

ИССЛЕДОВАНИЕ ПОДХОДА В ОЦЕНКЕ И ПРОГНОЗИРОВАНИИ ГЕОТЕХНИЧЕСКИХ РИСКОВ

Статья посвящена применению машинного обучения для интеллектуализации методов геотехнического мониторинга. Рассмотрено применение методов машинного обучения (ML) в оценке рисков, связанных с безопасностью инфраструктурных проектов в природных и техногенных условиях. Описываются этапы применения ML, включая сбор и обработку данных, выбор алгоритмов, обучение и валидация моделей. Обсуждаются преимущества и ограничения традиционных и современных методов, приводятся кейсы успешного внедрения ML в различных геотехнических проектах, а также примеры использования в различных условиях.

Ключевые слова: геотехнический мониторинг, машинное обучение.

Введение

Геотехнический мониторинг (ГМ) представляет собой сложную задачу из-за разнообразия и изменчивости характеристик почвы и горных пород. ГМ – это система наблюдений и контроля за состоянием и изменением грунтовых, природных и техногенных условий в процессе строительства и эксплуатации объектов [1]. Основная цель ГМ – выявление и предотвращение необратимых процессов в грунтовых основаниях, а также контроль деформаций зданий и сооружений. При проектировании системы мониторинга учитываются особенности каждого сооружения, что позволяет определить оптимальное расположение и количество наблюдательных точек.

Основой для разработки проектов ГМ являются прогнозные расчеты прочности и деформаций оснований и фундаментов. Эти расчеты учитывают как техногенные, так и природно-климатические воздействия, возникающие в процессе строительства и эксплуатации, а также изменения этих воздействий со временем [2].

ГМ используется для решения ряда задач, включая оценку эксплуатационной пригодности сооружений, неразрушающий контроль качества строительных работ нулевого цикла и анализ экологической безопасности территорий. Ключевая задача ГМ заключается в своевременном выявлении и прогнозировании развития неблагоприятных процессов в грунтовых массивах, которые могут повлиять на безопасную эксплуатацию зданий и сооружений [3]. Для этого разрабатываются и выполняются меры по предотвращению катастрофических ситуаций. ГМ является неотъемлемой частью системы безопасности любых проектируемых зданий и сооружений высокого уровня ответственности и должен осуществляться как в период строительства, так и в период последующей эксплуатации объекта.

Традиционные методы оценки рисков в геотехнической инженерии основывались на эмпирических наблюдениях и детерминированных моделях. Эти методы предоставляли структурированные подходы для анализа взаимодействий между грунтом и искусственными конструкциями, включая полевые исследования, лабораторные испытания и применение математических моделей для прогнозирования поведения грунтов и горных пород [4]. Однако динамика современных строительных проектов и урбанизация требуют более адаптивных и современных инструментов. Это создало необходимость в новых подходах, которые могут автоматизировать и оптимизировать процессы анализа, а также предсказывать потенциальные проблемы с высокой точностью. В этом контексте машинное обучение (ML) предлагает значительные преимущества благодаря своим возможностям предсказания и распознавания паттернов.

Машинное обучение, как часть искусственного интеллекта, позволяет компьютерам обучаться на основе данных и делать предсказания без явного программирования. Применение ML в геотехнической инженерии открывает новые горизонты для повышения безопасности и эффективности инфраструктурных проектов.

Основной целью данной статьи является исследование возможностей применения машинного обучения в ГМ для оценки рисков. В статье рассматриваются алгоритмы машинного обучения для оценки рисков, выявляются их ограничения и предлагается использование ML как более эффективного инструмента.

Обзор методов машинного обучения в геотехническом мониторинге

Традиционные методы оценки рисков в ГМ включают полевые исследования и лабораторные тесты. Полевые исследования включают такие процедуры, как бурение и отбор проб. Лабораторные тесты включают испытания на прочность сдвига и тесты на консолидацию. Эти методы предоставляют данные о физических и механических свойствах грунтов и камней, которые затем используются в детерминированных моделях для оценки рисков. Примеры таких моделей включают уравнение несущей способности Терцаги и методы предельного равновесия [5].

Однако традиционные методы имеют значительные ограничения. Высокая вариабельность грунтов и камней, нелинейные реакции материалов и временная изменчивость их свойств делают задачу точного прогнозирования сложной. Эти методы также являются трудоемкими и дорогими, что ограничивает их применение. В этом контексте машинное обучение предоставляет альтернативный подход, который позволяет анализировать большие объемы данных и выявлять сложные закономерности.

Основные этапы применения ML в геотехнической инженерии включают сбор и обработку данных, выбор алгоритмов, обучение моделей и их валидацию. Данные для геотехнической инженерии могут быть собраны из различных источников, включая полевые исследования, лабораторные тесты, мониторинг в реальном времени и исторические данные. Полевые данные включают информацию о физических и механических свойствах грунтов и камней, таких как плотность, пористость, влажность и прочность. Лабораторные данные включают результаты тестов на прочность сдвига и консолидацию. Данные мониторинга включают измерения деформаций, напряжений и других параметров в реальном времени.

Обработка данных включает очистку данных, удаление шумов и аномалий, нормализацию и масштабирование данных, а также выбор признаков. Очистка данных необходима для удаления ошибочных и недостоверных значений, которые могут негативно повлиять на обучение моделей. Нормализация и масштабирование данных позволяют привести все признаки к единому масштабу, что улучшает производительность моделей. Выбор признаков включает идентификацию наиболее значимых параметров, которые влияют на предсказываемый результат. Это позволяет сократить размерность данных и улучшить точность моделей.

Выбор алгоритмов зависит от задачи и доступных данных. В таблице 1 предоставлен сравнительный анализ организации машинного обучения для оценки геотехнических рисков, рассмотрены основные характеристики, преимущества и ограничения подходов, что позволяет получить целостное представление о том, как они справляются с различными аспектами оценки геотехнических рисков. Методы машинного обучения часто имеют преимущества в скорости обработки данных и точности прогнозирования, однако они требуют больших объемов данных для оптимальной работы.

Таблица 1– Обзор типов машинного обучения в геотехническом мониторинге

Тип машинного обучения	Применение в геотехнической инженерии	Преимущества	Ограничения
Обучение с учителем	Классификация грунтов, прогнозирование фундаментов	Прямое отображение входных и выходных данных	Требуются размеченные данные
Обучение без учителя	Обнаружение аномалий, кластеризация грунтов	Исследование данных без заранее заданных меток	Может пропустить шаблоны, заданные человеком

Тип машинного обучения	Применение в геотехнической инженерии	Преимущества	Ограничения
Обучение с подкреплением (RL)	Корректировки в реальном времени, оптимизация оборудования	Динамическое принятие решений в условиях неопределенности	Требуется симуляционная или пробная среда
Глубокое обучение (DL)	Моделирование сложного поведения грунтов, распознавание изображений	Может моделировать сложные паттерны и взаимосвязи	Требуются большие объемы данных, может быть непрозрачным
Федеративное обучение (FL)	Распределенная тренировка данных с сохранением конфиденциальности	Конфиденциальность данных и локализованная тренировка	Может быть медленнее централизованного обучения
Трансферное обучение (TL)	Быстрая адаптация моделей для новых площадок	Использует знания из предыдущих моделей/задач	Может не всегда эффективно переносить знания

Обучение моделей включает настройку гиперпараметров и оптимизацию моделей для достижения наилучших результатов. Валидация моделей включает проверку их точности на тестовых данных и сравнение с традиционными методами. Этот процесс позволяет выявить наиболее эффективные алгоритмы и подходы для решения конкретных задач в геотехнической инженерии.

Типы обучения представляют собой общие стратегии для построения и применения моделей машинного обучения, тогда как конкретные методы (таблица 2) реализуют эти стратегии для решения специализированных задач.

Таблица 2– Сравнительный обзор ведущих методов ML

Метод ML	Основное применение	Увеличение точности прогноза (%)
Генеративные состязательные сети (GAN)	Моделирование профилей грунтов	30% (в туннельных конструкциях)[6]
Прогнозирование временных рядов	Прогнозирование движения оползней	Не определено
Ансамблевое обучение	Комплексные прогнозы геотехнических рисков	18% [8]

Модели машинного обучения могут прогнозировать поведение грунта под различными нагрузками. В работе [6] модель, построенная на архитектуре генеративных состязательных сетей (Generative adversarial network, GAN), продемонстрировала эффективность в симуляции профилей грунтов, что особенно полезно в туннельных конструкциях. Данные датчиков, встроенных в буровые машины и стены туннеля, в сочетании с данными геологических исследований передаются в модель машинного обучения. GAN непрерывно анализирует данные, прогнозируя области потенциального проникновения воды или нестабильные слои почвы. Таким образом удалось скорректировать свою стратегию бурения в режиме реального времени, предотвращая потенциальные обвалы и обеспечивая безопасность рабочих.

Прогнозирование временных рядов используется для предсказания движений оползней. Его основная цель – предсказать будущие значения на основе прошлых и текущих данных. Исследование [7] показало, что модели временных рядов способны выдавать ранние предупреждения на основе различных факторов, таких как влажность почвы, градиент склона и исторические данные об оползнях.

Ансамблевое обучение комбинирует несколько моделей для достижения более высокой точности предсказаний. В работе [8] ансамблевые модели улучшили точность предсказаний на 18% по сравнению с одиночными моделями. Это особенно важно в сложных геотехнических сценариях, где множество факторов взаимодействуют друг с другом.

Примеры практического применения моделей ML в геотехническом мониторинге

Современные геотехнические практики значительно выиграли от интеграции вычислительных инструментов и современных методологий. Машинное обучение с его возможностями подходит для решения многих сложных проблем, присущих геотехнической инженерии. Но прежде чем любую модель машинного обучения можно будет обучить, данные необходимо подготовить, очистить и, возможно, дополнить. Для геотехнических данных это может включать нормализацию (масштабирование всех объектов в одинаковый диапазон), обработку пропущенных значений и даже возможное объединение нескольких типов наборов данных.

Благодаря достижениям в области разработки датчиков технологии и IoT (Интернет вещей) теперь стало возможным собирать данные в режиме реального времени со строительных площадок, буровых установок и даже глубоко под землей. Алгоритмы машинного обучения могут интегрировать эти данные, предоставляя немедленную информацию и потенциально выявляя риски или аномалии в режиме реального времени. Такой упреждающий подход значительно сокращает время реакции в случае непредвиденных проблем [9].

Для инженеров-геотехников получение развернутой информации для принятия обоснованных решений имеет первостепенное значение. Интеграция моделей машинного обучения в системы поддержки принятия решений позволяет инженерам моделировать различные сценарии, прогнозировать потенциальные проблемы и принимать решения на основе аналитики, опирающейся на данные. Эти системы оказывают помощь не только на этапе проектирования, но также во время строительства и постстроительного мониторинга [10].

Многие конструкции (мосты, туннели, плотины) требуют постоянного мониторинга. Алгоритмы машинного обучения могут анализировать данные от датчиков, обнаруживать мельчайшие сдвиги или изменения и прогнозировать потенциальные точки сбоя. Профилактическое обслуживание может спасти как ресурсы, так и жизни. Например, если целостность плотины находится под угрозой, раннее прогнозирование может привести к своевременной эвакуации и необходимому ремонту, смягчая потенциальные бедствия [11].

Детальное изучение конкретных проектов может дать информацию об опыте и преимуществах интеграции машинного обучения в геотехническую инженерию. Городское строительство часто ставит уникальные задачи, где фундамент является первоочередной проблемой. Учитывая изменчивый характер почвы и подземных коммуникаций в таких условиях, в работе [12] была реализована модель ML для прогнозирования наилучшего типа фундамента (неглубокого, глубокого или свайного) для различных объектов городской инфраструктуры. Используя набор данных, включающий образцы почвы, карты подземных коммуникаций и информацию о предыдущих строительных проектах, модель была обучена с использованием обучения с учителем. Рекомендации модели часто совпадают с суждениями инженеров-геотехников, но, что более важно, она обучена выявлять участки, где традиционные оценки потенциально ошибочны, тем самым предотвращая дорогостоящие затраты и задержки в строительстве.

Автоматизированные системы бурения получили широкое распространение в крупномасштабных геотехнических проектах. Исследование [13] направлено на интеграцию обучения с подкреплением в автоматизированные системы бурения. Цель состоит в том, чтобы позволить системе учиться на окружающей среде в режиме реального времени и принимать решения, которые оптимизируют эффективность бурения, обеспечивая при этом безопасность. Первоначальные результаты указывают на потенциальное сокращение сроков реализации проекта до 15% и значительное снижение износа оборудования.

В работе [14] был рассмотрен горный и сейсмически опасный регион с крутыми склонами и частыми дождями. Авторы разработали модель ML для оценки и прогнозирования устойчивости склонов на основе данных о характере осадков, типах почв, информации об

уклонах склонов и растительном покрове местности. Постоянно оценивая эти параметры, модель предлагала оценку устойчивости склонов в режиме реального времени, предполагая, когда и где могут потребоваться вмешательства. Такой упреждающий подход позволил резко сократить количество оползней в зонах критической инфраструктуры.

Обсуждение проблем, связанных с интеграцией машинного обучения в оценку геотехнических рисков

Объединение машинного обучения с оценкой геотехнических рисков может прокладывать новые пути и предлагать преимущества в решении ряда проблем геотехнических практик. Предполагая повышенную предсказательную способность и эффективный анализ, методы машинного обучения не лишены препятствий, связанных с качеством данных, прозрачностью модели, масштабируемостью и практической реализацией.

Исторически геотехнические данные могут быть разрозненными, противоречивыми и неполными. Причины варьируются от различных методов измерения до региональных различий в регистрации данных и даже экономических ограничений, которые ограничивают обширный сбор данных. Также необработанные данные часто содержат шум, выбросы или пропущенные значения, их очистка, нормализация и приведение в соответствие требуют значительных усилий и опыта. Преобразование необработанных геотехнических данных в машиночитаемый формат, способствующий точным прогнозам, остается серьезным препятствием [15].

Еще одна серьезная проблема – это «черный ящик» многих современных моделей машинного обучения. Инженеры-геотехники по самому характеру своей работы склонны доверять системам, обеспечивающим четкую причинно-следственную связь. Когда модель машинного обучения, такая как глубокая нейронная сеть, дает прогноз или оценку риска, путь к такому выводу не всегда прозрачен. Непрозрачность этих моделей может привести к колебаниям в их принятии, особенно в сценариях с высокими ставками, где понимание «почему» прогноза может быть столь же важным, как и сам прогноз.

Хотя модели машинного обучения превосходно справляются с обработкой больших наборов данных и сложными вычислениями, масштабируемость в средах реального времени остается проблемой. Оценка геотехнических рисков часто требует мгновенных решений, особенно в таких сценариях, как наблюдение за оползнями в реальном времени или структурная целостность инфраструктуры в сейсмоопасных районах. Чем крупнее и сложнее модель машинного обучения, тем большей вычислительной мощности она требует, что иногда может стать уязвимым местом при предоставлении аналитической информации в реальном времени.

Кроме того, при постоянном сборе данных модели необходимо периодически проверять на факт переобученности или доработанности. Обеспечение бесперебойной работы без нарушения оценок в реальном времени — задача, с которой сталкиваются инженеры и специалисты по обработке данных [16].

Большинство геотехнических учреждений имеют существующие системы оценки рисков. Эти системы, создаваемые годами или даже десятилетиями, глубоко встроены в их операционные рабочие процессы. Интеграция моделей машинного обучения в эти устаревшие системы — нетривиальная задача. Это требует не только технической адаптации, но и переустройства внутреннего порядка: обучение персонала, адаптация к новым парадигмам принятия решений и обеспечение того, чтобы интеграция не нарушала текущие операции [17].

В таблице 3 кратко обобщены основные вызовы, возникающие при внедрении ML в оценку геотехнических рисков. В таблице перечислены последствия каждой проблемы и потенциальные решения, что позволяет получить четкое представление о препятствиях, с которыми сталкиваются в этой области. Также таблица подчеркивает, что решения, хотя и требовательные, вполне достижимы.

Таблица 3 – Сводка проблем, возникающих при интеграции машинного обучения в оценку геотехнических рисков

Проблема	Последствие	Потенциальные решения
Сбор и предварительная обработка данных	Несогласованные и неполные наборы данных	Стандартизация, увеличение финансирования, передовые сенсоры
Интерпретируемость моделей и доверие	Нежелание принимать непрозрачные модели	Интеграция инструментов Explainable AI (XAI)
Масштабируемость и обработка в реальном времени	Задержки в принятии решений в критических ситуациях	Оптимизация алгоритмов и распределенные вычисления
Интеграция с существующими системами	Нарушения в текущих рабочих процессах	Программы обучения и поэтапная интеграция
Этические соображения и ответственность	Дилеммы относительно ответственности в случае ошибок модели	Четкие правовые рамки и руководящие принципы

Заключение

Современные геотехнические практики значительно выиграли от интеграции вычислительных инструментов и современных методологий. Машинное обучение с его возможностями подходит для решения многих сложных проблем, присущих геотехнической инженерии. Однако прежде чем любую модель машинного обучения можно будет обучить, данные необходимо подготовить, очистить и, возможно, дополнить. Для геотехнических данных это может включать нормализацию, обработку пропущенных значений и даже возможное объединение нескольких типов наборов данных.

Благодаря достижениям в области разработки датчиков технологии и IoT теперь стало возможным собирать данные в режиме реального времени со строительных площадок, буровых установок и даже глубоко под землей. Алгоритмы машинного обучения могут интегрировать эти данные, предоставляя немедленную информацию и потенциально выявляя риски или аномалии в режиме реального времени. Такой подход значительно сокращает время реакции в случае непредвиденных проблем.

Объединение машинного обучения с оценкой геотехнических рисков может открыть новые пути и предлагать преимущества в решении ряда проблем геотехнических практик. Предполагая повышенную предсказательную способность и эффективный анализ, методы машинного обучения не лишены препятствий, связанных с качеством данных, прозрачностью модели, масштабируемостью и практической реализацией. Тем не менее продолжающиеся исследования и разработки в этой области указывают на значительный потенциал для повышения безопасности и эффективности инфраструктурных проектов.

Литература

1. Геотехнический мониторинг [Электронный ресурс]. URL: https://official.academic.ru/4104/%D0%93%D0%B5%D0%BE%D1%82%D0%B5%D1%85%D0%BD%D0%B8%D1%87%D0%B5%D1%81%D0%BA%D0%B8%D0%B9_%D0%BC%D0%BE%D0%BD%D0%B8%D1%82%D0%BE%D1%80%D0%B8%D0%BD%D0%B3 (дата обращения: 20.04.2024).
2. Грязнова Е.М. Геотехнический мониторинг в строительстве / Е.М. Грязнова, А.Н. Гаврилов, Д.Ю. Чунюк. – Москва : МИСИ—МГСУ, 2017. – 82 с.
3. Улицкий В.М., Шашкин А.Г., Шашкин К.Г. Геотехническое сопровождение развития городов. СПб.: Стройиздат Северо-Запад, Геореконструкция, 2010. – 551 с.
4. Далматов Б.И. Механика грунтов, основания и фундаменты. – Стройиздат, 1998.
5. Далматов Б.И. Механика грунтов. Основы геотехники. Ч. 1. – Москва, 2000.

6. Zhang C, Liang M, Song X, Liu L, Wang H, Li W, et al. Generative adversarial network for geological prediction based on TBM operational data. *Mechanical Systems and Signal Processing*. 2022;162:108035.
7. Fang H, Shao Y, Xie C, Tian B, Shen C, Zhu Y, et al. A new approach to spatial landslide susceptibility prediction in karst mining areas based on explainable Artificial Intelligence. *Sustainability*. 2023;8, 15(4):3094. DOI:10.3390/su15043094
8. Krechowicz M, Krechowicz A. Risk assessment in energy infrastructure installations by horizontal directional drilling using machine learning. *Energies*. 2021;14(2):289. DOI: 10.3390/en14020289
9. Carri A. Innovative application of IoT technologies to improve geotechnical monitoring tools and early warning performances. In: *Critical Thinking in the Sustainable Rehabilitation and Risk Management of the Built Environment: CRIT-RE-BUILT. Proceedings of the International Conference; November 7-9, 2019, Iași, Romania. Switzerland*.
10. Mahdi IM, Ebid AM, Khallaf R. Decision support system for optimum soft clay improvement technique for highway construction projects. *Ain Shams Engineering Journal*. 2020;11(1): 213-223. DOI: 10.1016/j.asej.2019.08.007
11. Hallaji SM, Fang Y, Winfrey BK. Predictive maintenance of pumps in civil infrastructure: State-of-the-art, challenges and future directions. *Automation in Construction*. 2022;134: 104049. DOI: 10.1016/j.autcon.2021.104049
12. Seyedzadeh S, Rahimian FP, Oliver S, Rodriguez S, Glesk I. Machine learning modelling for predicting non-domestic buildings energy performance: A model to support deep energy retrofit decision-making. *Applied Energy*. 2020; 279:115908. DOI: 10.1016/j.apenergy.2020.115908
13. Sircar A, Yadav K, Rayavarapu K, Bist N, Oza H. Application of machine learning and artificial intelligence in oil and gas industry. *Petroleum Research*. 2021;6(4):379-391. DOI: 10.1016/j.ptlrs.2021.05.009
14. Bravo-López E, Fernández Del Castillo T, Sellers C, Delgado-García J. Landslide susceptibility mapping of landslides with artificial neural networks: Multi-approach analysis of backpropagation algorithm applying the neuralnet package in Cuenca. Ecuador. *Remote Sensing*. 2022;14(14):3495. DOI: 10.3390/rs14143495
15. Zhang W, Gu X, Tang L, Yin Y, Liu D, Zhang Y. Application of machine learning, deep learning and optimization algorithms in geoenvironment and geoscience: Comprehensive review and future challenge. *Gondwana Research*. 2022;109:1-17. DOI: 10.1016/j.gr.2022.03.015
16. Lu X, Xu Y, Tian Y, Cetiner B, Taciroglu E. A deep learning approach to rapid regional post-event seismic damage assessment using time-frequency distributions of ground motions. *Earthquake Engineering & Structural Dynamics*. 2021;50(6): 1612-1627. DOI: 10.1002/eqe.3415
17. Kim HS, Sun CG, Lee MG, Cho HI. Multivariate geotechnical zonation of seismic site effects with clustering-blended model for a city area, South Korea. *Engineering Geology*. 2021;294: 106365. DOI: 10.1016/j.enggeo.2021.106365
18. Мэрфи К. П. Вероятностное машинное обучение: введение / пер. с англ. А. А. Слинкина / К.П. Мэрфи. - Москва : ДМК Пресс, 2023. - 990 с.
19. Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение / Пер. с англ. А. А. Слинкина. - 2-е изд., испр. - М.: ДМК. Пресс, 2018. - 652 с.