



DOI: <https://doi.org/10.15688/ek.jvolsu.2026.1.12>

UDC 338.001.36  
LBC 65.054

Submitted: 23.12.2025  
Accepted: 13.01.2026

## APPLYING MACHINE LEARNING TECHNIQUES TO MANAGE INVENTORY IN RETAIL STORES

**Tatyana I. Guseva**

South Ural State University, Chelyabinsk, Russian Federation

**Abstract.** Based on the analysis of inventory management methods in retail trade, the paper shows the shortcomings of traditional demand planning methods when faced with a real market environment characterized by complex nonlinear dependencies. The author's hypothesis about the possibility of using an autoregressive model (AR) that includes integration (I) and moving average (MA) in combination with the LSTM machine learning method has been developed and tested in a model for demand forecasting in the retail trade of stationery products by ООО Kantstanta (LLC). The presented model allows processing stationary and non-stationary data series and identifying possible seasonal components and hidden patterns in the data. Sales information is loaded from a CSV file, where the data is presented in a wide format with monthly details, and there is an option for integration with 1C Accounting. The ARIMA model automatically decides whether differentiation is necessary in the case of a non-stationary series. Using LSTM machine learning is an option to improve this model, as machine learning methods show advantages for short-term forecasts, especially under high volatility conditions and in the presence of nonlinear relationships. An important feature of the model is the visual representation of time series with forecast values. The analysis of seven product categories using the model revealed different demand patterns, each of which requires an individual approach to calculating the optimal inventory level. The study results confirmed the effectiveness of using machine learning methods to manage inventory in conditions of dynamic demand changes and high competition.

**Key words:** inventory management, retail, demand forecasting, autoregressive models, machine learning.

**Citation.** Guseva T.I. Applying Machine Learning Techniques to Manage Inventory in Retail Stores. *Vestnik Volgogradskogo gosudarstvennogo universiteta. Ekonomika* [Journal of Volgograd State University. Economics], 2026, vol. 28, no. 1, pp. 143-152. (in Russian). DOI: <https://doi.org/10.15688/ek.jvolsu.2026.1.12>

УДК 338.001.36  
ББК 65.054

Дата поступления статьи: 23.12.2025  
Дата принятия статьи: 13.01.2026

## ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ УПРАВЛЕНИЯ ТОВАРНЫМИ ЗАПАСАМИ В РОЗНИЧНОЙ ТОРГОВЛЕ

**Татьяна Игоревна Гусева**

Южно-Уральский государственный университет, г. Челябинск, Российская Федерация

**Аннотация.** На основе анализа методов управления товарными запасами в розничной торговле показаны недостатки традиционных методов планирования спроса при столкновении с реальной рыночной средой, характеризующейся сложными нелинейными зависимостями. Авторская гипотеза о возможности применения авторегрессионной модели (AR), включающей интегрирование (I) и скользящее среднее (MA), в сочетании с методом машинного обучения LSTM получила развитие в разработанной и протестированной модели для прогнозирования спроса в розничной торговле канцелярскими товарами ООО «Канцтанта». Представленная модель позволяет обрабатывать стационарные и нестационарные ряды данных, идентифицировать возможные сезонные компоненты и скрытые паттерны в данных. Информация о продажах загружается из CSV-файла, где данные представлены в широком формате с ежемесячной детализацией, при этом есть возможность интеграции с 1С: Бухгалтерией. Модель ARIMA автоматически принимает решение о необходимости дифференцирования в случае нестационарного ряда. Использование машинного обучения

LSTM является вариантом улучшения данной модели, так как методы машинного обучения демонстрируют преимущество для краткосрочных прогнозов, особенно в условиях высокой волатильности, и при наличии нелинейных взаимосвязей. Важной особенностью модели является наглядная визуализация временных рядов с прогнозными значениями.

**Ключевые слова:** управление запасами, ритейл, прогнозирование спроса, авторегрессионные модели, машинное обучение.

**Цитирование.** Гусева Т. И. Применение методов машинного обучения для управления товарными запасами в розничной торговле // Вестник Волгоградского государственного университета. Экономика. – 2026. – Т. 28, № 1. – С. 143–152. – DOI: <https://doi.org/10.15688/ek.jvolsu.2026.1.12>

## Введение

Управление товарными запасами заключается в поддержании оптимального уровня запасов, снижении текущих расходов и избежании дефицита. Важным моментом в управлении запасами является правильный прогноз спроса особенно для товаров с ярко выраженной сезонностью или подверженных влиянию модных тенденций. Традиционные методы прогнозирования спроса часто полагаются на исторические данные и ручной анализ, поэтому могут не учитывать сложности и динамичного характера современных рынков. Одной из широко используемых статистических моделей для прогнозирования временных рядов является ARIMA (Autoregressive Integrated Moving Average). Данная модель сочетает в себе авторегрессию (AR), интегрирование (I) и скользящее среднее (MA). Модели с использованием машинного обучения более сложные в реализации, менее прозрачные в работе с данными, однако этот вид моделей позволяет работать с нелинейными зависимостями, улавливает сложные паттерны в данных. К моделям этого вида можно отнести SVR, Random Forest, XGBoost, LSTM с ее модификациями и др. [Применение методов ... , 2025]. Интеграция статистических методов анализа данных и машинного обучения способствует устойчивому росту и конкурентному преимуществу на рынке [Рогулин, 2023].

## Методика

В практике управления товарными запасами традиционно применяются два взаимодополняющих метода анализа и оптимизации, каждый из которых решает специфический круг задач. ABC/XYZ-анализ представляет собой комбинированный подход, позволяющий

классифицировать товарные позиции по двум ключевым параметрам: значимости для бизнеса и стабильности спроса. В основе ABC-анализа лежит принцип Парето, согласно которому небольшая доля ассортимента (группа А, обычно 20 % позиций) обеспечивает основную часть выручки (около 80 %). XYZ-анализ дополняет эту классификацию оценкой предсказуемости спроса, выделяя товары с устойчивым (X), переменным (Y) и нерегулярным (Z) характером потребления. Совместное применение этих методов позволяет выработать дифференцированную стратегию управления запасами для различных товарных групп [Zenkova et al., 2018].

EOQ-модель (Economic Order Quantity) предлагает принципиально иной подход к оптимизации, фокусируясь на расчете оптимального размера заказа, минимизирующего совокупные логистические издержки. Модель основывается на балансировке между затратами на хранение и расходами на оформление заказов, учитывая постоянный уровень спроса и мгновенное пополнение запасов.

Классическая формула Уилсона, являющаяся математическим выражением EOQ-модели, выводит оптимальный объем заказа как функцию от годового спроса, стоимости размещения заказа и затрат на хранение единицы товара. Тем не менее практическая применимость базовой версии модели ограничена рядом допущений, включая постоянство спроса и отсутствие дефицита [Горшкова и др., 2025].

Ограничения традиционных методов становятся особенно заметными при работе с современными ассортиментными матрицами, характеризующимися высокой динамикой спроса и сложными паттернами потребления. ABC/XYZ-анализ, несмотря на свою наглядность, не учитывает сезонные колебания и

взаимозаменяемость товаров, что может приводить к субоптимальным решениям в условиях быстро меняющегося рынка. EOQ-модель в своей классической форме демонстрирует низкую эффективность при работе с товарами, имеющими прерывистый спрос или значительные колебания в цепочке поставок. Эволюция традиционных подходов проявляется в разработке модифицированных версий EOQ-модели, учитывающих факторы, изначально не включенные в базовую формулировку. Модели с учетом оптовых скидок, вероятностного спроса и ограниченной мощности складов расширяют область применения метода, сохраняя при этом его концептуальную основу. Аналогичным образом развивается ABC/XYZ-анализ, интегрирующий дополнительные параметры классификации, такие как валовая маржинальность товаров или их стратегическая значимость для бизнеса. Подобные модификации позволяют частично преодолеть ограничения исходных методов, сохраняя их концептуальную простоту и наглядность.

Классические модели управления товарными запасами, вопреки своей концептуальной стройности и математической элегантности, демонстрируют существенные ограничения при столкновении с реальной рыночной средой, характеризующейся сложными нелинейными зависимостями. Основная слабость традиционных подходов заключается в их принципиальной линейности – они предполагают существование простых пропорциональных связей между параметрами системы, что редко соответствует действительности в условиях современного ритейла.

Проблема усугубляется при учете взаимовлияния различных факторов спроса, которое в классических моделях либо игнорируется, либо чрезмерно упрощается. Реальный потребительский спрос формируется под воздействием сложной системы нелинейных взаимосвязей между ценой, сезонностью, маркетинговой активностью и макроэкономическими показателями. Особенно ярко недостатки классических подходов проявляются при работе с нестационарными процессами и нелинейными динамическими системами, характерными для современных рынков. Традиционные модели, основанные на предположении о стационарности спроса и нормальном рас-

пределении ошибок прогнозирования, оказываются неадекватными при наличии таких явлений, как хаотическая динамика, долговременная память или фрактальные свойства временных рядов. Попытки применения линейных моделей к подобным системам приводят к систематическому занижению оценки рисков и существенным ошибкам в расчетах оптимальных уровней запасов. Это особенно критично для товаров с ярко выраженной сезонностью или подверженных влиянию модных тенденций, где традиционные методы дают наибольшие отклонения от реальных значений [Горшкова и др., 2025].

Регрессионный анализ занимает центральное место в арсенале методов прогнозирования спроса благодаря своей концептуальной ясности и интерпретируемости результатов. В основе регрессионных моделей лежит предположение о существовании функциональной зависимости между объемом спроса и набором факторов, влияющих на его формирование. Коэффициенты регрессии в данных моделях имеют четкую экономическую интерпретацию, показывая, на сколько единиц изменится объем спроса при изменении соответствующего фактора на одну единицу при прочих равных условиях.

Множественная линейная регрессия расширяет аналитические возможности за счет одновременного учета нескольких факторов спроса, что особенно важно в условиях реального рынка, где на потребительское поведение влияет комплекс взаимосвязанных переменных. В этих моделях каждый коэффициент отражает предельный вклад соответствующего фактора в формирование спроса при фиксированных значениях остальных переменных. В то же время применение классических регрессионных моделей сталкивается с проблемой мультиколлинеарности, когда объясняющие переменные оказываются сильно коррелированными между собой, что приводит к нестабильности оценок коэффициентов и затрудняет их интерпретацию.

Несмотря на широкое распространение линейных моделей, многие реальные зависимости между факторами и объемом спроса носят нелинейный характер. Для учета этой нелинейности применяются различные модификации регрессионного анализа, включая

полиномиальную регрессию, где зависимость моделируется полиномами более высоких степеней, и обобщенные линейные модели, позволяющие работать с нелинейными связями через использование функций связи.

Временные ряды спроса часто демонстрируют сложную структуру, включающую тренд, сезонность и случайные колебания, что требует специальных подходов к моделированию. Авторегрессионные модели (AR) и модели со скользящими средними (MA), а также их комбинации (ARIMA) позволяют учитывать автокорреляцию в данных и строить прогнозы на основе прошлых значений ряда спроса. Для учета влияния внешних факторов применяются модели с распределенным лагом и векторные авторегрессионные модели, которые позволяют анализировать взаимное влияние нескольких временных рядов. Современные разработки в этой области включают модели с изменяющимися во времени параметрами, способные адаптироваться к структурным сдвигам в динамике спроса [Тарасюк, 2025]. Модификацией ARIMA с учетом фактора сезонности является модель SARIMA. Данная модель требует подбора дополнительных параметров, связанных с фактором сезонности, что несколько усложняет ее использование [Wang, 2023].

Методы машинного обучения обычно превосходят статистические подходы в задачах классификации по метрикам точности, полноты и гармонической средней между точностью и полнотой (по F1-мере). Особенно значительное преимущество ML-методов наблюдается при наличии нелинейных взаимосвязей, большого числа потенциальных предикторов и разнородных данных [Волков, 2023; Digital Technologies ... , 2019]. Для анализа временных рядов в контексте прогнозирования спроса применяются методы машинного обучения Random Forest, SVR, XGBoost, LSTM.

Алгоритм Random Forest демонстрирует высокую эффективность при работе с данными, содержащими большое количество категориальных признаков, таких как регион продаж, категория товара или тип покупателя. Способность учитывать сложные взаимодействия между переменными без явного их указания делает Random Forest особенно полезным при моделировании спроса, где часто

наблюдаются неочевидные комбинации влияющих факторов. В то же время интерпретируемость модели снижается по сравнению с линейными методами, что требует использования дополнительных методов объяснения, среди которых анализ частичных зависимостей или SHAP-значения.

SVR также может обрабатывать в данных сложные и нелинейные взаимосвязи, часто присутствующие во временных рядах. Алгоритм фокусируется на захвате основной тенденции, а не на запоминании конкретных точек данных, что делает прогнозы более надежными для будущих шагов. Недостаток метода – сложность настройки из-за большого количества гиперпараметров в конфигурации.

Особенностями XGBoost является способность строить ансамбль из слабых предсказывающих моделей и эффективно обрабатывать разреженные данные. При этом алгоритм не обладает свойством экстраполяции за пределы домена обучающей выборки, что важно при прогнозировании временных рядов, и из-за большого количества гиперпараметров имеет сложную конфигурацию.

Долгая краткосрочная память LSTM как архитектура рекуррентных нейронных сетей представляет собой мощный инструмент для моделирования временных рядов спроса, обладающий способностью улавливать сложные временные зависимости. В отличие от традиционных статистических методов, LSTM специально разработана для обработки последовательностей с долговременными зависимостями, что особенно актуально для задач прогнозирования спроса, где текущие значения могут зависеть от событий, произошедших значительно раньше. Ключевой особенностью LSTM является наличие специальных вентиляционных механизмов забывания, входа и выхода, которые позволяют сети регулировать поток информации через временные шаги, сохраняя важные долгосрочные зависимости и фильтруя нерелевантную информацию. Архитектурные особенности LSTM делают ее особенно подходящей для работы с реальными данными спроса, которые часто характеризуются нестационарностью, шумами и сложными сезонными паттернами. Способность модели автоматически извлекать и комбинировать признаки различной временной

природы, от краткосрочных колебаний до долгосрочных трендов, позволяет достигать высокой точности прогнозирования без необходимости ручного проектирования признаков. Важным преимуществом LSTM при моделировании спроса является возможность обработки многомерных временных рядов, когда наряду с историческими значениями самого спроса учитываются дополнительные временные признаки, например цены, маркетинговые акции или макроэкономические показатели. Это позволяет создавать комплексные модели, учитывающие множество взаимосвязанных факторов, влияющих на потребительское поведение. Практическая реализация LSTM для прогнозирования спроса требует решения ряда методологических вопросов. Определение оптимальной глубины архитектуры (количество LSTM-слоев) и ширины (количество скрытых единиц в каждом слое) представляет собой компромисс между способностью модели улавливать сложные зависимости и риском переобучения. Особое внимание при обучении LSTM-моделей уделяется подготовке временных данных, включающей нормализацию, создание скользящих окон и стратегию разделения на обучающую и тестовую выборки с сохранением временного порядка. Для предотвращения переобучения, часто возникающего при работе с относительно небольшими наборами данных о спросе, применяются такие техники, как дропаут, ранняя остановка и регуляризация.

Сравнительные исследования демонстрируют, что LSTM особенно эффективны при прогнозировании спроса с ярко выраженными нелинейными и нестационарными характеристиками, где традиционные методы временных рядов показывают ограниченную эффективность [Волков, 2023; Применение методов ... , 2025; Погулин, 2023; Тарасюк, 2025; A Comparative Study ... , 2022]. Способность модели адаптироваться к изменяющимся во времени паттернам спроса делает ее устойчивой к структурным сдвигам в данных, часто наблюдаемым в реальных бизнес-средах. Однако применение LSTM сопряжено с повышенными вычислительными затратами и требовательностью к объему обучающих данных по сравнению с более простыми методами. Интерпретируемость LSTM-моделей оста-

ется существенным вызовом, хотя современные методы объяснимого искусственного интеллекта позволяют частично преодолеть этот недостаток [Артемов, 2025].

Сравнительный анализ традиционных экономических моделей и методов машинного обучения демонстрирует, что данные подходы обладают взаимодополняющими преимуществами и ограничениями. Это создает основу для разработки интегрированных методологий, сочетающих теоретическую обоснованность и интерпретируемость традиционных моделей с гибкостью и адаптивностью ML-подходов [Loureiro et al., 2018].

Гибридные модели объединяют прогнозы нескольких моделей для создания более надежного и точного прогноза. Например, при прогнозировании спроса модель ансамбля может сочетать прогнозы регрессионных моделей, нейронных сетей и традиционных статистических методов. Гибридные модели смягчают неотъемлемую неопределенность и изменчивость данных о спросе, что повышает эффективность прогнозирования [Abbasimehr et al., 2020; Wang et al., 2021].

## Результаты и обсуждения

Для прогнозирования спроса на канцелярские товары ООО «Канстанта» построена гибридная модель ARIMA-LSTM, в которой ARIMA моделирует долгосрочную динамику, а LSTM – краткосрочные паттерны. При резких изменениях объема продаж, которые могут указывать на изменение рыночного спроса, LSTM сохраняет информацию в состоянии ячейки и контролирует, как она обновляется и передается в следующий шаг времени. Кроме того, модель забывает устаревшую нерелевантную информацию и фокусируется на свежих сигналах. Это достигается благодаря четырехслойной архитектуре повторяющегося блока LSTM, а также способности модели использовать агрегированные данные для изучения временной зависимости. Для минимизации влияния размерности скрытого состояния для исследуемых товарных групп был задан собственный набор обучаемых параметров, благодаря чему каждая последовательность реагирует на специфические закономерности, не разделяя параметров с другими.

Исследование проводилось на основе данных о выручке ООО «Канстанта» за 2021–2024 годы. Первоначальная обработка данных включает загрузку информации о продажах из CSV-файла, где данные представлены в широком формате с ежемесячной детализацией. Для перехода к длинному формату применяется метод *melt*, который трансформирует столбцы с датами в отдельные наблюдения. Особое внимание уделяется очистке числовых значений: удаляются пробелы в качестве разделителей разрядов, запятые заменяются точками для корректного преобразования в вещественные числа. Это критически важный этап, поскольку некорректная обработка числовых данных может привести к существенным ошибкам в расчетах. Особенностью подхода является автоматизированный подбор параметров модели на основе статистических критериев, что позволяет адаптировать алгоритм к специфике каждого товара.

После группировки данных по товарным категориям и датам осуществляется проверка стационарности ряда с помощью расширенного теста Дики – Фуллера. Алгоритм подбора оптимальных параметров ARIMA реализует разветвленную логику в зависимости от стационарности исходного ряда. Для стационарных временных рядов перебираются комбинации параметров  $p$  и  $q$  в диапазоне от 0 до 2 при фиксированном  $d = 0$ . В случае нестационарных данных дифференцирование первого порядка ( $d = 1$ ) выполняется автоматически, после чего поиск оптимальных  $p$  и  $q$  осуществляется для стабилизированного ряда. Критерием оптимальности служит информационный критерий Акаике (AIC), который позволяет находить баланс между точностью модели и ее сложностью. Представленный алгоритм не только вычисляет  $p$ -значение, но и автоматически принимает решение о необходимости дифференцирования. Если  $p$ -значение превышает 0,05, ряд считается нестационарным и применяется операция первого порядка дифференцирования. Тем не менее для дифференцированного ряда дополнительно строятся графики автокорреляционной (ACF) и частичной автокорреляционной (PACF) функций, что позволяет визуально оценить структуру временного ряда и сделать предварительные выводы о воз-

можных значениях параметров  $p$  и  $q$ , а также идентифицировать возможные сезонные компоненты и скрытые паттерны в данных. Важной особенностью реализации алгоритма является наглядная визуализация результатов, включающая как фактические значения временного ряда, так и спрогнозированные показатели. Визуальный анализ этих графиков предоставляет аналитику ценную информацию для возможной модификации модели, например, перехода к SARIMA для учета сезонности.

Применение модели ARIMA в сочетании с LSTM-методом для прогнозирования спроса различных товарных категорий продемонстрировало его универсальность. Результаты анализа представлены в таблице.

Для категорий (школьно-письменные принадлежности, офисная бумага, сезонные товары) рассчитываются индексы сезонности путем сопоставления ежемесячных данных с усредненными значениями. Особое значение имеет дифференциация анализа:

- товары с выраженной цикличностью (тетради, дневники, ранцы) демонстрируют устойчивый пик в августе – сентябре (до 40–60 % квартальной выручки), обусловленный подготовкой к учебному году;

- офисные расходные материалы (бумага А4, картриджи) имеют менее выраженную, но статистически значимую сезонность с ростом в конце финансовых кварталов (март, июнь, сентябрь, декабрь), коррелирующую с бюджетными циклами корпоративных клиентов;

- сезонные товары широкого потребления (тепловые пушки, елочные украшения) показывают четкую привязку к климатическим и календарным факторам с пиками в ноябре – декабре и июне – июле.

Отклонения от исторических сезонных трендов служат маркерами структурных сдвигов. Резкий рост продаж бумаги А4 в марте 2020 г. (вопреки прогнозируемому снижению) отразил переход на удаленную работу, а рост квартальных продаж электроники в 2022 г. коррелировал с изменением бюджетного цикла корпоративных клиентов. Мониторинг таких аномалий позволяет адаптировать прогнозные модели к меняющимся рыночным условиям.

Анализ данных выявляет существенные межкатегорийные различия. Канцелярские товары для школы формируют 65–70 % годового оборота категории в III квартале, при этом динамика внутри категории неоднородна: базовые позиции (тетради 12–48 листов) имеют более сглаженный профиль, тогда как специализированные товары (дневники, наборы для творчества) отличаются резкой концентрацией спроса.

В категории офисной бумаги сезонность носит вторичный характер относительно структурных сдвигов: рост доли бумаги для цифровой печати нивелирует традиционный квартальный пик спроса на офсетные сорта. Особый интерес представляют товары с двойной сезонностью. Например, гуашь и акварельные краски демонстрируют пики не только в августе (школьный спрос), но и в апреле – мае (подготовка к летним пленэрам). Подобные нюансы критичны для оптимизации ассортиментной политики и логистики.

В ходе исследования была изучена возможность интеграция модели ARIMA-LSTM с 1С: Бухгалтерией.

Для настройки ансамбля потребовалась первоначальная обработка данных, что увеличило время настройки, кроме того, значительно возросла вычислительная нагрузка на компьютерную технику. Следовательно, для масштабирования на большое количество наименований товарных единиц целесообразно реализовать автоматизированный процесс подбора весов, позволяющий обрабатывать каждый временной ряд без участия оператора.

## Выводы

Проведенный анализ товарных категорий с использованием модели выявил различные паттерны спроса, каждый из которых требует индивидуального подхода к расчету оптимального объема заказа. Сезонная амплитуда напрямую влияет на ключевые показатели эффективности:

– управление запасами: категории с коэффициентом сезонности  $> 1,5$  (новогодний декор, школьные ранцы) требуют создания стратегических запасов за 3–4 месяца до пика, сопряженного с рисками иммобилизации капитала;

Таблица. Характеристики временных товарных рядов

Table. Characteristics of time series of commodities

Категория товара	Вид ряда	Оптимальные параметры модели	Динамика спроса
Бумага формата А4	Нестационарный ADF-статистика = $-2.860$ , p-value = $0.050156$	$p = 2$ (авторегрессия), $d = 1$ (дифференцирование), $q = 0$ (скользящее среднее) с показателем AIC = $1\ 559.799$	В августе наблюдается значительный рост, максимальное значение прогноза приходится на сентябрь, что может быть связано с сезонным повышением спроса в начале осени. Затем следует спад, после чего значения стабилизируются до конца прогнозного периода
Наборы первоклассника	Нестационарный ADF-статистика = $-0.491$ , p-value = $0.893810$	ARIMA(0, 1, 2) с AIC = $1390.606$	Резкий рост в августе – сентябре с последующей стабилизацией на этом уровне до конца прогнозного периода
Файлы формата А4	Стационарный ADF-статистика = $-6.807$ , p-value = $2.16748e-09$	ARIMA(0, 0, 0) с AIC = $1\ 278.328$	Хорошо предсказуемый, постоянный спрос на продукцию
Шариковые ручки	Стационарный ADF-статистика = $-3.177$ , p-value = $0.021362$	ARIMA(0, 0, 0) с AIC = $1\ 207.93$	Постоянный уровень прогнозируемого спроса
Папки регистраторов	Стационарный ADF-статистика = $-4.264$ , p-value = $0.000513$	ARIMA(0, 0, 0) с AIC = $1\ 129.29$	Постоянный уровень спроса
Бумага с липким слоем	Стационарный ADF-статистика = $-8.757$ , p-value = $2.73348e-14$	ARIMA(0, 0, 0) с AIC = $950.886$	Постоянный уровень спроса
Калькуляторы	Стационарный ADF-статистика = $-6.908$ , p-value = $1.23072e-09$	ARIMA(0, 0, 0) с AIC = $1\ 101.845$	Постоянный уровень спроса

– ценовая политика: для товаров с жесткой сезонностью (например, елочные украшения с 80 % продаж в ноябре – декабре) допустимо применение премиального ценообразования в пиковый период;

– кассовые разрывы: концентрация 40–50 % годовой выручки в одном квартале (характерно для школьного ассортимента) создает риски ликвидности в межсезонье, требующие кредитных инструментов для покрытия операционных расходов.

Совокупный экономический эффект от внедрения системы прогнозирования и оптимизации запасов для рассмотренных категорий может составить 18–25 % от общих затрат на логистику и хранение. В то же время важно учитывать, что реальная экономия будет зависеть от трех ключевых факторов: точности прогнозов, гибкости цепочек поставок и системы управления страховыми запасами. Повышение точности прогнозов на 5 % может дать дополнительную экономию 2–3 % за счет сокращения страховых запасов.

Гибкость поставок позволяет уменьшить оптимальный размер заказа, что особенно важно для сезонных товаров. Наконец, правильно настроенная система управления страховыми запасами на основе прогнозируемых показателей спроса может сократить затраты на хранение еще на 5–7 % [Research ... , 2022].

Для микропредприятий с ограниченными ресурсами внедрение модели прогнозирования спроса может дать даже более значимый экономический эффект (25–35 %), чем для среднего бизнеса. Это связано с тем, что:

– фиксированные затраты на логистику и хранение составляют большую долю в себестоимости (нет эффекта масштаба);

– ошибки в закупках критичнее (нехватка денег на экстренные поставки, риск заморозки оборотных средств);

– ручное управление запасами менее эффективно, поэтому автоматизация дает большую отдачу.

Экономия 25–35 % складывается из следующих факторов.

1. Сокращение складских затрат (10–15 % экономии):

– уменьшение занимаемой площади: если раньше под сезонные товары (бумага А4,

наборы первоклассника) резервировался избыточный запас, то теперь можно сократить страховой запас на 20–30 %;

– меньше потерь от устаревания: особенно важно для товаров с ограниченным сроком годности (клей, бумага с липким слоем);

– снижение нагрузки на кладовщика: меньше времени на инвентаризацию и поиск товаров.

2. Оптимизация закупок (8–12 % экономии):

– реже, но крупнее заказы: для стабильных товаров (файлы А4, ручки) можно увеличить интервалы между поставками, экономя на транспортных расходах;

– избежание срочных закупок: если раньше приходилось докупать бумагу А4 в сезон по высокой цене, то теперь закупки планируются заранее;

– консолидация поставок: для маловостребованных товаров (бумага с липким слоем) закупки можно делать раз в квартал, а не ежемесячно.

3. Снижение потерь от дефицита (5–8 % экономии):

– меньше «продаж упущенной выгоды»: если раньше товар заканчивался в пик спроса (например, перед 1 сентября), то теперь прогноз позволяет заранее увеличить запас;

– снижение количества «авральных» заказов: срочные поставки обычно на 15–20 % дороже.

4. Высвобождение оборотных средств (2–5 % экономии):

– оптимизация размера заказов позволяет сократить средний объем товарных запасов на складе на 20–30 %, которые могут быть направлены на развитие бизнеса.

Таким образом, внедрение системы прогнозирования на основе модели ARIMA-LSTM в сочетании с расчетами оптимального размера заказа обеспечивает комплексный экономический эффект, включающий сокращение логистических издержек, уменьшение затрат на хранение, высвобождение оборотных средств и снижение рисков устаревания товарных запасов.

Максимальный эффект достигается при адаптации методов управления запасами к специфике каждой товарной категории и постоянном мониторинге точности прогнозов.

Представленная реализация модели ARIMA-LSTM демонстрирует комплексный подход к прогнозированию временных рядов, сочетающий автоматизированный подбор параметров с гибкой обработкой различных типов данных. Использование адаптивной логи-

ки в зависимости от стационарности ряда, наглядная визуализация промежуточных результатов и прогнозов, а также обработка разнородных товарных категорий делают данный инструмент ценным для решения практических задач бизнес-прогнозирования.

### СПИСОК ЛИТЕРАТУРЫ

- Артемов, А. А. Модели машинного обучения в FMCG-ритейле: архитектура и эксплуатация в условиях высокой изменчивости данных / А. А. Артемов // Вестник науки. – 2025. – Т. 2, № 4 (85). – С. 663–675.
- Волков, А. Ю. Стратегия внедрения современных технологий в процесс оптимизации складских запасов оптовых торговых компаний / А. Ю. Волков // Universum: экономика и юриспруденция. – 2023. – № 8 (107). – С. 4–12. – DOI: 10.32743/UniLaw.2023.107.8.15820
- Горшкова, С. В. Экономическая эффективность управления запасами в торговых предприятиях: современные подходы и практические инструменты / С. В. Горшкова, Т. В. Панкина // Инновационная наука. – 2025. – № 6-1. – С. 140–142.
- Применение методов машинного обучения для прогнозирования нефтяных котировок / В. В. Назарова [и др.] // AlterEconomics. – 2025. – Т. 22, № 3. – С. 482–502. – DOI: 10.31063/AlterEconomics/2025.22-3.6
- Роголин, Р. С. Обзор прикладных основ использования аналитики данных и машинного обучения в прогнозировании спроса / Р. С. Роголин // Экономические и социально-гуманитарные исследования. – 2023. – № 3 (39). – С. 115–126. – DOI: 10.24151/2409-1073-2023-3-115-126
- Тарасюк, Н. Ю. Машинное обучение в системах поддержки принятия инвестиционных решений: сравнительный анализ традиционных экономических моделей и ML-подходов / Н. Ю. Тарасюк // Вестник евразийской науки. – 2025. – Т. 17, № s2. – URL: <https://esj.today/PDF/40FAVN225.pdf>
- A Comparative Study of Demand Forecasting Models for a Multi-Channel Retail Company: A Novel Hybrid Machine Learning Approach / A. Mitra [et al.] // Operations Research Forum. – 2022. – Vol. 3, № 4. – P. 58. – DOI: 10.1007/s43069-022-00166-4
- Abbasimehr, H. An Optimized Model Using LSTM Network for Demand Forecasting / H. Abbasimehr, M. Shabani, M. Yousefi // Computers & Industrial Engineering. – 2020. – Vol. 143. – DOI: 10.1016/j.cie.2020.106435
- Digital Technologies and Transformation of Modern Retail / S. Krymov [et al.] // IOP Conference Series Materials Science and Engineering. – 2019. – Vol. 497. – DOI: 10.1088/1757-899X/497/1/012126
- Loureiro, A. L. D. Exploring the Use of Deep Neural Networks for Sales Forecasting in Fashion Retail / A. L. D. Loureiro, V. L. Miguéis, L. F. da Silva // Decision Support Systems. – 2018. – Vol. 114 (4). – P. 81–93. – DOI: 10.1016/j.dss.2018.08.010
- Research on Intelligent Warehousing and Logistics Management System of Electronic Market Based on Machine Learning / R. Zhang [et al.] // Computational Intelligence and Neuroscience. – 2022. – Vol. 2022, Iss. 1. – DOI: 10.1155/2022/2076591
- Wang, C.-C. On the Application of ARIMA and LSTM to Predict Order Demand Based on Short Lead Time and On-time Delivery Requirements / C.-C. Wang, C.-H. Chien, A. J. C. Trappey // Processes. – 2021. – Vol. 9 (7), № 1157. – DOI: 10.3390/pr9071157
- Wang, Ya. Oil Price Forecasting based on Improved SARIMA Model / Ya. Wang // Highlights in Science, Engineering and Technology. – 2023. – Vol. 39. – P. 238–245. – DOI: 10.54097/hset.v39i.6535
- Zenkova, Z. N. The ABC-XYZ Analysis Modified for Data with Outliers / Z. N. Zenkova, T. V. Kabanova // Proceeding GOL'2018 The 4<sup>th</sup> IEEE International Conference on Logistics Operations Management. – 2018. – P. 63–68.

### REFERENCES

- Artemov A.A. Modeli mashinnogo obucheniya v FMCG-ritejle: arkhitektura i ekspluatatsiya v usloviyakh vysokoy izmenchivosti dannykh [Machine Learning Models in FMCG Retail: Architecture and Operation in Conditions of High Data Variability]. *Vestnik nauki* [Bulletin of Science], 2025, vol. 2, no. 4 (85), pp. 663-675.

- Volkov A. Yu. Strategija vnedrenija sovremennykh tekhnologij v process optimizacii skladских zapasov optovykh torgovykh kompanij [Strategy for the Introduction of Modern Technologies in the Process of Optimizing Warehouse Stocks of Wholesale Trading Companies]. *Universum: ekonomika i jurisprudencija* [Universum: Economics and Law], 2023, no. 8 (107), pp. 4-12. DOI: 10.32743/UniLaw.2023.107.8.15820
- Gorshkova S.V., Pankina T.V. Ekonomicheskaja effektivnost upravlenija zapasami v torgovykh predpriyatijakh: sovremennye podkhody i prakticheskiye instrumenty [Economic Efficiency of Inventory Management in Trade Enterprises: Modern Approaches and Practical Tools]. *Innovacionnaja nauka* [Innovative Science], 2025, no. 6-1, pp. 140-142.
- Nazarova V.V., Lodyagin B.A., Kruglov F.A., and Kruglov A.V. Primeneniye metodov mashinnogo obucheniya dlja prognozirovaniya neftjanykh kotirovok [Application of Machine Learning Methods for Predicting Oil Quotes]. *AlterEconomics*, 2025, vol. 22, no. 3, pp. 482-502. DOI: 10.31063/AlterEconomics/2025.22-3.6
- Rogulin R.S. Obzor prikladnykh osnov ispolzovaniya analitiki dannykh i mashinnogo obucheniya v prognozirovanii sprosa [Overview of Application Frameworks for Using Data Analytics and Machine Learning in Demand Forecasting]. *Ekonomicheskiye i socialno-gumanitarnye issledovaniya* [Economic and Social Research], 2023, no. 3 (39), pp. 115-126. DOI: 10.24151/2409-1073-2023-3-115-126
- Tarasyuk N. Yu. Mashinnoye obucheniye v sistemakh podderzhki prinjatija investicionnykh reshenij: sravnitelnyj analiz tradicionnykh ekonomicheskikh modelej i ML-podkhodov [Machine Learning in Investment Decision Support Systems: A Comparative Analysis of Traditional Economic Models and ML-Approaches]. *Vestnik evrazijskoj nauki* [The Eurasian Scientific Journal], 2025, vol. 17, no. s2. URL: <https://esj.today/PDF/40FAVN225.pdf>
- Mitra A., Jain A., Kishore A., Kumar P. A Comparative Study of Demand Forecasting Models for a Multi-Channel Retail Company: A Novel Hybrid Machine Learning Approach. *Operations Research Forum*, 2022, vol. 3, no. 4, p. 58. DOI: 10.1007/s43069-022-00166-4
- Abbasimehr H., Shabani M., Yousefi M. An Optimized Model Using LSTM Network for Demand Forecasting. *Computers & Industrial Engineering*, 2020, vol. 143. DOI: 10.1016/j.cie.2020.106435
- Krymov S., Kolgan M., Suvorova S., Martynenko O. Digital Technologies and Transformation of Modern Retail. *IOP Conference Series: Materials Science and Engineering*, 2019, vol. 497. DOI: 10.1088/1757-899X/497/1/012126
- Loureiro A.L.D., Miguéis V.L., da Silva L.F. Exploring the Use of Deep Neural Networks for Sales Forecasting in Fashion Retail. *Decision Support Systems*, 2018, vol. 114 (4), pp. 81-93. DOI: <https://doi.org/10.1016/j.dss.2018.08.010>
- Zhang R., Zhou X., Jin Y., Li J. Research on Intelligent Warehousing and Logistics Management System of Electronic Market Based on Machine Learning. *Computational Intelligence and Neuroscience*, 2022, vol. 2022, iss. 1. DOI: 10.1155/2022/2076591
- Wang C.-C., Chien C.-H., Trappey A.J.C. On the Application of ARIMA and LSTM to Predict Order Demand Based on Short Lead Time and On-Time Delivery Requirements. *Processes*, 2021, vol. 9 (7), no. 1157. DOI: 10.3390/pr9071157
- Wang Ya. Oil Price Forecasting Based on Improved SARIMA Model. *Highlights in Science, Engineering and Technology*, 2023, vol. 39, pp. 238-245. DOI: 10.54097/hset.v39i.6535
- Zenkova Z.N., Kabanova T.V. The ABC-XYZ Analysis Modified for Data with Outliers. *Proceeding GOL'2018 The 4<sup>th</sup> IEEE International Conference on Logistics Operations Management*, 2018, pp. 63-68.

### **Information About the Author**

**Tatyana I. Guseva**, Candidate of Sciences (Economics), Associate Professor, Head of the Department of Economics and Law, South Ural State University, Prosp. Lenina, 76, 454080 Chelyabinsk, Russian Federation, [gusevati@susu.ru](mailto:gusevati@susu.ru), <https://orcid.org/0009-0003-4412-0215>

### **Информация об авторе**

**Татьяна Игоревна Гусева**, кандидат экономических наук, доцент, заведующий кафедрой экономики и права, Южно-Уральский государственный университет, просп. Ленина, 76, 454080 г. Челябинск, Российская Федерация, [gusevati@susu.ru](mailto:gusevati@susu.ru), <https://orcid.org/0009-0003-4412-0215>