

РЕГИОНАЛЬНАЯ И ОТРАСЛЕВАЯ ЭКОНОМИКА /
REGIONAL AND SECTORAL ECONOMY<https://doi.org/10.15507/2413-1407.26343.498-518>EDN: <https://elibrary.ru/jxusgz>

УДК / UDC 33:004.032.26:353

<http://regionsar.ru>

ISSN 2413-1407 (Print)

ISSN 2587-8549 (Online)

Оригинальная статья / Original article

**Применение нейросетевых методов и моделей
при анализе краткосрочной экономической
динамики регионального развития****В. С. Брезгин**

*Институт природных ресурсов, экологии и криологии
Сибирского отделения Российской академии наук, <https://ror.org/00mj88198>
(г. Чита, Российская Федерация)
monmanage@bk.ru*

Аннотация

Введение. В условиях структурных шоков традиционные эконометрические методы теряют эффективность при прогнозировании региональной экономики, особенно при работе с короткими временными рядами. Цель исследования – разработка методологии анализа и краткосрочного прогнозирования территориальной динамики на основе нейросетевого моделирования, адаптированного к специфике региональной статистики.

Материалы и методы. Эмпирическую базу составили годовые данные Росстата по Забайкальскому краю за 2003–2022 гг., репрезентативные для ресурсных территорий РФ. Применены рекуррентные нейронные сети с LSTM-архитектурой. Авторский подход включает оценку системной значимости показателей через композитный индекс и сравнение стратегий формирования обучающей выборки (скользящего и расширяющегося окон).

Результаты исследования. Выявлена дифференцированная эффективность методов прогнозирования для различных типов показателей. Метод расширяющегося окна показал высокую точность для показателей с устойчивыми трендами (ошибка прогноза валового регионального продукта около 0,3 % в 2020–2021 гг.), тогда как метод скользящего окна оказался эффективнее для волатильных показателей. Разработанный инструментальный анализ системной значимости параметров выявил устойчивую кластерную структуру региональной экономики, включающую производственно-инвестиционный и социально-демографический кластеры. Верификация моделей подтвердила их устойчивость к типичным флуктуациям, однако продемонстрировала фундаментальные ограничения при беспрецедентных геополитических шоках 2022 г.

Заключение. Практическая значимость исследования заключается в создании комплексного инструментария для повышения эффективности регионального экономического планирования и прогнозирования в условиях структурных изменений. Материал может быть востребован в деятельности органов регионального управления и стратегического планирования.

© Брезгин В. С., 2026



Контент доступен под лицензией Creative Commons Attribution 4.0 License.
This work is licensed under a Creative Commons Attribution 4.0 License.



Ключевые слова: региональная экономика, экономическое прогнозирование, нейронные сети, LSTM-модели, короткие временные ряды, структурные сдвиги, системная значимость, Забайкальский край

Конфликт интересов. Автор заявляет об отсутствии конфликта интересов.

Финансирование. Работа выполнена в рамках государственного задания Института природных ресурсов, экологии и криологии Сибирского отделения Российской академии наук, проект «Адаптация региональных социо-эколого-экономических систем приграничных территорий Востока РФ к геополитическим и климатическим рискам: стратегические подходы и механизмы» (№ 126020216343-0).

Для цитирования: Брезгин В.С. Применение нейросетевых методов и моделей при анализе краткосрочной экономической динамики регионального развития. *Регионоведение*. 2026;34(3):498–518. <https://doi.org/10.15507/2413-1407.26343.498-518>

Application of Neural Network Methods and Models in the Analysis of Short-Term Economic Dynamics of Regional Development

V. S. Brezgin

*Institute of Natural Resources, Ecology and Cryology
of the Siberian Branch of the Russian Academy of Sciences, <https://ror.org/00mj88198>
(Chita, Russian Federation)
monmanage@bk.ru*

Abstract

Introduction. In the face of structural shocks, traditional econometric methods lose their effectiveness in forecasting regional economies, especially when working with short time series. The objective of this study is to develop a methodology for analyzing and forecasting short-term regional dynamics based on neural network modeling, adapted to the specifics of regional statistics.

Materials and Methods. The empirical base consisted of annual Rosstat data for the Trans-Baikal Territory for 2003–2022, representative of resource-rich territories of the Russian Federation. Recurrent neural networks with LSTM architecture were used. The author's approach includes assessing the systemic significance of indicators using a composite index and comparing training sample generation strategies (sliding and expanding windows).

Results. The differential effectiveness of forecasting methods for different types of indicators was revealed. The expanding window method demonstrated high accuracy for indicators with stable trends (gross regional product forecast error of approximately 0.3 % in 2020–2021), while the sliding window method was more effective for volatile indicators. The developed toolkit for analyzing the systemic significance of indicators revealed a stable cluster structure of the regional economy, including production-investment and socio-demographic clusters. Verification of the models confirmed their resilience to typical fluctuations but demonstrated fundamental limitations under the unprecedented geopolitical shocks of 2022.

Conclusion. The practical significance of this study lies in the development of a comprehensive toolkit for improving the effectiveness of regional economic planning and forecasting in the face of structural change. The material may be useful in the activities of regional government and strategic planning bodies.

Keywords: regional economy, economic forecasting, neural networks, LSTM-models, short time series, structural shifts, systemic significance, Trans-Baikal Territory

Conflict of interest. The author declares no conflict of interest.

Funding. The work was carried out within the framework of the state assignment of the Institute of Natural Resources, Ecology and Cryology of the Siberian Branch of the Russian Academy of Sciences, project “Adaptation of Regional socio-ecological-economic systems of the border territories of the Russian East to geopolitical and climatic risks: Strategic approaches and mechanisms” (no. 126020216343-0).

For citation: Brezgin V.S. Application of Neural Network Methods and Models in the Analysis of Short-Term Economic Dynamics of Regional Development. *Russian Journal of Regional Studies*. 2026;34(3):498–518. <https://doi.org/10.15507/2413-1407.26343.498-518>

ВВЕДЕНИЕ

В современных условиях возрастающей неопределенности экономического развития регионов актуальность приобретают разработка и применение эффективных методов прогнозирования экономической динамики¹ [1]. Качество краткосрочных прогнозов главных показателей регионального развития определяет обоснованность управленческих решений в сфере бюджетного планирования, социальной политики и стратегического управления территорией: систематические ошибки ведут к искажению в оценке доходной базы бюджетов, потребности в социальной инфраструктуре и мерах поддержки экономики. Необходимость совершенствовать инструментарий прогнозирования обусловлена как усложнением характера экономических процессов, так и увеличением скорости структурных изменений в региональных экономических системах².

Характер и масштаб исследуемой проблемы определяются спецификой уровня анализа. Региональной статистике свойственны относительно короткие временные ряды преимущественно годовой частоты, периодическое изменение методик учета и высокая чувствительность к внешним шокам. За последние два десятилетия региональные экономические системы России пережили несколько масштабных структурных сдвигов: кризисы 2008–2009 и 2014–2015 гг., пандемию COVID-19, геополитические трансформации 2022 г., каждый из которых существенно менял качество экономической динамики.

В этих условиях традиционные эконометрические методы не всегда демонстрируют достаточную эффективность, а методы машинного обучения, прежде всего рекуррентные нейронные сети с LSTM-архитектурой (*Long Short-Term Memory*), рассматриваются как перспективное дополнение. Вместе с тем применимость последних к коротким временным рядам региональной статистики и выбор оптимальной стратегии их обучения остаются недостаточно изученными.

Цель настоящего исследования – разработка на основе нейросетевых методов методологического подхода к анализу и прогнозированию региональной экономической динамики, обеспечивающего повышение точности прогнозов в условиях ограниченности исходных данных, структурных изменений в экономике и открытости самой системы.

Центральный исследовательский вопрос работы состоит в следующем: способны ли нейросетевые модели на основе LSTM-архитектуры обеспечить достаточный уровень точности краткосрочного прогнозирования региональной экономической динамики в условиях коротких временных рядов и структурных изменений,

¹ Хиндман Р.Дж., Атанасопулос Г. Прогнозирование: принципы и практика. 3-е изд. OTexts; 2021. URL: <https://otexts.com/fpp3> (дата обращения: 19.02.2025).

² Леманн Р., Вольрабе К. Прогнозирование региональной экономики: современная методология и будущие вызовы. *Economics and Business Letters*. 2014;3(4):218–231. URL: https://econpapers.repec.org/article/ovejourn/aid_3a10416.htm (дата обращения: 19.02.2025); Мокроносов А.Г., Вершинин А.А., Прудников Д.М. Прогнозирование обеспечения региональной экономики квалифицированными кадрами. *Известия Уральского государственного экономического университета*. 2012;(6):108–114. <https://www.elibrary.ru/pxlxhz>



и если да, какие стратегии формирования обучающей выборки эффективны для различных типов региональных показателей?

Научная новизна исследования заключается в разработке комплексного методологического подхода, интегрировавшего методы машинного обучения и классического статистического анализа для оценки системной роли экономических показателей и прогнозирования их динамики. Предложен метод оценки системной значимости показателей, основанный на сочетании прогностических характеристик и структурного анализа экономических взаимосвязей.

ОБЗОР ЛИТЕРАТУРЫ

Современное состояние методологии регионального экономического прогнозирования и стоящие перед ней вызовы систематизированы Р. Леманном и К. Вольрабе³. Значительная часть исследований в данной области выполнена в рамках классического эконометрического подхода⁴, включавшего линейную и множественную регрессии, модели ARIMA, методы экспоненциального сглаживания и VAR-модели. Накопленный опыт их применения выявил ряд существенных ограничений.

Традиционные эконометрические методы демонстрируют недостаточную эффективность при анализе нелинейных экономических процессов и сложных взаимозависимостей между различными показателями регионального развития⁵ [2]. Классические линейные модели часто не способны адекватно отражать динамическую структуру региональных экономических систем, особенно в условиях структурных сдвигов⁶. Наиболее остро данная проблема проявляется при работе с короткими временными рядами, характерными для региональной статистики.

Кроме того, классическим методам в ряде случаев не свойственна необходимая адаптивность к структурным изменениям в экономике, что снижает их практическую ценность в условиях возрастающей нестабильности⁷. Эмпирические данные свидетельствуют о системных проблемах: экономисты не смогли предсказать 148 из последних 150 рецессий, что указывает на фундаментальные ограничения классических методов прогнозирования⁸.

Альтернативное направление исследований связано с применением методов машинного обучения, в частности глубокого обучения, к задачам прогнозирования временных рядов. Систематический обзор данного направления представлен в работе Б. Лима и С. Зорена [3].

³ Леманн Р., Вольрабе К. Указ. соч.

⁴ Аллен П.Г. Эконометрическое прогнозирование. В кн.: Принципы прогнозирования. Под ред. Дж.С. Армстронга. Kluwer Academic Publishers; 2001. С. 303–362. URL: https://archive.org/details/isbn_9780792379300/page/n9/mode/2up (дата обращения: 19.02.2025).

⁵ Kavkler A., Mikek P., Böhm B., Boršič D. Nonlinear Econometric Models: The Smooth Transition Regression Approach. 2008. Available at: <https://clck.ru/3VJBYSR> (accessed 19.02.2025).

⁶ Кузнецов Ю.А., Перова В.И., Эйвазова Э.Н. Нейросетевое моделирование динамики инновационного развития регионов Российской Федерации. *Региональная экономика: теория и практика*. 2014;(4):18–28. URL: <https://clck.ru/3VDxyi> (дата обращения: 19.02.2025).

⁷ Песаран М.Х., Тиммерманн А. Выбор окна оценки в присутствии структурных сдвигов. *Journal of Econometrics*. 2007;137(1):134–161. URL: <https://clck.ru/3VDy9n> (дата обращения: 19.02.2025).

⁸ Лунгани П. Насколько точны прогнозы частного сектора? Межстрановые данные на основе консенсус-прогнозов роста производства. *International Journal of Forecasting*. 2001;17(3):419–432. URL: <https://www.sciencedirect.com/science/article/pii/S016920700100098X> (дата обращения: 19.02.2025).

Особую роль в анализе экономической динамики играют рекуррентные нейронные сети с LSTM-архитектурой, способные эффективно обрабатывать временные последовательности данных и учитывать долгосрочные зависимости [4]. Сравнительные исследования демонстрируют, что LSTM-модели превосходят классические методы ARIMA на 84–87 % по снижению ошибок прогнозирования экономических временных рядов [5]. Положительные результаты получены в широком спектре прикладных задач: при наукастинге, прогнозировании валового внутреннего продукта (ВВП) [6; 7], инфляции, в том числе на российских данных [8], спроса [9], цен на нефть⁹, финансовых временных рядов [4].

Отдельное направление образуют работы, применяющие нейросетевые методы к анализу региональной экономики. В ряде исследований¹⁰ [10] нейросетевой инструментарий (самоорганизующиеся карты Кохонена) используется для кластеризации и типологизации регионов по характеристикам инновационного развития и инновационных экосистем; предложен методический подход к прогнозированию целевых параметров социально-экономического развития регионов с применением стандартного аппарата нейронных сетей [11]; выполнен сравнительный анализ регрессионных и нейросетевых моделей при прогнозировании развития региона [2]. Вместе с тем в указанных материалах не ставилась задача комплексной оценки системной роли отдельных показателей в региональной экономической системе на основе сочетания их прогнозируемости и структуры экономических взаимосвязей.

Применение нейросетевых методов к региональным данным сопряжено с рядом методологических вызовов [3]. Основные проблемы связаны с необходимостью адаптировать архитектуру нейронных сетей к специфике коротких временных рядов, разработкой эффективных процедур валидации моделей и обеспечением интерпретируемости полученных результатов¹¹. Дискуссионную область образует выбор стратегии формирования обучающей выборки. Классическая работа М. Х. Песарана и А. Тиммерманна¹² показала, что выбор окна оценивания в присутствии структурных сдвигов существенно влияет на качество прогнозов.

Современные исследования не дают однозначного ответа на вопрос о сравнительных преимуществах скользящего и расширяющегося окон. Так, показано, что ни одна из стратегий не обладает устойчивым превосходством, и предложен комбинированный подход, основанный на их переключении в зависимости от недавней прогностической результативности [12]. Установлено, что процедуры с переменной длиной окна имеют преимущество главным образом при смене характера прогнозируемого процесса, тогда как в стабильных условиях они сопоставимы с фиксированным окном [13]. Предложена методика выбора размера скользящего окна при изменяющихся во времени параметрах модели [14]. Однако применительно к коротким рядам годовой региональной статистики данный вопрос

⁹ Тимофеев А.Г., Лебединская О.Г. Модель применения сверточной нейронной сети (CNN) в сочетании с долговременной памятью (LSTM) прогнозирования цены на нефть в условиях неопределенности. *Транспортное дело России*. 2022;(2):54–59. <https://www.elibrary.ru/piqbdw>

¹⁰ Кузнецов Ю.А., Перова В.И., Эйвазова Э.Н. Указ. соч.

¹¹ Эльскен Т., Метцен Я.Х., Хуттер Ф. Поиск архитектуры нейронных сетей: обзор. *Journal of Machine Learning Research*. 2019;20(55):1–21. URL: <https://dl.acm.org/doi/abs/10.5555/3322706.3361996> (дата обращения: 19.02.2025).

¹² Песаран М.Х., Тиммерманн А. Указ. соч.



практически не исследован. Дополнительно ситуация осложняется тем, что увеличение размера окна обучения сокращает объем доступной обучающей выборки, критичный для коротких рядов.

Таким образом, анализ литературы позволяет зафиксировать следующие проблемы. Эффективность LSTM-моделей продемонстрирована преимущественно на длинных и высокочастотных временных рядах (финансовых рынках, макроэкономических показателях), тогда как их применимость к коротким рядам годовой региональной статистики изучена фрагментарно. Остается открытым вопрос о сравнительной эффективности методов расширяющегося и скользящего окна для различных типов региональных экономических показателей. Отсутствует комплексный инструментарий, объединяющий оценку прогнозируемости параметров и анализ структуры их экономических взаимосвязей для определения системной роли в региональной экономике.

Настоящее исследование направлено на восполнение указанных пробелов: разрабатывается и апробируется на данных конкретного региона методологический подход, сочетающий LSTM-прогнозирование с двумя стратегиями формирования обучающей выборки и композитную оценку системной значимости показателей.

МАТЕРИАЛЫ И МЕТОДЫ

Исходные данные и обоснование выборки. Исследование основано на открытых данных Федеральной службы государственной статистики РФ по Забайкальскому краю за 2003–2022 гг.¹³ Выбор региона обоснован его типичностью для ресурсных территорий России, а также полной доступностью статистической информации за анализируемый период.

Оптимальная структура анализируемых показателей сформирована на базе предварительного анализа региональной экономической системы и включает два основных блока:

1) ядро модели, базовые показатели, описывающие главные аспекты регионального развития: индекс физического объема валового регионального продукта (ВРП) как интегральный параметр экономического развития, индекс реальных располагаемых доходов населения как индикатор благосостояния, численность населения и уровень занятости как характеристики человеческого капитала, оборот оптовой торговли как метрика деловой активности;

2) отраслевые параметры, отражающие специфику экономической структуры региона: показатели добывающей промышленности, строительства, инвестиционной активности.

Выбор показателей основан на комплексном анализе их роли в региональной экономической системе и доступности статистической информации. Учитывались следующие критерии: системная значимость для характеристики регионального развития, наличие достаточного объема исторических данных, устойчивость методики расчета показателя во времени, возможность межрегиональных сопоставлений.

Такой подход обеспечил баланс между полнотой охвата различных аспектов регионального развития и практической реализуемостью анализа с учетом ограничений по доступности сведений.

¹³ Территориальный орган Федеральной службы государственной статистики по Забайкальскому краю : сайт. URL: <https://75.rosstat.gov.ru> (дата обращения: 19.02.2025).

Использовались индексы экономических показателей. Для упрощения восприятия применялись их сокращенные названия; соответствие официальным наименованиям Росстата приведено в таблице 1.

Таблица 1. Соответствие сокращенных и полных названий анализируемых показателей
Table 1. Correspondence of abbreviated and full names of the analyzed indicators

Сокращенное название / Abbreviated name	Полное название / Full name
Валовой региональный продукт / Gross regional product	Индекс физического объема валового регионального продукта / Gross regional product physical volume index
Горнодобывающая отрасль / Mining industry	Индекс производства по виду деятельности «Добыча полезных ископаемых» / Production index for mining and quarrying
Строительство / Construction	Объем работ по виду деятельности «Строительство» / Work volume for construction
Инвестиции / Investments	Индекс физического объема инвестиций в основной капитал / Fixed capital investment physical volume index
Оборот оптовой торговли / Wholesale trade turnover	Индекс физического объема оборота оптовой торговли / Wholesale trade turnover physical volume index
Безработица / Unemployment	Уровень безработицы / Unemployment rate
Уровень занятости / Employment rate	Уровень занятости / Employment rate
Реальные располагаемые доходы / Real disposable income	Реальные располагаемые доходы населения / Real disposable income of the population
Численность населения / Population	Численность постоянного населения / Residential population

Примечание: все показатели выражены в процентах к предыдущему году.

Note: all figures are expressed as percentages of the previous year.

Источник: здесь и далее использовались данные Территориального органа Федеральной службы государственной статистики по Забайкальскому краю.

Source: hereinafter in the article, data were obtained from the Territorial Body of the Federal State Statistics Service for the Trans-Baikal Territory.

Предварительная обработка и валидация данных. Для повышения устойчивости модели к выбросам и нормализации входных данных применен робастный скейлер (*RobustScaler*). Выбор данного метода масштабирования обусловлен его устойчивостью к аномальным значениям, что важно при работе с экономическими показателями, которые могут содержать существенные отклонения в периоды кризисов или структурных изменений в экономике. Робастный скейлер использует медиану и межквартильный размах (IQR) вместо среднего значения и стандартного отклонения: $x' = (x - \text{median}) / \text{IQR}$, что обеспечивает устойчивость к выбросам в экономических данных¹⁴.

Для обеспечения сопоставимости данных и корректности их анализа реализована процедура предварительной валидации входных показателей. Проверялась

¹⁴ Юн Т., Пак Ё., Рю Э.К., Ван Ю. Робастное вероятностное прогнозирование временных рядов. *Proceedings of the 25th International Conference on Artificial Intelligence and Statistics*. 2022;151. URL: <https://clck.ru/3VE6jk> (дата обращения: 19.02.2025) ; Хансен Л.П., Сарджент Т.Дж. Робастное управление и неопределенность модели. *American Economic Review*. 2001;91(2):60–66. <https://doi.org/10.1257/aer.91.2.60>



согласованность временных рядов, выявлялись и корректировались пропущенные значения, проводился анализ выбросов и структурных разрывов в данных. Особое внимание уделялось проверке методологической сопоставимости показателей во времени, что важно при работе с длинными временными рядами, охватывающими периоды изменений в методиках статистического учета.

Методология моделирования и архитектура модели. Методологическая база исследования основана на применении методов глубокого обучения для анализа временных рядов экономических показателей регионального развития [3; 7]. В качестве базовой выбраны рекуррентные нейронные сети с LSTM-архитектурой, что обусловлено их способностью эффективно обрабатывать последовательные данные и выявлять долгосрочные зависимости во временных рядах¹⁵.

Разработанная архитектура представляет собой многослойную LSTM-сеть с возможностью гибкой настройки структурных параметров. Базовая конфигурация включает от одного до пяти LSTM-слоев с варьируемым количеством нейронов (от 32 до 256) в каждом слое. Такой диапазон параметров позволяет адаптировать сложность модели к специфике конкретных экономических показателей и доступному объему данных.

Для предотвращения переобучения после каждого LSTM-слоя внедрен слой Dropout с коэффициентом 0,2, что обеспечивало регуляризацию модели путем случайного отключения части нейронов в процессе обучения. Выходной слой реализован как полносвязный с линейной функцией активации, что соответствует задаче регрессии временных рядов.

Применялся подход авторегрессии, где каждый показатель рассматривался как результирующая переменная, а в качестве предикторов использовались лагированные значения этого же показателя (временное окно в 4–8 наблюдений). Это позволило выявлять внутреннюю динамику каждого параметра и оценить его прогнозируемость на основе собственной истории развития.

Модель выполнена на языке Python с использованием современного стека технологий машинного обучения. Базовая архитектура нейронной сети реализована с применением фреймворка TensorFlow 2.x и высокоуровневого API Keras, что обеспечило необходимую гибкость в конфигурации модели и эффективность ее обучения. Предварительная обработка данных осуществлялась с привлечением библиотек scikit-learn и pandas, что позволило эффективно воспроизвести все необходимые процедуры масштабирования и валидации данных. Для оптимизации гиперпараметров модели была задействована библиотека scikit-optimize, в которой доступны современные методы байесовской оптимизации.

Обучение модели проводилось с использованием оптимизатора Adam, который хорошо зарекомендовал себя в задачах обучения глубоких нейронных сетей благодаря адаптивной настройке параметров обучения. В качестве функции потерь использовалась среднеквадратичная ошибка (MSE, *Mean Squared Error*), что соответствовало задаче регрессии временных рядов. Для предотвращения переобучения применялся механизм ранней остановки обучения, который прекращал процесс при отсутствии улучшения на валидационной выборке в течение 10 эпох. Так был

¹⁵ Тимофеев А.Г., Лебединская О.Г. Указ. соч.

найден оптимальный момент остановки обучения и удалось избежать излишней подгонки модели под обучающие данные.

Методы прогнозирования временных рядов. В рамках исследования разработан комплексный подход к прогнозированию региональной экономической динамики, сочетающий классические методы анализа с современными технологиями машинного обучения и оптимизации¹⁶. Центральный элемент методологии – применение двух взаимодополняющих подходов: методов скользящего и расширяющегося окна [12–14], преимущества и ограничения которых определили их эффективность для различных типов экономических показателей.

Метод скользящего окна использует фиксированное количество наблюдений для формирования прогноза и последовательно сдвигается по временной оси. Размер окна определялся экспериментально и варьировался от 4 до 8 наблюдений в зависимости от качества анализируемого показателя. Данный метод продемонстрировал наибольшую эффективность при работе с показателями, которым свойственны выраженная краткосрочная динамика и высокая чувствительность к текущим экономическим условиям; способен быстро адаптироваться к изменениям в характере экономических процессов, что важно при анализе волатильных показателей.

Метод расширяющегося окна, напротив, начинает анализ с минимального набора данных (6–8 наблюдений) и последовательно увеличивает временной интервал по мере поступления новых сведений. Такой подход позволяет более эффективно учитывать долгосрочные тренды и структурные особенности временных рядов. Метод показал наилучшие результаты при прогнозировании показателей с устойчивой долгосрочной динамикой, таких как демографические характеристики и базовые экономические индикаторы.

Оптимизация и обучение модели. Для повышения надежности прогнозов задействован механизм автоматической валидации качества моделей с использованием пороговых значений коэффициента детерминации (R^2) [6]. При недостижении заданного порога качества (по умолчанию $R^2 > 0,7$) система автоматически инициировала процесс переобучения модели. Количество попыток переобучения ограничивалось настраиваемым параметром, который по умолчанию устанавливался на уровне трех итераций. Это позволило найти оптимальную конфигурацию модели без избыточных вычислительных затрат.

Значимым элементом методологии является система оптимизации гиперпараметров LSTM-модели, основанная на байесовском поиске¹⁷. Байесовская оптимизация дает возможность эффективно исследовать пространство параметров, концентрируясь на наиболее перспективных областях. В рамках оптимизации рассматривались количество нейронов (32–256), слоев (1–5) и эпох обучения (50–200), скорость обучения (10^4 – 10^{-2}), размер батча (16–128), коэффициент Dropout (0,1–0,5).

Особое внимание уделено разработке системы по оценке качества прогнозирования, учитывающей специфику коротких временных рядов и региональных экономических показателей. В качестве основных метрик использовались: средняя абсолютная ошибка (MAE, *Mean Absolute Error*) – для оценки абсолютных отклонений, средняя абсолютная процентная ошибка (MAPE, *Mean Absolute*

¹⁶ Хиндман Р.Дж., Атанасопулос Г. Указ. соч.

¹⁷ Эльскен Т., Метцен Я.Х., Хуттер Ф. Указ. соч.



Percentage Error) – для анализа относительных отклонений и симметричная средняя абсолютная процентная ошибка (SMAPE, *Symmetric Mean Absolute Percentage Error*) – для обеспечения устойчивости оценок при наличии экстремальных значений; дополнительной выступила среднеквадратичная ошибка (RMSE, *Root Mean Squared Error*) – для оценки влияния крупных отклонений на качество прогноза.

Процедура валидации прогнозов реализована с учетом необходимости корректной оценки прогностической способности модели в условиях ограниченных временных рядов [11]. Данные разделялись на обучающую (2003–2016 гг.) и тестовую (2017–2019 гг.) выборки. Валидация включала сопоставление прогнозных и фактических значений, анализ устойчивости прогнозов и оценку чувствительности результатов к размеру окна прогнозирования. Контроль качества осуществлялся посредством мониторинга стабильности прогнозов, анализа выбросов и аномалий, оценки влияния структурных сдвигов в экономике на точность прогнозирования.

Для предотвращения переобучения моделей применялся комплекс методов регуляризации, включая использование Dropout-слоев и раннюю остановку обучения. Оно прекращалось при отсутствии улучшения на валидационной выборке в течение 10 эпох, что позволило достичь оптимального баланса между точностью прогнозирования и обобщающей способностью модели.

Анализ системной значимости показателей. В рамках исследования разработан комплексный подход к анализу системной значимости экономических показателей регионального развития, основанный на интеграции методов машинного обучения и классического статистического анализа. При этом под системной значимостью показателя понималась степень обусловленности его динамики внутренними факторами развития региональной экономики, что проявлялось через устойчивые взаимосвязи с другими показателями и относительно высокую прогнозируемость значений.

Методологический подход к оценке системной значимости показателей базируется на многокритериальном анализе, включающем исследование корреляционных взаимосвязей, оценку прогнозируемости показателей, изучение устойчивости выявленных зависимостей. Основной особенностью разработанного подхода выступает его способность выявлять не только прямые, но и опосредованные связи между показателями, что дает возможность формировать более полное представление о структуре региональной экономики.

Корреляционный анализ реализован с использованием робастных методов оценки взаимосвязей, что значимо при работе с относительно короткими временными рядами, характерными для региональной статистики. Применение робастных оценок позволило минимизировать влияние выбросов и структурных сдвигов на результаты анализа, скользящего окна наблюдений при расчете корреляций – оценить стабильность выявленных взаимосвязей во времени, а также идентифицировать периоды изменения характера связей между показателями.

Интегральная оценка системной значимости показателей производилась на основе композитного индекса, учитывающего три аспекта:

1) качество прогностической модели (вес 40 %) – оценивалось через коэффициент детерминации (R^2) и среднюю абсолютную процентную ошибку прогноза (MAPE);

- 2) степень включенности в систему корреляционных связей (вес 30 %) – определялась количеством статистически значимых корреляций с другими показателями;
- 3) стабильность прогнозов (вес 30 %) – оценивалась через устойчивость прогнозных значений при различных конфигурациях модели.

Для интеграции различных критериев в единый индекс был применен подход, основанный на методологии многокритериального анализа¹⁸. Веса компонентов определены экспертным путем с учетом их относительной важности для характеристики системной роли показателя.

Композитный индекс системной значимости показателя (I) рассчитывался по формуле:

$$I = 0,4 \times R^2 + 0,3 \times (N_{\text{corr}} / N_{\text{total}}) + 0,3 \times (1 - \min(\text{MAPE} / 100, 1)),$$

где R^2 – коэффициент детерминации прогностической модели; N_{corr} – количество статистически значимых корреляций с модулем больше 0,3; N_{total} – общее количество анализируемых показателей.

Для **визуализации результатов** анализа разработана система многоуровневого представления данных:

а) динамическая тепловая карта корреляций – наглядно представляет интенсивность и направление взаимосвязей между показателями, благодаря чему возможно быстро идентифицировать кластеры взаимосвязанных показателей, выявлять потенциальные причинно-следственные связи;

б) график рейтинга системной значимости показателей, отражающий результаты интегральной оценки с учетом всех компонентов композитного индекса. Он показывает распределение параметров по степени их системной значимости, что способствует выявлению естественных групп со сходными характеристиками роли в региональной экономике. При этом адаптивность к изменениям в структуре экономических взаимосвязей достигается за счет постоянного обновления оценок по мере поступления новых данных и использования методов робастной статистики, устойчивых к структурным сдвигам в экономике. Такой подход позволяет отслеживать эволюцию экономических взаимосвязей и своевременно выявлять перемены в характере и интенсивности взаимодействий между различными показателями;

в) оценка асимметрии влияния показателей друг на друга, реализованная через анализ условных вероятностей значимых изменений показателей (дополнительный элемент анализа). Осуществляется с целью выяснения направленности причинно-следственных связей, что важно для понимания механизмов распространения экономических импульсов в региональной экономике, а также идентификации значимых точек приложения управленческих воздействий.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

Сравнительный анализ эффективности прогнозирования выявил существенные различия в точности методов скользящего окна и расширяющегося окна для разных групп показателей регионального развития.

¹⁸ Яцало Б.И., Грицюк С.В., Диденко В.И., Мирзеабасов О.А. Система многокритериального анализа решений DecernsMCDA и ее практическое применение. *Программные продукты и системы*. 2014;(2):79–84. <https://www.elibrary.ru/tpouxn>



Результаты прогнозирования интегральных экономических показателей неоднородны. Так, для ВРП более высокую точность обеспечил метод скользящего окна (MAE = 1,79; MAPE = 1,77 %; SMAPE = 1,75 %) против метода расширяющегося окна (MAE = 2,31; MAPE = 2,23 %; SMAPE = 2,28 %). Максимальные отклонения в прогнозах ВРП приходились на периоды экономической нестабильности 2013–2015 гг., что подчеркивает важность учета структурных изменений в экономике. Напротив, для реальных располагаемых доходов населения бóльшую точность продемонстрировал метод расширяющегося окна (MAE = 0,21; MAPE = 0,20 %; SMAPE = 0,20 %) по сравнению с методом скользящего окна (MAE = 2,90; MAPE = 3,03 %; SMAPE = 2,95 %), что согласуется с наличием устойчивого долгосрочного тренда в динамике доходов.

Точность прогнозирования отраслевых показателей варьировала в зависимости от специфики сектора. В инерционной горнодобывающей отрасли преимущество оказалось на стороне метода расширяющегося окна (MAE = 1,09; MAPE = 1,01 %; SMAPE = 1,01 %) относительно метода скользящего окна (MAE = 4,12; MAPE = 3,83 %; SMAPE = 3,74 %). В волатильной строительной отрасли, напротив, последний показал несколько лучшие результаты (MAE = 7,36; MAPE = 7,03 %; SMAPE = 7,47 %) в сравнении с методом расширяющегося окна (MAE = 9,56; MAPE = 9,21 %; SMAPE = 9,91 %), что отражает чувствительность сектора к колебаниям конъюнктуры.

Для показателей инвестиционной активности методы продемонстрировали сопоставимую точность с незначительным преимуществом скользящего окна (MAE = 7,85; MAPE = 7,94 %; SMAPE = 7,92 %) над расширяющимся (MAE = 8,60; MAPE = 9,37 %; SMAPE = 8,68 %).

Наибольшая стабильность точности прогнозирования характерна для группы социально-демографических параметров. Метод расширяющегося окна эффективно справился с прогнозированием численности населения (MAE = 0,075; MAPE = 0,076 %; SMAPE = 0,076 %) и уровня безработицы (MAE = 4,42; MAPE = 4,54 %; SMAPE = 4,70 %), существенно превзойдя метод скользящего окна (MAE = 10,92; MAPE = 10,99 %; SMAPE = 11,67 %).

На тестовом периоде 2017–2019 гг. показатели можно разделить на три группы по устойчивости прогнозных оценок. Высокую устойчивость (MAPE < 1 %) показали прогнозы численности населения и реальных доходов населения (метод расширяющегося окна). Среднюю (MAPE 1–5 %) – прогнозы ВРП, показателей горнодобывающей отрасли и уровня занятости (также метод расширяющегося окна). Низкая устойчивость (MAPE > 5 %) свойственна прогнозам по строительству, инвестиционной активности и уровню безработицы при использовании метода скользящего окна.

Анализ структуры экономических взаимосвязей. Построенная корреляционная матрица (рис. 1) наглядно представляет интенсивность и направление связей между различными показателями за счет цветовой дифференциации и числовых значений коэффициентов корреляции. Данный инструмент обеспечивает возможность быстрой идентификации групп взаимосвязанных показателей и первичной оценки структуры экономических взаимодействий.




Рис. 1. Корреляционная матрица показателей регионального развития (для годовых индексов): 1 – валовой региональный продукт, 2 – горнодобывающая отрасль, 3 – строительство, 4 – инвестиции, 5 – оборот оптовой торговли, 6 – безработица, 7 – уровень занятости, 8 – реальные располагаемые доходы, 9 – численность населения

Fig. 1. Correlation matrix of regional development indicators (for annual performance indices): 1 – gross regional product, 2 – mining industry, 3 – construction, 4 – investments, 5 – wholesale trade turnover, 6 – unemployment, 7 – employment rate, 8 – real disposable income, 9 – population

Примечание: цветовой градиент отражает интенсивность корреляционных связей: насыщенность оттенка соответствует силе связи; синий цвет обозначает положительную корреляцию, красный – отрицательную.


Note: the color gradient reflects the intensity of the correlation: the saturation of the hue corresponds to the strength of the relationship; blue indicates a positive correlation, red indicates a negative correlation.

Как видно из рисунка 1, наиболее сильные положительные связи сформировались в производственно-инвестиционном блоке: динамика ВРП и строительства тесно связаны ($r = 0,68$), а строительство – с инвестициями в основной капитал ($r = 0,64$). Выраженные отрицательные связи наблюдались между уровнем занятости и инвестициями ($r = -0,72$), безработицей ($r = -0,66$); численностью населения и реальными располагаемыми доходами ($r = -0,65$), строительством ($r = -0,63$). Слабее всего в общую систему взаимосвязей включена горнодобывающая отрасль: ее коэффициенты корреляции по модулю не превышали 0,37.

Визуализация результатов ранжирования в виде упорядоченной диаграммы (рис. 2) дала возможность классифицировать естественные группы показателей по величине системной значимости: с высоким ($> 0,7$), средним (0,5–0,7) и низким ($< 0,5$)



уровнем. Такая группировка может служить основой для дифференциации подходов к прогнозированию и выбора соответствующих методов анализа.



Р и с. 2. Ранжирование показателей по степени системной значимости на основе результатов нейросетевого анализа

F i g. 2. Ranking of indicators by degree of systemic significance based on the results of neural network analysis

Примечание: цветом показано распределение показателей по уровню системной значимости: темно-синим – высокий уровень, синим – средний, серым – низкий.

Note: the color shows the distribution of indicators by level of systemic significance: dark blue – high level, blue – medium, gray – low.

Как видно из рисунка 2, лидирующие позиции принадлежат валовому региональному продукту (0,85) и строительству (0,82) – только эти показатели образуют группу высокой системной значимости (индекс выше 0,7). Средняя группа (0,5–0,7) включает численность населения (0,69), безработицу (0,68), уровень занятости (0,61) и реальные располагаемые доходы (0,60), т. е. преимущественно социально-демографические показатели. Низкие значения композитного индекса (менее 0,5) получены для оборота оптовой торговли (0,43), инвестиций (0,43) и горнодобывающей отрасли (0,32).

Валидация прогностической способности моделей. Для проверки устойчивости разработанных моделей проведена дополнительная валидация их прогностической способности на данных 2020–2022 гг. (табл. 2).

В прогнозировании динамики ВРП наблюдалось существенное снижение точности в 2022 г. Если в 2020–2021 годах метод расширяющегося окна демонстрировал высокую точность (ошибка около 0,3 %), то в 2022 расхождение достигло 8,44 %: фактическое значение составило 97,0 % при прогнозе 105,4 %. Метод скользящего окна, несмотря на более консервативные прогнозы, также не смог предсказать масштаб экономического спада.

Т а б л и ц а 2. Прогностическая способность моделей расширяющегося (РО) и скользящего окна (СО), в процентах к предыдущему году

Table 2. Predictive ability of the expanding window (EW) and sliding window (SW) models, percent of the previous year

Показатель / Indicator	2020			2021			2022		
	факт / actual	РО / (EW)	СО / (SW)	факт / actual	РО / (EW)	СО / (SW)	факт / actual	РО / (EW)	СО / (SW)
Валовой региональный продукт / Gross regional product	104,5	104,2	101,5	105,4	105,1	101,6	97,0	105,4	101,7
Горнодобывающая отрасль / Mining industry	99,8	110,0	105,9	110,9	111,5	105,4	102,7	108,4	105,0
Строительство / Construction	131,2	103,2	94,2	97,1	103,3	96,2	120,6	109,9	97,8
Инвестиции / Investment	121,9	105,3	105,4	119,5	106,8	104,4	99,5	112,3	105,2
Оборот оптовой торговли / Wholesale trade turnover	87,3	108,3	98,5	106,8	120,1	98,6	112,3	109,1	99,8
Безработица / Unemployment	105,4	96,4	89,3	94,9	97,2	89,8	93,6	108,9	91,1
Уровень занятости / Employment rate	99,8	101,2	101,4	100,7	100,1	101,3	98,8	99,6	101,2
Реальные располагаемые доходы / Real disposable income	99,9	103,4	101,0	102,2	102,7	100,8	100,2	104,2	100,8
Численность населения / Population	99,4	99,5	99,4	99,4	99,5	99,4	95,0	99,5	99,4

Источник: фактические значения – данные Забайкалкрайстата; прогнозные значения – расчеты автора.

Source: actual values – Zabaykalkraystat data; forecast values – author's calculations.

Показательна динамика строительной отрасли: в 2022 г. зафиксирован существенный рост (120,6 %), значительно превысивший прогнозные значения обоих методов (109,87 и 97,84 % соответственно). Инвестиционная активность продемонстрировала резкое снижение до 99,5 % после значительного роста в 2020, 2021 гг. (121,9 и 119,5 % соответственно).

Резкое снижение численности населения до 95,0 % в 2022 г. отразило реальные демографические процессы в регионе, включая естественную убыль населения, миграционный отток и влияние геополитических событий. Это зафиксировано в официальной статистике Росстата и характеризует фактическую демографическую ситуацию в Забайкальском крае. Указанное отклонение прогнозных значений от фактических демонстрирует ограничения используемых методов в условиях беспрецедентных внешних воздействий на региональную демографическую систему. Динамика показателей рынка труда в 2022 году также обнаружила влияние структурных изменений: уровень безработицы (93,55 %) оказался значительно ниже прогноза методом расширяющегося окна (108,85 %); оборот оптовой торговли показал неожиданно высокий рост в 2022 г. (112,3 %), существенно превысив прогнозные значения обоих методов.



ОБСУЖДЕНИЕ

Применение LSTM-архитектуры к коротким временным рядам региональной статистики продемонстрировало как значительные возможности, так и определенные ограничения: для большинства показателей достигнут уровень точности, достаточный для задач краткосрочного прогнозирования (ошибка MAPE – от сотых долей процента для численности населения до 7–8 % для наиболее волатильных показателей, строительства и инвестиций, по лучшему из двух методов). При этом эффективность прогнозирования оказалась дифференцированной в зависимости от характера динамики показателя и выбранной стратегии формирования обучающей выборки.

Внимания заслуживает обнаруженная асимметрия в точности прогнозирования. Наиболее высокая точность достигнута для демографических показателей и реальных располагаемых доходов населения при использовании метода расширяющегося окна, что объясняется наличием устойчивых долгосрочных трендов и относительно низкой волатильностью данных показателей. Сходный механизм – инерционность развития отрасли – лежит, по-видимому, в основе преимущества этого метода для горнодобывающей промышленности.

Напротив, для показателей с высокой краткосрочной волатильностью лучшие результаты продемонстрировал метод скользящего окна благодаря более эффективной адаптации к изменениям краткосрочных тенденций: высокие ошибки прогнозирования строительной отрасли отражают ее волатильность и чувствительность к экономической конъюнктуре. Близкая точность методов для инвестиционной активности может быть связана с высокой чувствительностью инвестиционных процессов к изменениям ситуации и необходимостью более гибкого учета краткосрочных тенденций. Максимальные отклонения прогнозов ВРП, зафиксированные в периоды экономической нестабильности (2013–2015 гг.), указывают на важность учета структурных изменений в экономике при прогнозировании.

Пояснения требует и структура композитного индекса системной значимости. Большой вес качества прогностической модели (40 %) свидетельствует о приоритетной прогнозируемости показателя как индикатора его системной значимости. Равные веса для степени включенности в систему связей и стабильности прогнозов (по 30 %) подчеркивают важность как структурной включенности показателя в систему экономических взаимосвязей, так и устойчивости этих взаимосвязей во времени.

Тестирование инструментария на данных регионального развития показало его способность выявлять как прямые, так и опосредованные связи между показателями; разработанная система визуализации обеспечила гибкую настройку порогов значимости корреляций и масштаба представления данных. Преимущества анализа определяются возможностью оценить работу моделей в условиях значительных экономических потрясений, связанных с пандемией COVID-19 и последующими структурными изменениями в экономике. Верификация моделей на данных 2020–2022 гг. позволила оценить их устойчивость к масштабным структурным шокам: если влияние пандемии в 2020–2021 гг. удалось спрогнозировать с приемлемой точностью, то события 2022 г. привели к существенным отклонениям фактических значений от прогнозных по большинству показателей. Значимые

расхождения наблюдались в динамике инвестиционной активности и демографических показателей, что отразило беспрецедентный характер структурных изменений в экономике региона.

Полученные результаты согласуются с данными предшествовавших исследований и в ряде аспектов дополняют их. Продемонстрированная применимость LSTM-моделей к экономическим временным рядам соответствует выводам о превосходстве LSTM-архитектуры над классическими методами ARIMA [5] и положительном опыте ее использования при прогнозировании ВВП [7], инфляции на российских данных [8] и финансовых временных рядов [4]. Вместе с тем, в отличие от большинства указанных работ, выполненных на длинных и/или высокочастотных рядах, настоящее исследование показывает, что сопоставимые по качеству результаты достижимы и на коротких рядах годовой региональной статистики – при условии адаптации архитектуры, автоматической валидации качества и многократного переобучения моделей.

Исследование подтвердило теоретические положения о влиянии выбора окна оценивания на качество прогнозов в условиях структурных сдвигов¹⁹ [12–14] и адаптировало их к специфике региональной экономики. Установленная дифференциация эффективности расширяющегося и скользящего окна согласуется с выводом о том, что процедуры с переменной длиной окна обеспечивают преимущество главным образом при смене характера прогнозируемого процесса [13], а рекомендация комбинированного подхода для ВВП, инвестиций и строительства перекликается с результатами [12], где предложена стратегия переключения между окнами в зависимости от их недавней прогностической результативности. Отличие настоящей работы состоит в том, что выбор стратегии обучения увязан с содержательным типом регионального показателя – трендовые социально-демографические индикаторы против волатильных производственно-инвестиционных, – а не только со статистическими свойствами ряда.

По отношению к российским исследованиям нейросетевого анализа региональной экономики настоящая работа дополняет материалы по кластеризации и типологизации регионов²⁰ [10], прогнозированию отдельных региональных показателей [2; 11] инструментом количественной оценки системной роли показателей внутри региональной экономической системы, сочетающим оценку их прогнозируемости и структуры взаимосвязей.

Проведенное исследование имеет ряд ограничений. Первое связано с относително короткой длиной анализируемых временных рядов, что проявляется при использовании традиционного коэффициента детерминации. Для сравнения результатов прогнозирования различных по природе временных рядов более подходящими являются относительные метрики MAPE и SMAPE²¹. Второе касается чувствительности моделей к структурным изменениям в экономике региона, что особенно заметно в периоды экономических кризисов и институциональных преобразований. Третье, фундаментальное, ограничение продемонстрировала верификация прогнозов 2020–2022 гг.: используемые методы не способны предсказывать

¹⁹ Песаран М.Х., Тиммерманн А. Указ. соч.

²⁰ Кузнецов Ю.А., Перова В.И., Эйвазова Э.Н. Указ. соч.

²¹ Хиндман Р.Дж., Атанасопулос Г. Указ. соч.



последствия масштабных структурных изменений. Геополитические события, кардинально меняющие условия функционирования региональной экономики, находятся за пределами прогностических возможностей моделей, обучаемых на исторических данных. Наконец, следует учитывать, что апробация подхода выполнена на данных одного региона, а разработанный инструментарий нужно рассматривать как вспомогательное средство анализа, требующее содержательной экономической интерпретации получаемых результатов и учета специфики конкретного региона.

ЗАКЛЮЧЕНИЕ

Проведенное исследование позволяет дать утвердительный ответ на поставленный исследовательский вопрос. Нейросетевые модели на основе LSTM-архитектуры способны обеспечивать достаточный для практических задач уровень точности краткосрочного прогнозирования региональной экономической динамики даже в условиях коротких временных рядов и структурных изменений: разработанный методологический подход, включающий оптимизацию архитектуры, байесовский поиск гиперпараметров, автоматическую валидацию качества и многократное переобучение моделей, продемонстрировал высокую эффективность при прогнозировании широкого спектра показателей Забайкальского края.

Основным методологическим результатом стало выявление дифференцированной эффективности стратегий формирования обучающей выборки. Метод расширяющегося окна продемонстрировал более высокую точность при прогнозировании показателей с выраженными долгосрочными трендами (прежде всего демографических и социальных индикаторов с низкой волатильностью) и характеризуется повышенной устойчивостью к локальным колебаниям. Метод скользящего окна обнаружил лучшие результаты для волатильных показателей, чувствительных к изменениям экономической конъюнктуры, а также более высокую адаптивность к краткосрочным тенденциям. Для ряда показателей, включая ВРП, инвестиционную активность и строительство, целесообразно использование комбинированного подхода, учитывающего результаты обоих методов прогнозирования.

Разработанный инструментарий анализа системной значимости показателей позволил выявить устойчивую кластерную структуру региональной экономики, интегрировавшую производственно-инвестиционный и социально-демографический кластеры. Сочетание сетевого анализа корреляционных взаимосвязей и композитного индекса системной значимости обеспечило количественную основу для понимания механизмов взаимодействия различных секторов региональной экономики и их роли в формировании общей динамики развития.

Верификация моделей на данных 2020–2022 гг. подтвердила их прогностическую способность в условиях типичных экономических флуктуаций и при таких серьезных потрясениях, как пандемия COVID-19: метод расширяющегося окна обеспечил прогнозирование ВРП с ошибкой около 0,3 % в 2020–2021 гг. Существенные отклонения прогнозных значений от фактических в 2022 г. связаны в первую очередь с беспрецедентным характером структурных изменений. Подобные геополитические события, кардинально меняющие условия функционирования региональной экономики, выходят за пределы прогностических возможностей моделей, обучаемых на исторических данных. Вместе с тем даже в этих условиях разработанные модели сохранили способность улавливать общие тенденции развития.

Перспективы дальнейших исследований связаны с разработкой гибридных моделей, адаптивно сочетающих преимущества методов расширяющегося и скользящего окна в зависимости от характера временного ряда и экономической ситуации; интеграцией в модели дополнительной информации о структурных изменениях, включая качественные индикаторы институциональных изменений, экспертные оценки и механизмы раннего выявления структурных сдвигов и геополитических рисков; развитием методов интерпретации результатов нейросетевого моделирования; совершенствованием анализа системной значимости с учетом динамического характера экономических взаимосвязей.

Практическая значимость результатов определяется возможностью их применения в деятельности органов регионального управления и стратегического планирования. Разработанный инструментарий интегрирован в общую систему мониторинга регионального развития и может использоваться для формирования кратко- и среднесрочных прогнозов важных показателей, анализа структурных взаимосвязей и оценки системной устойчивости различных секторов экономики. Результаты анализа системной значимости служат основой для разработки дифференцированных подходов к управлению: показатели с высокой системной значимостью могут рассматриваться как индикаторы системной устойчивости, тогда как слабо включенные в систему взаимосвязей требуют внимания при разработке мер экономической политики и антикризисных программ.

Высокая точность прогнозирования демографических показателей и реальных располагаемых доходов населения открывает дополнительные возможности для планирования социальной политики и оценки потребности в социальной инфраструктуре. Для исследователей региональной экономики предложенный подход представляет методологическую основу, применимую к другим регионам со сходными характеристиками статистических данных, а также может быть востребован в образовательных программах по региональной экономике и прикладному анализу данных.

В целом проведенное исследование демонстрирует, что нейросетевые методы при соответствующей адаптации к специфике коротких временных рядов способны стать действенным дополнением традиционного инструментария регионального экономического анализа. Ограничения прогностической способности моделей в условиях существенных геополитических изменений являются естественными и определяют направления дальнейшего совершенствования методологии регионального экономического прогнозирования.

СПИСОК ЛИТЕРАТУРЫ

1. Гамукин В.В. Изменение структуры ВРП в субъектах Уральского федерального округа. *Экономика региона*. 2017;13(2):410–421. <https://doi.org/10.17059/2017-2-7>
2. Бородин С.Н. Прогнозирование экономического развития региона на основе регрессионных и нейросетевых моделей. *Russian Economic Bulletin*. 2024;7(1):290–300. <https://www.elibrary.ru/eqfigc>
3. Lim B., Zohren S. Time-Series Forecasting with Deep Learning: A Survey. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*. 2021;379(2194):20200209. <https://doi.org/10.1098/rsta.2020.0209>
4. Видмант О.С. Прогнозирование финансовых временных рядов с использованием рекуррентных нейронных сетей LSTM. *Общество: политика, экономика, право*. 2018;(5):63–66. <https://doi.org/10.24158/pep.2018.5.12>



5. Siامي-Namini S., Tavakoli N., Namin A.S. A Comparison of ARIMA and LSTM in Forecasting Time Series. In: 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA). 2018. P. 1394–1401. <https://doi.org/10.1109/ICMLA.2018.00227>
6. Richardson A., van Florenstein Mulder T., Vehbi T. Nowcasting GDP Using Machine-Learning Algorithms: A Real-Time Assessment. *International Journal of Forecasting*. 2021;37(2):941–948. <https://doi.org/10.1016/j.ijforecast.2020.10.005>
7. Hamiane S., Ghanou Y., Khalifi H., Telmem M. Comparative Analysis of LSTM, ARIMA, and Hybrid Models for Forecasting Future GDP. *Ingénierie des Systèmes d'Information*. 2024;29(3):853–861. <https://doi.org/10.18280/isi.290306>
8. Матыцын А.В. Применение LSTM-модели к прогнозированию CPI и уровня инфляции на примере России. *Вопросы инновационной экономики*. 2022;12(2):1241–1252. <https://doi.org/10.18334/vinec.12.2.114845>
9. Abbasimehr H., Shabani M., Yousefi M. An Optimized Model Using LSTM Network for Demand Forecasting. *Computers and Industrial Engineering*. 2020;143:106435. <https://doi.org/10.1016/j.cie.2020.106435>
10. Летягина Е.Н., Перова В.И. Нейросетевое моделирование региональных инновационных экосистем. *Journal of New Economy*. 2021;22(1):71–89. <https://doi.org/10.29141/2658-5081-2021-22-1-4>
11. Трещевский Ю.И., Гладких М.О., Опойкова Е.А., Папина О.Н. Методический подход к прогнозированию целевых параметров социально-экономического развития регионов с использованием стандартного аппарата нейронных сетей. *Регион: системы, экономика, управление*. 2020;(4):114–126. <https://doi.org/10.22394/1997-4469-2020-51-4-114-126>
12. Feng Y., Zhang Y., Wang Y. Out-of-Sample Volatility Prediction: Rolling Window, Expanding Window, or Both? *Journal of Forecasting*. 2024;43(3):567–582. <https://doi.org/10.1002/for.3046>
13. Hall S.G., Tavlás G.S., Wang Y., Gefang D. Inflation Forecasting with Rolling Windows: An Appraisal. *Journal of Forecasting*. 2024;43(4):827–851. <https://doi.org/10.1002/for.3059>
14. Inoue A., Jin L., Rossi B. Rolling Window Selection for Out-of-Sample Forecasting with Time-Varying Parameters. *Journal of Econometrics*. 2017;196(1):55–67. <https://doi.org/10.1016/j.jeconom.2016.03.006>

REFERENCES

1. Gamukin V.V. Structural Change of Gross Regional Product in the Subjects of Ural Federal District. *Economy of Regions*. 2017;13(2):410–421. (In Russ., abstract in Eng.) <https://doi.org/10.17059/2017-2-7>
2. Borodin S.N. Forecasting the Economic Development of the Region Based on Regression and Neural Network Models. *Russian Economic Bulletin*. 2024;7(1):290–300. (In Russ., abstract in Eng.) <https://www.elibrary.ru/eqfige>
3. Lim B., Zohren S. Time-Series Forecasting with Deep Learning: A Survey. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*. 2021;379(2194):20200209. <https://doi.org/10.1098/rsta.2020.0209>
4. Vidmant O.S. Forecasting Financial Time Series with LSTM Recurrent Neural Networks. *Obshchestvo: politika, ekonomika, pravo*. 2018;(5):63–66. (In Russ., abstract in Eng.) <https://doi.org/10.24158/pep.2018.5.12>
5. Siامي-Namini S., Tavakoli N., Namin A.S. A Comparison of ARIMA and LSTM in Forecasting Time Series. In: 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA). 2018. P. 1394–1401. <https://doi.org/10.1109/ICMLA.2018.00227>
6. Richardson A., van Florenstein Mulder T., Vehbi T. Nowcasting GDP Using Machine-Learning Algorithms: A Real-Time Assessment. *International Journal of Forecasting*. 2021;37(2):941–948. <https://doi.org/10.1016/j.ijforecast.2020.10.005>
7. Hamiane S., Ghanou Y., Khalifi H., Telmem M. Comparative Analysis of LSTM, ARIMA, and Hybrid Models for Forecasting Future GDP. *Ingénierie des Systèmes d'Information*. 2024;29(3):853–861. (In French) <https://doi.org/10.18280/isi.290306>
8. Matytsyn A.V. Application of LSTM Model to Prediction of CPI and Inflation Rate on the Example of Russia. *Russian Journal of Innovation Economics*. 2022;12(2):1241–1252. (In Russ., abstract in Eng.) <https://doi.org/10.18334/vinec.12.2.114845>
9. Abbasimehr H., Shabani M., Yousefi M. An Optimized Model Using LSTM Network for Demand Forecasting. *Computers and Industrial Engineering*. 2020;143:106435. <https://doi.org/10.1016/j.cie.2020.106435>

10. Letyagina E.N., Perova V.I. Neural Network Modeling of Regional Innovation Eco-systems. *Journal of New Economy*. 2021;22(1):71–89. (In Russ., abstract in Eng.) <https://doi.org/10.29141/2658-5081-2021-22-1-4>
11. Treschevsky Yu.I., Gladkikh M.O., Opoykova E.A., Papina O.N. Methodological Approach to Prognosis of Target-High Parameters of Regions Socio-Economic Development Using the Standard Neural Network Apparatus. *Region: Systems, Economics, Management*. 2020;(4):114–126. (In Russ., abstract in Eng.) <https://doi.org/10.22394/1997-4469-2020-51-4-114-126>
12. Feng Y., Zhang Y., Wang Y. Out-of-Sample Volatility Prediction: Rolling Window, Expanding Window, or Both? *Journal of Forecasting*. 2024;43(3):567–582. <https://doi.org/10.1002/for.3046>
13. Hall S.G., Tavlas G.S., Wang Y., Gefang D. Inflation Forecasting with Rolling Windows: An Appraisal. *Journal of Forecasting*. 2024;43(4):827–851. <https://doi.org/10.1002/for.3059>
14. Inoue A., Jin L., Rossi B. Rolling Window Selection for Out-of-Sample Forecasting with Time-Varying Parameters. *Journal of Econometrics*. 2017;196(1):55–67. <https://doi.org/10.1016/j.jeconom.2016.03.006>

Об авторе:

Брезгин Вячеслав Сергеевич, кандидат экономических наук, научный сотрудник лаборатории эколого-экономических исследований Института природных ресурсов, экологии и криологии Сибирского отделения Российской академии наук (672014, Российская Федерация, г. Чита, ул. Недорезова, д. 16а), ORCID: <https://orcid.org/0000-0001-9008-4540>, Researcher ID: R-5652-2016, SPIN-код: 2984-6475, monmanage@bk.ru

Доступность данных и материалов. Наборы данных, использованные и/или проанализированные в ходе текущего исследования, можно получить у автора по обоснованному запросу.

Автор прочитал и одобрил окончательный вариант рукописи.

Поступила 21.02.2025; одобрена после рецензирования 15.07.2025; принята к публикации 30.07.2025.

About the author:

Vyacheslav S. Brezgin, Cand.Sci. (Econ.), Researcher, Laboratory of Ecological and Economic Research, Institute of Natural Resources, Ecology and Cryology, Siberian Branch of the Russian Academy of Sciences (16a Nedorezova St., Chita 672014, Russian Federation), ORCID: <https://orcid.org/0000-0001-9008-4540>, Researcher ID: R-5652-2016, SPIN-code: 2984-6475, monmanage@bk.ru

Availability of data and materials. The datasets used and/or analyzed during the current study are available from the author on reasonable request.

The author has read and approved the final manuscript.

Submitted 21.02.2025; revised 15.07.2025; accepted 30.07.2025.