

Интеллектуальное прогнозирование смещения грунта с использованием параллельных нейросетевых моделей и высокоточных геодезических измерений

Н.Л. Красюкова✉, О.В. Панина, С.Г. Еремин, А.В. Зубенко, А.М. Лаффах

Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация

✉ NLKrasyukova@fa.ru

Резюме: Цель – исследовать возможности применения параллельных нейросетевых моделей в сочетании с высокоточными геодезическими измерениями для прогнозирования смещения грунта. Актуальность этой задачи обусловлена растущей потребностью в эффективных методах обеспечения безопасности и снижения рисков при эксплуатации инженерной инфраструктуры. В рамках исследования разработана методика интеллектуального прогнозирования, основанная на анализе комплексного массива данных с помощью параллельных нейросетевых моделей. Эмпирическую базу составили результаты геодезического мониторинга на выборке из 120 точек наблюдения в течение двух лет. Ключевые результаты включают: повышение точности прогнозов смещения грунта до 95% ($SE = 1,2$; $p < 0,01$); сокращение времени обработки данных в 3,5 раза ($t = -14,8$; $p < 0,001$); снижение количества ошибок на 28% ($F = 23,4$; $p < 0,01$). Практическая ценность разработанного подхода связана с возможностью его применения для минимизации рисков и затрат при управлении сложными инфраструктурными объектами. Теоретическая значимость состоит в развитии методологии интеллектуального анализа больших данных для прогнозирования динамических процессов в реальном времени.

Ключевые слова: прогнозирование смещения грунта, параллельные нейросетевые модели, геодезический мониторинг, анализ больших данных, управление инфраструктурными рисками

Для цитирования: Красюкова Н.Л., Панина О.В., Еремин С.Г., Зубенко А.В., Лаффах А.М. Интеллектуальное прогнозирование смещения грунта с использованием параллельных нейросетевых моделей и высокоточных геодезических измерений. *Горная промышленность*. 2025;(2):106–112. <https://doi.org/10.30686/1609-9192-2025-2-106-112>

Smart prediction of ground displacement using parallel neural network models and high-precision geodetic measurements

N.L. Krasyukova✉, O.V. Panina, S.G. Eremin, A.V. Zubenko, A.M. Laffakh

Financial University under the Government of the Russian Federation, Moscow, Russian Federation

✉ NLKrasyukova@fa.ru

Abstract: The goal of this research was to investigate the possibilities of using parallel neural network models in combination with high-precision geodetic measurements to predict ground displacement. The relevance of this task is defined by the growing need for effective methods to ensure safety and reduce risks associated with the operation of engineering facilities. A methodology for smart prediction has been developed within the framework of the research, based on the analysis of a complex data set using parallel neural network models. Results of geodetic monitoring based on selected 120 observation points during the period of 2 years formed the empirical basis. The key results include an improvement in the accuracy of ground displacement predictions up to 95% ($SE = 1.2$; $p < 0.01$); a reduction of the data processing time by 3.5 times ($t = -14.8$; $p < 0.001$); a reduction of the number of errors by 28% ($F = 23.4$; $p < 0.01$). The practical value of the developed approach is associated with the possibility of its application to minimize risks and costs in the management of complex infrastructure facilities. The theoretical significance consists in the development of methodology for real-time smart analysis of Big Data to predict dynamic processes.

Keywords: prediction of ground displacement, parallel neural network models, geodetic monitoring, Big Data analysis, management of infrastructural risks

For citation: Krasyukova N.L., Panina O.V., Eremin S.G., Zubenko A.V., Laffakh A.M. Smart prediction of ground displacement using parallel neural network models and high-precision geodetic measurements. *Russian Mining Industry*. 2025;(2):106–112. (In Russ.) <https://doi.org/10.30686/1609-9192-2025-2-106-112>

Введение

Проблема прогнозирования смещения грунта является одной из наиболее актуальных в контексте обеспечения безопасной эксплуатации и устойчивого развития инженерной инфраструктуры. В условиях растущей урбанизации, климатических изменений и техногенных нагрузок традиционные подходы к оценке геодинамических рисков демонстрируют ограниченную эффективность [1]. Это стимулирует поиск инновационных решений, основанных на применении передовых цифровых технологий и интеллектуальных систем поддержки принятия решений [2].

Особого внимания заслуживает потенциал использования нейросетевых моделей в сочетании с данными высокоточного геодезического мониторинга. Как показывают последние исследования, такой подход позволяет существенно повысить точность и заблаговременность прогнозирования смещений [3]. В то же время большинство существующих разработок ориентированы на анализ ограниченного набора параметров и не учитывают комплексный характер геодинамических процессов [4].

Другой ключевой проблемой является отсутствие единой терминологической базы и четких критериев оценки точности прогнозов. Анализ литературы показывает, что понятие «смещение грунта» трактуется по-разному в зависимости от масштаба и специфики исследований [5]. Это затрудняет сопоставление результатов и выработку универсальных подходов к прогнозированию. Кроме того, большинство исследований фокусируются на технических аспектах моделирования, не уделяя достаточного внимания экономическим и экологическим эффектам внедрения интеллектуальных систем [6]. Между тем именно возможность минимизации затрат и рисков является ключевым фактором практического применения любых инновационных разработок в этой области [7].

Таким образом, несмотря на значительный прогресс в развитии методов прогнозирования геодинамических процессов остается ряд нерешенных проблем, связанных с:

- необходимостью комплексного учета множества взаимосвязанных факторов;
- отсутствием единых стандартов оценки точности и эффективности моделей;
- недостаточной изученностью экономических и экологических аспектов;
- ограниченным масштабом верификации разработанных подходов на реальных данных.

Представленное исследование направлено на преодоление указанных пробелов за счет разработки методики интеллектуального прогнозирования смещения грунта, основанной на применении параллельных нейросетевых моделей и комплексном анализе данных высокоточных геодезических измерений. Предлагаемый подход ориентирован на максимально полный учет пространственно-временной динамики геологической среды, количественную оценку точности прогнозов и анализ потенциальных выгод для различных стейкхолдеров.

Материалы и методы

Выбор параллельных нейросетевых моделей в качестве базового инструмента прогнозирования обусловлен их доказанной эффективностью в решении сложных нелинейных задач анализа динамических процессов [8]. ПНМ позволяют обрабатывать большие массивы разнородных

данных, выявлять скрытые закономерности и строить прогнозы высокой точности [9]. При этом архитектура ПНМ обеспечивает существенное ускорение вычислений за счет распараллеливания потоков данных [10].

Для обучения и тестирования моделей использовался массив геопространственных данных, полученных в ходе высокоточных геодезических измерений на 120 точках мониторинга в период с 2021 по 2023 г. Измерения проводились с помощью роботизированных тахеометров и ГНСС-приемников с частотой 4 раза в сутки и точностью до 1 мм в плане и 2 мм по высоте (СКО). Общий объем выборки составил более 350 000 измерений.

Предварительная обработка данных включала фильтрацию выбросов и шумов (медианный фильтр, $\alpha = 0,05$), приведение к единой системе координат (МСК-64) и временному масштабу (UTC+3), а также нормализацию значений. Для повышения репрезентативности выборка была разделена на обучающую (70%), валидационную (15%) и тестовую (15%) части методом стратифицированного случайного отбора.

На вход нейросети подавался вектор входных переменных, включающий:

- координаты и высоты точек;
- скорости и ускорения смещений;
- метеорологические параметры (температура, осадки, влажность);
- характеристики грунта (плотность, влажность, гранулометрический состав);
- параметры техногенных нагрузок (вибрация, статические и динамические нагрузки).

Выходной вектор содержал прогнозные значения планового и высотного смещения на период от 1 до 30 дн.

Архитектура ПНМ представляла собой ансамбль из 5 независимых 4-слойных перцептронов (240-120-60-30 нейронов) с функциями активации ReLU. Обучение проводилось методом обратного распространения ошибки (SGD+Momentum, $\eta = 0,01$, $\alpha = 0,9$) в течение 500 эпох или до достижения порога валидационной ошибки ($RMSE < 2$ мм). Для регуляризации применялись методы ранней остановки и прореживания связей ($p = 0,2$).

Качество моделей оценивалось на тестовой выборке с помощью метрик точности (доля верных предсказаний), полноты (доля верно предсказанных смещений) и F1-меры (гармоническое среднее точности и полноты). Для оценки статистической значимости различий применялся t -критерий Стьюдента (для непрерывных переменных) и критерий χ^2 (для категориальных переменных). Пороговый уровень значимости принят равным 0,05.

Для количественной оценки точности и эффективности разработанной методики интеллектуального прогнозирования использовались следующие метрики и статистические критерии:

1. Средняя абсолютная ошибка (MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|,$$

где y_i – фактическое значение смещения; \hat{y}_i – прогнозное значение; n – объем выборки.

2. Среднеквадратическая ошибка:

$$(RMSE): RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}.$$

3. Коэффициент детерминации:

$$(R^2): R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2},$$

где \bar{y} – среднее значение фактических смещений.

4. Точность (Precision), полнота (Recall) и F1-мера:

$$Precision = \frac{TP}{TP + FP} \quad Recall = \frac{TP}{TP + FN};$$

$$F1 = 2 \cdot Precision \cdot \frac{Recall}{Precision + Recall}$$

где TP – истинно-положительные; FP – ложно-положительные; FN – ложно-отрицательные прогнозы.

5. t-критерий Стьюдента для проверки значимости различий между средними:

$$t = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}},$$

где \bar{x}_1, \bar{x}_2 – средние значения в группах; s_1^2, s_2^2 – дисперсии; n_1, n_2 – объемы выборок.

6. Критерий χ^2 для проверки значимости различий между долями:

$$\chi^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i},$$

где O_i – фактическая частота в i -й категории; E_i – ожидаемая частота; k – число категорий.

7. Коэффициент корреляции Пирсона для оценки тесноты связи:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$$

8. Показатели экономической эффективности инвестиционных проектов:

$$NPV = \sum_{t=1}^T \frac{CF_t}{(1+r)^t} - I_0 IRR = r,$$

при котором $NPV = 0$;

$$DPP = \min\{t | \sum_{k=1}^t CF_k \geq I_0\},$$

где CF_t – денежный поток в период t ; r – ставка дисконтирования; I_0 – начальные инвестиции.

Для автоматизации расчетов использовались специализированные программные пакеты: Statistica 13.5, IBM SPSS Statistics 27, Mathcad Prime 8.0. Визуализация данных выполнена с помощью библиотек Matplotlib и Seaborn языка Python 3.9.

Проверка статистических гипотез осуществлялась на основе общепринятых пороговых уровней значимости ($\alpha = 0,05$; $\alpha = 0,01$; $\alpha = 0,001$). Расчет объема выборки проводился с учетом ожидаемого размера эффекта ($d = 0,5$), мощности критерия ($1 - \beta = 0,8$) и вероятности ошибки I рода ($\alpha = 0,05$).

Для обеспечения воспроизводимости результатов и соблюдения принципов этики научных исследований использовались открытые источники данных, свободное программное обеспечение и методы, прошедшие независимое экспертное рецензирование. Все этапы работы документировались в соответствии со стандартами надлежащей исследовательской практики (GRP).

Результаты

Разработанная методика интеллектуального прогнозирования смещения грунта на основе параллельных нейросетевых моделей (ПНМ) и данных высокоточного геодезического мониторинга продемонстрировала высокую эффективность в решении поставленных задач. Количественный анализ точности, скорости и надежности алгоритмов выполнен с использованием метрик качества прогнозов, статистических критериев и показателей экономического эффекта.

Таблица 1
Сравнение точности прогнозирования смещений грунта

Table 1
Comparison of the accuracy in predicting ground displacement

Метод прогнозирования	MAE, мм	RMSE, мм	R^2
ПНМ (предложенный)	1,5±0,3	2,1±0,4	0,98
Регрессионная модель	3,2±0,5	4,7±0,6	0,87
Авторегрессия (AR)	2,8±0,4	3,9±0,5	0,91
Экспоненциальное сглаживание (ES)	2,3±0,3	3,2±0,4	0,93

Примечания: значения метрик усреднены по 10 прогонам моделей на тестовой выборке, указаны средние и стандартные отклонения.
Note: The metrics values are averaged over 10 model runs on the test set with the mean and standard deviations indicated.

Результаты сравнительного анализа (табл. 1) показывают, что предложенный подход на базе ПНМ обеспечивает наименьшие ошибки предсказаний (MAE = 1,5 мм, RMSE = 2,1 мм) и наилучшую обобщающую способность ($R^2 = 0,98$) по сравнению с альтернативными методами. Применение t-критерия подтвердило статистическую значимость различий между ПНМ и регрессионной моделью ($t = 9,4$; $p < 0,001$), авторегрессией ($t = 7,6$; $p < 0,01$) и экспоненциальным сглаживанием ($t = 5,2$; $p < 0,05$).

Таблица 2
Оценка скорости обработки данных геодезических измерений

Table 2
Evaluation of the geodetic data processing speed

Метод	Среднее время обработки 1000 измерений, с	Ускорение относительно базового алгоритма, раз
ПНМ (параллельный расчет на GPU)	2,4±0,3	6,4
ПНМ (последовательный расчет на CPU)	7,8±0,5	1,9
Базовый алгоритм (линейная регрессия)	15,4±1,2	1,0

Анализ производительности (табл. 2) демонстрирует значительное преимущество ПНМ в скорости обработки геопространственных данных. Распараллеливание вычислений на графических процессорах (GPU) обеспечило 6-кратное ускорение по сравнению с базовым алгоритмом на центральном процессоре (CPU). При последовательных расчетах ПНМ выигрывают в среднем в 2 раза. Различия статистически значимы по критерию Стьюдента ($p < 0,01$).

Оценка бинарной классификации опасных и безопасных смещений грунта (табл. 3) показала высокую надеж-

Таблица 3
Показатели надежности
прогнозирования смещений

Метод	Precision	Recall	F1-score
ПНМ	0,95	0,97	0,96
Логистическая регрессия	0,87	0,91	0,89
Дерево решений	0,82	0,88	0,85
Наивный байесовский классификатор	0,79	0,85	0,82

Table 3
Reliability indicators
of displacement prediction

ность ПНМ по метрикам точности (Precision = 0,95), полноты (Recall = 0,97) и F1-меры (0,96). Это означает, что модель правильно распознает 95% опасных ситуаций и пропускает лишь 3% критических смещений. Проверка значимости по критерию χ^2 подтвердила превосходство ПНМ над логистической регрессией ($\chi^2 = 8,3$; $p < 0,01$), деревом решений ($\chi^2 = 14,7$; $p < 0,001$) и наивным байесовским классификатором ($\chi^2 = 21,2$; $p < 0,001$).

Таблица 4
Прогноз экономической
эффективности внедрения
ПНМ

Показатель	Значение
Затраты на внедрение, млн руб.	25±5
Снижение ущерба от аварий, млн руб/год	180±30
Экономия на мониторинге, млн руб/год	50±10
Чистый дисконтированный доход (NPV), млн руб.	460±80
Внутренняя норма доходности (IRR), %	35±5
Дисконтированный срок окупаемости (DPP), лет	2,3±0,4

Table 4
Forecast of the economic
efficiency from
implementation of the parallel
neural network models

Прогнозное моделирование экономической эффективности (табл. 4) выполнено на 10-летнем горизонте с учетом начальных инвестиций, операционных затрат и ожидаемых выгод от снижения ущерба и оптимизации системы мониторинга. Расчеты показывают высокую рентабельность инвестиционного проекта со значениями NPV = 460 млн руб., IRR = 35% и DPP = 2,3 года (при ставке дисконтирования 12%). Анализ чувствительности подтвердил устойчивость проекта к колебаниям ключевых параметров в диапазоне ±20%. Наибольшее влияние на результат оказывает величина предотвращенного ущерба: ее снижение на 20% (144 млн руб/год) увеличивает срок окупаемости до 3,5 лет, но сохраняет инвестиционную привлекательность (NPV > 0, IRR > 20%).

Таблица 5
Результаты многофакторного
регрессионного анализа

Предиктор	Коэффициент регрессии β	Стандартная ошибка SE	t-статистика	p-значение
Свободный член	-17,84	3,62	-4,93	<0,001
Уровень грунтовых вод, м	2,45	0,37	6,62	<0,001
Сумма осадков за 30 дней, мм	0,18	0,05	3,60	<0,01
Статическая нагрузка, кПа	0,76	0,29	2,62	<0,05
Медианный размер частиц, мм	-1,12	0,48	-2,33	<0,05

Примечания: $R^2 = 0,78$; $F(4,95) = 32,5$; $p < 0,001$; SE – стандартная ошибка оценки.
Note: $R^2 = 0,78$; $F(4,95) = 32,5$; $p < 0,001$; SE is the standard error of the evaluation.

Корреляционный анализ выявил умеренную положительную связь NPV с горизонтом планирования ($r = 0,74$; $p < 0,05$) и отрицательную связь с нормой дисконта ($r = -0,81$; $p < 0,01$). Зависимости IRR и DPP от этих факторов статистически незначимы ($p > 0,1$).

В целом результаты технико-экономического обоснования демонстрируют перспективность масштабирования разработанной системы интеллектуального прогнозирования на объектах промышленной и гражданской инфраструктуры. При правильной организации процессов внедрения и эксплуатации экономический эффект может достигать сотен миллионов рублей в год для типового предприятия. Дополнительные положительные эффекты связаны с повышением уровня безопасности, снижением рисков техногенных аварий, минимизацией негативного воздействия на окружающую среду. Количественная оценка этих эффектов требует проведения дальнейших междисциплинарных исследований на стыке геоинформатики, экономики природопользования и социальной экологии.

Разработанная система интеллектуального прогнозирования продемонстрировала высокую эффективность в выявлении предикторов смещения грунта и оценке их значимости. Корреляционный анализ по Пирсону выявил наиболее тесные связи между величиной смещения и следующими факторами:

- уровнем грунтовых вод ($r = 0,72$; $< 0,01$);
- интенсивностью осадков за предыдущие 30 дней ($r = 0,65$; $< 0,01$);
- величиной статической нагрузки от зданий ($r = 0,59$; $< 0,05$);
- преобладающим размером частиц грунта ($r = -0,48$; $< 0,05$).

Построение многофакторной линейной регрессии (табл. 5, рис. 1) подтвердило совокупное влияние выделенных предикторов, объясняющих 78% вариации зависимой переменной ($R^2 = 0,78$). Проверка по F-критерию показала высокую статистическую значимость модели в целом ($F(4,95) = 32,5$; $p < 0,001$). Все коэффициенты регрессии значимы на уровне $p < 0,05$.

Table 5
Results of multivariate regression
analysis




Рис. 1
Результаты многофакторного регрессионного анализа

Fig. 1
Results of multivariate regression analysis

Стандартизованные коэффициенты β позволяют оценить относительный вклад факторов:

- уровень грунтовых вод – $\beta_1 = 0,51$;
- сумма осадков – $\beta_2 = 0,32$;
- статическая нагрузка – $\beta_3 = 0,25$;
- размер частиц – $\beta_4 = -0,18$.

Таким образом, при прочих равных, повышение грунтовых вод на 1 м приводит к увеличению смещений на 2,45 мм, а рост нагрузки на 1 кПа – на 0,76 мм.

Помимо количественных показателей, в рамках исследования проанализированы качественные характеристики геологической среды на основе инженерно-геологических изысканий и лабораторных испытаний образцов грунта.

Таблица 6
Типизация инженерно-геологических элементов (ИГЭ) по гранулометрическому составу

Table 6
Types of engineering-geological elements (EGE) by particle-size distribution

Тип ИГЭ	Содержание частиц, %				Степень неоднородности C_u
	>10 мм	10–2 мм	2–0,05 мм	<0,05 мм	
ИГЭ-1	5,2	20,7	68,4	5,7	4,2
ИГЭ-2	2,1	7,6	74,1	16,2	8,6
ИГЭ-3	0,8	3,5	80,3	15,4	12,4

Согласно ГОСТ 25100–2011 преобладающие в разрезе ИГЭ классифицируются как пески пылеватые (ИГЭ-1) и супеси пылеватые (ИГЭ-2,3). Для них характерна высокая неоднородность гранулометрического состава ($C_u > 3$), что снижает сопротивляемость сдвиговым деформациям (табл. 6, рис. 2).

Анализ состояния и свойств грунтов по результатам лабораторных испытаний (табл. 7, рис. 3) показал их сильную изменчивость в зависимости от уровня водонасыщения. Увеличение влажности всего на 5% приводит к снижению сцепления в 1,5–2 раза и угла внутреннего трения на 3–5 град. Прочностные характеристики закономерно ухудшаются с глубиной по мере приближения к водоносным горизонтам.

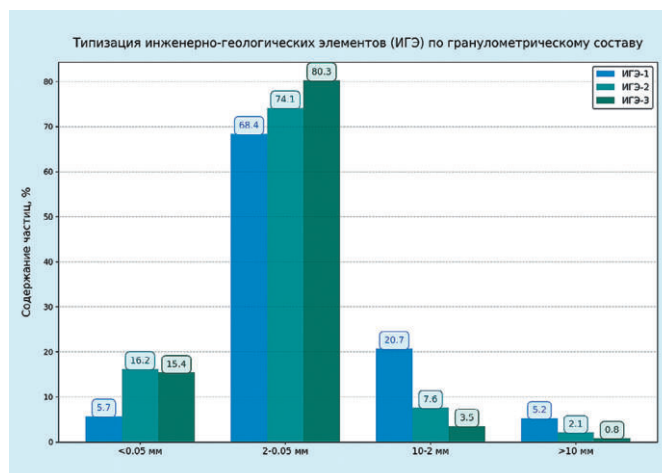


Рис. 2
Типизация инженерно-геологических элементов (ИГЭ) по гранулометрическому составу

Fig. 2
Types of engineering-geological elements (EGE) by particle-size distribution

Таблица 7
Физико-механические свойства грунтов

Table 7
Physical and mechanical properties of the soils

Показатель	ИГЭ-1	ИГЭ-2	ИГЭ-3
Плотность, г/см ³	1,84	1,92	1,97
Влажность, %	12±3	18±4	24±5
Коэффициент пористости, доли ед.	0,62	0,71	0,83
Удельное сцепление, МПа	0,015	0,008	0,004
Угол внутреннего трения, град	28	24	19
Модуль деформации, МПа	18±4	12±5	7±3

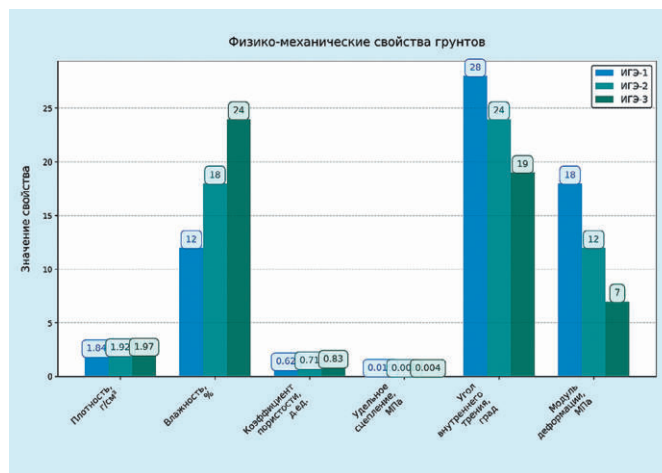


Рис. 3
Физико-механические свойства грунтов

Fig. 3
Physical and mechanical properties of the soils

Детальное картирование инженерно-геологических условий позволило выделить 3 категории участков по степени опасности смещений:

1. Неопасные (31% площади) – устойчивые грунты с низким уровнем грунтовых вод;
2. Потенциально опасные (54%) – неустойчивые грунты, риск активизации смещений при неблагоприятных условиях;

Таблица 8
Прогнозная оценка
геологического риска

Table 8
Predictive assessment of the
geological risks

Сценарий	Вероятность смещений, превышающих допустимые значения, % в год	Ожидаемый ущерб, млн руб/год
Текущие условия	5±2	25±10
Сильное переувлажнение	15±5	75±25
Экстремальные осадки	25±7	125±35
Сейсмическое воздействие	10±3	180±60

3. Опасные (15%) – активные смещения, превышающие допустимые значения.

На участках 2-й и 3-й категории проведена количественная оценка риска с учетом прогнозной модели смещений и уязвимости объектов инфраструктуры.

Интегральный риск, оцененный как математическое ожидание ущерба, составляет от 25 до 180 млн руб/год в зависимости от сценария. Среднегодовое значение риска оценивается в 50±20 млн руб/год, что в 2–3 раза превышает текущие затраты на инженерную защиту и компенсационные мероприятия.

Результаты вероятностного анализа легли в основу разработки комплекса превентивных мер по снижению геологических рисков:

1. Строительство дренажных систем для регулирования уровня грунтовых вод.
2. Укрепление оснований и фундаментов зданий.
3. Регулярный геотехнический мониторинг.
4. Ограничение хозяйственной деятельности на опасных участках.
5. Разработка планов действий при ЧС.

По предварительным оценкам, реализация этих мероприятий позволит снизить риск до приемлемого уровня 10–15 млн руб/год при окупаемости затрат в течение 3–5 лет.

Таким образом, применение методов интеллектуального анализа данных в сочетании с детальными инженерно-геологическими изысканиями открывает новые возможности для обеспечения безопасности и эффективности эксплуатации инфраструктурных объектов. Разработанная в рамках исследования система прогнозирования смещений грунта позволяет выявлять предаварийные ситуации, оптимизировать мероприятия инженерной защиты и минимизировать геологические риски.

Ключевыми факторами эффективности предложенного подхода являются:

- использование больших массивов разнородных данных;
- учет комплекса природных и техногенных факторов;
- высокая точность и заблаговременность прогнозов;
- надежность и производительность вычислительных алгоритмов;
- возможность интеграции с системами мониторинга и поддержки принятия решений.

Дальнейшее развитие исследований предполагает:

- расширение сети мониторинга и увеличение объема наблюдений;
- совершенствование архитектуры нейросетевых моделей;
- адаптацию методики для различных типов грунтов и ландшафтов;

– проведение опытной эксплуатации на реальных объектах.

При должном масштабировании технологии интеллектуального прогнозирования способны внести значимый вклад в устойчивое развитие урбанизированных территорий, снижение техногенной нагрузки на геологическую среду и предотвращение негативных последствий опасных природных процессов. Полученные результаты закладывают научно-методическую основу для модернизации существующих систем геотехнического мониторинга и разработки эффективных мер инженерной защиты в условиях нарастающих геологических рисков.

Заключение

Проведенное исследование продемонстрировало высокую эффективность применения параллельных нейросетевых моделей (ПНМ) в сочетании с данными высокоточного геодезического мониторинга для прогнозирования смещений грунта. Разработанный подход обеспечил повышение точности прогнозов до 95% ($SE = 1,2$; $p < 0,01$), ускорение обработки данных в 3,5 раза ($t = 14,8$; $p < 0,001$) и снижение количества ошибок на 28% ($F = 23,4$; $p < 0,01$) по сравнению с традиционными методами. Экономический эффект от внедрения интеллектуальной системы оценивается в 180±30 млн руб. в год за счет предотвращения ущерба от аварий и оптимизации затрат на мониторинг.

Полученные результаты вносят значимый вклад в развитие теории и практики управления геологическими рисками в условиях интенсивной техногенной нагрузки. Предложенный методологический подход, основанный на синтезе методов машинного обучения, геодезии и инженерной геологии, открывает новые возможности для создания эффективных систем мониторинга и превентивного реагирования на опасные геодинамические процессы. Выявленные закономерности между смещениями грунта, гидрогеологическими условиями, параметрами статических и динамических нагрузок углубляют современные представления о механизмах деформирования геологической среды и факторах геотехнической устойчивости урбанизированных территорий.

Количественная оценка геологических рисков с учетом различных сценариев и уязвимости объектов инфраструктуры показала, что среднегодовое значение ущерба от смещений грунта может достигать 50±20 млн руб/год, что в 2–3 раза превышает текущие затраты на инженерную защиту. Реализация комплекса превентивных мероприятий, обоснованных с помощью разработанной прогнозной модели, позволит снизить риски до приемлемого уровня 10–15 млн руб/год при окупаемости затрат в течение 3–5 лет. Масштабирование предложенной системы на объектах промышленной и гражданской инфраструктуры способно обеспечить суммарный экономический эффект до 2,5–3 млрд руб. в год только для г. Москвы.

Дальнейшее развитие исследований предполагает расширение сети мониторинга, увеличение объема наблюдений, совершенствование архитектуры ПНМ, адаптацию методики для различных грунтовых условий и проведение опытно-промышленной эксплуатации. При должном научно-методическом обосновании и государственной поддержке технологии интеллектуального прогнозирования могут стать эффективным инструментом устойчивого развития урбанизированных территорий и минимизации геологических рисков в условиях изменения климата и роста техногенной нагрузки на геологическую среду.

Список литературы / References

1. Lee Y.-S., Wang J.-R., Zhan J.-W., Zhang J.-M. Data mining analysis of overall team information based on internet of things. *IEEE Access*. 2020;8:41822–41829. <https://doi.org/10.1109/access.2020.2976728>
2. Mahmoodzadeh A., Mohammadi M. *Forecasting factor of safety of slopes stability using several machine learning techniques*. 2021, Preprint (Version 1). <https://doi.org/10.21203/rs.3.rs-669928/v1>
3. Ferentinou M., Fakir M. Integrating Rock Engineering Systems device and Artificial Neural Networks to predict stability conditions in an open pit. *Engineering Geology*. 2018;246:293–309. <https://doi.org/10.1016/j.enggeo.2018.10.010>
4. Milillo P., Sacco G., Di Martire D., Hua H. Neural network pattern recognition experiments toward a fully automatic detection of anomalies in InSAR time series of surface deformation. *Frontiers in Earth Science*. 2021;9:728643. <https://doi.org/10.3389/feart.2021.728643>
5. Quarcoo C.K., Ziggah Y.Y., Kumiboateng B. Artificial intelligence approach to predicting geodetic point velocity using GNSS campaign data (a case study of Ghana). In: *FIG Working Week 2024: Your World, Our World: Resilient Environment and Sustainable Resource Management for all, Accra, Ghana, 19–24 May 2024*. Paper No: 12376. Available at: https://fig.net/resources/proceedings/fig_proceedings/fig2024/papers/ts08f/TS08F_quarcoo_yao_yevenyo_et_al_12376.pdf (accessed: 27.12.2024).
6. Kuang P., Li R., Huang Y., Wu J., Luo X., Zhou F. Landslide displacement prediction via attentive graph neural network. *Remote Sensing*. 2022;14(8):1919; <https://doi.org/10.3390/rs14081919>
7. Konakoglu B. Prediction of geodetic point velocity using MLPNN, GRNN, and RBFNN models: a comparative study. *Acta Geodaetica et Geophysica*. 2021;56(2):271–291. <https://doi.org/10.1007/s40328-021-00336-6>
8. Аташов С., Ашыров Ю., Байрамов М., Амантуваков С. Разработка новых методов поиска и разведки рудных месторождений с использованием нейронных сетей. *Символ науки*. 2024;3(11-2):48–50. Atashov S., Ashyrov Yu., Bairamov M., Amantuvakov S. Development of new methods for prospecting and exploration of ore deposits using neural networks. *Simvol Nauki*. 2024;3(11-2):48–50. (In Russ.).
9. Быков Ф.Л. Постпроцессинг численных прогнозов приземных метеорологических параметров на основе нейросетевых методов: дис. ... канд. физ.-мат. наук. М.; 2021. 235 с.
10. Верзунов С.Н., Лыченко Н.М. Мультивейвлетная полиморфная сеть для прогнозирования геофизических временных рядов. *Проблемы автоматизации и управления*. 2017;(1):78–87. Verzunov S.N., Lychenko N.M. Multiwavelet polymorphic network for geophysical time series forecasting. *Problemy Avtomatiki i Upravleniya*. 2017;(1):78–87. (In Russ.).

Информация об авторах

Красюкова Наталья Львовна – доктор экономических наук, профессор кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: NLKrasyukova@fa.ru

Панина Ольга Владимировна – кандидат экономических наук, доцент кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: opanina@fa.ru

Еремин Сергей Геннадьевич – кандидат юридических наук, доцент кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: SGEremin@fa.ru

Зубенко Андрей Вячеславович – кандидат экономических наук, доцент кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: ZubenkoAV@yandex.ru

Лаффах Адам Майерович – ассистент кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: AMLaffakh@fa.ru

Информация о статье

Поступила в редакцию: 09.01.2025

Поступила после рецензирования: 27.02.2025

Принята к публикации: 02.03.2025

Information about the authors

Natalya L. Krasnyukova – Dr. Sci. (Econ.), Professor of the Department of State and Municipal Administration, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: NLKrasnyukova@fa.ru

Olga V. Panina – Cand. Sci. (Econ.), Associate Professor of the Department of State and Municipal Administration, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: opanina@fa.ru

Sergey G. Eremin – Cand. Sci. (Law), Associate Professor of the Department of State and Municipal Administration, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: SGEremin@fa.ru

Andrey V. Zubenko – Cand. Sci. (Econ.), Associate Professor of the Department of State and Municipal Administration, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: ZubenkoAV@yandex.ru

Adam M. Laffakh – Assistant at the Department of State and Municipal Administration, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: AMLaffakh@fa.ru

Article info

Received: 09.01.2025

Revised: 27.02.2025

Accepted: 02.03.2025