

DOI: 10.26794/2587-5671-2025-29-1-20-33

УДК 336.25,330.11(045)

JEL G17, G32, H61

Перспективные модели финансового прогнозирования доходов бюджета

А.К. Караев, О.В. Борисова

Финансовый университет, Москва, Россия

АННОТАЦИЯ

Предметом исследования является выбор модели финансового прогнозирования доходов бюджета, позволяющей наиболее корректно провести оценку и получить прогнозное значение на следующий период. **Целью** исследования является выявление перспективных моделей финансового прогнозирования доходов бюджета РФ. Применяемые с 60-х гг. XX в. DSGE-модели не смогли выявить целый ряд кризисов и своевременно предсказать уровень изменения государственных доходов в США, Еврозоне, России, что не позволило оперативно корректировать политику, проводимую в области управления государственными доходами. **Новизна исследования** состоит в выявлении недостатков современной методологии финансового прогнозирования, связанных с устареванием используемых подходов и необходимостью поиска новых моделей, позволяющих оперативно уточнять прогностические результаты. В исследовании использовались такие **методы**, как: измерение прогнозных величин и размера их ошибок, анализ и сравнение результатов, полученных по методам и моделям машинного и глубокого обучения. **В результате** исследования прогностических методов и моделей машинного и глубокого обучения, используемых в реальном бизнесе, на фондовом рынке и в государственных финансах, были отобраны наиболее перспективные из них. Основными критериями отбора послужили: возможность моделирования нелинейных связей параметров, оперативность расчета, минимальность ошибки, отсутствие проблемы с переобучением. В процессе исследования была выявлена целесообразность проведения декомпозиции временных рядов, что позволило минимизировать прогностические ошибки и выбрать наиболее точную из моделей для прогнозирования доходов бюджета РФ. Результаты исследования могут быть использованы для формирования системы прогнозных показателей, применяемых для разработки системы дашбордов для государственных служащих с целью повышения точности и оперативности принимаемых ими решений.

Ключевые слова: прогнозная модель; финансовое прогнозирование; прогнозирование доходов бюджета; нейронные сети; вивлет-преобразование

Для цитирования: Караев А.К., Борисова О.В. Перспективные модели финансового прогнозирования доходов бюджета. *Финансы: теория и практика*. 2025;29(1):20-33. DOI: 10.26794/2587-5671-2025-29-1-20-33

ORIGINAL PAPER

Prospective Models of Financial Forecasting of Budget Revenues

A.K. Karaev, O.V. Borisova

Financial University, Moscow, Russia

ABSTRACT

The **subject** of the study is the choice of a model for financial forecasting of budget revenues, which allows the most correct assessment and obtaining a forecast value for the next period. The **purpose** of the study is to identify promising models of financial forecasting of budget revenues of the Russian Federation. DSGE models used since the 60s of the twentieth century have failed to identify a number of crises and timely predict the level of changes in government revenues in the United States, the Eurozone, and Russia, which did not allow for prompt adjustment of the policy pursued in the field of public revenue management. The **novelty of the study** consists in identifying the shortcomings of the modern methodology of financial forecasting associated with the obsolescence of the approaches used and the need to search for new models that allow you to quickly refine the prognostic results. The study used such **methods** as measuring predictive values and the size of their errors, analyzing and comparing the results obtained using methods and models of machine and deep learning. As a **result** of the study of predictive methods and models of machine and deep learning used in real business, the stock market and public finance, the most promising of them were selected. The main selection criteria were the possibility of modeling nonlinear relationships of parameters, the efficiency of calculation, the minimality of error, and the absence of a problem with retraining. In the course of the study, the expediency of time series decomposition was revealed, which made it possible to minimize predictive errors and choose the most accurate model for forecasting budget revenues of the Russian Federation. The results of the study can be used to form a system

© Караев А.К., Борисова О.В., 2025

of predictive indicators used to develop a dashboard system for civil servants in order to improve the accuracy and efficiency of their decisions.

Keywords: predictive model; financial forecasting; budget revenue forecasting; neural networks; vivlet transformation

For citation: Karaev A.K., Borisova O.V. Prospective models of financial forecasting of budget revenues. *Finance: Theory and Practice*. 2025;29(1):20-33. (In Russ.). DOI: 10.26794/2587-5671-2025-29-1-20-33

ВВЕДЕНИЕ

Существенное изменение мировой экономической и политической ситуации приводит к необходимости оперативного реагирования на происходящие трансформации. Цифровизация значительного количества процессов в национальной экономике, повышение уровня нестабильности, оперативное развитие технологий ставят принципиально новые задачи перед системой государственного управления. В результате появилась острая потребность в методах, позволяющих оперативно прогнозировать ключевые финансовые показатели в государственном секторе для принятия на их основе управленческих решений в режиме реального времени.

В значительном количестве российских исследований основное внимание уделялось вопросам планирования бюджетных показателей на основе норм Бюджетного кодекса РФ [1, с. 186], оценки достоверности прогнозов [2, с. 2020], их когнитивного моделирования [3, с. 179], а также качества прогнозирования [4, с. 40]. Активно разрабатываются вопросы выбора методологического аппарата для осуществления прогнозирования основных индикаторов [5, с. 599]. Доказано [6, с. 5], что для целей прогнозирования макроэкономических индикаторов возможно применение значительного количества методов. Часть методов предполагает использование большого количества данных, макроэкономических и финансовых показателей, которые имеют разный уровень доступности. Другие, наоборот, показывают хорошие результаты в условиях ограниченной выборки. Ряд показателей является высокочастотным, иные не обладают таким свойством. Активно развивается в последнее время парадигма машинного и глубокого обучения. Представленный в работе анализ и сравнение моделей позволит отобрать наиболее перспективные из них для использования в прогностических целях.

Цель статьи — определить наиболее перспективные методы прогнозирования доходов бюджета РФ. Для ее достижения:

- проведен обзор исследований, показывающих ключевые причины, стимулирующие переход от DSGE к альтернативным моделям;
- определены основные прогностические методы, дана их характеристика;
- представлен процесс выбора модели для прогнозирования бюджетных показателей.

ПРИЧИНЫ ПЕРЕХОДА ОТ DSGE К МОДЕЛЯМ МАШИННОГО ОБУЧЕНИЯ

Сегодня для прогнозирования используют DSGE-модели, которые активно критикуются за: нестабильность результатов, повышенную чувствительность к качеству данных, невозможность учета неравномерности загрузки производственных мощностей и степени их обновления [7, с. 205]; сложность реализации в связи с отсутствием нелинейного характера тренда; опору на гипотезу о рациональных ожиданиях, несмотря на то, что доказано формирование волн оптимизма и пессимизма, связанных с иррациональностью принятия решений и др. [8, с. 125]. Имеются исследования, обобщающие отдельные критические замечания по модели DSGE [9, с. 77]. В них представлены основные причины, способствующие переходу к альтернативным моделям прогнозирования в государственном секторе. Авторы указывают на затруднение объяснения продолжительности и глубины рецессий. Активно развивающиеся DSGE-модели не смогли предсказать ряд кризисных явлений и последствия пандемии (2007, 2008, 2020 гг. и др.) из-за необходимости регулярной калибровки моделей, поверхностных результатов оценки, плохо улавливающих изменения тенденций на рынке. В начале 2000-х гг. появились исследования, в рамках которых осуществляется прогнозирование бюджетных доходов методами авторегрессии, моделью смешанных данных и др. [10]. В прогнозе макроэкономических показателей начинают использовать векторную авторегрессию, интегрированную модель авторегрессии — скользящего среднего, резервуарные вычисления [6]. Это приводит к появлению у центральных банков, министерства финансов ряда стран альтернативных вариантов прогностических моделей,

основанных на методах и алгоритмах машинного (ML) и глубокого машинного обучения (DL). Они сокращают использование статистических (эконометрических) моделей, дающих неплохие результаты при наличии линейных связей между показателями, поскольку те не позволяют уловить значительную часть сигналов [11, с. 187]. Эти модели демонстрируют чувствительность к взаимосвязям между показателями, требуют исключения мультиколлинеарности и гетероскедастичности, оценки автокорреляции остатков, демонстрируя высокую прогностическую способность при прогнозировании доходов бюджетов в стабильной ситуации.

В большинстве стран временной ряд для прогнозирования государственных доходов ограничен 30–40 годами, а в моделях существует необходимость учета значительного количества факторов. Эти аспекты учтены в методах и алгоритмах машинного и глубокого обучения, чья эффективность зависит от размера выборки. Их применение предполагает настройку параметров и гиперпараметров, влияющих на качество модели. На текущий момент они признаются одними из самых перспективных.

ФИНАНСОВОЕ МОДЕЛИРОВАНИЕ ДОХОДОВ БЮДЖЕТА: ПОСЛЕДОВАТЕЛЬНОСТЬ И ВЫБОР МОДЕЛИ

Определение базы финансового прогнозирования доходов бюджета

Этап предполагает сбор данных для прогнозирования и размещение их в единой базе. Это позволяет повысить скорость обработки данных, что отражается на оперативности процесса моделирования. Данная база содержит три уровня согласно архитектуре ANSI-SPARC: пользовательский, концептуальный и внутренний. Техническое описание физической реализации базы выходит за пределы данного исследования.

Модели глубокого и машинного обучения, тестируемые для прогнозирования доходов бюджета: характеристика, достоинства и недостатки

В исследовании протестированы модели и алгоритмы машинного и глубокого обучения (табл. 1), которые работают с данными при наличии определенного типа шума, могут определить и учесть нелинейные связи между отдельными группами данных, свободны от учета мультиколлинеарности. Сравнительная харак-

теристика моделей представлена в табл. 2. Понимание механизма работы модели позволяет учесть необходимые для конкретной ситуации особенности обработки информации при прогнозировании государственных доходов, а гиперпараметры — настроить ее.

Для повышения точности прогнозов используется декомпозиция временных рядов. В ее рамках временной ряд подразделяется на несколько компонентов: тренд, сезонность, цикличность, остатки или «шум». Декомпозиция временных рядов позволяет: разделять необработанные данные на различные компоненты для повышения качества анализа с учетом времени, выявлять аномалии, проводить визуализацию данных, повысить качество прогнозирования временных рядов.

К недостаткам метода относят:

- необходимость предположений о компонентах, которые могут быть нарушены изменением динамики и внешними факторами;
- необходимость выявления данных, искажающих тенденцию, снижающих точность декомпозиции и влияющих на надежность компонентов;
- возможность получения низкого качества прогнозной модели при использовании стандартных методов декомпозиции;
- нецелесообразность использования подхода для нерегулярных или зашумленных данных;
- зависимость точности полученных прогнозных результатов от правильного выбора значений параметров [12].

Тренд представляет долгосрочное движение или общее направление, в котором анализируемые данные увеличиваются, уменьшаются или стабилизируются с течением времени. При этом могут использоваться разные тенденции: восходящие, нисходящие, неизменные. Их понимание позволит определить общую траекторию движения данных.

Цикличность представляет повторяющиеся закономерности, не имеющие фиксированного периода. Тренд и циклическую компоненту обычно объединяют в одну тренд-циклическую компоненту. Конкретные функциональные взаимосвязи между этими компонентами имеют разный вид.

Сезонность позволяет выявить повторяющиеся закономерности или колебания данных, происходящие через определенные промежутки времени, например, ежемесячные, ежеквартальные или годовые циклы. В нашем случае влияние оказывает время года, поскольку денежный поток

Таблица 1 / Table 1

**Сравнительная характеристика методов и моделей машинного обучения /
Comparative Characteristics of Machine Learning Methods and Models**

Критерии сравнения / Comparison criteria	Линейные и обобщенные регрессионные модели / Linear and generalized regression models	Деревья решений / Decision trees	Случайный лес / Random Forest	К-ближайшие соседи / K-nearest neighbors	Машины опорных векторов / Support Vector machines	Нейронные сети / Neural networks	Наивный Байес / Naive Bayes	Градиентный бустинг / Gradient boosting	Экстремальный градиентный бустинг / Extreme gradient boosting
Возможность прогнозирования временного ряда	+	+	+	+	+	+	+	+	+
Необходимость учета эффекта коллинеарности переменных	+	–	–	–	–	–	–	–	–
Возможность выявления и учета нелинейных связей	+	+	+	+	+	+	+	+	+
Построение классификации по данным, характеризующимся определенным типом шума	–	–	–	–	–	–	+	+	+
Трудоемкость в обучении модели	–	–	–	–	–	+	–	+	–
Сложность интерпретации результатов расчетов	–	–	–	–	+	+	+	+	+

Источник / Source: разработано авторами / Developed by the authors.

зависит от обязательств, налагаемых налоговым кодексом и иными нормативными документами и др. Выявление этих закономерностей позволяет корректнее осуществить процесс прогнозирования и описать цикличность данных.

Остатки представляют оставшиеся случайные вариации или отклонения в данных после выявления трендовых, циклических и сезонных компонент. Они являются шумом. Их невозможно предсказать во временных рядах. Проводимая оценка необходима для понимания общей изменчивости данных.

Для разложения временных рядов принято использовать методы: классической декомпози-

ции, разложения скользящего среднего, сезонное и трендовое разложение с использованием LOESS, сингулярный спектральный анализ, сезонного извлечения во временных рядах ARIMA. После проведения вычислений все элементы временного ряда объединяются, что позволяет повысить качество прогноза.

Для очистки временного ряда от шумов и случайных выбросов в работе будет использован метод вивлет-преобразований. Он позволяет осуществить фильтрацию и предварительно обработать данные, которые впоследствии будут использованы для построения прогноза.

**Характеристика моделей, используемых в расчетах для прогнозирования доходов бюджета РФ /
Characteristics of the Models Used in Calculations for Forecasting Budget Revenues of the Russian Federation**

Наименование модели / Name of the model	Механизм работы модели / The mechanism of operation of the model	Гиперпараметры / Hyperparameters	Достоинства модели / Advantages of the model	Тип модели / Model Type
Gradient Boosting Regressor	Суть алгоритма: создание леса с фиксированным количеством деревьев решений. Подбор модели начинается с определения среднего значения целевых показателей. Далее добавляется прогноз, полученный за счет последующих деревьев. На следующих этапах деревья решений подбираются для прогнозирования отрицательных градиентов выборок. Градиенты обновляются в каждом итераторе	• Количество деревьев; • максимальная глубина дерева; • скорость масштабирования; • функция потерь	• Применим для слабо обучающихся и слабо прогнозирующих моделей	Ансамблевая модель
CatBoost Regressor	Строится на предположении среднего значения целевой переменной. Предполагает формирование ансамбля деревьев решений. Каждое новое дерево минимизирует ошибки или остатки предыдущих. Деревья выращиваются путем введения правила: все узлы на одном уровне проверяются одним и тем же предиктором с одним и тем же условием. Индекс листа вычисляется при помощи побитовых операций	• Глубина дерева; • скорость обучения; • количество итераций	• Имеет расширенные функции по сравнению с алгоритмами Gradient и XGBoost, увеличивающие его надежность, скорость и точность; используется для интеграции типов данных в единую структуру, категориальных функций и обработки нечисловых значений; • имеет открытый исходный код	Экстремальный градиентный бустинг
Extra Trees Regressor	В расчетах применяют исходный набор данных. Выбор точек «разреза» для разделения узлов осуществляется случайным образом. С помощью алгоритма определяется лучший из подмножеств признаков, что позволяет при добавлении рандомизации сохранить оптимизацию в модели	• Количество функций, учитываемых в каждом узле принятия решений; • минимальное количество выборок для узла; • количество деревьев в лесу	• Используется для повышения производительности расчетов; имеет простой алгоритм построения деревьев решений; содержит незначительное количество ключевых гиперпараметров, простых в настройке; характеризуется низкой систематической ошибкой и высокой скоростью подбора модели	Метод случайного леса, дерева решений

Продолжение таблицы 2 / Table 2 (continued)

Наименование модели / Name of the model	Механизм работы модели / The mechanism of operation of the model	Гиперпараметры / Hyperparameters	Достоинства модели / Advantages of the model	Тип модели / Model Type
LSTM	Архитектура модели состоит из входного, скрытого и выходного слоя. Они регулируют состояние и отклик ячейки. Входные и выходные слои регулируют чтение и доступ на запись, скрытый – сбрасывает содержимое ячеек памяти, как только оно устаревает. Состояние ячейки обновляется при поступлении информации. Алгоритм обучения в модели является локальным в пространстве и времени. Он обучается преодолевать минимальные временные задержки, превышающие 1000 дискретных временных шагов	• Стандартная ячейка; • количество эпох; • функция g, регулирующая входные данные ячейки; • функция h, регулирующая выходные данные ячейки	• Позволяет решать сложные задачи с длительным запаздыванием; • улучшает качество модели, составленной на основе нестационарных данных за счет их предобработки; • приводит к улучшению результатов моделирования при совместном использовании со сверточными нейронными сетями; • позволяет не проводить тесты на стационарность, сезонность и др.	Нейронная сеть
Gated Recurrent Units	Основу модели составляют два вектора, определяющие тип информации, передающейся на выход. Особенностью векторов является возможность хранения старой информации. Ворота обновления определяют объем предшествующей информации. Они определяются текущим вводом и предшествующим скрытым состоянием, выраженным функцией активации сигмовидной формы. Выходные значения вентиля обновления находятся между 0 и 1. Ворота сброса оценивают размер проигнорированной информации. Вентиль сброса определяет значения, используя текущий ввод и предыдущее скрытое состояние, выраженное функцией активации сигмовидной формы. Скрытое состояние определяется после вычисления вентилей обновления и сброса. Оно представляет собой новую информацию. Далее «расчетное состояние» объединяется с предыдущим скрытым. В результате формируется текущее скрытое состояние, комбинирующее старую и новую информацию. Применение ворот обновления и сброса позволяет решить проблему исчезающего градиента рекуррентной нейронной сети	Размер входного вектора; размер скрытого слоя	• Улавливает зависимости за счет использования в модели ретроспективной информации из массива данных; • решает проблему с исчезающим градиентом; • имеет простую модификацию в отличие от Lstm; • позволяет получить качественные результаты при наличии небольшой выборки; • имеет меньше параметров, чем Lstm; • требует незначительные вычислительные мощности	Нейронная сеть

Окончание таблицы 2 / Table 2 (continued)

Наименование модели / Name of the model	Механизм работы модели / The mechanism of operation of the model	Гиперпараметры / Hyperparameters	Достоинства модели / Advantages of the model	Тип модели / Model Type
N-BEATS	Архитектура модели формируется путем объединения блоков в иерархическую структуру. В разветвленной архитектуре блоки характеризуются полносвязными уравнениями. На входе каждый блок получает данные. На выходе из него формируется два сигнала: 1) прямой прогноз; 2) обратный прогноз. Каждый блок получает данные, генерирует прогноз и осуществляет обратное преобразование. Входные данные следующего блока формируются вычитанием выходных данных обратного прогноза предшествующего блока и его входных данных. Полученный остаток обрабатывается сетью. Прогнозы блоков объединяются в окончательном результате — общем прогнозе	• Горизонт планирования; • функция потерь; • количество прошлых лагов модели; • целочисленные значения для каждого типа стека (сезонность, тренд, идентичность); • целочисленное значение, определяющее количество гармонических членов для типа стека сезонности; • целочисленное значение, для степени полинома тренда; • категориальное значение, определяющее тип нормализации; • значение с плавающей запятой, представляющее скорость обучения для процесса оптимизации модели	• Имеет прозрачную структуру модели и высокую интерпретируемость результатов; • характеризуется повышенной производительностью, высокой точностью и незначительным временем обучения по сравнению с другими архитектурами глубокого обучения	Нейронная сеть

Источник / Source: [10, 13–18].

Каждый из методов и алгоритмов целесообразно использовать для прогноза изучаемых временных рядов. Они отличны по степени изученности, точности получаемых с их помощью прогностических результатов, возможности учета отдельных особенностей временного ряда.

ВЫБОР ПРОГНОСТИЧЕСКОЙ МОДЕЛИ

Выбор моделей прогнозирования доходов бюджета, рассчитанных авторами, осуществляется на основе ряда критериев. К ним относят: точность аппроксимации; перекрестную проверку; экспертную оценку.

Для обоснования используемых в работе критериев был изучен ряд исследований. В каждом из них были использованы перекрестная проверка и метод экспертной оценки. Значительные отличия в исследованиях [10, 13, 19–22] были связаны с показателями, на основе которых происходит выбор модели. В результате определены ошиб-

ки, которые использовались для выбора модели прогнозирования доходов бюджета РФ.

РЕЗУЛЬТАТЫ ФИНАНСОВОГО МОДЕЛИРОВАНИЯ ДОХОДОВ БЮДЖЕТА РФ

Выбор методов и алгоритмов в исследовании определен необходимостью ухода от соблюдения стационарности временных рядов. Расчеты проведены в Python и Wolfram Mathematica 12.0. Модели построены на основе 80%-ной используемой выборки. Остальные 20% выборки были оставлены для проверки качества полученных прогнозов. В качестве регрессора в моделях использовались ежемесячные доходы бюджета. Результаты представлены в табл. 3.

Критерием выбора прогностической модели является минимальная величина ошибок (MAE, RMSE, MAPE). Для моделей глубокого обучения учитывалось значение коэффициента детерминации (R^2).

Таблица 3 / Table 3

Ошибки и коэффициент детерминации прогнозных моделей доходов бюджета РФ / Errors and Coefficient of Determination of Forecast Models of Budget Revenues of the Russian Federation

№ п/п	Наименование модели / Name of the model	MAE	RMSE	MAPE	R2
1	Модели машинного обучения				
1.1	CatBoost Regressor	57,87	70,32	0,24	–
1.2	Gradient Boosting Regressor	61,41	76,17	0,25	–
1.3	Extra Trees Regressor	71,15	82,36	0,27	–
2	Модели глубокого обучения				
2.1	Gated Recurrent Units, GRU	131	168	17	0,66
2.2	LTSM	119	144	17	0,69
2.3	N-BEATS	92	115	14	0,76

Источник / Source: расчет сделан авторами на основе данных Минфина России / The calculation was made by the authors based on data from the Ministry of Finance of the Russian Federation. URL: <https://minfin.gov.ru/ru/statistics/fedbud> (дата обращения: 24.03.2024) / (accessed on 24.03.2024).




Рис. 1 / Fig. 1. Прогноз доходов бюджета с использованием модели CatBoost / Budget Revenue Forecast Using the Catboost Model

Источник / Source: разработано авторами / Developed by the authors.

Среди моделей машинного обучения наилучшие результаты показал алгоритм CatBoost Regressor. Размер трех ошибок по алгоритму минимален. Среди моделей глубокого обучения минимальные ошибки у N-BEATS. Коэффициент детерминации у этой модели наиболее высок. Далее проведено сравнение по размеру ошибок между CatBoost Regressor и N-BEATS. Выявлено преимущество первого алгоритма. Прогнозы доходов бюджета, полученные по тестовым выборкам, показали, что CatBoost Regressor хорошо прогнозирует обучающую выборку, четко улавливает динамику изменений, но не работает на тестовой выборке (рис. 1). Видно, что прогноз (красная линия тренда) в 2021–2023 гг., сделанный на тестовой выборке, существенно отличается от фактических доходов федерального бюджета (синяя линия тренда), де-

монстрируя переобучение модели. Следовательно, ее использование для формирования прогнозной модели требует коррекции. В следующих исследованиях будут протестированы нормализованные выборки, прошедшие предобработку данных, за счет приведения к первым разностям, логарифмам первых разностей, ценам 2011 г., а также протестированы модели с перенастроенными гиперпараметрами (табл. 2).

Прогноз по модели N-BEATS показывает, что она лучше улавливает тренд на тестовой выборке (2021–2023 гг.) (рис. 2). Отклонения прогноза (красная линия тренда) от фактического значения доходов федерального бюджета незначительны (синяя линия тренда). Они укладываются в доверительный интервал (представленный бледно-красной границей). Прогностическая способность




Рис. 2 / Fig. 2. Прогноз доходов бюджета с использованием модели N-BEATS / Budget Revenue Forecast Using the N-BEATS Model

Источник / Source: разработано авторами / Developed by the authors.

модели выше. Модель ошибается осенью 2022 г. при наличии аномального поведения данных. Это связано со значительным ростом внутреннего производства и резким снижением доходов от импорта, поскольку, с одной стороны, активизировалась политика импортозамещения, а с другой — были введены против России санкционные ограничения. Также отметим рост волатильности прочих доходов в этот период.

Прогнозные значения укладываются в доверительный интервал, автокорреляция остатков отсутствует. Следовательно, модель N-BEATS целесообразно применять для прогнозирования в государственном секторе, что доказывает выдвинутую гипотезу.

Далее рассмотрим подход, позволяющий минимизировать прогностические ошибки.

Неоднозначность полученных результатов привела авторов к необходимости использования процедуры предварительной декомпозиции временного ряда, которая была протестирована на доходах бюджетов субъектов РФ, взятых за период с 01.2013 по 03.2023 г. Источником данных является сайт Казначейства России¹.

В исследовании использовались агрегированные значения доходов консолидированных бюд-

жетов субъектов РФ. В дальнейшем планируется разработать модели прогнозирования доходов бюджетов конкретных субъектов РФ. Краткосрочное прогнозирование поступлений доходов в течение финансового года, на ежемесячной основе, является основным вкладом в эффективное управление денежными средствами казначейства (Treasury Cash Management). Сезонный характер этих поступлений должен соответствовать запланированным выплатам бюджетной поддержки расходным обязательствам в течение финансового года², а также необходимости привлечения краткосрочного финансирования для покрытия любого краткосрочного дефицита бюджета. Ожидаемый сезонный характер сбора доходов также имеет ключевое значение для мониторинга целевых показателей сбора доходов в течение финансового года.

Их прогноз с использованием процедуры предварительной декомпозиции временного ряда путем дискретного вейвлет-преобразования (семейства *ReverseBiorthogonalSplineWavelet*) позволил выявить высокую прогностическую точность модели ($R^2 = 99,9\%$).

Было протестировано несколько различных семейств вейвлетов. В расчетах применялась процедура построения прогнозов на основе интерпо-

¹ Федеральное казначейство. Консолидированные бюджеты субъектов Российской Федерации и бюджетов территориальных государственных внебюджетных фондов. URL: <https://roskazna.gov.ru/ispolnenie-byudzhetrov/konsolidirovannye-byudzhety-subektov/> (дата обращения: 24.03.2024).

² Основные направления бюджетной, налоговой и таможенно-тарифной политики на 2024 год и на плановый период 2025 и 2026 годов: утв. Минфином России. URL: https://www.consultant.ru/document/cons_doc_LAW_429950/ (дата обращения: 24.03.2024).




Рис. 3 / Fig. 3. Реальные и прогнозные ежемесячные агрегированные доходы бюджетов субъектов РФ / Real and Projected Monthly Aggregated Revenues of the Budgets of the Subjects of the Russian Federation

Источник / Source: разработано авторами / Developed by the authors.

Примечание / Note: синей линией представлены реальные данные (период 01.2013–03.2023 гг.), желтой – прогнозные значения (период 03.2021–03.2023 гг.). Исследование проведено в 2023 г. с использованием имевшихся на то время исходных данных / The blue line represents real data (period 01.2013–03.2023), the yellow line represents predicted values (period 03.2021–03.2023). The study was conducted in 2023 using the initial data available at that time.

ляции и экстраполяции данных временного ряда. Расчеты сделаны с использованием декомпозиции ряда на основе DWT. Наиболее высокая точность прогноза получена с использованием семейства ReverseBiorthogonalSplineWavelet 8,8. Результаты приведены на рис. 3.

При сравнении N-BEATS и модели, построенной на основе процедуры предварительной декомпозиции временного ряда путем дискретного вейвлет-преобразования по критерию R^2 , очевидно преимущество последней. Следовательно, выдвинутая авторами гипотеза доказана. Метод обладает наиболее высоким прогностическим потенциалом.

Использование предлагаемой модели позволит государственным служащим принимать ответственные и обоснованные решения.

Модели прогнозирования доходов служат трем взаимосвязанным, но различным бюджетным целям. Во-первых, они востребованы при составлении среднесрочных бюджетов (как федерального бюджета, так и бюджетов субъектов); во-вторых, для краткосрочного управления денежными средствами в течение финансового года; и, в-третьих, для прогнозирования расходов.

Обоснованные прогнозы доходов необходимы для достижения устойчивого финансирования государственных проектов и программ и во избежание крупных незапланированных и, возможно,

неприемлемых бюджетных дефицитов, которые могут возникнуть в течение следующего года.

Важным аспектом прогнозирования доходов является его связь с краткосрочной и среднесрочной стабильностью бюджета. Предвзятость в отношении оптимизма доходов и политическое давление с целью расходования бюджетных сумм или сверх них, как правило, приводят к тому, что дефицит превышает целевые уровни. Поэтому политика сбора доходов и стратегии прогнозирования должны быть скоординированы со стратегиями управления бюджетом, чтобы лучше учитывать изменчивость расходов и доходов как в краткосрочной, так и в среднесрочной перспективе.

ВЫВОДЫ

Финансовое прогнозирование является одним из наиболее важных аспектов в условиях роста нестабильности и увеличивающегося санкционного давления. Вклад данного исследования состоит, во-первых, в попытке использовать альтернативные DSGE методы и модели, чтобы минимизировать выявленные слабые места. Во-вторых, работа позволяет сравнить методы и модели машинного и глубокого обучения для выявления наиболее перспективных из них для дальнейшего использования. Выявлены отдельные аспекты, которые необходимо учитывать при выборе моделей для расчета. В-третьих, в исследовании

показана целесообразность использования метода N-BEATS при осуществлении финансового прогнозирования доходов бюджета. Доказана эффективность применения процедуры предварительной декомпозиции нестационарного нелинейного временного ряда с использованием дискретных вейвлет-преобразований. Используемая при прогнозировании процедура позволила повысить его точность с 65–80 до 99%. При этом выбор наиболее точного метода осуществлялся с применением традиционного подхода.

В исследовании имеются ограничения. Во-первых, сравниваемые методы и модели используются в прогностических целях для прогнозирования доходных показателей бюджета с января 2011 г., что связано с ограниченностью данных о ежемесячных доходах федерального бюджета, представленных Минфином России. Во-вторых, для прогноза использовались исключительно открытые данные с официальных источников. В-третьих, расчеты проводились на ежемесячных данных, поскольку разрабатываемые модели предполагали получение прогноза в режиме реального времени. Это позволило обучить модель и протестировать ее качество. Для показателей иной периодичности

модели не тестировались вследствие значительного уменьшения объема выборки, что негативно могло отразиться на их прогностической силе.

Полученные авторами результаты указывают на необходимость дальнейших исследований. Необходимо поиск повышения точности прогнозов показателей федерального бюджета Российской Федерации. Для этого целесообразно протестировать предварительную декомпозицию временных рядов с дискретными вейвлет-преобразованиями из различных семейств.

В перспективе целесообразно разработать систему прогнозных методов и моделей, использующих машинное обучение для прогнозирования агрегированных статей доходов и расходов федерального и региональных бюджетов с целью формирования на их основе системы дашбордов. Это позволило бы государственным служащим в режиме реального времени получать информацию о прогнозных показателях для принятия на их основе управленческих решений по перераспределению финансирования отдельных мероприятий в рамках национальных проектов в РФ, распределению имеющихся финансовых ресурсов на будущий год и др.

БЛАГОДАРНОСТИ

Статья подготовлена по результатам исследований, выполненных за счет бюджетных средств по государственному заданию Финансовому университету на 2023 г. Финансовый университет, Москва, Россия.

ACKNOWLEDGEMENTS

The article was prepared based on the results of research carried out at the expense of budgetary funds according to the state assignment of the Financial University for 2023. Financial University, Moscow, Russia.

СПИСОК ЛИТЕРАТУРЫ

1. Ширинов С. Э. Роль и значение финансовых нормативов в прогнозировании налоговых поступлений в бюджет. *Экономика и бизнес: теория и практика*. 2021;(5–3):186–189. DOI: 10.24412/2411–0450–2021–5–3–186–189
2. Федотов Д. Ю. Анализ прогнозирования налоговых доходов федерального бюджета России. *Финансы и кредит*. 2017;23(34):2016–2031. DOI: 10.24891/fc.23.34.2016
3. Джу О. С. Прогнозирование устойчивости бюджетной системы в условиях развития интеграционных процессов с применением метода когнитивного моделирования. *Вестник Ростовского государственного экономического университета (РИНХ)*. 2021;(3):177–185.
4. Барбашова Н. Е., Комарницкая А. Н. Мировой опыт долгосрочного бюджетного прогнозирования: национальный и региональный аспекты. *Финансы: теория и практика*. 2021;25(6):40–53. DOI: 10.26794/2587–5671–2021–25–6–40–53
5. Макеева Н. М., Станкевич И. П. Наукастинг элементов использования ВВП России. *Экономический журнал Высшей школы экономики*. 2022;26(4):598–622. DOI: 10.17323/1813–8691–2022–26–4–598–622
6. Ballarin G., Dellaportas P., Griliryeva L., Hirt M., van Huellen S., Ortega J.-P. Reservoir computing for macroeconomic forecasting with mixed-frequency data. *International Journal of Forecasting*. 2024;40(3):1206–1237. DOI: 10.1016/j.ijforecast.2023.10.009

7. Кравцов М.К., Лазовский В.Г., Федченко Л.В. Прогнозирование макропоказателей белорусской экономики на основе динамической балансово-эконометрической межотраслевой модели. *Экономика, моделирование, прогнозирование*. 2018;(12):202–219.
8. Серков Л.А. Критический подход к анализу проблем динамических стохастических моделей общего равновесия. *Экономика и бизнес: теория и практика*. 2015;(8):122–126.
9. Storm S. Cordon of conformity: Why DSGE models are not the future of macroeconomics. *International Journal of Political Economy*. 2021;50(2):77–98. DOI: 10.1080/08911916.2021.1929582
10. Ghysels E., Ozkan N. Real-time forecasting of the US federal government budget: A simple mixed frequency data regression approach. *International Journal of Forecasting*. 2015;31(4):1009–1020. DOI: 10.1016/j.ijforecast.2014.12.008
11. Борисова О.В. Применимость авторегрессии для моделирования бюджетных показателей. *РИСК: ресурсы, информация, снабжение, конкуренция*. 2023;(3):184–190. DOI: 10.56584/1560-8816-2023-3-184-190
12. Choubey P. Time series decomposition. WallStreetMojo. Nov. 26, 2023. URL: <https://www.wallstreetmojo.com/time-series-decomposition/> (дата обращения: 24.12.2023).
13. Горшенин А. К., Кузьмин В. Ю. Анализ конфигураций LSTM-сетей для построения среднесрочных векторных прогнозов. *Информатика и ее применения*. 2020;14(1):10–16. DOI: 10.14357/19922264200102
14. Alsharef A., Aggarwal K., Sonia, Kumar M., Mishra A. Review of ML and AutoML solutions to forecast time-series data. *Archives of Computational Methods in Engineering*. 2022;29(7):5297–5311. DOI: 10.1007/s11831-022-09765-0
15. Alam B. CatBoost algorithm: Supervised machine learning in Python. Hands-On.Cloud. Apr. 28, 2022. URL: <https://hands-on.cloud/catboost-algorithm-supervised-machine-learning-in-python/> (дата обращения: 24.06.2024).
16. Filho M. Multiple time series forecasting with N-BEATS in Python. Forecastegy. Jun. 02, 2023. URL: <https://forecastegy.com/posts/multiple-time-series-forecasting-nbeats-python/> (дата обращения: 24.06.2024).
17. Gers F.A., Schmidhuber J., Cummins F. Learning to forget: Continual prediction with LSTM. *Neural Computation*. 2000;12(10):2451–2471. DOI: 10.1162/089976600300015015
18. Oreshkin B.N., Carpov D., Chapados N., Bengio Y. N-beats: Neural basis expansion analysis for interpretable time series forecasting. In: 8th Int. virtual conf. on learning representations — ICLR 2020 (April 26–May 01, 2020). Appleton, WI: ICLR; 2020:1–31. URL: <http://mapdic.com/upload/2022/07/param-a3aa083f4dc74071814b8986acf28c71.pdf>
19. Рапаков Г.Г., Горбунов В.А., Дианов С.В., Елизарова Л.В. Исследование LSTM-нейросетевого подхода при моделировании временных рядов. *Вестник Череповецкого государственного университета*. 2023;(3):47–54. DOI: 10.23859/1994-0637-2023-3-114-4
20. Фокин Н., Полбин А. VAR-LASSO модель для прогнозирования ключевых макроэкономических показателей России. *Деньги и кредит*. 2019;(2):67–93. DOI: 10.31477/rjmf.201902.67
21. Фокин Н.Д. VAR-LASSO модель на большом массиве российских экономических данных. *Экономическое развитие России*. 2019;26(1):20–30.
22. Bollt E.M. On explaining the surprising success of reservoir computing forecaster of chaos? The universal machine learning dynamical system with contrast to VAR and DMD. *Chaos*. 2021;31(1). DOI: 10.1063/5.0024890

REFERENCES

1. Shirinov S.E. Role and significance of financial standards in forecasting tax revenues to the budget. *Ekonomika i biznes: teoriya i praktika = Economy and Business: Theory and Practice*. 2021;(5–3):186–189. (In Russ.). DOI: 10.24412/2411-0450-2021-5-3-186-189
2. Fedotov D. Yu. An analysis of tax revenues forecasting of the Russian federal budget. *Finansy i kredit = Finance and Credit*. 2017;23(34):2016–2031. (In Russ.). DOI: 10.24891/fc.23.34.2016
3. Dzh O.S. Forecasting the sustainability of budgetary system in conditions of development of integration processes using the method of cognitive modeling. *Vestnik Rostovskogo gosudarstvennogo ekonomicheskogo universiteta (RINKh) = Vestnik of Rostov State University of Economics*. 2021;(3):177–185. (In Russ.).

4. Barbashova N. E., Komarnitskaya A. N. World experience of long-term budget forecasting: National and regional aspects. *Finance: Theory and Practice*. 2021;25(6):40–53. DOI: 10.26794/2587–5671–2021–25–6–40–53
5. Makeeva N., Stankevich I. Nowcasting of the components of Russian GDP. *Ekonomicheskii zhurnal Vysshei shkoly ekonomiki = The HSE Economic Journal*. 2022;26(4):598–622. (In Russ.). DOI: 10.17323/1813–8691–2022–26–4–598–622
6. Ballarin G., Dellaportas P., Griliryeva L., Hirt M., van Huellen S., Ortega J.-P. Reservoir computing for macroeconomic forecasting with mixed-frequency data. *International Journal of Forecasting*. 2024;40(3):1206–1237. DOI: 10.1016/j.ijforecast.2023.10.009
7. Kravtsov M. K., Lazovski V. G., Fedchenko L. V. Forecasting of the macroeconomic indicators of the Belarusian economy on the basis of the dynamic balance-econometric interindustry model. *Ekonomika, modelirovanie, prognozirovanie*. 2018;(12):202–219. (In Russ.).
8. Serkov L. A. Critical approach to the analysis of the problems of dynamic stochastic general equilibrium model. *Ekonomika i biznes: teoriya i praktika = Economy and Business: Theory and Practice*. 2015;(8):122–126. (In Russ.).
9. Storm S. Cordon of conformity: Why DSGE models are not the future of macroeconomics. *International Journal of Political Economy*. 2021;50(2):77–98. DOI: 10.1080/08911916.2021.1929582
10. Ghysels E., Ozkan N. Real-time forecasting of the US federal government budget: A simple mixed frequency data regression approach. *International Journal of Forecasting*. 2015;31(4):1009–1020. DOI: 10.1016/j.ijforecast.2014.12.008
11. Borisova O. V. Applicability of autoregression for modeling budget indicators. *RISK: resursy, informatsiya, snabzhenie, konkurentsia = RISK: Resources, Information, Supply, Competition*. 2023;(3):184–190. (In Russ.). DOI: 10.56584/1560–8816–2023–3–184–190
12. Choubey P. Time series decomposition. WallStreetMojo. Nov. 26, 2023. URL: <https://www.wallstreetmojo.com/time-series-decomposition/> (accessed on 24.12.2023).
13. Gorshenin A. K., Kuzmin V. Yu. Analysis of configurations of LSTM networks for medium-term vector forecasting. *Informatika i ee primeneniya = Informatics and Applications*. 2020;14(1):10–16. (In Russ.). DOI: 10.14357/19922264200102
14. Alsharef A., Aggarwal K., Sonia, Kumar M., Mishra A. Review of ML and AutoML solutions to forecast time-series data. *Archives of Computational Methods in Engineering*. 2022;29(7):5297–5311. DOI: 10.1007/s11831–022–09765–0
15. Alam B. CatBoost algorithm: Supervised machine learning in Python. Hands-On.Cloud. Apr. 28, 2022. URL: <https://hands-on.cloud/catboost-algorithm-supervised-machine-learning-in-python/> (accessed on 24.06.2024).
16. Filho M. Multiple time series forecasting with N-BEATS in Python. Forecastegy. Jun. 02, 2023. URL: <https://forecastegy.com/posts/multiple-time-series-forecasting-nbeats-python/> (accessed on 24.06.2024).
17. Gers F. A., Schmidhuber J., Cummins F. Learning to forget: Continual prediction with LSTM. *Neural Computation*. 2000;12(10):2451–2471. DOI: 10.1162/089976600300015015
18. Oreshkin B. N., Carpov D., Chapados N., Bengio Y. N-beats: Neural basis expansion analysis for interpretable time series forecasting. In: 8th Int. virtual conf. on learning representations — ICLR 2020 (April 26–May 01, 2020). Appleton, WI: ICLR; 2020:1–31. URL: <http://mapdic.com/upload/2022/07/param-a3aa083f4dc74071814b8986acf28c71.pdf>
19. Rapakov G. G., Gorbunov V. A., Dianov S. V., Elizarova L. V. Research of the LSTM neural network approach in time series modeling. *Vestnik Cherepovetskogo gosudarstvennogo universiteta = Cherepovets State University Bulletin*. 2023;(3):47–54. (In Russ.). DOI: 10.23859/1994–0637–2023–3–114–4
20. Fokin N., Polbin A. Forecasting Russia's key macroeconomic indicators with the VAR-LASSO model. *Russian Journal of Money and Finance*. 2019;78(2):67–93. (In Russ.: *Den'gi i kredit*. 2019;(2):67–93. DOI: 10.31477/rjmf.201902.67).
21. Fokin N. D. VAR-LASSO model for the Russian economy using a large dataset. *Ekonomicheskoe razvitiye Rossii = Russian Economic Development*. 2019;26(1):20–30. (In Russ.).
22. Bollt E. M. On explaining the surprising success of reservoir computing forecaster of chaos? The universal machine learning dynamical system with contrast to VAR and DMD. *Chaos*. 2021;31(1). DOI: 10.1063/5.0024890

ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS



Алан Канаматович Караев — доктор экономических наук, профессор, главный научный сотрудник Института исследований социально-экономических трансформаций и финансовой политики, Финансовый университет, Москва, Россия

Alan K. Karaev — Dr. Sci. (Econ.), Prof., Chief Researcher at the Institute for Research on Socio-Economic Transformations and Financial Policy, Financial University, Moscow, Russia

<http://orcid.org/0000-0002-5120-7816>

akkaraev@fa.ru



Ольга Викторовна Борисова — кандидат экономических наук, доцент, доцент кафедры корпоративных финансов и корпоративного управления, Финансовый университет, Москва, Россия

Olga V. Borisova — Cand. Sci. (Econ.), Assoc. Prof., Department of Corporate Finance and Corporate Governance, Financial University, Moscow, Russia

<https://orcid.org/0000-0002-7889-2745>

Автор для корреспонденции / Corresponding author:

OLVBorisova@fa.ru

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Conflicts of Interest Statement: The authors have no conflicts of interest to declare.

Статья поступила в редакцию 18.06.2023; после рецензирования 25.07.2023; принята к публикации 27.08.2023.

Авторы прочитали и одобрили окончательный вариант рукописи.

The article was submitted on 18.06.2023; revised on 25.07.2023 and accepted for publication on 27.08.2023.

The authors read and approved the final version of the manuscript.