

М.В. Раскатова, Е.Е. Терелецкова, А.А. Сало, Э.А. Чельшев

СРАВНИТЕЛЬНЫЙ АНАЛИЗ НЕЙРОСЕТЕВЫХ И АRIМА-МОДЕЛЕЙ
ДЛЯ ПРОГНОЗИРОВАНИЯ ВРЕМЕННЫХ РЯДОВ:
ОЦЕНКА ЭФФЕКТИВНОСТИ И ПРИМЕНИМОСТИ

Аннотация. В статье проводится сравнительный анализ нейросетевых и АRIМА-моделей для прогнозирования временных рядов. Оценивается их эффективность и применимость в различных сценариях прогнозирования. Нейросетевые модели, такие как многослойные перцептроны и сверточные нейронные сети, обладают высокой гибкостью и способностью улавливать сложные нелинейные взаимосвязи в данных. АRIМА-модели (авторегрессионные интегрированные скользящие средние) предназначены для прогнозирования стационарных временных рядов и часто используются для прогнозирования экономических и финансовых данных. В статье описаны теоретические понятия АRIМА-модели и нейросетевой модели, указаны виды нейросетевых моделей: перцептрон, многослойный перцептрон, рекуррентные нейронные сети, сверточные нейронные сети и глубокие нейронные сети. Также указаны иные модели прогнозирования: SARIMA и SARIMAX. Для сравнения этих двух моделей применена программа STATISTICA. Также в статье оценена точность двух моделей для различных сценариев прогнозирования с помощью ошибки MAPE.

Ключевые слова: нейронные сети, прогнозирование, прогнозирование временных рядов, АRIМА-модель, нейросетевая модель, ошибка MAPE.

M.V. Raskatova, E.E. Tereletsikova, A.A. Salo, E.A. Chelyshev

COMPARATIVE ANALYSIS OF NEURAL NETWORK
AND ARIMA MODELS FOR TIME SERIES FORECASTING: EVALUATION
OF EFFICIENCY AND APPLICABILITY

Abstract. This article provides a comparative analysis of neural network and ARIMA models for time series forecasting. Their effectiveness and applicability in various forecasting scenarios are assessed. Neural network models such as multilayer perceptrons and convolutional neural networks are highly flexible and capable of capturing complex nonlinear relationships in data. ARIMA (Autoregressive Integrated Moving Average) models are designed for forecasting stationary time series and are often used to forecast economic and financial data. The article describes the theoretical concepts of the ARIMA model and the neural network model, and indicates the types of neural network models: perceptron, multilayer perceptron, recurrent neural networks, convolutional neural networks and deep neural networks. Other forecasting models are also indicated: SARIMA and SARIMAX. To compare these two models, the STATISTICA program was used. Also, this paper evaluates the accuracy of two models for different forecasting scenarios using the MAPE error.

Keywords: neural networks, forecasting, time series forecasting, ARIMA model, neural network model, MAPE error.

Введение

Прогнозирование временных рядов имеет решающее значение во многих областях, включая финансы, экономику и здравоохранение. Оно позволяет организациям и исследователям делать обоснованные прогнозы на основе исторических данных. Существует

Раскатова Марина Викторовна

кандидат технических наук, доцент кафедры информационных технологий и естественно-научных дисциплин, Национальный исследовательский университет «МЭИ», Москва. Сфера научных интересов: нейронные сети, вычислительная техника, прогнозирование временных рядов, сравнительный анализ моделей прогнозирования. Автор более 100 опубликованных научных работ. ORCID: 0000-0001-7671-3312, SPIN-код: 8053-5041, AuthorID: 609945.

Электронный адрес: RaskatovaMV@mpei.ru

Терелецкова Есения Евгеньевна

студент, Национальный исследовательский университет «МЭИ», Москва. Сфера научных интересов: цифровое общество, экономическое моделирование, нейронные сети, методы прогнозирования. Автор пяти опубликованных научных работ. ORCID:0009-0003-6409-3939.

Электронный адрес: esenia2018.t@gmail.com

Сало Анна Андреевна

студент, Национальный исследовательский университет «МЭИ», Москва. Сфера научных интересов: нейросетевое прогнозирование, эконометрические модели, Python. Автор одной опубликованной научной работы. ORCID: 0009-0009-2640-8614.

Электронный адрес: anyasalo@yandex.ru

Чельшев Эдуард Артурович

аспирант, Национальный исследовательский университет «МЭИ», Москва. Сфера научных интересов: машинное обучение по прецедентам, искусственные нейронные сети, машинная обработка текстов на естественном языке, C++. Автор более 20 опубликованных научных работ. ORCID: 0000-0001-8417-8823, SPIN-код: 5357-7604, AuthorID: 1088395.

Электронный адрес: chel.ed@yandex.ru

множество различных методов прогнозирования временных рядов, каждый со своими преимуществами и недостатками. В статье сравнивается точность прогнозов двух моделей на основе ряда метрик, включая среднюю абсолютную ошибку.

ARIMA-модели

ARIMA – интегрированная модель и методология анализа временных рядов. Для прогнозирования временных рядов ARIMA использует интегрированную модель авторегрессии – скользящего среднего. Есть три различных числа (p , d , q), которые используются для параметризации моделей в ARIMA. В связи с этим модели ARIMA обозначаются символом ARIMA (p , d , q). Вместе эти параметры подсчитывают сезонность, тенденцию и шум в наборах данных:

p – это авторегрессионная модель. Модель временных рядов, в которой значения временного ряда в данный момент линейно зависят от предыдущих значений этого же ряда;

d – интегрированная часть модели;

q – скользящая средняя модели. Именно она позволяет установить погрешность модели как линейную комбинацию значений ошибок, которые произошли в прошлом.

Для сезонного прогнозирования временных рядов можно предложить удачный вариант модели ARIMA – сезонный вариант SARIMA или SARIMAX. В этой модели сезонная дифференциация соответствующего порядка используется для удаления нестационарности из ряда [1; 2].

Нейросетевые модели

Функция искусственной нейронной сети состоит в том, чтобы отобразить множество входов на множество выходов. В начальный период на некотором множестве пар «вход – выход» происходит обучение нейросети. В основе нейросети лежит искусственный нейрон.

На Рисунке 1 представлена схема произвольной искусственной нейронной сети.

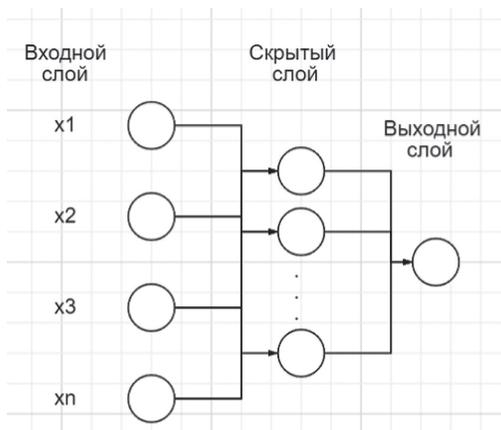


Рисунок 1. Схема ИНС

Источник: здесь и далее схемы, рисунки и графики составлены авторами.

Л.Г. Комарцова и А.В. Максимов подчеркивают, что «искусственный нейрон – это узел искусственной нейронной сети, являющийся упрощенной моделью естественного нейрона» [3, с. 40].

Существуют следующие типы нейронных сетей.

1. «Перцептрон – первая модель обучения с учителем. Обучение перцептрона требует наличие учителя и состоит в таком подборе весов w_{ij} , чтобы выходной сигнал i_j был наиболее близок к заданному значению d_i . При таком способе обучения каждой обучающей выборке, представленной вектором x , поставлено в соответствии ожидаемое значение d_i на выходе i -го нейрона» [4, с. 11].

2. «Многослойные перцептроны (MLP) – это нейронная сеть, состоящая из входного, выходного и расположенных между ними одного (или нескольких) скрытых слоев нейронов» [5, с. 25].

3. «Рекуррентные нейронные сети (RNN) являются наиболее подходящими для анализа последовательных данных, таких как язык. В рекуррентных нейронных сетях невозможно выделить отдельные слои. Сигналы могут циркулировать по сети во всех направлениях, образуя сложную пространственно-временную структуру (pattern)» [6, с. 61].

4. «Сверточные нейронные сети (CNN) являются одной из форм многослойных нейронных сетей. Первая часть состоит из слоев свертки и максимального пула, которые выступают в качестве экстрактора признаков. Вторая часть состоит из полносвязного слоя, который выполняет нелинейные преобразования извлеченных признаков и действует как классификатор» [7, с. 10].

5. «Глубокие нейронные сети (DNN) – сети с большим числом слоев для автоматического извлечения признаков из сложных данных» [8].

*Прогнозирование временных рядов с трендом
при помощи ARIMA-модели и нейросетевой модели*

Для проведения сравнения ARIMA-модели и нейросетевой модели в данном исследовании использовалась программа STATISTICA. Экспериментальные данные, касающиеся количества продаж малого бизнеса, были занесены в программу STATISTICA с целью прогнозирования будущего количества продаж. Количество данных составило: 55 значений для обучающей выборки и 10 значений для тестовой выборки. Для этой цели был построен линейный график данных (см. Рисунок 2), демонстрирующий предполагаемое наличие тренда и нестационарность ряда.



Рисунок 2. Линейный график временного ряда

Для подтверждения этого предположения был использован тест Дики – Фуллера [9], выполненный при помощи языка программирования PYTHON, результаты которого показали, что ряд является нестационарным. Для достижения стационарности временного ряда было проведено интегрирование.

На Рисунке 3 можно увидеть продифференцированный линейный график временного ряда.

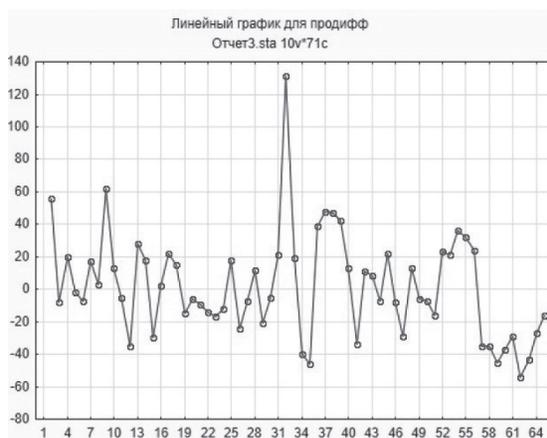


Рисунок 3. Продифференцированный линейный график временного ряда

Затем была построена автокорреляционная функция (далее – АКФ) [10] и частичная автокорреляционная функция (далее – ЧАКФ), на основе которых были определены параметры ARIMA-модели: $p = 1, d = 1, q = 1$ [11].

После подбора параметров был построен прогноз по всей модели (см. Рисунок 4) и проведен анализ ее адекватности с использованием трех методов: визуального анализа, оценки гистограммы остатков и расчета средней абсолютной ошибки MAPE, задаваемой формулой

$$MAPE = abs \frac{(v_1 - v_2)}{v_1} \cdot 100 \%,$$

где v_1 – фактические данные; v_2 – прогнозируемые данные.

Гистограмма остатков показала нормальное распределение, ошибка MAPE составила 3,112 %, что свидетельствует о том, что модель адекватна.

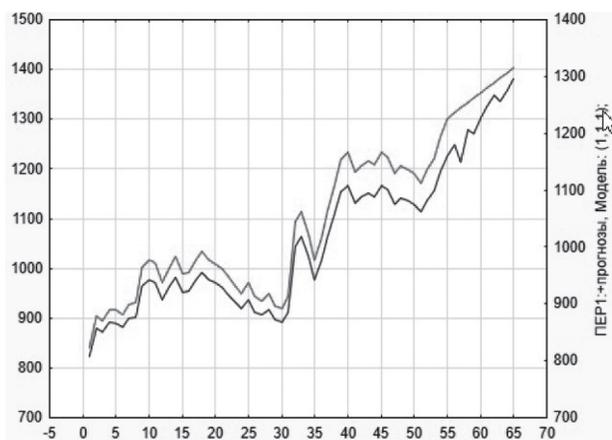


Рисунок 4. Прогноз по всей модели

После проверки модели на адекватность можно построить прогноз на тестовой выборке для 10 значений. Ошибка MAPE методом построения прогноза ARIMA-модели составила 2,554 % (см. Рисунок 5).

1		Маре
СРЕДНЕЕ набл.		2,553831
нач дан	прогноз	0
1249,000	1235,725	1,062857
1214,000	1244,257	2,492336
1279,000	1253,109	2,024326
1271,000	1261,914	0,714861
1303,000	1270,726	2,476885
1326,000	1279,537	3,503978
1349,000	1288,348	4,496037
1335,000	1297,160	2,834483
1357,000	1305,971	3,760439
1380,000	1314,782	4,725939

Рисунок 5. Ошибка MAPE методом построения прогноза ARIMA-модели

Сравнительный анализ нейросетевых и ARIMA-моделей для прогнозирования ...

Для создания прогноза временных рядов с использованием нейросетевой модели был задействован пакет «Автоматизированная нейронная сеть» в программе STATISTICA. При использовании тех же данных (55 для обучающей выборки и 10 для тестовой) было построено 5 нейросетевых моделей: MLP 12-4-1, MLP 12-4-1, MLP 12-2-1, MLP 12-3-1, MLP 12-4-1, указанных на Рисунке 6.

Сеть ID	Архитектура	Производ...	Контр. п...	Тест. произ...	Алгоритм	Функ. о...	Акт. скры...	Акт. вык...
1	MLP 12-4-1	0,913565	0,848776	---	BFGS 12	Сум. ква...	Логистиче...	Тождест...
2	MLP 12-4-1	0,911373	0,847955	---	BFGS 9	Сум. ква...	Гиперболи...	Тождест...
3	MLP 12-2-1	0,904971	0,855574	---	BFGS 9	Сум. ква...	Гиперболи...	Тождест...
4	MLP 12-3-1	0,947144	0,880969	---	BFGS 72	Сум. ква...	Гиперболи...	Тождест...
5	MLP 12-4-1	0,912483	0,852382	---	BFGS 11	Сум. ква...	Логистиче...	Тождест...

Рисунок 6. Построенные сети

Для оценки качества этих моделей были проанализированы гистограммы остатков и проведено сравнение их прогнозов для временного ряда (см. Рисунок 7). Анализ гистограмм остатков важен для определения соответствия модели предположениям о нормальности распределения остатков. Сравнение гистограмм помогает выявить различия в точности прогнозов, а также возможные проблемы в моделях.

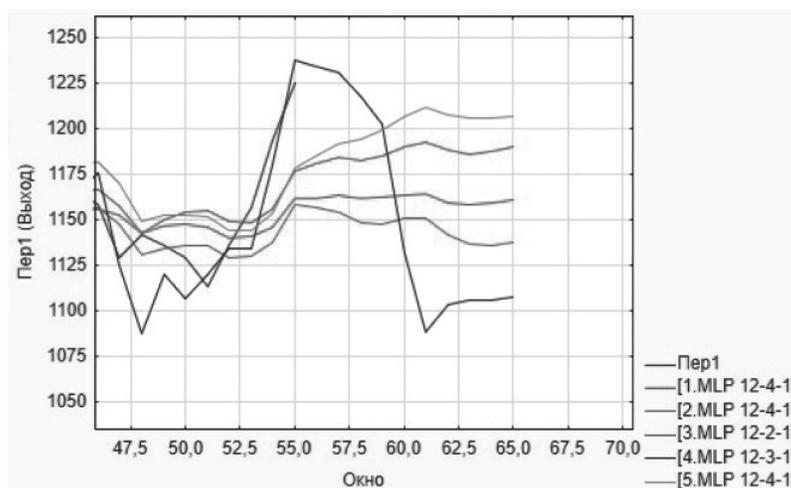


Рисунок 7. Прогноз исходного ряда пятью нейросетевыми моделями

После анализа гистограмм и прогноза моделей была выявлена наиболее подходящая нейросетевая модель (MLP 12-3-1), с помощью которой была оценена ошибка MAPE для тестовой выборки – она составила 10,76 % (см. Рисунок 8).

		1
		таpe
СРЕДНЕЕ набл.		10,769
1193	прогноз	
1225	1237,741	1,040069
1249	1234,440	1,166
1214	1230,544	1,363
1279	1217,412	4,815
1271	1202,472	5,392
1303	1131,507	13,161
1326	1088,305	17,926
1349	1103,035	18,233
1335	1106,289	17,132
1357	1105,799	18,511
1380	1107,859	19,720

Рисунок 8. Ошибка MAPE для тестовой выборки

*Прогнозирование временных рядов с факторами
при помощи ARIMA-модели и нейросетевой модели*

Медведева Н.И. утверждает, что «факторы – это те процессы, которые существенным образом могут повлиять на дальнейшее развитие событий и их конечный результат, поэтому они должны учитываться в прогнозах.

При разработке прогнозов важно обозначить, какие факторы признаются неизменными в будущем, а какие изменяются и включаются в варианты прогноза» [12, с. 405].

Для прогнозирования количества продаж можно взять те же данные со следующими факторами: «количество рабочих дней», «приток новых клиентов», «затраты на рекламу». Эти факторы являются изменяемыми.

ARIMA-модель не включает в себя учет влияющих факторов на конечную переменную. Она применяется для анализа и прогнозирования временных рядов и фокусируется на авторегрессии, интеграции и скользящем среднем значении [13]. Поэтому в исследовании не учитываются факторы, описанные ранее. Так, ошибка MAPE составила 2,554 % (как и в прогнозировании временных рядов с трендом).

В прогнозировании нейросетевым пакетом использовались упомянутые ранее факторы, которые представлены на Рисунке 9.

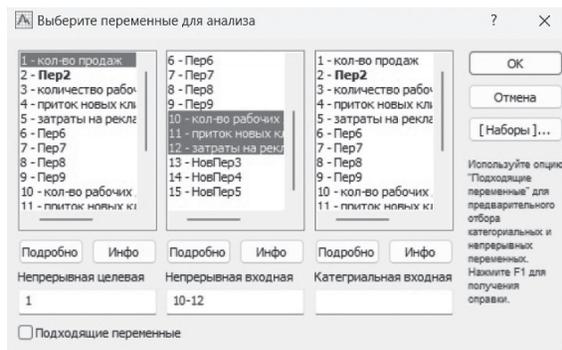


Рисунок 9. Факторы, используемые при прогнозировании

Воспользовавшись методом многократных подвыборок, было построено n количество нейросетевых моделей. После обучения этих сетей было выявлено, что три из них имеют

Сравнительный анализ нейросетевых и ARIMA-моделей для прогнозирования ...

самый лучший результат: контрольная производительность и тестовая производительность близки к 1. На Рисунке 10 показаны выявленные три модели: MLP 36–30–1, MLP 36–20–1, MLP 36–10–1.

Сеть ID	Архитектура	Производ...	Контр. п...	Тест. произ...	Алгоритм	Функ. о...	Акт. скрв...	Акт. вык...
5	MLP 36-30-1	0.967822	0.886630	0.966288	BFGS 25	Сум. ква...	Гиперболическая	Тождест...
10	MLP 36-20-1	0.963813	0.869346	0.964605	BFGS 20	Сум. ква...	Гиперболическая	Тождест...
15	MLP 36-10-1	0.968108	0.886988	0.963939	BFGS 25	Сум. ква...	Гиперболическая	Тождест...

Рисунок 10. Наиболее подходящие модели по контрольной и тестовой производительности

Проанализировав гистограмму остатков, ошибку MAPE и прогнозирование исходного временного ряда, можно сделать вывод, что модель MLP 36–30–1 считается наиболее подходящей.

Модель MLP 36–30–1 на проекции исходного ряда можно увидеть на Рисунке 11.

Ошибка MAPE этой модели составила 1,374 %, что представлено на Рисунке 12.

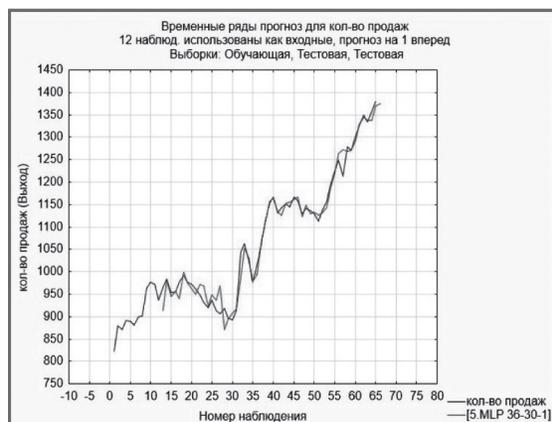


Рисунок 11. Модель MLP 36–30–1 на проекции исходного временного ряда

	1
	Mape
СРЕДНЕЕ набл.	1,3743

Рисунок 12. Ошибка MAPE для модели MLP 36–30–1

Заключение

Таким образом, в результате исследования можно сделать вывод, что ARIMA-модель лучше всего подходит для данных, которые являются стационарными либо имеют тренд. Также ARIMA-модели хорошо работают с данными, которые имеют сезонность, например, ежедневными или ежемесячными данными.

Нейросетевые модели лучше всего подходят для данных, которые являются нестационарными, имеют сложную зависимость между переменными, имеют факторы, влияющие

на прогноз. Они также хорошо работают с данными, которые имеют высокую размерность или содержат пропуски или выбросы.

Этот вывод может быть полезен при выборе метода прогнозирования исходя из специфики данных и задачи исследования.

Также в качестве итога можно отметить, что вместо использования ARIMA-моделей при прогнозировании данных, имеющих факторы или сезонность, лучше использовать модель SARIMA или SARIMAX.

Литература

1. Горяев В.М., Бембитов Д.Б., Мучкаев Д.Н., Аль-Килани В.Х. Модель SARIMA и статистика скользящего окна для локальных метеоданных // Современные наукоемкие технологии. 2019. № 6. С. 31–38. EDN IBKFMX.
2. Минасян Д.Г. Моделирование банковской стабильности Армении с помощью ARIMA // Регион и мир. 2023. Т. 14. № 4 (47). С. 108–114. EDN WEAOGF.
3. Комарцова Л.Г., Максимов А.В. Нейрокомпьютеры: учеб. пособие. 2-е изд. М.: Изд-во МГТУ им. Н.Э. Баумана, 2004. 400 с. ISBN 5-7038-2554-7.
4. Солдатова О.П. Нейроинформатика: учеб. пособие. Самара: Изд-во СГАУ им. С.П. Королева, 2013. 130 с.
5. Гафаров Ф.М., Галимянов А.Ф. Искусственные нейронные сети и их приложения: учеб. пособие. Казань : Изд-во Казанского университета, 2018. 120 с.
6. Вакуленко С.А., Жихарева А.А. Практический курс по нейронным сетям : учеб. пособие. СПб.: Университет ИТМО, 2018. 71 с.
7. Маршалко Д. А., Кубанских О. В. Архитектура свёрточных нейронных сетей // Ученые записки брянского государственного университета. 2019. № 4 (16). С. 10–13. EDN: HOCSSF
8. Лемпицкий В. Глубокие нейронные сети: пути применения // ПостНаука. Дата публикации: 19.01.2021. URL: <https://postnauka.org/longreads/155983> (дата обращения: 19.03.2024).
9. Гребенюк Е.А., Малинкина А.В. Применение методов эконометрического анализа данных для идентификации и датирования «пузырей» на финансовых рынках // Проблемы управления. 2014. № 5. С. 50–58. EDN SULSDJ.
10. Светульников С.Г., Мацкевич В.В., Шайхлеева Н.И. Комплексная автокорреляционная функция в моделировании сложных экономических процессов // Неделя науки СПбПУ : материалы научной конференции с международным участием, 18–23 ноября 2019 г. Институт промышленного менеджмента, экономики и торговли. В 3 ч. Ч. 1. Высшая школа управления и бизнеса. СПб.: Санкт-Петербургский политехнический университет Петра Великого, 2019. С. 128–131. EDN YXUVTE.
11. Пилюгина А.В., Бойко А.А. Определение оптимальных параметров модели экспоненциального сглаживания временного ряда для прогнозирования валютного курса // Прикаспийский журнал: управление и высокие технологии. 2016. № 1. С. 114–127. EDN VWXXHEB.
12. Медведева Н.И. Факторы, влияющие на уровень вероятности в реализации прогнозов социально-экономического развития // Эпоха науки. 2019. № 20. С. 404–405. EDN YSKPUN. DOI: 10.24411/2409-3203-2019-12080
13. Трофимов П.Ю., Носков В.Ю. Прогнозирование временных рядов методом ARIMA // Теплотехника и информатика в образовании, науке и производстве : Сборник докладов VI Всероссийской научно-практической конференции студентов, аспирантов и молодых учёных (ТИМ'2017) с международным участием, Екатеринбург, 11–12 мая 2017 года. Екатеринбург: Уральский федеральный университет имени первого Президента России Б.Н. Ельцина, 2017. С. 260–262. EDN ZSQKTВ.

References

1. Goryaev V.M., Bembitov D.B., Muchkaev D.N., Al'-Kilani V.Kh. (2019) SARIMA model and moving window statistics for local weather data. *Modern High Technologies*. No. 6. Pp. 31–38. (In Russian).
2. Minasyan D.G. (2023) Modelling Banking Stability of Armenia Using ARIMA Model. *Region and the World*. Vol. 14. No. 4 (47). Pp. 108–114. (In Russian).
3. Komartsova L.G. Maksimov A.V. (2004) *Neyrokomp'yutery* [Neurocomputers] : Training Manual. 2nd edition. Moscow : Bauman MSTU Publ. 400 p. ISBN 5-7038-2554-7. (In Russian).
4. Soldatova O.P. (2013) *Neyroinformatika* [Neuroinformatics] : Training Manual. Samara : Samara State Aerospace University Publ. 130 p. (In Russian).
5. Gafarov F.M., Galimyanov A.F. (2018) *Iskusstvennyye neyronnyye seti i ikh prilozheniya* [Artificial neural networks and their applications]: Training Manual. Kazan : Kazan University Publ. 120 p. (In Russian).
6. Vakulenko S.A., Zhikhareva A.A. (2018) *Prakticheskiy kurs po neyronnym setyam* [Practical course on neural networks] : Training Manual. St. Petersburg : Saint Petersburg State University of Information Technologies, Mechanics and Optics Publ. 71 p. (In Russian).
7. Marshalko D. A., Kubanskikh O. V. (2019) Architecture of Convolutional Neural Networks. *Journal of Scientific notes of Bryansk State University*. No. 4 (16). Pp. 10–13. (In Russian).
8. Lempitsky V. (2021) Applications of Deep Neural Networks. *PostNauka*. 19 January. URL: <https://postnauka.org/longreads/155983> (accessed 19.03.2024). (In Russian).
9. Grebenyuk E.A., Malinkina A.V. (2014) Application of methods of econometric data analysis for identifying and dating “bubbles” in financial markets. *Problemy upravleniya*. No. 5. Pp. 50–58. (In Russian).
10. Svetunkov S.G., Matskevich V.V., Shaykhleeva N.I. (2019) Complex autocorrelation function in modeling complex economic processes. In: *Nedelya nauki SPbPU* [St. Petersburg Polytechnic University's Science Week] : Proceedings of the Scientific Conference with International Participation. St. Petersburg, 18–23 November 2019, St. Petersburg : Peter the Great St. Petersburg Polytechnic University Publ. Pp. 128–131. (In Russian).
11. Pilyugina A.V., Boyko A.A. (2016) Determining the optimal parameters of an exponential smoothing model for a time series for forecasting the exchange rate. *The Caspian Journal: Management and High Technologies*. No. 1. Pp. 114–127. (In Russian).
12. Medvedeva N.I. (2019) Factors influencing the level of probability in the implementation of socio-economic development forecasts. *Era of Science*. No. 20. Pp. 404–405. DOI: 10.24411/2409-3203-2019-12080 (In Russian).
13. Trofimov P.Y., Noskov V.Y. (2017) Forecasting time series using the ARIMA method. In: *Teplotekhnika i informatika v obrazovanii, nauke i proizvodstve* [Heat Engineering and Informatics in Education, Science and Production] : Collection of reports of the VI All-Russian scientific and practical conference of students, postgraduate students and young scientists (TM'2017) with international participation. Ekaterinburg, 11–12 May, 2017. Ekaterinburg : Ural Federal University named after the first President of Russia B.N. Yeltsin, Pp. 260-262. (In Russian).