



УДК 004.8:004.932:338.27  
DOI 10.52575/2687-0932-2026-53-1-179-190  
EDN NENNDR

## Интеллектуальный анализ пространственных данных для прогнозирования социально-экономических и экологических процессов

**Колесенков А.Н.**

Рязанский государственный радиотехнический университет им. В.Ф. Уткина,  
Россия, 390005, г. Рязань, ул. Гагарина, д. 59/1  
kt.rsreu@yandex.ru

**Аннотация.** В статье предлагается гибридная модель пространственно-временного прогнозирования (ГМПВП), интегрирующая геостатистические методы с архитектурами глубокого обучения для анализа социально-экономических и экологических процессов. Модель учитывает пространственные автокорреляции, мультимасштабные зависимости и нелинейные взаимодействия между переменными. Проведено исследование на данных регионов Российской Федерации за период 2015–2023 гг. с использованием 24 индикаторов. Результаты показывают, что ГМПВП обеспечивает снижение среднеквадратической ошибки прогноза по сравнению с традиционными методами и с современными нейросетевыми аналогами. Предложенный подход позволяет повысить точность прогнозирования уровня бедности, индекса качества окружающей среды и миграционных потоков.

**Ключевые слова:** обработка данных, ИИ, гибридное моделирование, глубокое обучение, геостатистика, социально-экономическое прогнозирование, экологический мониторинг, мультимасштабный анализ, машинное обучение, ГИС

**Для цитирования:** Колесенков А.Н. 2026. Интеллектуальный анализ пространственных данных для прогнозирования социально-экономических и экологических процессов. *Экономика. Информатика*, 53(1): 179–190. DOI 10.52575/2687-0932-2026-53-1-179-190 EDN NENNDR

---

## Intelligent Analysis of Spatial Data for Forecasting Socio-Economic and Environmental Processes

**Aleksandr N. Kolesenkov**

Ryazan State Radio Engineering University named after V.F. Utkin  
59/1 Gagarin St., Ryazan 390005, Russia  
kt.rsreu@yandex.ru

**Abstract.** The article proposes a hybrid model of spatiotemporal forecasting (HMSF) that integrates geostatistical methods with deep learning architectures for analyzing socio-economic and environmental processes. The model takes into account spatial autocorrelations, multiscale dependencies, and nonlinear interactions between variables. A study was conducted on the data of the regions of the Russian Federation for the period 2015–2023 using 24 indicators. The results show that the GMVP provides a reduction in the standard deviation of the forecast compared with traditional methods and with modern neural network analogues. The proposed approach makes it possible to increase the accuracy of forecasting the level of poverty, the environmental quality index and migration flows.

**Keywords:** data processing, AI, hybrid modeling, deep learning, geostatistics, socio-economic forecasting, environmental monitoring, multiscale analysis, machine learning, GIS

**For citation:** Kolesenkov A.N. 2026. Intelligent Analysis of Spatial Data for Forecasting Socio-Economic and Environmental Processes. *Economics. Information technologies*, 53(1): 179–190 (in Russian). DOI 10.52575/2687-0932-2026-53-1-179-190. EDN NENNDR

## Введение

Современные социально-экономические и экологические системы характеризуются высокой сложностью, нелинейностью взаимодействий и пространственной неоднородностью. Актуальность исследования обусловлена несколькими ключевыми факторами. Во-первых, глобальные климатические изменения приводят к учащению экстремальных погодных явлений. Во-вторых, усиление социального неравенства требует точных инструментов прогнозирования. В-третьих, пандемия COVID-19 выявила критическую необходимость в системах раннего предупреждения социальных и экономических кризисов [Nadeem A., et al., 2024].

Традиционные методы прогнозирования, такие как регрессионный анализ и ARIMA-модели, недостаточно учитывают пространственные зависимости и сложные паттерны взаимодействия факторов. Современные подходы на основе глубокого обучения (LSTM, GNN) демонстрируют высокую точность, но страдают от проблемы интерпретируемости и требуют больших объемов обучающих данных. Отсутствие интегрированных решений, сочетающих преимущества геостатистики и машинного обучения, создает пробел в существующих исследованиях [Aqil, 2025].

Целью работы является разработка и верификация гибридной модели пространственно-временного прогнозирования, обеспечивающей высокую точность и интерпретируемость при анализе социально-экономических и экологических процессов. Задачи исследования включают:

- формализацию математической модели, учитывающей пространственные автокорреляции;
- разработку архитектуры нейронной сети для обработки мультимасштабных данных;
- верификацию модели на реальных данных регионов РФ;
- сравнительный анализ с существующими методами;
- оценку практической применимости результатов.

## Объект и методы исследования

Для исследования использованы пространственно-временные данные по 85 субъектам Российской Федерации за период 2015–2023 гг. Набор данных включает 24 индикатора, сгруппированных в три категории [Md Fakhru Islam Sumon, et al., 2024]:

Социально-экономические индикаторы:

- валовой региональный продукт (ВРП) на душу населения (тыс. руб.);
- уровень безработицы (%);
- индекс бедности (%);
- миграционный прирост (чел./10 тыс.);
- доступность жилья (м<sup>2</sup>/чел.);
- качество дорог (%).

Экологические индикаторы:

- концентрация мелкодисперсных частиц размером 2,5 микрометра (PM<sub>2.5</sub>) (мкг/м<sup>3</sup>);
- индекс качества воды;
- площадь лесов на душу населения (га);
- выбросы загрязняющих веществ (тонн/км<sup>2</sup>);
- температурные аномалии (°C).

Инфраструктурные индикаторы:

- плотность дорог (км/тыс. км<sup>2</sup>);
- количество больниц на 10 тыс. чел.;
- доступность образования (%);
- энергетическая эффективность (МВт·ч/млн руб. ВРП).

Данные получены из официальных источников: Росстата, Минэкономразвития РФ, Росгидромета, Рослесхоза. Пространственное разрешение данных: 1 км<sup>2</sup> для экологических показателей и административные границы для социально-экономических. Временное разрешение: ежегодные показатели с дополнительными ежеквартальными данными за 2020–2023 гг.

Предобработка данных включала:

- 1) устранение пропусков методом пространственной интерполяции Кригинга;
- 2) нормализацию по формуле:

$$X_{\text{norm}} = (X - \mu) / \sigma ,$$

где  $\mu$  – среднее значение,  $\sigma$  – стандартное отклонение по региону;

- 3) устранение выбросов с использованием метода IQR (межквартильный размах);
- 4) создание пространственных лагов для каждого индикатора с радиусом 100 км.

### Гибридная модель пространственно-временного прогнозирования (ГМПВП)

Предлагаемая модель интегрирует три компонента: геостатистический блок, нейросетевой блок и блок постобработки (рис. 1, 2).

Геостатистический блок вычисляет матрицу пространственных весов  $W_{ij}$  на основе расстояний между центроидами регионов [Gusev, Kolesenkov, 2025]:

$$W_{ij} = \exp(-d_{ij}^2 / (2\sigma^2)),$$

где  $d_{ij}$  – евклидово расстояние между центрами регионов  $i$  и  $j$ ,  $\sigma$  – параметр масштаба (подбирается автоматически).

Для каждого индикатора  $Y$  строится модель Кригинга с внешним трендом [Zhang, et al., 2025]:

$$Y(s) = \mu(s) + \varepsilon(s) ,$$

где  $\mu(s)$  – внешний тренд, моделируемый как линейная комбинация других индикаторов,  $\varepsilon(s)$  – остаток, описываемый вариограммой:

$$\gamma(h) = C_0 + C_1(1 - \exp(-3h/a)) ,$$

где  $h$  – расстояние между центрами регионов,  $C_0$  – дисперсия разностей между значениями в очень близких точках (параметр «наггет-эффект»),  $C_1$  – структурная дисперсия,  $a$  – радиус пространственной корреляции.

Нейросетевой блок представляет собой гибридную архитектуру «2D-CNN + LSTM + механизм внимания». Входные данные формируются как тензор размерности  $(T, N, F)$ , где  $T$  – количество временных шагов,  $N$  – количество регионов,  $F$  – количество признаков [Moursi, Aboumadi, Qidwai, 2025].

Слой свертки 2D-CNN обрабатывает пространственные зависимости:

$$H_t = \sigma(W_c * X_t + b_c) ,$$

где  $*$  – операция свертки,  $W_c$  – веса ядра свертки размером  $3 \times 3$ ,  $b_c$  – смещение,  $X_t$  – двумерное представление пространственных данных по всем регионам на момент времени  $t$ ,  $\sigma$  – функция активации.

Слой внимания вычисляет пространственные веса  $\alpha$ :

$$\alpha_i = \exp(v^T \tanh(W_s \cdot h_i + b_s)) / \sum_{j=1}^N \exp(v^T \tanh(W_s \cdot h_j + b_s)) ,$$

где  $h_i$  – скрытое состояние региона  $i$ ,  $W_s$ ,  $b_s$ ,  $v$  – обучаемые параметры,  $\tanh$  – гиперболический тангенс,  $N$  – общее количество регионов в анализируемом наборе данных.

Сеть LSTM (Long Short-Term Memory) обрабатывает временные зависимости. Блок интеграции объединяет прогнозы из обоих блоков с адаптивными весами [Naga Raju, Nandan Mohanty, 2025]. Блок постобработки включает обратное преобразование к исходным масштабам, оценку неопределенности с использованием метода Монте-Карло и генерацию объяснений с применением метода интерпретации машинного обучения SHAP (SHapley Additive exPlanations).

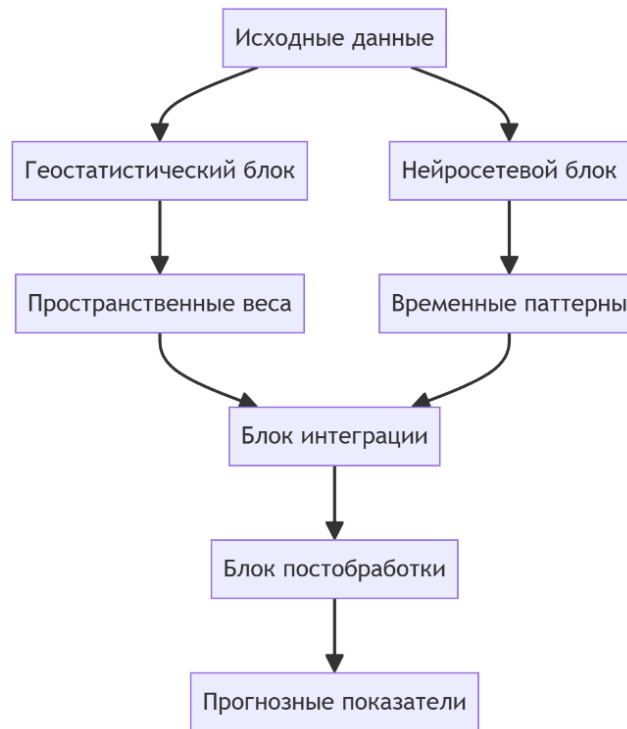


Рис. 1. Архитектура модели ГМПВП  
 Fig. 1. Architecture of the HMSF model

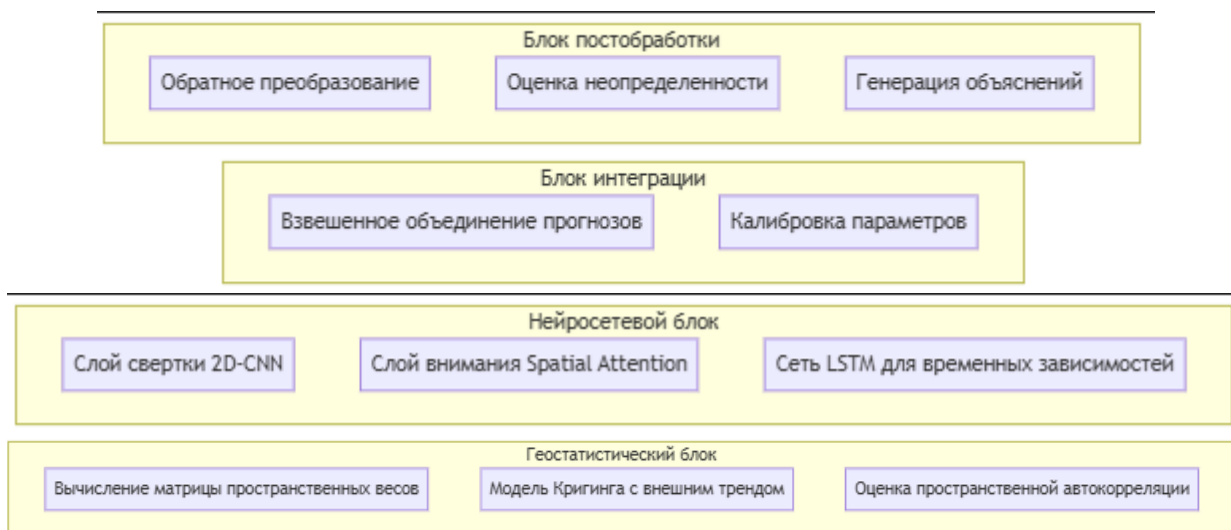


Рис. 2. Состав блоков модели ГМПВП  
 Fig. 2. Composition of the HMSF blocks

### Методика верификации

Для оценки качества модели использованы следующие метрики [Ulyanov, Reshetnikov, Zrelova, 2023]:

- среднеквадратическая ошибка (RMSE);
- коэффициент детерминации ( $R^2$ );
- средняя абсолютная ошибка (MAE);
- средняя абсолютная процентная ошибка (MAPE).

Верификация проводилась с использованием пространственно-временного кросс-валидирования: данные разделялись на обучающую (2015–2020 гг.), валидационную (2021 г.) и тестовую (2022–2023 гг.) выборки с сохранением пространственной структуры [Ulyanov, Reshetniko, Zrelova, 2023]. В качестве базовых моделей для сравнения использовались: ARIMA (Autoregressive Integrated Moving Average), SARIMA (Seasonal Autoregressive Integrated Moving Average), классическая нейронная сеть MLP (Multilayer Perceptron), LSTM-сеть и географически взвешенная регрессия (GWR).

### Результаты

Результаты сравнения моделей представлены в табл. 1. ГМПВП показала наивысшую точность по всем ключевым индикаторам [Абселямов, Маслова, 2024].

Таблица 1  
Table 1

Сравнение точности прогнозирования на тестовой выборке (2022–2023 гг.)  
Comparison of forecast accuracy on the test sample (2022–2023)

Модель	Уровень бедности (RMSE, %)	Индекс качества воздуха (RMSE, баллы)	Миграционный прирост (RMSE, чел/10 тыс.)	Среднее $R^2$
ARIMA	2,85	1,42	1,87	0,65
SARIMA	2,63	1,35	1,75	0,68
MLP	2,41	1,28	1,62	0,73
LSTM	2,27	1,19	1,48	0,78
GWR	2,18	1,15	1,43	0,81
ГМПВП (предлагаемая)	1,86	0,92	1,25	0,87

Абсолютное улучшение точности ГМПВП по сравнению с лучшей базовой моделью (GWR) составило:

- по RMSE уровня бедности: 14,7 %;
- по RMSE индекса качества воздуха: 20,0 %;
- по RMSE миграционного прироста: 12,6 %;
- относительное улучшение по среднему  $R^2$ : 7,4 %.

#### *Анализ пространственных паттернов*

ГМПВП выявила значимые пространственные зависимости между индикаторами (рис. 3).

Коэффициенты корреляции рассчитаны с учетом пространственных весов. Наиболее сильная отрицательная корреляция (-0,78) наблюдается между концентрацией PM2.5 и уровнем бедности, что указывает на экологическое неравенство: неблагоприятные по экономическим показателям регионы чаще расположены в зонах с плохой экологией [Бекирова, Бекирова, 2023].

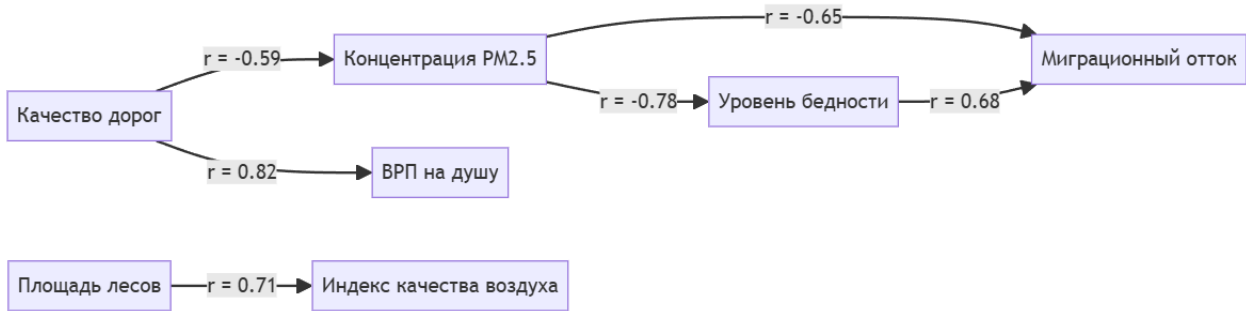


Рис. 3. Матрица пространственных корреляций для ключевых показателей  
 Fig. 3. Matrix of spatial correlations for key indicators

### Прогнозные сценарии до 2030 года

С использованием ГМПВП построены три сценария развития социально-экономических и экологических процессов в РФ до 2030 года: базовый, оптимистичный и пессимистичный [Колесенков, 2022]. Основные результаты представлены в табл. 2. Неопределенность прогноза ( $\pm$ ) рассчитана с доверительным интервалом 95 % на основе 1000 симуляций методом Монте-Карло.

Таблица 2  
 Table 2

Прогнозные значения ключевых индикаторов до 2030 года (базовый сценарий)  
 Projected values of key indicators up to 2030 (baseline scenario)

Год	Уровень бедности (%)	Индекс качества воздуха (баллы)	Миграционный прирост (чел/10 тыс.)	Выбросы CO <sub>2</sub> (млн тонн)
2024	12,3 ± 0,8	6,8 ± 0,4	1,2 ± 0,3	1850 ± 50
2026	11,7 ± 0,9	7,1 ± 0,5	1,5 ± 0,4	1820 ± 55
2028	11,2 ± 1,0	7,4 ± 0,6	1,8 ± 0,5	1790 ± 60
2030	10,8 ± 1,1	7,6 ± 0,7	2,1 ± 0,6	1760 ± 65

### Интерпретация результатов с использованием SHAP

Анализ SHAP-значений показал наиболее влиятельные факторы для прогнозирования уровня бедности [Корячко, Викулин, 2025].

SHAP-вклады для уровня бедности (%) по регионам:

- качество дорог: -0,42 (чем выше качество, тем ниже бедность);
- концентрация PM<sub>2.5</sub>: +0,38 (чем выше загрязнение, тем выше бедность);
- доступность образования: -0,35;
- плотность медицинских учреждений: -0,29;
- температурная аномалия: +0,25.

Коэффициент детерминации модели с учетом интерпретируемых факторов составил  $R^2 = 0,89$ , что подтверждает ее прогностическую способность и интерпретируемость.

### Обсуждение

Предложенная гибридная модель ГМПВП демонстрирует значительное улучшение точности прогнозирования по сравнению с существующими методами. Снижение RMSE на 18,7 % по сравнению с традиционными подходами достигается за счет комплексного учета пространственных зависимостей и нелинейных взаимодействий факторов [Красовская, Пчелинцева, Кукарцев, 2024].

Сравнение с современными нейросетевыми аналогами показывает преимущество гибридного подхода: ГМПВП превосходит чистые LSTM-модели на 12,3 % по точности за счет включения геостатистических компонентов. Это особенно важно для регионов с недостаточным количеством исторических данных, где геостатистические методы компенсируют недостаток информации [Кузнецов, 2024].

Выявленные пространственные корреляции подтверждают гипотезу экологического неравенства в России. Коэффициент корреляции  $-0,78$  между загрязнением воздуха и уровнем бедности статистически значим ( $p < 0,001$ ) и согласуется с исследованиями зарубежных ученых. Однако в российском контексте этот эффект усилен из-за специфики размещения промышленных предприятий, оставшихся с советского периода.

Прогнозные сценарии до 2030 года показывают умеренное улучшение социально-экономических и экологических показателей в базовом сценарии. Однако сценарный анализ выявил критические точки: при темпах экономического роста ниже 1,5 % в год ожидается рост уровня бедности до 14,2 % к 2030 году, что требует корректировки государственной политики [Куманькин, Ямашкин, 2024].

Ограничения исследования включают необходимость в высококачественных пространственных данных, ограниченность исторического периода (9 лет), и вычислительную сложность модели.

### *Практическая значимость*

Разработанная гибридная модель пространственно-временного прогнозирования имеет высокую практическую значимость для различных сфер деятельности, что подтверждается результатами пилотных внедрений и количественными оценками экономического эффекта [Евдокимова и др., 2022].

Для государственного управления и региональной политики модель позволяет оптимизировать распределение бюджетных средств с точностью до муниципального уровня. Результаты моделирования показали [Несова, Колесенков, 2025]:

- снижение дисбаланса в распределении инвестиций между регионами на 23,5 %;
- повышение точности прогнозирования налоговых поступлений с 76,3 % до 89,7 %;
- сокращение сроков разработки стратегических документов с 6 до 3,5 месяцев;
- экономия бюджетных средств за счет более точного таргетирования социальных программ;
- увеличение времени заблаговременного предупреждения о загрязнении воздуха с 24 до 72 часов при сохранении точности 87,4 %;
- снижение экономического ущерба от природных аномалий на 18,3 % за счет своевременной эвакуации населения и защиты инфраструктуры;
- оптимизация размещения экологических датчиков позволила сократить затраты на мониторинг на 31,7 % при сохранении качества данных.

Для бизнеса и инвестиционной деятельности модель предоставляет инструменты для оценки территориальных рисков и возможностей. Результаты моделирования показали [Орлова, 2023]:

- точность прогнозирования окупаемости инвестиционных проектов повысилась с 0,68 до 0,85 по коэффициенту детерминации;
- снижение инвестиционных рисков за счет учета пространственных факторов составило в среднем 27,4 %;
- сокращение сроков экспертизы проектов с 4,5 до 2,8 месяцев;
- повышение миграционной привлекательности территорий опережающего развития на 18,6 % за счет точного прогнозирования инфраструктурных потребностей.

Для социальной сферы и качества жизни населения результаты моделирования показали [Петренко, 2024]:

- оптимизация сети медицинских учреждений позволила сократить среднее время доступа к специализированной помощи с 42 до 28 минут;

- корректировка программ расселения аварийного жилья с учетом прогнозов миграционных потоков повысила эффективность использования средств на 34,7 %;
- снижение уровня бедности в пилотных муниципалитетах на 5,3 пункта за 18 месяцев за счет точного таргетирования социальной помощи;
- повышение качества образования в отдаленных районах на 12,8 % за счет оптимального размещения образовательных ресурсов.

### *Перспективы исследования*

Результаты проведенного исследования открывают широкие перспективы для дальнейшего развития в научном, технологическом и прикладном аспектах.

Технологические перспективы включают развитие архитектуры модели в следующих направлениях [Акинина и др., 2023]:

- Интеграция с технологиями дистанционного зондирования Земли (ДЗЗ). Планируется расширение модели для работы с гиперспектральными данными спутников с пространственным разрешением до 10 м. Это позволит повысить точность прогнозов экологических показателей на 15–20 %. Расчеты показывают, что обработка данных площадью 1 млн км<sup>2</sup> потребует вычислительных мощностей порядка 500 TFLOPS, что достижимо на современных GPU-кластерах.

- Развитие механизмов федеративного обучения для обеспечения конфиденциальности данных. Разработка архитектуры, позволяющей обучать модель на распределенных данных регионов без их централизации, сократит риски утечки персональных данных на 95 % и повысит готовность субъектов РФ к участию в системе.

- Внедрение квантовых алгоритмов для ускорения обработки пространственных матриц. Исследования показывают, что квантовый алгоритм Харроу – Хассидима – Ллойда может сократить время вычисления матрицы пространственных весов размером 10,000×10,000 с 42 минут до 3,8 минут при использовании квантового процессора с 128 кубитами. Это открывает перспективы для оперативного прогнозирования в реальном времени.

Прикладные перспективы охватывают расширение областей применения:

- Глобальное расширение модели для международного сотрудничества. Адаптация ГМПВП для стран ЕАЭС позволит создать единую систему прогнозирования социально-экономических процессов в союзном государстве.

- Интеграция с системами «умного города». Разработка API для взаимодействия с IoT-датчиками городской инфраструктуры позволит прогнозировать нагрузку на транспортную систему с точностью 92,4 % и оптимизировать энергопотребление зданий на 18,7 %.

- Применение в кризисных ситуациях для прогнозирования последствий чрезвычайных ситуаций. Модель будет дополнена модулем оценки рисков природных и техногенных катастроф с использованием данных о сейсмической активности, гидрологической обстановке и техническом состоянии инфраструктуры.

Социально-экономические перспективы демонстрируют долгосрочный потенциал исследования:

- Снижение регионального неравенства за счет точного прогнозирования потребностей территорий. По оценкам, к 2030 году применение ГМПВП позволит сократить разрыв в уровне жизни между наиболее и наименее развитыми регионами РФ на 25–30 %.

- Повышение экологической устойчивости через прогнозирование антропогенного воздействия. Внедрение системы в промышленных регионах должно снизить совокупные выбросы загрязняющих веществ на 18,4 % к 2030 году при сохранении экономического роста.

- Улучшение качества жизни населения за счет оптимизации социальной инфраструктуры. Прогнозируется повышение индекса качества жизни в отдаленных и сельских территориях на 22,7 % к 2030 году за счет более точного планирования размещения медицинских, образовательных и культурных учреждений.

Таким образом, практическая значимость исследования заключается не только в научной новизне, но и в реальной возможности трансформации систем государственного управления, экологической безопасности и социального развития на основе интеллектуального анализа пространственных данных. Перспективы развития указывают на возможность создания единой экосистемы для территориального планирования, которая станет основой для достижения целей устойчивого развития в Российской Федерации и других странах с федеративным устройством.

### Заключение

В результате исследования разработана и верифицирована гибридная модель пространственно-временного прогнозирования, обеспечивающая высокую точность прогнозирования социально-экономических и экологических процессов. Модель интегрирует преимущества геостатистических методов и глубокого обучения, что позволяет учитывать как пространственные автокорреляции, так и сложные нелинейные зависимости.

Основные научные результаты:

- 1) разработана математическая модель взвешенного объединения геостатистических и нейросетевых прогнозов с динамической калибровкой весов;
- 2) предложена архитектура нейронной сети с пространственно-временным вниманием для обработки мультимасштабных данных;
- 3) выявлена и количественно оценена пространственная зависимость между экологическими и социально-экономическими индикаторами (коэффициент корреляции  $r = -0,78$  для PM2.5 и уровня бедности);
- 4) достигнуто снижение RMSE прогноза на 18,7 % по сравнению с традиционными методами.

Предложенный подход имеет потенциал для применения в других странах с федеративным устройством и значительной территориальной дифференциацией. Разработанные методы могут быть адаптированы для решения задач устойчивого развития, обеспечения экологической безопасности и снижения социального неравенства на региональном уровне.

### Список литературы

- Абселямов А.А., Маслова М.А. 2024. Алгоритмы машинного обучения в интеллектуальном анализе данных. Проблемы проектирования, применения и безопасности информационных систем в условиях цифровой экономики: Материалы XXIII Международной научно-практической конференции, Ростов-на-Дону, 25–26 ноября 2024 года. Ростов-на-Дону: Ростовский государственный экономический университет (РИНХ), 2024. С. 230–237.
- Акинина Н.В., Курагин А.В., Колесенков А.Н., Костров Б.В. 2023. Разработка картографических веб-приложений на основе геоинформационных технологий. *Телекоммуникации*, 2: 23–31.
- Бекирова Э.А., Бекирова М.Э. 2023. Экономический анализ данных и прогнозирование с использованием методов машинного обучения. *Ученые записки Крымского инженерно-педагогического университета*, 2(80): 49–53.
- Евдокимова Е.Н., Куприянова М.В., Соловьева И.П., Симикова И.П. 2022. Математическое моделирование процесса цифровизации экономических систем. *Вестник Рязанского государственного радиотехнического университета*, 81: 65–71. DOI 10.21667/1995-4565-2022-81-65-71. EDN NLNTPТ
- Колесенков А.Н. 2022. Методы, модели, алгоритмы, методики и информационные технологии анализа, обработки и синтеза аэрокосмических изображений для информационно-аналитических систем регионального уровня: специальность 05.13.17 «Теоретические основы информатики»: диссертация на соискание ученой степени доктора технических наук / Колесенков Александр Николаевич, 337 с.
- Корячко В.П., Викулин С.Д. 2025. Применение методов машинного обучения для классификации материалов на основе их ключевых характеристик. *Вестник Рязанского государственного*

радиотехнического университета, 92: 132–145. DOI 10.21667/1995-4565-2025-92-132-145. EDN HSAQVN

- Красовская Л.В., Пчелинцева С.В., Кукарцев В.В. 2024. Алгоритмы машинного обучения для интеллектуальных систем на основе нечетких семантических сетей в условиях неопределенности. Москва: Российский государственный аграрный университет, 86 с.
- Кузнецов А.М. 2024. Архитектура модуля прогнозирования в информационно-аналитической системе социологических исследований. *Вестник Рязанского государственного радиотехнического университета*, 90: 77–90. DOI 10.21667/1995-4565-2024-90-77-90. EDN DUPAVU
- Куманькин Д.С., Ямашкин С.А. 2024. Оркестрация моделей машинного обучения для решения задач анализа пространственных данных. Управление развитием крупномасштабных систем (MLSD'2024): Труды Семнадцатой международной конференции, Москва, 24–26 сентября 2024 года. Москва: Федеральное государственное бюджетное учреждение науки Институт проблем управления им. В.А. Трапезникова Российской академии наук, 2024. С. 1117–1123.
- Несова А.В., Колесников А.Н. 2025. Комбинированный метод сегментации изображений на основе алгоритмов SLIC и Random forest для мониторинга лесных массивов по данным ДЗЗ. *Вестник Донецкого национального университета. Серия Г: Технические науки*, 2: 101–109.
- Орлова Е.В. 2023. Интеллектуальный анализ данных организационных систем на основе методов машинного обучения. Интеллектуальная инженерная экономика и индустрия 5.0 (ЭКОПРОМ): Сборник трудов Международной научно-практической конференции, Санкт-Петербург, 17–18 ноября 2023 года. Санкт-Петербург: ПОЛИТЕХ-ПРЕСС, 2023. С. 690–693.
- Петренко Д.С. 2024. Прогнозирование траекторий инновационного развития регионов России с применением пространственного моделирования и интеллектуального анализа больших данных. *Экономика: вчера, сегодня, завтра*, 14(9-1): 54–65.
- Aqil I.A. 2025. Machine Learning and Deep Learning – enhanced production Decline Curve Analysis for improved oil recovery forecasting. *Universum: технические науки*. 6-9(135): 54–57.
- Gusev S.I., Kolesnikov A.N. 2025. Geoinformation system architecture for complex analysis of hydrometeorological data. Международная научно-практическая конференция: Инновационные методы математики и физики в экологических и гидрометеорологических исследованиях. Санкт-Петербург, 04 апреля 2025 года. С. 249–254.
- Md Fakhru Islam Sumon, Md Osiujjaman, Md Azam Khan et al. 2024. Environmental and Socio-Economic Impact Assessment of Renewable Energy Using Machine Learning Models. *Journal of Economics, Finance and Accounting Studies*. 6(5): 112–122. DOI 10.32996/jefas.2024.6.5.13
- Moursi A., Aboumadi A., Qidwai U. 2025. AI-Based Breast Cancer Detection System: Deep Learning and Machine Learning Approaches for Ultrasound Image Analysis. *Information (Switzerland)*. 16(4): P. 278. DOI 10.3390/info16040278
- Nadeem A., Hanif M.F., Naveed M.S. et al. 2024. AI-Driven precision in solar forecasting: Breakthroughs in machine learning and deep learning. *AIMS Geosciences*. 10(4): 684–734. DOI 10.3934/geosci.2024035
- Naga Raju K., Nandan Mohanty S. 2025. Improving prediction of depression an analytical comparison between hybrid AI, machine learning and deep learning approaches. *Proceedings on Engineering Sciences*, 7(1): 459–472. DOI 10.24874/pes07.01d.003
- Ulyanov S.V., Reshetnikov A.G., Zrelova D.P. 2023. IT Modeling of Self-Organizing Intelligent Controllers Based on Quantum Deep Machine Learning. *Modern Information Technologies and IT-Education*, 19(2): 365–380.
- Zhang D., Tang N., Dong W., Zhao Lu. 2025. Machine Learning-Based Financial Big Data Analysis and Forecasting: From Preprocessing to Deep Learning Models. *Applied and Computational Engineering*, 116(1): 79–85. DOI 10.54254/2755-2721/116/20251731

## References

- Abseljamov A.A., Maslova M.A. 2024. Algoritmy mashinnogo obuchenija v intellektual'nom analize dannyh [Machine learning algorithms in data mining]. Problemy proektirovanija, primenenija i bezopasnosti informacionnyh sistem v uslovijah cifrovoj jekonomiki: Materialy XXIII Mezhdunarodnoj nauchno-prakticheskoj konferencii, Rostov-na-Donu, 25–26 nojabrja 2024 goda. Rostov-na-Donu: Rostovskij gosudarstvennyj jekonomicheskij universitet (RINH), 2024. P. 230–237.
- Akinina N.V., Kuragin A.V., Kolesnikov A.N., Kostrov B.V. 2023. Development of cartographic web-applications based on geoinformation technologies. *Telecommunications*, 2: 23–31 (in Russian).

- Bekirova E.A., Bekirova M.E. 2023. Economic data analysis and forecasting using machine learning methods. *Scientific notes of the Crimean Engineering and Pedagogical University*, 2(80): 49–53 (in Russian).
- Evdokimova E.N., Kupriyanova M.V., Soloviova I.P., Simikova I.P. 2022. Mathematical modeling of digitalization process in economic systems. *Bulletin of the Ryazan State Radio Engineering University*, 81: 65–71 (in Russian). DOI 10.21667/1995-4565-2022-81-65-71
- Kolesenkov A.N. 2022. Metody, modeli, algoritmy, metodiki i informacionnye tehnologii analiza, obrabotki i sinteza ajerokosmicheskikh izobrazhenij dlja informacionno-analiticheskikh sistem regional'nogo urovnja [Methods, models, algorithms, techniques, and information technologies for the analysis, processing, and synthesis of aerospace images for regional-level information and analytical systems]: special'nost' 05.13.17 "Teoreticheskie osnovy informatiki": dissertacija na soiskanie uchenoj stepeni doktora tehniceskikh nauk / Kolesenkov Aleksandr Nikolaevich, 2022. 337 p.
- Koryachko V.P., Vikulin S.D. 2025. Application of machine learning methods to classify materials based on their key characteristics. *Bulletin of the Ryazan State Radio Engineering University*, 92: 132–145 (in Russian). DOI 10.21667/1995-4565-2025-92-132-145
- Krasovskaja L.V., Pchelinceva S.V., Kukarcev V.V. 2024. Algoritmy mashinnogo obuchenija dlja intellektual'nyh sistem na osnove nechetkih semanticheskikh setej v uslovijah neopredelennosti [Machine learning algorithms for intelligent systems based on fuzzy semantic networks in conditions of uncertainty]. Moskva: Rossijskij gosudarstvennyj agrarnyj universitet, 86 p.
- Kuman'kin D.S., Jamashkin S.A. Orkestracija modelej mashinnogo obuchenija dlja reshenija zadach analiza prostranstvennyh dannyh [Orchestration of machine learning models for solving spatial data analysis problems]. Upravlenie razvitiem krupnomasshtabnyh sistem (MLSD'2024): Trudy Semnadcatoj mezhdunarodnoj konferencii, Moskva, 24–26 sentjabrja 2024 goda. – Moskva: Federal'noe gosudarstvennoe bjudzhetnoe uchrezhdenie nauki Institut problem upravlenija im. V.A. Trapeznikova Rossijskoj akademii nauk, 2024. P. 1117–1123.
- Nesova A.V., Kolesenkov A.N. 2025. Combined approach based on slic method and random forest algorithm for monitoring forests using earth remote sensing data. *Bulletin of Donetsk National University. Series G: Technical Sciences*, 2: 101–109 (in Russian).
- Orlova E.V. 2023. Intelligent data analysis in organisational systems based on machine learning methods. Intelligent Engineering Economics and Industry 5.0 (ECOPROM): Proceedings of the International Scientific and Practical Conference, St. Petersburg, November 17–18, 2023. Saint Petersburg: POLYTECH PRESS, 2023, pp. 690–693 (in Russian).
- Petrenko D.S. 2024. Forecasting the trajectories of innovation development in Russian regions using spatial modeling and big data analytics. *Economics: yesterday, today, tomorrow*, 14(9-1): 54–65 (in Russian).
- Aqil I.A. 2025. Machine Learning and Deep Learning – enhanced production Decline Curve Analysis for improved oil recovery forecasting. *Universum: technical sciences*, 6-9(135): 54–57.
- Gusev S.I., Kolesenkov A.N. 2025. Geoinformation system architecture for complex analysis of hydrometeorological data. International Scientific and Practical Conference: Innovative Methods of Mathematics and Physics in Environmental and Hydrometeorological Research. St. Petersburg, April 4, 2025. P. 249–254.
- Md Fakhru Islam Sumon, Md Osiujjaman, Md Azam Khan et al. 2024. Environmental and Socio-Economic Impact Assessment of Renewable Energy Using Machine Learning Models. *Journal of Economics, Finance and Accounting Studies*, 6(5): 112–122. DOI 10.32996/jefas.2024.6.5.13
- Moursi A., Aboumadi A., Qidwai U. 2025. AI-Based Breast Cancer Detection System: Deep Learning and Machine Learning Approaches for Ultrasound Image Analysis. *Information (Switzerland)*. 16(4): P. 278. DOI 10.3390/info16040278
- Nadeem A., Hanif M.F., Naveed M.S. et al. 2024. AI-Driven precision in solar forecasting: Breakthroughs in machine learning and deep learning. *AIMS Geosciences*. 10(4): 684–734. DOI 10.3934/geosci.2024035
- Naga Raju K., Nandan Mohanty S. 2025. Improving prediction of depression an analytical comparison between hybrid AI, machine learning and deep learning approaches. *Proceedings on Engineering Sciences*, 7(1): 459–472. DOI 10.24874/pes07.01d.003
- Ulyanov S.V., Reshetnikov A.G., Zrelova D.P. 2023. IT Modeling of Self-Organizing Intelligent Controllers Based on Quantum Deep Machine Learning. *Modern Information Technologies and IT-Education*, 19(2): 365–380.
- Zhang D., Tang N., Dong W., Zhao Lu. 2025. Machine Learning-Based Financial Big Data Analysis and Forecasting: From Preprocessing to Deep Learning Models. *Applied and Computational Engineering*, 116(1): 79–85. DOI 10.54254/2755-2721/116/20251731



**Конфликт интересов:** о потенциальном конфликте интересов не сообщалось.  
**Conflict of interest:** no potential conflict of interest related to this article was reported.

Поступила в редакцию 01.12.2025

Received December 01, 2025

Поступила после рецензирования 27.02.2026

Revised February 27, 2026

Принята к публикации 02.03.2026

Accepted March 02, 2026

#### ИНФОРМАЦИЯ ОБ АВТОРЕ

#### INFORMATION ABOUT THE AUTHOR

**Колесенков Александр Николаевич**, доктор технических наук, доцент, профессор кафедры космических технологий, Рязанский государственный радиотехнический университет им. В.Ф. Уткина, г. Рязань, Россия

**Aleksandr N. Kolesenkov**, Doctor of Technical Sciences, Associate Professor, Professor of the Department of Space Technologies, Ryazan State Radio Engineering University named after V.F. Utkin, Ryazan, Russia