

Научно-исследовательский журнал «Экономический вестник / *Economic Bulletin*»
<https://eb-journal.ru>
2025, Том 4 № 6 2025, Vol. 4. Iss. 6 <https://eb-journal.ru/archives/category/publications>
Научная статья / Original article
УДК 336.051



¹ Лукичёв М.А.,

¹ *Московский финансово-промышленный университет Синергия*

Разработка модели прогноза чистого долга компаний-застройщиков с использованием машинного обучения

Аннотация: в условиях системного кризиса российского строительного сектора, обусловленного рекордной долговой нагрузкой и высокой стоимостью заёмных средств, актуальной становится задача проактивной оценки финансовых рисков застройщиков многоквартирного жилья. В статье представлена прогнозная модель чистого долга, разработанная на основе методов машинного обучения и обученная на данных российских публичных компаний-застройщиков. Модель учитывает ключевые предикторы риска, такие как уровень чистого долга в предыдущем периоде и темпы его изменения. Результаты подтверждают, что величина чистого долга компаний – застройщиков определяется преимущественно внутренней динамикой, а не макроэкономической конъюнктурой. Предложенный инструмент может служить основой для системы раннего предупреждения о дефолтах и поддержки финансовой устойчивости строительной отрасли.

Ключевые слова: финансовые риски, застройщики многоквартирного жилья, прогноз чистого долга, машинное обучение

Для цитирования: Лукичёв М.А. Разработка модели прогноза чистого долга компаний-застройщиков с использованием машинного обучения // Экономический вестник. 2025. Том 4. № 6. С. 65 – 74.

Поступила в редакцию: 16 сентября 2025 г.; Одобрена после рецензирования: 14 ноября 2025 г.; Принята к публикации: 28 декабря 2025 г.

¹ *Lukichev M.A.,*

¹ *Moscow Financial and Industrial University Synergy*

Development of a model for forecasting the net debt of real estate developers using machine learning

Abstract: in the context of the systemic crisis in the Russian construction sector caused by the record debt burden and high cost of borrowed funds, the task of proactive assessment of financial risks of developers of multi-apartment housing becomes urgent. The article presents a predictive net debt model developed based on machine learning methods and trained on data from Russian public real estate companies. The model takes into account key risk predictors, such as the level of net debt in the previous period and the rate of its change. The results confirm that the amount of net debt of real estate developers is determined mainly by internal dynamics, rather than by macroeconomic conditions. The proposed tool can serve as the basis for an early warning system for defaults and support for the sustainability of the construction industry.

Keywords: financial risks, multi-apartment housing developers, net debt forecast, machine learning

For citation: Lukichev M.A. Development of a model for forecasting the net debt of real estate developers using machine learning. Economic Bulletin. 2025. 4 (6). P. 65 – 74.

The article was submitted: September 16, 2025; Approved after reviewing: November 14, 2025; Accepted for publication: December 28, 2025.

Введение

Разработка модели прогнозирования долговой нагрузки застройщиков многоквартирных домов (МКД) является важным инструментом проактивного управления финансовыми рисками в условиях экономической турбулентности, в которой находится российский строительный сектор. Девелоперская отрасль столкнулась с системным кризисом, обусловленным совокупностью макроэкономических шоков и изменений государственной политики.

Согласно данным Центра макроэкономического анализа и краткосрочного прогнозирования (ЦМАКП), по состоянию на осень 2025 года чистый долг застройщиков превысил их прибыль в шесть раз [1]. Данный показатель представляет собой один из наиболее высоких среди отраслей российской экономики наряду с автомобильной промышленностью (пять к одному) и судостроением, где соотношение чистого долга к прибыли составляет около четырех к одному [2]. Подобный уровень долговой нагрузки свидетельствует о высокой зависимости отрасли от заемного капитала и, как следствие, о повышенной чувствительности к колебаниям стоимости заёмных средств.

Особую обеспокоенность вызывает тот факт, что на обслуживание долга российские компании в среднем направляют более 36 % своей прибыли – максимальный за всю историю наблюдений ЦМАКП показатель. Рост процентных расходов напрямую обусловлен сохраняющейся высокой ключевой ставкой Банка России и доминированием в кредитных портфелях крупнейших банков займов с плавающей процентной ставкой, доля которых достигает 75 % [3].

Несмотря на формально положительную рентабельность, существенная часть операционной прибыли направляется на выплату процентов по долговым обязательствам, что фактически нивелирует операционную эффективность и снижает финансовую устойчивость предприятий-застройщиков. Высокий уровень долговой нагрузки является важным параметром, который увеличивает риск для собственников компании, который невозможно хеджировать т.к. грозит неисполнением обязательств [4].

В этих условиях традиционные подходы к финансовому и риск-анализу, основанные исключительно на ретроспективной оценке показателей чистого долга, демонстрируют ограниченную прогностическую ценность, что обуславливает необходимость разработки специализированной модели прогноза чистого долга, способной учитывать внутренние и экзогенные факторы для корректной оценки финансовых рисков.

Материалы и методы исследований

Системные риски, возникающие в строительном секторе, не ограничиваются отдельными компаниями и представляют угрозу для финансовой системы страны. Аналитики Capital Economics [5] отмечают, что Россия находится в зоне повышенных рисков, что связано с высоким объемом дефолтов по корпоративным облигациям, как представлено на рис. 1.




Рис. 1. Статистика корпоративных дефолтов по облигациям российских компаний. Источник: [6].

Fig. 1. Statistics of corporate defaults on bonds of Russian companies. Source: [6].

Результаты и обсуждения

В 2024 г. количество дефолтов снизилось до 167 шт. (на 15,65% к 2023 г.), но объем вырос до 89,2 млрд руб. (+32% к 2023 г.). Такая динамика указывает на увеличение среднего размера дефолта (средний объем на один дефолт вырос с 340 млн руб. в 2023 г. до 534 млн руб. в 2024 г.).

На рис. 2 представлен отраслевой срез дефолтов по корпоративным облигациям. Основная их доля приходится на финансовый сектор (35%) и сферу недвижимости (25%), которые вместе составляют 60% от общего числа.

Также в корпоративном секторе наблюдается рост просроченной задолженности с 17% до 23% за последний год, а доля убыточных организаций достигла 30%, что является максимальным показателем с 2020 г. [7].




Рис. 2. Отраслевая дефолтов по корпоративным облигациям Источник: Анализ дефолтов облигационного рынка [Электронный ресурс] / SDF Solutions. URL: <https://sdf-solutions.com/defaults/> (дата обращения: 02.09.2025).

Fig. 2. Industry defaults on corporate bonds Source: Analysis of bond market defaults [Electronic resource] / SDF Solutions. URL: <https://sdf-solutions.com/defaults/> (date of access: 09.02.2025).

Представленные данные подтверждают актуальность финансового риск-менеджмента и обуславливают необходимость перехода от ретроспективного анализа к прогностическим моделям оценки долговой нагрузки, что особенно важно в контексте финансового планирования и формирования финансово-инвестиционных ожиданий.

Прогнозирование долговой нагрузки может осуществляться с применением двух основных подходов: финансового моделирования и математического (статистического или машинного) моделирования. Первый подход применим при наличии доступа к внутренним планам компании и предполагает детализированное проектирование её денежных потоков, тогда как второй опирается на внешние данные и может варьироваться от классических эконометрических методов до современных алгоритмов машинного обучения.

Финансовые модели [8; 9] строятся на основе прогноза операционных, инвестиционных и финансовых потоков с дискретностью – по месяцам, кварталам или годам. В них учитываются ожидаемые поступления от дольщиков, выплаты по кредитам (включая проценты), инвестиции в новые объекты недвижимости, а также возврат и привлечение заёмных средств. Результатом является детальная динамика долговой нагрузки и ликвидности, позволяющая сформировать различные сценарии развития: «базовый», «оптимистичный» и «стрессовый». В такие сценарии также закладываются риски, связанные с недоисполнением планов по продажам, колебаниями процентных ставок, изменениями стоимости квадратного метра и отклонениями в темпах строительства. Вместе с тем, точность финансового моделирования зависит от качества исходных предпосылок, а разработчик модели может не обладать полной информацией о реальных намерениях компании относительно привлечения новых займов, что потенциально ведёт к смещению прогноза.

На уровне корпоративного финансового контроля и риск-менеджмента часто применяются статистические методы [10], ориентированные на выявление ранних сигналов ухудшения финансовой устойчивости. Одним из таких опережающих индикаторов выступает прогноз чистого долга. Однако традиционные эконометрические модели, основанные на линейных зависимостях, зачастую оказываются недостаточными для адекватного отражения сложной, нелинейной природы взаимосвязей между финансовыми показателями, макроэкономической средой и отраслевой динамикой.

В этой связи особое значение приобретают методы машинного обучения [11; 12], способные эффективно моделировать сложные и нелинейные взаимодействия между предикторами. Эмпирические исследования [12; 13; 14] демонстрируют, что алгоритмы, такие как случайный лес (Random Forest), значительно превосходят классические подходы – например, линейную или логистическую регрессию в задачах прогнозирования дефолтов, оценки кредитных рисков или динамики рыночных цен, особенно в условиях ограниченного набора публично доступных финансовых данных.

Успешность любой модели машинного обучения, особенно в такой сложной и динамичной области, как прогнозирование долговой нагрузки застройщиков, напрямую зависит от качества и полноты используемых предикторов (признаков). Для создания комплексной и надежной модели необходимо собрать данные по нескольким взаимосвязанным уровням: макроэкономическому, отраслевому и корпоративному. Такой многоуровневый подход позволит учесть как общую экономическую конъюнктуру, так и специфику деятельности конкретной компании, что является залогом повышения точности и практической применимости прогноза.

В качестве объектов исследования отобраны компании – российские застройщики, публикующие финансовую отчетность в соответствии с Международными стандартами финансовой отчетности (МСФО). Данные охватывают период с 2011 года по первую половину 2025 года. Формирование набора предикторов требует системного подхода, сочетающего сбор данных из множества источников и тщательной подготовки, как представлено в табл. 1. Общий объем выборки составил 346 наблюдений.

Таблица 1

Предикторы, используемые для прогноза чистого долга компаний – застройщиков.

Table 1

Predictors used to forecast net debt of real estate developers.

Категория предикторов	Переменные	Источник
1	2	
Макроэкономические	Курс золота, установленный Банком России, р.	Cbonds.ru [15]
	Ключевая ставка Банка России на каждый рабочий день	
	Средневзвешенные процентные ставки по кредитам, предоставленным ЮЛ в рублях свыше 3 лет, %	
	ИПЦ к предыдущему месяцу: Базовый индекс потребительских цен	
	Курс рубля к доллару USD/RUB (Банк России), р.	
	Россия PMI в производственном секторе	
	Россия уровень базовой инфляции в годовом выражении, %	
Отраслевые	Количество заключенных договоров участия в долевом строительстве (ДДУ) в отношении жилой недвижимости в Москве, шт.	Ростреестр [16], по результатам поиска информации в СМИ автором
	Общая сумма кредитов по льготным ипотечным программам, Россия, млрд. р.	ДОМ.РФ [17]
	Количество предоставленных ИЖК, под залог прав требования по ДДУ за месяц в рублях	Cbonds.ru
Финансовые	Показатели отчета о прибылях и убытках, отчета о движении денежных средств и баланса	Financemarket.ru [18]

Целевой переменной модели выступает чистый долг, рассчитываемый как сумма всех обязательств застройщика включая обязательства по проектному финансированию за вычетом денежных средств и остатков на эскроу-счетах. Статистические свойства целевой переменной представлены на рис. 3.

По представленном рис. 3 можно сделать вывод о скошенности распределения и наличия в выборке отрицательных значений, что обусловлено наличием денежных средств на балансе компаний в отдельные периоды времени.




Рис. 3. Гистограмма распределения чистого долга компаний-застройщиков, млрд руб. Источник: разработано автором в Python по данным [18].

Fig. 3. Histogram of distribution of net debt of construction companies, billion rubles. Source: developed by the author in Python based on data from [18].

Важным этапом предобработки данных для обучения модели является обработка пропущенных значений. По целевой переменной доля пропусков составляет 0,289%, что не представляет существенной проблемы с точки зрения её статистических свойств. Пропущенные наблюдения заменены медианой целевой переменной – подход, особенно оправданный при асимметричном распределении данных, поскольку медиана устойчивее к влиянию выбросов по сравнению со средним значением. Для остальных признаков пропущенные значения отсутствуют.

На следующем этапе проведена трансформация целевой переменной с применением метода QuantileTransformer [19], поскольку в исходном масштабе показатель чистого долга характеризуется выраженной правосторонней асимметрией, значительным разбросом значений и наличием отрицательных величин.

На следующем этапе сгенерированы лаговые признаки (отставания), что представляет собой ключевой шаг при построении моделей на основе временных рядов. Поскольку прогнозирование будущих значений осуществляется на основе исторических данных, в модель вводятся переменные, отражающие значения показателей на предыдущем временном шаге. В ходе этого этапа используются лаговые переменные для макроэкономических, отраслевых показателей и чистого долга (абсолютное и относительное его изменение).

При построении моделей прогнозирования временных рядов, таких как долговая нагрузка застройщиков, корректная кросс-валидация имеет решающее значение. Стандартные методы машинного обучения (например, KFold) недопустимы, так как нарушают хронологическую последовательность и вызывают «утечку информации из будущего», что приводит к необъективно завышенной оценке качества модели.

Единственно корректный подход – использование TimeSeriesSplit [20], который разбивает данные на последовательные временные блоки: модель обучается на прошлых данных и тестируется на последующих, что имитирует реальные условия прогнозирования. В данном исследовании применено 4 фолда, где каждый последующий обучающий набор расширяется за счёт предыдущих периодов, а тестовый всегда следует за ним во времени.

Для одновременной оценки качества модели и подбора гиперпараметров использовалась вложенная кросс-валидация: во внешнем цикле данные разделяются на обучающую и тестовую части, а во внутреннем – с использованием TimeSeriesSplit и GridSearchCV подбираются оптимальные параметры. Такой подход обеспечивает несмещённую оценку обобщающей способности модели и полное сохранение временной структуры данных на всех этапах.

После разделения выборки на тестовую и обучающую выполнено обучение модели случайного леса (RF) с количеством деревьев 500 и глубиной 6. «Модель случайного леса (Random Forest) соединяет множество решающих деревьев в целях улучшения качества прогнозирования. Каждое дерево строится независимо друг от друга, что позволяет уменьшить переобучение и повысить обобщающую способность модели» [11].

Для оценки качества модели при валидации и тестировании использовались средняя абсолютная ошибка (MAE) [21] и коэффициент детерминации (R2) [22].

Модель прогнозирования чистого долга показала хорошее качество: коэффициент детерминации равен 0,68 (объясняет 68% изменчивости показателя), а средняя абсолютная ошибка MAE = 0,11. Учитывая, что целевая переменная была нормирована в диапазоне от 0 до 1, ошибка прогноза составляет около 11% от полного диапазона значений.

Анализ на четырёх фолдах кросс-валидации (с использованием TimeSeriesSplit) подтвердил, что модель улавливает общую динамику и тренды трансформированного чистого долга, однако точность снижается в периоды высокой волатильности, как представлено на рис. 4.

Фактические и прогнозные значения net_debt_qt (с лагами макропоказателей)

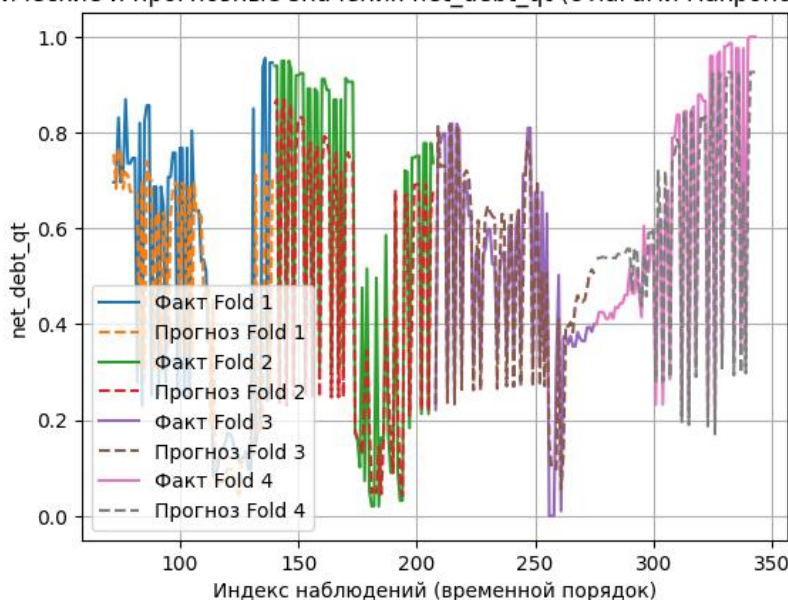


Рис. 4. Фактические и прогнозные значения чистого долга. Источник: разработано автором в Python.

Fig. 4. Actual and projected net debt values. Source: developed by the author in Python.

Анализ значимости признаков модели прогнозирования чистого долга (рис. 5) показал, что два ключевых фактора – изменение чистого долга в абсолютном (net_debt_lag1, 48,6%) и относительном изменении (net_debt_change, 46,6%) вместе объясняют 95,2% важности модели.

Net_debt_lag1 подтверждает сильную инерционность долговой нагрузки: текущий уровень долга в основном определяется его значением в предыдущем периоде. Net_debt_change демонстрирует, что динамика долга (темпы роста или снижения) является важным риск-индикатором компании с ускоряющимся ростом долга значительно более уязвимы, даже при сопоставимом абсолютном уровне задолженности.

В совокупности это указывает на то, что финансовое состояние компании определяется в первую очередь её внутренней историей и динамикой, и в меньшей степени внешней макроэкономической конъюнктурой. Таким образом, устойчивость бизнеса в текущих условиях зависит преимущественно от его способности управлять денежными потоками и долговыми обязательствами.




Рис. 5. Значимость признаков в модели прогноза чистого долга. Источник: разработано автором в Python.

Fig. 5. Significance of features in the net debt forecasting model. Source: developed by the author in Python.

Результаты апробации модели на примере компании ПАО «Самолет» показывают адекватный результат работы модели, как представлено в табл. 2.

Таблица 2

Апробация модели прогнозирования чистого долга на примере компании-застройщика ПАО Самолет.

Table 2

Testing the net debt forecasting model using the example of the construction company PAO Samolet.

Показатель	Значение на середину 2025 года	Источник
Курс золота, р. за грамм	8515,426	Cbonds.ru [15]
Курс USD/RUB (р. за долл., в среднем)	84,86	
Ключевая ставка Банка России на каждый рабочий день	21	
ИПЦ к предыдущему месяцу: Базовый индекс потребительских цен	100,49	
Инфляционная база, %	8,84	
Россия PMI в производственном секторе	49,15	
Количество заключенных договоров участия в долевом строительстве (ДДУ) в отношении жилой недвижимости в Москве, шт.	9137	Ростреестр [16], по результатам поиска информации в СМИ автором
Общая сумма кредитов по льготным ипотечным программам, Россия, млрд р.	15,13	ДОМ.РФ [17]
Значение чистого долга компании по бухгалтерской отчетности за 6 месяцев 2025, тыс. руб.	249 236 632	Financemarket.ru [18]

Продолжение таблицы 2
Continuation of Table 2

Прогноз модели		
Ожидаемый чистый долг компании на 2026 год, тыс. руб.	130 172 226	Расчет по разработанной модели

Согласно проведенным расчётам, прогнозное значение чистого долга составляет 130 172 226 тыс. рублей. Данный результат следует рассматривать как оценку будущей долговой нагрузки компании при условии сохранения сложившихся макроэкономических тенденций и неизменности текущей внутренней финансовой политики.

Выводы

Подводя итог проведенному исследованию, можно сделать вывод, что разработка модели прогноза чистого долга застройщиков с использованием машинного обучения является своевременной, значимой и практически осуществимой задачей. Российский строительный сектор находится в состоянии системного кризиса, обусловленного высокой долговой нагрузкой, резким ростом стоимости заимствований и коррекцией спроса. В этих условиях создание проактивной системы раннего предупреждения о финансовом риске становится не просто желательным, а необходимым условием для стабилизации отрасли и минимизации системных рисков для всей финансовой системы страны. Представленная модель прогнозирования чистого долга компаний-застройщиков предлагает комплексный подход к решению этой задачи. Благодаря использованию методов машинного обучения, в частности алгоритмов, способных улавливать нелинейные зависимости и временные паттерны, модель демонстрирует высокую прогностическую способность ($R^2 = 0,68$) и устойчивость к переобучению при корректной кросс-валидации на временных рядах.

Ключевым практическим преимуществом разработанного инструмента является его ориентация на раннее выявление ухудшения финансового состояния застройщиков задолго до наступления дефолта. Это открывает возможности для своевременного вмешательства со стороны регуляторов, инвесторов и самих компаний: от реструктуризации долгов до корректировки инвестиционной стратегии.

В перспективе возможно улучшение модели за счет включения дополнительных источников данных (например, операционных показателей проектов или ESG-факторов), что позволит повысить её прогностическую ценность в условиях нестабильной экономической среды.

Список источников

1. Долги застройщиков в шесть раз превысили прибыль к осени 2025 года [Электронный ресурс] // Московская Перспектива. 2025. 5 ноября. URL: <https://mperspektiva.ru/topics/dolgi-zastroyschikov-v-shest-raz-prevysili-pribyl-k-oseni-2025-goda/> (дата обращения: 02.09.2025)
2. Максимальную долговую нагрузку несут предприятия в строительстве, деревообработке и автопроме [Электронный ресурс] // SALT News. 2025. 6 ноября. URL: <https://salt.news/promishlennost/maksimalnuyu-dolgovuyu-nagruzku-nesut-predpriyatiya-v-stroitelstve-derevoobrabotke-i-avtoprome/> (дата обращения: 02.09.2025)
3. Долговая нагрузка застройщиков России достигла максимума за год [Электронный ресурс] // International Investment. URL: <https://internationalinvestment.biz/business/6409-dolgovaja-nagruzka-zastroyschikov-rossii-dostigla-maksimuma-za-god.html> (дата обращения: 02.09.2025)
4. Modigliani F., Miller M.H. The Cost of Capital, Corporation Finance and the Theory of Investment // The American Economic Review. 1958. Vol. 48. No. 3. P. 261 – 297. URL: <http://www.jstor.org/stable/1809766> (дата обращения: 02.09.2025)
5. Russia: are financial stability risks starting to crystallise? [Электронный ресурс] / Capital Economics. URL: <https://www.capitaleconomics.com/publications/emerging-europe-economics-update/russia-are-financial-stability-risks-starting> (дата обращения: 02.09.2025)
6. Анализ дефолтов облигационного рынка [Электронный ресурс] / SDF Solutions. URL: <https://sdf-solutions.com/defaults/> (дата обращения: 02.09.2025)
7. Долги застройщиков в шесть раз превысили прибыль к осени 2025 года [Электронный ресурс] // Московская Перспектива. 2025. 5 ноября. URL: <https://mperspektiva.ru/topics/dolgi-zastroyschikov-v-shest-raz-prevysili-pribyl-k-oseni-2025-goda/> (дата обращения: 02.09.2025)
8. Помулев А.А. Методические аспекты прогнозирования денежных потоков при проектном финансировании сферы жилой недвижимости // Российский экономический интернет-журнал. 2020. № 2. С. 45.

9. Граница Ю.В. Применение эконометрических моделей в прогнозировании показателей финансовой отчетности // Инновационное развитие экономики. Будущее России : материалы и доклады VI Всероссийской (национальной) научно-практической конференции, Княгинино, 18 апреля 2019 года. Т. 1. Княгинино: Нижегородский государственный инженерно-экономический институт, 2019. С. 51 – 55.

10. Федорова Е.А., Довженко С.Е. Модели прогнозирования банкротства предприятий строительной отрасли и отрасли сельского хозяйства // Эффективное антикризисное управление. 2014. № 6 (87). С. 94 – 99.

11. Стерник С.Г., Тютюкина Е.Б., Помулев А.А. Оценка рисков проектов государственно-частного партнерства с использованием алгоритмов искусственного интеллекта // МИР (Модернизация. Инновации. Развитие). 2024. Т. 15. № 3. С. 421 – 438. DOI 10.18184/2079-4665.2024.15.3.421-438

12. Горохов А.Д., Помулев А.А. Развитие методов оценки рисков проектов в нефтегазовой отрасли с использованием машинного обучения // Таможенные чтения – 2023: Новые реалии внешнеэкономической деятельности: взгляд таможни, бизнеса и науки: Сборник материалов Международной научно-практической конференции, Санкт-Петербург, 21–23 ноября 2023 года. Санкт-Петербург: Российская таможенная академия, 2023. С. 48 – 54.

13. Moscatelli M., Parlapiano F., Narizzano S., Viggiano G. Corporate default forecasting with machine learning [Electronic resource] // Expert Systems with Applications. 2020. Vol. 161. P. 113567. DOI: 10.1016/j.eswa.2020.113567. URL: <https://www.sciencedirect.com/science/article/abs/pii/S0957417420303912>

14. Помулев А.А. Разработка метода прогнозирования стоимости бизнеса публичных компаний в рамках сравнительного подхода с использованием искусственного интеллекта. Финансы: теория и практика/Finance: Theory and Practice. <https://doi.org/10.26794/2587-5671-2026-30-3-1862-02>

15. Cbonds. Финансовые индексы и аналитика [Электронный ресурс]. URL: <https://cbonds.ru/> (дата обращения: 18.09.2025)

16. Росреестр. За восемь месяцев в столице оформлено максимальное число первичных договоров [Электронный ресурс]. URL: <https://rosreestr.gov.ru/press/archive/za-vosem-mesyatsev-v-stolitse-oformleno-maksimalnoe-chislo-pervichnykh-dogovorov/> (дата обращения: 18.08.2025)

17. Дом.РФ. Единая отчетность по льготному ипотечному кредитованию [Электронный ресурс]. URL: <https://дом.рф/programmy-gosudarstvennoj-podderzhki/report/> (дата обращения: 18.09.2025)

18. Скринер акций РФ и США Finance Marker. URL: <https://financemarker.ru/stocks/?exchange=MOEX> (дата обращения: 18.09.2025)

19. QuantileTransformer – scikit-learn 1.6.1 documentation [Электронный ресурс]. URL: <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.QuantileTransformer.html> (дата обращения: 04.09.2025)

20. TimeSeriesSplit – scikit-learn 1.6.1 documentation [Электронный ресурс]. URL: https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.TimeSeriesSplit.html (дата обращения: 04.09.2025)

21. Mean absolute error: сайт. DOI отсутствует. URL: https://scikit-learn.org/stable/modules/generated/sklearn.metrics.mean_absolute_error.html (дата обращения: 20.08.2025)

22. Scikit-learn. R2 score: сайт. DOI отсутствует. URL: https://scikit-learn.org/stable/modules/generated/sklearn.metrics.r2_score.html (дата обращения: 20.09.2025)

References

1. Developers' debt exceeded profits sixfold by autumn 2025 [Electronic resource]. Moskovskaya Perspektiva. 2025. November 5. URL: <https://mperspektiva.ru/topics/dolgi-zastroyschikov-v-shest-raz-prevysili-pribyl-koseni-2025-goda/> (date of access: 09.02.2025)

2. Enterprises in construction, woodworking, and the automotive industry bear the maximum debt burden [Electronic resource]. SALT News. 2025. November 6. URL: <https://salt.news/promishlennost/maksimalnuyu-dolgovuyu-nagruzku-nesut-predpriyatiya-v-stroitelstve-derevoobrabotke-i-avtoprome/> (date of access: 09.02.2025)

3. The debt burden of Russian developers reached a one-year maximum [Electronic resource]. International Investment. URL: <https://internationalinvestment.biz/business/6409-dolgovaja-nagruzka-zastroyschikov-rossii-dostigla-maksimuma-za-god.html> (date of access: 09.02.2025)

4. Modigliani F., Miller M.H. The Cost of Capital, Corporation Finance and the Theory of Investment. The American Economic Review. 1958. Vol. 48. No. 3. P. 261 – 297. URL: <http://www.jstor.org/stable/1809766> (accessed on September 2, 2025)

5. Russia: Are Financial Stability Risks Starting to Crystallize? [Electronic resource]. Capital Economics. URL: <https://www.capitaleconomics.com/publications/emerging-europe-economics-update/russia-are-financial-stability-risks-starting> (date of access: 09.02.2025)

6. Analysis of Bond Market Defaults [Electronic resource]. SDF Solutions. URL: <https://sdf-solutions.com/defaults/> (date of access: 09.02.2025)
7. Developers' Debts Exceeded Profits Six Times by Autumn 2025 [Electronic resource]. Moskovskaya Perspektiva. 2025. November 5. URL: <https://mperspektiva.ru/topics/dolgi-zastroyshchikov-v-shest-raz-prevysili-pribyl-k-oseni-2025-goda/> (date of access: 02.09.2025)
8. Pomulev A.A. Methodological aspects of cash flow forecasting in project financing of residential real estate. Russian Economic Internet Journal. 2020. No. 2. P. 45.
9. Granitsa Yu.V. Application of econometric models in forecasting financial statement indicators. Innovative development of the economy. The future of Russia: materials and reports of the VI All-Russian (national) scientific and practical conference, Knyaginino, April 18, 2019. T. 1. Knyaginino: Nizhny Novgorod State Engineering and Economic Institute, 2019. P. 51 – 55.
10. Fedorova E.A., Dovzhenko S.E. Bankruptcy Forecasting Models for Enterprises in the Construction and Agricultural Industries. Effective Crisis Management. 2014. No. 6 (87). P. 94 – 99.
11. Sternik S.G., Tyutyukina E.B., Pomulev A.A. Risk Assessment of Public-Private Partnership Projects Using Artificial Intelligence Algorithms. MIR (Modernization. Innovation. Development). 2024. Vol. 15. No. 3. P. 421 – 438. DOI 10.18184/2079-4665.2024.15.3.421-438
12. Gorokhov A.D., Pomulev A.A. Development of methods for assessing project risks in the oil and gas industry using machine learning. Customs Readings – 2023: New realities of foreign economic activity: the view of customs, business and science: Collection of materials from the International scientific and practical conference, St. Petersburg, November 21-23, 2023. St. Petersburg: Russian Customs Academy, 2023. P. 48 – 54.
13. Moscatelli M., Parlapiano F., Narizzano S., Viggiano G. Corporate default forecasting with machine learning [Electronic resource]. Expert Systems with Applications. 2020. Vol. 161. P. 113567. DOI: 10.1016/j.eswa.2020.113567. URL: <https://www.sciencedirect.com/science/article/abs/pii/S0957417420303912>
14. Pomulev A.A. Development of a method for forecasting the business value of public companies within the framework of a comparative approach using artificial intelligence. Finance: Theory and Practice. <https://doi.org/10.26794/2587-5671-2026-30-3-1862-02>
15. Cbonds. Financial indices and analytics [Electronic resource]. URL: <https://cbonds.ru/> (accessed: 18.09.2025)
16. Rosreestr. The maximum number of primary contracts was signed in the capital in eight months [Electronic resource]. URL: <https://rosreestr.gov.ru/press/archive/za-vosem-mesyatsev-v-stolitse-oformleno-maksimalnoe-chislo-pervichnykh-dogovorov-/> (date of access: 18.08.2025)
17. Dom.RF. Unified reporting on preferential mortgage lending [Electronic resource]. URL: <https://dom.rf/programmy-gosudarstvennoj-podderzhki/report/> (date of access: 18.09.2025)
18. Finance Marker Russian and US stock screener. URL: <https://financemarket.ru/stocks/?exchange=MOEX> (accessed: 18.09.2025)
19. QuantileTransformer – scikit-learn 1.6.1 documentation [Electronic resource]. URL: <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.QuantileTransformer.html> (date of access: 04.09.2025)
20. TimeSeriesSplit – scikit-learn 1.6.1 documentation [Electronic resource]. URL: https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.TimeSeriesSplit.html (date of access: 04.09.2025)
21. Mean Absolute Error: website. No DOI. URL: https://scikit-learn.org/stable/modules/generated/sklearn.metrics.mean_absolute_error.html (date of access: 20.08.2025)
22. Scikit-learn. R2 Score: website. No DOI. URL: https://scikit-learn.org/stable/modules/generated/sklearn.metrics.r2_score.html (date of access: 20.09.2025)

Информация об авторе

Лукичёв М.А., аспирант, Московский финансово-промышленный университет Синергия, m89262749985@gmail.com

© Лукичёв М.А., 2025