Миронов Артем Юрьевич, магистрант
Российский новый университет
Mironov Artem Yuryevich**,** Master's student
Russian New University

РАЗРАБОТКА ПРОГРАММНОГО МОДУЛЯ ОБЪЯСНИМОГО ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ИНТЕРПРЕТАЦИИ ПРОГНОЗОВ СПРОСА В РОЗНИЧНОЙ ТОРГОВЛЕ
DEVELOPMENT OF AN EXPLAINABLE ARTIFICIAL INTELLIGENCE SOFTWARE MODULE FOR INTERPRETING RETAIL DEMAND FORECASTS

Аннотация. Рассматривается программный модуль локальной интерпретации прогнозов спроса в розничной торговле. Для линейной регрессии реализовано точное аддитивное разложение прогноза относительно средних значений признаков обучающей выборки, для случайного леса – локальная оценка чувствительности посредством замены отдельных признаков базовыми значениями. Описаны архитектура модуля, вычислительный эксперимент и использование прогноза для расчета пополнения товарного запаса.

Abstract. The paper considers a software module for local interpretation of retail demand forecasts. For linear regression, an exact additive decomposition relative to the mean training feature values is implemented; for a random forest, local sensitivity is estimated by replacing individual features with baseline values. The module architecture, computational experiment, and the use of forecasts for inventory replenishment calculations are described.

Ключевые слова: Объяснимый искусственный интеллект, прогнозирование спроса, интерпретируемость, машинное обучение, линейная регрессия, случайный лес.

Keywords: Explainable artificial intelligence, demand forecasting, interpretability, machine learning, linear regression, random forest.

Введение

Прогнозирование спроса используется при планировании закупок и управлении товарным запасом. Модели машинного обучения позволяют учитывать сезонность, предыдущие продажи, цену, промоакции и календарные факторы, однако вместе с ростом сложности модели снижается прозрачность результата. Специалист видит числовой прогноз, но не всегда понимает, какие признаки сформировали отклонение от обычного уровня спроса [1-4].

Для локального объяснения применяются модельно-независимые методы LIME и SHAP [5, 6]. Они позволяют анализировать отдельный прогноз, но универсальность таких методов сопровождается дополнительными вычислениями и отдельными требованиями к обработке зависимых признаков [7, 8]. В прикладной системе полезно явно различать точное объяснение, следующее из структуры модели, и приближенную локальную оценку.

Цель статьи – разработать воспроизводимый программный модуль локальной интерпретации прогнозов спроса. Модуль не заменяет прогнозную модель и не принимает решение о закупке автоматически. Его задача – показать направление и величину влияния признаков, сохранить диагностическую информацию о качестве объяснения и передать прогноз в простой расчет пополнения запаса.

Формирование признакового описания

Вычислительный эксперимент построен на синтетическом ряде ежедневных продаж. В генераторе заданы базовый спрос, годовая сезонность, промоакции, особые и выходные дни, колебания цены и случайный шум. После формирования лагов и скользящих средних осталось 700 наблюдений: 560 использованы для обучения и 140 – для тестирования. Разделение выполнено по времени без перемешивания.

Модель получает 12 признаков. Скользящие показатели рассчитываются после сдвига продаж на один день, поэтому значение спроса прогнозируемой даты не попадает в ее входные данные. Базовые значения, используемые при интерпретации, рассчитываются только по обучающей выборке.

Таблица 1

Состав признаков прогнозной модели

Группа	Состав	Назначение
Календарные	Промоакция, особый день, выходной день	Учитывают режим продаж и события
Цена	Индекс цены	Отражает изменение ценового уровня
Лаги	Продажи за 1, 7, 14 и 30 дней	Передают недавнюю динамику спроса
Скользящие	Средние продажи за 7 и 30 дней	Сглаживают краткосрочные колебания
Сезонность	Синус и косинус годового цикла	Описывают положение даты в годовом цикле

Алгоритм интерпретации прогноза

Для линейной регрессии используется точное аддитивное разложение. Базовая точка задается средними значениями признаков обучающей выборки. Если w_i – коэффициент модели, x_i – значение признака для анализируемого дня, а μ_i – его среднее на обучении, вклад признака рассчитывается как:

$$c_i = w_i \cdot (x_i - \mu_i).$$

Базовый прогноз равен результату модели для вектора средних значений. Для линейной модели сумма базового прогноза и всех вкладов восстанавливает исходный результат. Положительный вклад повышает прогноз относительно базы, отрицательный – понижает. Такой вклад объясняет расчет модели, но не доказывает причинное влияние признака на продажи.

Для случайного леса применяется другой режим. Сначала вычисляется исходный прогноз, затем по одному признаку его текущее значение заменяется средним по обучающей выборке. Разность между исходным и повторным прогнозом считается локальным влиянием признака:

$$d_i = f(x) - f(x^{(i)}).$$

Из-за нелинейности и взаимодействий признаков значения d_i не обязаны складываться в разность между прогнозом и базой. Поэтому модуль дополнительно сохраняет диагностический остаток. Ненулевой остаток в этом режиме рассматривается не как ошибка программы, а как признак неаддитивности локальной оценки. При использовании связанных лаговых и скользящих признаков отдельная замена также может создавать нетипичную комбинацию значений [8].

Архитектура программного модуля

Программный модуль отделен от сценария обучения моделей. Внешний слой готовит данные и получает прогноз, а ядро интерпретации работает с уже рассчитанными параметрами. Для линейной регрессии ядру передаются коэффициенты, свободный член, базовые значения и наблюдение. Для случайного леса используется функция прогноза. Такое разделение позволяет проверять вычисления независимо от библиотеки, применяемой для обучения.

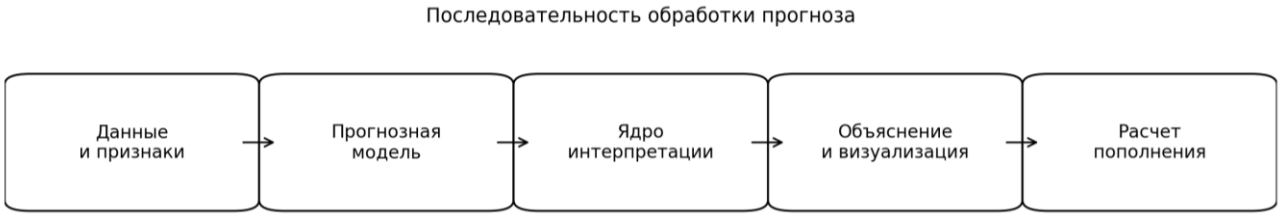

Рисунок 1. Архитектура программного модуля интерпретации прогнозов

В результате сохраняются исходный и базовый прогнозы, значения вкладов или локальных влияний и диагностический остаток. Для пользовательского представления признаки сортируются по абсолютной величине влияния; знак сохраняется. Шесть наиболее заметных факторов выводятся на диаграмму, полный набор остается в результатах расчета.

Вычислительный эксперимент

Для сравнения обучены линейная регрессия и случайный лес из 200 деревьев с максимальной глубиной 10 и минимальным числом наблюдений для разделения 5. Качество оценивалось по MAE, RMSE, MAPE и R^2. На синтетическом наборе линейная модель показала меньшую ошибку по всем четырем показателям.

Таблица 2

Качество прогноза на 140 тестовых наблюдениях

Модель	MAE, ед.	RMSE, ед.	MAPE, %	R^2
Линейная регрессия	4,37	5,67	5,43	0,8847
Случайный лес	5,23	7,46	6,26	0,8004

Для 30.12.2025 фактические продажи составили 94 единицы, а прогноз линейной регрессии – 96,91923. Базовый прогноз для этого наблюдения равен 113,43214, сумма двенадцати вкладов – 16,51291. После сложения восстанавливается исходный прогноз. Наиболее заметные отрицательные вклады дали синус годовой сезонности (-5,81), отсутствие промоакции (-5,42) и будний день (-2,84).

Точное линейное разложение проверено на всех 140 тестовых наблюдениях. Максимальное расхождение между исходным прогнозом и суммой базы с вкладами составило $1{,}42 \cdot 10^{-14}$ при принятом допуске 10^{-10}. Для случайного леса на последнем тестовом дне прогноз равен 100,53928, базовое значение – 109,56293, диагностический остаток -3,88043. Этот результат подтверждает, что локальные замены для нелинейной модели нельзя выдавать за точное аддитивное разложение.

Вычислительное ядро дополнительно проверено 13 автоматическими тестами. Проверялись восстановление линейного прогноза, обработка ошибочных значений, независимость от порядка признаков, сохранность входных данных, локальные замены, расчет заказа и формирование диаграммы.

Расчет пополнения запаса

Интерпретация и расчет пополнения выполняют разные функции. Вклады объясняют прогноз, но повторно в формулу заказа не добавляются. В демонстрационном правиле используются дневной прогноз $\hat{y}$, срок поставки L, страховой запас S и текущий остаток I:

$Q = max\,(0,\ \lceil \hat{y} \cdot L + S - I \rceil)$.

При прогнозе 96,91923 единицы в день, сроке поставки 7 дней, остатке 420 единиц и страховом запасе 80 единиц расчетная потребность с резервом равна 758,43461. Нехватка составляет 338,43461 единицы, поэтому после округления вверх программа рекомендует заказать 339 единиц. Это правило показывает переход от прогноза к прикладному действию, но не заменяет промышленную систему управления запасами.

Эксплуатационные ограничения

Полученные результаты относятся к воспроизводимому учебному эксперименту на синтетических данных. Они подтверждают вычислительную корректность модуля, но не позволяют оценить экономический эффект для действующего магазина. Перед внедрением требуется проверка на реальных продажах, нескольких товарах и разных режимах спроса.

Отдельная проблема связана с зависимыми признаками. Лаги продаж и скользящие средние формируются из одного временного ряда, поэтому независимая замена одного значения средним может создавать комбинацию, редко встречающуюся в данных. В нелинейном режиме результат следует трактовать как локальную чувствительность модели, а не как причинный эффект.

Формула пополнения также упрощена: она предполагает постоянный средний спрос на период поставки и не учитывает уже размещенные заказы, минимальные партии, резервирование товара, стоимость хранения и ограничения поставщика. Эти параметры должны добавляться на прикладном уровне без изменения вычислительного ядра интерпретации.

Заключение

Разработан программный модуль локальной интерпретации прогнозов спроса, в котором для разных типов моделей явно используются разные свойства объяснения. Для линейной регрессии реализовано точное аддитивное разложение, а для случайного леса – локальная оценка чувствительности с диагностическим остатком. Такое разграничение позволяет не смешивать математически разные результаты под одним обозначением «вклад признака».

Эксперимент подтвердил точность линейного разложения на 140 тестовых наблюдениях и возможность связать прогноз с расчетом пополнения запаса. Дальнейшее развитие связано с проверкой на реальных данных, сравнением локальных оценок с SHAP и исследованием того, помогает ли объяснение специалисту быстрее и обоснованнее принимать решение.

Список литературы:

1. Бирюков Д. Н., Дудкин А. С. Объяснимость и интерпретируемость – важные аспекты безопасности решений, принимаемых интеллектуальными системами // Научно-технический вестник информационных технологий, механики и оптики. 2025. Т. 25, № 3. С. 373-386. DOI: 10.17586/2226-1494-2025-25-3-373-386.

2. Аверкин А. Н. Объяснимый искусственный интеллект как часть искусственного интеллекта третьего поколения // Речевые технологии. 2023. № 1. С. 4-10.

3. Рогулин Р. С. Обзор прикладных основ использования аналитики данных и машинного обучения в прогнозировании спроса // Экономические и социально-гуманитарные исследования. 2023. № 3. С. 115-126. DOI: 10.24151/2409-1073-2023-3-115-126.

4. Рогулин Р. С. Использование методов анализа данных и машинного обучения для прогнозирования и планирования спроса при управлении цепочками поставок // Теоретическая экономика. 2024. № 8. С. 35-53.

5. Ribeiro M. T., Singh S., Guestrin C. Why Should I Trust You?: Explaining the Predictions of Any Classifier // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2016. P. 1135-1144. DOI: 10.1145/2939672.2939778.

6. Lundberg S. M., Lee S.-I. A Unified Approach to Interpreting Model Predictions // Advances in Neural Information Processing Systems. 2017. Vol. 30.

7. Barredo Arrieta A., Diaz-Rodriguez N., Del Ser J. et al. Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI // Information Fusion. 2020. Vol. 58. P. 82-115. DOI: 10.1016/j.inffus.2019.12.012.

8. Aas K., Jullum M., Loland A. Explaining individual predictions when features are dependent: More accurate approximations to Shapley values // Artificial Intelligence. 2021. Vol. 298. Article 103502. DOI: 10.1016/j.artint.2021.103502.

9. Aggarwal A. Explainable AI for Demand Forecasting and Price Optimization: A Transparent Approach Using Tree Models and SHAP // 2025 International Conference on Artificial Intelligence and Machine Vision (AIMV). 2025. DOI: 10.1109/AIMV66517.2025.11203339.

10. Mishra L. N., Senapati B., Nayak S. K., Rangari A. J. Explainable Retail Demand Forecasting: A Hybrid LightGBM-SHAP Framework for Inventory Optimization // IEEE Access. 2026. Vol. 14. P. 43613-43633. DOI: 10.1109/ACCESS.2026.3675540