

МЕТОДЫ И АЛГОРИТМЫ ИНТЕЛЛЕКТУАЛЬНОЙ ПОДДЕРЖКИ ПРИНЯТИЯ УПРАВЛЕНЧЕСКИХ РЕШЕНИЙ В ОРГАНИЗАЦИОННЫХ СИСТЕМАХ ТОРГОВЫХ КОМПАНИЙ

Леохин Юрий Львович,
Московский технический университет связи
и информатики, Москва, Россия, y.l.leokhin@mtuci.ru

Дымкова Светлана Сергеевна,
Московский технический университет связи
и информатики, Москва, Россия, s.s.dymkova@mtuci.ru

Фатхулин Тимур Джалилевиц,
Московский технический университет связи
и информатики, Москва, Россия, t.d.fatkhulin@mtuci.ru

Зозуля Ирина Сергеевна,
Московский технический университет связи
и информатики, Москва, Россия

DOI: 10.36724/2072-8735-2025-19-12-44-50

Manuscript received 28 August 2025;
Accepted 18 November 2025

Ключевые слова: алгоритм, метод, метрика, эффективность, интеллектуальная поддержка, организационная система, модель

Данная работа представляет собой исследование проблемы прогнозирования объемов продаж в организационных системах торговых компаний. Целью работы является определение наиболее эффективного метода и алгоритма, используемого для интеллектуального принятия решений об изменении объемов продаж торговой организационной системы. Актуальность данной работы заключается в стремительном росте получаемых объемов информации и данных, а также в необходимости для торговых компаний идти в ногу со временем и в умении своевременно корректировать стратегии бизнеса путем принятия управленческих решений в своих организационных системах. Традиционные методы, основанные на теории вероятностей и математической статистике, не могут эффективно осуществлять прогнозы продаж с учетом вышеуказанных тенденций в мировых бизнес-процессах. Применение современных методов, которые ориентированы на прогнозирование рассматриваемого типа данных, может дать значительное повышение эффективности в решении указанной задачи. Объектом исследования являются объемы продаж торговых компаний. Предмет исследования – метрики оценки качества методов и алгоритмов прогнозирования объемов продаж для принятий управленческих решений в организационных системах торговых компаний. По итогам проведенного исследования выявлены оптимальные методы и алгоритмы, обеспечивающие высокую точность прогнозирования спроса на разнообразные категории продукции. Представлены рекомендации относительно целесообразности тех или иных настроек гиперпараметров моделей, способствующих повышению качества результатов прогнозирования. Сделаны выводы о практическом применении каждого метода и алгоритма, а также указаны направления и перспективы исследований. Основу методологии исследования составили аналитические методы, включая сравнительный анализ, эксперимент и обобщение полученных выводов.

Информация об авторах:

Леохин Юрий Львович, Проректор по научной работе, профессор, д.т.н., Московский технический университет связи и информатики, Москва, Россия, orcid.org/0000-0003-3321-4497

Дымкова Светлана Сергеевна, к.т.н., Московский технический университет связи и информатики, Москва, Россия, orcid.org/0000-0003-0945-9850

Фатхулин Тимур Джалилевиц, доцент, к.т.н., Московский технический университет связи и информатики, Москва, Россия, orcid.org/0000-0003-0998-1055

Зозуля Ирина Сергеевна, магистрант, Московский технический университет связи и информатики, Москва, Россия, orcid.org/0009-0006-3445-8070

Для цитирования:

Леохин Ю.Л., Дымкова С.С., Фатхулин Т.Д., Зозуля И.С. Методы и алгоритмы интеллектуальной поддержки принятия управленческих решений в организационных системах торговых компаний // Т-Comm: Телекоммуникации и транспорт. 2025. Том 19. №12. С. 44-50.

For citation:

Yu.L. Leokhin, S.S. Dymkova, T.D. Fatkhulin, I.S. Zozulya, "Methods and algorithms of intellectual support for making management decisions in organizational systems of trading companies," T-Comm, 2025, vol. 19, no.12, pp. 44-50. (in Russian)

Введение

Под организационной системой торговых компаний, занимающихся продажами, обычно понимают формальную структуру, процессы, политики и процедуры, которые регулируют деятельность и функционирование таких организаций. Применение современных методов, использующих все возможности вычислительной техники, позволяет повысить эффективность управления в организационных системах компаний, в том числе при прогнозировании объемов продаж. В свою очередь методы и алгоритмы интеллектуальной поддержки принятия управленческих решений в торговых компаниях позволяют повысить эффективность функционирования организаций. Для прогнозирования таких величин, как объемы продаж тех или иных товаров и услуг, могут использоваться традиционные методы и алгоритмы, базирующиеся на теории вероятностей и математической статистике, а также современные подходы, например, методы машинного обучения. Важно отметить, что в настоящее время методы машинного обучения получают все более широкое применение в разных сферах жизни [1, 9, 13-15, 17-19]. Они позволяют повысить эффективность обработки изображений [14], функционирования сетей связи [2-12, 20, 21], работы производств и складов, где необходима классификация различного рода объектов [9, 22].

Эти методы дают возможность осуществлять более точные долгосрочные прогнозы котировок валют и индексов бирж [15], а также прогнозировать спрос на товары и услуги [9-12, 15]. В будущем совместное использование программно-конфигурируемых сетей и методов машинного обучения позволит добиться значительных успехов при управлении все усложняющимися сетями связи [2-5]. В работах [9, 15] показано, что использование стандартных методов, алгоритмов и моделей не всегда является самым эффективным вариантом. Часто необходима модификация использующихся алгоритмов, а затем уже построение на их основе улучшенной модели [1, 9, 15]. Такая модель позволяет добиться максимально эффективной работы в той или иной сфере применения [16, 17].

В современном обществе различные компании предоставляют покупателям много товаров и услуг. Для прогнозирования разных показателей объемов их продаж требуется крайне много сил и затрат, как временных, так и человеческих. На помощь приходят методы машинного обучения, которые систематизируют, находят закономерности и прогнозируют показатели, например, объемы продаж.

Для эффективного прогнозирования необходимо проанализировать и оценить разные методы машинного обучения, подобрать наиболее подходящие для конкретной задачи, исходя из доступных ресурсов для вычислений. В настоящем исследовании планируется выявить методы и алгоритмы машинного обучения, которые будут эффективно прогнозировать объемы продаж, а также определить, необходима ли их дальнейшая модификация.

Для достижения указанной ранее цели исследования необходимо решить следующие взаимосвязанные задачи:

- проанализировать существующие методы, которые могут быть применены для прогнозирования объема продаж;
- определить основные этапы построения моделей прогнозирования;

- определить метрики для оценки эффективности рассматриваемых моделей;
- провести экспериментальные исследования;
- сделать выводы о выбранных моделях и дать рекомендации по их применению.

1 Анализ методов и алгоритмов, используемых для прогнозирования объема продаж

Проведем сравнительный анализ наиболее часто применяемых для прогнозирования объемов продаж методов, алгоритмов и моделей машинного обучения (МО) [9, 18, 19].

Линейная регрессия – базовая модель машинного обучения, которая анализирует независимую переменную и взаимосвязи между независимыми и зависимыми переменными. Данный метод используется уже длительное количество времени и является базовым методом для применения машинного обучения [12]. Linear Regression (линейная регрессия) – данный алгоритм является самым быстрым по скорости и простым в реализации, не требует никаких дополнительных настроек, основан на вычислении линейной зависимости между признаками и целевой переменной. Алгоритм не способен выявлять сложные нелинейные зависимости в данных, однако в настоящем исследовании он применяется в качестве базового алгоритма для сравнения результатов более продвинутых алгоритмов и анализа их производительности, что позволяет провести исследование более полно и объективно [6].

Такие количественные методы, как регрессия и анализ временных рядов, отличаются большей степенью упорядоченности и надежности. Регрессионные методы помогают выявлять взаимосвязи между факторами, влияющими на исследуемый показатель, и самим показателем, создавая таким образом модели, позволяющие спрогнозировать изменения одного параметра на основе изменений других. Анализ временных рядов предназначен для обнаружения повторяющихся структур и динамики в наблюдениях, выполненных последовательно во времени, что полезно для предсказания будущих показателей на основе прошлых данных. Эти два подхода обеспечивают проведение статистического анализа, проверку предположений и повышение качества управленческих решений благодаря высокой степени достоверности и точности заключений.

Модели «Случайный лес» и «Дерево решений» используются для прогнозирования при принятии последовательных альтернативных решений [12]. Random Forest (случайный лес) – ансамблевый алгоритм МО, в котором в качестве базового слабого алгоритма при построении ансамбля применяется обычное бинарное дерево решений, а итоговый прогноз алгоритма строится на основании усреднения прогнозов множества параллельно построенных деревьев, обученных на случайных подвыборках данных [7].

Градиентный бустинг (Gradient Boosting) – более современный и действенный подход машинного обучения, используемый для решения широкого круга задач регрессии и классификации. Данный метод строит предсказательные модели в форме ансамбля слабых предсказывающих моделей – «деревьев» решений [9, 12]. Алгоритмы XGBoost, CatBoost являются представителями другого популярного ансамблевого метода градиентного усиления или градиентного бустинга (от

англ. boosting – повышение, усиление). Вместо параллельного построения деревьев их обучение производится последовательно: каждое следующее дерево учится на ошибках предсказаний предыдущего, таким образом общая ошибка ансамбля постепенно минимизируется. В данном случае применяется принцип градиентного спуска, в котором имеется некоторая целевая функция ошибок, минимизируемая с определенным размером шага (*learning_rate*). Итоговый прогноз представляет собой сумму предсказаний всех деревьев, умноженный на *learning_rate* [13-18].

Нейросетевое моделирование формирует образы, основанные на работе человеческого мозга. Нейросеть представляет собой множество искусственных нейронов, которые объединены слоями, обрабатывающими входящий сигнал и формирующими выходной сигнал. При использовании данного метода можно решать задачи разного рода, например, обработка естественного языка, принятие решений, оптимизация процессов, распознавание образов и изображений и другие. Нейронная сеть LSTM (Long-Short-Term Memory, нейронная сеть с долгосрочной-краткосрочной памятью) – тип рекуррентной нейронной сети, который подходит для обработки последовательных данных, таких как временные ряды.

2 Этапы построения моделей, основанных на рассматриваемых методах и алгоритмах, и метрики оценки их эффективности

Построение моделей машинного обучения (МО) для данного исследования производится с использованием Google Colaboratory. Для исследования был выбран язык программирования Python, т.к. он является высокоуровневым языком программирования с универсальными возможностями и довольно простой реализацией. Данный язык имеет множество библиотек для обработки и визуализации данных, а также множество библиотек для реализации МО.

Для проведения данного исследования будут необходимы следующие библиотеки:

- библиотека Pandas позволяет обрабатывать и анализировать данные разного формата, визуализировать массивы различной сложности;
- библиотека Scikit-learn предназначена для быстрой реализации и сравнения различных алгоритмов машинного обучения без глубокого погружения в низкоуровневые детали;
- для сравнения алгоритмов МО соответствующие библиотеки – XGBoost, CatBoost, LightGBM, Keras.

Для прогнозирования объема продаж разного рода товаров или услуг с применением методов машинного обучения необходимо определить основные этапы построения моделей и рассмотреть их ключевые особенности [1, 15].

Первым этапом построения модели является предварительная обработка данных. Данный этап важен для качества прогноза. Основной задачей этапа является приведение данных к такому виду, чтобы минимизировать проблемы и погрешности, которые могут возникнуть на следующих этапах.

Таким образом, в предварительную обработку данных могут входить такие способы, как стандартизация и нормализация данных для приведения к единому масштабу, преобразование категорий в числовые форматы (one-hot encoding, label encoding и т.п.), агрегация данных (группировка по месяцам,

категориям, сезонам), заполнение пропусков (missing values imputation) – замена отсутствующих значений средним, медианой, модой или специализированными методами, логарифмическое или другое нелинейное преобразование данных для выравнивания распределений, отбор признаков (feature selection) – удаление ненужных или избыточных характеристик, что снижает риск переобучения и повышает производительность модели. Качественная подготовка данных улучшает точность и стабильность работы модели, а также уменьшает вероятность появления ошибок в результатах анализа.

Вторым этапом построения модели является анализ данных и выделение значимых признаков. Задачей данного этапа является определение природы имеющихся данных и определение важных факторов, влияющих на прогнозируемый показатель. Важными моментами являются визуализации данных, поиск паттернов и цикличности, применение статистических тестов для выявления значимых факторов.

Третьим этапом построения алгоритма машинного обучения является выбор и обучение модели. На данном этапе важно определить характер и специфику данных. К основным классам моделей относятся:

- регрессионные модели: линейная регрессия, гребневая регрессия, дерево решений, случайный лес, градиентный бустинг (CatBoost, LightGBM, XGBoost).
- временные ряды: ARIMA, SARIMA, Prophet, LSTM (для учёта временной динамики).

При выборе модели необходимо учитывать критерии: простота реализации и прозрачность модели, точность и стабильность результатов, скорость обучения и возможность масштабирования.

Четвертым этапом построения является определение гиперпараметров (от англ. hyper – сверх, т.е. настраиваемые пользователем параметры обучения алгоритма) и подбор лучшей модели. В каждой модели существует свой ряд гиперпараметров, которые определяют поведение и сложность модели. Гиперпараметры необходимо выбрать таким образом, чтобы их комбинация обеспечивала высокую точность прогноза. В их подборе помогают критерии точности такие, как MSE (Mean Squared Error), RMSE (Root Mean Squared Error), MAE (Mean Absolute Error), MAPE (Mean Absolute Percentage Error) и другие.

Далее необходимо провести проверку качества и валидности модели. Проверка качества происходит с помощью оценки поведения модели данных на независимых данных, которые не использовались при обучении, что позволяет определить, не переобучилась ли модель. К метрикам качества относятся MAE (средняя абсолютная ошибка), MAPE (средняя процентная ошибка), R^2 (коэффициент детерминации).

RMSE (Root Mean Square Error) показывает среднеквадратическое отклонение прогноза модели от фактического значения продаж.

Метрика RMSE особенно ценна тем, что из-за возведения ошибок в квадрат показатель сильно вырастает на больших ошибках, что помогает выявлять сильные выбросы. Метрика RMSE выражается в тех же единицах, что и исходные данные, что облегчает интерпретацию данного показателя.

В отличие от RMSE, метрика MAE (Mean Absolute Error) показывает среднее абсолютное значение предсказания от истинного значения и большие ошибки не так сильно влияют на

результат. Данная метрика показывает насколько далеко полученные прогнозы находятся от настоящих значений, получая среднее значение разброса по всему набору данных. MAE имеет то же измерение, что и RMSE.

Показатель R^2 (R-квадрат) отражает долю дисперсии фактических продаж, которую предсказывает модель. Чем выше показатель, тем точнее предсказание. Нулевое значение означает отсутствие взаимосвязи, а единица – полное соответствие модели данным.

Совместное применение указанных метрик позволяет более точно оценить построенную модель и сделать необходимые выводы относительно ее качества. Взаимосвязи между метриками для интерпретации результатов можно охарактеризовать следующим образом:

- низкие значения одновременно всех показателей показывают, что модель слишком простая, но отклонения разброса значений ошибок невелики;
- высокие значения одновременно всех показателей свидетельствуют о том, что в целом модель предсказывает данные, но не улавливает отдельные тенденции и есть выбросы;
- низкое значение R^2 при высоких RMSE и MAE означает, что модель очень плохо прогнозирует данные;
- высокое значение R^2 при низких RMSE и MAE отражает идеально точную модель для прогноза;
- при значительной разнице между RMSE и MAE можно сделать вывод о наличии сильных выбросов;
- при анализе метрик на тренировочной и тестовой выборках хорошие показатели метрик на тренировочном наборе при плохих на тестовом свидетельствуют о переобучении.

3 Экспериментальная оценка эффективности рассматриваемых методов и алгоритмов

На основании ранее рассмотренных этапов построения моделей машинного обучения для прогнозирования объёма продаж алгоритмы были обучены на выборках, полученных с открытой платформы «Kaggle». Проведем 3 эксперимента, содержащие различные наборы данных реальных продаж различных товаров и рассмотрим результаты их эффективности.

Эксперимент №1. В данном эксперименте использован датасет продаж кофейных напитков (информация из открытых ресурсов платформы «Kaggle»: <https://www.kaggle.com/datasets/ihelon/coffee-sales>). Данные представляют собой продажи кофейных напитков (капучино, горячий шоколад, какао, латте, американо и др.) в вендинговых аппаратах. Данные были преобразованы и приведены к единому числовому формату.

Всего в датасете указаны 262 факта продажи в разные временные рамки. Задача состоит в прогнозировании объёмов продаж в ближайшем будущем. В таблице 1 указаны результаты работы алгоритмов на тестовой (test) и обучающей (train) выборках по различным метрикам.

Проанализировав таблицу 1, можно сделать вывод, что лучше всего себя показывает метод XGBoost как до настройки гиперпараметров, так и после. Неплохие результаты по точности показал метод RandomForest, но он все же уступает точности, полученной методом XGBoost после настройки гиперпараметров.

CatBoost показал неплохие результаты работы на тренировочных данных, но на тестовом наборе и после настройки гиперпараметров результаты ухудшились. Самые плохие результаты показал LSTM до и после настройки гиперпараметров. Данный метод сильно переобучился, что дало плохие результаты как на тренировочном, так и на тестовом наборах данных.

На рисунке 1 проиллюстрированы полученные результаты по рассчитанным метрикам после настройки гиперпараметров. Проведенный анализ графиков указывает на то, что алгоритмы на обучающей и тренировочной выборках переобучаются, особенно алгоритмы с градиентным усилением XGBoost, CatBoost. Однако переобучение является неотъемлемой частью машинного обучения из-за выбросов и шумов. Более устойчивым к переобучению оказался Random Forest. LSTM показывает значительную ошибку на тестовом наборе, что еще раз отмечает необходимость усложнения подхода к ее построению, а также увеличения объема данных [11].

При сравнении наиболее точных алгоритмов минимальную разницу между ошибками на тренировочной и тестовой выборках демонстрирует Random Forest. Несмотря на более высокую точность, XGBoost демонстрирует большую переобучаемость. Однако стоит отметить, что Random Forest имеет гораздо меньше возможностей настройки, следовательно, в данном случае, показывает максимально возможную точность. Алгоритмы на основе градиентного спуска имеют большие возможности для повышения точности путем более тонкой настройки гиперпараметров.

При сравнении необходимости конструирования нейронной сети LSTM с настройкой гиперпараметров может потребоваться доработка ресурсоемкости, что даст меньшее количество ошибок и снижение переобучения.

Таким образом, целесообразно рассмотреть XGBoost, продемонстрировавший лучшие показатели на тестовой выборке, несмотря на переобучаемость на тренировочном наборе [5, 9, 13].

Таблица 1

Результаты работы алгоритмов в Эксперименте №1

Алгоритм	Метрика	С настройками		Без настроек	
		train	test	train	test
CatBoost	MAE	0,40	0,92	0,23	0,58
LinearRegression		0,26	0,24	0,26	0,24
LSTM		8,46	9,29	13,36	14,16
RandomForest		0,40	0,44	0,12	0,16
XGBoost		0,00	0,14	0,01	0,14
CatBoost	R ²	0,98	0,90	0,99	0,96
LinearRegression		0,95	0,98	0,95	0,98
LSTM		-3,64	-3,98	-9,93	-10,12
RandomForest		0,96	0,97	0,99	0,99
XGBoost		1,00	0,99	1,00	0,99
CatBoost	RMSE	0,55	1,33	0,32	0,89
LinearRegression		0,92	0,54	0,92	0,54
LSTM		9,13	9,93	14,01	14,84
RandomForest		0,85	0,79	0,47	0,39
XGBoost		0,00	0,41	0,01	0,42




Рис. 1. Результаты проведения Эксперимента №1

Эксперимент №2. В данном эксперименте использован датасет продаж одежды из магазина ZARA (информация из открытых ресурсов платформы «Kaggle»: <https://www.kaggle.com/datasets/xontoloyo/data-penjualan-zara>). Данные представляют собой продажи одежды, аксессуаров и иных вещей из магазина ZARA. Данные были предобработаны и приведены к единому числовому формату. Всего в датасете указаны 252 факта продажи в разные временные рамки. Поставлена задача спрогнозировать объёмы продаж в ближайшем будущем. В таблице 2 указаны результаты работы алгоритмов на тестовой (test) и обучающей (train) выборках по различным метрикам.

Проанализировав данные из таблицы 2, можно сделать выводы о том, что лучше всего себя показал Random Forest. Настройка гиперпараметров улучшила показатели Random Forest и XGBoost. Однако, модели XGBoost и CatBoost показывают сильное переобучение как на обучающих, так и на тестовых данных. Следовательно, можно сделать вывод, что лучшее сочетание производительности на тренировочном и тестовом наборе данных показала модель Random Forest.

Таблица 2

Результаты работы алгоритмов в Эксперименте №2

Алгоритм	Метрика	С настройками		Без настроек	
		train	test	train	test
CatBoost	MAE	260,42	570,37	228,07	609,72
LinearRegression		588,75	580,33	588,75	580,33
LSTM		1796,06	1859,80	1800,51	1864,25
RandomForest		322,39	576,87	230,06	586,63
XGBoost		0,42	676,13	9,43	674,41
CatBoost	R ²	0,79	-0,27	0,84	0,40
LinearRegression		0,03	-0,02	0,03	-0,02
LSTM		-6,50	-7,42	-6,54	-7,46
RandomForest		0,70	-0,16	0,84	-0,22
XGBoost		1,00	-0,58	1,00	-0,58
CatBoost	RMSE	320,61	766,02	283,90	807,15
LinearRegression		689,80	687,70	689,80	687,70
LSTM		1929,22	1981,14	1933,36	1985,32
RandomForest		385,34	734,70	278,12	752,30
XGBoost		0,57	857,02	12,80	854,80

На рисунке 2 проиллюстрированы полученные результаты по рассчитанным метрикам после настройки гиперпараметров. Модель LSTM показывает наилучшие результаты на тренировочной выборке данных, но худшие на тестовом наборе, причиной чего может быть переобучение. Модели XGBoost и CatBoost показывают более ровные результаты как на тренировочном, так и на тестовом наборе данных. Следовательно, лучше всего себя показывает XGBoost, так как демонстрирует лучшие результаты и меньшую вероятность переобучения.

Эксперимент №3. В данном эксперименте использован датасет продаж шоколадных изделий (информация из открытых ресурсов платформы «Kaggle»: <https://www.kaggle.com/datasets/atharvasoundankar/chocolate-sales>). Данные представляют собой продажи шоколадных изделий (белого, молочного и темного шоколада). Данные были предобработаны и приведены к единому числовому формату. Всего в датасете указаны 1094 факта продажи в разные временные рамки. Задача спрогнозировать объёмы продаж в ближайшем будущем. В таблице 3 указаны результаты работы алгоритмов на тестовой (test) и обучающей (train) выборках по различным метрикам.




Рис. 2. Результаты проведения Эксперимента №2

Таблица 3

Результаты работы алгоритмов в Эксперименте №3

Алгоритм	Метрика	С настройками		Без настроек	
		train	test	train	test
CatBoost	MAE	2545,29	3356,54	2124,56	3553,72
LinearRegression		3223,27	3333,31	3223,27	3333,31
LSTM		5559,15	5891,64	5569,03	5901,58
RandomForest		2656,43	3313,52	1277,70	3483,51
XGBoost		206,91	4060,16	681,00	4003,61
CatBoost	R ²	0,41	-0,11	0,59	-0,26
LinearRegression		0,05	-0,06	0,05	-0,06
LSTM		-1,83	-2,10	-1,83	-2,10
RandomForest		0,36	-0,07	0,84	-0,19
XGBoost		1,00	-0,66	0,95	-0,59
CatBoost	RMSE	3168,73	4236,75	2631,84	4515,74
LinearRegression		4017,86	4145,17	4017,86	4145,17
LSTM		6914,42	7160,11	6922,41	7168,28
RandomForest		3289,61	4173,40	1643,32	4398,18
XGBoost		272,20	5196,35	899,25	5086,65

Проанализировав данные из таблицы 3, можно сделать выводы о том, что лучше всего себя показал XGBoost. Настройка гиперпараметров улучшила показатели XGBoost, минимизировав ошибки на тренировочном наборе, тем не менее, факт переобучения наблюдается. Однако, модели CatBoost и Random Forest показали улучшенные показатели после настройки гиперпараметров. Модель LSTM показала худшие результаты даже после настройки гиперпараметров по сравнению с линейной регрессией и остальными моделями. Следовательно, можно сделать вывод, что лучшее сочетание производительности на тренировочном и тестовом наборе данных показала модель XGBoost.

На рисунке 3 проиллюстрированы полученные результаты по рассчитанным метрикам после настройки гиперпараметров. Модель LSTM показывает наилучшие результаты на тренировочной выборке данных, но худшие на тестовом наборе, причиной чего может быть переобучение или недостаточная настройка модели. Модели XGBoost и CatBoost показывают более сбалансированные результаты как на тренировочной, так и на тестовой выборке.




Рис. 3. Результаты проведения Эксперимента №3

Следовательно, лучше всего себя показывает XGBoost, так как демонстрирует лучшие результаты и меньшую вероятность переобучения.

4 Выводы

Таким образом, в настоящей работе были исследованы методы и алгоритмы, применяемые в прогнозировании объёмов продаж различных товаров, что позволяет осуществлять интеллектуальную поддержку принятия управленческих решений в организационных системах торговых компаний. В ходе работы были определены основные гиперпараметры. Для обоснования выбора наиболее подходящих для решения указанной задачи методов, моделей и алгоритмов машинного обучения были проведены теоретические и экспериментальные исследования.

На основании трёх экспериментов были выявлены недостатки алгоритмов и определён лучший из них. Однако даже самые лучшие результаты показывают алгоритмы с минимальными настройками гиперпараметров, так как каждый набор данных имеет свои особенности и изъяны. Наиболее подходящим для прогнозирования объёмов продаж, согласно проведенным экспериментам, является алгоритм XGBoost.

В дальнейших исследованиях для улучшения эффективности, производительности и показателей метрик будет модифицирован алгоритм XGBoost. Алгоритм будет протестирован на уже используемых в экспериментах 1-3 трёх датасетах и также на одном новом датасете.

Литература

1. Фатхулин Т.Д., Зозуля И.С. Исследование методов прогнозирования показателей бизнес-процессов // REDS: Телекоммуникационные устройства и системы. 2025. Т. 15, № 2. С. 12-17.
2. Портнов Э.Л., Фатхулин Т.Д. Технологии достижения высоких скоростей передачи в современных когерентных DWDM-системах связи // T-Comm: Телекоммуникации и транспорт. 2015. Т. 9, - №8. С. 34-37.
3. Деарт В.Ю., Фатхулин Т.Д. Анализ современного состояния транспортных сетей с целью внедрения технологии программно-конфигурируемых сетей (SDN) // T-Comm: Телекоммуникации и транспорт. 2017. Том 11. №6. С. 4-9.
4. V. Deart and T. Fatkhulin, "Analysis of the functioning of a multi-domain transport software-defined network with controlled optical layer," 2017 21st Conference of Open Innovations Association (FRUCT), Helsinki, Finland, 2017, pp. 79-87, DOI: 10.23919/FRUCT.2017.8250168.
5. Деарт В.Ю., Фатхулин Т.Д. Анализ транспортных программно-конфигурируемых сетей (T-SDN) с управляемым оптическим уровнем с целью получения модели, позволяющей оценить возможность предоставления сервиса Bandwidth on Demand // T-Comm: Телекоммуникации и транспорт. 2018. Т.12. №4. С. 35-42.
6. Деарт В.Ю., Фатхулин Т.Д. Анализ процесса создания суперканала с необходимой пропускной способностью в сети,

построенной по технологии транспортных программно-конфигурируемых сетей (T-SDN) // T-Comm: телекоммуникации и транспорт. 2018. Том 12. №10. С. 23-30.

7. Leokhin Y.L., Fatkhulin T.D. Approach to Estimating the Probability of Providing "Cloud" Services in the SDN // 2020 Systems of Signals Generating and Processing in the Field of on Board Communications, Moscow, Russia, 2020, pp. 1-9, DOI: 10.1109/IEEECONF48371.2020.9078593.

8. Leokhin Y.L., Fatkhulin T.D. Evaluation of Service Availability in Software-Defined Optical Network // 2021 Systems of Signals Generating and Processing in the Field of on Board Communications, Moscow, Russia, 2021, pp. 1-6, DOI: 10.1109/IEEECONF51389.2021.9416122.

9. Вишневецкий В.М., Леохин Ю.Л., Фатхулин Т.Д., Занегин А.В. Методы машинного обучения в решении задачи прогнозирования спроса на отдельные виды товаров // T-Comm: Телекоммуникации и транспорт. 2024. Том 18. №10. С. 34-43.

10. Ринас Н.А., Золкин А.Л., Каберова А.Р., Скибин Ю.В. Влияние автоматизации и искусственного интеллекта на социальное неравенство // Экономика и управление: проблемы, решения. 2025. Т. 7, № 1(154). С. 116-125. DOI 10.36871/ek.up.p.r.2025.01.07.015. EDN BGBKZZ

11. Бесталова В.В., Каберова А.Р., Белинская Д.Б. [и др.]. Методический подход к управлению устойчивостью развития региона // Экономика и управление: проблемы, решения. 2024. Т. 11, № 11(152). С. 88-93. DOI 10.36871/ek.up.p.r.2024.11.11.011. EDN GDEJYC

12. Драгуленко В.В., Золкин А.Л., Есина О.И., Каберова А.Р. Влияние численности населения на экономический рост и развитие стран // Экономика и управление: проблемы, решения. 2024. Т. 11, № 9(150). С. 67-75. DOI 10.36871/ek.up.p.r.2024.09.11.009. EDN ANEUBG

13. Леохин Ю.Л., Фатхулин Т.Д., Занегин А.В. Модификация метода градиентного усиления для прогнозирования спроса на отдельные виды товаров // Научные технологии в космических исследованиях Земли. 2025. Т. 17. № 2. С. 32-41. DOI: 10.36724/2409-5419-2025-17-2-32-41

14. Леохин Ю.Л., Дымкова С.С., Фатхулин Т.Д. Исследование и разработка инструментальных средств повышения качества изображений // T-Comm: Телекоммуникации и транспорт. 2025. Том 19. №4. С. 45-56. (in English)

15. Леохин Ю.Л., Дымкова С.С., Фатхулин Т.Д. Методы машинного обучения в прикладных задачах прогнозирования динамично изменяющихся данных // T-Comm: Телекоммуникации и транспорт. 2025. Том 19. №8. С. 49-63.

16. Дымкова С.С., Кретова И.С., Варламов О.В. Научометрический анализ результатов рецензирования материалов конференции TIRVED2024 // T-Comm: Телекоммуникации и транспорт. 2024. Том 18. №12. С. 19-26.

17. Leokhin Y., Fatkhulin T., Boitsov K. Computer Vision Methods in Applied Problems of Classifying Objects in Images // 2025 Wave Electronics and its Application in Information and Telecommunication Systems (WECONF), St. Petersburg, Russian Federation, 2025, pp. 1-10, DOI: 10.1109/WECONF65186.2025.11017109.

18. Leokhin Y., Fatkhulin T., Zanezin A., Rakhmatova A. Researching the Efficiency of Machine Learning Methods Used in Forecasting Demand for Certain Types of Goods // 2025 Systems of Signals Generating and Processing in the Field of on Board Communications, Moscow, Russian Federation, 2025, pp. 1-8, DOI: 10.1109/IEEECONF64229.2025.10948113.

19. Fatkhulin T., Leokhin Y., Zanezin A., Rakhmatova A. Development and Research of a Modified Gradient Boosting Method Effectiveness to Solve Applied Problems of Time-Series Forecasting // 2025 Systems of Signals Generating and Processing in the Field of on Board Communications, Moscow, Russian Federation, 2025, pp. 1-10, DOI: 10.1109/IEEECONF64229.2025.10948023.

20. Варламов О.В. Организация одночастотных сетей цифрового радиовещания стандарта DRM. Особенности и результаты практических испытаний // T-Comm: Телекоммуникации и транспорт. 2018. Том 12. №11. С. 4-20. EDN: YQNCWT

21. Варламов О.В., Варламов В.О., Долгопятова А.В. Международная сеть DRM вещания для создания информационного поля в Арктике // T-Comm: Телекоммуникации и транспорт. 2019. Том 13. №9. С. 9-16. EDN: CHEXOK

22. Дымкова С.С. Новые принципы организации функционирования систем по продвижению результатов научных исследований // Системы синхронизации, формирования и обработки сигналов. 2017. Т. 8. № 1. С. 34-37. EDN: ZWBOYX

METHODS AND ALGORITHMS OF INTELLECTUAL SUPPORT FOR MAKING MANAGEMENT DECISIONS IN ORGANIZATIONAL SYSTEMS OF TRADING COMPANIES

Yuri L. Leokhin, Moscow Technical University of Communications and Informatics, Moscow, Russia, y.l.leokhin@mtuci.ru
Svetlana S. Dymkova, Moscow Technical University of Communications and Informatics, Moscow, Russia, s.s.dymkova@mtuci.ru
Timur D. Fatkhulin, Moscow Technical University of Communications and Informatics, Moscow, Russia, t.d.fatkhulin@mtuci.ru
Irina S. Zozulya, Moscow Technical University of Communications and Informatics, Moscow, Russia, s.s.dymkova@mtuci.ru

Abstract

This paper is a study of the problem of forecasting sales volumes in organizational systems of trading companies. The purpose of the work is to determine the most effective method and algorithm used for intelligent decision-making on changing sales volumes of a trading organizational system. The relevance of this work lies in the rapid growth of the received volumes of information and data, as well as the need for trading companies to keep up with the times and the ability to promptly adjust business strategies by making management decisions in their organizational systems. Traditional methods based on probability theory and mathematical statistics cannot effectively carry out sales forecasts taking into account the above trends in global business processes. The use of modern methods that are focused on forecasting the type of data in question can provide a significant increase in the efficiency of solving this problem. The object of the study is the sales volumes of trading companies. The subject of the study is metrics for assessing the quality of methods and algorithms for forecasting sales volumes for making management decisions in the organizational systems of trading companies. Based on the results of the study, optimal methods and algorithms were identified that provide high accuracy of forecasting demand for various product categories. Recommendations are presented regarding the appropriateness of certain settings of model hyperparameters that contribute to improving the quality of forecasting results. Conclusions are made on the practical application of each method and algorithm, and research directions and prospects are indicated. The research methodology is based on analytical methods, including comparative analysis, experiment, and generalization of the findings.

Keywords: algorithm, method, metric, efficiency, intellectual support, organizational system, model

References

- [1] T. D. Fatkhulin and I. S. Zozulya, "Study of methods for forecasting business process indicators," *REDS: Telecommunication devices and systems*, 2025. Vol. 15, No. 2. pp. 12-17. (in Russian)
- [2] E. L. Portnov and T. D. Fatkhulin, "Technologies aimed at achieving high speed transmission in modern coherent DWDM communication systems," *T-Comm*. 2015. Vol 9. No.8, pp. 34-37. (in Russian)
- [3] V. Yu. Deart and T. D. Fatkhulin, "Analysis of current state of transport networks with the purpose of introducing software defined networks (SDN) technology," *T-Comm*, 2017, vol. 11, no.6, pp. 4-9. (in Russian)
- [4] V. Deart and T. Fatkhulin, "Analysis of the functioning of a multi-domain transport software-defined network with controlled optical layer," *2017 21st Conference of Open Innovations Association (FRUCT)*, Helsinki, Finland, 2017, pp. 79-87, DOI: 10.23919/FRUCT.2017.8250168.
- [5] V. Yu. Deart and T. D. Fatkhulin, "Analysis of transport software-defined networks (T-SDN) with controlled optical layer to obtain a model providing assesment of the possibility of bandwidth on demand service," *T-Comm*, 2018, vol. 12, no.4, pp. 35-42. (in Russian)
- [6] V. Yu. Deart and T. D. Fatkhulin, "Analysis of the process of creating a superchannel with the necessary capacity in the network organized according to transport software-defined networks (T-SDN) technology," *T-Comm*, 2018, vol. 12, no.10, pp. 23-30. (in Russian)
- [7] Y. L. Leokhin and T. D. Fatkhulin, "Approach to Estimating the Probability of Providing "Cloud" Services in the SDN," *2020 Systems of Signals Generating and Processing in the Field of on Board Communications*, Moscow, Russia, 2020, pp. 1-9, DOI: 10.1109/IEEECONF48371.2020.9078593.
- [8] Y. L. Leokhin and T. D. Fatkhulin, "Evaluation of Service Availability in Software-Defined Optical Network," *2021 Systems of Signals Generating and Processing in the Field of on Board Communications*, Moscow, Russia, 2021, pp. 1-6, DOI: 10.1109/IEEECONF51389.2021.9416122.
- [9] V. M. Vishnevsky, Yu. L. Leokhin, T. D. Fatkhulin and A. V. Zanein, "Machine learning methods in solving the problem of forecasting demand for specific types of goods," *T-Comm*, vol. 18, no. 10, pp. 34-43. (in Russian)
- [10] N. A. Rinas, A. L. Zolkin, A. R. Kaberova and Yu. V. Skibin, "The Impact of Automation and Artificial Intelligence on Social Inequality," *Economy and Management: Problems, Solutions*, 2025, Vol. 7, No. 1(154), pp. 116-125. DOI 10.36871/ek.up.p.r.2025.01.07.015. (in Russian)
- [11] V. V. Bespalova, A. R. Kaberova, D. B. Belinskaya [et al.], "Methodological approach to managing the sustainability of regional development," *Economy and Management: Problems, Solutions*, 2024, Vol. 11, No. 11(152), pp. 88-93. DOI 10.36871/ek.up.p.r.2024.11.11.011. (in Russian)
- [12] V. V. Dragulenko, A. L. Zolkin, O. I. Esina and A. R. Kaberova, "The Impact of Population on Economic Growth and Development of Countries," *Economy and Management: Problems, Solutions*, 2024, Vol. 11, No. 9(150), pp. 67-75. DOI 10.36871/ek.up.p.r.2024.09.11.009. (in Russian)
- [13] Yu. L. Leokhin, T. D. Fatkhulin, A. V. Zanein, "The gradient boosting method modification to forecast demand for individual types of goods," *H&ES Reserch*. 2025. Vol. 17. No. 2, pp. 32-41. Dpt. of MC and IT, Docent, Candidate Sc. (Tech.), Moscow Technical University of Communications and Informatics, Moscow, Russian Federation, 2025, pp. 1-10, DOI: 10.1109/IEEECONF64229.2025.10948113.
- [14] Yu. L. Leokhin, S. S. Dymkova, T. D. Fatkhulin, "Research and development of image improvement tools," *T-Comm*, 2025, vol. 19, no. 4, pp. 45-56.
- [15] Yu. L. Leokhin, S. S. Dymkova, T. D. Fatkhulin, "Machine learning methods in applied problems of forecasting dynamically changing data", *T-Comm*, 2025, vol. 19, no.8, pp. 49-63. (in Russian)
- [16] S. S. Dymkova, I. S. Kretova and O. V. Varlamov, "Conference papers per-reviewing results: TIRVED-2024 scientometric research," *T-Comm*, vol. 18, no.12 pp. 19-26. (in Russian)
- [17] Y. Leokhin, T. Fatkhulin and K. Boitsov, "Computer Vision Methods in Applied Problems of Classifying Objects in Images," *2025 Wave Electronics and its Application in Information and Telecommunication Systems (WECONF)*, St. Petersburg, Russian Federation, 2025, pp. 1-10, DOI: 10.1109/WECONF65186.2025.11017109.
- [18] Y. Leokhin, T. Fatkhulin, A. Zanein and A. Rakhmatova, "Researching the Efficiency of Machine Learning Methods Used in Forecasting Demand for Certain Types of Goods," *2025 Systems of Signals Generating and Processing in the Field of on Board Communications*, Moscow, Russian Federation, 2025, pp. 1-8, DOI: 10.1109/IEEECONF64229.2025.10948113.
- [19] T. Fatkhulin, Y. Leokhin, A. Zanein and A. Rakhmatova, "Development and Research of a Modified Gradient Boosting Method Effectiveness to Solve Applied Problems of Time-Series Forecasting," *2025 Systems of Signals Generating and Processing in the Field of on Board Communications*, Moscow, Russian Federation, 2025, pp. 1-10, DOI: 10.1109/IEEECONF64229.2025.10948023.
- [20] O.V. Varlamov, "Organization of single frequency DRM digital radio broadcasting networks. Features and results of practical tests," *T-Comm*. 2018. vol. 12, no.11, pp. 4-20.
- [21] O.V. Varlamov, V.O. Varlamov, A.V. Dolgopyatova, "DRM broadcasting international network to create an information field in the Arctic region," *T-Comm*. 2019. vol. 13, no.9, pp. 9-16.
- [22] S. S. Dymkova, "New principles for organizing the functioning of systems to promotion scientific research results," *Synchronization, signal generation and processing systems*, 2017, vol. 8, no. 1, pp. 34-37.

Information about authors:

Yuri L. Leokhin, Vice-Rector for Scientific Work, full professor, Dr. Sc. (Tech.), Moscow Technical University of Communications and Informatics, Moscow, Russia, orcid.org/0000-0003-3321-4497

Svetlana S. Dymkova, Candidate Sc. (Tech.), Moscow Technical University of Communications and Informatics, Moscow, Russia, orcid.org/0000-0003-0945-9850

Timur D. Fatkhulin, Dpt. of MC and IT, Docent, Candidate Sc. (Tech.), Moscow Technical University of Communications and Informatics, Moscow, Russia, orcid.org/0000-0003-0998-1055

Irina S. Zozulya, master's student, Moscow Technical University of Communications and Informatics, Moscow, Russia, orcid.org/0009-0006-3445-8070