шайнуров Абай Серикович, э.ф.к., «Экономика және басқару» кафедрасының аға оқытушысы, Қорқыт Ата атындағы Қызылорда университеті, Қызылорда, 120000, Қазақстан Республикасы. E-mail: kaup@mail.ru, <https://orcid.org/0000-0003-2009-9151>

Жаныс Арай Бошанкызы – п.ф.к., доцент, Ресей мемлекеттік аграрлық университеті – Мәскеу Тимирязев атындағы ауыл шаруашылығы академиясы, Мәскеу, Ресей. Электрондық пошта: zhanys@rgau-msha.ru. ORCID: 0000-0001-9242-414X.

Лаззат Қайратқызы Дюсембаева, С. Сейфуллин атындағы Қазақ агротехникалық зерттеу университеті, Гуманитарлық және педагогикалық ғылымдар институты, Жоғары математика кафедрасы, <https://orcid.org/0000-0003-2950-8062>, Scopus ID: 5840530150

Жанар Ордабайқызы Рыскулова, экономика ғылымдарының магистрі (экономика), Л. Гумилев атындағы Еуразия ұлттық университетінің экономика және кәсіпкерлік кафедрасының аға оқытушысы, ryskulova_zho@enu.kz <https://orcid.org/0000-0002-8427-0571>

Shainurov Abay Serikovich, candidate of economic sciences, senior lecturer at the Departments of Economics and Management, Korkyt Ata Kyzylorda University, Kyzylorda, 120000, Republic of Kazakhstan. E-mail: kaup@mail.ru, <https://orcid.org/0000-0003-2009-9151>

Zhanys Aray Boshankyzy – Candidate of Pedagogical Sciences, Associate Professor, Department of Higher Mathematics, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, Moscow, Russia. E-mail: zhanys@rgau-msha.ru. ORCID: 0000-0001-9242-414X.

Lazzat Kairatovna Dyusembayeva, S. Seifullin Kazakh Agrotechnical Research University, Institute of Humanitarian and Pedagogical Sciences, Department of Higher Mathematics, <https://orcid.org/0000-0003-2950-8062>, Scopus ID: 5840530150

Zhanar Ordabayeva Ryskulova, M.Sc. (Econ.), Senior Lecturer, Department of Economics and Entrepreneurship, L. Gumilyov Eurasian National University, ryskulova_zho@enu.kz <https://orcid.org/0000-0002-8427-0571>