

АНАЛИЗ ДАННЫХ И ПОСТАНОВКА ЗАДАЧИ МАШИННОГО ОБУЧЕНИЯ В УПРАВЛЕНИИ ТОВАРНЫМИ ЗАПАСАМИ ПРИ ЦЕНЗУРИРОВАННОМ СПРОСЕ

А.А. Микрюков, 9127771067@mail.ru, <https://orcid.org/0009-0008-4664-6911>

В.В. Захаров, metkol@yandex.ru, <https://orcid.org/0000-0002-3321-7156>

Южно-Уральский государственный университет, Челябинск, Россия

Аннотация. Цель исследования. Целью работы является анализ структуры данных и формализация задачи машинного обучения в управлении товарными запасами в условиях отсутствия данных о продажах. Такая ситуация характерна для оптовой торговли и дистрибуции, где доступная для анализа информация описывает не фактический спрос, а лишь наличие складских остатков и цен на определённую дату формирования прайс-листа. **Материалы и методы.** В качестве эмпирической базы использованы ежедневные прайс-листы крупного оптового поставщика автозапчастей, охватывающие более 100 календарных дней наблюдения. На их основе сформированы временные ряды, отражающие динамику доступности складских остатков, цен по отдельным товарным позициям. Применены методы анализа временных рядов, статистического описания данных и выявления структурных особенностей ассортимента. **Результаты.** В процессе накопления и обработки данных была сформирована выборка, включающая в себя 133 852 уникальные товарные единицы. Проведённый анализ показал, что для значительной части товарных позиций характерны длительные периоды отсутствия товара на складе, средняя длительность которых составила 39,3 дня, приводящие к систематическому цензурированию наблюдаемого спроса. Установлено, что львиная доля отсутствия товарных позиций на складе поставщика, а именно 91,7 % длятся не менее 3 дней, 75 % превышают 1 неделю, 55,6 % продолжаются 14 дней и более, используется без учёта эффекта цензурирования, что приводит к искажению оценки спроса и снижению качества управленческих решений. Выявлены количественные характеристики периодов отсутствия товара, подтверждающие необходимость перехода от прямого анализа наблюдаемых величин к моделированию скрытого спроса. **Заключение.** Полученные результаты формируют методологическую основу для разработки моделей машинного обучения, ориентированных на восстановление скрытого спроса и поддержку принятия решений в системах управления товарными запасами. Предложенный подход может быть использован при создании аналитических инструментов и программных библиотек для обработки данных в условиях неполной наблюдаемости.

Ключевые слова: машинное обучение, управление товарными запасами, скрытый спрос, цензурированный спрос, временные ряды

Для цитирования: Микрюков А.А., Захаров В.В. Анализ данных и постановка задачи машинного обучения в управлении товарными запасами при цензурированном спросе // Вестник ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника». 2026. Т. 26, № 3. С. 79–88. DOI: 10.14529/ctcr260307

Original article
DOI: 10.14529/ctcr260307

DATA ANALYSIS AND MACHINE LEARNING PROBLEM FORMULATION IN INVENTORY MANAGEMENT UNDER CENSORED DEMAND

A.A. Mikryukov, 9127771067@mail.ru, <https://orcid.org/0009-0008-4664-6911>

V.V. Zakharov, metkol@yandex.ru, <https://orcid.org/0000-0002-3321-7156>

South Ural State University, Chelyabinsk, Russia

Abstract. The purpose of this study is to analyze the structure of daily supplier price lists and to formulate a machine learning problem for inventory management when direct sales data are unavailable. This setting is typical for wholesale and distribution companies, where the available information reflects

assortment composition, prices, and stock balances rather than actual customer demand. **Materials and Methods.** The empirical basis of the study consists of daily price lists from a large wholesale auto parts supplier covering 113 calendar days of observations. The data were preprocessed by normalizing product records, constructing stable SKU identifiers, and forming daily time series that include stock balances, prices, and product availability indicators. The study applies descriptive statistics, time series analysis, assortment dynamics analysis, and detection of consecutive out-of-stock intervals. Particular attention is paid to distinguishing between two different states: a zero-stock balance for an item still present in the price list and the complete absence of an item from the observed data. **Results.** The processed dataset contains 133,852 unique stock keeping units. For a representative sample of 5,000 SKUs, 36 consecutive zero-stock intervals were identified. The average duration of an out-of-stock period was 39.3 days, the median duration was 25 days, and the maximum duration reached 113 days. It was found that 91.7 % of such periods lasted at least 3 days, 75.0 % exceeded one week, and 55.6 % continued for 14 days or more. These results show that stockouts are not isolated short-term deviations but a systematic source of demand censoring. **Conclusion.** The study demonstrates that direct use of inventory balances or sales observations without accounting for censoring may lead to biased demand estimation and poorer replenishment decisions. The proposed problem formulation provides a methodological basis for developing machine learning models aimed at recovering latent demand and supporting inventory management under incomplete data observability.

Keywords: machine learning, inventory management, latent demand, censored demand, time series, data analysis

For citation: Mikryukov A.A., Zakharov V.V. Data analysis and machine learning problem formulation in inventory management under censored demand. *Bulletin of the South Ural State University. Ser. Computer Technologies, Automatic Control, Radio Electronics*. 2026;26(3):79–88. (In Russ.) DOI: 10.14529/ctcr260307

Введение

Управление товарными запасами является одной из ключевых задач в организационных и экономических системах, поскольку напрямую влияет на уровень совокупных издержек, устойчивость цепочек поставок и качество обслуживания клиентов. Классические модели управления запасами, такие как модель экономического размера заказа (англ. Economic Order Quantity, EOQ) и (s, S)-политики (англ. (s, S) inventory policy), широко применяются в теории и практике при условии наличия информации о спросе или продажах [1, 2]. Однако в условиях высокой номенклатурной сложности и нестабильности поставок эффективность таких подходов существенно снижается.

В последние годы методы машинного обучения получили широкое распространение в задачах прогнозирования спроса и управления запасами благодаря способности учитывать нелинейные зависимости, сезонные эффекты и большие объёмы данных [3, 4]. Современные исследования демонстрируют эффективность гибридных моделей, сочетающих статистические методы анализа временных рядов и нейросетевые подходы, в том числе в задачах интеграции прогнозирования в ERP-системы [5]. Вместе с тем подавляющее большинство существующих работ предполагает наличие исторических данных о продажах, которые используются в качестве прямого наблюдения спроса.

На практике, особенно в сегменте оптовой торговли и дистрибуции, данные о фактических продажах часто отсутствуют либо недоступны для анализа. Вместо этого компании располагают ежедневными прайс-листами поставщиков, содержащими информацию об ассортименте, ценах и текущих складских остатках товаров. В подобных условиях спрос не наблюдается напрямую и проявляется в цензурированном виде: при наличии товара на складе возможный спрос частично реализуется, а при его отсутствии остаётся скрытым.

Таким образом, задача управления запасами в таких системах может быть сформулирована как задача восстановления скрытого спроса по косвенным наблюдениям и принятия управленческих решений в условиях неопределённости. Данная постановка принципиально отличается от классических задач прогнозирования временных рядов продаж и требует применения специализированных моделей машинного обучения, способных работать с неполными и цензурированными данными [6, 7].

Целью настоящей работы является анализ структуры данных ежедневных прайс-листов и выявление характерных проявлений цензурированного спроса, а также формирование методоло-

гической основы для дальнейшего применения моделей машинного обучения в задачах управления товарными запасами при отсутствии данных о продажах.

1. Материалы и методы

1.1. Описание данных

В качестве данных для исследования были использованы прайс-листы крупной федеральной оптовой компании, реализующей автозапчасти на территории РФ. Получаемый ежедневно прайс-лист сохраняется в специально разработанном для удобства последующих экспериментов формате.

На данный момент период наблюдений включает в себя более 200 календарных дней с 1 октября 2025 г. и по сегодняшний день (май 2026). Прайс-лист формируется и отправляется оптовым покупателям каждый день и содержит 80–90 тыс. уникальных товаров, каждая строка для которого содержит следующие колонки-атрибуты: бренд, нормированный код производителя (предобработанная строка), код артикула компании (собственный формат для обработки), код производителя, количество (непосредственное количество товара на момент формирования прайс-листа), цена. Все вышеперечисленные характеристики в последующем используются для моделирования и построения признаков, обучения и тестирования разрабатываемых моделей.

Код производителя, он же оригинальные номер детали, используется в качестве уникального идентификатора и соответствует так называемому SKU (от англ. Stock Keeping Unit – товарно-материальная единица, SKU), данный идентификатор используется для формирования временных рядов по каждой товарной позиции (табл. 1).

Описательная статистика ежедневных прайс-листов

Таблица 1

Table 1

Descriptive statistics of daily price lists

Показатель	Среднее	Std	Min	Max
Строк в прайс-листе (n-rows)	92 756	5 900	80 499	98 894
Уникальные товарные единицы в день (n unique sku)	91 981	5 864	79 842	98 151
Доля пропусков qty	0,00279	0,00018	0,00241	0,00316
Доля пропусков price	0	0	0	0
Доля нулевых остатков (qty=0)	0,00279	0,00018	0,00241	0,00316

1.2. Анализ объёма и структуры данных

Проанализировав динамику потока данных, а именно число уникальных SKU (англ. Stock Keeping Unit– товарно-материальная единица, SKU) в день, можно дать положительную оценку количественной и качественной устойчивости экспериментальной базы (рис. 1, 2).




Рис. 1. Динамика количества строк в ежедневных прайс-листах
Fig. 1. Example of a SKU time series: stock balance and price dynamics



Рис. 2. Динамика числа уникальных товарных единиц в день
Fig. 2. Assortment dynamics: SKU appearance and disappearance by day

Проведенный анализ подтверждает, что плавно изменяющийся объём и число уникальных товарных позиций, не имеют резких выбросов, что позволяет рассматривать набор данных как достаточно пригодный для проведения экспериментов с воспроизводимыми временными рядами.

1.3. Формирование временных рядов

В процессе предварительной обработки данных выполнена нормализация товарных позиций: дедубликация, унификация оригинальных кодов, формирование устойчивых идентификаторов. Далее для каждой товарной позиции был сформирован временной ряд с дневной частотой, включающий значения складского остатка, цены и бинарный индикатор доступности товара (табл. 2).

Фрагмент временного ряда товарной позиции (пример)

Таблица 2

Table 2

Fragment of a SKU time series (example)

date	qty	price	available
2025-10-01	2.0	1330.0	1
2025-10-02	2.0	1330.0	1
2025-10-03	2.0	1330.0	1
2025-10-04	2.0	1330.0	1
2025-10-05	2.0	1330.0	1
2025-10-06	2.0	1330.0	1
2025-10-07	2.0	1330.0	1
2025-10-08	2.0	1330.0	1
2025-10-09	2.0	1330.0	1
2025-10-10	2.0	1330.0	1
2025-10-11	2.0	1330.0	1
2025-10-12	2.0	1330.0	1
2025-10-13	2.0	1330.0	1
2025-10-14	2.0	1330.0	1
2025-10-15	2.0	1330.0	1

Сплошная линия на рис. 3 отображает количество складского остатка, пунктирная – цену. Периоды отсутствия товаров на складе соответствуют нулевым значениям остатка, в которых спрос фактически не наблюдается, т. е. является цензурированным.




Рис. 3. Пример временного ряда товарной позиции: динамика остатка и цены
Fig. 3. Example of a SKU time series: stock balance and price dynamics

2. Результаты

2.1. Общие характеристики ассортимента

В ходе проведения данного исследования на основе ежедневно накапливаемых прайс-листов был сформирован массив экспериментальных данных, содержащий 133 852 уникальные товарные позиции (SKU) за весь период наблюдений. Последующий анализ длительности периодов отсутствия товара на складе был проведен с использованием репрезентативной выборки из 5000 SKU, которая позволила значительно снизить вычислительную сложность без потери статистической значимости результатов. Данная выборка была сформирована из общего множества товарных позиций, что позволяет охватить весь временной интервал наблюдений и обеспечить сопоставимость результатов и устойчивость оценок.

2.2. Динамика ассортимента во времени

Ассортимент товарных позиций является динамическим, что подтверждает анализ ежедневно поступающих данных, отдельно взятые единицы товара периодически появляются и исчезают. Для количественной оценки этих процессов была проанализирована динамика появления и исчезновения ранее присутствующих на складе предприятия позиций (рис. 4).



Рис. 4. Динамика ассортимента: появление и исчезновение SKU по дням
Fig. 4. Assortment dynamics: SKU appearance and disappearance by day

По данным из прайс-листов можно заметить, что в большинстве дней наблюдается стабильная динамика значительного числа позиций, в то же время длительные периоды полной стабиль-

ности ассортимента отсутствуют, что указывает на необходимость учитывать изменения ассортимента при формировании временных рядов.

Отсутствие товара в прайс-листе не может интерпретироваться как отсутствие спроса на эту товарную единицу и должно рассматриваться как отсутствие наблюдения. Данный факт имеет принципиальное значение для последующих анализа и наблюдения в целом.

2.3. Анализ периодов отсутствия товара на складе

Следующим и не менее важным этапом исследования является анализ периодов отсутствия товара на складе, рассматриваемых в качестве интервалов цензурирования фактического спроса. Для каждой товарной позиции из выборки были зафиксированы периоды, в течение которых складской остаток принимал нулевое значение ($qty = 0$), в результате выявлено 36 отдельных серий дней с нулевым складским остатком.

2.4. Распределение длительности периодов отсутствия товаров

Для оценки характера цензурирования спроса было построено распределение длительности периодов отсутствия товара на складе (рис. 5).




Рис. 5. Диаграмма длительности периодов отсутствия товаров
Fig. 5. Duration diagram of out-of-stock periods

Анализ распределения показывает выраженную асимметрию и наличие длинного правого «хвоста», что свидетельствует о преобладании anomalously затяжных периодов отсутствия товара.

2.5. Количественные характеристики периодов цензурирования

Анализ количественных характеристик длительности периодов отсутствия товара на складе показал, что в среднем товар может отсутствовать в течение 39,3 дня, хотя медианное значение заметно ниже и составляет 25 дней. Максимально зафиксированная продолжительность отсутствия позиций достигла 113 дней. Этому же значению соответствуют 90-й и 95-й перцентили, что совпадает с длиной наблюдаемого временного интервала.

Дополнительно было установлено, что:

- подавляющее большинство периодов отсутствия товара (91,7 %) длятся не менее 3 дней;
- три четверти случаев (75,0 %) превышают одну неделю (7 дней);
- а больше половины (55,6 %) периодов продолжаются 14 дней и более.

Такая длительность периодов отсутствия товара говорит о том, что для значительной части позиций дефицит является не кратковременным отклонением, а устойчиво повторяющимся состоянием.

2.6. Интерпретация результатов в контексте наблюдаемости спроса

Выявленные длительные периоды отсутствия товара на складе приводят к систематическому искажению наблюдаемых данных, где зафиксировать фактический спрос не представляется возможным, а наблюдаемый период продаж содержит структурные разрывы.

Таким образом, прямое использование данных о продажах и остатках товара без поправки на цензурирование может привести к систематической недооценке спроса и формированию

смещённых прогнозов. Поэтому восстановление скрытого спроса – необходимый этап при подготовке данных и применении методов машинного обучения в задачах управления товарными запасами.

3. Обсуждение результатов

3.1. Характер цензурирования спроса в реальных данных

В рассматриваемой системе отсутствие товара на складе оказалось не единичным событием, а устойчиво повторяющимся состоянием. Длительность периодов отсутствия, в среднем превышающая один календарный месяц, а также значительная доля интервалов отсутствия товаров продолжительностью более двух недель указывают на устойчивую проблему неполной наблюдаемости спроса. Сложившаяся ситуация значительно отличается от классических предпосылок теории управления запасами, в которых предполагается либо полная наблюдаемость спроса, либо наличие кратковременных дефицитов, не оказывающих существенного влияния на статистические характеристики временных рядов [5, 8]. В рассматриваемом случае наблюдаемые данные формируются в условиях длительного цензурирования, что приводит к систематическим искажениям при прямом использовании исторических наблюдений.

3.2. Последствия игнорирования цензурированного спроса

Игнорирование эффектов цензурирования спроса при построении прогнозных моделей приводит к накоплению ошибок, которые проявляются на нескольких уровнях. Во-первых, модели прогнозирования, обучаемые на данных с длительными периодами нулевых наблюдений, систематически занижают оценку спроса. Во-вторых, такие искажения транслируются в управленческие решения, связанные с пополнением запасов, что усиливает вероятность повторных дефицитов.

Данный эффект формирует замкнутый контур отрицательной обратной связи: недооценка спроса приводит к недостаточному объёму заказов, что, в свою очередь, увеличивает длительность периодов отсутствия товара. Аналогичные эффекты описываются в работах, посвящённых стохастическому управлению запасами, однако в большинстве исследований предполагается наличие корректных наблюдений спроса [2, 9], что не соответствует условиям, выявленным в настоящем исследовании.

3.3. Методологические аспекты интерпретации данных

В рамках данной работы принципиально различаются два состояния. Первое – это отсутствие товара на складе при сохранении товарной позиции в ассортименте ($qty = 0$) и отсутствие товарной позиции в ежедневном прайс-листе. Второе интерпретируется как отсутствие наблюдения, а не как нулевой остаток. Такое разделение позволяет избежать искусственного удлинения периодов отсутствия товаров и обеспечивает более корректную интерпретацию данных. Такой подход согласуется с практикой анализа динамических ассортиментов и отражает реальные бизнес-процессы в оптовой торговле, где товар может временно выводиться из ассортимента по причинам, не связанным с фактическим спросом. Игнорирование этого фактора приводит к смешению различных режимов наблюдаемости и снижает интерпретируемость результатов анализа.

3.4. Связь полученных результатов с методами машинного обучения

Результаты исследования подчёркивают ограничения традиционных методов анализа временных рядов, основанных на прямом использовании наблюдаемых продаж или остатков. Классические статистические модели прогнозирования, такие как ARIMA (англ. Autoregressive Integrated Moving Average, ARIMA – авторегрессионная модель скользящего среднего) и экспоненциальное сглаживание, предполагают стационарность наблюдаемого процесса и не учитывают наличие длительных периодов цензурирования [1, 2].

Современные гибридные подходы, сочетающие статистические методы и нейросетевые архитектуры, в частности рекуррентные нейронные сети и LSTM (англ. Long Short-Term Memory – сеть долгой краткосрочной памяти), демонстрируют более высокую гибкость при работе с нелинейными и нестационарными данными [3–7]. Однако даже такие модели требуют корректно подготовленных входных данных и явного учёта режимов наблюдаемости спроса.

С учётом выявленных закономерностей следующую задачу машинного обучения целесообразно связывать с восстановлением скрытого спроса. В этом случае модель будет работать не только с видимыми остатками, но и с той частью спроса, которая не попадает в данные в периоды отсутствия товара на складе.

3.5. Практическая значимость и перспективы внедрения

С практической точки зрения предложенная интерпретация данных может быть полезна при доработке корпоративных систем управления запасами. Разделение режимов наблюдаемости и оценка длительности периодов отсутствия товара позволяют точнее готовить данные для алгоритмов, работающих с реальными прайс-листами оптовой торговли.

В дальнейшем этот подход можно использовать при создании программных библиотек и аналитических модулей для подготовки данных, восстановления скрытого спроса и поддержки решений по пополнению запасов. Такой инструментарий соответствует современным тенденциям развития ML-ориентированных систем в логистике и управлении запасами [10, 11], а также требованиям к воспроизводимости и масштабируемости аналитических решений [12].

Заключение

В данной работе проведён анализ структуры и свойств данных ежедневных прайс-листов оптового поставщика в контексте задач управления товарными запасами. Показано, что для значительной части ассортимента характерны длительные периоды отсутствия товара на складе, приводящие к систематическому цензурированию фактического спроса.

На основе реальных данных выявлены количественные характеристики периодов отсутствия товаров, свидетельствующие о том, что нулевые наблюдения не могут интерпретироваться как низкий или отсутствующий спрос. Это делает некорректным прямое применение классических методов прогнозирования и управления запасами без предварительного восстановления скрытого спроса.

Полученные результаты формируют методологическую основу для дальнейших исследований, направленных на разработку моделей машинного обучения, способных работать в условиях неполной наблюдаемости данных [13–15]. Практическая значимость работы заключается в возможности использования предложенного подхода при проектировании аналитических и программных решений для повышения эффективности управления товарными запасами в реальных организационно-экономических системах.

Список литературы

1. Silver E.A. Operations Research in Inventory Management: A Review and Critique // Operations Research. 1981. Vol. 29, no. 4. P. 628–645. DOI: 10.1287/opre.29.4.628
2. Axsäter S. Inventory Control. 3rd ed. Cham: Springer, 2015. DOI: 10.1007/978-3-319-15729-0
3. Gutierrez J.C., Polo Triana S.I., León Becerra J.S. Benefits, challenges, and limitations of inventory control using machine learning algorithms: literature review // OPSEARCH. 2025. Vol. 62. P. 1140–1172. DOI: 10.1007/s12597-024-00839-0
4. Albayrak Ünal Ö., Erkeyman B., Usanmaz B. Applications of Artificial Intelligence in Inventory Management: A Systematic Review of the Literature // Archives of Computational Methods in Engineering. 2023. Vol. 30. P. 2605–2625. DOI: 10.1007/s11831-022-09879-5
5. Микрюков А.А., Гилёв Д.В. Комбинированный метод прогнозирования спроса на продовольственные товары на основе ансамбля LSTM-сети и SARIMA-модели для интеграции в ERP-системы российского ритейла // Вестник ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника». 2025. Т. 25, № 4. С. 122–128. DOI: 10.14529/ctcr250409
6. Bertsimas D., Kallus N. From Predictive to Prescriptive Analytics // Management Science. 2020. Vol. 66, no. 3. P. 1025–1044. DOI: 10.1287/mnsc.2018.3253
7. Ban G.-Y., Rudin C. The Big Data Newsvendor: Practical Insights from Machine Learning // Operations Research. 2019. Vol. 67, no. 1. P. 90–108. DOI: 10.1287/opre.2018.1757
8. Микрюков А.А. Концепция и реализация нового подхода к прогнозированию продаж товарных запасов с использованием методов машинного обучения // Современная наука: актуальные проблемы теории и практики. Серия: Естественные и технические науки. 2025. № 5-1. С. 115–119.
9. Cao Y., Shen Z.-J.M. Quantile forecasting and data-driven inventory management under nonstationary demand // Operations Research Letters. 2019. Vol. 47, no. 6. P. 465–472. DOI: 10.1016/j.orl.2019.08.008
10. Chen B. Data-Driven Inventory Control with Shifting Demand // Production and Operations Management. 2021. Vol. 30, no. 5. P. 1365–1385. DOI: 10.1111/poms.13326

11. Supervised learning for integrated forecasting and inventory control / J.F. van der Haar, A.P. Wellens, R.N. Boute, R.J.I. Basten // *European Journal of Operational Research*. 2024. Vol. 319, no. 2. P. 573–586. DOI: 10.1016/j.ejor.2024.07.004
12. Deep reinforcement learning for inventory control: A roadmap / R.N. Boute, J. Gijsbrechts, W. van Jaarsveld, N. Vanvuchelen // *European Journal of Operational Research*. 2022. Vol. 298, no. 2. P. 401–412. DOI: 10.1016/j.ejor.2021.07.016
13. Inventory – forecasting: Mind the gap / T.E. Goltso, A.A. Syntetos, C.H. Glock, G. Ioannou // *European Journal of Operational Research*. 2022. Vol. 299, no. 2. P. 397–419. DOI: 10.1016/j.ejor.2021.07.040
14. de Castro Moraes T., Yuan X.-M. Data-Driven Solutions for the Newsvendor Problem: A Systematic Literature Review // *Advances in Production Management Systems. Artificial Intelligence for Sustainable and Resilient Production Systems. IFIP Advances in Information and Communication Technology*. Springer, 2021. P. 149–158. DOI: 10.1007/978-3-030-85910-7_16
15. Deep Controlled Learning for Inventory Control / T. Temizöz, C. Imdahl, R. Dijkman et al. // *European Journal of Operational Research*. 2025. Vol. 324, no. 1. P. 104–117. DOI: 10.1016/j.ejor.2025.01.026

References

1. Silver E.A. Operations Research in Inventory Management: A Review and Critique. *Operations Research*. 1981;29(4):628–645. DOI: 10.1287/opre.29.4.628
2. Axsäter S. *Inventory Control*. 3rd ed. Cham: Springer, 2015. DOI: 10.1007/978-3-319-15729-0
3. Gutierrez J.C., Polo Triana S.I., León Becerra J.S. Benefits, challenges, and limitations of inventory control using machine learning algorithms: literature review. *OPSEARCH*. 2025;62:1140–1172. DOI: 10.1007/s12597-024-00839-0
4. Albayrak Ünal Ö., Erkeyman B., Usanmaz B. Applications of Artificial Intelligence in Inventory Management: A Systematic Review of the Literature. *Archives of Computational Methods in Engineering*. 2023;30:2605–2625. DOI: 10.1007/s11831-022-09879-5
5. Mikryukov A.A., Gilev D.V. Combined method for forecasting food product demand based on an ensemble of LSTM network and SARIMA model for integration into ERP systems of Russian retail. *Bulletin of the South Ural State University. Ser. Computer Technologies, Automatic Control, Radio Electronics*. 2025;25(4):122–128. (In Russ.) DOI: 10.14529/ctcr250409
6. Bertsimas D., Kallus N. From Predictive to Prescriptive Analytics. *Management Science*. 2020;66(3):1025–1044. DOI: 10.1287/mnsc.2018.3253
7. Ban G.-Y., Rudin C. The Big Data Newsvendor: Practical Insights from Machine Learning. *Operations Research*. 2019;67(1):90–108. DOI: 10.1287/opre.2018.1757
8. Mikryukov A.A. Concept and Implementation of a New Approach to Sales Forecasting in Inventory Management Using Machine Learning Methods. *Modern Science: Actual Problems of Theory and Practice. Series: Natural and Technical Sciences*. 2025;(5-1):115–119. (In Russ.)
9. Cao Y., Shen Z.-J.M. Quantile forecasting and data-driven inventory management under nonstationary demand. *Operations Research Letters*. 2019;47(6):465–472. DOI: 10.1016/j.orl.2019.08.008
10. Chen B. Data-Driven Inventory Control with Shifting Demand. *Production and Operations Management*. 2021;30(5):1365–1385. DOI: 10.1111/poms.13326
11. van der Haar J.F., Wellens A.P., Boute R.N., Basten R.J.I. Supervised learning for integrated forecasting and inventory control. *European Journal of Operational Research*. 2024;319(2):573–586. DOI: 10.1016/j.ejor.2024.07.004
12. Boute R.N., Gijsbrechts J., van Jaarsveld W., Vanvuchelen N. Deep reinforcement learning for inventory control: A roadmap. *European Journal of Operational Research*. 2022;298(2):401–412. DOI: 10.1016/j.ejor.2021.07.016
13. Goltso T.E., Syntetos A.A., Glock C.H., Ioannou G. Inventory – forecasting: Mind the gap. *European Journal of Operational Research*. 2022;299(2):397–419. DOI: 10.1016/j.ejor.2021.07.040
14. de Castro Moraes T., Yuan X.-M. Data-Driven Solutions for the Newsvendor Problem: A Systematic Literature Review. In: *Advances in Production Management Systems. Artificial Intelligence for Sustainable and Resilient Production Systems. IFIP Advances in Information and Communication Technology*. Springer, 2021. P. 149–158. DOI: 10.1007/978-3-030-85910-7_16

15. Temizöz T., Imdahl C., Dijkman R., Lamghari-Idrissi D., van Jaarsveld W. Deep Controlled Learning for Inventory Control. *European Journal of Operational Research*. 2025;324(1):104–117. DOI: 10.1016/j.ejor.2025.01.026

Информация об авторах

Микрюков Алексей Александрович, аспирант кафедры информационных систем и технологий, Южно-Уральский государственный университет, Челябинск, Россия; 9127771067@mail.ru.

Захаров Вадим Владимирович, ведущий инженер кафедры информационных систем и технологий, Южно-Уральский государственный университет, Челябинск, Россия; metkol@yandex.ru.

Information about the authors

Aleksey A. Mikryukov, Postgraduate student of the Department of Information Systems and Technologies, South Ural State University, Chelyabinsk, Russia; 9127771067@mail.ru.

Vadim V. Zakharov, Leading engineer of the Department of Information Systems and Technologies, South Ural State University, Chelyabinsk, Russia; metkol@yandex.ru.

Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации.

Авторы заявляют об отсутствии конфликта интересов.

Contribution of the authors: the authors contributed equally to this article.

The authors declare no conflicts of interests.

Статья поступила в редакцию 04.05.2026

The article was submitted 04.05.2026