

Экономические и социально-гуманитарные исследования. 2023. № 3 (39). С. 115—126.

Economic and Social Research. 2023. No. 3 (39). P. 115—126.

Обзорная статья

УДК 338.001.36

doi: 10.24151/2409-1073-2023-3-115-126

<https://elibrary.ru/hmwmtx>

## Обзор прикладных основ использования аналитики данных и машинного обучения в прогнозировании спроса

*Р. С. Рогулин*

*Владивостокский государственный университет, г. Владивосток, Россия*

*rafassiaofusa@mail.ru*

**Аннотация.** Представлен всесторонний обзор методов анализа данных и машинного обучения, осуществляющих прогнозирование и планирование спроса. Проанализированы статьи, материалы конференций и книги на английском языке, изданные с 2001 по 2023 г. Путем преобразования суждений выделены логические основы значения этих подходов для оптимизации уровней запасов и сокращения дефицита, а также преимущества и проблемы, связанные с внедрением методов, с их потенциалом в процессах принятия решений. Рассмотрены и традиционные статистические методы: анализ временных рядов, скользящие средние, — и передовые методы: регрессионный анализ, нейронные сети, ансамблевые модели. Сделан сравнительный анализ сильных сторон, ограничений и особенностей приложения передовых методов. Даны рекомендации по совершенствованию управления цепочками поставок и повышению удовлетворенности клиентов.

**Ключевые слова:** аналитика данных, прогнозирование спроса, оптимизация уровней запасов, сокращение дефицита, удовлетворенность клиентов, статистические методы, передовые методы, управление цепочками поставок, модели машинного обучения

**Для цитирования:** Рогулин Р. С. Обзор прикладных основ использования аналитики данных и машинного обучения в прогнозировании спроса // Экономические и социально-гуманитарные исследования. 2023. № 3 (39). С. 115—126. <https://doi.org/10.24151/2409-1073-2023-3-115-126> EDN: HMWMTX.

Review article

## Overview of application frameworks for using data analytics and machine learning in demand forecasting

*R. S. Rogulin*

*Vladivostok State University, Vladivostok, Russia*

*rafassiaofusa@mail.ru*

© Рогулин Р. С.

**Abstract.** A comprehensive overview of data analytics and machine learning techniques that perform demand forecasting and planning is presented. The author has reviewed scholarly articles, conference papers and books in English published between 2001 and 2023. By judgment conversion, the logical underpinnings of the importance of these approaches in optimizing inventory levels and reducing shortages, as well as advantages and problems associated with the implementation of the methods, with their potential in decision-making processes are highlighted. Both traditional statistical methods: time series analysis, moving averages — and advanced methods: regression analysis, neural networks, ensemble models — are considered. A comparative analysis of the strengths, limitations and application features of the best practices has been made. Recommendations are given to improve supply chain management and increasing customer satisfaction.

**Keywords:** data analytics, demand forecasting, optimizing inventory levels, reducing shortages, customer satisfaction, statistical methods, advanced methods, supply chain management, machine learning models

**For citation:** Rogulin R. S. “Overview of Application Frameworks for Using Data Analytics and Machine Learning in Demand Forecasting”. *Economic and Social Research* 3 (39) (2023): 115—126. (In Russian). <https://doi.org/10.24151/2409-1073-2023-3-115-126> EDN: HMWMTX.

## Введение

Большие наборы данных и сложные алгоритмы аналитики данных и машинного обучения позволяют принимать решения на основе их обработки, что приводит к повышению операционной эффективности и улучшению стратегии, ориентированной на клиента. При прогнозировании спроса модели анализа данных и машинного обучения анализируют исторические данные о продажах, рыночные тенденции и внешние факторы. Так создается точный прогноз, который помогает компаниям оптимизировать процессы производства, закупок и распределения. Оптимизируется управление запасами, поскольку организации могут поддерживать оптимальный уровень запасов, сни-

жать текущие расходы и избежать дефицита. Следовательно, клиенты испытывают наибольшее удовлетворение, поскольку продукты легко доступны, заказы выполняются вовремя, а качество обслуживания повышается. Кроме того, алгоритмы машинного обучения позволяют компаниям лучше понять предпочтения клиентов, их поведение и составить модели покупок, тем самым облегчаются операции персонализированного маркетинга, включающие в себя целевые рекламные акции и индивидуальные предложения продуктов. В целом интеграция методов анализа данных и машинного обучения способствует устойчивому росту и конкурентному преимуществу на рынке [2; 30].

## Методология анализа данных и машинного обучения

Рассматриваемая методология предлагает множество потенциальных преимуществ, совершенствующих процессы принятия решений и повышающих общую эффективность цепочки поставок [4; 5; 6; 7; 30].

Во-первых, компании получают более глубокое представление о моделях и тенден-

циях спроса. Аналитика исторических данных о продажах, поведении клиентов и динамике рынка помогает выявлять закономерности и корреляции, которые могут быть неочевидными при использовании традиционных методов. Затем алгоритмы машинного обучения могут использовать эти шаб-

лоны для создания точных прогнозов спроса, которые необходимы в обосновании решений в отношении производства, закупок и распределения. В результате компании могут поддерживать оптимальный уровень запасов, снижать текущие расходы и минимизировать риск дефицита.

Во-вторых, интеграция методов анализа данных и машинного обучения обеспечивает упреждающее и оперативное управление цепочками поставок. Постоянно отслеживая и анализируя данные, можно выявлять потенциальные сбои, предвидеть изменения спроса и соответствующим образом корректировать свою деятельность. Эта гибкость в планировании и выполнении цепочки поставок помогает снизить риски, оптимизировать ресурсы и обеспечить своевременную доставку продукта клиентам. Кроме того, способность прогнозировать изменения в структуре спроса и адаптироваться к ним — это условие конкурентного преимущества в организации деятельности, поскольку оно подразумевает быстрое реагирование на колебания рынка и предпочтения клиентов.

Кроме того, методология направлена на повышение уровня удовлетворенности клиентов за счет повышения уровня обслужива-

ния и создания персонализированного опыта. Точное прогнозирование спроса и оптимизация запасов позволяют оперативно реагировать на потребности клиентов, сокращая время выполнения заказов и улучшая доступность продукции. Используя алгоритмы машинного обучения, маркетинговые службы также могут получить представление об индивидуальных предпочтениях клиентов и прогнозировать их поведение. Эти данные составляют базу для целевых маркетинговых кампаний, индивидуальных рекламных акций и индивидуальных рекомендаций по продуктам. Такой уровень персонализации повышает вовлеченность клиентов, их лояльность и общую удовлетворенность.

В заключение отметим следующие преимущества методологии анализа данных и машинного обучения: улучшаются процессы принятия решений, обеспечивается упреждающее и оперативное управление цепочками поставок, повышается удовлетворенность клиентов, достигается прозрачность цепочки поставок и эффективность сотрудничества, что способствует формированию культуры непрерывного совершенствования и инноваций.

### **Применение методов анализа данных и машинного обучения**

Традиционные методы прогнозирования спроса часто полагаются на исторические данные и ручной анализ, поэтому могут не учитывать сложности и динамичного характера современных рынков. Однако с появлением аналитики данных и машинного обучения в логику аналитических операций были включены огромные объемы данных и передовые алгоритмы — появилась возможность создания более точных и своевременных прогнозов [7; 8; 9; 10; 11].

*Методы анализа данных* явились способом анализировать, помимо исторических данных о продажах, рыночные тенденции, поведение клиентов и различные внешние факторы, влияющие на спрос. Выявляя

закономерности, корреляции и сезонность в данных, маркетологи получили представление о колебаниях спроса, о предпочтениях клиентов, т. е. прочную основу для эффективного прогнозирования спроса и планирования [12; 14; 15].

*Методы машинного обучения* явились способом повышать точность прогнозирования спроса. Эти алгоритмы могут автоматически извлекать уроки, связанные с техническими и организационными факторами производства продукта, обрабатывая исторические шаблоны данных, — и делать прогнозы на основе выявленных шаблонов. Модели машинного обучения фиксируют сложные взаимосвязи, нелинейные тенденции

и даже адаптируются к динамике рынка. Используя такие алгоритмы, как регрессия, дерево решений, нейронная сеть и ансамблевый метод, можно разрабатывать сложные модели прогнозирования, точность которых повышается с течением времени.

Применение методов анализа данных и машинного обучения имеет ряд целеполагающих преимуществ.

1. Уменьшается число ошибок прогнозирования, что сводит к минимуму риск затоваривания или дефицита. В результате оптимизируется распределение запасов, ресурсов и эксплуатационных расходов.

2. Увеличивается быстрота реагирования на изменения потребительского спроса благодаря непрерывности анализа данных, характерной для модели машинного обучения. При этом выявляются новые тенденции, внезапные сдвиги или сезонные колебания, которые требуют корректировки стратегий производства, закупок и распределения. Такая адаптивность позволяет компаниям избегать упущенных возможностей или избыточных запасов.

3. Активизируется возможность принятия стратегических решений, благодаря ценности полученной информации. Эта информация может управлять разработкой продуктов, маркетинговыми кампаниями и стратегиями ценообразования, которые

соответствуют ожиданиям клиентов, а следовательно, повышается их удовлетворенность и лояльность.

4. Повышается точность прогнозирования спроса, что в управлении процессами закупок, производства и логистике запасов способствует повышению экономического эффекта от цепочки поставок, оптимизации закупок, сокращению времени выполнения заказов и более эффективному использованию ресурсов. Это, в свою очередь, приводит к экономии затрат и повышению прибыльности.

Стоит отметить, что для внедрения методов анализа данных и машинного обучения требуются надежная инфраструктура данных, квалифицированные специалисты, а также постоянный мониторинг и проверка моделей. Кроме того, необходимо решать проблемы качества данных, интеграции данных и интерпретируемости модели, чтобы обеспечить надежность и действенность информации.

В заключение обратим внимание на следующие преимущества применения методов анализа данных и машинного обучения: повышение точности прогнозов, оперативное реагирование на динамику рынка, оптимизирование запасов, общая эффективность цепочки поставок и, как следствие, устойчивый рост в современной динамичной и сложной бизнес-среде.

### Прогнозирование спроса методами анализа данных

*Традиционные статистические методы*, такие как анализ временных рядов, скользящие средние и экспоненциальное сглаживание, доказали свою эффективность в прогнозировании моделей спроса [1; 3; 13; 16; 17; 18; 19; 20; 21; 22; 23; 24; 25; 26; 27; 28; 29].

*Анализ временных рядов* — это фундаментальный статистический метод выявления закономерностей и тенденций во времени. Поскольку на данные о спросе часто влияют предыдущие значения, задача исследователей — анализируя исторические модели спроса, определить сезонность, тенденции

и другие повторяющиеся модели, которые могут помочь в прогнозах. Методы анализа временных рядов, такие как модели авторегрессионного интегрированного скользящего среднего (ARIMA) и сезонная декомпозиция временных рядов, помогают улавливать основные закономерности (сезонность, тенденции) и делать точные прогнозы спроса [1; 3; 13; 20; 21; 22; 23; 24; 25; 26; 27; 28; 29; 31].

*Скользящие средние* — традиционный статистический метод, вычисляет среднее значение для прошлых точек данных.

Скользящие средние сглаживают краткосрочные колебания спроса, обеспечивая более четкое представление об общей тенденции. Различные типы скользящих средних, такие как простая скользящая средняя (SMA) и взвешенная скользящая средняя (WMA), могут применяться в зависимости от конкретных характеристик данных о спросе [1; 3; 13; 21; 22; 23; 24; 25; 26; 27; 28; 29].

*Экспоненциальное сглаживание* — это статистический метод, который присваивает прошлым наблюдениям экспоненциально уменьшающиеся веса, при этом самым последним точкам данных присваиваются более высокие веса. Этот метод наиболее подходит для данных о спросе, которые демонстрируют постепенное изменение или тенденцию. Модели экспоненциального сглаживания, такие как простое экспоненциальное сглаживание (SES), двойное экспоненциальное сглаживание (метод Холта) и тройное экспоненциальное сглаживание (метод Холта — Уинтерса), помогают фиксировать тенденции и сезонность в данных о спросе. Регулируя коэффициент сглаживания, можно делать акцент на последних данных по сравнению с более ранними наблюдениями, что позволяет точно прогнозировать спрос [1; 21; 22; 23; 24; 25; 26; 27; 28].

Особенность статистических методов состоит в том, что результаты относительно просто реализовать и интерпретировать, это делает методы доступными даже для неподготовленных в теории статистики пользователей. Кроме того, методы требуют минимальных вычислительных ресурсов, что делает их пригодными для прогнозирования спроса в сценариях реального или близкого к реальному времени. Их можно применять к различным типам данных о спросе, включая непрерывные, прерывистые и сезонные модели спроса.

Однако важно признать и ограничения традиционных статистических методов, поскольку они часто предполагают стационарность: статистические свойства данных

остаются постоянными во времени. В действительности модели спроса преобразуются в зависимости от динамики рынка, внешних факторов или изменений в поведении потребителей. Однако традиционные статистические методы с трудом адаптируются к изменениям, что снижает точность прогнозов. Более того, они могут оказаться неэффективными при работе с выбросами или нерегулярными моделями спроса, которые распространены в определенных отраслях или категориях продуктов [29].

Несмотря на ограничения, традиционные статистические методы обеспечивают прочную прикладную основу историческим моделям спроса и могут служить эталоном для оценки эффективности более продвинутых методов прогнозирования. При использовании в сочетании с другими методами, а именно с алгоритмами машинного обучения, они способствуют более точному и надежному прогнозированию [29].

В заключение следует обратить внимание на то, что традиционные статистические методы, используя исторические данные о спросе, продолжают играть жизненно важную роль в понимании динамики спроса и служат основой для более совершенных методов прогнозирования.

*Передовые методы*, такие как регрессионный анализ, нейронные сети и ансамблевые модели, выходят за рамки традиционных статистических методов и предлагают мощные инструменты для создания точных прогнозов путем выявления сложных взаимосвязей [29].

*Регрессионный анализ* — универсальный метод, исследует взаимосвязь между зависимой переменной (спросом) и одной или несколькими независимыми переменными (цена, рекламные акции и экономические показатели) [29]. Анализируя исторические данные о спросе наряду с соответствующими факторами, регрессионные модели могут определять количественный показатель влияния разных переменных на спрос.

Практичность метода состоит в наличии разных способов регрессионного анализа: можно использовать линейную регрессию, множественную регрессию и логистическую регрессию, в зависимости от характера данных о спросе и целей исследования. Регрессионный анализ помогает выявить драйверы спроса и обеспечивает основу для прогнозирования и планирования спроса.

*Нейронные сети*, опосредованные теорией функционирования человеческого мозга, представляют собой класс алгоритмов машинного обучения, успешно распознающих образы. Они состоят из взаимосвязанных узлов (нейронов), организованных слоями, каждый из которых способствует вычислению и интерпретации данных. Обучаясь на исторических данных, нейронные сети фиксируют нелинейности, взаимодействия и зависимости в моделях спроса, которые могут быть неочевидными для традиционных статистических методов. Модели глубокого обучения, такие как глубокие нейронные сети и рекуррентные нейронные сети (RNN), особенно эффективны при обработке данных временных рядов и могут значительно повысить точность прогнозирования [31].

*Модели ансамбля* объединяют прогнозы нескольких моделей для создания более надежного и точного прогноза. Такие модели, как бэггинг, бустинг и суммирование, используют возможности разнообразия и «коллективный интеллект» нескольких моделей для преодоления ограничений отдельных моделей. Например, при прогнозировании спроса модель ансамбля может сочетать прогнозы регрессионных моделей, нейронных сетей и традиционных статистических методов. Ансамблевые модели смягчают неотъемлемую неопределенность и изменчивость данных о спросе, что повышает эффективность прогнозирования [1; 3; 13; 20; 21; 22; 23; 24; 25; 26].

Преимущества передовых методов очевидны: они фиксируют сложные отношения,

нелинейности и взаимодействия между драйверами спроса; обрабатывают большие и разнообразные наборы данных, позволяя использовать несколько источников данных для прогнозирования; могут адаптироваться к преобразованию моделей спроса и динамике рынка, обеспечивая более надежные прогнозы в динамичной бизнес-среде.

Однако перечисленные передовые методы часто требуют значительных вычислительных ресурсов и опыта анализа данных и машинного обучения. Качество данных и предварительной обработки прямо пропорционально точности обучения и проверки модели. Кроме того, интерпретируемость передовых методов может быть ограничена, что затрудняет понимание основных факторов, определяющих спрос.

Эффективность передовых методов зависит от выбора подходящей модели на основе характеристик данных о спросе и в соответствии с целями исследования. Необходимо учитывать сильные стороны и ограничения каждого метода и соответствующим образом адаптировать свой подход. Показатели проверки и оценки, такие как среднеквадратическая ошибка (MSE) или средняя абсолютная ошибка в процентах (MAPE), определяют оценку производительности моделей, в отличие от эталонных или традиционных методов [27].

В заключение следует отметить, что преимущества повышенной точности прогнозирования и адаптивности делают передовые методы ценными активами в оптимизации уровней запасов, сокращении дефицита и повышении удовлетворенности клиентов.

*Регрессионный анализ, нейронные сети и модели ансамбля* имеют уникальные сильные стороны, ограничения и особенности приложения. Проведем сравнительный анализ этих аспектов, поскольку их понимание имеет решающее значение для выбора наиболее подходящего метода на основе характеристик данных о спросе и конкретных целей прогнозирования [28].

Сила регрессионного анализа заключается в количественной оценке влияния разных факторов на спрос, что делает его результативным в выявлении причинно-следственных связей и движущих сил спроса. Регрессионный анализ особенно эффективен, когда существуют четкие линейные или нелинейные отношения между переменной спроса и независимыми переменными. Он может обрабатывать как непрерывные, так и категориальные независимые переменные. Однако предполагается, что взаимосвязь между переменными постоянна во времени, что может ограничивать точность в захвате динамических моделей спроса. Кроме того, требуется тщательный выбор соответствующих независимых переменных и предполагается, что связь является стационарной [31].

Возможности нейронных сетей, в том числе моделей глубокого обучения, состоят в захвате сложных закономерностей и нелинейных отношений в данных о спросе. Их способность учиться на исторических данных и распознавать сложные закономерности делает их пригодными для обработки больших и разнообразных наборов данных. Нейронные сети могут адаптироваться к изменению моделей спроса. Они эффективны в решении задач прогнозирования, когда отношения сложны и традиционные статистические методы дают сбой. Однако нейронные сети требуют значительных вычислительных ресурсов для обучения, большого набора данных, а «черный ящик» делает их менее интерпретируемыми по сравнению с другими методами, что может ограничить понимание основных факторов спроса [14].

Сила моделей ансамбля заключается в их способности использовать «коллективный разум» и возможности отдельных моделей. Бэггинг и бустинг особенно эффективны, когда в данных есть неопределенности или когда разные модели охватывают разные аспекты моделирования спроса. Однако для моделей ансамбля вероятны большие

вычислительные ресурсы, и требуется тщательный выбор и обучение отдельных моделей. Интерпретируемость также может стать проблемой при объединении нескольких моделей [29].

Выделим логические основы выбора каждого передового метода. Регрессионный анализ подходит, когда необходимо понять причинно-следственные связи и количественно оценить влияние цены, рекламных акций и маркетинговой деятельности на спрос.

Нейронные сети, в том числе модели глубокого обучения, хорошо подходят для захвата сложных шаблонов и нелинейных отношений в данных о спросе. Они эффективны, когда существуют сложные взаимодействия между драйверами спроса и когда необходимо учитывать временные зависимости.

Ансамблевые модели подходят, когда необходимо повысить точность и надежность прогнозирования. Они полезны, когда разные модели охватывают разные аспекты моделей спроса или когда необходимо учитывать неопределенности в данных.

В заключение уточним логический смысл суждений об особенностях прогнозирования спроса передовыми методами. Регрессионный анализ дает количественную оценку влияния драйверов спроса, но предполагает постоянную взаимосвязь. Нейронные сети захватывают сложные шаблоны, но требуют значительных вычислительных ресурсов и имеют ограниченную интерпретируемость. Ансамблевые модели повышают точность прогнозирования, но могут требовать значительных вычислительных ресурсов. Принимая во внимание конкретные характеристики данных о спросе и желаемые цели прогнозирования, исследователи и практики могут выбрать наиболее подходящий метод, который наилучшим образом соответствует их потребностям и максимизирует точность и надежность прогнозов спроса.

## Заключение

Обоснуем выводы, полученные в ходе обзорного исследования, и сформулируем рекомендации. Обзорное исследование методов анализа данных и машинного обучения дало ценную информацию о потенциальных преимуществах и проблемах, связанных с подходами к прогнозированию и планированию спроса. Основные суждения обзора можно резюмировать с упором на прикладное использование.

1. Преимущества использования методов: повышение точности прогнозирования спроса, оптимизация уровня запасов, сокращение дефицита, повышение скорости выполнения заказов и повышение удовлетворенности клиентов. Компании могут использовать эти методы, чтобы получить конкурентное преимущество, повысить эффективность цепочки поставок и повысить прибыльность.

2. Изучены методы: традиционные статистические методы, такие как анализ временных рядов, скользящие средние и экспоненциальное сглаживание, и передовые методы, такие как регрессионный анализ, нейронные сети, ансамблевые модели, а также проведен сравнительный анализ особенностей их применения. Компании получают представление о сильных сторонах, ограничениях и применении каждого метода, а также всестороннее понимание его полезности в различных контекстах.

3. Роль прикладного использования методов в оптимизации запасов и сокращении дефицита: компании имеют возможность поддерживать оптимальные уровни запасов, сводить к минимуму их нехватку и избегать ситуаций затоваривания. Целевой вектор этой деятельности направлен на повышение эффективности работы, снижение транспортных расходов и повышение удовлетворенности клиентов.

В заключение подчеркнем, что применение аналитики данных и машинного обучения требует решения проблем, связанных

с качеством данных, опытом и этическими соображениями. Используя сильные стороны приложения традиционных статистических и передовых методов и устраняя ограничения, можно добиться устойчивого роста на современном рынке, управляемом данными.

## Список литературы и источников

1. A comparative study of demand forecasting models for a multi-channel retail company: A novel hybrid machine learning approach / A. Mitra, A. Jain, A. Kishore, P. Kumar // *Operations Research Forum*. 2022. Vol. 3. Art. No. 58. <https://doi.org/10.1007/s43069-022-00166-4>
2. **Abbasimehr H., Shabani M., Yousefi M.** An optimized model using LSTM network for demand forecasting // *Computers & Industrial Engineering*. 2020. Vol. 143. Art. ID: 106435. <https://doi.org/10.1016/j.cie.2020.106435>
3. An improved demand forecasting model using deep learning approach and proposed decision integration strategy for supply chain / Z. H. Kilimci, A. O. Akyuz, M. Uysal et al. // *Complexity*. 2019. Vol. 2019. Art. ID: 9067367. <https://doi.org/10.1155/2019/9067367>
4. **Box G. E. P., Jenkins G. M., Reinsel G. C.** *Time Series Analysis: Forecasting and Control*. 4<sup>th</sup> ed. Hoboken, NJ: Wiley, 2008. 784 p.
5. **Breiman L.** Random forests // *Machine Learning*. 2001. Vol. 45 (1). P. 5–32. <https://doi.org/10.1023/A:1010933404324>
6. **Bruzda J.** Demand forecasting under fill rate constraints — The case of re-order points // *International Journal of Forecasting*. 2020. Vol. 36. Iss. 4. P. 1342–1361. <https://doi.org/10.1016/j.ijforecast.2020.01.007>
7. **Carbonneau R., Laframboise K., Vahidov R.** Application of machine learning techniques for supply chain demand forecasting // *European Journal of Operational Research*. 2008. Vol. 184. Iss. 3. P. 1140–1154. <https://doi.org/10.1016/j.ejor.2006.12.004>

8. **Chien C.-F., Hong T.-Y., Guo H.-Z.** An empirical study for smart production for TFT-LCD to empower Industry 3.5 // *Journal of Chinese Institute of Engineers*. 2017. Vol. 40. Iss. 7. P. 552—561. <https://doi.org/10.1080/02533839.2017.1372220>
9. **Choi T.-M., Hui C.-L., Yu Y.** Intelligent time series fast forecasting for fashion sales: A research agenda // 2011 International Conference on Machine Learning and Cybernetics. Guilin: IEEE, 2011. P. 1010—1014. <https://doi.org/10.1109/ICMLC.2011.6016870>
10. **Das P., Chaudhury S.** Prediction of retail sales of footwear using feedforward and recurrent neural networks // *Neural Computing and Applications*. 2007. Vol. 16 (4). P. 491—502. <https://doi.org/10.1007/s00521-006-0077-3>
11. Fast fashion sales forecasting with limited data and time / T.-M. Choi, C.-L. Hui, N. Liu et al. // *Decision Support Systems*. 2014. Vol. 59. P. 84—92. <https://doi.org/10.1016/j.dss.2013.10.008>
12. Forecasting of demand using ARIMA model / **J. Fattah, L. Ezzine, Z. Aman et al.** // *International Journal of Engineering Business Management*. 2018. Vol. 10 (2). <https://doi.org/10.1177/1847979018808673>
13. Fuzzy forecast combining for apparel demand forecasting / M. Kaya, E. Yeşil, M. F. Dodurka, S. Sıradağ // *Intelligent Fashion Forecasting Systems: Models and Applications* / eds T.-M. Choi, C.-L. Hui, Y. Yu. Berlin; Heidelberg: Springer, 2013. P. 123—146. [https://doi.org/10.1007/978-3-642-39869-8\\_7](https://doi.org/10.1007/978-3-642-39869-8_7)
14. **Gutierrez R. S., Solis A. O., Mukhopadhyay S.** Lumpy demand forecasting using neural networks // *International Journal of Production Economics*. 2008. Vol. 111. Iss. 2. P. 409—420. <https://doi.org/10.1016/j.ijpe.2007.01.007>
15. Hierarchical pattern recognition for tourism demand forecasting / M. Hu, R. T. R. Qiu, D. C. Wu, H. Song // *Tourism Management*. 2021. Vol. 84. Art. No. 104263 <https://doi.org/10.1016/j.tourman.2020.104263>
16. **Hui P. C. L., Choi T.-M.** 5 — Using artificial neural networks to improve decision making in apparel supply chain systems // *Information Systems for the Fashion and Apparel Industry* / ed. T.-M. Choi. New York: Woodhead Publ., 2016. P. 97—107. (Woodhead Publishing Series in Textiles). <https://doi.org/10.1016/B978-0-08-100571-2.00005-1>
17. **İmce S., Beyca Ö. F.** Demand forecasting with integration of time series and regression models in pharmaceutical industry // *International Journal of Advances in Engineering and Pure Sciences*. 2022. Vol. 34. Iss. 3. P. 415—425. <https://doi.org/10.7240/jeps.1127844>
18. *Introduction to Statistical Learning: with Applications in R* / G. James, D. Witten, T. Hastie, R. Tibshirani. New York: Springer, 2021. XV, 607 p. (Springer Texts in Statistics). <https://doi.org/10.1007/978-1-0716-1418-1>
19. **Kang Y., Hyndman R. J., Smith-Miles K.** Visualising forecasting algorithm performance using time series instance spaces // *International Journal of Forecasting*. 2017. Vol. 33. Iss. 2. P. 345—358. <https://doi.org/10.1016/j.ijforecast.2016.09.004>
20. **Karimnezhad A., Moradi F.** Bayes, E-Bayes and robust Bayes prediction of a future observation under precautionary prediction loss functions with applications // *Applied Mathematical Modelling*. 2016. Vol. 40. Iss. 15-16. P. 7051—7061. <https://doi.org/10.1016/j.apm.2016.02.040>
21. **Kogan K., Herbon A.** Production under periodic demand update prior to a single selling season: A decomposition approach // *European Journal of Operational Research*. 2008. Vol. 184. Iss. 1. P. 133—146. <https://doi.org/10.1016/j.ejor.2006.11.009>
22. **Kourentzes N.** Intermittent demand forecasts with neural networks // *International Journal of Production Economics*. 2013. Vol. 143. Iss. 1. P. 198—206. <https://doi.org/10.1016/j.ijpe.2013.01.009>
23. **Kozik P., Sep J.** Aircraft engine overhaul demand forecasting using ANN // *Management and Production Engineering Review*. 2012. Vol. 3. P. 21—26.
24. **Lasek A., Cercone N., Saunders J.** Restaurant sales and customer demand forecasting:

- Literature survey and categorization of methods // Smart City 360°: First EAI International Summit, Revised Selected Papers. Cham: Springer, 2016. P. 479—491. [https://doi.org/10.1007/978-3-319-33681-7\\_40](https://doi.org/10.1007/978-3-319-33681-7_40)
25. **Loureiro A. L. D., Miguéis V. L., Silva L. F. da.** Exploring the use of deep neural networks for sales forecasting in fashion retail // Decision Support Systems. 2018. Vol. 114. P. 81—93. <https://doi.org/10.1016/j.dss.2018.08.010>
  26. **Lu C.-J.** Sales forecasting of computer products based on variable selection scheme and support vector regression // Neurocomputing. 2014. Vol. 128. P. 491—499. <https://doi.org/10.1016/j.neucom.2013.08.012>
  27. **Moon M. A.** Demand and Supply Integration: The Key to World-Class Demand Forecasting. 2<sup>nd</sup> ed. Berlin; Boston: Walter de Gruyter, 2018. XVI, 234 p. <https://doi.org/10.1515/9781501506024>
  28. **Mostard J., Teunter R., Koster R. de.** Forecasting demand for single-period products: A case study in the apparel industry // European Journal of Operational Research. 2011. Vol. 211. Iss. 1. P. 139—147. <https://doi.org/10.1016/j.ejor.2010.11.001>
  29. **Nia A. R., Awasthi A., Bhuiyan N.** Industry 4.0 and demand forecasting of the energy supply chain: A literature review // Computers & Industrial Engineering. 2021. Vol. 154. Art. ID: 107128. <https://doi.org/10.1016/j.cie.2021.107128>
  30. Utilizing Random forest with iForest-based outlier detection and SMOTE to detect movement and direction of RFID tags / G. Alfian, M. Syafrudin, N. L. Fitriyani et al. // Future Internet. 2023. Vol. 15. Iss. 3. Art. No. 103. <https://doi.org/10.3390/fi15030103>
  31. **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. Art. No. 1157. <https://doi.org/10.3390/pr9071157>
- ## References
1. 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* 3 (2022): 58. <https://doi.org/10.1007/s43069-022-00166-4>
  2. Abbasimehr H., Shabani M., Yousefi M. “An Optimized Model Using LSTM Network for Demand Forecasting”. *Computers & Industrial Engineering* 143 (2020). <https://doi.org/10.1016/j.cie.2020.106435>
  3. Kilimci Z. H., Akyuz A. O., Uysal M., Akyokus S., Uysal M. O., Bulbul B. A., Ekmis M. A. “An Improved Demand Forecasting Model Using Deep Learning Approach and Proposed Decision Integration Strategy for Supply Chain”. *Complexity* 2019 (2019): 9067367. <https://doi.org/10.1155/2019/9067367>
  4. Box G. E. P., Jenkins G. M., Reinsel G. C. *Time Series Analysis: Forecasting and Control*. 4<sup>th</sup> ed. Hoboken, NJ: Wiley, 2008. 784 p.
  5. Breiman Leo. “Random Forests”. *Machine Learning* 45.1 (2001): 5—32. <https://doi.org/10.1023/A:1010933404324>
  6. Bruzda Joanna. “Demand Forecasting under Fill Rate Constraints — The Case of Re-Order Points”. *International Journal of Forecasting* 36.4 (2020): 1342—1361. <https://doi.org/10.1016/j.ijforecast.2020.01.007>
  7. Carbonneau Real, Laframboise Kevin, Vahidov Rustam. “Application of Machine Learning Techniques for Supply Chain Demand Forecasting”. *European Journal of Operational Research* 184.3 (2008): 1140—1154. <https://doi.org/10.1016/j.ejor.2006.12.004>
  8. Chien Chen-Fu, Hong Tzu-Yen, Guo Hong-Zhi. “An Empirical Study for Smart Production for TFT-LCD to Empower Industry 3.5”. *Journal of Chinese Institute of Engineering* 40.7 (2017): 552—561. <https://doi.org/10.1080/02533839.2017.1372220>
  9. Choi Tsan-Ming, Hui Chi-Leung, Yu Yong. “Intelligent Time Series Fast Forecasting for Fashion Sales: A Research Agenda”. *2011 International*

- Conference on Machine Learning and Cybernetics, ICMLC 2011*. Guilin: IEEE, 2011. 1010—1014. <https://doi.org/10.1109/ICMLC.2011.6016870>
10. Das Prasun, Chaudhury Subhasis. “Prediction of Retail Sales of Footwear using Feedforward and Recurrent Neural Networks”. *Neural Computing and Applications* 16.4 (2007): 491—502. <https://doi.org/10.1007/s00521-006-0077-3>
  11. Choi Tsan-Ming, Hui Chi-Leung, Liu Na, Ng Sau-Fun, Yu Yong. “Fast Fashion Sales Forecasting with Limited Data and Time”. *Decision Support Systems* 59 (2014): 84—92. <https://doi.org/10.1016/j.dss.2013.10.008>
  12. Fattah J., Ezzine L., Aman Z., El Mousami H., Lachhab A. “Forecasting of Demand using ARIMA Model”. *International Journal of Engineering Business Management* 10 (2018). <https://doi.org/10.1177/1847979018808673>
  13. Kaya M., Yeşil E., Dodurka M. F., Siradağ S. “Fuzzy Forecast Combining for Apparel Demand Forecasting”. *Intelligent Fashion Forecasting Systems: Models and Applications*. Eds T.-M. Choi, C.-L. Hui, Y. Yu. Berlin: Springer, 2013. 123—146. [https://doi.org/10.1007/978-3-642-39869-8\\_7](https://doi.org/10.1007/978-3-642-39869-8_7)
  14. Gutierrez R. S., Solis A. O., Mukhopadhyay S. “Lumpy Demand Forecasting using Neural Networks”. *International Journal of Production Economics* 111.2 (2008): 409—420. <https://doi.org/10.1016/j.ijpe.2007.01.007>
  15. Hu M., Qiu R. T. R., Wu D. C., Song H. “Hierarchical Pattern Recognition for Tourism Demand Forecasting”. *Tourism Management* 84 (2021): 104263. <https://doi.org/10.1016/j.tourman.2020.104263>
  16. Hui P. C. L., Choi T.-M. “5 — Using Artificial Neural Networks to Improve Decision Making in Apparel Supply Chain Systems”. *Information Systems for the Fashion and Apparel Industry*. Ed. T.-M. Choi. New York: Woodhead Publ., 2016. 97—107. Woodhead Publishing Series in Textiles. <https://doi.org/10.1016/B978-0-08-100571-2.00005-1>
  17. İmece S., Beyca Ö. F. “Demand Forecasting with Integration of Time Series and Regression Models in Pharmaceutical Industry”. *International Journal of Advances in Engineering and Pure Sciences* 34.3 (2022): 415—425. <https://doi.org/10.7240/jeps.1127844>
  18. James Gareth, Witten Daniela, Hastie Trevor, Tibshirani Robert. *Introduction to Statistical Learning: With Applications in R*. New York: Springer, 2021. xvi, 607 p. Springer Texts in Statistics. <https://doi.org/10.1007/978-1-0716-1418-1>
  19. Kang Y., Hyndman R. J., Smith-Miles K. “Visualising Forecasting Algorithm Performance using Time Series Instance Spaces”. *International Journal of Forecasting* 33.2 (2017): 345—358. <https://doi.org/10.1016/j.ijforecast.2016.09.004>
  20. Karimnezhad Ali, Moradi Fahimeh. “Bayes, E-Bayes and Robust Bayes Prediction of a Future Observation under Precautionary Prediction Loss Functions with Applications”. *Applied Mathematical Modelling* 40.15-16 (2016): 7051—7061. <https://doi.org/10.1016/j.apm.2016.02.040>
  21. Kogan K., Herbon A. “Production under Periodic Demand Update Prior to a Single Selling Season: A Decomposition Approach”. *European Journal of Operational Research* 184.1 (2008): 133—146. <https://doi.org/10.1016/j.ejor.2006.11.009>
  22. Kourentzes Nikolaos. “Intermittent Demand Forecasts with Neural Networks”. *International Journal of Production Economics* 143.1 (2013): 198—206. <https://doi.org/10.1016/j.ijpe.2013.01.009>
  23. Kozik Piotr, Sep Jaroslaw. “Aircraft Engine Overhaul Demand Forecasting using ANN”. *Management and Production Engineering Review* 3 (2012): 21—26.
  24. Lasek A., Cercone N., Saunders J. “Restaurant Sales and Customer Demand Forecasting: Literature Survey and Categorization of Methods”. *Smart City 360°: First EAI International Summit, Revised Selected Papers*. Cham: Springer, 2016. 479—491. [https://doi.org/10.1007/978-3-319-33681-7\\_40](https://doi.org/10.1007/978-3-319-33681-7_40)
  25. Loureiro A., Miguéis V., Silva L. F. da. “Exploring the Use of Deep Neural Networks for Sales Forecasting in Fashion Retail”. *Decision Support Systems* 114 (2018): 81—93. <https://doi.org/10.1016/j.dss.2018.08.010>

26. Lu Chi-Jie. “Sales Forecasting of Computer Products Based on Variable Selection Scheme and Support Vector Regression”. *Neurocomputing* 128 (2014): 491–499. <https://doi.org/10.1016/j.neucom.2013.08.012>
27. Moon Mark A. *Demand and Supply Integration: The Key to World-Class Demand Forecasting*. 2<sup>nd</sup> ed. Berlin: Walter de Gruyter, 2018. xvi, 234 p. <https://doi.org/10.1515/9781501506024>
28. Mostard J., Teunter R., Koster R. de. “Forecasting Demand for Single-Period Products: A Case Study in the Apparel Industry”. *European Journal of Operational Research* 211.1 (2011): 139–147. <https://doi.org/10.1016/j.ejor.2010.11.001>
29. Nia A. R., Awasthi A., Bhuiyan N. “Industry 4.0 and Demand Forecasting of the Energy Supply Chain”. *Computers & Industrial Engineering* 154 (2021): 107128. <https://doi.org/10.1016/j.cie.2021.107128>
30. Alfian G., Syafrudin M., Fitriyani N. L., Alam S., Pratomo D. N., Subekti L., Octava M. Q. H., Yulianingsih N. D. et al. “Utilizing Random Forest with iForest-Based Outlier Detection and SMOTE to Detect Movement and Direction of RFID Tags”. *Future Internet* 15.3 (2023): 103. <https://doi.org/10.3390/fi15030103>
31. 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* 9 (2021): 1157. <https://doi.org/10.3390/pr9071157>

#### Информация об авторе

**Родюлин Родион Сергеевич** — кандидат экономических наук, доцент кафедры математики и моделирования, Владивостокский государственный университет (Россия, 690000, г. Владивосток, ул. Гоголя, 41).

#### Information about the author

**Rodion S. Rogulin** — PhD (Econ.), Associate Professor at the Mathematics and Modelling Department, Vladivostok State University (Russia, 690000, Vladivostok, Gogol str., 41).

Статья поступила в редакцию 29.05.2023.

The article was submitted 29.05.2023.