

Краткие сообщения Brief reports

Краткое сообщение
УДК 338.274.3; 004.85
DOI: 10.14529/ctcr250409

КОМБИНИРОВАННЫЙ МЕТОД ПРОГНОЗИРОВАНИЯ СПРОСА НА ПРОДОВОЛЬСТВЕННЫЕ ТОВАРЫ НА ОСНОВЕ АНСАМБЛЯ LSTM-СЕТИ И SARIMA-МОДЕЛИ ДЛЯ ИНТЕГРАЦИИ В ERP-СИСТЕМЫ РОССИЙСКОГО РИТЕЙЛА

А.А. Микрюков¹, 9127771067@mail.ru, <https://orcid.org/0009-0008-4664-6911>

Д.В. Гилёв², denis.gilev@urfu.ru, <https://orcid.org/0000-0003-1040-5696>

¹ Южно-Уральский государственный университет, Челябинск, Россия

² Уральский федеральный университет, Екатеринбург, Россия

Аннотация. Цель исследования: повышение точности прогнозирования спроса на продовольственные товары в условиях высокой волатильности и сложной сезонной структуры для последующей интеграции в модули управления запасами ERP-систем, включая российские решения на платформе «1С». **Материалы и методы.** Предложен комбинированный метод на основе ансамбля SARIMA (англ. Seasonal Autoregressive Integrated Moving Average – сезонная авторегрессионная модель скользящего среднего) и многослойной LSTM-сети (англ. Long Short-Term Memory – сеть долгой краткосрочной памяти). Веса моделей определяются адаптивно на основе ошибки на валидационной выборке. Эксперимент проведён на реальных данных соревнования M5 Forecasting (Walmart), включающих временные ряды спроса по 120 наименованиям продуктов питания. Для оценки качества использованы метрики MAE, RMSE, MAPE и тест Дибальда – Мариано. **Результаты.** Предложенный ансамбль снижает среднюю абсолютную процентную ошибку (MAPE) до 52,96 % – на 1,1 % лучше SARIMA и на 14,0 % лучше LSTM. Статистическая значимость улучшения подтверждена тестом Дибальда – Мариано ($p < 0,001$). Анализ показал, что комбинация линейной интерпретируемости SARIMA и нелинейной гибкости LSTM обеспечивает устойчивость к выбросам и повышает точность в периоды резких колебаний спроса (например, перед праздниками). Практическая ценность работы заключается в возможности снижения уровня дефицита и избыточных запасов за счёт более точного прогноза спроса. **Заключение.** Разработанный метод демонстрирует высокий потенциал для интеграции в ERP-системы российского ритейла, где требуется баланс между точностью, интерпретируемостью и автоматизацией. Результаты позволяют рекомендовать ансамбль для внедрения в модули автоматизированного планирования закупок и управления товарными запасами.

Ключевые слова: прогнозирование спроса, машинное обучение, SARIMA, LSTM-сеть, ансамблевые модели, ERP-системы, управление товарными запасами, временные ряды

Для цитирования: 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

Brief report

DOI: 10.14529/ctcr250409

**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****A.A. Mikryukov**¹, 9127771067@mail.ru, <https://orcid.org/0009-0008-4664-6911>**D.V. Gilev**², denis.gilev@urfu.ru, <https://orcid.org/0000-0003-1040-5696>¹ South Ural State University, Chelyabinsk, Russia² Ural Federal University, Ekaterinburg, Russia

Abstract. The purpose of the study. To improve the accuracy of food demand forecasting under conditions of high volatility and complex seasonality for integration into inventory management modules of ERP systems, including Russian solutions based on the 1C platform. **Materials and methods.** A hybrid method is proposed based on an ensemble of SARIMA (Seasonal Autoregressive Integrated Moving Average) and a multilayer LSTM network (Long Short-Term Memory). Model weights are determined adaptively based on validation error. The experiment was conducted on real data from the M5 Forecasting Competition (Walmart), covering demand time series for 120 food products. Evaluation metrics included MAE, RMSE, MAPE, and the Diebold–Mariano test. **Results.** The proposed ensemble reduces Mean Absolute Percentage Error (MAPE) to 52.96 % – 1.1 % better than SARIMA and 14.0 % better than LSTM. Statistical significance of the improvement was confirmed by the Diebold–Mariano test ($p < 0.001$). The combination of SARIMA’s interpretability and LSTM’s nonlinear flexibility provides robustness to outliers and higher accuracy during sharp demand fluctuations (e.g., before holidays). The practical value of the study lies in the possibility of reducing the level of shortages and excess stocks through a more accurate demand forecast. **Conclusion.** The developed method shows strong potential for integration into ERP systems used in Russian retail, where a balance between accuracy, interpretability, and automation is essential. The results support the practical adoption of the ensemble in automated procurement and inventory planning modules.

Keywords: demand forecasting, machine learning, SARIMA, LSTM network, ensemble models, ERP systems, inventory management, time series

For citation: 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

Введение

Одной из ключевых задач в управлении цепочками поставок розничной торговли является минимизация издержек при одновременном обеспечении высокого уровня сервиса. В российской практике эта задача всё чаще решается в рамках ERP-систем, среди которых доминирующее положение занимает платформа «1С» – в частности, конфигурации «1С: Управление торговлей» и «1С: ERP Управление предприятием». Центральным элементом таких систем является модуль прогнозирования спроса, от точности которого напрямую зависит эффективность управления товарными запасами [1].

Традиционные статистические методы, такие как SARIMA, ценятся за интерпретируемость и устойчивость к переобучению [2], но не всегда достаточно хорошо справляются с нелинейными паттернами. В то же время нейросетевые подходы, особенно LSTM-сети, способны улавливать сложные временные зависимости [3], но склонны к переобучению на коротких или разреженных рядах и работают как «чёрный ящик» [4]. В условиях ERP-среды, где важны как точность, так и прозрачность решений, особенно актуальным становится гибридный подход. Идея комбинирования статистических и нейросетевых моделей впервые была предложена Zhang [5] и активно развивается в последние годы [6]. Современные исследования подтверждают, что эффективное прогнозирование требует интеграции разнородных методов, учёта теоретических основ и эмпирических особенностей данных [7, 8]. Однако остаются открытыми вопросы адаптивного взвешива-

ния компонентов ансамбля и его масштабируемости на тысячи номенклатурных единиц – типичную для ERP-систем нагрузку.

Цель данной работы – разработать и экспериментально оценить комбинированный метод прогнозирования спроса на основе ансамбля SARIMA-модели и LSTM-сети с адаптивным взвешиванием, ориентированный на интеграцию в ERP-системы российского ритейла.

1. Материалы и методы

В эксперименте использованы данные соревнования M5 Forecasting – Accuracy, организованного Walmart и доступного на платформе Kaggle [9]. Данные охватывают период с 2011 по 2016 г. и включают:

- ежедневные продажи более чем по 30 000 товарным единицам;
- информацию о магазинах, категориях, департаментах;
- календарные события, промоакции, цены.

Для исследования была выбрана подвыборка из 120 наименований из категории «Food» (мясные и молочные продукты, хлебобулочные изделия и т. д.), характеризующихся выраженной недельной сезонностью и умеренной волатильностью.

1.1. Методология

1.1.1. SARIMA-модель

Модель SARIMA(p,d,q)(P,D,Q)[s] применяется для описания линейных компонент ряда. Для ежедневных данных выбрано значение сезонности $s = 7$. Параметры модели подбирались автоматически с использованием библиотеки pmdarima на основе минимизации AIC (англ. Akaike Information Criterion – информационный критерий Акаике) в соответствии с рекомендациями классических работ по анализу временных рядов [2, 10].

1.1.2. LSTM-сеть использовалась двухслойная LSTM-архитектура:

- вход: скользящее окно длиной 90 дней;
- скрытые слои: 50 и 25 LSTM-ячеек;
- выход: полносвязный слой (Dense) для прогноза на 7 дней;
- функция активации: ReLU;
- оптимизатор: Adam, скорость обучения 0.001;
- регуляризация: dropout 0.2, early stopping при отсутствии улучшения на 10 эпох.

Данные нормализовались методом Min-Max. Архитектура основана на фундаментальной работе Hochreiter & Schmidhuber [3] и современных обзорах по применению рекуррентных сетей в прогнозировании временных рядов [4].

1.1.3. Архитектура ансамбля «Финальный прогноз» формируется как взвешенная сумма:

$$\hat{Y}_t^{\text{ensemble}} = \alpha \cdot \hat{y}_t^{\text{SARIMA}} + (1 - \alpha) \cdot \hat{y}_t^{\text{LSTM}}.$$

Значение веса $\alpha \in [0,1]$ определяется путём минимизации MAE на валидационной выборке. Такой подход обеспечивает баланс между интерпретируемостью и адаптивностью, позволяя модели автоматически определять, какая из компонент более надёжна в текущих условиях.

1.1.4. Метрики оценки

Для оценки качества прогнозов использовались следующие метрики: MAE (англ. Mean Absolute Error – средняя абсолютная ошибка). RMSE (англ. Root Mean Square Error – корень из среднеквадратичной ошибки). MAPE (англ. Mean Absolute Percentage Error – средняя абсолютная процентная ошибка). Тест Дибальда – Мариано (Diebold-Mariano test) – для проверки статистической значимости различий между моделями [11].

2. Результаты

2.1. Подготовка данных

Временной ряд одного товара (например, FOODS_3_090) был разделён на выборки:

- Train: 1147 дней (60 %);
- Val: 383 дня (20 %);
- Test: 383 дня (20 %).

Такое разделение позволяет обеспечить достаточный объём данных для обучения и валидации, а также адекватную оценку качества на независимой тестовой выборке, соответствует стандартным практикам временных рядов и рекомендациям из [10, 12].

2.2. Оптимизация веса ансамбля

Вес α был подобран на валидационной выборке. Оптимальное значение:

$$\alpha = 0,553.$$

Это означает, что SARIMA и LSTM вносят примерно равный вклад в финальный прогноз. Такой результат свидетельствует о том, что ни одна из моделей не доминирует, а их комбинация позволяет компенсировать слабые стороны каждой.

2.3. Сравнение моделей

Сравнение моделей по метрикам качества (среднее по 120 ассортиментным позициям)
Comparison of models by quality metrics (average for 120 product lines)

МОДЕЛЬ	MAE	RMSE	MAPE, %
SARIMA	23,446	32,881	53,524
LSTM	19,077	26,093	61,576
Ансамбль (предложенный)	19,725	27,723	52,956

Источник: составлено автором.

Анализ (см. таблицу) показывает, что ансамбль обеспечивает наилучшую точность по MAPE – на 1,1 %, лучше SARIMA и на 14,0 % лучше LSTM. При этом MAE и RMSE ансамбля близки к результатам LSTM, что указывает на стабильность прогноза. Стоит отметить, что MAPE у LSTM оказался выше, чем у SARIMA, что может быть связано с повышенной чувствительностью LSTM к резким скачкам спроса, которые интерпретируются как выбросы. В то же время ансамбль демонстрирует более сглаженное поведение, что делает его более устойчивым к таким колебаниям.

2.4. Статистическая проверка

Для оценки значимости использован тест Дибальда – Мариано [11]:


– DM-статистика: 4,476;

– p-value: < 0,001.

Нулевая гипотеза отвергается на уровне $\alpha = 0,05$ – ансамбль статистически значимо лучше SARIMA. Это подтверждает, что улучшение точности не является случайным и имеет практическую значимость.

2.5. Визуализация прогнозов

На рисунке представлено сравнение прогнозов моделей на тестовом участке для одного из товаров.



Сравнение прогнозов моделей (номенклатурная единица «Packaged Meat» («Мясо в упаковке»))
Comparison of model predictions (SKU: «Packaged Meat»)

Предложенный подход эффективно сочетает линейную интерпретацию SARIMA и нелинейную аппроксимацию LSTM. Особенно значительное повышение точности наблюдается в перио-

дах резких изменений спроса (например, перед праздниками), где LSTM компенсирует систематическую ошибку SARIMA. Однако ансамбль требует большего времени на настройку. Для масштабирования на тысячи наименований товарных единиц целесообразно реализовать автоматизированный процесс подбора весов, позволяющий обрабатывать каждый временной ряд без участия оператора. Также следует отметить, что при отсутствии данных о промоакциях точность снижается на 25–30 %, что указывает на важность включения экзогенных факторов в будущих модификациях [9, 13]. Важным аспектом является и интерпретируемость модели. В отличие от «чёрного ящика» LSTM ансамбль позволяет оценить вклад каждой компоненты, что важно для принятия управленческих решений [1, 14].

Выводы

Разработан и экспериментально оценен комбинированный метод прогнозирования спроса на основе ансамбля SARIMA и LSTM с адаптивным взвешиванием. На реальных данных M5 Competition показано, что ансамбль снижает MAPE до 52,96 % – на 1,1 % лучше SARIMA и на 14,0 % лучше LSTM. Статистическая значимость улучшения подтверждена тестом Дибальда – Мариано ($p < 0,001$). Полученные результаты позволяют рекомендовать предложенный метод для внедрения в ERP – системы российского ритейла использующие модули планирования закупок и управления товарными запасами [1, 14, 15].

Перспективы дальнейших исследований:

- включение экзогенных переменных (промо, погода, календарь);
- онлайн-обучение и адаптация весов в реальном времени;
- интеграция с модулями управления нормативами запасов в ERP-системах [16].

Список литературы

1. Więcek P., Kubek D. The Impact Time Series Selected Characteristics on the Fuel Demand Forecasting Effectiveness Based on Autoregressive Models and Markov Chains // *Energies*. 2024. Vol. 17, no. 16. P. 4163. DOI: 10.3390/en17164163
2. Box G.E.P., Jenkins G.M., Reinsel G.C. Time Series Analysis: Forecasting and Control. 4th ed. Wiley, 2008. 746 p.
3. Hochreiter S., Schmidhuber J. Long short-term memory // *Neural Computation*. 1997. Vol. 9, no. 8. P. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735
4. Exogenous Data for Load Forecasting: A Review / R. Christen, L. Mazzola, A. Denzler, E. Portmann // *Proceedings of the 12th International Conference on Data Science, Technology and Applications (DATA 2023)*. 2023. P. 489–500. DOI: 10.5220/0010213204890500
5. Zhang G.P. Time series forecasting using a hybrid ARIMA and neural network model // *Neurocomputing*. 2003. Vol. 50. P. 159–175. DOI: 10.1016/S0925-2312(01)00702-0
6. Smyl S. A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting // *International Journal of Forecasting*. 2020. Vol. 36, no. 1. P. 75–85. DOI: 10.1016/j.ijforecast.2019.03.017
7. Forecasting: theory and practice / F. Petropoulos, D. Apiletti, V. Assimakopoulos et al. // *International Journal of Forecasting*. 2022. Vol. 38, no. 3. P. 705–871. DOI: 10.1016/j.ijforecast.2021.11.001
8. Ord J.K., Fildes B., Kourentzes N. Principles of Business Forecasting. 2nd ed. Wessex Press, 2017. 550 p.
9. M5 Competition: Forecasting Accuracy. Kaggle. URL: <https://www.kaggle.com/c/m5-forecasting-accuracy/data> (дата обращения: 05.04.2025).
10. Hyndman R.J., Athanasopoulos G. Forecasting: principles and practice. 2nd ed. Melbourne: OTexts, 2021. 422 p. URL: <https://otexts.com/fpp2/>.
11. Diebold F.X., Mariano R.S. Comparing predictive accuracy // *Journal of Business & Economic Statistics*. 1995. Vol. 13, no. 3. P. 253–263. DOI: 10.1080/07350015.1995.10524599
12. Makridakis S., Spiliotis E., Assimakopoulos V. The M5 competition: Background, organization, and implementation // *International Journal of Forecasting*. 2022. Vol. 38, no. 4. P. 1325–1336. DOI: 10.1016/j.ijforecast.2021.07.007
13. Implementation of Models for Demand Forecasting for e-Commerce using Time Series Forecasting / N. Yadav, A. Roushan, V. Singh et al. // *2024 Second International Conference*

on Advanced Computing & Communication Technologies (ICACCTech). 2024. DOI: 10.1109/ICACCTech65084.2024.00020

14. Enhancing manufacturing productivity: A review of AI-Driven supply chain management optimization and ERP systems integration / O.A. Adenekan, N.O. Solomon, P. Simpa, S.C. Obasi // *International Journal of Modern Engineering Research*. 2024. Vol. 6, no. 5. DOI: 10.51594/ijmer.v6i5.1126

15. Tulli S.K.C. Comparative Analysis of Traditional and AI-based Demand Forecasting Models // *International Journal of Emerging Trends in Science and Technology*. 2020. Vol. 07, no. 03. P. 6842–6847. DOI: 10.18535/ijetst/v7i6.02

16. Analysis of the Effectiveness of ARIMA, SARIMA, and SVR Models in Time Series Forecasting: A Case Study of Wind Farm Energy Production / K. Szostek, D. Mazur, G. Drałus, J. Kuszniar // *Energies*. 2024. Vol. 17 (19). P. 4803. DOI: 10.3390/en17194803

References

1. Więcek P., Kubek D. The Impact Time Series Selected Characteristics on the Fuel Demand Forecasting Effectiveness Based on Autoregressive Models and Markov Chains. *Energies*. 2024;17(16):4163. DOI: 10.3390/en17164163

2. Box G.E.P., Jenkins G.M., Reinsel G.C. *Time Series Analysis: Forecasting and Control*. 4th ed. Wiley, 2008. 746 p.

3. Hochreiter S., Schmidhuber J. Long short-term memory. *Neural Computation*. 1997;9(8):1735–1780. DOI: 10.1162/neco.1997.9.8.1735

4. Christen R., Mazzola L., Denzler A., Portmann E. Exogenous Data for Load Forecasting: A Review. In: *Proceedings of the 12th International Conference on Data Science, Technology and Applications (DATA 2023)*. 2023. P. 489–500. DOI: 10.5220/0010213204890500

5. Zhang G.P. Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*. 2003;50:159–175. DOI: 10.1016/S0925-2312(01)00702-0

6. Smyl S. A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting. *International Journal of Forecasting*. 2020;36(1):75–85. DOI: 10.1016/j.ijforecast.2019.03.017

7. Petropoulos F., Apiletti D., Assimakopoulos V. et al. Forecasting: theory and practice. *International Journal of Forecasting*. 2022. Vol. 38, no. 3. P. 705–871. DOI: 10.1016/j.ijforecast.2021.11.001

8. Ord J.K., Fildes B., Kourentzes N. *Principles of Business Forecasting*. 2nd ed. Wessex Press, 2017. 550 p.

9. M5 Competition: Forecasting Accuracy. Kaggle. Available at: <https://www.kaggle.com/c/m5-forecasting-accuracy/data> (accessed 05.04.2025)

10. Hyndman R.J., Athanasopoulos G. *Forecasting: principles and practice*. 2nd ed. Melbourne: OTexts, 2021. 422 p. URL: <https://otexts.com/fpp2/>.

11. Diebold F.X., Mariano R.S. Comparing predictive accuracy. *Journal of Business & Economic Statistics*. 1995;13(3):253–263. DOI: 10.1080/07350015.1995.10524599

12. Makridakis S., Spiliotis E., Assimakopoulos V. The M5 competition: Background, organization, and implementation. *International Journal of Forecasting*. 2022;38(4):1325–1336. DOI: 10.1016/j.ijforecast.2021.07.007

13. Yadav N., Roushan A., Singh V., Kumari N., Diksha. Implementation of Models for Demand Forecasting for e-Commerce using Time Series Forecasting. In: *2024 Second International Conference on Advanced Computing & Communication Technologies (ICACCTech)*. 2024. DOI: 10.1109/ICACCTech65084.2024.00020

14. Adenekan O.A., Solomon N.O., Simpa P., Obasi S.C. Enhancing manufacturing productivity: A review of AI-Driven supply chain management optimization and ERP systems integration. *International Journal of Modern Engineering Research*. 2024;6(5). DOI: 10.51594/ijmer.v6i5.1126

15. Tulli S.K.C. Comparative Analysis of Traditional and AI-based Demand Forecasting Models. *International Journal of Emerging Trends in Science and Technology*. 2020;07(03). 6842–6847. DOI: 10.18535/ijetst/v7i6.02

16. Szostek K., Mazur D., Drałus G., Kuszniar J. Analysis of the Effectiveness of ARIMA, SARIMA, and SVR Models in Time Series Forecasting: A Case Study of Wind Farm Energy Production. *Energies*. 2024;17(19):4803. DOI: 10.3390/en17194803

Информация об авторах

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

Гилёв Денис Викторович, канд. техн. наук, доц. кафедры экономики, Уральский федеральный университет, Екатеринбург, Россия; denis.gilev@urfu.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.

Denis V. Gilev, Cand. Sci. (Eng.), Ass. Prof. of the Department of Economics, Ural Federal University, Ekaterinburg, Russia; denis.gilev@urfu.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 23.06.2025

The article was submitted 23.06.2025