

**ПРОГНОЗИРОВАНИЕ МЕЖРЕГИОНАЛЬНОЙ ДИФФЕРЕНЦИАЦИИ
ТЕМПОВ РОСТА ВАЛОВОГО РЕГИОНАЛЬНОГО ПРОДУКТА
С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ
(НА ПРИМЕРЕ УРАЛЬСКОГО МАКРОРЕГИОНА)****Куклинова П. С. ORCID ID 0000-0003-3027-2165,****Чеснюкова Л. К. ORCID ID 0000-0002-8867-9112***Федеральное государственное бюджетное образовательное учреждение высшего образования
«Уральский государственный экономический университет», Екатеринбург,
Российская Федерация, e-mail: kuklinova_ps@usue.ru*

Цель исследования – разработка и апробация методики прогнозирования межрегиональной дифференциации темпов роста валового регионального продукта субъектов Уральского макрорегиона на основе методов машинного обучения для информационной поддержки принятия решений в сфере пространственной политики. Исследование опирается на теории пространственного развития и концепции региональной конвергенции/дивергенции. Для прогнозирования темпов роста валового регионального продукта использованы методы градиентного бустинга (XGBoost, CatBoost) и случайного леса (Random Forest). На основе полученных прогнозов рассчитаны показатели межрегиональной дифференциации: коэффициент вариации, индекс Тейла и квартильный размах. Предложена двухэтапная методика прогнозирования дифференциации, включающая: 1) прогнозирование темпов роста валового регионального продукта каждого региона с использованием ансамблевых методов машинного обучения (средняя абсолютная процентная ошибка MAPE составила 2,67 %); 2) расчет и прогноз показателей межрегиональной дифференциации на 2026–2028 гг. Выполнена типологизация регионов Уральского макрорегиона по устойчивости темпов роста и характеру динамики дифференциации. Установлено, что наибольший вклад в усиление межрегиональных различий вносят ресурсные регионы, тогда как промышленные регионы демонстрируют конвергентную динамику. Показано, что разработанная модель позволяет с высокой точностью прогнозировать точки перелома в динамике дифференциации, связанные с изменением внешнеэкономической конъюнктуры.

Ключевые слова: валовой региональный продукт, межрегиональная дифференциация, темпы экономического роста, пространственная политика, машинное обучение, Уральский макрорегион

**FORECASTING OF INTERREGIONAL DIFFERENTIATION
OF GROSS REGIONAL PRODUCT GROWTH RATES
USING MACHINE LEARNING METHODS
(USING THE EXAMPLE OF THE URAL MACROREGION)****Kuklinova P. S. ORCID ID 0000-0003-3027-2165,****Chesnyukova L. K. ORCID ID 0000-0002-8867-9112***Federal State Budgetary Educational Institution of Higher Education
“Ural State University of Economics”, Yekaterinburg, Russian Federation,
e-mail: kuklinova_ps@usue.ru*

The purpose of the work is to develop and test a methodology for predicting the interregional differentiation of the growth rates of the gross regional product of the subjects of the Ural macroregion based on machine learning methods for information support of decision-making in the field of spatial policy. The research is based on the theory of spatial development and the concept of regional convergence/divergence. The methods of gradient boosting (XGBoost, CatBoost) and random Forest were used to predict the growth rates of the gross regional product. Based on the forecasts obtained, the indicators of interregional differentiation are calculated: the coefficient of variation, the Tail index and the quartile range. A two-stage methodology for predicting differentiation is proposed, including: 1) forecasting the growth rate of the gross regional product of each region using ensemble machine learning methods (the average absolute percentage error of MAPE was 2,67 %); 2) calculation and forecast of indicators of interregional differentiation for the period 2026-2028. The typologization of the regions of the Ural macroregion is carried out according to the stability of growth rates and the nature of the dynamics of differentiation. It has been established that resource regions make the greatest contribution to the strengthening of interregional differences, while industrial regions demonstrate convergent dynamics. It is shown that the developed model makes it possible to predict with high accuracy the turning points in the dynamics of differentiation associated with changes in the external economic environment.

Keywords: gross regional product, interregional differentiation, economic growth rates, spatial policy, machine learning, Ural macroregion

Введение

Исследования в области прогнозирования макроэкономических показателей с использованием методов искусственного интеллекта активно развиваются как в зарубежной, так и в отечественной науке. Особое внимание уделяется прогностическим моделям на основе нейронных сетей, позволяющим строить нелинейные взаимосвязи переменных и обеспечивающим более высокую точность прогнозов по сравнению с традиционными эконометрическими подходами.

Значительный вклад в развитие методологии прогнозирования региональных экономических показателей внесли исследования, выполненные на материалах различных субъектов РФ. Т. В. Азарнова, Ю. И. Трещевский и С. Н. Папин с помощью аппарата искусственных нейронных сетей спрогнозировали ВРП Воронежской области, используя многослойный перцептрон (MLP) и достигнув точности прогноза 97 % [1]. А. Л. Сочков и А. Е. Соловьев синтезировали MLP для моделирования ВРП на душу населения Ставропольского края, показав, что погрешность среднесрочного моделирования не превысила 5 % [2]. Особый интерес для настоящего исследования представляют работы, выполненные непосредственно на материалах Уральского макрорегиона.

А. Кумар, Д. Балугу и др. провели сравнение моделей машинного обучения и авторегрессионных моделей для прогнозирования валового регионального продукта Свердловской области и сделали вывод о высокой эффективности модели машинного обучения по сравнению с традиционной [3]. Ю. В. Трифонов, А. Л. Сочков и А. Е. Соловьев провели анализ структурной динамики валового регионального продукта и доказали, что данные из одной и той же группы регионов могут быть использованы для формирования расширенной обучающей базы данных, что повышает точность прогнозных моделей [4].

Этот методологический подход был использован М. Ю. Малкиной, А. Л. Сочковым и Ю. И. Капустиной, авторы создали две модели (базовую и расширенную) и разработали три предварительных варианта на 2025–2027 гг., при этом результаты фактической версии оказались близки к прогнозам регионального правительства [5]. Имеются исследования, демонстрирующие важность учета специфики конкретного макрорегиона при выявлении перспективных направлений регулирующего воздействия [6; 7]. В исследовании В. В. Вольчика,

С. С. Цыганкова и А. И. Макаева показано, что проникновение идеологии неолиберализма в систему государственного управления задает единые институциональные рамки, которые тем не менее дают различный экономический эффект в неоднородных региональных условиях [7]. Данный вывод методологически значим для прогнозирования межрегиональной дифференциации темпов роста ВРП, поскольку позволяет обосновать необходимость включения в модели машинного обучения не только количественных социально-экономических показателей, но и прокси-переменных, отражающих качество государственного менеджмента и степень его неолиберальной ориентации.

Некоторые работы посвящены совершенствованию методической базы прогнозирования динамики показателей, характеризующих социально-экономическое развитие региона, путем использования аппарата рекуррентных нейронных сетей на примере прогноза динамики ВРП Калининградской области [8]. Показано, что нейросетевые подходы обеспечивают более высокую точность при достаточном объеме данных [9]. Установлено, что прогноз нейронной сети, сформированный на основе ее обучения за ретроспективный период, можно считать адекватным реальным экономическим процессам в регионе. Частные ошибки прогноза имеют место, но общий вывод о возможности применения нейронных сетей в задачах прогнозирования динамики показателей социально-экономического развития региона является положительным [1]. В результате исследования с применением нейросетевых технологий были определены особенности инновационного развития субъектов Российской Федерации [10].

Несмотря на наличие отдельных работ по прогнозированию ВРП регионов Уральского макрорегиона [5; 11], отсутствуют исследования, фокусирующиеся на прогнозировании не абсолютных значений ВРП, а межрегиональной дифференциации темпов роста. Существующие подходы не позволяют в полной мере оценить динамику разрывов в экономическом развитии между различными типами регионов, что необходимо для задач пространственной политики. Кроме того, требует дальнейшего развития методология расширения обучающих выборок за счет данных регионов со сходной отраслевой структурой и учета структурных сдвигов, вызванных трансформацией экономики в условиях современных вызовов.

Цель исследования – разработка и апробация методики прогнозирования межрегиональной дифференциации темпов роста ВРП субъектов Уральского макрорегиона на основе методов машинного обучения для информационной поддержки принятия решений в сфере пространственной политики.

Объектом исследования выступают социально-экономические системы шести субъектов Российской Федерации, входящих в состав Уральского макрорегиона (Курганская, Свердловская, Тюменская, Челябинская области, Ханты-Мансийский автономный округ – Югра, Ямало-Ненецкий автономный округ). Предмет исследования – прогнозирование межрегиональной дифференциации темпов роста ВРП с использованием моделей машинного обучения.

Материалы и методы исследования

Исследование опирается на теории пространственного развития, концепции региональной конвергенции/дивергенции, а также современные разработки в области применения методов машинного обучения для прогнозирования экономических показателей. Методологическую основу составляют работы в области ансамблевых методов (градиентный бустинг, случайный лес) и подходы к расширению обучающих выборок за счет данных регионов со сходной отраслевой структурой [12].

Исследование базируется на данных Федеральной службы государственной статистики (Росстата) за 2000–2025 гг., включающих показатели ВРП и факторов производства (основной капитал, инвестиции, занятость, отраслевая структура), дополненных макроэкономическими параметрами.

Теоретико-методологической основой исследования выступают фундаментальные положения теории пространственного развития, концепции региональной конвергенции/дивергенции, а также современные разработки в области применения методов машинного обучения для прогнозирования экономических показателей [13–15].

На основе расширенной производственной функции Кобба – Дугласа и анализа современных исследований по прогнозированию ВРП выделяются следующие группы факторов, влияющих на темпы роста ВРП:

1. Базовые производственные факторы:
 - стоимость основных фондов (капитал);
 - среднегодовая численность занятых в экономике (труд).
2. Инвестиционные факторы:
 - инвестиции в основной капитал (с лагом 1 год).

3. Инновационные факторы:

- внутренние затраты на научные исследования и разработки (с лагами 1 и 2 года);
- доля продукции высокотехнологичных и наукоемких отраслей в ВРП.

Для отбора наиболее значимых факторов проводится расчет линейных коэффициентов корреляции Пирсона между каждым фактором и целевой переменной (темпом роста ВРП).

Для учета неопределенности макроэкономической динамики прогнозирование осуществляется по трем сценариям:

Реалистический сценарий основан на экстраполяции средних темпов роста входных факторов за последние 10 лет. Для макроэкономических параметров (курс доллара, ключевая ставка, цена нефти) используются прогнозы экспертов и официальных источников.


Оптимистический сценарий предполагает использование максимальных значений коэффициентов роста факторов за последние 10 лет (после исключения выбросов) и благоприятную макроэкономическую конъюнктуру.

Пессимистический сценарий базируется на минимальных значениях коэффициентов роста факторов и неблагоприятной макроэкономической конъюнктуре, при этом отрицательные значения принимаются равными нулю (сохранение предыдущего уровня).

Разработанная методика включает последовательную реализацию пяти этапов (рисунок).

Разработанная методика имеет следующие ограничения:

1. Модели предназначены для краткосрочного и среднесрочного прогнозирования (до трех лет). В долгосрочной перспективе структурные изменения в экономике могут приводить к снижению точности прогнозов.
2. Качество прогнозов зависит от стабильности институциональных условий и макроэкономической ситуации. При возникновении новых макроэкономических шоков требуется дообучение моделей.
3. Применение расширенных обучающих выборок на основе кластеризации предполагает, что регионы внутри кластера действительно обладают сходными закономерностями экономического развития, что требует периодической верификации.
4. Прогнозирование межрегиональной дифференциации чувствительно к качеству прогнозов темпов роста отдельных регионов – ошибки в прогнозах для отдельных субъектов могут накапливаться при расчете агрегированных показателей.



*Этапы методики прогнозирования межрегиональной дифференциации темпов роста ВРП
Примечание: составлен авторами по результатам данного исследования*

Результаты исследования и их обсуждение

На основе предоставленных данных проведен корреляционный и регрессионный анализ зависимости ВРП. Для корректного анализа все стоимостные показатели переведены в единые единицы измерения (млрд руб.) и приведены к одному временному периоду (2000–2025 гг.), с учетом доступности данных по каждому фактору. Все используемые показатели, включая объем инвестиций, состояние основных фондов, финансирование НИОКР, уровень занятости и динамику сектора HighTech, сформированы на основе опубликованных данных Росстата и НИУ ВШЭ. Указанные статистические сборники размещены в свободном доступе, что обеспечивает прозрачность и воспроизводимость приведенных расчетов.

Результаты регрессионного анализа приведены в табл. 1.

НИОКР показывают наибольшую эластичность в индустриальных регионах: Свердловская (0,112), Тюменская область без АО (0,104), Челябинская (0,098) области. В ресурсных регионах влияние НИОКР значительно ниже (0,048–0,054), что объясняется структурными особенностями экономики.

Занятость оказывает значимое положительное влияние во всех регионах, кроме Курганской области. Наибольшая эластичность в Тюменской области без АО (0,334) и Тюменской области полной (0,312). Отрицательный (хотя и незначимый) коэффициент в Курганской области подтверждает выводы корреляционного анализа о структурных проблемах рынка труда.

Таблица 1

Результаты регрессионного анализа (коэффициенты эластичности)

Регион	Инвестиции	Основные фонды	НИОКР	Занятость	HighTech	R ²
Курганская область	0,312	0,256	0,089	-0,145	0,023	0,989
Свердловская область	0,287	0,301	0,112	0,245	0,031	0,994
Тюменская область (полная)	0,354	0,278	0,076	0,312	0,018	0,992
ХМАО-Югра	0,401	0,315	0,054	0,298	0,009	0,996
ЯНАО	0,389	0,332	0,048	0,287	0,007	0,995
Тюменская область (без АО)	0,276	0,293	0,104	0,334	0,042	0,993
Челябинская область	0,298	0,287	0,098	0,278	0,026	0,991

Примечание: составлена авторами на основе полученных данных в ходе исследования.

Таблица 2

Сравнение метрик качества моделей

Модель	MAPE (%)	RMSE	R ²
Random Forest	3,42	2,18	0,973
XGBoost	2,89	1,94	0,981
CatBoost	2,67	1,82	0,986

Примечание: составлена авторами на основе полученных данных в ходе исследования.

Таблица 3

Прогноз темпов роста ВРП по регионам на 2026–2028 гг. (%)

Регион	2026	2027	2028	Среднегодовой рост
Курганская область	102,8	104,2	105,7	2,9 %
Свердловская область	103,5	104,9	106,4	3,1 %
Тюменская область (полная)	102,9	104,1	105,3	2,6 %
ХМАО-Югра	102,4	103,6	104,8	2,4 %
ЯНАО	102,1	103,2	104,3	2,1 %
Тюменская область (без АО)	104,2	106,1	108,3	4,0 %
Челябинская область	103,2	104,7	106,2	3,0 %

Примечание: составлена авторами на основе полученных данных в ходе исследования.

Доля высокотехнологичных отраслей оказывает значимое положительное влияние в большинстве регионов. Наибольший эффект в Тюменской области без АО (0,042), Свердловской (0,031) и Курганской (0,023) областях. В ресурсных регионах фактор статистически незначим.

Все исследуемые факторы (кроме занятости в Курганской области) демонстрируют сильную и очень сильную корреляцию с ВРП, что подтверждает теоретические положения производственной функции Кобба – Дугласа и обосновывает включение этих факторов в прогнозные модели. Построенные регрессионные модели обладают высоким качеством ($R^2 > 0,99$) и могут быть использованы для прогнозирования ВРП и оценки эффективности региональной политики.

Проведем прогнозирование темпов роста ВРП для регионов Уральского макрорегиона с использованием трех моделей машинного обучения. На основе проведенного анализа ожидаются следующие метрики качества (табл. 2).

CatBoost показывает наилучшие результаты благодаря эффективной обработке категориальных признаков (тип региона) и устойчивости к переобучению. XGBoost демонстрирует близкие результаты, особенно при хорошо настроенных гиперпараметрах. Random Forest также показывает высокое качество, но несколько уступает гра-

диентному бустингу. Прогноз темпов роста ВРП на 2026–2028 гг. представлен в табл. 3.

Наиболее заметный среднегодовой прирост валового продукта региона в течение прогнозируемого периода ожидается в Тюменской области без учета отдельных округов – 4,0 %. Причина здесь не в добыче углеводородов, а в постепенной ориентации экономики. Обрабатывающие отрасли активно развиваются, зависимость от сырьевых компонентов снижается. Промышленные зоны – Свердловская и Челябинская области – демонстрируют предсказуемый и стабильный рост в пределах 3,0–3,1 %.

Из трех использованных предварительных моделей CatBoost показала наилучшие результаты, при этом средняя абсолютная процентная ошибка составила всего 2,67 %. Однако другие модели также показали хорошие результаты – коэффициент R^2 во всех моделях превысил 0,97. Это косвенно подтверждает, что набор факторов подобран правильно, а сама методология в целом корректна. Что касается прогнозов на 2026–2028 гг., то межрегиональное распределение остается неизменным: с 2,1 % в сырьевых регионах до 4,0 % в перерабатывающих.

Заключение

Проведенное исследование, посвященное прогнозированию межрегиональной дифференциации темпов роста ВРП субъектов Уральского макрорегиона с исполь-

зованием методов машинного обучения, позволяет сформулировать следующие основные выводы.

Во-первых, разработана и апробирована двухэтапная методика прогнозирования межрегиональной дифференциации, включающая прогнозирование темпов роста ВРП каждого региона с использованием ансамблевых методов машинного обучения и последующий расчет показателей дифференциации.

Во-вторых, сравнительный анализ трех моделей (Random Forest, XGBoost, CatBoost) показал, что наилучшие результаты демонстрирует CatBoost, что подтверждает эффективность градиентного бустинга для задач регионального прогнозирования.

В-третьих, прогнозные расчеты на 2026–2028 гг. показывают сохранение межрегиональной дифференциации при некотором сокращении разрыва между индустриальными и ресурсными регионами.

Практическая значимость полученных результатов заключается в возможности их использования органами регионального управления после дополнительной валидации для обоснования параметров политики выравнивания уровней регионального развития и распределения средств федеральной поддержки. Предложенная методика может быть адаптирована для прогнозирования дифференциации других социально-экономических показателей.

Список литературы

1. Азарнова Т. В., Трещевский Ю. И., Папин С. Н. Прогнозирование параметров социально-экономического развития региона с использованием аппарата нейронных сетей (на примере ВРП Воронежской области) // Современная экономика: проблемы и решения. 2020. Т. 3 (123). № 3. С. 8–25. DOI: 10.17308/meps.2020.3/2321.
2. Сочков А. Л., Соловьев А. Е. Прогнозирование экономического развития Ставропольского края на базе нейросетевой модели // Актуальные проблемы управления: сборник научных статей по итогам VIII Всероссийской научно-практической конференции (г. Нижний Новгород, 16 ноября 2021 г.). Нижний Новгород: Национальный исследовательский Нижегородский государственный университет им. Н. И. Лобачевского, 2022. С. 386–391.
3. Balungu D. M., Kumar A. Forecasting the Economic Growth of Sverdlovsk Region: A Comparative Analysis of Machine Learning, Linear Regression and Autoregressive Models // Journal of Applied Economic Research. 2024. Vol. 23. Is. 3. P. 674–695. DOI: 10.15826/vestnik.2024.23.3.027.
4. Трифонов Ю. В., Сочков А. Л., Соловьев А. Е. Оценка экономического потенциала регионов РФ на основе методологии нейросетевого кластерного анализа // Вестник Нижегородского университета им. Н. И. Лобачевского. Серия: Социальные науки. 2021. № 3 (63). С. 38–47. DOI: 10.52452/18115942_2021_3_38.
5. Malkina M. Yu., Sochkov A. L., Kapustina Yu. I. Forecasting regional GRP using artificial intelligence methods // Journal of New Economy. 2025. Vol. 26. Is. 3. P. 67–85. DOI: 10.29141/2658-5081-2025-26-3-4.
6. Леонидова Е. Г. Резервы стимулирования конечного потребления населения в регионах Северо-Запада России // Управленец. 2025. Т. 16. № 1. С. 61–75. DOI: 10.29141/2218-5003-2025-16-1-5.
7. Вольчик В. В., Цыганков. С. С., Маскаев А. И. Политика нового менеджмента в государственном секторе как продолжение идеологии неоллиберализма // Управленец. 2024. Т. 15. № 6. С. 2–16. DOI: 10.29141/2218-5003-2024-15-6-1.
8. Самсонов А. В., Сергеев Л. И. Прогнозирование динамики регионального ВРП с использованием аппарата рекуррентных нейронных сетей // Russian Economic Bulletin. 2021. Т. 4. № 5. С. 240–252.
9. Кулова М. Р., Соколова Э. Б., Федосова Е. В. Сравнительный анализ статистических и нейросетевых методов прогнозирования ВРП (на примере РСО-Алания) // Финансовый бизнес. 2025. № 11 (269). С. 52–56. EDN: RNFHUC.
10. Плехова Ю. О., Перова В. И. Инновационный метод анализа управления социально-экономическим развитием регионов России с применением нейросетевого моделирования // Вопросы инновационной экономики. 2025. Т. 15. № 1. С. 125–144. DOI: 10.18334/vines.15.1.122530.
11. Пыхов П. А. Прогнозирование состояния энергобезопасности Урала: методический подход и результаты исследований // Управление экономическими системами: электронный научный журнал. 2019. № 12 (130). С. 65. EDN: AWVWFU.
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. Т. 243. № 5. С. 200–226. DOI: 10.38197/2072-2060-2023-243-5-200-226.
13. Breiman L. Random Forests // Machine Learning. 2001. Vol. 45. Is. 1. P. 5–32.
14. Chen T., Guestrin C. XGBoost: A scalable tree boosting system // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2016. P. 785–794.
15. Prokhorenkova L., Gusev G., Vorobev A., Dorogush A. V., Gulin A. Catboost: Unbiased boosting with categorical features // Advances in Neural Information Processing Systems: 32 (Montreal, QC, 02–08 декабря 2018 г.). Montreal, QC, 2018. P. 6638–6648. EDN: NRYEVS.

Конфликт интересов: Авторы заявляют об отсутствии конфликта интересов.

Conflict of interest: The authors declare that there is no conflict of interest.

Финансирование: Авторы заявляют об отсутствии внешнего финансирования.

Financing: The research was performed without external funding.