pISSN 2071-4688
eISSN 2311-8709

Бюджетно-налоговая система

ПРОГНОЗИРОВАНИЕ ФИНАНСОВОГО ОБЕСПЕЧЕНИЯ ГОСУДАРСТВЕННЫХ УЧРЕЖДЕНИЙ С ПРИМЕНЕНИЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА НА ПРИМЕРЕ МУЗЕЕВ

DOI: https://doi.org/10.24891/cttnfe
EDN: https://elibrary.ru/cttnfe

Александр Александрович ЗАДНЕПРОВСКИЙ

аспирант, кафедра финансов, Санкт-Петербургский государственный экономический университет (СПбГЭУ), Санкт-Петербург, Российская Федерация
e-mail: zadneprovskiy_econ@mail.ru
ORCID: 0009-0002-9877-6132
SPIN: 9919-9474

История статьи:
Рег. № 360/2026
Получена 08.04.2026
Одобрена 19.06.2026
Доступна онлайн 29.10.2026

Специальность: 5.2.4

УДК 336.14, 332.14
JEL: H6, H72, O33, C53

Ключевые слова:
финансовое обеспечение, государственные учреждения, расходы бюджета, прогнозирование, искусственный интеллект

Аннотация

Предмет. Прогнозирование финансового обеспечения государственных учреждений на основе региональных панельных данных субъектов РФ.

Цели. Разработка и апробация методики прогнозирования финансового обеспечения музеев с применением методов искусственного интеллекта.

Методология. Сформирован панельный набор данных 85 субъектов Российской Федерации за 2018–2024 гг. Применены методы машинного обучения – градиентный бустинг, линейные модели с регуляризацией и их ансамбли. Подбор гиперпараметров осуществлен с помощью агента искусственного интеллекта (ИИ-агента) на базе языковой модели Qwen3.5-27B. Проведено 32 вычислительных эксперимента. Точность прогноза оценивалась с помощью медианной абсолютной процентной ошибки (МдАПО); применена скользящая валидация на четырех тестовых годах (2021–2024 гг.).

Результаты. Модель градиентного бустинга обеспечивает МдАПО 8,1% по регионам, что превосходит лучший наивный прогноз на 1,9 п.п. и прогноз по предшествующему году на 4,6 п.п. Средняя МдАПО по скользящей валидации составила 12%. Для 64% регионов ошибка прогноза не превышает 15%. Наибольшей предиктивной силой обладают инфраструктурные (28,6%) и кадровые (22%) характеристики учреждений. Выявлена систематическая тенденция к занижению прогноза для крупных регионов, обусловленная дискреционными бюджетными решениями, не предсказуемыми на основе операционных показателей.

Область применения. Результаты могут применяться органами государственной власти при планировании расходов бюджета и предварительной оценке ожидаемых объемов финансового обеспечения.

Выводы. Методы искусственного интеллекта демонстрируют преимущество перед традиционными эконометрическими подходами в условиях нелинейных зависимостей и межрегиональной гетерогенности. Предложенная методика применима к прогнозированию финансовых показателей государственных учреждений в других отраслях при наличии аналогичных операционных данных в региональном разрезе.

© Издательский дом ФИНАНСЫ и КРЕДИТ, 2026

Для цитирования: Заднепровский А.А. Прогнозирование финансового обеспечения государственных учреждений с применением искусственного интеллекта на примере музеев // Финансы и кредит. – 2026. – № 10. – С. 66 – 85. DOI: 10.24891/cttnfe EDN: CTTNFE

Финансовое обеспечение учреждений культуры является ключевым инструментом реализации государственной политики в сфере культуры, утвержденной Указом Президента РФ от 24.12.2014 № 808[1]. Музеи как государственные учреждения и институты сохранения культурного наследия в основном являются бюджетными учреждениями, поэтому их основными источниками финансового обеспечения служат бюджетные ассигнования, доходы от оказания платных услуг, доходы от прочей предпринимательской деятельности и гранты. При этом региональная дифференциация финансового обеспечения учреждений культуры остается значительной: финансовое обеспечение музеев существенно варьируется между субъектами РФ и определяется комплексом инфраструктурных, кадровых и институциональных факторов [1]. Ученые отмечают сохраняющуюся неравномерность распределения бюджетных расходов по регионам; отсюда возникает вопрос о возможности прогнозирования объемов финансового обеспечения на основе объективных характеристик учреждений [2, 3].

Традиционные подходы к прогнозированию бюджетных показателей опираются на эконометрические модели (векторная авторегрессия (vector autoregression, VAR), сезонная авторегрессионная модель интегрированного скользящего среднего (seasonal autoregressive integrated moving average, SARIMA)) и экспертные оценки. Однако классические модели не всегда обеспечивают достаточную точность в условиях структурных изменений [4, 5]. Все чаще авторы упоминают методы машинного обучения (далее – МО) как подходы, способные учитывать нелинейные зависимости и взаимодействия между показателями-предикторами.

Важно отметить, что МО является подобластью искусственного интеллекта (далее – ИИ), который стал ключевым элементом настоящей работы. Применение МО для прогнозирования показателей государственных финансов достаточно широко представлено в исследованиях в последние годы. Существует разнообразие методов МО, каждый из которых демонстрирует свои преимущества и недостатки. Градиентный бустинг превосходит авторегрессионные модели при прогнозировании ВВП [6, 7]. Обобщенные регрессионные нейронные сети (generalized regression neural networks, GRNN) показали превосходство над традиционными подходами в прогнозировании налоговых доходов муниципалитетов США [8], хотя преимущество варьируется в зависимости от горизонта прогноза. Рядом авторов успешно апробированы ансамблевые модели в целях прогнозирования государственных расходов и распределения бюджетных ассигнований [9, 10].

Отечественные авторы также проявляют значительный интерес к ИИ. А.К. Караев и О.В. Борисова провели сравнительный анализ моделей прогнозирования доходов бюджета, включая методы МО, и установили преимущества и недостатки, а также особенности МО и методов глубокого обучения [11]. И.А. Астраханцева и А.С. Герасимов успешно применили градиентный бустинг для прогнозирования региональной инфляции [12]. А.Е. Харитонова использовала аналогичные методы для прогнозирования налоговой нагрузки предприятий [13]. Аналогичные подходы успешно применены для моделирования регионального товарооборота [14].

Неоднократно подтвержденная эффективность МО в прогнозировании доходов и расходов, безусловно, стимулирует проведение все большего числа научных экспериментов и разработку стандартизированных подходов, в частности для бюджетного процесса. Некоторые авторы указывают на возрастающую необходимость модернизации инструментария финансово-экономического прогнозирования в системе управления государственными финансами с использованием методов ИИ [15, 16].

[1] Указ Президента РФ от 24.12.2014 № 808 (ред. от 17.07.2025) «Об утверждении Основ государственной культурной политики».

Вместе с тем исследования, направленные непосредственно на прогнозирование финансирования учреждений культуры с использованием методов МО, в доступной авторам литературе отсутствуют. Более того, в каждой из ранее упомянутых работ проводилась апробация множества методов МО и так или иначе указывалось на эффективность различных методов в различных задачах. Подобный подход трудозатратен и заставляет сомневаться в возможности разработки унифицированных подходов.

К примеру, А.К. Караев и О.В. Борисова в своем исследовании подчеркивают необходимость перенастраивать гиперпараметры моделей для повышения точности прогнозирования [11]. Ручной подбор гиперпараметров неэффективен в силу необходимости затратить существенное количество времени на поиск идеальной модели. Мы предлагаем автоматизировать подбор гиперпараметров с помощью ИИ.

Таким образом, объектом исследования являются музеи всех форм собственности и уровней управления в разрезе субъектов Российской Федерации, а предметом – процессы формирования и прогнозирования их финансового обеспечения на основе операционных и социально-экономических характеристик.

Целью исследования выступает прогнозирование финансового обеспечения музеев РФ и установление факторов, ассоциированных с объемами финансирования. Для достижения цели решаются следующие задачи:

– формирование панельного набора данных операционных и социально-экономических показателей;

– автоматизированный подбор и сравнение прогнозных моделей;

– анализ относительного вклада групп факторов в прогноз;

– оценка робастности результатов с помощью скользящей валидации.

Исследование основано на панельных данных 85 субъектов Российской Федерации за период 2017–2024 гг. Данные агрегированы из двух основных источников:

1) формы федерального статистического наблюдения по музеям (8-НК)[2]: посещаемость, число экскурсий и выставок, кадровый состав, площади помещений, объем фондов, инфраструктура безопасности и доступности;

2) социально-экономические показатели Росстата и Банка России: ВРП региона[3], численность населения[4], демографическая структура, уровень бедности[5], индекс потребительских цен[6], ключевая ставка Банка России[7].

Целевой переменной определено совокупное финансовое обеспечение музеев региона за год (тыс. руб.), включающее бюджетные ассигнования, доходы от оказания платных услуг,

[2] Форма федерального статистического наблюдения 8-НК «Сведения о деятельности музея» за 2017–2024 гг. // Министерство культуры Российской Федерации. URL: https://stat.mkrf.ru/forms

[3] Валовой региональный продукт по субъектам Российской Федерации в 2017–2024 гг. // Федеральная служба государственной статистики. URL: https://rosstat.gov.ru/statistics/accounts

[4] Численность населения Российской Федерации по полу и возрасту на 1 января 2017–2024 гг.: статистический бюллетень // Федеральная служба государственной статистики.
URL: https://rosstat.gov.ru/storage/mediabank/sp_1.1.xlsx

[5] Уровень бедности (доля населения с денежными доходами ниже границы бедности) по субъектам Российской Федерации в 2017–2024 гг. // Федеральная служба государственной статистики.
URL: https://rosstat.gov.ru/folder/13723

[6] Индексы потребительских цен по Российской Федерации и субъектам Российской Федерации (к декабрю предыдущего года) за 2017–2024 гг. // Федеральная служба государственной статистики.
URL: https://rosstat.gov.ru/statistics/price

[7] Ключевая ставка Банка России за 2017–2024 гг. // Банк России. URL: https://www.cbr.ru/hd_base/keyrate/

гранты и прочие поступления. Период наблюдения ограничен 2018–2024 гг., поскольку данные за 2017 г. используются для формирования лаговых переменных. Для исключения информационной утечки из набора признаков удалены текущие финансовые показатели, тавтологически связанные с целевой переменной. Сохранены лаговые значения ($t - 1$) всех показателей, что обеспечивает корректность прогнозной постановки: модель использует только информацию, доступную на момент составления прогноза. Итоговая панель содержит 510 наблюдений (обучающая выборка, 2018–2023 гг.) и 85 наблюдений (тестовая выборка, 2024 г.). Пространство признаков включает около 196 переменных, столбцы с долей пропусков свыше 50% исключены.

Все признаки классифицированы в 11 тематических групп для последующей интерпретации: инфраструктура (45 переменных), кадры (35), коллекции (20), активность (15), цифровизация (10), бюджет и ВРП (8), демография (8), макроэкономика (4), структура сети (3), COVID (2), лаги прочих показателей (46).

В работе сравниваются три группы прогнозных моделей:

- наивные базовые модели – прогноз по значению предшествующего года, среднее за предшествующие годы, линейная экстраполяция тренда, прогноз по среднему темпу роста (любая содержательная модель должна превосходить лучший наивный прогноз[8]);
- линейные модели с регуляризацией – Ридж и Лассо (Ridge, Lasso);
- модели градиентного бустинга (CatBoost, LightGBM, XGBoost).

Архитектуры глубокого обучения для временных рядов (LSTM – long short-term memory, GRU – gated recurrent unit, N-BEATS – neural basis expansion analysis for interpretable time series forecasting) не рассматривались ввиду несоответствия структуре данных: указанные модели требуют длинных одномерных последовательностей (сотни точек на объект), тогда как в настоящем исследовании на каждый регион приходится 7 годовых наблюдений при ~196 признаках – задача кросс-секционного прогноза на табличных данных.

Как было упомянуто ранее, подбор параметров в задачах бюджетного прогнозирования нестабилен, требует множества итераций и не дает гарантированного результата. Для снижения субъективности и систематизации процесса подбора моделей в исследовании использован ИИ-агент на базе языковой модели Qwen3.5-27B. Агент последовательно формулировал гипотезы, задавал конфигурации моделей и запускал эксперименты, опираясь на результаты предыдущих итераций. Такой подход позволил провести 32 эксперимента (исключая наивные прогнозы), охватывающих различные классы моделей и комбинации гиперпараметров. Подробные технические аспекты реализации ИИ-агента не рассматриваются, поскольку не являются предметом настоящего исследования.

В качестве основного показателя качества используется медианная абсолютная процентная ошибка (MedAPE, далее – МдАПО) – медиана относительных ошибок прогноза по регионам. МдАПО рассчитывается как медианное значение всех абсолютных процентных ошибок (APE, далее – АПО):

$$АПО = \frac{|A_i - F_i|}{|A_i|} \cdot 100, \quad (1)$$

где A – фактическое значение показателя i-го региона;

[8] Hyndman R.J., Athanasopoulos G. Forecasting: Principles and Practice. 3rd ed. Melbourne, OTexts, 2021. URL: https://otexts.com/fpp3/

F – прогнозируемое значение показателя i-го региона;

i – индекс региона.

Коэффициент детерминации может давать завышенную оценку качества модели [10] в силу существенной межрегиональной дисперсии (финансовые поступления музеев Москвы превышают показатели малых регионов примерно в 900 раз). МдАПО одинаково учитывает регионы независимо от масштаба, устойчива к выбросам и интерпретируема: МдАПО = 8%. Это означает, что для типичного региона ошибка прогноза составляет около 8%.

Однако далее для ознакомления также приводятся показатели: средняя абсолютная процентная ошибка (MAPE, далее – САПО) (формула (2)), коэффициент детерминации (R^2) и средняя абсолютная ошибка (MAE, далее – САО).

$$САПО = \frac{1}{n}\sum_{i=1}^{n}\left(\frac{|A_i - F_i|}{|A_i|}\right)\cdot 100, \qquad (2)$$

где n – число наблюдений (регионов).

Обучение проводилось на данных 2018–2023 гг., тестирование – на данных 2024 г. Для оценки робастности применена скользящая валидация: модель последовательно обучается на данных до года $t - 1$ и тестируется на году t для t = 2021, 2022, 2023, 2024, что имитирует реальную задачу прогнозирования и позволяет выявить нестабильность модели во времени[9].

Далее на *рис. 1* представлена сводная информация о проведенных экспериментах и соответствующих значениях МдАПО.

Как видно из графика, каждый следующий эксперимент демонстрировал некоторое улучшение показателя МдАПО относительно предыдущего. Стоит отметить, что данные, представленные на графике, рассчитаны на тестовой выборке.

В *табл. 1* приведены представители каждого типа апробированных моделей и все наивные эксперименты для обеспечения репрезентативности.

Оптимизированная модель CatBoost показывает наименьшую МдАПО (8,1%), превосходя лучший наивный прогноз (наивный (темп роста), 10%) на 1,9 п.п. и прогноз по предшествующему году (12,7%) на 4,6 п.п. Обращает на себя внимание расхождение рангов моделей: наивный (темп роста) при наивысшем R^2 (0,988) демонстрирует САПО = 23,8%, что на 8,7 п.п. хуже CatBoost. Это подтверждает наблюдение А.К. Караева и О.В. Борисовой о необходимости использования нескольких метрик при оценке прогнозных моделей на гетерогенных данных [11].

Из 32 проведенных экспериментов 9 конфигураций превзошли лучший наивный прогноз по МдАПО. Оптимальные гиперпараметры CatBoost (глубина деревьев = 5, скорость обучения = 0,06, L2-регуляризация = 1) выявлены агентом в ходе последовательного сужения поисковой сетки: деревья меньшей глубины демонстрировали недообучение, а более глубокие – переобучение на панели из ~600 наблюдений. На *рис. 2* представлено распределение отклонений лучшей модели.

[9] Hyndman R.J., Athanasopoulos G. Op. cit.

Анализ распределения ошибок по 85 регионам (*рис. 3*) показывает, что для большинства из них модель обеспечивает приемлемую точность: ошибка менее 10% зафиксирована для 55% регионов (47 из 85), менее 15% – для 64%.

Для 14 регионов (16%) ошибка превышает 25%. Подобные расхождения, вероятно, обусловлены дискреционными решениями в бюджетной политике региона (изменение грантовых программ, целевые субсидии, реструктуризация региональных бюджетов), которые не могут быть предсказаны на основе операционных показателей музеев. Стоит также отметить систематическую тенденцию к недопрогнозированию: модель занижает прогноз для 69% регионов.

Анализ структуры ошибок выявил значимую зависимость смещения от масштаба региона: ранговая корреляция Спирмена между фактическими поступлениями и ошибкой прогноза составила –0,379 ($p < 0{,}001$), что свидетельствует о систематическом недопрогнозировании для регионов с высокими объемами финансирования (*рис. 4*). Данная закономерность, по всей видимости, отражает концентрацию дискреционных грантов и целевых субсидий в крупных регионах – поступлений, не предсказуемых на основе операционных характеристик музеев. Для малых регионов, финансируемых преимущественно по нормативной формуле, модель демонстрирует существенно меньшее смещение.

В силу технических особенностей CatBoost (наличия встроенной функции оценки важности признаков по приросту, gain importance) представляется возможным оценить предсказательную силу по группам факторов.

Инфраструктурные характеристики (28,6%) и кадровый потенциал (22%) в совокупности ассоциированы с более чем половиной предсказательной силы модели. Бюджетные показатели и ВРП (7,6%) занимают третье место, за ними следуют коллекционные фонды (6,8%) и посещаемость (6,3%). Далее идут цифровизация (6,3%) и демография региона, в котором находятся музеи (4,7%). Макроэкономические индикаторы (1,6%) и COVID-факторы (0,1%) вносят минимальный вклад, что объясняется их неизменностью в пределах одного года для всех регионов: эти факторы не содержат информации для межрегиональной дифференциации.

Доминирование инфраструктурных и кадровых характеристик может объясняться механизмом финансирования музеев: согласно Постановлению Правительства РФ от 26.06.2015 № 640[10], объем субсидии на государственное задание определяется нормативными затратами на оказание услуг, которые в свою очередь отражают масштаб инфраструктуры и численность персонала учреждения.

На *рис. 5* представлены параметры, обладающие наибольшей важностью для предсказательной силы модели. Описание некоторых показателей приведено в *табл. 2*.

Результаты скользящей валидации (*табл. 3*) подтверждают устойчивость модели при изменении тестового периода.

Наихудший результат зафиксирован для 2022 г. (МдАПО = 15,5%), что может быть обусловлено повышенной волатильностью финансирования в условиях геополитических изменений. По мере увеличения объема обучающих данных наблюдается тенденция к улучшению качества прогноза.

[10] Постановление Правительства РФ от 26.06.2015 № 640 (ред. от 10.12.2025) «О порядке формирования государственного задания на оказание государственных услуг (выполнение работ) в отношении федеральных государственных учреждений и финансового обеспечения выполнения государственного задания».

Полученные результаты свидетельствуют о применимости методов машинного обучения для прогнозирования финансовых поступлений музеев на региональном уровне. МдАПО = 8,1% для лучшей модели сопоставима с точностью прогнозов налоговых доходов, полученных И.Х. Чангом (I.H. Chung) и др. [8] для муниципалитетов США, и согласуется с результатами А.К. Караева и О.В. Борисовой [11] по прогнозированию доходов федерального бюджета в части диапазона достижимой точности. При этом в отличие от указанной работы, где CatBoost демонстрировал переобучение на месячных данных и уступил модели N-BEATS, на годовых панельных данных с регуляризацией алгоритм показывает устойчивые результаты – предположительно вследствие отсутствия выраженной сезонной компоненты и большего числа информативных признаков. Преимущество CatBoost на данной задаче согласуется с наблюдениями Р. Щепанек (R. Szczepanek) [17] о конкурентоспособности данного алгоритма на малых выборках.

Использование ИИ-агента для автоматизированного подбора модели позволило систематически исследовать пространство гиперпараметров и архитектур. Задача подбора нетривиальна. Как мы упоминали ранее, лишь 9 из 32 экспериментов превзошли наивный прогноз. Более половины комбинаций оказались хуже простой экстраполяции. Применение ИИ-агента может способствовать ускорению выбора модели для прогнозирования того или иного показателя в зависимости от типа располагаемых данных и непосредственно самого целевого показателя.

Необходимо четко разграничить предиктивную и объясняющую силу полученных результатов. Выявленные факторы обладают высокой предиктивной силой: они позволяют с приемлемой точностью прогнозировать объемы поступлений. Однако это не означает, что данные факторы являются причинами финансирования. Модели прогнозирования выявляют статистические ассоциации, которые могут отражать обратную причинность, опущенные переменные или общие латентные факторы [18]. В частности, высокий вклад инфраструктурных признаков может объясняться тем, что крупные музеи одновременно имеют большие площади и получают больше финансирования, при этом площади не являются причиной финансирования. Для установления причинно-следственных связей между характеристиками музеев и объемами их финансирования необходимо проведение каузального анализа с применением специализированных методов (инструментальные переменные, разрывный дизайн, разности разностей), что является предметом отдельного исследования.

Результаты данной работы следует рассматривать в контексте ряда ограничений. Панель из ~600 наблюдений является относительно малой для методов МО; риск переобучения минимизирован регуляризацией и скользящей валидацией, однако полностью исключить его невозможно. Модель не учитывает пространственные эффекты (пространственную автокорреляцию), которые могут быть значимыми в контексте федеральных программ развития культуры. Наконец, 16% регионов с ошибкой более 25% указывают на принципиальное ограничение подхода: дискреционные бюджетные решения не могут быть предсказаны на основе операционных характеристик, что отмечается и для моделей прогнозирования налоговых доходов [8, 11].

Несмотря на указанные ограничения, модель может быть полезна для предварительной оценки ожидаемых объемов финансирования при планировании бюджетных расходов на культуру [19, 20]. Для большинства регионов (64%) отклонение прогноза от факта не превышает 15%, что сопоставимо с точностью экспертных оценок. Модель может использо-

ваться как аналитический инструмент для выявления регионов с аномально низким или высоким финансированием относительно их операционных характеристик, что представляет интерес для мониторинга реализации государственной политики в сфере культуры[11].

В работе проведен сравнительный анализ прогнозных моделей финансового обеспечения музеев 85 субъектов Российской Федерации на панельных данных 2018–2024 гг. с использованием автоматизированного подбора моделей МО посредством ИИ-агента.

Совокупное финансовое обеспечение музеев по всем субъектам РФ составило 146,9 млрд руб. в 2024 г. Наблюдается значительное расхождение медианного (734 млн руб.) и среднего (1 728,1 млн руб.) значений финансового обеспечения, указывающее на асимметрию распределения средств: крупные регионы (например, Москва – 36 млрд руб. в 2024 г.) получают значительно больше средств, смещая среднее в большую сторону. Типичный регион получает финансирование на уровне упомянутой ранее медианы.

Модель CatBoost, относящаяся к моделям градиентного бустинга, продемонстрировала наилучшие результаты, обеспечивая МдАПО на уровне 8,1% и превзойдя классический прогноз на 4,6 п.п. Абсолютная величина медианной ошибки составила 48,5 млн руб., средняя абсолютная ошибка – 276,2 млн руб. Подобное расхождение обусловлено теми же причинами, по которым наблюдается расхождение между медианным и средним финансовым обеспечением музеев. Кроме того, крупные регионы могут получать субсидии на выполнение государственного задания и прочие средства, которые не могут быть спрогнозированы на основании использованных в работе показателей.

Те же причины могут объяснять выявленную систематическую тенденцию модели к занижению прогноза: 59 из 85 регионов получили больше средств, чем было спрогнозировано моделью. Медианное отклонение фактических поступлений от прогнозных значений составило 22,2 млн руб., в то время как среднее остается существенно выше – на уровне 212,2 млн руб.

Устойчивость модели была подтверждена с помощью скользящей валидации. Даже с учетом геополитической нестабильности в годах, использованных в валидации (2021–2024 гг.), средняя МдАПО составила 12%. Качество прогноза стабильно росло после стабилизации и накопления обучающих данных, начиная с 2023 г.

Вклад исследования заключается, во-первых, в демонстрации возможности применения моделей ИИ для предварительной оценки будущих объемов финансового обеспечения музеев при планировании расходов. Во-вторых, модель может быть использована в качестве аналитического инструмента для идентификации регионов с аномально низким или аномально высоким финансовым обеспечением, не обусловленным показателями деятельности музеев. В-третьих, исследование позволило продемонстрировать способность моделей ИИ к проведению многофакторного анализа, в частности для выявления показателей-предикторов. Такой подход значительно менее трудозатратен, чем классический.

В дальнейших исследованиях целесообразно провести апробацию предложенных подходов на уровне отдельного субъекта РФ в целях подтверждения или опровержения гипотезы о меньшей ошибке прогноза при анализе более стабильных панельных данных. Кроме того, описанный в данном исследовании подход может быть применен в других отраслях, что также требует апробации.

[11] Указ Президента РФ от 24.12.2014 № 808 (ред. от 17.07.2025).

Таблица 1
Сравнение моделей на тестовых данных (2024 г.)

Table 1
Comparison of models on test data (2024)

Модель	МдАПО, %	САПО, %	R^2	САО, млн руб.
CatBoost (оптимизир.)	8,1	15,1	0,955	276
Наивный (темп роста)	10,0	23,8	0,988	224
CatBoost (по умолч.)	11,0	15,3	0,970	271
XGBoost	11,3	17,7	0,964	318
Наивный (предыдущий год)	12,7	18,3	0,984	258
LightGBM	13,3	17,2	0,909	374
Наивный (тренд)	13,6	28,8	0,967	308
Наивный (среднее)	34,6	37,9	0,926	539

Источник: авторская разработка по данным: Формы 8-НК Министерства культуры РФ. URL: https://stat.mkrf.ru/forms; Валовой региональный продукт по субъектам Российской Федерации в 2017–2024 гг. URL: https://rosstat.gov.ru/statistics/accounts; Численность населения Российской Федерации по полу и возрасту на 1 января 2017–2024 гг. : статистический бюллетень. URL: https://rosstat.gov.ru/storage/mediabank/sp_1.1.xlsx; Уровень бедности (доля населения с денежными доходами ниже границы бедности) по субъектам Российской Федерации в 2017–2024 гг. URL: https://rosstat.gov.ru/folder/13723; Индексы потребительских цен по Российской Федерации и субъектам Российской Федерации (к декабрю предыдущего года) за 2017–2024 гг. URL: https://rosstat.gov.ru/statistics/price; Ключевая ставка Банка России за 2017–2024 гг. URL: https://www.cbr.ru/hd_base/keyrate/

Source: Authoring, based on the data from: Form 8-NK of the Ministry of Culture of the Russian Federation. URL: https://stat.mkrf.ru/forms; Gross Regional Product by subjects of the Russian Federation in 2017–2024. URL: https://rosstat.gov.ru/statistics/accounts; Population of the Russian Federation by gender and age as of January 1, 2017–2024: statistical bulletin. URL: https://rosstat.gov.ru/storage/mediabank/sp_1.1.xlsx; Poverty level (share of the population with monetary incomes below the poverty line) by subjects of the Russian Federation in 2017–2024. URL: https://rosstat.gov.ru/folder/13723; Consumer price indices for the Russian Federation and its subjects (as of December of the previous year) for 2017–2024. URL: https://rosstat.gov.ru/statistics/price; Key rate of the Bank of Russia for 2017–2024. URL: https://www.cbr.ru/hd_base/keyrate/

Таблица 2
Описание некоторых факторов с наибольшей предсказательной силой в модели CatBoost

Table 2
Description of some factors with the highest predictive power in the CatBoost model

Признак	Описание
ВРП	ВРП субъекта РФ, в котором находится музей (млн руб.)
Численность работников	Общая численность работников музея (чел.)
Площадь помещений	Общая площадь помещений зданий музея ($м^2$)
Штатная численность	Численность сотрудников по штатному расписанию в текущем году (чел.)
Предметы в АМС	Число музейных предметов, внесенных в автоматизированную музейную систему (АМС) (ед.)
Фактически работающих	Число фактически работающих сотрудников по штатному расписанию
Фонд: муниципальная собственноость	Число предметов, являющихся муниципальной собственностью, переданных музею в оперативное управление или безвозмездное пользование
Посты вневедомственной охраны	Количество постов вневедомственной (сторожевой) охраны музея (ед.)
Площадь видеонаблюдения	Площадь помещений, находящихся под контролем системы видеонаблюдения ($м^2$)
Предметы в Госкаталоге	Число музейных предметов, внесенных в Государственный электронный каталог в текущем году (ед.)
Посты охраны музея	Количество постов собственной (сторожевой) охраны музея

Источник: авторская разработка по данным: Министерства культуры РФ.
URL: https://stat.mkrf.ru/forms

Source: Authoring, based on the Ministry of Culture of the Russian Federation data.
URL: https://stat.mkrf.ru/forms

Таблица 3
Результаты скользящей валидации модели CatBoost

Table 3
Results of the rolling validation of the CatBoost model

Тестовый год	R^2	САПО, %	МдАПО, %	САО, млн руб.
2021	0,981	15,8	10,4	151
2022	0,894	21,6	15,5	372
2023	0,957	16,6	13,9	289
2024	0,955	15,1	8,1	276
Среднее	0,947	17,3	12	277

Источник: авторская разработка по данным: Формы 8-НК Министерства культуры РФ. URL: https://stat.mkrf.ru/forms; Валовой региональный продукт по субъектам Российской Федерации в 2017–2024 гг. URL: https://rosstat.gov.ru/statistics/accounts; Численность населения Российской Федерации по полу и возрасту на 1 января 2017–2024 гг. : статистический бюллетень. URL: https://rosstat.gov.ru/storage/mediabank/sp_1.1.xlsx; Уровень бедности (доля населения с денежными доходами ниже границы бедности) по субъектам Российской Федерации в 2017–2024 гг. URL: https://rosstat.gov.ru/folder/13723; Индексы потребительских цен по Российской Федерации и субъектам Российской Федерации (к декабрю предыдущего года) за 2017–2024 гг. URL: https://rosstat.gov.ru/statistics/price; Ключевая ставка Банка России за 2017–2024 гг. URL: https://www.cbr.ru/hd_base/keyrate/

Source: Authoring, based on data from: Form 8-NK of the Ministry of Culture of the Russian Federation. URL: https://stat.mkrf.ru/forms; Gross regional product by subjects of the Russian Federation in 2017–2024. URL: https://rosstat.gov.ru/statistics/accounts; Population of the Russian Federation by sex and age as of January 1, 2017–2024: statistical bulletin. URL: https://rosstat.gov.ru/storage/mediabank/sp_1.1.xlsx; Poverty level (share of the population with cash incomes below the poverty line) by subjects of the Russian Federation in 2017–2024. URL: https://rosstat.gov.ru/folder/13723; Consumer price indices for the Russian Federation and its subjects (compared to December of the previous year) for 2017–2024. URL: https://rosstat.gov.ru/statistics/price; Key rate of the Bank of Russia for 2017–2024. URL: https://www.cbr.ru/hd_base/keyrate/

Рисунок 1
Результаты проведенных экспериментов

Figure 1
Results of the conducted experiments

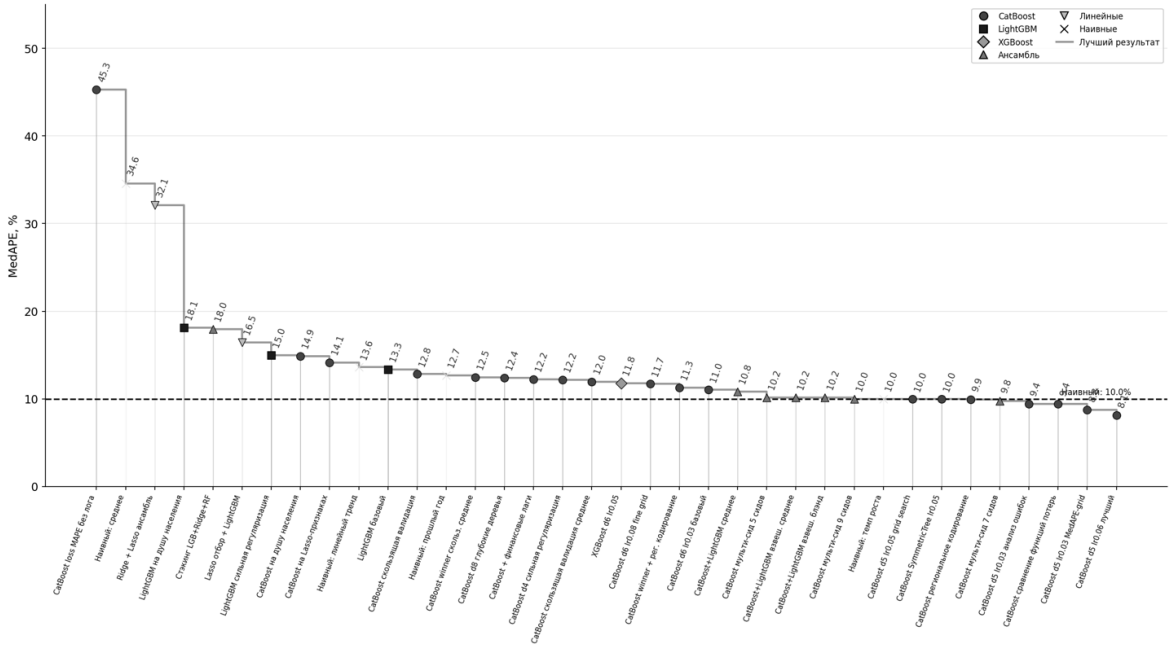

Источник: авторская разработка по данным *табл. 1*

Source: Authoring, based on *Table 1* data

Рисунок 2
Фактические и прогнозные значения финансовых поступлений, 2024 г.

Figure 2
Actual and forecasted values of financial receipts, 2024

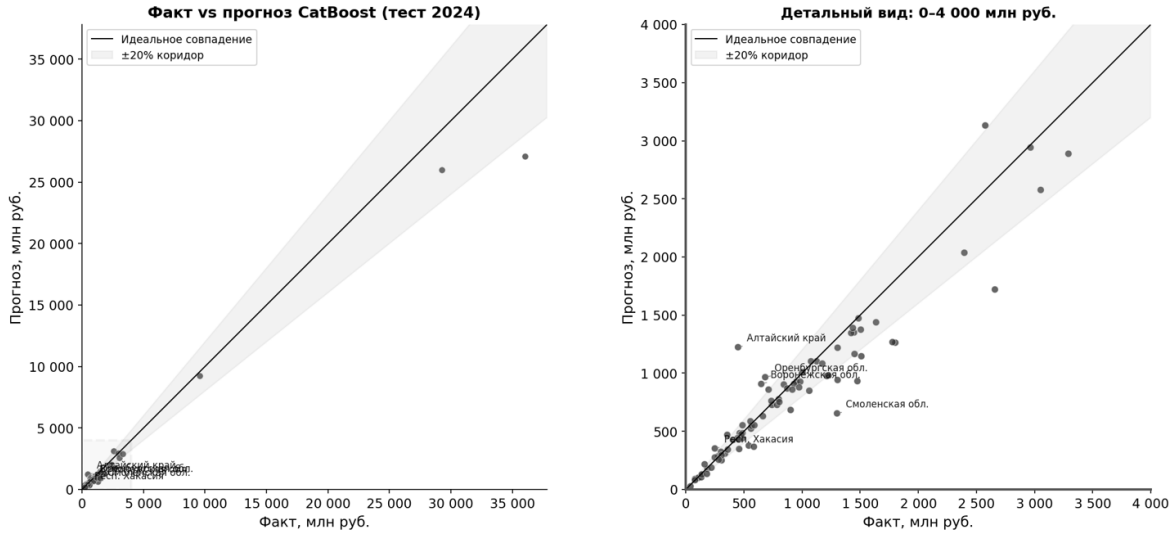

Источник: авторская разработка по данным *табл. 1*

Source: Authoring, based on *Table 1* data

Рисунок 3
Гистограмма ошибок прогноза по субъектам РФ, 2024 г.

Figure 3
Histogram of forecast errors by Russian region, 2024

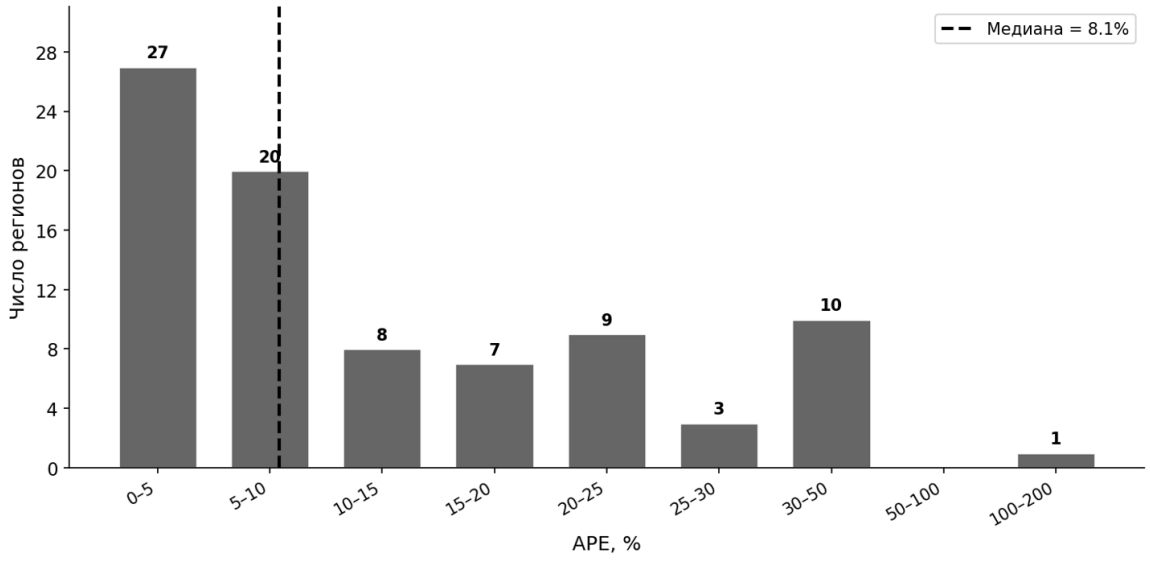

Источник: авторская разработка по данным *табл. 1*

Source: Authoring, based on *Table 1* data

Рисунок 4
Зависимость ошибки прогноза от объема фактического финансового обеспечения музеев по субъектам РФ, 2024 г.

Figure 4
Dependence of forecast error on the volume of actual financial support for museums by Russian region, 2024

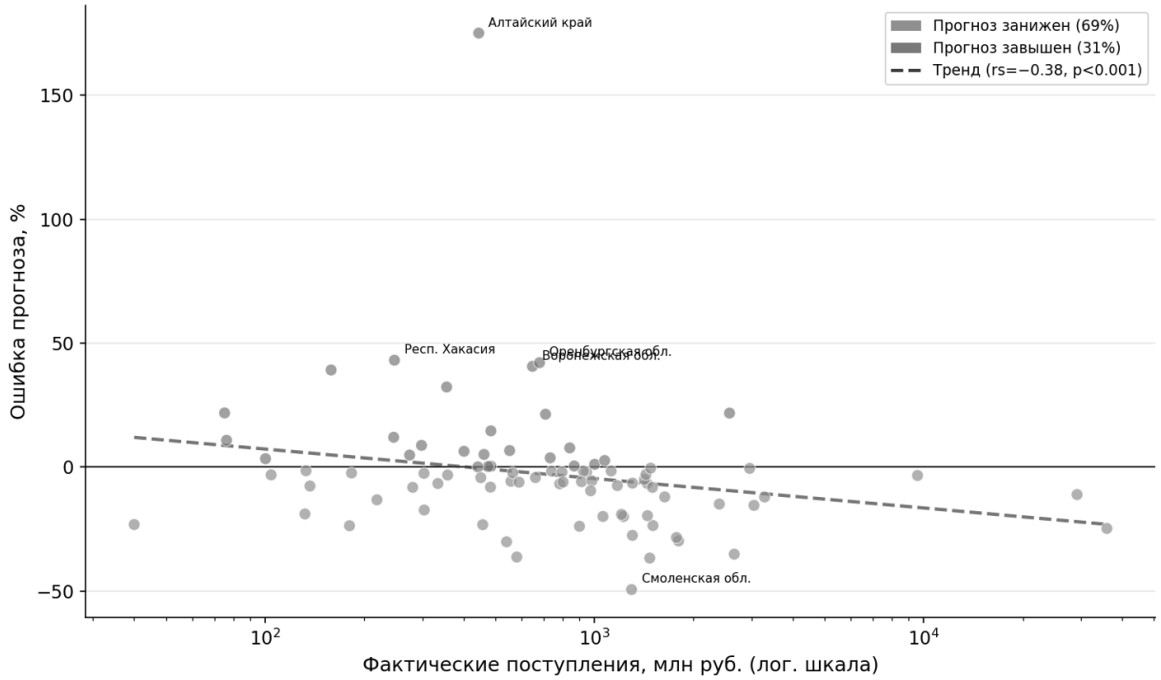

Источник: авторская разработка по данным *табл. 1*

Source: Authoring, based on *Table 1* data

Рисунок 5
Факторы с наибольшей предсказательной силой в модели CatBoost

Figure 5
Factors with the highest predictive power in the CatBoost model

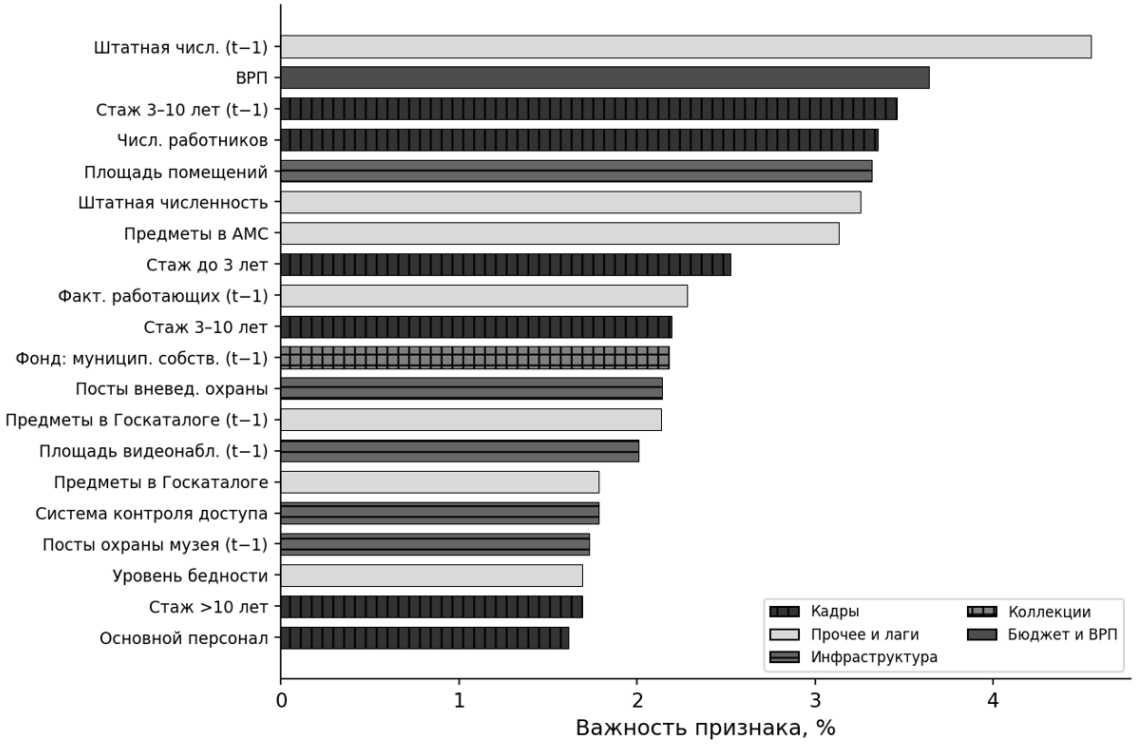

Источник: авторская разработка по данным *табл. 2*

Source: Authoring, based on *Table 2* data

Список литературы

1. Шабунова А.А., Соколова Т.И. Функционирование музеев Вологодской области через призму их финансового обеспечения // Проблемы развития территории. 2025. Т. 29. № 1. С. 73–88. DOI: 10.15838/ptd.2025.1.135.6 EDN: UKIVKV
2. Матвеев В.В. Финансирование сферы культуры в аспекте реализации государственной культурной политики: аналитический обзор // Вестник Астраханского государственного технического университета. Серия: Экономика. 2022. № 4. С. 59–69. DOI: 10.24143/2073-5537-2022-4-59-69 EDN: YABNOI
3. Хусаинова Р.З. Цифровая трансформация музеев и креативные индустрии // Вестник Московского государственного университета культуры и искусств. 2024. № 6. С. 186–194. DOI: 10.24412/1997-0803-2024-6122-186-194 EDN: FBWKFM
4. Kara B., Şengüler H. A Comparative Analysis of Budget Forecasting Methods: A Systematic Literature Review Covering the 1983–2024 Period. *Public Budgeting & Finance*, 2025, pbaf.70008. DOI: 10.1111/pbaf.70008 EDN: KDUOAM
5. Караев А.К., Пинская М.Р., Мельничук М.В. Краткосрочное прогнозирование налоговых доходов бюджетов: применяемые методы и их релевантность для России // Вестник Московского университета. Серия 6: Экономика. 2025. Т. 60. № 2. С. 3–19. DOI: 10.55959/MSU0130-0105-6-60-2-1 EDN: HUQYCG

6. Yoon J. Forecasting of Real GDP Growth Using Machine Learning Models: Gradient Boosting and Random Forest Approach. *Computational Economics*, 2020, vol. 57, pp. 247–265. DOI: 10.1007/s10614-020-10054-w EDN: NZUQPD

7. Майкова А.А., Старченкова О.Д., Схведиани А.Е. Моделирование валового регионального продукта при помощи методов машинного обучения // Вестник Пермского университета. Серия: Экономика. 2025. Т. 20. № 4. С. 449–467. DOI: 10.17072/1994-9960-2025-4-449-467 EDN: BGUSCM

8. Chung I.H., Williams D.W., Do M.R. For Better or Worse? Revenue Forecasting with Machine Learning Approaches. *Public Performance & Management Review*, 2022, vol. 45, iss. 5, pp. 1133–1154. DOI: 10.1080/15309576.2022.2073551 EDN: ISIOVB

9. Drăgulin B., Ştefan V., Tăbîrcă A.-I. et al. AI-Driven Models for Forecasting Public Expenditures in the Digital Era. *Electronics*, 2025, vol. 14, iss. 20. DOI: 10.3390/electronics14204047 EDN: HUDVZT

10. Prasetyo B., Suharjito. Optimizing Government Funding Allocation with Ensemble Machine Learning Models. 10th International Conference on Computing, Engineering and Design (ICCED), Jeddah, Saudi Arabia, 2024, pp. 1–5. DOI: 10.1109/ICCED64257.2024.10983885

11. Караев А.К., Борисова О.В. Перспективные модели финансового прогнозирования доходов бюджета // Финансы: теория и практика. 2025. Т. 29. № 1. С. 20–33. DOI: 10.26794/2587-5671-2025-29-1-20-33 EDN: YISEIL

12. Астраханцева И.А., Герасимов А.С. Прогнозирование региональной инфляции на основе гибридной модели машинного обучения: градиентный бустинг и случайный лес // Научные труды Вольного экономического общества России. 2023. 243. Т. № 5. С. 200–226. DOI: 10.38197/2072-2060-2023-243-5-200-226 EDN: JATZXG

13. Харитонова А.Е. Прогнозирование налоговой нагрузки сельскохозяйственных предприятий методами машинного обучения // Налоги и налогообложение. 2023. № 4. С. 28–38. DOI: 10.7256/2454-065X.2023.4.43917 EDN: VUBDLU

14. Цветков В.А., Абрамов Е.Г., Майорова Е.А. Влияние состояния торговой отрасли на оборот розничной торговли в регионах России // Экономика региона. 2025. Т. 21. № 1. С. 70–84. DOI: 10.17059/ekon.reg.2025-1-6 EDN: URYGJA

15. Понкратов В.В., Караев А.К., Бельников С.С., Борисова О.В. Модернизация инструментария финансово-экономического прогнозирования в системе управления государственными финансами // Научные труды Вольного экономического общества России. 2025. Т. 256. № 6. С. 131–150. DOI: 10.38197/2072-2060-2025-256-6-131-150 EDN: IUPBUW

16. Морунова Г.В., Силакова Л.В., Заднепровский А.А., Иванов А.В. Внедрение искусственного интеллекта в управление государственными финансами и бизнесом как фактор устойчивого развития территорий // Экономика. Налоги. Право. 2025. Т. 18. № 4. С. 57–70. DOI: 10.26794/1999-849X-2025-18-4-57-70 EDN: ZJLCDK

17. Szczepanek R. Daily Streamflow Forecasting in Mountainous Catchment Using XGBoost, LightGBM and CatBoost. *Hydrology*, 2022, vol. 9, iss. 12. DOI: 10.3390/hydrology9120226 EDN: XSUHEG

18. Brand J.E., Zhou X., Xie Y. Recent Developments in Causal Inference and Machine Learning. *Annual Review of Sociology*, 2023, vol. 49, pp. 81–110. DOI: 10.1146/annurev-soc-030420-015345 EDN: DTGOAX

19. Белоусов Ю.В., Тимофеева О.И. Прогноз влияния цифровизации на управление государственными финансами // Мир новой экономики. 2022. Т. 16. № 4. С. 113–123. DOI: 10.26794/2220-6469-2022-16-4-113-123 EDN: XSJJZY

20. Морунова Г.В., Федосов В.А., Салтыков А.С. Информационные системы бюджетного процесса в России: современное состояние и перспективы развития // Финансовый журнал. 2025. Т. 17. № 4. С. 44–61. DOI: 10.31107/2075-1990-2025-4-44-61 EDN: RIPVVA

Информация о конфликте интересов

Я, автор данной статьи, со всей ответственностью заявляю о частичном и полном отсутствии фактического или потенциального конфликта интересов с какой бы то ни было третьей стороной, который может возникнуть вследствие публикации данной статьи. Настоящее заявление относится к проведению научной работы, сбору и обработке данных, написанию и подготовке статьи, принятию решения о публикации рукописи.

pISSN 2071-4688
eISSN 2311-8709

Fiscal System

FORECASTING FINANCIAL SUPPORT FOR GOVERNMENT INSTITUTIONS USING ARTIFICIAL INTELLIGENCE: THE CASE STUDY OF MUSEUMS

DOI: https://doi.org/10.24891/cttnfe
EDN: https://elibrary.ru/cttnfe

Aleksandr A. ZADNEPROVSKII

Saint Petersburg State University of Economics (SPbSEU), St. Petersburg, Russian Federation
e-mail: zadneprovskiy_econ@mail.ru
ORCID: 0009-0002-9877-6132

Article history:
Article No. 360/2026
Received 8 Apr 2026
Accepted 19 Jun 2026
Available online
29 Oct 2026

JEL Classification: H6, H72, O33, C53

Keywords: financial support, government institutions, budget expenses, forecasting, artificial intelligence

Abstract

Subject. Forecasting the financial support of public institutions based on regional panel data of the constituent entities of the Russian Federation.

Objectives. To develop and test a methodology for forecasting the financial support of museums using artificial intelligence methods.

Methods. A panel dataset of 85 constituent entities of the Russian Federation for 2018–2024 was compiled. Machine learning methods were applied, including gradient boosting, regularized linear models, and their ensembles. Hyperparameter tuning was carried out using an artificial intelligence agent (AI agent) based on the Qwen3.5-27B language model. Thirty-two computational experiments were conducted. Forecast accuracy was assessed using the median absolute percentage error (MdAPE); rolling validation was applied over four test years (2021–2024).

Results. The gradient boosting model achieves an MdAPE of 8.1% across regions, outperforming the best naive forecast by 1.9 percentage points and the previous-year forecast by 4.6 percentage points. The average MdAPE under rolling validation was 12%. For 64% of the regions, the forecast error does not exceed 15%. Infrastructure-related characteristics of institutions (28.6%) and personnel-related characteristics (22%) demonstrate the highest predictive power. A systematic tendency to underestimate forecasts for large regions was identified; this is driven by discretionary budgetary decisions that cannot be predicted based on operational indicators.

Conclusions and Relevance. Artificial intelligence methods demonstrate an advantage over traditional econometric approaches in the context of nonlinear relationships and interregional heterogeneity. The proposed methodology is applicable to forecasting financial indicators of public institutions in other sectors, provided that similar operational data at the regional level are available. The results can be used by public authorities in budget expenditure planning and in preliminary assessments of expected levels of financial support.

© Publishing house FINANCE and CREDIT, 2026

Please cite this article as: Zadneprovskii A.A. Forecasting financial support for government institutions using artificial intelligence: The case study of museums. *Finance and Credit*, 2026, iss. 10, pp. 66–85. DOI: 10.24891/cttnfe EDN: CTTNFE

References

1. Shabunova A.A., Sokolova T.I. [The functioning of museums in the Vologda Region through the prism of their financial support]. *Problemy razvitiya territorii*, 2025, vol. 29, no. 1, pp. 73–88. (In Russ.) DOI: 10.15838/ptd.2025.1.135.6 EDN: UKIVKV
2. Matveev V.V. [Financing the cultural sector in the context of implementing state cultural policy: an analytical review]. *Vestnik Astrakhanskogo gosudarstvennogo tekhnicheskogo universiteta. Seriya: Ekonomika*, 2022, no. 4, pp. 59–69. (In Russ.) DOI: 10.24143/2073-5537-2022-4-59-69 EDN: YABNOI
3. Khusainova R.Z. [Digital transformation of museums and creative industries]. *Vestnik Moskovskogo gosudarstvennogo universiteta kul'tury i iskusstv*, 2024, no. 6, pp. 186–194. (In Russ.) DOI: 10.24412/1997-0803-2024-6122-186-194 EDN: FBWKFM
4. Kara B., Şengüler H. A Comparative Analysis of Budget Forecasting Methods: A Systematic Literature Review Covering the 1983–2024 Period. *Public Budgeting & Finance*, 2025, 70008. DOI: 10.1111/pbaf.70008 EDN: KDUOAM
5. Karaev A.K., Pinskaya M.R., Mel'nichuk M.V. [Short-term forecasting of budget tax revenue: Methods used and their relevance for Russia]. *Vestnik Moskovskogo universiteta. Seriya 6: Ekonomika*, 2025, vol. 60, no. 2, pp. 3–19. (In Russ.) DOI: 10.55959/MSU0130-0105-6-60-2-1 EDN: HUQYCG
6. Yoon J. Forecasting of Real GDP Growth Using Machine Learning Models: Gradient Boosting and Random Forest Approach. *Computational Economics*, 2020, vol. 57, pp. 247–265. DOI: 10.1007/s10614-020-10054-w EDN: NZUQPD
7. Maikova A.A., Starchenkova O.D., Skhvediani A.E. [Gross regional product modeling with machine learning methods]. *Vestnik Permskogo universiteta. Seriya: Ekonomika*, 2025, vol. 20, no. 4, pp. 449–467. (In Russ.) DOI: 10.17072/1994-9960-2025-4-449-467 EDN: BGUSCM
8. Chung I.H., Williams D.W., Do M.R. For Better or Worse? Revenue Forecasting with Machine Learning Approaches. *Public Performance & Management Review*, 2022, vol. 45, iss. 5, pp. 1133–1154. DOI: 10.1080/15309576.2022.2073551 EDN: ISIOVB
9. Drăgulin B., Ştefan V., Tăbîrcă A.-I. et al. AI-Driven Models for Forecasting Public Expenditures in the Digital Era. *Electronics*, 2025, vol. 14, iss. 20. DOI: 10.3390/electronics14204047 EDN: HUDVZT
10. Prasetyo B., Suharjito. Optimizing Government Funding Allocation with Ensemble Machine Learning Models. In: *10th International Conference on Computing, Engineering and Design (ICCED)*, Jeddah, Saudi Arabia, 2024, pp. 1–5. DOI: 10.1109/ICCED64257.2024.10983885
11. Karaev A.K., Borisova O.V. [Prospective models of financial forecasting of budget revenues]. *Finansy: teoriia i praktika*, 2025, vol. 29, no. 1, pp. 20–33. (In Russ.) DOI: 10.26794/2587-5671-2025-29-1-20-33 EDN: YISEIL
12. Astrakhantseva I.A., Gerasimov A.S. [Regional inflation prediction based on hybrid machine learning model: Gradient boosting and random forest]. *Nauchnye trudy Vol'nogo ekonomicheskogo obshchestva Rossii*, 2023, vol. 243, no. 5, pp. 200–226. (In Russ.) DOI: 10.38197/2072-2060-2023-243-5-200-226 EDN: JATZXG

13. Kharitonova A.E. [Forecasting the tax burden of agricultural enterprises by machine learning methods]. *Nalogi i nalogooblozhenie*, 2023, no. 4, pp. 28–38. (In Russ.) DOI: 10.7256/2454-065X.2023.4.43917 EDN: VUBDLU

14. Tsvetkov V.A., Abramov E.G., Maiorova E.A. [The impact of the trade sector on retail trade turnover in Russian regions]. *Ekonomika regiona*, 2025, vol. 21, no. 1, pp. 70–84. (In Russ.) DOI: 10.17059/ekon.reg.2025-1-6 EDN: URYGJA

15. Ponkratov V.V., Karaev A.K., Bel'nikov S.S., Borisova O.V. [Modernization of financial and economic forecasting tools in the public finance management system]. *Nauchnye trudy Vol'nogo ekonomicheskogo obshchestva Rossii*, 2025, vol. 256, no. 6, pp. 131–150. (In Russ.) DOI: 10.38197/2072-2060-2025-256-6-131-150 EDN: IUPBUW

16. Morunova G.V., Silakova L.V., Zadneprovskii A.A., Ivanov A.V. [Introduction of artificial intelligence into public finance and business management as a factor of sustainable development of territories]. *Ekonomika. Nalogi. Pravo*, 2025, vol. 18, no. 4, pp. 57–70. (In Russ.) DOI: 10.26794/1999-849X-2025-18-4-57-70 EDN: ZJLCDK

17. Szczepanek R. Daily Streamflow Forecasting in Mountainous Catchment Using XGBoost, LightGBM and CatBoost. *Hydrology*, 2022, vol. 9, iss. 12. DOI: 10.3390/hydrology9120226 EDN: XSUHEG

18. Brand J.E., Zhou X., Xie Y. Recent Developments in Causal Inference and Machine Learning. *Annual Review of Sociology*, 2023, vol. 49, pp. 81–110. DOI: 10.1146/annurev-soc-030420-015345 EDN: DTGOAX

19. Belousov Yu.V., Timofeeva O.I. [Forecast of the digitalization impact on public financial management]. *Mir novoi ekonomiki*, 2022, vol. 16, no. 4, pp. 113–123. (In Russ.) DOI: 10.26794/2220-6469-2022-16-4-113-123 EDN: XSJJZY

20. Morunova G.V., Fedosov V.A., Saltykov A.S. [Financial management information systems in Russia: Current state and prospects of development]. *Finansovyi zhurnal*, 2025, vol. 17, no. 4, pp. 44–61. (In Russ.) DOI: 10.31107/2075-1990-2025-4-44-61 EDN: RIPVVA

Conflict-of-interest notification

I, the author of this article, bindingly and explicitly declare of the partial and total lack of actual or potential conflict of interest with any other third party whatsoever, which may arise as a result of the publication of this article. This statement relates to the study, data collection and interpretation, writing and preparation of the article, and the decision to submit the manuscript for publication.