

УДК 311: 336.14 DOI: 10.14451/1.255.460

Эконометрическое моделирование динамики доходов консолидированного бюджета Российской Федерации

© 2026 Цыпин Александр Павлович

Кандидат экономических наук, доцент, доцент кафедры бизнес-аналитики, Факультет налогов, аудита и бизнес-анализа. Финансовый университет при Правительстве РФ, Москва, Россия.
E-mail: aptsy-pin@fa.ru

Ключевые слова: консолидированный бюджет, доходы, динамика, моделирование, искусственные нейронные сети, прогноз.

Актуальность выбранной темы исследования заключается в том, что анализ динамики доходов консолидированного бюджета позволяет не только констатировать текущее или прошлое состояние, но и прогнозировать, планировать и корректировать социально-экономический курс Российской Федерации в условиях глобальной нестабильности, обеспечивая тем самым ее экономическую безопасность и устойчивое развитие. Таким образом, выбор модели, наилучшим образом подходящей для построения надежного прогноза, является одной из актуальных задач статистической науки. Применение к временному ряду доходов консолидированного бюджета трех конкурирующих методик моделирования позволяет сделать следующие выводы: эконометрические модели дают менее успешную аппроксимацию в отличие от искусственных нейронных сетей; в свою очередь прогноз, полученный на основе многослойного перцептрона, признан наихудшим, что объясняется архитектурой выбранной нейросети, не способной учитывать предыдущие состояния.

Введение

Изучение динамики доходов консолидированного бюджета Российской Федерации имеет ключевое значение для обеспечения финансовой стабильности, эффективного управления ресурсами и устойчивого социально-экономического развития страны. Так, динамика консолидированного бюджета напрямую отражает изменения деловой активности российских компаний, уровень прибыльности организаций и рост доходов населения страны. Помимо этого, динамика доходов бюджета указывает на степень адаптации экономической системы страны

к внешним (внутренним) шокам, особенно это актуально в свете санкций 2014 и 2022 гг. А также она характеризует процесс импортозамещения и переориентации внешней торговли.

В свою очередь моделирование временного ряда доходов консолидированного бюджета позволяет строить реалистичные прогнозы в краткосрочной перспективе [5], что формирует понимание уровня успешности страновых инфраструктурных проектов.

Несмотря на актуальность выбранной темы, обращение к российскому сектору научных

публикаций не выявляет значительного количества работ в этом направлении. В частности, можно выделить лишь несколько публикаций, заслуживающих внимание. Так, в исследовании Михиной Е. В. [6] проводится структурно-динамический анализ консолидированного бюджета на интервале 2021–2023 гг. В публикации Забниной Г. Г. [3] также рассматривается структура бюджета в 2020–2022 гг. Оценке структурных подвижек посвящена работа под руководством Давтаевой З. Р., основным выводом которой является – «в период с 2018 г. по 2022 г. осуществлен поворот России в сторону диверсификации доходной части бюджета» [2]. К сожалению, период анализа, используемый указанными авторами, незначителен, что не позволяет оценить воздействие кризисов (шоков) на динамику консолидированного бюджета и построить надежные прогнозы. В проводимом нами исследовании заполним имеющийся пробел и применим к временному ряду доходов бюджета ряд эконометрических методов и методов машинного обучения для получения прогнозов на 2025 г.

Материалы и методы

Источником информации динамики доходов консолидированного бюджета Российской Федерации послужили данные, публикуемые Росстатом в бюллетени «Краткосрочные экономические показатели Российской Федерации» [4].

Относительно самих данных необходимо сделать замечание. Так, временной ряд в бюллетени представлен нарастающим итогом с начала года, соответственно чтобы привести его в нормальную для анализа форму необходимо сделать пересчет.

В качестве конкурирующих моделей в работе использовались: множественное линейное уравнение с нелинейным трендом и сезонными фиктивными переменными, трехпараметрическая модель экспоненциального сглаживания, модель, основанная на многослойном перцептроне (MLP – англ. Multilayer Perceptron).

Также стоит отметить, что основы подходов к моделированию и прогнозированию макроэконо-

мических индикаторов (в том числе на основе искусственных нейронных сетей) были обнаружены нами в более ранних публикациях [7; 8].

Результаты исследования

Первым делом проведем визуализацию анализируемого временного ряда, и построим линейную диаграмму, для этого используем функцию `tidyplot{tidyplots}` среды программирования R (рис. 1).

Приведенная на рисунке динамика анализируемого показателя дает нам понимание наличия долговременного повышающегося тренда, при этом можно выделить два периода развития – до 2020 года и после этой временной точки. Данные отрезки развития временного ряда отличаются разной скоростью, при этом во втором подпериоде угол наклона больше чем в первом.

Сезонная компонента, в первом приближении, не обнаруживается. При этом амплитуда колебаний к концу временного ряда увеличивается, что указывает на мультипликативный тип сезонности.

Для точной идентификации компонент (составляющих) ряда воспользуемся процедурой BV4, которая используется Федеральным статистическим управлением Германии для декомпозиции (разделения) и сезонной корректировки временных рядов [10]. Эта процедура реализована в функции `BV4.1{deseats}` среды программирования R (рис. 2).

Сделанные выше предположения подтверждаются. Так наблюдается нелинейная долговременная тенденция (Trend). Также фиксируем мультипликативная сезонность (Seasonality) с увеличением амплитуды колебаний к концу ряда.

Идентифицированные компоненты учтем в построении эконометрических моделей. Так в трендовой модели с сезонными фиктивными переменными используем параболу второго порядка для описания долговременной составляющей.

Для оценки параметров эконометрической модели используем метод наименьших квадратов.

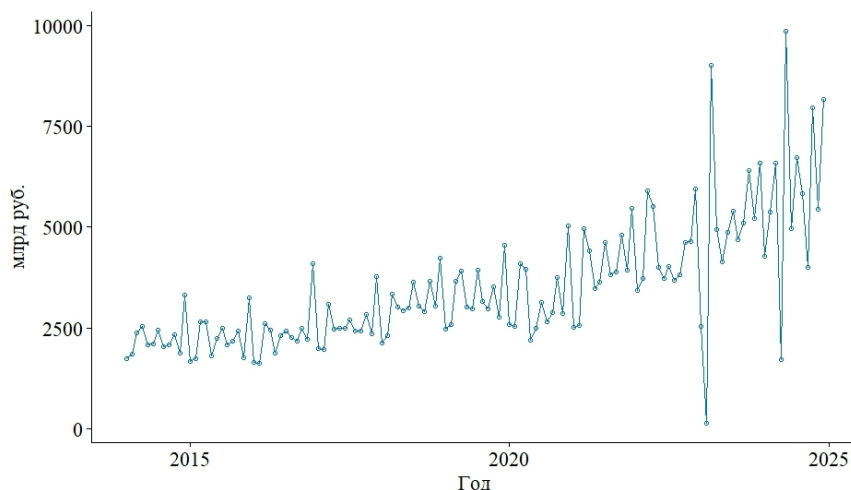


Рис. 1. Динамика доходов консолидированного бюджета Российской Федерации, млрд руб.




Рис. 2. Декомпозиция временного ряда консолидированного бюджета Российской Федерации (Примечание: Observations – фактические данные; Trend – долговременная компонента; Seasonality – сезонная компонента; Rest – случайная компонента).

Реализация этого подхода в среде программирования R осуществляется с помощью базовой функции `lm{stats}`. В итоге работы алгоритма получаем результаты моделирования, приведенные в таблице 1.

Приведенные в таблице 1 характеристики показывают, что модель статистически значима в целом (F-статистика получена высокой при низком значении p-уровня). При этом 74,0% колебаний анализируемого ряда описывается моделью.

Также необходимо обратиться к оценке средней абсолютной относительной ошибки (MAPE), которая призвана оценивать уровень аппроксимации модели. В случае параболы с сезонными значениями статистики равно 35,230%, что выше допустимого уровня в 10%, отсюда делаем вывод о неудовлетворительном качестве подгонки предсказанных уровней к фактическим.

Отдельно стоит указать на статистическую незначимость коэффициентов при переменных t и Z_3 , что объясняется значительным нарастанием амплитуды колебаний после 2022 года.

Таблица 1. Характеристики эконометрической модели с нелинейным трендом и сезонными фиктивными переменными.

Показатели	Оценки коэффициентов (b_j)	Стандартная ошибка коэффициентов b_j	t-уровень Стьюдента	p-уровень значимости
Св. член	3601,12	334,77	10,76	0,000
t	-4,27	7,77	-0,55	0,584
t ²	0,25	0,06	4,42	0,000
Z ₁	-2180,53	360,51	-6,05	0,000
Z ₂	-2255,68	360,40	-6,26	0,000
Z ₃	-293,01	360,30	-0,81	0,418
Z ₄	-1292,82	360,21	-3,59	0,000
Z ₅	-1293,15	360,14	-3,59	0,000
Z ₆	-1604,93	360,07	-4,46	0,000
Z ₇	-1023,19	360,01	-2,84	0,005
Z ₈	-1582,79	359,96	-4,40	0,000
Z ₉	-1724,06	359,93	-4,79	0,000
Z ₁₀	-812,05	359,90	-2,26	0,026
Z ₁₁	-1630,74	359,88	-4,53	0,000

Примечание: $R^2 = 0,740$; $F_{\text{факт}} = 25,850$, $p < 0,000$.

Также необходимо обратить внимание на значения коэффициентов при фиктивных сезонных переменных. В нашем случае они все получены отрицательными, то есть уровни базового месяца (декабрь) во всех имеющихся периодах выше остальных. Этот факт логичен, так как в конце года закрывается финансовый год, соответственно активизируются все бизнес-процессы и растут денежные потоки.

Далее рассмотрим построение трехпараметрической модели экспоненциального сглаживания (модель Хольта-Виверса) [1]. Для этого используем функцию `hw{forecast}`. Результатом работы алгоритма являются характеристики модели, приведенные на рисунке 3.

Среди приведенных на рисунке 3 характеристик трехпараметрической модели экспоненциального сглаживания прежде всего нас интересует значение MAPE = 30,937. Как видно оно получено

ниже чем в предыдущем случае, но по-прежнему указывает на неудовлетворительную аппроксимацию.

Далее перейдем к многослойному перцептронному, который состоит из входа (подаются исходные уровни временного ряда), выхода (выводятся предсказанные уровни динамического ряда) и несколько скрытых слоев (рис. 4).

В среде программирования R существуют несколько библиотек, в которых реализуются нейронные сети применительно к моделированию и прогнозированию динамических рядов. Остановимся на функции `m1p{nnfor}`, которая отражает нейронную сеть прямого распространения сигнала (без обратных связей).

Результаты тестирования моделей, в том числе многослойного перцептрона, приведем в таблице 2.

```

Holt-winters' multiplicative method

Call:
hw(y = ts.y, h = 12, seasonal = "multiplicative")

Smoothing parameters:
alpha = 0.0412
beta  = 0.0032
gamma = 0.0001

Initial states:
l = 2266.1761
b = 4.0114
s = 1.3679 0.9042 1.1687 0.9075 0.9324 1.0853
      0.9135 1.0866 0.9413 1.3007 0.6933 0.6985

sigma: 0.2149

      AIC      AICC      BIC
2380.863 2386.231 2429.870

Training set error measures:
      ME      RMSE      MAE      MPE      MAPE      MASE      ACF1
Training set 121.0014 798.0432 491.6506 -16.42552 30.93663 0.7464336 -0.2126916

```

Рис. 3. Характеристики модели Хольта-Виверса для временного ряда доходов консолидированного бюджета Российской Федерации.

Таблица 2. Сравнительная характеристика прогнозов доходов консолидированного бюджета Российской Федерации.

Статистики	Параболический тренд с сезонными фиктивными переменными	Модель Хольта-Винтерса	MLP
ME	-0,000	121,001	-0,879
RMSE	797,978	798,043	159,014
MAE	460,061	491,651	117,699
MPE	-23,418	-16,426	0,429
MAPE	35,230	30,937	4,379
MASE	0,383	0,746	–

Примечание: ME – средняя ошибка; RMSE – квадратный корень из среднеквадратичной ошибки; MAE – средняя абсолютная ошибка; MSPE – среднеквадратичная ошибка в процентах; MAPE – средняя абсолютная ошибка в процентах; MASE – средняя абсолютная масштабированная ошибка.

Согласно приведенным в таблице 2 метрикам, наилучшие результаты показывает искусственная нейронная сеть. К примеру, RMSE и MAPE получены наименьшими из трех конкурирующих моделей. Таким образом, можно сделать вывод, что многослойный перцептрон (MLP) осуществил наилучшую аппроксимацию, то есть расхождения между фактическими и предсказанными значениями по этой подде- минимальны.

Далее перейдем к сопоставлению прогнозов по всем трем моделям (табл. 3). Но прежде стоит отметить, что искусственная нейронная сеть не продуцирует доверительных интервалов прогнозов.




Рис. 4. Структура многослойного перцептрона (MLP), использованного для моделирования уровней временного ряда доходов консолидированного бюджета Российской Федерации.

Таблица 3. Сравнительные характеристика фактических уровней доходов консолидированного бюджета и прогнозов по трем конкурирующим моделям.

Период	Факт	Параболический тренд с сезонными фиктивными переменными			Модель Хольта-Винтерса			MLP
		точечный прогноз	ниж. дов. граница	верх. дов. граница	точечный прогноз	ниж. дов. граница	верх. дов. граница	
янв.25	4876,6	5276,2	4613,2	5939,1	5198,0	3439,4	6956,5	6710,9
фев.25	3662,5	5263,5	4592,4	5934,6	5212,0	3449,5	6974,4	7371,6
мар.25	8950,0	7289,2	6609,5	7968,8	7394,3	5627,5	9161,2	7780,5
апр.25	6903,0	6352,9	5664,5	7041,2	6348,2	4576,3	8120,1	3008,2
май.25	5250,7	6416,5	5719,1	7113,9	6457,2	4679,5	8234,8	9468,7
июн.25	4167,6	6169,2	5462,6	6875,9	6178,6	4394,6	7962,6	6103,3
июл.25	8221,4	6816,0	6099,8	7532,1	6795,1	5004,0	8586,3	7975,7
авг.25	6198,8	6321,9	5596,0	7047,8	6346,9	4548,0	8145,9	6482,4
сен.25	6067,4	6246,6	5510,7	6982,5	6445,0	4637,4	8252,6	5042,7
окт.25	–	7225,1	6479,0	7971,2	7185,9	5368,9	9002,9	8666,6
ноя.25	–	6473,4	5717,0	7229,9	6569,2	4741,9	8396,5	5859,1
дек.25	–	8171,7	7404,6	8938,7	8152,9	6314,5	9991,3	7844,5

Имеющиеся в нашем распоряжении фактические уровни временного ряда доходов консолидированного бюджета за 2025 г. позволяют осуществить сопоставление их с точечными прогнозами по трем моделям.

Точечные прогнозы по регрессионной трендовой модели и модели Хольта-Винтерса схожи (расхождения минимальны), при этом в прогнозе прослеживается сезонная волна синхронная с фактическими уровнями. Недостатком

прогноза по этим моделям является более сдержанный характер колебаний, то есть фактические уровни проявляют большую глубину флуктуаций.

В свою очередь, прогноз по MLP характеризуется значительными перепадами уровней, но не «улавливают» сезонную составляющую. В итоге наблюдаем значительные расхождения между фактом и прогнозом в 2025 г.

Более формализованный подход к сопоставлению факта и прогноза дает коэффициент (индекс) Тейла (U_1). Значения данной статистики находятся в интервале от 0 до 1, при этом нижний предел указывает на равенство всех фактических уровней модельным, то есть $y_t = y'_t$. Тогда как близость к верхнему пределу указывает на полное неравенство.

Оценим значения U_1 -статистики на основе данных, представленных в таблице 3. Для этих целей используем функцию `TheilU{DescTools}` среды программирования R. В итоге работы алгоритма получаем следующие значения индекса: $U_1(LMS) = 0,097$; $U_1(HW) = 0,095$; $U_1(MLP) = 0,190$.

Как и ожидалось, значения коэффициента Тейла по регрессионной модели и модели Хольта-Винтерса схожи и близки к нулю, что указывает на хорошее качество прогноза. Тогда как значение по третьей модели (многослойный перцептрон) получено более высоким, но также близко к нулю, нежели к единице, соответственно данный прогноз также можно признать удовлетворительным.

Выводы

Подводя итог проведенного исследования, посвященного моделированию и прогнозированию

сложного временного ряда доходов консолидированного бюджета Российской Федерации, можно сделать ряд выводов.

Во-первых, анализируемый временной ряд содержит сезонную мультипликативную компоненту и нелинейный тренд. Этот факт объясняется влиянием на механизм генерации уровней санкционного кризиса и требует особого подхода к моделированию сложной динамики ряда.

Во-вторых, оценка аппроксимирующих свойств трех конкурирующих моделей показала, что наилучшие результаты дает модель, основанная на многослойном перцептронном, то есть фактические уровни временного ряда на интервале 2014–2024 гг. практически совпадают с предсказанными (модельными) значениями.

В-третьих, несмотря на высокие аппроксимирующие свойства искусственной нейронной сети, модель продуцирует худший вариант прогноза из трех рассмотренных моделей. В частности, она не учитывает сезонную компоненту в результате чего фактические значения за 2025 г. находятся в противофазе по отношению к прогнозам, полученным на основе многослойного перцептрона.

Подводя итог, стоит указать на тот факт, что искусственные нейронные сети прямого распространения показывают отличные аппроксимирующие свойства, но при этом выдают высокие ошибки прогноза. По-видимому, необходимо обратить свое внимание на другие виды архитектуры нейросетей, которые учитывают («запоминают») предыдущие состояния, что очень важно при анализе временных рядов.

Библиографический список

1. *Атчаде М. Н.* Адаптивные методы прогнозирования: реализация в Excel и программе R : учебное пособие. – СПб. : Санкт-Петербургский государственный экономический университет, 2018. – 101 с.
2. *Давтаева З. Р., Насуханова М. Р., Межиева А. И.* Специфика и особенности структуры и динамики доходов консолидированного бюджета в России // Экономика и управление: проблемы, решения. – 2023. – Т. 1, 11(140). – С. 138–146. – DOI: [10.36871/ek.up.p.r.2023.11.01.013](https://doi.org/10.36871/ek.up.p.r.2023.11.01.013).
3. *Забнина Г. Г., Краснокутская Н. С., Люлина Т. В.* Влияние санкций на исполнение консолидированных бюджетов субъектов РФ // Дневник науки. – 2023. – 5(77). – URL: <https://dnevniknauki.ru/index.php/articlecategories/economy> (дата обр. 01.02.2026).

4. Краткосрочные экономические показатели Российской Федерации / Росстат. – URL: <https://rosstat.gov.ru/compendium/document/50802> (дата обр. 01.02.2026).
5. Лосева А. В. Статистическое исследование налогового потенциала регионов России : дис. ... канд. экономических наук : 08.00.12 / Лосева Анна Валериевна. – Новосибирск, 2011. – 300 с.
6. Михина Е. В. Налоговые доходы бюджета в условиях внешнесанкционного давления на российскую экономику // Инновации и инвестиции. – 2025. – № 8. – С. 574–578.
7. Цыпин А. П. Изучение динамики среднедушевых доходов с использованием статистических методов: анализ временных рядов // Учет. Анализ. Аудит. – 2025. – Т. 12, № 1. – С. 46–61. – DOI: [10.26794/2408-9303-2025-12-1-46-61](https://doi.org/10.26794/2408-9303-2025-12-1-46-61).
8. Цыпин А. П. Статистический анализ динамики грузооборота коммерческого транспорта в России // Вопросы региональной экономики. – 2025. – 1(62). – С. 235–243.
9. Imanbayeva Z., Mussirov G., Nurgaliyeva A. Enhancing Agricultural Efficiency and Land Resource Management through Information Systems // Qubahan Academic Journal. – 2024. – Vol. 4, no. 2. – P. 342–354. – DOI: [10.48161/qaj.v4n2a543](https://doi.org/10.48161/qaj.v4n2a543). – EDN EWOMFJ.
10. Komponentenzerlegung und Saisonbereinigung ökonomischer Zeitreihen mit dem Verfahren BV4.1 / Statistisches Bundesamt (Destatis). – URL: https://www.destatis.de/DE/Methoden/Saisonbereinigung/BV41-methodenbericht-Heft3_2004.html?nn=352030 (visited on 02/01/2026).