

УДК 004.89

DOI: [10.26102/2310-6018/2026.54.3.017](https://doi.org/10.26102/2310-6018/2026.54.3.017)

Применение машинного обучения и анализа значимых признаков для прогнозирования потребностей на российском фармацевтическом рынке

А.С. Ломакин^{1,2}, А.А. Оганесян¹✉, А.В. Зубков^{1,2}

¹Волгоградский государственный технический университет, Волгоград,
Российская Федерация

²Волгоградский государственный медицинский университет, Волгоград,
Российская Федерация

Резюме. Статья посвящена исследованию применения компьютерных методов анализа табличных данных для прогнозирования потребления товаров на российском фармацевтическом рынке. В статье раскрывается основной этап разработки информационной системы, предназначенной для прогнозирования закупок лекарственных препаратов и поддержки принятия управленческих решений в сфере лекарственного обеспечения. Рассматриваются особенности закупочной деятельности медицинских организаций и ключевые риски, связанные с планированием потребности в лекарственных средствах и формированием цен на фармацевтическую продукцию. Детально изложены современные методы, используемые в работе, включая модели машинного обучения и анализ значимости признаков с помощью SHAP. Описывается процесс подготовки и предобработки данных, включающий сбор, очистку, преобразование и кодирование признаков, а также формирование обучающих и тестовых выборок для построения регрессионных моделей. Особое внимание уделено выявлению факторов, влияющих на ценообразование лекарственных препаратов, и повышению точности прогнозирования за счет применения специализированных моделей для отдельных групп препаратов. Авторами работы оценивается экономический эффект от использования предложенного решения. Кроме того, инструмент помогает медорганизациям эффективнее планировать закупки путем снижения рисков и оптимизации бюджета. В рамках устойчивого рационального развития фармрынка России подробно рассматриваются вопросы автоматизации закупок и прогнозирования цен в качестве ключевых факторов.

Ключевые слова: машинное обучение, искусственный интеллект, SHAP-анализ, информационные системы, прогнозирование потребностей, фармацевтический рынок.

Для цитирования: Ломакин А.С., Оганесян А.А., Зубков А.В. Применение машинного обучения и анализа значимых признаков для прогнозирования потребностей на российском фармацевтическом рынке. *Моделирование, оптимизация и информационные технологии.* 2026;14(3). URL: <https://moitvvt.ru/ru/journal/article?id=2241> DOI: 10.26102/2310-6018/2026.54.3.017

Applying machine learning and feature analysis to predict demand in the Russian pharmaceutical market

A.S. Lomakin^{1,2}, A.A. Oganessian¹✉, A.V. Zubkov^{1,2}

¹Volgograd State Technical University, Volgograd, the Russian Federation

²Volgograd State Medical University, Volgograd, the Russian Federation

Abstract. This article explores the use of computer-based methods for analyzing tabular data to forecast consumption in the Russian pharmaceutical market. It describes the key stage of developing an information system designed to forecast drug procurement and support management decision-making in the pharmaceutical supply chain. It examines the specifics of medical organizations' procurement

activities and the key risks associated with planning drug demand and pricing. It details the modern methods used in the study, including machine learning models and feature significance analysis using SHAP. It describes the data preparation and preprocessing process, including collecting, cleaning, transforming, and encoding features, as well as generating training and test samples for building regression models. Particular attention is paid to identifying factors influencing drug pricing and improving forecasting accuracy through the use of specialized models for specific drug groups. The economic impact of implementing the developed tool is assessed. It enables medical organizations to more effectively manage procurement, optimize budgets, reduce financial risks. Specific attention is given to forecasting drug prices and automating the planning and procurement process as part of the sustainable and rational development of the Russian pharmaceutical market.

Keywords: machine learning, artificial intelligence, SHAP analysis, information systems, demand forecasting, pharmaceutical market.

For citation: Lomakin A.S., Oganessian A.A., Zubkov A.V. Applying machine learning and feature analysis to predict demand in the Russian pharmaceutical market. *Modeling, Optimization and Information Technology*. 2026;14(3). (In Russ.). URL: <https://moitvvt.ru/ru/journal/article?id=2241> DOI: 10.26102/2310-6018/2026.54.3.017

Введение

Процесс закупки лекарственных препаратов медицинскими организациями представляет собой сложный многоэтапный механизм, на каждом этапе которого возникают существенные риски, способные привести к значительным финансовым потерям и нарушению обеспечения пациентов необходимыми медикаментами.

На этапе планирования ключевой проблемой становится неверное определение потребности в лекарственных средствах, что в дальнейшем может привести как к дефициту препаратов, так и к необоснованным затратам. Этап подготовки аукционной документации сопряжен с рисками ошибочного расчета начальной максимальной цены контракта (НМЦК) и ошибками в документации, что создает угрозу признания закупки несостоявшейся или заключения контракта на невыгодных условиях.

В ходе проведения конкурсного отбора существует риск недополучения ожидаемой экономии из-за недостаточной конкуренции или неверной стратегии проведения торгов, что противоречит стратегии развития фармацевтической промышленности до 2030 года¹. Наконец, на этапе исполнения контракта медицинские организации сталкиваются с такими проблемами, как навязывание поставщиками дополнительных условий, расторжение контрактов из-за ошибок в планировании, дефицит препаратов на рынке или их отзыв.

Указанные риски ведут не только к финансовым потерям, но и к сбоям в лекарственном обеспечении пациентов, что напрямую влияет на качество медицинской помощи. В связи с этим разработка инструментов, позволяющих минимизировать данные риски на этапах планирования и подготовки закупок, приобретает особую актуальность.

Материалы и методы

Настоящее исследование направлено на создание методики прогнозирования цен и оптимизации закупочных процессов, что позволит медицинским организациям повысить эффективность расходования бюджетных средств и обеспечить стабильность поставок лекарственных препаратов.

¹ Распоряжение Правительства РФ от 07.06.2023 N 1495-р (ред. от 21.10.2024) «Об утверждении Стратегии развития фармацевтической промышленности Российской Федерации на период до 2030 года». КонсультантПлюс. URL: https://www.consultant.ru/document/cons_doc_LAW_449976/ (дата обращения: 12.11.2025).

Мы предлагаем создать комплексное решение для минимизации рисков медицинских организаций на этапе планирования закупок лекарственных препаратов. Основная задача – упростить процесс планирования потребности, снизив вероятность ошибок при расчете начальной максимальной цены контракта (НМЦК). Создание такого инструмента подразумевает автоматизированный сбор рыночных данных, в том числе из медицинских информационных систем [1] и единой информационной системы госзакупок, анализ коммерческих предложений поставщиков и предположительного расчета средневзвешенной цены на позицию в контракте, что значительно сокращает временные затраты и исключает человеческий фактор при подготовке документации.

В практике государственных закупок лекарственных препаратов цена контракта формируется на основе анализа исторических данных, коммерческих предложений и ряда рыночных факторов. Формально задачу прогнозирования цены единицы лекарственного препарата для целей планирования закупок можно представить как задачу регрессии следующим образом.

Имеется ретроспективный набор данных о государственных закупках лекарственных препаратов за период с 2015 по 2024 год: $D = \{C_1, \dots, C_i\}$, где каждый элемент C_i представляет собой запись об отдельном контракте (лот, позиция в контракте).

Для каждого контракта C_i известен набор его характеристик (признаков) $X_i = \{x_1, \dots, x_n\}$, влияющих на итоговую цену. Этот набор включает в себя атрибуты контракта, препарата, заказчика и поставщика. Объяснение для каждого элемента итогового набора признаков $A_p = \{a_1, \dots, a_p\}$, полученного в результате предобработки исходных данных X_i , представлено в Таблице 1.

Таблица 1 – Итоговый набор признаков A_p для прогнозирования цены лекарственного препарата

Table 1 – The final set of A_p features for predicting the price of a drug

Название признака	Описание
МНН	Международное непатентованное наименование препарата (закодировано).
Дата закупки	Дата проведения закупки (преобразована в числовой формат).
Количество упаковок	Общее количество упаковок препарата в лоте (шт.).
Доля SKU в лоте	Доля конкретной товарной позиции (SKU) в общем объеме лота (%).
ИНН поставщика	Идентификационный номер налогоплательщика поставщика (закодирован).
ИНН заказчика	Идентификационный номер налогоплательщика заказчика (закодирован).
Субъект РФ	Субъект Российской Федерации, в котором осуществляется закупка (закодирован).
Вид извещения	Способ определения поставщика (аукцион, котировка и т. д., закодирован).
Год выпуска данных	Год, к которому относятся данные о закупке.

Целевой переменной является цена за одну упаковку лекарственного препарата по контракту C_i , обозначаемая как $Price(C_i) \in R^+$ (цена \in множество положительных действительных чисел).

Таким образом, задача заключается в построении регрессионной модели F , которая на основе входных признаков контракта будет предсказывать его цену с минимальной ошибкой. Целевую функцию можно записать следующим образом:

$$F(X_i, H) \rightarrow \hat{y}_i \approx Price(C_i), \quad (1)$$

где F – алгоритм регрессии (например, Random Forest, Gradient Boosting), X_i – вектор признаков i -го контракта из множества A_p , H – множество гиперпараметров модели F , \hat{y}_i – предсказанное моделью значение цены, $Price(C_i)$ – фактическая цена из исторических данных.

В данном случае задача сводится к обучению статистического регрессора F' , который будет аппроксимировать истинную, но неизвестную зависимость F между характеристиками контракта и его ценой. Оптимизация достигается за счет минимизации функции потерь (например, средней абсолютной ошибки – MAE) на обучающих данных.

Исследование построено на основе размеченного набора данных. Он был разделен на обучающую выборку L_{train} , валидационную L_{val} и тестовую T . Обучающая выборка используется для обучения моделей, валидационная – для подбора гиперпараметров и предотвращения переобучения. Тестовая выборка служит для итоговой объективной оценки качества моделей. При этом между выборками не должно быть пересечений: $L_{train} \cap L_{val} \cap T = \emptyset$. Все выборки содержат пары «признаки – целевая переменная (цена)».

Чтобы повысить точность прогнозирования, вместо одной общей модели мы построили ансамбль специализированных. То есть, для каждого k -го препарата был обучен отдельный регрессор F_k . В итоге мы получили решение, представляющее набор моделей: $\{F_1, F_2, \dots, F_9\}$.

Отдельно отметим, что в системе лекарственного обеспечения необходимо корректное определение потребности в лекарственных средствах. Просчеты, допущенные на подготовительном этапе, обычно влекут негативные последствия, повторяющиеся системно. Среди последствий как нарушения непрерывности лекарственного обеспечения пациентов, так и нецелевое и неэффективное использование бюджетных ассигнований, сопряженных с соответствующими финансовыми и правовыми рисками.

Применение научно-обоснованных методов прогнозирования снижает вероятность ошибки и позволяет медицинским организациям учитывать текущую конъюнктуру фармацевтического рынка и динамику цен, тем самым минимизируя риск заключения контрактов по экономически необоснованной стоимости, особенно в случаях заключения контрактов с единственным поставщиком или проведения закупок малого объема, где отсутствие конкуренции часто приводит к неоправданному росту цен.

Создание метода прогнозирования цен на лекарственные препараты не только минимизирует эти риски, но и способствует повышению прозрачности и эффективности всей системы госзакупок в здравоохранении, обеспечивая оптимальное использование бюджетных средств при одновременном гарантированном обеспечении пациентов необходимыми препаратами.

В современной научной литературе прогнозирование цены и потребления лекарственных препаратов рассматривается как важная задача для эффективного управления фармацевтическим рынком, особенно в России.

Для этих целей подходят, например, экономико-математические методы, включая анализ временных рядов и тренд-сезонные модели, применяются для прогнозирования продаж различных групп лекарственных препаратов. Так, в исследовании Самарского университета [2] показано, что для разных групп препаратов (сердечно-сосудистые, нервной системы, противомикробные и противоопухолевые) используются разные тренд-сезонные модели, обеспечивающие высокую точность прогнозов с ошибкой менее 10 %, однако они не учитывают изменений цены на конкретное лекарственное средство.

За рубежом также проходят исследования на эту тему. Так, в статье [3] рассматриваются традиционные методы линейной регрессии и модель случайного леса (random forest) для прогнозирования цен на фармацевтические препараты на основе более 200,000 закупок из 10 стран. Модель random forest показала высокую точность ($R^2 = 0,85$, $RMSE = 0,81$), что демонстрирует потенциал машинного обучения для прогнозирования цен.

Одновременно с этим, в работе [4] предложена модель глубокого обучения на основе многослойного перцептрона (MLP) для прогнозирования изменений цен на лекарства. Модель использует текстовое описание причин изменения цены и демонстрирует высокую точность прогноза, адаптируясь к динамике рынка. Однако все зарубежные аналоги не подходят для применения на российском фармацевтическом рынке, вследствие особенностей проведения государственных закупок в РФ, ограничений валютных сделок из-за условий развития экономики под санкциями.

Для получения более точных результатов при прогнозировании цен на лекарственные препараты следует стараться избежать применения эвристических методов, основанных на мнениях фармацевтов, которые учитывают не все факторы рынка, могут применяться два принципиально разных подхода Case-Based Reasoning (CBR) и математическое моделирование (регрессионный анализ). CBR опирается на поиск аналогий в исторических данных, сравнивая текущую ситуацию с похожими случаями из прошлого, что особенно полезно для редких или новых препаратов, где недостаточно статистики для построения формальных моделей. Этот метод отличается гибкостью и интерпретируемостью, но его точность сильно зависит от полноты базы прецедентов. В отличие от него, регрессионный анализ строит строгие математические зависимости между ценой и влияющими факторами (такими как спрос, себестоимость, инфляция), обеспечивая высокую точность прогноза при наличии достаточных данных [5], хотя он и менее адаптивен к уникальным ситуациям и требует корректного учета всех значимых переменных.

Эффективность современных моделей машинного обучения обусловлена способностью работать с большими данными и учитывать сложные зависимости. В статье [6] по инвестиционным рискам описаны особенности этих моделей и их применение для прогнозирования ценовых трендов. Аналогично, потенциал искусственного интеллекта и машинного обучения в фармацевтическом секторе отмечен в обзоре [7], посвященном оптимизации процессов разработки и сбыта лекарств.

Однако, наш датасет содержит порядка ста тысяч записей, чего, обычно, достаточно для обучения качественной модели. К тому же, в датасете содержатся количественные признаки, например, цена, с которыми отлично работают регрессионные модели. Вообще, среди множества методов прогнозирования одним из самых точных и надежных является математическое моделирование. Этот метод основан на построении математических моделей, которые адекватно отражают закономерности изменения цен. По сути, каждая модель представляет собой уравнение регрессии, в котором значение прогнозируемого показателя рассматривается как функция нескольких значимых признаков.

Прогнозирование на основе многофакторных регрессионных моделей предполагает выявление комплекса факторов, оказывающих существенное влияние на изменение прогнозируемых цен.

Для обучения качественных моделей необходимо подготовить и векторизовать имеющиеся наборы данных, разделить их на обучающую, валидационную и тестовую выборки, а также выбрать наиболее подходящий алгоритм для задачи регрессии.

Для каждого набора данных необходимо обучить базовую модель классического машинного обучения, хорошо работающего с табличными данными, в отличие от

моделей глубокого обучения [8, 9], в основу которых заложены алгоритмы машины опорных векторов (SVM), случайного леса, градиентного бустинга, деревьев решений и K ближайших соседей. Затем, для наилучшей полученной модели происходит подбор гиперпараметров с помощью специальных методов, которые позволяют добиться более высокой точности относительно базовой модели по ключевым метрикам.

Для подготовки данных для прогнозирования цен на лекарственные препараты и их пригодности для обучения моделей машинного обучения был выполнен комплексный предпроцессуальный конвейер, включающий сбор [10], очистку, преобразование и кодирование данных. Исходные данные были получены из базы государственных закупок лекарственных препаратов моноклональных антител за период с 2015 по 2022 год и содержали 102 254 записи по 9 препаратам, использующихся, в том числе в стандартах таргетной терапии меланомы [11], немелкоклеточного рака легкого [12], лимфомы Ходжкина, в формате CSV.

На первом этапе данные были загружены из отдельных файлов, после чего из каждого набора удалены строки заголовков для корректной обработки. Особое внимание было уделено выявлению и устранению выбросов, поскольку их наличие может исказить статистические показатели (например, средние значения) и снижать точность предсказательных моделей. Удаление экстремальных значений также способствовало нормализации распределения данных, что важно для последующего анализа.

Для работы с временными метками даты были преобразованы в числовой формат (float), так как большинство алгоритмов машинного обучения² требуют числового представления временных данных. Категориальные переменные, такие как «Субъект», «Заказчик» и «Вид извещения», были закодированы с помощью dummy-переменных (бинарных индикаторов), что позволило сохранить их смысловую нагрузку в числовом виде. Для кодирования международных непатентованных наименований (МНН) применен метод LabelEncoder, преобразующий категории в числовые метки.

Проведенная предобработка обеспечила совместимость данных с классическими алгоритмами машинного обучения и перейти к этапу построения и сравнения прогностических моделей для анализа динамики цен на лекарственные препараты.

После приведения всех данных к единому формату, они были объединены в единый датасет, где в качестве целевой переменной выступили значения цен за упаковку лекарственного препарата. Далее данные были разделены на обучающую (80 %) и тестовую (20 %) выборки в стандартном для машинного обучения соотношении 4:1.

На подготовленной обучающей выборке было проведено обучение нескольких классических регрессионных моделей. Для выбора оптимальной конфигурации использовался метод GridSearchCV, который позволил определить наилучшие гиперпараметры моделей по критерию средней абсолютной ошибки (MAE).

Прогнозные значения полученного первичного регрессора на тестовой выборке были сопоставлены с фактическими данными и визуализированы (Рисунок 1).

Для оценки качества полученной тестовой модели была введена специальная метрика, которая по своей сути представляет MAE (метрика средней абсолютной ошибки), деленное на среднее значение цены на препарат:

$$quality = \sum_{i=1}^n |y_i - \hat{y}_i| / y_i. \quad (2)$$

Чем меньше значение метрики quality, тем лучше качество модели, поскольку оно указывает на более низкую относительную ошибку модели в сравнении со средним значением цены на препарат, позволяя оценить, насколько точно она предсказывает целевую переменную.

² Бишоп К.М. *Распознавание образов и машинное обучение*. Санкт-Петербург: Вильямс; 2020. 960 с.

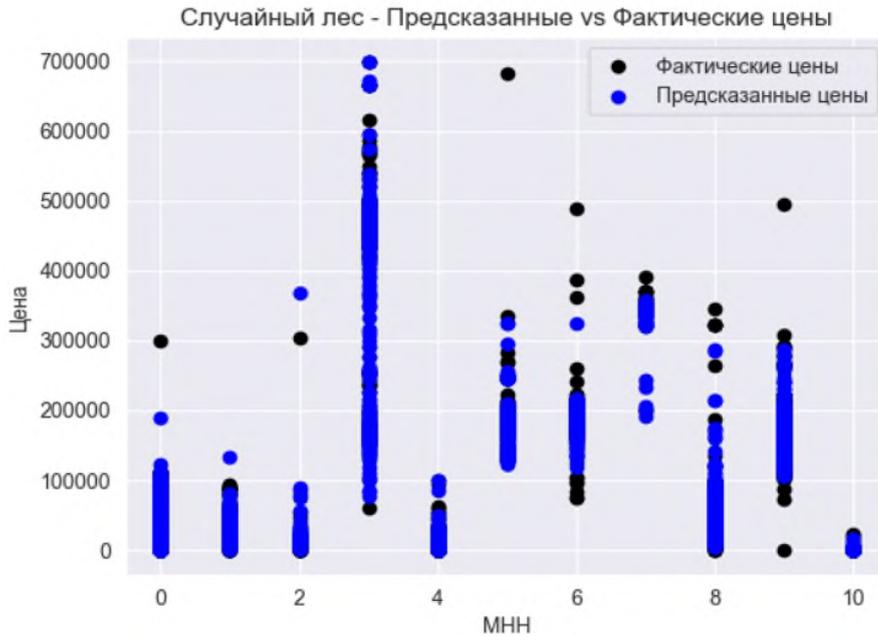


Рисунок 1 – Соотношение предсказанных и фактических цен на препараты
Figure 1 – Ratio of predicted and actual drug prices

Также необходимо было ввести метрику, которая бы учитывала разброс значений цены на препарат в датасете. Для этих целей была введена метрика *quality_std*, причем, чем меньше ее абсолютное значение, тем выше мера разброса, то есть больше разброс данных относительно их среднего значения и средней цены на препарат.

$$quality_std = \sum_{i=1}^n |y_i - \hat{y}_i| / \sqrt{\frac{\sum_{y=1}^n (y_i - \bar{y})^2}{n}}. \quad (3)$$

Проведенный анализ точности модели показал, что средняя абсолютная ошибка (MAE) составила 4746 рублей при средней цене препарата 39305 рублей, что соответствует относительной погрешности прогнозирования около 12 %. Достигнутый уровень точности в целом можно считать приемлемым для практического применения, поскольку в большинстве случаев модель обеспечивает прогноз цены с отклонением, не превышающим ±12 % от фактического значения. Вместе с тем дополнительная метрика стандартного отклонения относительной ошибки на уровне 6,43 % свидетельствует и о заметной неоднородности точности предсказаний между отдельными наблюдениями.

В целях повышения качества прогнозирования было предложено реализовать два улучшения. Во-первых, необходимо провести тщательный отбор признаков, оставив только наиболее значимые факторы, действительно влияющие на цену препаратов. Во-вторых, следует разработать отдельные специализированные модели для каждого препарата или групп схожих препаратов. Такой подход позволит лучше учитывать специфические закономерности ценообразования для разных лекарственных средств и, как следствие, добиться более точных предсказаний.

Вследствие вышесказанного, было решено обучить отдельные модели-регрессоры для каждого из наборов данных по препаратам. Анализ важности признаков с использованием метода SHAP (Рисунок 2) позволил выявить ключевые факторы, оказывающие наибольшее влияние на прогноз модели.

Метод SHAP³ работает так, что для каждого предсказания определяется значение его вклада в общий прогноз модели. Для отображения информации начальная линия прогноза выбирается с предположением всего среднего значения целевой переменной или другого репрезентативного показателя. Для каждого предсказания метод рассчитывает вклад отдельных предикторов, опираясь на концепцию идеи значимости Шепли (Shapley values) из теории игр. Таким образом, рассматривают не только индивидуальное влияние свойств, но и совокупное влияние пар признаков. Методология особенно полезна в случаях, когда важно понять, какие признаки оказывают наибольшее влияние на принятие решений моделью.

Проведя соответствующий анализ, основными значимыми признаками стали: дата проведения закупки, количество упаковок в лоте, доля SKU в лоте, международное непатентованное наименование (МНН), идентификационный номер налогоплательщика (ИНН) поставщика и заказчика. Именно эти параметры были отобраны в качестве входных переменных для построения девяти отдельных прогнозных моделей – по одной для каждого исследуемого набора данных по каждому препарату.

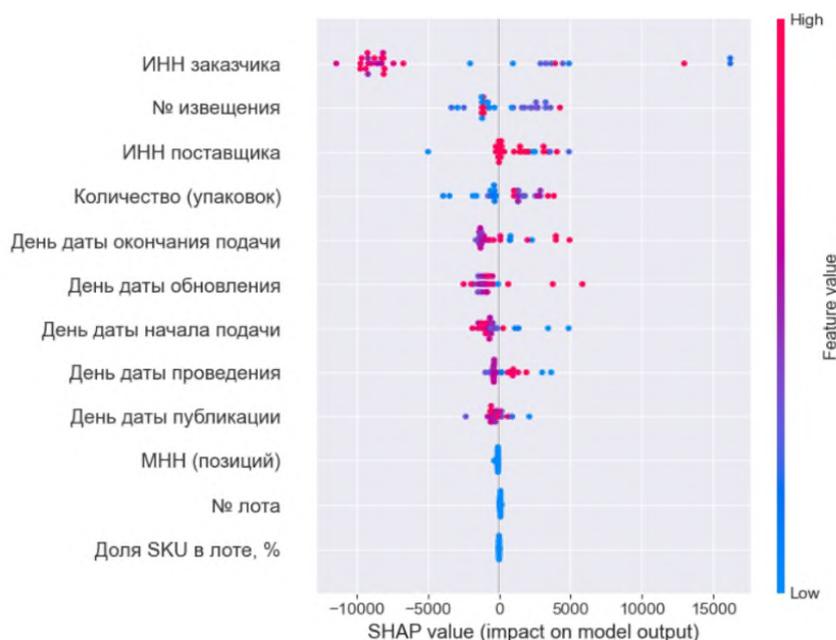


Рисунок 2 – Ранжирование влияния признаков на прогноз первичной регрессионной модели
 Figure 2 – Ranking the influence of features on the primary regression model's prediction

Результаты

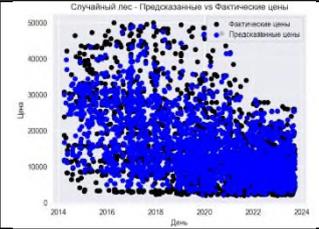
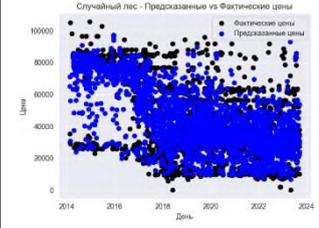
Таким образом, нам удалось достичь наилучших результатов в 8 случаях с использованием алгоритма Random Forest (Случайный лес) и в 1 случае с использованием алгоритма Gradient Boosting (Градиентный бустинг). Каждая из итоговых моделей, результаты которых представлены в Таблице 2, прошла подбор оптимальных гиперпараметров по ключевым метрикам, с помощью метода GridSearchCV, алгоритм которого основан на переборе заданного пространства параметров по сетке значений. Для каждой комбинации параметров GridSearchCV выполняет кросс-валидацию, оценивая производительность модели на различных подвыборках данных.

³ shap.Explainer. SHAP documentation. URL: <https://shap.readthedocs.io/en/latest/generated/shap.Explainer.html#shap.Explainer> (дата обращения: 18.11.2025).

Таблица 2 – Полученные результаты для каждой из итоговых моделей
Table 2 – The results obtained for each of the final models

Модель для препарата	Quality, %	Quality_std, %	MAE	MSLE (среднеквадратичная логарифмическая ошибка)	Визуализация предсказанных значений в зависимости от даты
Доксорубин	2,21	43,63	7381,89	0,0014	
Кадсила	13,2	59,80	19335,62	0,0335	
Капектабин	2,2	28,87	3928,92	0,0116	
Паклитаксел	12,98	38,36	1630,23	0,1776	
Трастузумаб	29,1	35,51	81,53	0,2661	
Циклофосфамид	30,81	13,67	2618,73	0,9391	
Петрузумаб	23,49	28,32	1927,54	0,3704	

Таблица 2 (продолжение)
Table 2 (continued)

Пембро- риа	18,1	39,14	4273,08	0,2441	
Петрузу- маб и трастузу- маб	12,48	33,4	7920,6	0,1464	

Нетрудно заметить, что в моделях, где значение метрики *quality_std* достаточно низкое, точность несколько ниже, чем в остальных, что вполне объяснимо, так как в данном случае разброс цен на препарат лежит в больших диапазонах (высокое значение стандартного отклонения).

Большой разброс цен может указывать на наличие интенсивной конкуренции на рынке препаратов. В целом, стоимость лекарств зависит от их категории. Специализированные препараты часто демонстрируют большую волатильность цен из-за уникальности состава и ограниченного производства, тогда как распространенные лекарства с множеством производителей имеют более стабильное ценообразование. Колебания этого показателя во времени могут сигнализировать о рыночных изменениях – введении новых регуляторных норм, колебаниях спроса и предложения или сезонных факторах, влияющих на фармрынок.

Вследствие этого можно говорить о создании достаточно точных моделей машинного обучения, которые можно использовать в дальнейших исследованиях и работах в рамках проекта по созданию веб-приложения^{4,5} для управления лекарственным обеспечением Волгоградской области.

Заключение

Итак, грамотное применение методов математического моделирования при наличии полных и достоверных данных позволяет достигать высокой точности прогнозирования ценовой динамики на российском фармацевтическом рынке. Разработанные модели машинного обучения демонстрируют практическую ценность для решения ключевых задач в сфере госзакупок лекарственных препаратов, включая точное предсказание цен на конкретные медикаменты, оптимизацию закупочных процессов и анализ рыночных тенденций. Полученные результаты свидетельствуют, что использование таких прогнозных моделей позволяет существенно повысить эффективность планирования закупок, минимизировать финансовые риски и принимать более обоснованные управленческие решения.

Особую значимость данный подход приобретает в условиях необходимости

⁴ Баланов А.Н. *Бэкенд-разработка веб-приложений: архитектура, проектирование и управление проектами*. Санкт-Петербург: Лань; 2024. 312 с.

⁵ Заяц А.М., Васильев Н.П. *Проектирование и разработка WEB-приложений. Введение в frontend и backend разработку на JavaScript и node.js*. Санкт-Петербург: Лань; 2023. 120 с.

обеспечения доступности лекарственных средств при рациональном использовании бюджетных средств, что делает его ценным инструментом для участников фармацевтического рынка и государственных заказчиков.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Гусев А.В., Зарубина Т.В. Поддержка принятия врачебных решений в медицинских информационных системах медицинской организации. *Врач и информационные технологии*. 2017;(2):60–72.
Gusev A.V., Zarubina T.V. Clinical decisions support in medical information systems of a medical organization. *Medical Doctor and IT*. 2017;(2):60–72. (In Russ.).
2. Малыгина Ю.С., Орлова К.Ю. Прогнозирование продаж групп лекарственных препаратов в аптечном сегменте Российской Федерации. В сборнике: *Проблемы экономики современных промышленных комплексов. Финансирование и кредитование в экономике России: методологические и практические аспекты: Сборник трудов XV Всероссийской научно-практической конференции, 05 декабря 2022 года, Самара, Россия*. Самара: Самарский научный центр РАН; 2022. С. 16–27.
Malygina Yu.S., Orlova K.Yu. Forecast of sales for drug groups in the pharmacy segment of the Russian Federation. In: *Problems of economics of modern industrial complexes. Financing and lending in the Russian economy: Methodological and practical aspects: Proceedings of the XV All-Russian Scientific and Practical Conference, 05 December 2022, Samara, Russia*. Samara: Samara Scientific Center of the RAS; 2022. P. 16–27. (In Russ.).
3. Fazekas M., Veljanov Z., de Oliveira A.B. Predicting pharmaceutical prices. Advances based on purchase-level data and machine learning. *BMC Public Health*. 2024;24(1). <https://doi.org/10.1186/s12889-024-19171-9>
4. Ragb H. *Multi-layered deep learning perceptron based model for predicting drug price changes*. TechRxiv. URL: <https://doi.org/10.36227/techrxiv.24417697.v1> [Accessed 15th November 2025].
5. Пучков Е.В. Сравнительный анализ алгоритмов обучения искусственной нейронной сети. *Инженерный вестник Дона*. 2013;(4). URL: <https://ivdon.ru/magazine/archive/n4y2013/2135>
Puchkov E.V. Comparative analysis of the artificial neural network training algorithms. *Engineering Journal of Don*. 2013;(4). (In Russ.). URL: <https://ivdon.ru/en/magazine/archive/n4y2013/2135>
6. Парфенов А.К. Анализ и оценка инвестиционных рисков при инвестировании с применением математического моделирования. *Молодой ученый*. 2024;(49):9–13.
7. Филина О.В., Сунгатуллин К.И. Прогнозирование потребностей рынка в лекарственных средствах на основе технологий искусственного интеллекта. *Экономика и безопасность*. 2025;(1):22–25.
Filina O.V., Sungatullin K.I. Forecasting the market needs for medicines based on artificial intelligence technologies. *Economy and Security*. 2025;(1):22–25. (In Russ.).
8. Горячкин Б.С., Чечнев А.А. Анализ чувствительности метрик бинарной классификации к дисбалансу данных. *E-Scio*. 2021;(4):23–34.
9. Николенко С., Кадури А., Архангельская Е. *Глубокое обучение. Погружение в мир нейронных сетей*. Санкт-Петербург: Питер; 2020. 480 с.
10. Костяшин Н.А., Колбина О.Н., Яготинцева Н.В. Применение автоматизированных средств сбора информации по сайтам. *Информационные технологии и системы: управление, экономика, транспорт, право*. 2020;(3):11–17.
Kostyashin N.A., Kolbina O.N., Yagotinceva N.V. Use of automated tools for collecting

- information on sites. *Information Technologies and Systems: Management, Economics, Transport, Law*. 2020;(3):11–17. (In Russ.).
11. Строяковский Д.Л., Абрамов М.Е., Демидов Л.В. и др. Практические рекомендации по лекарственному лечению меланомы кожи. *Злокачественные опухоли*. 2022;12(3S2-1):287–306. <https://doi.org/10.18027/2224-5057-2022-12-3s2-287-306>
 12. Лактионов К.К., Артамонова Е.В., Бредер В.В. и др. Практические рекомендации по лекарственному лечению немелкоклеточного рака легкого. *Злокачественные опухоли*. 2021;11(3S2-1):36–54. <https://doi.org/10.18027/2224-5057-2021-11-3s2-02>

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Ломакин Арсений Сергеевич, магистрант, **Arseniy S. Lomakin**, Master's Degree student, Волгоградский государственный технический университет, Волгоград, Российская Федерация. Volgograd, the Russian Federation.
e-mail: arseny.lomakin@gmail.com
ORCID: [0009-0001-9340-1748](https://orcid.org/0009-0001-9340-1748)

Оганесян Артём Артакович, магистрант, **Artem A. Oganessian**, Master's Degree student, Волгоградский государственный технический университет, Волгоград, Российская Федерация. Volgograd, the Russian Federation.
e-mail: gdoq123@yandex.ru

Зубков Александр Владимирович, кандидат технических наук, доцент кафедры программного обеспечения автоматизированных систем, Волгоградский государственный технический университет, Российская Федерация, Волгоград, Российская Федерация. **Alexander V. Zubkov**, Candidate of Engineering Sciences, Associate Professor at the Department of Automated Systems Software, Volgograd State Technical University, Russian Federation, Volgograd, the Russian Federation.
e-mail: zubkov.alexander.v@gmail.com
ORCID: [0000-0003-0425-5695](https://orcid.org/0000-0003-0425-5695)

Статья поступила в редакцию 19.02.2026; одобрена после рецензирования 24.03.2026; принята к публикации 28.03.2026.

The article was submitted 19.02.2026; approved after reviewing 24.03.2026; accepted for publication 28.03.2026.