



Прогнозирование развития промышленности Российской Федерации: сравнительный анализ математического инструментария

Целью данной работы является комплексный сравнительный анализ различных математических методов прогнозирования ключевого показателя промышленного развития — добавленной стоимости промышленности Российской Федерации. Исследование направлено на оценку эффективности и точности традиционных и современных подходов в условиях реальной, подверженной кризисным явлениям экономической динамики. Определение наиболее надежного инструментария для построения среднесрочных прогнозов имеет важное значение для повышения обоснованности макроэкономических решений.

Эмпирической базой исследования послужили официальные статистические данные Всемирного банка за период 2002–2021 гг. Для моделирования были отобраны такие показатели, как добавленная стоимость в промышленности, валовое накопление капитала и доля средне- и высокотехнологичного экспорта. Для обеспечения стационарности и устранения трендовой составляющей все временные ряды были преобразованы с помощью вторых разностей, что подтверждено тестом Дики-Фуллера. Сравнительный анализ проводился между тремя методами: методом экстраполяции на основе исторических трендов, многофакторной линейной эконометрической моделью, оцениваемой методом наименьших квадратов, и нейросетевой моделью с долгой краткосрочной памятью (LSTM). Оценка качества моделей выполнялась путем сравнения прогнозов на периоды 2011–2012 и 2019–2021 гг. с фактическими данными.

Результаты исследования выявили существенное превосходство современных методов над традиционной экстраполяцией, которая дала значительный и нарастающий разброс прогнозных

значений. Эконометрическая модель показала значительно более высокую и устойчивую точность, адекватно отразив основные линейные зависимости. Наилучшие результаты продемонстрировала LSTM-модель, которая наиболее точно спрогнозировала траекторию восстановления после кризиса 2008–2010 гг. и корректно зафиксировала замедление роста в преддверии кризиса 2020 г. Однако ни одна из моделей не смогла предсказать экстремальный спад 2020 г., вызванный глобальным внешним шоком (пандемия COVID-19), что указывает на ограниченность любого формализованного подхода в условиях непредвиденных структурных изменений.

Проведенный анализ позволяет сделать вывод о высокой эффективности и перспективности применения архитектур глубокого обучения, в частности моделей LSTM, для задач прогнозирования сложных макроэкономических показателей. Эти модели способны устанавливать нелинейные зависимости и долгосрочные эффекты во временных рядах. Эконометрические модели сохраняют свою ценность как надежный и интерпретируемый инструмент для анализа устойчивых линейных взаимосвязей. Полученные результаты подтверждают, что использование LSTM-моделей с оптимизированными параметрами может существенно повысить точность макроэкономических прогнозов, что является важным условием для формирования научно обоснованной промышленной и экономической политики.

Ключевые слова: добавленная стоимость, метод прогнозирования, корреляционный анализ, регрессионный анализ, нестационарные временные ряды, экстраполяция, эконометрическая модель, LSTM-модель, обучение модели.

Elena M. Karpenko, Ivan V. Beresten

Belarussian State University, Minsk, Republic of Belarus

Forecasting the Industrial Development of the Russian Federation: a Comparative Analysis of Mathematical Tools

The purpose of this paper is a comprehensive comparative analysis of various mathematical methods for forecasting a key index of industrial development — the value added of industry in the Russian Federation. The research aims to assess the effectiveness and accuracy of traditional and modern approaches in the context of real, crisis-prone economic dynamics. Determining the most reliable tools for making medium-term forecasts is important to increase the validity of macroeconomic decisions.

The empirical basis of the study was the official statistics of the World Bank for the period from 2002 to 2021. Indexes such as industrial value added, gross capital formation, and the share of medium- and high-tech exports were selected for modeling. To ensure stationarity and eliminate the trend component, all-time series were transformed using second differences, which was confirmed by the Dickey-Fuller test. The comparative analysis was carried out between three methods: the method of extrapolation based on historical trends, a multifactorial

linear econometric model estimated by the least squares method, and a neural network model with long short-term memory (LSTM). The quality of the models was assessed by comparing forecasts for the periods 2011–2012 and 2019–2021 with actual data.

The results of the study revealed a significant superiority of modern methods over traditional extrapolation, which gave a significant and increasing range of forecast values. The econometric model showed significantly higher and more stable accuracy, adequately reflecting the main linear dependencies. The best results were demonstrated by the LSTM model, which most accurately predicted the trajectory of recovery after the 2008–2010 crisis and correctly recorded a slowdown in growth ahead of the 2020 crisis. However, none of the models was able to predict the extreme recession of 2020 caused by the global external shock (the COVID-19 pandemic), which indicates the limitations of any formalized approach in the face of unforeseen structural changes.

The analysis makes it possible to conclude that deep learning architectures, in particular LSTM models, are highly effective and promising for forecasting complex macroeconomic in-dexes. These models are capable of establishing nonlinear dependencies and long-term effects in time series. Econometric models retain their value as a reliable and interpretable tool for analyzing stable linear relationships. The results obtained confirm that the use of LSTM models with

opti-mized parameters can significantly improve the accuracy of macroeconomic forecasts, which is an important condition for the formation of scientifically sound industrial and economic policy.

Keywords: value added, forecasting method, correlation analysis, regression analysis, non-stationary time series, extrapolation, econometric model, LSTM-model, model training.

Введение

Добавленная стоимость является одним из ключевых показателей экономической эффективности, поскольку отражает способность предприятия или отрасли создавать реальную ценность. Сущность этого показателя заключается в разнице между стоимостью проданных товаров или услуг и суммой затрат, потребовавшихся на их создание. Проще говоря, добавленная стоимость показывает, сколько нового «богатства» генерируется в процессе производства [1].

Классические подходы к анализу временных рядов, разработанные Боксом и Дженкинсом, заложили основу для применения ARIMA-моделей в экономике. В их монументальном труде описаны принципы построения моделей для прогнозирования на основе исторических данных, что позволило выявить основные тренды и сезонные составляющие в динамике экономических показателей [2, с. 161-215].

Ряд исследований демонстрирует, что методы экстраполяции успешно применяются в сочетании с эконометрическими моделями для прогнозирования ключевых экономических показателей. Так, классическая работа С. Макридакиса и С. Уилрайта подробно описывает эффективность простых экстраполяционных методов, показывая, что при корректном учёте исторических трендов и сезонных колебаний они способны давать конкурентоспособные прогнозы в краткосрочной перспективе [3].

С развитием эконометрики внимание исследователей

переключилось на построение более комплексных моделей, способных учитывать взаимосвязь между множеством экономических переменных. Работы Дж. Стока и М. Уотсона направлены на исследования бизнес-циклов и структурных векторных авторегрессионных моделей. Так, в одной из работ подробно рассмотрены методы анализа динамических взаимосвязей между экономическими индикаторами, что имеет прямое применение при прогнозировании показателей [4].

В дальнейшем развитие эконометрических методов прогнозирования связано с активным применением регрессионного анализа и структурных моделей. Дж. Сток и М. Уотсон в другой своей работе изучили использование динамических моделей с множеством факторов, что позволяет учитывать не только прямые эффекты, но и взаимодействия между различными экономическими индикаторами для прогнозирования определённого показателя [5].

В последние десятилетия бурное развитие методов машинного обучения и нейросетевых технологий произвело революцию в области прогнозирования временных рядов. Одной из ключевых разработок в этой сфере стали рекуррентные нейронные сети, а в особенности модели LSTM, предложенные Хохрейтером и Шмидхубером в 1996-1997 гг. [6]. Эти модели успешно справляются с задачами обнаружения сложных нелинейных зависимостей и учёта длительной временной памяти. Дополнительные исследования, такие как работа Фишера и Краусса и сравнительный ана-

лиз LSTM и традиционных методов прогнозирования, проведенный Siami-Namini, показали, что LSTM обладают преимуществом в точности и адаптивности при прогнозировании экономических показателей [7-8].

Методология исследования

Метод экстраполяции используется для прогнозирования будущих значений временного ряда на основе его исторических данных. Он предполагает продолжение выявленных тенденций без учёта дополнительных факторов, влияющих на систему.

Как правило, при прогнозировании социально-экономических показателей оперируют не точечной, а интервальной оценкой, рассчитывая так называемые доверительные интервалы прогноза [9]. В общем виде границы доверительного интервала прогноза можно определить по выражению:

$$y_{n+1} \pm t_{\alpha} * S_y. \quad (1)$$

где y_{n+1} — точечная прогнозная оценка значения уровня в точке $n + 1$; S_y — среднее квадратическое отклонение фактических данных от расчетных; t_{α} — табличное значение t -статистики Стьюдента с уровнем значимости α .

Эконометрическая модель прогнозирования создаётся для количественной оценки влияния ряда факторов на зависимую переменную. Общая линейная форма модели имеет вид:

$$Y = \beta_0 + \beta_1 * X_1 + \beta_2 * X_2 + \epsilon \quad (2)$$

где b_0 — константный член (свободный член); $\beta_0, \beta_1, \beta_2$ — коэффициенты, отражающие

влияние соответствующих факторов; ϵ — случайная ошибка, учитывающая неучтённые факторы и случайные колебания.

Основным методом для оценки коэффициентов является метод наименьших квадратов (МНК). Суть метода состоит в минимизации суммы квадратов отклонений прогнозируемых значений от фактических.

После оценки коэффициентов модели её можно использовать для прогнозирования будущих значений добавленной стоимости. Если будущие значения независимых переменных предсказаны (например, с помощью экстраполяционных методов), то прогноз для периода $T + 1$ рассчитывается по следующей формуле:

$$Y_{t+1} = \beta_0 + \beta_1 * X_{1,t+1} + \beta_2 * X_{2,t+1} + \beta_3 * X_{3,t+1}, \quad (3)$$

где Y_{T+1} — прогнозируемое значение зависимой переменной; $X_{i,T+1}$ — прогнозные значения независимых переменных [10].

Что касается нейронных сетей LSTM, то по своей сути они представляют из себя рекуррентные нейронные сети, которые могут сохранять предыдущие значения, которые, в свою очередь, могут влиять на последующее прогнозирование.

Внутри каждой LSTM-клетки происходят вычисления по набору уравнений:

1. Забывающий элемент (forget gate):

$$f_t = \sigma(W_f \cdot x_t + U_f \cdot h_{t-1} + b_f) \quad (4)$$

2. Входной элемент (input gate):

$$i_t = \sigma(W_i \cdot x_t + U_i \cdot h_{t-1} + b_i). \quad (5)$$

3. Кандидат нового состояния:

$$c_{t*} = \tanh(W_c \cdot x_t + U_c \cdot h_{t-1} + b_c). \quad (6)$$

4. Обновление состояния памяти:

$$c_{t*} = f_t * c_{t-1} * \tanh(W_c \cdot x_t + U_c \cdot h_{t-1} + b_c). \quad (7)$$

5. Выходной элемент (output gate):

$$o_{t*} = \sigma(W_o \cdot x_t + U_o \cdot h_{t-1} + b_o). \quad (8)$$

6. Вычисление выходного скрытого состояния:

$$h_t = o_{t*} * \tanh(c_{t*}), \quad (9)$$

где x_t — вход в момент времени t ; h_{t-1} — скрытое состояние предыдущего временного шага; c_t — состояние памяти; W , U , b — обучаемые веса и смещения; σ (сигмоида) и $\tanh$ (гиперболический тангенс) — нелинейные функции активации [11].

Скрытое состояние передаётся в последний полносвязный слой (Dense-слой), который делает линейное преобразование:

$$y_{scaled} = W_{dense}^T * h + b_{dense}. \quad (10)$$

Далее происходит обратное масштабирование, чтобы получить итоговое значение прогноза:

$$y_{scaled} = W_{dense}^T * h + b_{dense}. \quad (11)$$

Выборка данных

В данной работе проведен сравнительный анализ методов прогнозирования добавленной стоимости промышленности на примере российской экономики. Исследование направлено на оценку того, насколько различные подходы способны предсказать развитие этого показателя.

В качестве исходных данных для сравнительного анализа

методов прогнозирования добавленной стоимости промышленности на примере российской экономики использованы показатели, приведенные в табл. 1, за 2002–2021 гг. Прогнозы строятся на основе данных за период 2002–2018 гг., после чего полученные результаты сопоставляются с фактическими значениями за 2019–2021 гг. Это позволит выявить, насколько хорошо и точно каждая модель справляется с задачей прогнозирования в условиях реальной экономической динамики.

Приведенные значения анализируемых показателей приведены в табл. 2.

Между исследуемыми экономическими показателями проведён корреляционный анализ. Выявленные коэффициенты корреляции позволяют оценить степень влияния факторов на динамику добавленной стоимости производства, что определяет, какие показатели оказывают наибольшее воздействие на экономический результат.

Корреляционная матрица продемонстрировала, что взаимосвязи между целевой переменной Y и основными факторами ($X1$, $X3$, $X4$, $X5$, $X6$) находятся в допустимых пределах и подтверждают корректность их включения в модель. Значения коэффициентов корреляции с Y варьируются в диапазоне от 0,7 до $|-0,87|$. Коэффициент корреля-

Таблица 1 / Table 1

Выбранные показатели для проведения анализа
Selected indexes for analysis

Обозначение	Показатель
Y	Добавленная стоимость в промышленности, включая строительство, текущий долл. США
X1	Экспорт товаров и услуг, % ВВП
X2	Прямые иностранные инвестиции, чистый приток, % от ВВП
X3	Валовое накопление капитала, % от ВВП
X4	Занятость в промышленности, % от общей занятости (смоделированная оценка МОТ)
X5	Расходы на исследования и разработки, % от ВВП
X6	Средне- и высокотехнологичный экспорт, % экспорта промышленной продукции

Таблица 2 / Table 2

Значения анализируемых показателей за 2002–2021 гг.

Values of the analyzed indexes for 2002–2021

Год	Y, млрд. долл. США	X1, % от ВВП	X2, % от ВВП	X3, % от ВВП	X4, % от общей занятости	X5, % от ВВП	X6, % экспорта промышленной продукции
2002	100,381	35,21	1,01	20,03	30,17	1,25	36,71474
2003	123,308	35,25	1,84	20,86	30,23	1,27	35,11722
2004	187,365	34,42	2,61	20,90	29,63	1,15	34,49047
2005	249,293	35,20	2,03	20,08	29,26	1,07	27,57418
2006	314,603	33,73	3,80	21,17	28,91	1,07	25,98935
2007	405,794	30,16	4,30	24,16	28,82	1,12	26,77874
2008	511,323	31,31	4,50	25,50	28,66	1,04	28,20797
2009	358,565	27,94	2,99	18,93	27,50	1,25	26,46914
2010	457,469	29,22	2,83	22,62	27,74	1,13	24,01654
2011	601,779	28,06	2,69	24,26	27,45	1,02	22,17679
2012	642,677	26,91	2,29	24,55	27,77	1,03	23,65865
2013	646,277	25,85	3,02	23,27	27,73	1,03	22,83858
2014	575,178	27,11	1,07	22,39	27,52	1,07	21,67938
2015	406,237	28,70	0,50	22,15	27,18	1,10	27,95741
2016	372,488	25,85	2,55	23,10	26,95	1,10	29,92196
2017	482,859	26,09	1,81	23,61	26,97	1,11	28,44841
2018	539,532	30,79	0,53	21,92	26,81	0,99	26,08290
2019	544,345	28,43	1,89	22,66	26,78	1,04	27,45622
2020	443,699	25,52	0,63	23,46	26,50	1,09	28,27877
2021	581,425	30,00	2,21	23,01	26,62	0,96	29,98930

Таблица 3 / Table 3

Применение теста ADF для проверки гипотезы о наличии единичного корня во временном ряду

Application of the ADF test to verify the hypothesis of the presence of a unit root in a time series

Переменные	p-value (тест на единичный корень в исходной модели)	p-value (тест на единичный корень в модели первых разностей)	p-value (тест на единичный корень в модели вторых разностей)
Y	0,357	0,061	0,005
X1	0,414	0,011	0,024
X3	0,053	0,010	0,020
X6	0,168	0,059	0,004

ции между Y и X2 составляет всего 0,1, что свидетельствует о слабой линейной связи данного показателя с добавленной стоимостью — целесообразно исключить эту переменную из дальнейшего анализа для упрощения модели и повышения её интерпретируемости.

Следует отметить, что между переменными X1 и X4 наблюдается более высокая взаимосвязь, чем между каждой из этих переменных и целевой переменной Y. Такая ситуация указывает на наличие частичного дублирования информации: значительная часть вари-

ации X4 уже объясняется X1. При этом коэффициент корреляции между X4 и Y оказался ниже, чем между X1 и Y, что свидетельствует о меньшей объясняющей способности X4 в отношении целевой переменной. Именно её удаление позволит сохранить информативность модели и повысить устойчивость оценок.

Далее проведем оценку регрессионной модели по таким статистическим критериям, как значимость коэффициентов и коэффициент детерминации, при $\alpha = 0,05$. Переменные X3 и X5 обладают р-значени-

ем, равным 0,05738 и 0,0855 соответственно, что превышает порог значимости в $\alpha = 0,05$. Исходя из этого, переменные целесообразно исключить поочередно из модели и провести переоценку регрессионной зависимости.

Так, можно отметить, что модель с включенным X3 имеет более высокую объясняющую способность ($R^2 = 0,92349$) и статистическую значимость включённых переменных, что подтверждает её корректность и надёжность.

Для проверки гипотезы о наличии единичного корня во временном ряду был применен тест Дики-Фуллера (ADF). Для устранения проблемы нестационарности были применены первые и вторые разности. При этом, путем последовательного вычисления разностей второго порядка удалось убрать трендовую составляющую и преобразовать ряды в стационарные (табл. 3).

Для построения окончательной регрессионной модели было принято решение работать с преобразованными временными рядами, полученными посредством вторых разностей.

Регрессионный анализ, построенный на основе преобразованных рядов, показал, что переменные X1 и X6 не оказывают статистически значимого влияния на зависимую переменную Y. При этом общая объясняющая способность модели остаётся на высоком уровне ($R^2 = 0,71628$). В связи с этим, одну из переменных необходимо исключить из расчетной регрессии при $\alpha = 0,05$.

Вследствие комбинирования вариантов была пересчитана регрессионная модель, где зависимая переменная Y объясняется факторами X3 и X6. Все включённые факторы обладают статистической значимостью (p-value < 0,05) и приемлемым уровнем объясняющей способности ($R^2 = 0,716$).

Результаты проведенной проверки предпосылок МНК говорят о корректности новой спецификации (табл. 4).

Таким образом, с учетом вышеуказанных преобразований и уточнения модели, дальнейшее исследование проводится на основе зависимой переменной Y и факторов X3, X6. Проверка стационарности преобразованных рядов с помощью теста на единичный корень подтвердила, что после применения вторых разностей все ряды становятся стационарными.

Эмпирический анализ

На первом этапе прогнозируется значение добавленной стоимости производства (Y) на 2019–2021 гг. с использованием метода экстраполяции. Одновременно с этим производится экстраполяция значений независимых переменных (X) на тот же период. Полученные по методу экстраполяции прогнозные значения по X3, X6 затем используются в качестве входной выборки при построении двух следующих моделей для прогнозирования Y. Результаты экстраполирования приведены в табл. 5.

После получения прогнозных значений, рассчитанных на основе вторых разностей, необходимо выполнить обратное преобразование для восстановления исходного масштаба данных. Этот процесс включает двойное интегрирование: сначала выполняется суммирование вторых разностей для получения первого уровня изменений, а затем — накопление этих изменений с базовым уровнем исходного ряда. В итоге полученные значения снова отражают фактические уровни показателя Y в его первоначальном виде, что позволит сравнить полученные прогнозы с фактическими данными, проведенными в исходных единицах измерения (табл. 6).

Таблица 4 / Table 4

Проверка выполнения предпосылок МНК
Verification of the fulfilment of the prerequisites of the least squares' method

Предпосылка МНК	Значение (тест)	Вывод
Гетероскедастичность	p-value = 0,1953 (тест Глейзера)	Модель гомоскедастична
Автокорреляция первого порядка	DW stat = 2,0799	Отсутствует
Автокорреляция старших порядков	ACF и PACF	Отсутствует
Мультиколлинеарность	1 < VIF < 5	Умеренная
Распределение ошибок закону нормального распределения	p-value = 0,6503 (тест Харке-Бера)	Соответствует
Prob (F-stat)	0,0005	Значим, модель объясняет 71,6% вариации Y

Таблица 5 / Table 5

Экстраполирование включенных в модель показателей
Extrapolation of the indexes included in the model

Год	Y(f), млрд долл. США	X3(f), % от ВВП	X6(f), % экспорта промышленной продукции
2019	146,551	-1,135	-0,229
2020	63,015	-1,154	-0,311
2021	-73,707	-1,173	-0,394

Таблица 6 / Table 6

Сравнение полученных с помощью экстраполяции переведенных прогнозных значений и фактических значений результирующего показателя
Comparison of the interpreted forecast values obtained by extrapolation and the actual values of the resulting index

Год	Прогнозируемое значение Y, млрд долл. США	Фактическое значение Y, млрд долл. США
2019	742,7558	544,3449
2020	1008,995	443,6992
2021	1201,5276	581,4253

Таблица 7 / Table 7

Сравнение полученных с помощью построенной эконометрической модели переведенных прогнозных значений и фактических значений результирующего показателя
Comparison of the interpreted forecast values obtained using the constructed econometric model and the actual values of the resulting index

Год	Прогнозируемое значение Y (dd), млрд долл. США	Прогнозируемое значение Y, млрд долл. США	Фактическое значение Y, млрд. долл. США
2019	-21,9915	574,2131	544,3449
2020	-21,5671	587,3274	443,6992
2021	-21,1428	579,2989	581,4253

Полученные значения по методу экстраполяции показали, что прогнозные уровни Y для 2019–2021 гг. отличаются между собой, разрыв между фактическим и прогнозируемым значением Y увеличивается ежегодно. Модель экстраполяции не смогла корректно спрогнозировать уровень Y.

Следующий рассмотренный метод проводится на основе прогноза, построенного с помощью многофакторной эконометрической модели, учитывающий влияние независимых переменных (X3, X6). Так, значения экзогенных переменных за 2019-2021 гг. получены из экстраполирования (табл. 5).

В табл. 7 отражен получившийся прогноз $\hat{Y}$ как в форме вторых разностей, так и в переведенном виде.

Таким образом, эконометрическая модель показала значительно более высокую точность прогнозирования по сравнению с методом экстраполяции. Разрыв между прогнозными и фактическими значениями в первый год оказался минимальным, во второй — уже существенно возрос, а на третий год модель обеспечила практически полное совпадение с реальным значением показателя. Причины заметного увеличения расхождения во втором году будут рассмотрены позже.

Следующим этапом рассматривается применение LSTM-модели. Модель обучается, подстраивая свои веса так, чтобы минимизировать функцию потерь (mean_squared_error в данном случае). Используется оптимизатор (adam), чтобы улучшать процесс обучения. Для обучения модели использовался продукт Google Colab.

Рассмотрим модель с заданным $\text{look_back} = 3$. Значения экзогенных переменных за 2019–2021 гг. получены из экстраполирования (табл. 5). В табл. 8 отражен получившийся прогноз $\hat{Y}$ как в форме вторых разностей, так и в переведенном виде.

Для сравнения данной модели рассмотрим анализ LSTM с заданным $\text{look_back} = 7$. Результаты анализа приведены в табл. 9.

Таким образом, можно утверждать, что при использовании окна длиной в 7 временных шагов модель оказалась менее эффективной — прогнозы с таким параметром характеризуются чуть большим разбросом и менее точным отражением актуальной динамики ряда, чем в случае с более коротким окном, где look_back равен 3. Полученный результат во многом схож с прогнозом,

Таблица 8 / Table 8
Сравнение полученных с помощью LSTM-модели ($\text{look_back} = 3$) переведенных прогнозных значений и фактических значений результирующего показателя
Comparison of the interpreted forecast values obtained using the LSTM model ($\text{look_back} = 3$) and actual values of the resulting index

Год	Прогнозируемое значение $\hat{Y}$ (dd), млрд долл. США	Прогнозируемое значение $\hat{Y}$, млрд долл. США	Фактическое значение Y , млрд долл. США
2019	-15,66	580,5446	544,3449
2020	-19,74	601,8175	443,6992
2021	-27,28	595,8104	581,4253

Таблица 9 / Table 9
Сравнение полученных с помощью LSTM-модели ($\text{look_back} = 7$) переведенных прогнозных значений и фактических значений результирующего показателя
Comparison of the interpreted forecast values obtained using the LSTM model ($\text{look_back} = 7$) and actual values of the resulting index

Год	Прогнозируемое значение $\hat{Y}$ (dd), млрд долл. США	Прогнозируемое значение $\hat{Y}$, млрд долл. США	Фактическое значение Y , млрд долл. США
2019	-17,33	578,8746	544,3449
2020	-16,96	601,2575	443,6992
2021	-13,78	609,8804	581,4253

построенным на основе эконометрической модели, при этом 2020 год остаётся таким же проблемным периодом, характеризующимся наибольшим расхождением между прогнозными и фактическими значениями.

На основании проведённого анализа можно заключить, что как эконометрическая модель, так и LSTM-модель справились с прогнозированием показателя на 2019–2021 гг. значительно лучше, чем метод экстраполяции. При этом стоит учитывать высокую сложность задачи, обусловленную волнообразной динамикой результирующего показателя в 2002–2018 гг., связанной с последствиями финансово-экономического кризиса 2008–2010 гг. и валютного кризиса в России 2014–2015 гг. [12]. Несмотря на эти колебания, обе модели продемонстрировали хорошую способность воспринимать основные тенденции и формировать адекватные прогнозы.

Как уже отмечалось ранее, 2020 г. оказался наиболее трудным для прогнозирования

из-за наступившего коронавирусного периода: на фоне нарастающей добавленной стоимости модели не смогли предсказать столь резкий спад.

Особый интерес представляет оценка работы прогнозных моделей в период выхода страны из мирового экономического кризиса 2008–2010 гг., что приходится на 2011–2012 гг. Этот этап характеризовался восстановительным ростом, изменением структуры спроса и постепенной стабилизацией макроэкономических показателей.

Прогнозы строятся на основе данных за период 2002–2010 гг., после чего полученные результаты сопоставляются с фактическими значениями за 2011–2012 гг. В результате проведённого корреляционного и регрессионного анализа был осуществлён отбор факторов, оказывающих статистически значимое влияние на целевую переменную. В итоговую спецификацию модели вошли три экзогенные переменные — X_3 , X_4 и X_5 .

Для устранения трендовой составляющей были примене-

ны вторые разности, что позволило преобразовать X4 и X5 в стационарный вид.

Регрессионный анализ, проведенный на основе преобразованных рядов, показал, что переменные X4 и X5 оказывают статистически значимое влияние на зависимую переменную Y: их р-значения составляют 0,0261 и 0,012 соответственно, что не превышает порог значимости в $\alpha = 0,05$. А проведенные проверки подтвердили корректность спецификации и отсутствие нарушений ключевых предпосылок МНК, что обеспечивает надёжность полученных оценок.

Анализ результатов прогнозирования показал, что на отрезке 2011–2012 гг., соответствующем периоду выхода экономики России из мирового финансово-экономического кризиса 2008–2010 гг., наилучшие результаты продемонстрировала LSTM-модель (табл. 10). Её прогнозы наиболее точно отразили реальную траекторию восстановления показателя, причём во втором прогнозируемом году (2012) расхождение с фактическими данными оказалось минимальным — практически полное совпадение.

В то же время эконометрическая модель и метод экстраполяции показали менее удовлетворительные результаты. Оба метода спрогнозировали резкий и устойчивый рост показателя сразу после кризисного периода, что не соответство-

Сравнительный анализ примененных методов прогнозирования
Comparative analysis of the applied forecasting methods

Год	Фактическое значение Y, млрд. долл. США	Прогнозируемое значение Y, млрд. долл. США		
		экстраполяция	эконометрическая модель	LSTM
2011	601,7793	628,2191	637,2904	548,4728
2012	642,6768	875,1611	911,9462	654,4069

вало реальной посткризисной динамике, характеризовавшейся более умеренными темпами.

Выводы

Проведённое исследование подтвердило, что процесс прогнозирования неизбежно сталкивается с проблемой влияния внешних факторов, которые трудно формализовать и учесть в рамках модели. Эти факторы, носящие зачастую внезапный и масштабный характер, способны существенно исказить траекторию развития показателя, что особенно ярко проявилось в 2020 г. Данный период, совпавший с глобальным кризисом, вызванным пандемией COVID-19, стал испытанием для всех рассмотренных методов прогнозирования: ни одна из моделей не смогла точно воспроизвести резкий спад, однако эконометрическая модель и LSTM-модель продемонстрировали более адекватную реакцию, корректно зафиксировав замедление темпов роста показателя по сравнению с предыдущими годами.

Отдельного внимания заслуживает анализ посткризисного периода восстановления

экономики после мирового финансово-экономического кризиса 2008–2010 гг. На интервале 2011–2012 гг. наилучшие результаты показала LSTM-модель, обеспечив практически полное совпадение прогнозных и фактических значений.

Сопоставление результатов по двум проведённым анализам позволяет сделать вывод, что LSTM-модель продемонстрировала наибольшую устойчивость и точность прогнозирования в различных экономических условиях. При этом эконометрическая модель также показала высокую эффективность, особенно в части корректного отражения замедления темпов роста в кризисные периоды. Тем не менее, при условии отсутствия в будущем значимых внешних шоков, способных радикально изменить траекторию развития экономики, LSTM-модель с оптимально подобранными параметрами может рассматриваться как приоритетный инструмент прогнозирования, обеспечивающий баланс между точностью, адаптивностью и способностью учитывать сложную динамику исследуемого показателя.

Литература

1. Григорьев А.Н. Добавленная стоимость через призму новой политэкономии // Символ науки. 2021. № 3. С. 56–61.
2. Terence C., Mills. A Very British Affair. Six Britons and the Development of Time Series Analysis During the 20th Century. UK: Loughborough University, 2013. 437 с. DOI: 10.1057/9781137291264.
3. Wichern D. W. Forecasting: Methods and Applications by Spyros Makridakis, Steven C. Wheelwright // Journal of the American Statistical

Association. 1979. № 74(367). С. 733–734. DOI: 10.2307/2287014.
4. Stock J. H., Watson M. W. Vector Autoregressions // Journal of Economic Perspectives. 2001. № 15(4). С. 101–115. DOI: 10.1257/jep.15.4.101.
5. Stock J. H., Watson M. W. Forecasting Output and Inflation: The Role of Asset Prices // Journal of Economic Literature. 2003. № 41(3). С. 788–829. DOI: 10.1257/002205103322436197.
6. Hochreiter S., Schmidhuber J. Long Short-Term Memory // Neural Comput. 1997. № 9(8). С. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735.

7. Fischer T., Krauss C. Deep learning with long short-term memory networks for financial market predictions // *European Journal of Operational Research*. 2018. № 270(2). С. 654–669. DOI: 10.1016/j.ejor.2017.11.054.

8. Siami Namini, S. A Comparison of ARIMA and LSTM in Forecasting Time Series // 17th IEEE International Conference on Machine Learning and Applications (ICMLA). 2018. DOI: 10.4108/EAI.13-7-2018.161409.

9. Котова Т.Н., Хачатурян Р.Е. Методы прогнозной экстраполяции в техническом сервисе // *Достижения вузовской науки*. 2014. № 8. С. 242–249.

10. Розенцвайг А.К. Методы эконометри-

ческого моделирования и анализа социально-экономических явлений. Набережные Челны: Набережночелнинский институт Казанского федерального университета, 2014. 121 с. DOI: 10.13140/RG.2.1.3998.5526.

11. Козлов С.В., Седенков С.А. Анализ LSTM и GRU моделей для построения прогнозов временных рядов // *International Journal of Open Information Technologies*. 2024. № 7. С. 43–50.

12. Шихалиева Д.С., Беляева С.В. Траектория экономических кризисов в России в период становления и развития рыночной экономики: оценка, эволюция, управление // *Вестник университета*. 2021. № 12. С. 144–150. DOI: 10.26425/1816-4277-2021-12-144-150.

References

1. Grigor'yev A.N. Added Value through the Prism of the New Political Economy. *Simvol nauki = Symbol of Science*. 2021; 3: 56–61. (In Russ.)

2. Terence C., Mills. A Very British Affair. Six Britons and the Development of Time Series Analysis During the 20th Century. UK: Loughborough University; 2013. 437 p. DOI: 10.1057/9781137291264.

3. Wichern D. W. Forecasting: Methods and Applications by Spyros Makridakis, Steven C. Wheelwright. *Journal of the American Statistical Association*. 1979; 74(367): 733–734. DOI: 10.2307/2287014.

4. Stock J. H., Watson M. W. Vector Autoregressions. *Journal of Economic Perspectives*. 2001; 15(4): 101–115. DOI: 10.1257/jep.15.4.101.

5. Stock J. H., Watson M. W. Forecasting Output and Inflation: The Role of Asset Prices. *Journal of Economic Literature*. 2003; 41(3): 788–829. DOI: 10.1257/00220510322436197.

6. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Comput*. 1997; 9(8): 1735–1780. DOI: 10.1162/neco.1997.9.8.1735.

7. Fischer T., Krauss C. Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*. 2018; 270(2): 654–669. DOI: 10.1016/j.ejor.2017.11.054.

8. Siami Namini, S. A Comparison of ARIMA and LSTM in Forecasting Time Series. 17th IEEE International Conference on Machine Learning and Applications (ICMLA). 2018. DOI: 10.4108/EAI.13-7-2018.161409.

9. Kotova T.N., Khachatryan R.Ye. Methods of Predictive Extrapolation in Technical Service. *Dostizheniya vuzovskoy nauki = Achievements of University Science*. 2014; 8: 242–249. (In Russ.)

10. Rozentsvayg A.K. Metody ekonometricheskogo modelirovaniya i analiza sotsial'no-ekonomicheskikh yavleniy = Methods of Econometric Modeling and Analysis of Socio-Economic Phenomena. *aberezhnye Chelny: Naberezhnye Chelny Institute of Kazan Federal University*; 2014. 121 p. DOI: 10.13140/RG.2.1.3998.5526. (In Russ.)

11. Kozlov S.V., Sedenkov S.A. Analysis of LSTM and GRU Models for Constructing Time Series Forecasts. *International Journal of Open Information Technologies = International Journal of Open Information Technologies*. 2024; 7: 43–50. (In Russ.)

12. Shikhaliyeva D.S., Belyayeva S.V. The Trajectory of Economic Crises in Russia during the Formation and Development of a Market Economy: Assessment, Evolution, Management. *Vestnik universiteta = Bulletin of the University*. 2021; 12: 144–150. DOI: 10.26425/1816-4277-2021-12-144-150. (In Russ.)

Сведения об авторах

Елена Михайловна Карпенко

Д.э.н., профессор

Белорусский государственный университет,
Минск, Республика Беларусь

Эл. почта: emkarpenko@mail.ru

Иван Валерьевич Берестень

Студент

Белорусский государственный университет,
Минск, Республика Беларусь

Эл. почта: vanekberesten@mail.ru

Information about the authors

Elena M. Karpenko

Dr Sci. (Economics), Professor

Belarussian State University,
Minsk, Republic of Belarus

Email: emkarpenko@mail.ru

Ivan V. Beresten

Student

Belarussian State University,
Minsk, Republic of Belarus

Email: vanekberesten@mail.ru