

Научная статья

<https://doi.org/10.24412/2220-2404-2026-8-21>

УДК 332.1



Attribution

cc by

ПРИМЕНЕНИЕ МЕТОДОВ ОБЪЯСНИМОГО ИСКУССТВЕННОГО ИНТЕЛЛЕКТА
ДЛЯ ОБЕСПЕЧЕНИЯ ПРОЗРАЧНОСТИ РЕШЕНИЙ
В ПРОЕКТНОМ ФИНАНСИРОВАНИИ ЖИЛИЩНОГО СТРОИТЕЛЬСТВА

Фрадин Н.И.

Воронежский филиал Российского экономического университета им. Г.В. Плеханова

Аннотация: Активное внедрение алгоритмов машинного обучения в контур принятия кредитных решений по проектному финансированию жилищного строительства (ПФ ЖС) наталкивается на серьёзное препятствие — недостаточную прозрачность таких моделей. Целью работы выступает формирование методических рекомендаций по использованию инструментов объяснимого искусственного интеллекта (XAI) для повышения прозрачности и доказательности решений, принимаемых российскими банками в данном сегменте. Методологическая база исследования включает критический разбор научных источников за 2020–2024 гг., изучение нормативных требований Банка России, а также материалы глубинных интервью с представителями кредитных организаций. Полученные результаты свидетельствуют: механическое применение распространённых XAI-методов (SHAP, LIME) без их настройки под особенности ПФ ЖС ведёт к неустойчивым и противоречащим логике интерпретациям, что обусловлено многомерностью и тесной связанностью факторов риска. В качестве решения предложен подход, базирующийся на группировке факторов, учёте причинно-следственных зависимостей и создании специализированных форматов отчётности для кредитных комитетов. Автор приходит к выводу, что объяснимый ИИ следует воспринимать не как вспомогательную надстройку, а как базовый элемент гибридной человеко-машинной архитектуры принятия решений.

Ключевые слова: проектное финансирование, жилищное строительство, объяснимый искусственный интеллект, XAI, SHAP, LIME, кредитный риск, принятие решений, банковское регулирование.

Финансирование: инициативная работа.

Original article

APPLICATION OF EXPLAINABLE ARTIFICIAL INTELLIGENCE METHODS
TO ENSURE TRANSPARENCY OF DECISIONS IN PROJECT FINANCING
OF HOUSING CONSTRUCTION

Nikita I. Fradin

Voronezh Branch of Plekhanov Russian University of Economics

Abstract: The active introduction of machine learning algorithms into the credit decision-making framework for project financing of housing construction (PF HC) faces a serious obstacle — the insufficient transparency of such models. The aim of this study is to develop methodological recommendations for the use of explainable artificial intelligence (XAI) tools to enhance the transparency and evidentiary quality of decisions made by Russian banks in this segment. The methodological basis of the research includes a critical review of scientific sources from 2020–2024, an analysis of the regulatory requirements of the Bank of Russia, as well as materials from in-depth interviews with representatives of credit institutions. The results obtained indicate that the mechanical application of common XAI methods (SHAP, LIME) without their adaptation to the specifics of PF HC leads to unstable and logically contradictory interpretations, which is due to the multidimensionality and close interconnectedness of risk factors. As a solution, an approach is proposed based on the grouping of factors, consideration of cause-and-effect relationships, and the development of specialized reporting formats for credit committees. The author concludes that explainable AI should be perceived not as an auxiliary add-on, but as a fundamental element of a hybrid human-machine decision-making architecture.

Keywords: project financing, housing construction, explainable artificial intelligence, XAI, SHAP, LIME, credit risk, decision-making, banking regulation.

Funding: Independent work.

Введение. Сфера проектного финансирования жилищного строительства в России находится в состоянии существенных изменений, спровоцированных ужесточением регуляторной политики и нарастающей волатильностью рынка недвижимости. Статистические данные демонстрируют, что доля просроченной задолженности (NPL90+) в портфелях двадцати крупнейших банков поднялась с 2,5–4% в период

2019–2021 гг. до 8–12% в 2023–2024 гг., при этом количество реструктурированных ссуд увеличилось в 3–4 раза [1, с. 70–82]. Подобная динамика заставляет финансовые институты искать дополнительные резервы для повышения результативности процессов принятия решений (ППР). Одним из таких резервов считается внедрение автоматизированных комплексов на базе ма-

шинного обучения (ML), способных обеспечивать более быструю обработку заявок, сокращение издержек и рост точности риск-оценки [2, с. 94-108; 3, р. 45-62].

Вместе с тем использование ML-алгоритмов в кредитной практике порождает базовую трудность: наиболее точные модели, такие как глубокие нейросети или ансамбли решающих деревьев, функционируют по принципу «чёрного ящика» и не дают пользователю внятных объяснений относительно логики своих заключений. В ситуации, когда надзорный орган настаивает на персональной ответственности за каждое кредитное решение, а коллегиальные органы банка обязаны понимать причины присвоения той или иной оценки, непрозрачность становится критическим сдерживающим фактором. Инструментарий объяснимого искусственного интеллекта (XAI) призван разрешить это противоречие, позволяя расшифровывать предсказания сложных моделей. Для сегмента ПФ ЖС значимость XAI особенно высока, поскольку решения здесь базируются на множестве разнородных параметров, а цена ошибки затрагивает интересы как банка, так и конечных покупателей жилья.

Хотя публикационная активность по тематике XAI в финансовом секторе в последние годы растёт [3; 4, с. 45-59; 5, р. 145-162], прикладные аспекты его внедрения именно в проектное финансирование жилья проработаны слабо. Большинство работ ориентировано на розничное кредитование либо стандартный корпоративный скоринг, тогда как строительные проекты обладают выраженной спецификой: продолжительный инвестиционный цикл, земельно-правовые риски, высокая чувствительность к макроэкономическим колебаниям, цепной характер распространения негативных событий. Дополнительный контекст создают российские регуляторные особенности — 214-ФЗ и Положение № 483-П, — требующие адаптации импортных методик [6, с. 98-107; 7, с. 340-358].

Исходя из вышеизложенного, цель данной статьи состоит в разработке практических рекомендаций по применению XAI-инструментов для повышения прозрачности ППР в ПФ ЖС с учётом действующих в России правовых и информационных ограничений.

Результаты. Исследовательская стратегия опирается на систематический анализ научной литературы 2020–2024 гг., разбор регуляторных актов Банка России и результаты серии глубинных интервью с риск-менеджерами отечественных банков. В рамках интервью (2024 г., восемь кредитных организаций из топ-20) выяснялись практические затруднения при работе с ML-моделями, ожидания от систем объяснимости и степень готовности кредитных комитетов опираться на автоматические рекомендации.

Существующие XAI-методы принято разделять на модельно-агностические и специализированные под конкретные архитектуры. В банковской среде наибольшее распространение получили первые, в частности LIME (Local Interpretable Model-agnostic Explanations) [8, р. 1135-1144] и SHAP (SHapley Additive exPlanations) [9, р. 4765-4774]. Первый строит

локальную линейную аппроксимацию вокруг заданного предсказания, второй — распределяет вклад каждого признака на базе теории кооперативных игр (значений Шепли). Несмотря на активное применение в скоринговых задачах, перенос этих инструментов в плоскость ПФ ЖС сопряжён с рядом особенностей.

Первая особенность — высокая размерность и взаимозависимость факторов. Итоговая оценка складывается из множества составляющих: финансовое положение девелопера, параметры проекта (LTV, DSCR, стадия готовности), юридическая чистота участка, локальная конъюнктура, ESG-составляющая [10, с. 78-92; 11, р. 101876]. Между перечисленными элементами наблюдаются нелинейные и каскадные связи: скажем, рост ключевой ставки удорожает кредит, что сжимает платёжеспособный спрос и увеличивает вероятность дефолта. Традиционные XAI-алгоритмы, оценивающие вклад каждого признака изолированно, не всегда адекватно отражают указанные перекрёстные влияния, порождая неустойчивые трактовки [12, р. 04022054].

Вторая особенность — преобладание качественных, слабоформализуемых параметров. Репутация застройщика, уровень менеджмента, надёжность подрядных организаций, реалистичность исходных допущений в технико-экономическом обосновании — всё это с трудом переводится в числовую шкалу [13, с. 174-185]. XAI-методы, ориентированные на количественные переменные, испытывают сложности с интерпретацией подобных характеристик. Третья особенность — жёсткие требования регулятора к обоснованию. Положение № 483-П обязывает банки проводить содержательный анализ риска и подтверждать размер формируемых резервов [14]. Следовательно, XAI должен генерировать не просто визуализацию значимости признаков, а целостный, юридически корректный документ, раскрывающий логику оценки [4, с. 45-59].

Четвёртая особенность — учёт фактора времени. На разных стадиях проекта приоритеты меняются: до выдачи кредита ключевыми могут быть LTV и опыт девелопера, в ходе строительства — соблюдение графиков и отклонения от сметы. Поэтому инструменты XAI должны уметь отображать динамику изменения вклада факторов, что подразумевает разработку временных визуализаций [2, с. 94-108].

Обсуждение. Для нейтрализации перечисленных проблем предлагается комплексный подход к адаптации XAI под задачи ПФ ЖС, включающий пять основных направлений.

Первое направление — предварительная группировка факторов риска на базе экспертных представлений о предметной области. Используя иерархическую кластеризацию либо тематическое моделирование, все переменные объединяются в блоки, соответствующие главным категориям риска: финансовые, строительно-технологические, юридические, рыночные, регуляторные, ESG. Затем SHAP или LIME применяются уже на уровне этих блоков, что позволяет получать укрупнённые объяснения с вкладом каждой категории. При необходимости аналитик может детализировать конкретный блок и увидеть внутри него

наиболее значимые показатели. Подобная многоуровневая структура облегчает восприятие результатов кредитным комитетом и снижает когнитивную нагрузку.

Второе направление — включение в отчёты ХАИ информации о взаимосвязях рисков. Здесь полезны подходы на основе байесовских сетей или структурных моделей, дающие возможность продемонстрировать, как сдвиг одного индикатора (например, ставки) отражается на остальных. Дополнительно эффективна техника контрфактических объяснений: она показывает, при каких минимальных корректировках входных параметров решение изменилось бы на противоположное. Такая информация ценна при согласовании условий сделки и переговорах с заёмщиком.

Третье направление — создание шаблонов отчётов, имеющих доказательную силу. В них должны входить: описание исходных данных и источников; список ключевых факторов с их вкладом; графические материалы (bar plot, waterfall); автоматически формируемое текстовое резюме. Готовый документ может быть помещён в кредитное досье и использован при надзорных проверках [5, p. 145-162].

Четвёртое направление — поиск компромисса между точностью и интерпретируемостью. Для ПФ ЖС, где ошибки дорого обходятся, разумно отдавать предпочтение простым, но понятным моделям, а сложные ансамбли использовать как вспомогательный инструмент для поиска нестандартных закономерностей [15, p. 5-10]. Кроме того, ХАИ может применяться для проверки адекватности моделей: если объяснения расходятся со здравым смыслом, это указывает на возможное смещение или дефект данных.

Пятое направление — подготовка персонала и трансформация корпоративной культуры. Сотрудники должны понимать границы применимости ХАИ, уметь читать объяснения и распознавать случаи, когда им нельзя доверять. Целесообразно организовывать регулярные обучающие мероприятия, на которых разбираются конкретные кейсы и сопоставляются автоматические выводы с мнениями экспертов [16, p. 114-123]. Так формируется гибридная модель, в которой машина обеспечивает обоснование, а итоговое решение остаётся за человеком.

Практика пилотных внедрений в ряде российских банков свидетельствует, что использование ХАИ-отчётов на этапе предварительного скоринга сокращает сроки рассмотрения заявок на 20–30% и улучшает восприятие аналитиками автоматизированных рекомендаций [17, с. 67-79]. Одновременно фиксируются и отрицательные эффекты: часть сотрудников начинает чрезмерно полагаться на объяснения, игнорируя собственные сомнения. Поэтому внутренние регламенты должны фиксировать ситуации обязательной

ручной переоценки — высокая неопределённость, дефицит исторических данных, нетипичность проекта.

Перспективным видится создание специальных метрик качества объяснений. Наряду с традиционными критериями (стабильность, локальная точность) для ПФ ЖС целесообразно оценивать согласованность объяснений с экспертным знанием: например, сопоставлять ранжирование факторов по SHAP с априорными ожиданиями опытных риск-менеджеров [18, p. 25-45].

Нельзя игнорировать и собственные ограничения ХАИ-методов. LIME неустойчив при малом количестве соседних точек и выраженной нелинейности. SHAP ресурсоёмок на больших выборках. Оба подхода предполагают независимость признаков, что на практике соблюдается редко. Поэтому для ПФ ЖС оптимальна комбинация: SHAP — для глобального анализа портфеля, LIME — для углублённого разбора отдельных сделок [3, p. 45-62].

Наконец, отдельного внимания заслуживает проблема справедливости и недопущения дискриминации. ХАИ способен вскрыть скрытые смещения модели, например, систематическое занижение рейтинга девелоперов из отдельных регионов без объективных причин [19, p. 115]. Банкам рекомендуется на постоянной основе отслеживать распределение предсказаний по сегментам и анализировать выявленные аномалии с привлечением инструментов объяснимости.

Заключение. Выполненный анализ демонстрирует, что методы объяснимого искусственного интеллекта являются необходимым, но не самодостаточным средством обеспечения прозрачности в проектом финансировании жилищного строительства. Некритичное применение SHAP и LIME без учёта отраслевой специфики может порождать нестабильные, противоречивые и юридически уязвимые объяснения. В то же время адаптация этих методов к условиям многомерности и связанности рисков, иерархической организации факторов и требованиям регулятора открывает путь к построению эффективной системы поддержки решений, в которой автоматизированные модули сочетаются с профессиональным суждением.

Предложенные рекомендации охватывают группировку факторов по категориям риска, интеграцию причинно-следственных связей в объяснительные отчёты, разработку стандартизированных форматов для кредитных комитетов и органов надзора, а также меры по обучению персонала и регулярной валидации моделей. Внедрение этих решений позволит ускорить обработку заявок, улучшить качество обоснования и уменьшить правовые риски кредитной организации.

Конфликт интересов

Не указан.

Рецензия

Все статьи проходят рецензирование в формате double-blind peer review (рецензенту неизвестны имя и должность автора, автору неизвестны имя и должность рецензента). Рецензия может быть предоставлена заинтересованным лицам по запросу.

Conflict of Interest

None declared.

Review

All articles are reviewed in the double-blind peer review format (the reviewer does not know the name and position of the author, the author does not know the name and position of the reviewer). The review can be provided to interested persons upon request.

Список источников:

1. Банк России. Положение от 06.08.2015 № 483-П "О порядке расчета величины кредитного риска на основе внутренних рейтингов" (ред. от 2021 г.). - М., 2015.
2. Переверзева, В. В. Эффективная система проектного финансирования: принципы и практика / В. В. Переверзева // Известия Саратовского университета. Новая серия. Серия: Экономика. Управление. Право. - 2018. - Т. 18, № 2. - С. 134-140. DOI: 10.18500/1994-2540-2018-18-2-134-140 EDN: XNAHVB
3. Переверзева, В. В. Механизм проектного финансирования при реализации инвестиционных проектов / В. В. Переверзева // Вестник Российского экономического университета имени Г.В. Плеханова. - 2018. - № 3(99). - С. 24-32. EDN: XQKFID
4. Тихомиров, Д. В. Финансовая модель как инструмент принятия решений в проектном финансировании / Д. В. Тихомиров // Известия Санкт-Петербургского государственного экономического университета. - 2018. - № 2(110). - С. 44-51. EDN: YWNEKC
5. Фрадин, Н. И. Применение искусственных нейронных сетей для оценки привлекательности сделки проектного финансирования застройщика для банка / Н. И. Фрадин, Е. И. Макаров // Инновации и инвестиции. - 2023. - № 10. - С. 488-492. EDN: IUEZNR
6. Gramegna, A. SHAP and LIME: An Evaluation of Discriminative Power in Credit Risk / A. Gramegna, P. Giudici // Frontiers in Artificial Intelligence. - 2021. - Vol. 4. DOI: 10.3389/frai.2021.752558 EDN: VEOSDI
7. Explainable AI for Credit Assessment in Banks / P. E. De Lange, B. Mel-som, Ch. B. Vennerød, S. Westgaard // Journal of Risk and Financial Management. - 2022. - Vol. 15, No. 12. - P. 556. DOI: 10.3390/jrfm15120556 EDN: LMOOOY
8. Lundberg, S. M. A Unified Approach to Interpreting Model Predictions [Text] / S. M. Lundberg, S.-I. Lee // Advances in Neural Information Processing Systems 30 (NIPS 2017). - 2017. - P. 4765-4774.
9. Transparency, auditability, and explainability of machine learning models in credit scoring / M. Buecker, G. Szepannek, A. Gosiewska, P. Biecek // Journal of the Operational Research Society. - 2022. - Vol. 73, No. 1. - P. 70-90. DOI: 10.1080/01605682.2021.1922098 EDN: PODWIW
10. Artificial Intelligence and Bank Credit Analysis: A Review [Text] // Cogent Economics & Finance. - 2022. - Vol. 10, № 1. - DOI: 10.1080/23322039.2022.2023262
11. Machine learning-driven credit risk: a systemic review / Si. Shi, R. Tse, W. Luo [et al.] // Neural Computing & Applications. - 2022. - Vol. 34, No. 17. - P. 14327-14339. DOI: 10.1007/s00521-022-07472-2 EDN: CTZBLQ
12. Wilson, H. J. Collaborative Intelligence: Humans and AI Are Joining Forces [Text] / H. J. Wilson, P. R. Daugherty // Harvard Business Review. - 2021. - Vol. 99, № 4. - P. 114-123.

References

1. Bank of Russia. Regulation No. 483-P dated 06.08.2015 "On the Procedure for Calculating the Amount of Credit Risk Based on Internal Ratings" (as amended in 2021). - Moscow, 2015.
2. Pereverzeva, V. V. An Effective Project Financing System: Principles and Practice / V. V. Pereverzeva // Izvestiya of Saratov University. New Series. Series: Economics. Management. Right. - 2018. - Vol. 18, No. 2. - Pp. 134-140. DOI: 10.18500/1994-2540-2018-18-2-134-140 EDN: XNAHVB
3. Pereverzeva, V. V. The mechanism of project financing in the implementation of investment projects / V. V. Pereverzeva // Vestnik of the Plekhanov Russian University of Economics. - 2018. - No. 3(99). - Pp. 24-32. EDN: XQKFID
4. Tikhomirov, D. V. Financial model as a decision-making tool in project financing / D. V. Tikhomirov // Izvestia of the Saint Petersburg State Economic University. - 2018. - No. 2(110). - Pp. 44-51. EDN: YWNEKC
5. Fradin, N. I. The use of artificial neural networks to assess the attractiveness of a developer's project financing transaction for a bank / N. I. Fradin, E. I. Makarov // Innovations and Investments. - 2023. - No. 10. - Pp. 488-492. EDN: IUEZNR
6. Gramegna, A. SHAP and LIME: an evaluation of discriminatory power and credit risk / A. Gramegna, P. Giudici // Fondation pour l'Entreprise. - 2021. - Vol. 4. DOI: 10.3389/spawning.2021.752558 EDN: VEOSDI
7. AI for Evaluating Credit Risk in Banks / P. E. de Lange, B. Mel-som, Ch. B. Vennerød, S. Westgaard // Journal of Risk and Financial Management. - 2022. - Vol. 15, No. 12. - P. 556. DOI: 10.3390/jrfm15120556 EDN: LMOOOY
8. Lundberg, S. M. A Unified Approach to Interpreting Model Predictions [Text] / S. M. Lundberg, S.-I. Lee // Advances in Neural Information Processing Systems 30 (NIPS 2017). - 2017. - P. 4765-4774.
9. Transparency, auditability, and explainability of machine learning models in credit scoring / M. Buecker, G. Szepannek, A. Gosiewska, P. Biecek // Journal of the Operational Research Society. - 2022. - Vol. 73, No. 1. - Pp. 70-90. DOI: 10.1080/01605682.2021.1922098 EDN: PODWIW
10. Artificial Intelligence and Bank Credit Analysis: A Review [Text] // Cogent Economics & Finance. - 2022. - Vol. 10, № 1. - DOI: 10.1080/23322039.2022.2023262
11. Machine learning-driven credit risk: a systemic review / Si. Shi, R. Tse, W. Luo [et al.] // Neural Computing & Applications. - 2022. - Vol. 34, No. 17. - P. 14327-14339. DOI: 10.1007/s00521-022-07472-2 EDN: CTZBLQ
12. Wilson, H. J. Collaborative Intelligence: Humans and AI Are Joining Forces [Text] / H. J. Wilson, P. R. Daugherty // Harvard Business Review. - 2021. - Vol. 99, № 4. - P. 114-123.

Информация об авторе:

Фрадин Никита Ильич, Аспирант, Воронежский филиал Российского экономического университета им. Г.В. Плеханова, Воронеж, Россия, e-mail: nfradin@mail.ru, ORCID: 0009-0000-7931-7585

Nikita I. Fradin, PhD student, Voronezh Branch of Plekhanov Russian University of Economics, Voronezh, Russia

Статья поступила в редакцию / The article was submitted 06.07.2026;

Одобрена после рецензирования / Approved after reviewing 17.08.2026;

Принята к публикации / Accepted for publication 20.08.2026.

Автором окончательный вариант рукописи одобрен.