



Источник изображения: <https://stock.adobe.com/ru/search/free>

# ТРАНСФОРМАЦИИ В ГЕОТЕХНИКЕ С ПОМОЩЬЮ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА: ДОСТИЖЕНИЯ, ПРОБЛЕМЫ И ПЕРСПЕКТИВЫ

Принята к публикации 24.12.2025  
Опубликована 30.01.2026

## ШЕЙЛ Б.

Инженерный факультет Кембриджского университета, г. Кембридж, Великобритания  
bbs24@cam.ac.uk

## АНАГНОСТОПУЛОС К.

Факультет (школа) компьютерных наук Университета Глазго, г. Глазго, Великобритания

## БАКЛИ Р.

Факультет (школа) инженерных наук имени Джеймса Ватта Университета Глазго, г. Глазго, Великобритания

## ЧИАНТИА М.О.

Факультет (школа) естественных и инженерных наук Университета Данди, г. Данди, Великобритания; факультет наук о Земле и окружающей среде Университета Милана-Бикокка, г. Милан, Италия

## ФЕБРИАНТО Э.

Факультет (школа) инженерных наук имени Джеймса Ватта Университета Глазго, г. Глазго, Великобритания

## ФУ Ц.

Факультет (школа) инженерных наук и материаловедения Лондонского университета имени Королевы Марии, г. Лондон, Великобритания

## ГАО Ч.

Факультет (школа) инженерных наук имени Джеймса Ватта Университета Глазго, г. Глазго, Великобритания

## ГЭН С.

Инженерный факультет Университета Уорика, г. Ковентри, Великобритания

## ГУН Б.

Колледж инженерных, дизайнерских и естественных наук при Лондонском университете имени Брунеля, г. Лондон, Великобритания

## ХЭНЛИ К.

Бакалавриат по химическим технологиям Эдинбургского университета, г. Эдинбург, Великобритания

## ХЭ П.

Факультет (школа) естественных и инженерных наук Университета Данди, г. Данди, Великобритания

## КОЛОМВАТСОС К.

Факультет инженерных и компьютерных наук Университета Фессалии, г. Волос, Греция

**ЛОПЕС Б.К.Ф.Л.**

Факультет гражданского и экологического строительства  
Университета Стратклайда, г. Глазго, Великобритания

**НИНИЧ Й.**

Инженерный факультет (школа) Бирмингемского  
университета, г. Бирмингем, Великобритания

**ПРЕВИТАЛИ М.**

Факультет (школа) естественных и инженерных наук  
Университета Данди, г. Данди, Великобритания

**РЕЗАНИЯ М.**

Инженерный факультет (школа) Университета Уорика,  
г. Ковентри, Великобритания

**РУИС-ЛОПЕС А.**

Компания Seequent («Сиквент») – дочерняя компания  
корпорации Bentley Systems по подземным технологиям,  
г. Крайстчерч, Новая Зеландия; инженерный факультет  
Лондонского Имперского колледжа,  
г. Лондон, Великобритания

**СУНЬ Ц.**

Факультет (школа) инженерных наук имени Джеймса Ватта  
Университета Глазго, г. Глазго, Великобритания

**СУРЬЯСЕНТАНА С.**

Факультет гражданского и экологического строительства  
Университета Стратклайда, г. Глазго, Великобритания

**ТАБОРДА Д.**

Инженерный факультет Лондонского имперского  
колледжа, г. Лондон, Великобритания

**УТИЛИ С.**

Инженерный факультет (школа) Университета Ньюкасла,  
г. Ньюкасл-апон-Тайн, Великобритания

**ВАЙТ С.**

Компания Geowynnd («Геовинд»),  
г. Лондон, Великобритания

**ЧЖАН П.**

Факультет гражданского и экологического строительства  
Сингапурского национального университета, Сингапур

**АННОТАЦИЯ**

Предлагаем вниманию читателей адаптированный перевод подробного обзора «Трансформации в геотехнике с помощью искусственного интеллекта: достижения, проблемы и перспективы», который был подготовлен международной группой исследователей (преимущественно из Великобритании). Основой данной работы явился доклад авторов на Первом симпозиуме по применению искусственного интеллекта в геотехнике, проведенном в мае 2023 года в шотландском городе Глазго, после чего она почти два года дорабатывалась и в январе 2025 года поступила в виде статьи в редакцию журнала *Computers and Geotechnics* («Компьютеры и геотехника») издательства Elsevier («Элсевир/Эльзевир»). Этот обзор будет опубликован в указанном журнале в январе 2026 года. Сейчас эта работа находится в открытом доступе по лицензии CC BY 4.0, которая позволяет копировать, распространять, адаптировать, видоизменять ее и создавать новое на ее основе при указании вида лицензии, типов изменений и ссылки на первоисточник. В данном случае полная ссылка на источник для перевода приведена в конце.

Необходимость в освоении подземного пространства для создания критически важных объектов гражданского строительства неуклонно растет – для размещения коммунальной и транспортной инфраструктуры в городских условиях, для реализации инновационных жилищных и коммерческих решений, а также для поддержки растущей инфраструктуры возобновляемой энергетики, особенно в морской прибрежной зоне. Пожалуй, наиболее перспективным инструментом для соответствующей трансформации геотехники является искусственный интеллект (ИИ) благодаря его способности извлекать знания из данных и обеспечивать кардинальное повышение эффективности, устойчивости, надежности и безопасности работ.

Цель данной статьи – сформировать общее понимание текущего уровня применения искусственного интеллекта в геотехнике и исследовать перспективные направления его развития. Чтобы продемонстрировать достигнутый прогресс в этой сфере, рассматриваются конкретные примеры распространенных вариантов использования ИИ, в том числе для интеллектуальных геотехнических изысканий, прогнозного моделирования поведения грунтов и оптимизации процессов проектирования и строительства. Кроме того, в статье затрагиваются важнейшие исследовательские вопросы, такие как недостаток данных и проблемы интерпретации результатов, а также обсуждаются возможности, которые открываются при внедрении ИИ в геотехнику. И наконец, определяются ключевые технологические перспективы будущих преобразований в отрасли.

**КЛЮЧЕВЫЕ СЛОВА:**

геотехника; геотехнические изыскания; искусственный интеллект; интеллектуальные инженерные изыскания; моделирование поведения грунтов; оптимизация геотехнического проектирования; машинное обучение; человеко-машинное взаимодействие; междисциплинарный подход; этические аспекты; правовые аспекты.

**ССЫЛКА ДЛЯ ЦИТИРОВАНИЯ:**

Шейл Б., Анагностопулос К., Бакли Р., Чиантиа М.О., Фебрианто Э., Фу Ц., Гао Ч., Гэн С., Гун Б., Хэнли К., Хэ П., Коломватсос К., Лопес Б.К.Ф.Л., Нинич Й., Превитали М., Резания М., Руис-Лопес А., Сунь Ц., Сурьясентана С., Таборда Д., Утили С., Вайт С., Чжан П. Трансформации в геотехнике с помощью искусственного интеллекта: достижения, проблемы и перспективы (адапт. пер. с англ.) // *Геоинфо*. 2025. Т. 7. № 4. С. 52–80.  
DOI:10.58339/2949-0677-2025-7-4-52-80.

# ARTIFICIAL INTELLIGENCE TRANSFORMATIONS IN GEOTECHNICS: PROGRESS, CHALLENGES AND FUTURE ENABLERS

Accepted for publication 24.12.2025

Published 30.01.2026

**SHEIL B.**

Department of Engineering, University of Cambridge,  
Cambridge, UK  
bbs24@cam.ac.uk

**ANAGNOSTOPOULOS C.**

School of Computing Science, University of Glasgow, Glasgow,  
UK

**BUCKLEY R.**

James Watt School of Engineering, University of Glasgow,  
Glasgow, UK

**CIANTIA M.O.**

School of Science and Engineering, University of Dundee,  
Dundee, Scotland, UK; Department of Earth and Environmental  
Sciences, University of Milano-Bicocca, Milan, Italy

**FEBRIANTO E.**

James Watt School of Engineering, University of Glasgow,  
Glasgow, UK

**FU J.**

School of Engineering and Materials Science, Queen Mary  
University of London, London, UK

**GAO Z.**

James Watt School of Engineering, University of Glasgow,  
Glasgow, Coventry

**GENG X.**

School of Engineering, University of Warwick, Coventry, UK

**GONG B.**

College of Engineering, Design and Physical Sciences, Brunel  
University of London, London, UK

**HANLEY K.**

Chemical Engineering (BEng Hons) programme, University of  
Edinburgh, Edinburgh, UK

**HE P.**

School of Science and Engineering, University of Dundee,  
Dundee, UK

**KOLOMVATSOS K.**

Engineering and Computer Science, University of Thessaly,  
Volos, Greece

**LOPES B.C.F.L.**

Department of Civil and Environmental Engineering, University  
of Strathclyde, Glasgow, UK

**NINIC J.**

School of Engineering, University of Birmingham, Birmingham, UK

**PREVITALI M.**

School of Science and Engineering, University of Dundee,  
Dundee, UK

**REZANIA M.**

School of Engineering, University of Warwick, Coventry, UK

**RUIZ-LOPEZ A.**

Seequent (The Bentley Subsurface Company), Christchurch,  
New Zealand; Faculty of Engineering, Imperial College London,  
London, UK

**SUN J.**

James Watt School of Engineering, University of Glasgow,  
Glasgow, UK

**SURYASENTANA S.**

Department of Civil and Environmental Engineering, University  
of Strathclyde, Glasgow, UK

**TABORDA D.**

Faculty of Engineering, Imperial College London, London, UK

**UTILI S.**

School of Engineering, Newcastle University, Newcastle upon  
Tyne, UK

**WHYTE S.**

Geowynd company, London, UK

**ZHANG P.**

Department of Civil and Environmental Engineering, National  
University of Singapore, Singapore

**ABSTRACT**

We present to our readers an adapted translation of the extensive review paper “Artificial intelligence transformations in geotechnics: progress, challenges and future enablers”, authored by an international group of researchers (predominantly from the United Kingdom). This work is based on the authors’ report at the 1st Workshop on AI in Geotechnics, held in May 2023 in Glasgow, Scotland, UK. After that workshop, the paper had been revised for almost two years, and it was submitted to the Computers and Geotechnics journal of the Elsevier publishing company in January 2025. The review will be published in that journal in January 2026. The paper is currently available in open access under the CC BY 4.0 license, which allows users to copy, distribute, adapt, modify it, and build upon it, provided that the license type, changes made are indicated and the original source is referenced. In our case, the full reference to the original source is provided at the end of the translation.

**Our reliance on the underground space to deliver critical civil engineering infrastructure is growing: to accommodate utility and transport infrastructure in urban environments, to provide innovative housing and commercial solutions, and to support proliferating renewable energy infrastructure, particularly offshore. Artificial intelligence (AI) is arguably the most promising enabler to transform geotechnical engineering by extracting knowledge from data to achieve step-change increases in efficiency, sustainability, reliability and safety.**

**This paper seeks to develop a shared understanding of the state of the art of AI in geotechnics and to explore future developments. By way of example, specific popular use cases in geotechnics are considered to highlight current progress in AI applications including intelligent site investigation, predictive modelling for soil behaviour, and optimisation of design and construction processes. The paper then addresses key research challenges, such as data scarcity and interpretability, and discusses the opportunities that lie ahead in the integration of AI with geotechnical engineering. Finally, priority technological enablers are identified for future transformations.**

#### KEYWORDS:

**geotechnics; geotechnical investigations; artificial intelligence; intelligent site investigations; soil behavior modeling; geotechnical design optimization; machine learning; human-machine interaction; interdisciplinary approach; ethical aspects; legal aspects.**

#### FOR CITATION:

**Sheil B., Anagnostopoulos C., Buckley R., Ciantia M.O., Febrianto E., Fu J., Gao Z., Geng X., Gong B., Hanley K., He P., Kolomvatsos K., Lopes B.C.F.L., Ninic J., Previtali M., Rezania M., Ruiz-Lopez A., Sun J., Suryasentana S., Taborda D., Utili S., Whyte S., Zhang P. Transformatsii v geotekhnike s pomoshch'yu iskusstvennogo intellekta: dostizheniya, problemy i perspektivy (adapt. per. s angl.) [Artificial intelligence transformations in geotechnics: progress, challenges and future enablers (adapted translation from English into Russian)] // Geoinfo. 2025. T. 7. № 4. S. 52–80. DOI:10.58339/2949-0677-2025-7-4-52-80 (in Rus.).**

#### ВВЕДЕНИЕ ►

Интеграция искусственного интеллекта (ИИ) в самые разные сферы деятельности уже стимулирует прогресс в их трансформации. Например, в здравоохранении инструменты диагностики и прогнозные модели на основе ИИ способствуют повышению точности выявления заболеваний и планирования лечения [1]. Применение искусственного интеллекта в экономике, в частности в ее финансовой сфере, позволило оптимизировать торговые стратегии, управление рисками и выявление мошеннических действий [2]. Технологии ИИ также используются для создания цифровых двойников крупных строительных объектов, например железнодорожных мостов и путей [3, 4]. В связи с недавним быстрым развитием крупных языковых моделей (программных алгоритмов, анализирующих тексты, понимающих их контексты, обрабатывающих их и генерирующих новые тексты, например ChatGPT [5]) значительный вырос интерес к исследованиям потенциала ИИ для обеспечения кардинального увеличения эффективности и инноваций в геотехнике.

Один из ключевых стимулов внедрения искусственного интеллекта в геотехнику – насущная необходимость в решении все более сложных задач, возникающих как при развитии подземной инфраструктуры [6, 7 и др.], так и при строительстве инфраструктуры морской прибрежной энергетики [8 и др.].

Подповерхностные условия могут быть как очень сложными, так и неопределенными. Точное прогнозирование поведения грунтов – также весьма сложная задача. Традиционные аналитические методы часто не справляются с тонкостями и парадоксами геотехнических данных, что приводит к потенциальным неточностям и неэффективности процессов проектирования и строительства [9]. Однако для более глубокого анализа растущих массивов данных, который позволит создавать более целостные и точные прогнозные модели и повышать эффективность рабочих процессов, могут послужить передовые алгоритмы машинного обучения (МО) и методы, основанные на данных. Важно отметить, что возможности многих подходов МО могут быть, в свою очередь, расширены для учета неопределенностей моделей, что повысит надежность их работы со сложными или неполными данными.

В этой обзорно-концептуальной статье обобщены ключевые возможности, проблемы и необходимость исследований в области применения искусственного интеллекта в геотехнике. Вместо исчерпывающего обзора имеющихся литературных источников рассматриваются отдельные показательные примеры использования ИИ в интеллектуальных инженерных изысканиях, прогнозном моделировании поведения грунтов, а также в оптимизации процессов проектирования и строительства, чтобы под-

крепить приведенные аргументы. При этом обсуждение каждого из перспективных направлений основывается на современной доказательной базе.

#### ЦЕЛИ И НАПРАВЛЕНИЯ РАЗВИТИЯ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ►

Развитие ИИ направлено на создание интеллектуальных машин, которые могут имитировать человеческий интеллект. Основная цель при этом – сделать так, чтобы машины могли воспринимать информацию по окружающей среде, рассуждать, извлекать уроки из опыта и принимать обоснованные решения на основе данных и закономерностей [10]. Искусственный интеллект – это широкий термин, охватывающий в том числе машинное обучение, компьютерное зрение и робототехнику (рис. 1).

Машинное обучение (machine learning, ML) является фундаментальным элементом разработки интеллектуальных систем и включает создание алгоритмов и/или статистических моделей, позволяющих машинам постепенно улучшать эффективность выполнения конкретных задач при наличии обучающих данных. Оно включает следующие подобласти, каждая из которых сосредоточена на определенных аспектах имитации интеллекта: обучение «с учителем» (контролируемое), обучение «без учителя» (неконтролируемое), обучение с подкреплением (методом «проб и ошибок»), глубокое обучение,

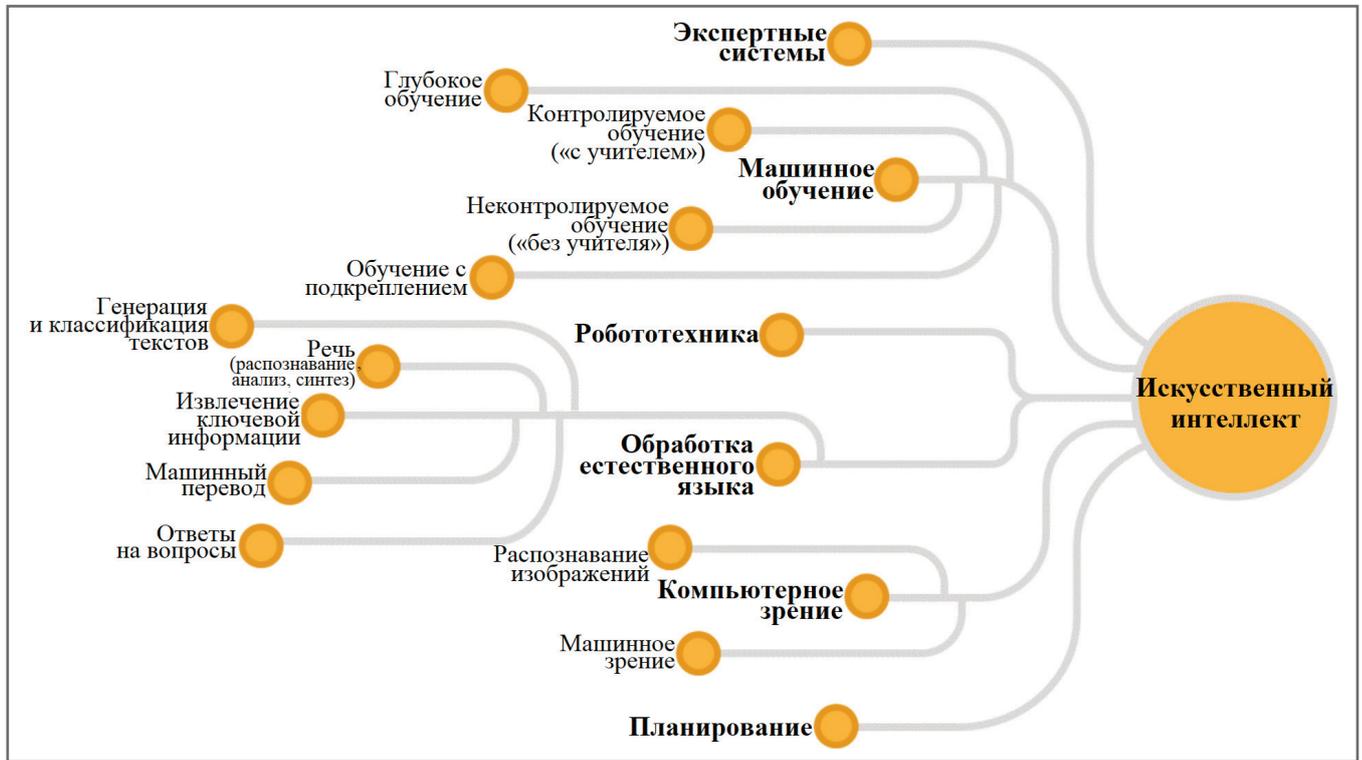


Рис. 1. Схема направлений (подобластей) искусственного интеллекта

а также байесовские методы и обработку естественного языка (однако такая классификация не полностью соответствует рисунку 1 – и редактор адаптированного перевода счел необходимым добавить пояснения. Во-первых, байесовские методы – это скорее не подобласть машинного обучения, а технический подход, который можно применять во всех перечисленных до него подобластях. Поэтому данный подход не обозначен на рисунке 1, хотя иногда его показывают как пересекающийся слой или как уточнения внутри других ветвей. Во-вторых, обработку естественного языка чаще выделяют в виде отдельной ветви искусственного интеллекта, как показано на рисунке 1, хотя в ней активно используются методы машинного обучения для анализа и генерации текстов и речи. – *Ред.*)

Глубокое обучение (deep learning, DL) представляет собой дополнительную подобласть машинного обучения, направленную на разработку и обучение искусственных нейронных сетей, которые имитируют архитектуру и принципы работы человеческого мозга. Оно использует множество слоев (отсюда в названии слово «глубокое»), взаимосвязанных узлов, или нейронов, для решения более сложных задач, автоматически учась иерархически представлять данные, абстрагировать и извлекать признаки данных на разных уровнях сложности (абстракции).

В процессе обучения с подкреплением (reinforcement learning, RL) обучающийся агент (алгоритм, система) многократно взаимодействует с заданной средой, то есть пробует разные действия, каждый раз получая обратную связь о принятых решениях в виде «штрафа» или «вознаграждения», в результате чего со временем вырабатывает оптимальное поведение.

Обработка естественного языка (natural language processing, NLP) направлена на то, чтобы дать машинам возможность понимать, анализировать и генерировать человеческий язык. Это направление выходит за рамки простого распознавания текста и включает в том числе такие задачи, как анализ тональности (эмоциональной окраски), машинный перевод и ответы на вопросы.

Также популярны варианты машинного обучения, построенные на байесовском подходе, которые используются для учета алеаторных (связанных с природными случайностями и шумом в данных) и эпистемических (обусловленных недостатком знаний) неопределенностей при анализе данных. В геотехнических приложениях они могут учитывать неопределенности, связанные с материалами (включая их пространственную изменчивость и неопределенность свойств) и/или с численными моделями, а также неопределенности,

присущие качеству данных и системам измерений [11–13].

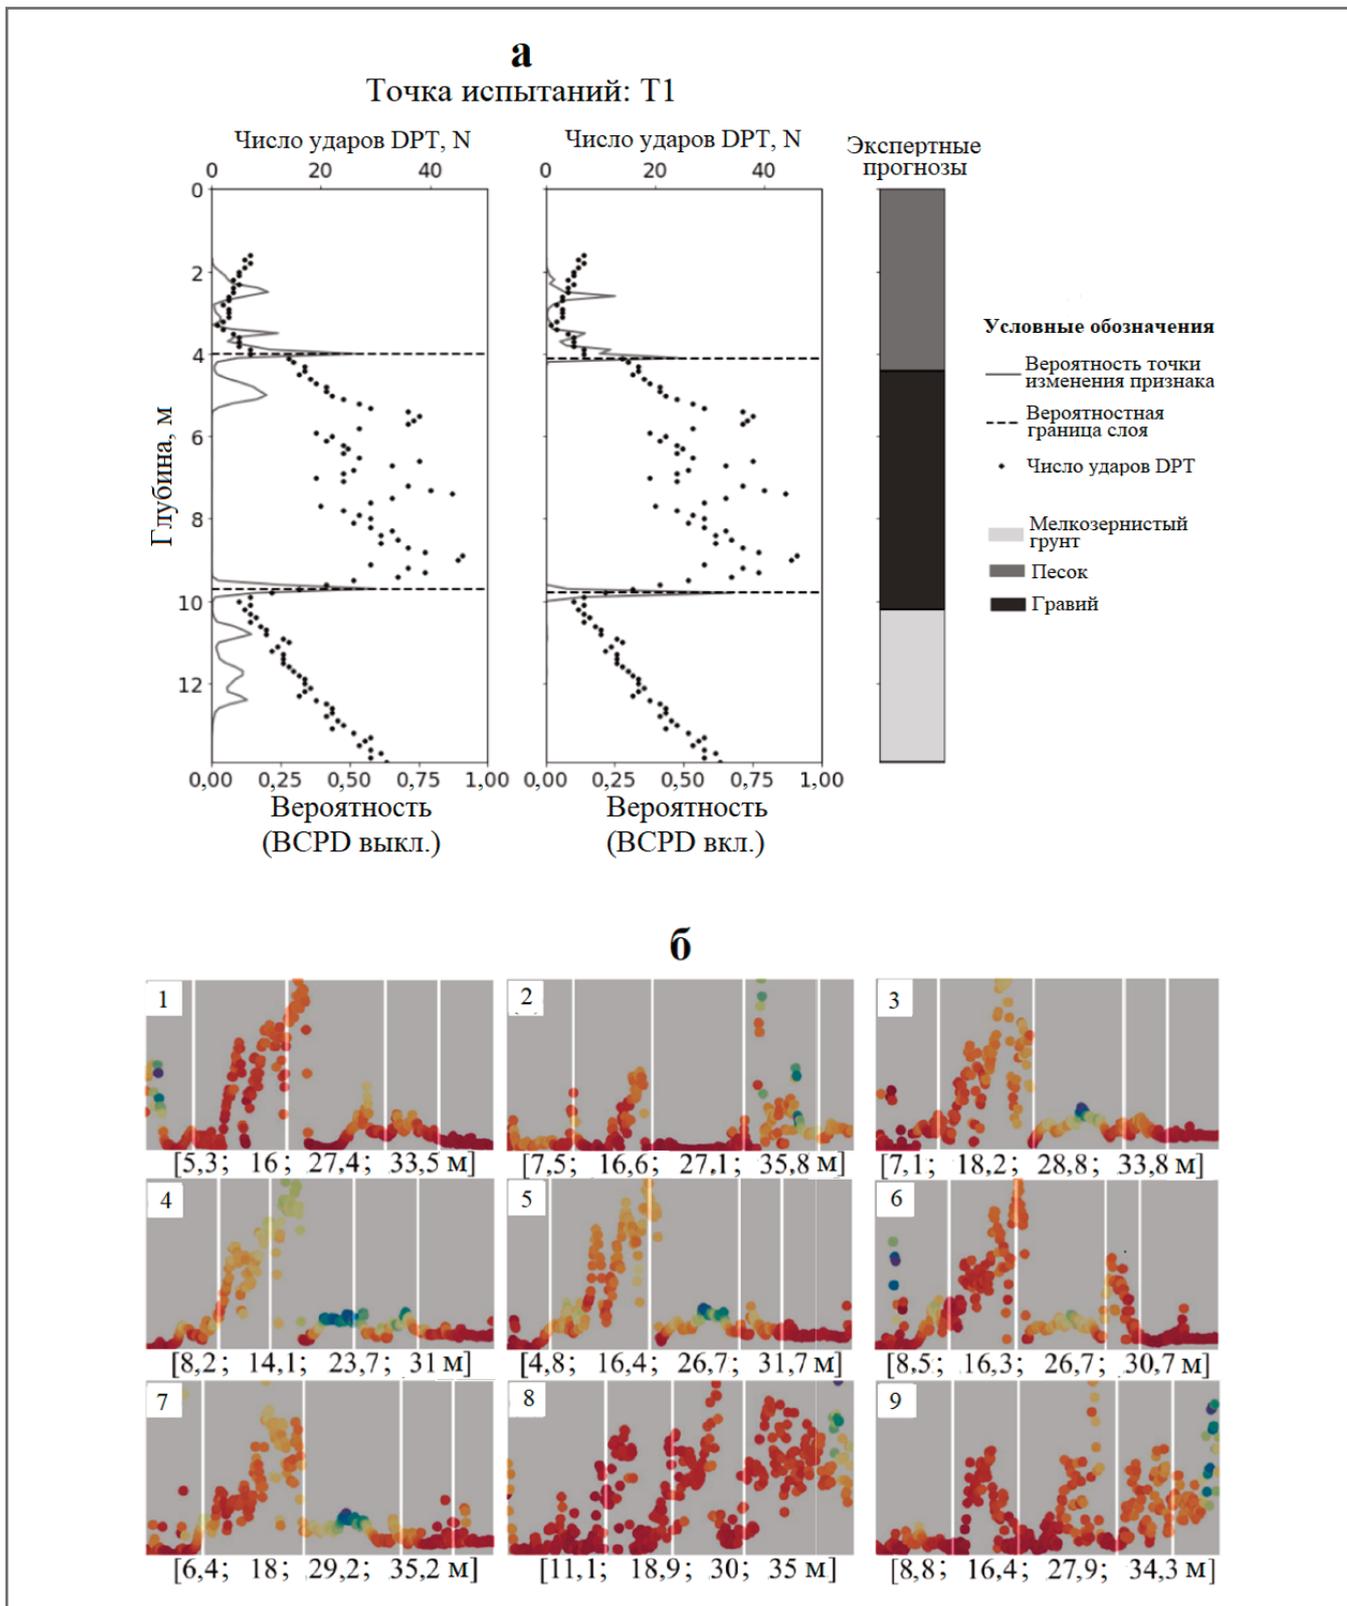
### ПОСЛЕДНИЕ ДОСТИЖЕНИЯ В ОТДЕЛЬНЫХ ПОПУЛЯРНЫХ ПРИЛОЖЕНИЯХ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ГЕОТЕХНИКЕ ▶

Данная работа сосредоточена на последних достижениях в области регрессионных моделей и классификаторов для:

1. Инверсии (например, установления связи между полевыми данными и геотехническими параметрами).
2. Прогнозирования реакций материалов (например, при устройстве свай, смещениях фундаментов, оползнях).
3. Прогнозирования реакций инженерных конструкций (например, для управления тоннелепроходческими комплексами).
4. Повышения эффективности детерминированных методов (например, комплексных геомеханических (конститутивных) моделей поведения материалов).

### Интеллектуальные инженерные изыскания и моделирование грунтовой среды ▶

При геотехнических изысканиях для построения моделей грунтовой среды на основе данных широко применяется машинное обучение, чтобы



**Рис. 2.** Прогнозирование границ стратиграфических слоев с использованием: а – данных динамического зондирования сплошным наконечником без отбора проб (методом DPT) [21]; б – данных статического зондирования конусом (методом СРТ) [28]. *Расшифровка аббревиатуры:* ВСПД – байесовский метод выявления точек изменений для отдельных признаков (Univariate Bayesian Change Point Detection)

получить информацию, необходимую для проектирования фундаментов и выбора оптимальных мест отбора проб [14–16].

Модели грунтовых условий на основе данных обычно строятся с использо-

ванием геотехнической информации, такой как результаты динамического зондирования грунтов пробоотборником (методом SPT) или сплошным наконечником без отбора проб (методом DPT). Это моделирование решает такие

две основные задачи прогнозирования, как определение стратиграфического строения подповерхностной среды и пространственная интерполяция (прогнозирование) геотехнических свойств грунтов.

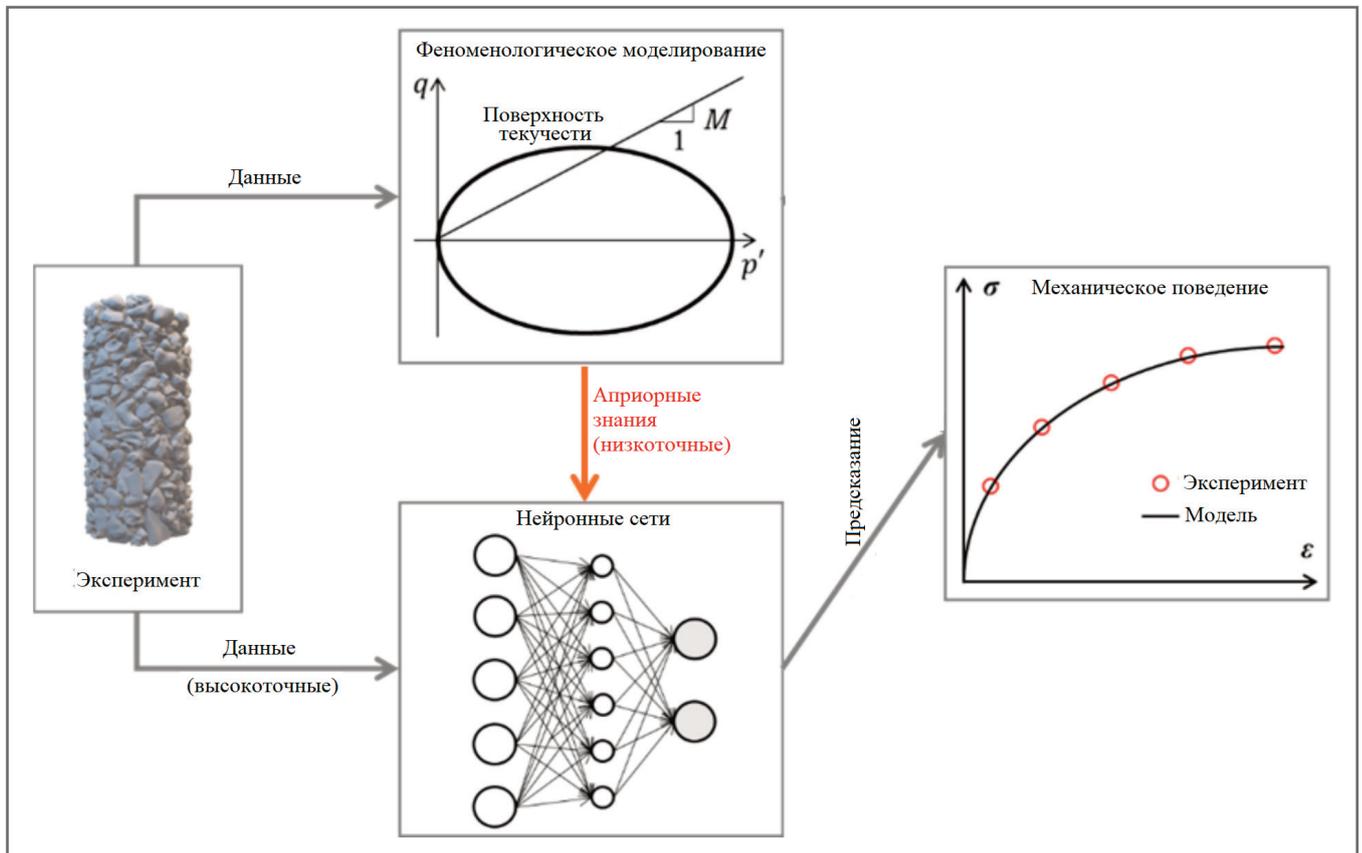


Рис 3. Процесс моделирования с несколькими/многими уровнями точности, использованный в работе Чжана и др. [99], который включает комбинацию нейронной сети на основе данных и традиционные модели на основе наблюдений (феноменологические)

Для определения стратиграфического строения грунтовой среды к настоящему моменту применяются различные методы машинного обучения, такие как:

- регрессия на основе гауссовских процессов, которая математически эквивалентна своему предшественнику – кригингу [17];
- байесовский выбор класса моделей [18];
- метод выявления точек изменений в данных (например, для определения границ стратиграфических слоев) [19–21];
- байесовское сжимающее восстановление разреженных данных [22];
- подходы на основе случайных полей [23, 24];
- регрессия с использованием метода регуляризации LASSO (Least Absolute Shrinkage and Selection Operator – «оператор наименьшего абсолютного сжатия и отбора признаков») [25];
- методы кластеризации [26, 27];
- глубокое обучение (в последнее время) [28].

На рисунке 2 приведены примеры недавних реальных случаев идентификации границ стратиграфических слоев с использованием данных статического зондирования конусом (мето-

дом СРТ) и динамического зондирования сплошным наконечником без отбора проб (методом DPT). Как показали Сурьясентана с коллегами [29], байесовские методы выявления точек/границ изменений для отдельных признаков (Univariate Bayesian Change Point Detection, BCPD) превосходят многомерные подходы (для нескольких признаков) при выделении стратиграфических слоев по данным СРТ. В частности, комбинированный (типологический) индекс поведения грунта  $I_c$  обеспечивает более надежное прогнозирование границ, чем совместный анализ сопротивления под конусом  $Q$ , и коэффициента трения  $F_v$  (отношения сопротивления по боковой поверхности к лобовому). Это, вероятно, связано с эмпирической калибровкой индекса  $I_c$  на основе существующих баз данных по классификации грунтов, которые неявно включают априорные знания, подходящие для стратиграфической интерпретации.

Ранее для пространственного прогнозирования геотехнических свойств исследователи применяли такие методы, как: кригинг [30–33]; подходы на основе случайных полей [31]; байесовское сжимающее восстановление разре-

женных данных [22, 34–36]; множественно-точечная статистика [37]; метод XGBoost (алгоритм градиентного бустинга, использующий ансамбль решающих деревьев) [38]; нейронные сети [39, 40].

Кроме того, в последнее время вырос интерес к комплексному моделированию грунтовых условий, объединяющему данные из разных источников (результаты геофизических и геотехнических исследований). Объединение данных разных типов направлено на создание более точных и согласованных моделей грунтовой среды, использующих преимущества каждого источника. Методы объединения данных применяются для изучения взаимосвязей между различными источниками и их использования для прогнозирования состояния подповерхностных условий. К этим методам относятся: кокригинг [39, 41]; подходы на основе случайных полей [42]; многомасштабные подходы [43]; байесовский вывод (байесовская вероятностная оценка) [44, 45]; байесовское сжимающее восстановление разреженных данных из разных источников [46, 47]; метод случайного леса (ансамблирование деревьев решений) [48]; нейронные сети [39, 49, 50].

## Прогнозное моделирование поведения грунтов ▶

Грунты представляют собой сложные дисперсные материалы со сложным механическим поведением, включая критическое состояние [51, 52], зависимость от начального состояния (например, [53]), дилатансию при нагружении [54–56 и др.], анизотропию [57, 58 и др.], деструктурирование [59–61 и др.], зависимость от траектории напряжений [62 и др.], зависимость от времени [63, 64 и др.] и некоаксиальность напряжений и деформаций [65 и др.]. Это послужило стимулом для разработки ряда комплексных геомеханических (конститутивных) моделей поведения грунтов, предназначенных для учета его зависимости от времени [66, 67 и др.], зависимости от состояния [68, 69 и др.], дилатансии при нагружении [70, 71 и др.], анизотропии [72–74 и др.], зависимости от траектории напряжений [75 и др.], некоаксиальности напряжений и деформаций [76 и др.] и фазовых переходов [77 и др.].

При традиционном конститутивном моделировании предполагается, что поведение грунта может быть описано математическим уравнением с набором параметров или переменных. Но стремление отразить нестандартные реакции грунтов все время приводит к появлению все более сложных конститутивных моделей с увеличенным количеством материальных параметров. Например, модель SANISAND [78] включает несколько тензоров внутренней структуры грунта и внутренних переменных, которые, хотя и позволяют успешно моделировать сложное поведение материала, значительно усложняют калибровку модели и ограничивают ее интерпретируемость.

С ростом доступности ресурсов искусственного интеллекта в начале 1990-х годов некоторые исследователи начали изучать применение методов ИИ, в частности нейронных сетей, в качестве альтернативы для моделирования поведения материалов [79, 80 и др.]. Эллис с соавторами [81] и Габусси с коллегами [79] стали пионерами в разработке комплексных геомеханических (конститутивных) моделей грунтов на основе нейронных сетей. И вскоре появилось заметное количество конститутивных моделей на основе ИИ [82–84 и др.]. Развитие такого моделирования вышло за рамки нейронных сетей и включало другие методы ИИ, например эволюционную регрессию [85]. В последние годы исследования в рассматриваемой области перешли к численной

реализации этих «интеллектуальных» материальных моделей [86–89 и др.].

Однако эффективность ранних конститутивных моделей на базе ИИ, полностью основанных на данных, была неоднозначной из-за их низкой интерпретируемости и необходимости в больших объемах данных для эффективного обучения. Важно отметить, что такие модели демонстрировали слабую способность к обобщению (экстраполяции): достоверность прогнозов ухудшалась за пределами области признаков, использованных в обучающем наборе данных.

Возрождение в последние годы интереса к использованию искусственного интеллекта в геотехнике дало новый толчок разработке конститутивных моделей на основе ИИ, причем методы машинного обучения с учетом физических закономерностей [90–92] стали ключевым трендом в моделировании материалов. В недавних исследованиях рассматривалась возможность объединения априорных/базовых знаний, таких как эмпирические зависимости или физические законы, с методами МО для ограничения предсказаний разумными пределами [93–98 и др.]. Несмотря на то что эти разработки значительно улучшили обобщающую способность, такие гибридные модели по-прежнему требуют больших наборов высококачественных данных для достижения эффективности предсказаний, сопоставимой с эффективностью использования традиционных конститутивных моделей.

Эти проблемы стимулировали развитие интерпретируемых подходов в МО, пригодных для обучения на наборах разреженных геотехнических данных [99]. Например, Чжан с соавторами [100] включили в нейронную сеть на основе априорной информации три различных теоретических подхода – инкрементальную нелинейность, гиперупругость и упругопластичность (например, рис. 3). Для создания моделей поведения реальных грунтов в сочетании с многоуровневой схемой моделирования (с разной точностью) использовались три модели нейронных сетей на основе априорной информации, чтобы максимизировать влияние разреженных высокоточных данных (и, следовательно, снизить зависимость от них). Такой подход обеспечил эффективный, точный и универсальный метод моделирования поведения грунтов. Это продемонстрировало потенциал методов ИИ, учитывающих физические законы (физически информированных), для создания конститутивных моделей грунта.

## Оптимизация геотехнического проектирования, строительных процессов и оценки рисков ▶

В современной геотехнике ключевым направлением стала оптимизация геотехнического проектирования и строительных процессов с растущим вниманием к использованию технологий искусственного интеллекта.

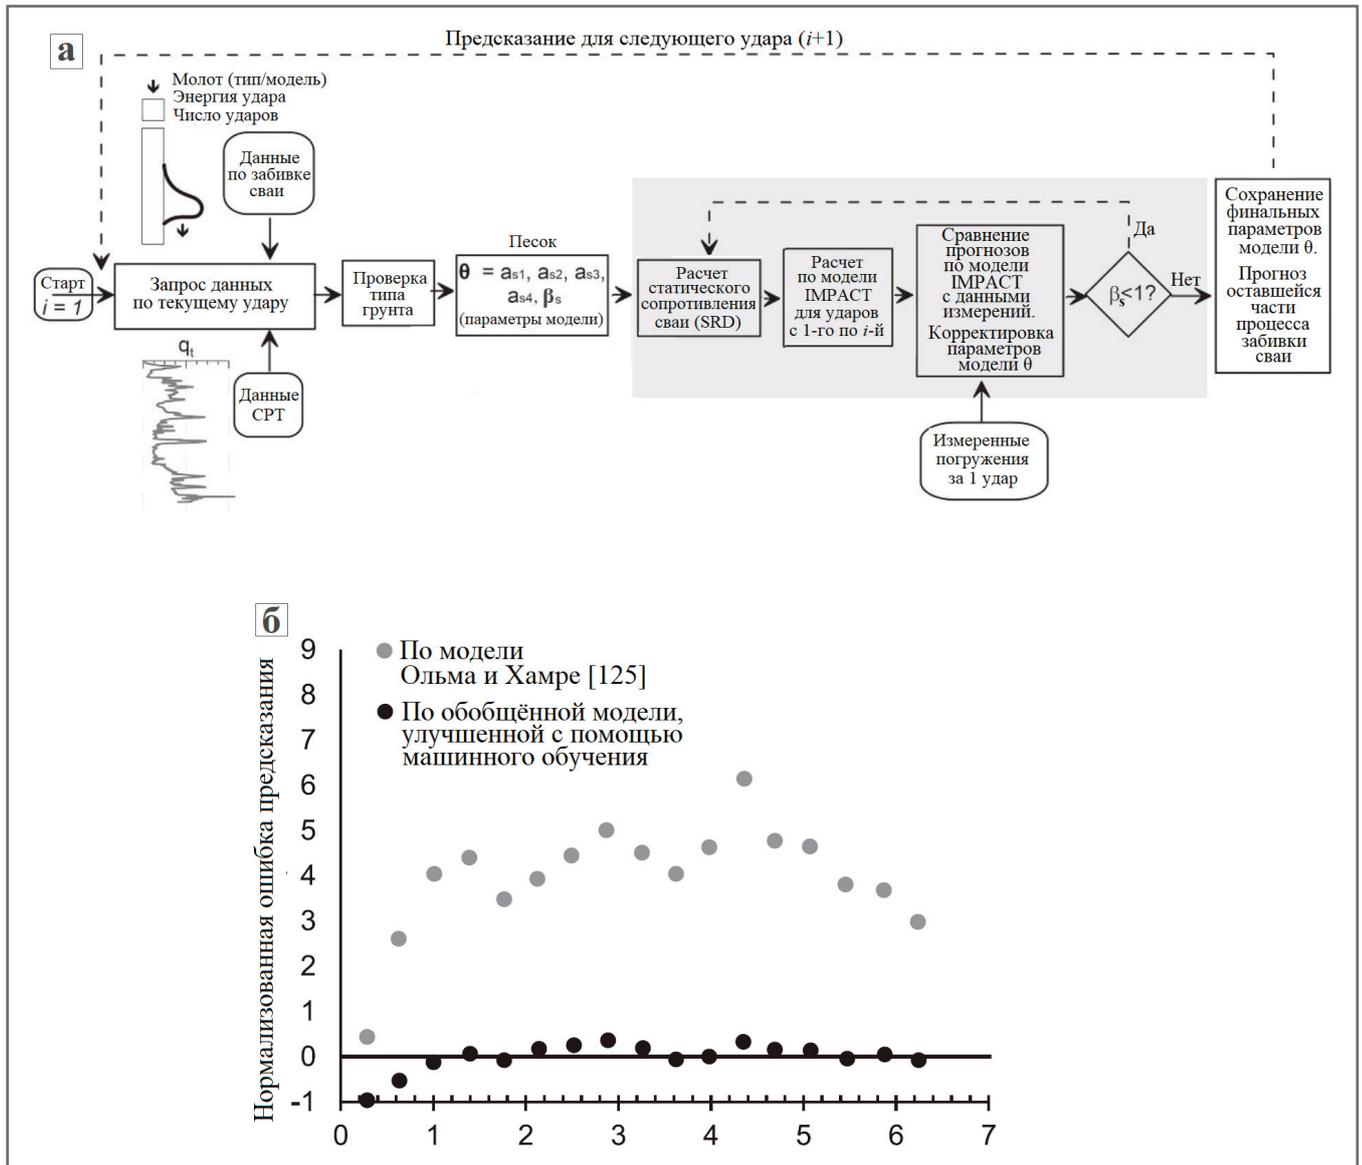
Исторически геотехническое проектирование в значительной степени опиралось на ручные расчеты и анализ, эмпирические методы и упрощенные модели [101]. Хотя эти подходы во многих случаях демонстрировали эффективность, их ограничения при решении сложных современных задач становятся все более очевидными.

В сфере фундаментостроения для прогнозирования несущей способности [102–105 и др.] и осадок [106–110 и др.] фундаментов неглубокого заложения применялись различные алгоритмы машинного обучения.

Исследователи также использовали методы ИИ для уточнения различных аспектов проектирования свай, включая:

- забиваемость свай [111, 112 и др.];
- сопротивление вертикальной нагрузке [113–117 и др.];
- сопротивление боковой нагрузке [118–120 и др.];
- осадки и смещения [121–123 и др.];
- эффекты для группы свай [124 и др.].

Пример усовершенствования метода проектирования с помощью искусственного интеллекта представлен на рисунке 4 – в данном случае для решения задачи забиваемости сваи, то есть среднего значения глубины ее погружения за один удар молота [112]. На рисунке показана ошибка в прогнозах забиваемости сваи при использовании стандартной для отрасли модели, которую разработали Ольм и Хамре [125], и обобщенной модели, улучшенной с помощью машинного обучения, для случая забивки рабочей сваи в переходных грунтах (смешанного состава) на шельфе. Следует отметить, что ключевым компонентом структуры МО была модель на основе волнового уравнения под названием IMPACT, которая описывает, как энергия удара молота распространяется вдоль сваи и взаимодействует с грунтом, причем ее внутренние параметры не изменялись в процессе обучения. Получившаяся в итоге обновленная обобщенная модель продемонстрировала значительно более высокую точность по сравнению с моделью Ольма и Хамре [125].



**Рис. 4.** Пример решения задачи забиваемости сваи с помощью искусственного интеллекта: а – схема использования обобщенной прогнозной модели, улучшенной с помощью машинного обучения; б – соответствующий график нормализованной ошибки предсказаний для забиваемости тестовой шельфовой сваи, не участвовавшей в обучении модели, по сравнению с результатами, полученными с использованием стандартной для отрасли модели Ольма и Хамре [125] (по вертикально оси – отношение разности между предсказанным и измеренным погружением сваи к измеренному значению). *Буквенные обозначения:*  $\theta = \{a_{s1}, a_{s2}, a_{s3}, a_{s4}, \beta_s\}$  – вектор параметров модели, которые описывают взаимодействие сваи с грунтом при забивке;  $a_{s1} - a_{s4}$  – сопротивление грунта в соответствующих слоях вдоль ствола (shaft, отсюда нижний индекс s) сваи;  $\beta_s$  – коэффициент, задающий распределение бокового сопротивления вдоль ствола сваи, то есть определяющий наклон и форму кривой бокового сопротивления вдоль ствола (если  $\beta_s < 1$  – эта кривая вогнутая, пологая, сопротивление увеличивается с глубиной замедленно;  $\beta_s = 1$  – кривая линейная, сопротивление растет с глубиной равномерно;  $\beta_s > 1$  – кривая выпуклая, крутая, сопротивление увеличивается с глубиной ускоренно)

Подобный подход не ограничивался рассмотренной задачей. Он успешно применялся также для прогнозирования параметров прокладки трубопровода методом продавливания (прокола) [126].

Еще одно популярное направление использования искусственного интеллекта – проектирование устойчивости склонов [127, 128]. В публикациях основное внимание уделяется исследованию механизмов разрушения склонов, оптимизации повышения их устойчивости и оценке коэффициента (запаса) устойчивости [129–131], прогнозированию времени разрушения [100], про-

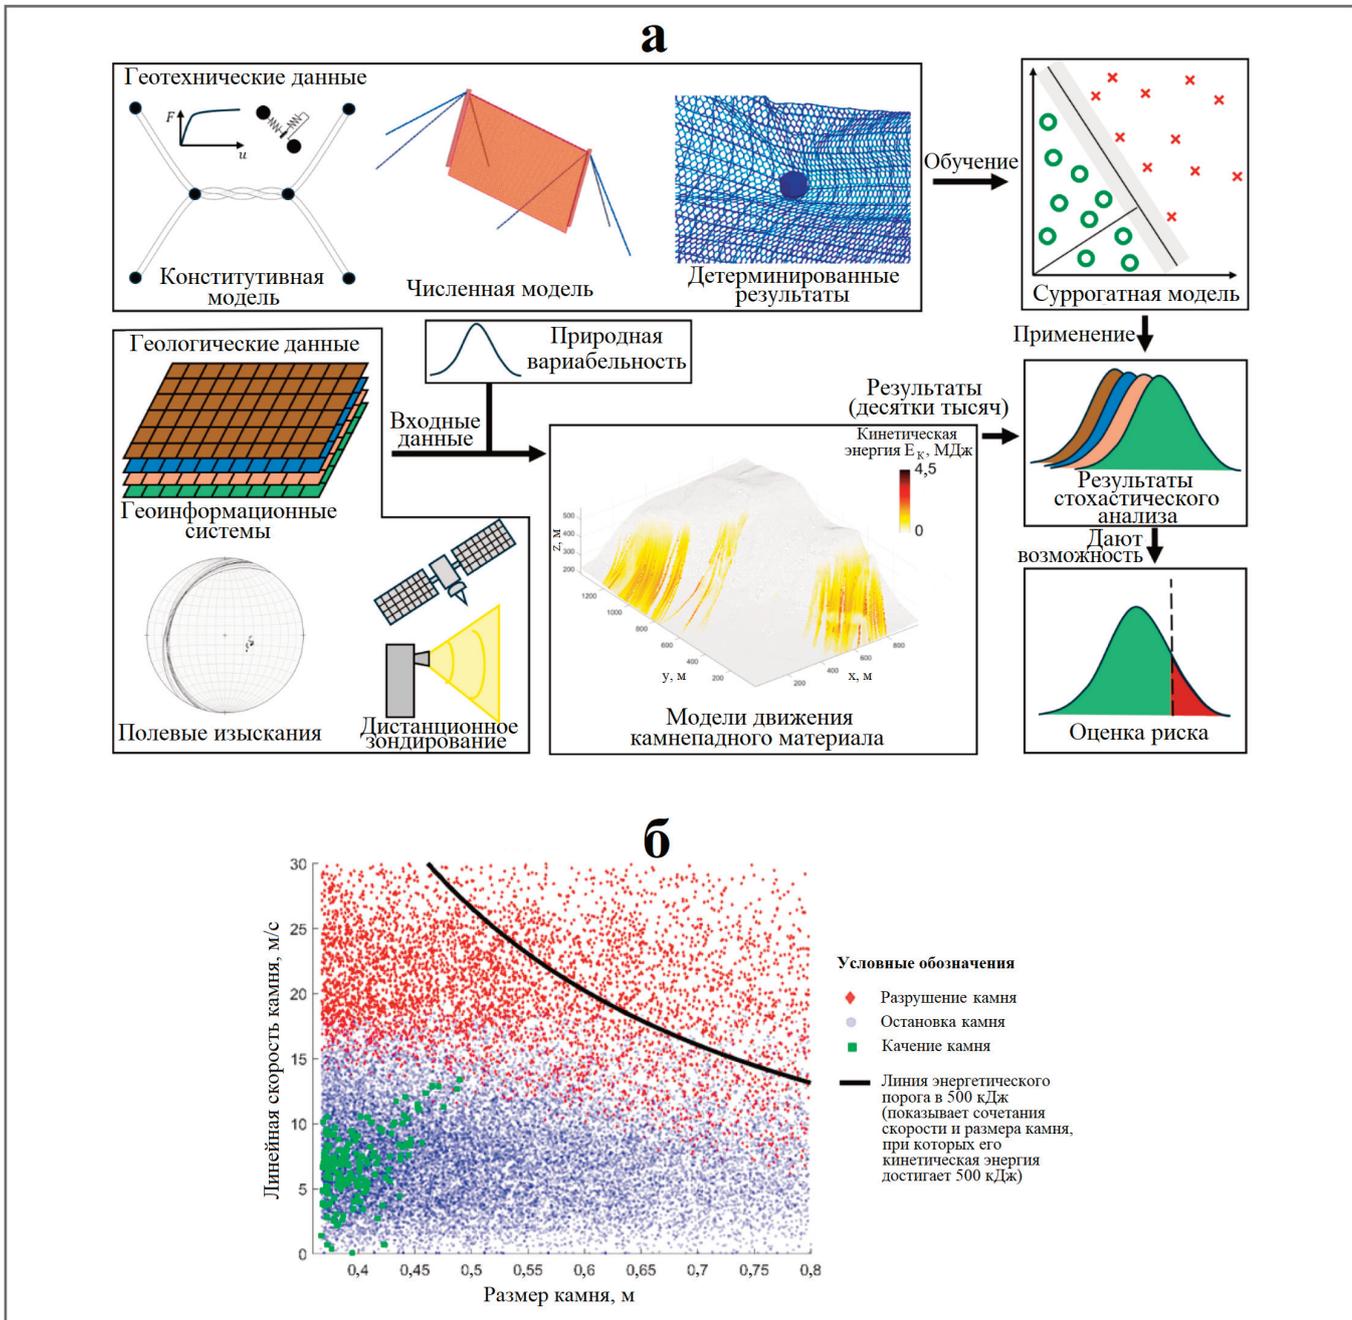
странственно-временному картированию оползневой опасности [132], а также разработке суррогатных (упрощенных аппроксимационных) моделей, основанных на данных [133].

Недавние работы также посвящены разработке стохастических методов, усиленных алгоритмами машинного обучения [32, 134, 135]. Новым направлением исследований в этой области является объединение методов МО и технологий дистанционного зондирования, например спутниковой интерферометрической радиолокации с синтезированной апертурой (Interferomet-

ric Synthetic Aperture Radar, InSAR), для прогнозирования аномального поведения, указывающего на возможное начало разрушения склона [136, 137 и др.].

Популярные области применения в геотехническом строительстве в первую очередь связаны с тоннелестроением, где наиболее распространенными направлениями являются:

- прогнозирование эффективности работы тоннелепроходческого комплекса (ТПК);
- прогнозирование осадок, вызванных проходкой тоннелей;



**Рис. 5.** Использование суррогатных моделей на основе искусственного интеллекта для задачи снижения риска камнепадов: а – блок-схема их применения для достижения точности передовых численных моделей при уровне эффективности, необходимом для крупномасштабного территориального планирования; б – пример результатов работы суррогатной модели относительно стандартного порога энергии в 500 кДж [154]

- оценка и прогнозирование геологических условий впереди забоя;
- оптимизация конструкции ротора (режущей части) ТПК.

Другие области исследований включают: прогнозирование повреждений зданий, вызванных строительством тоннеля [138, 139], автоматизацию работы ТПК [140], оценку состояния тоннелей [141–143], обнаружение аномалий [144, 145 и др.], измерение геометрических параметров и расположения конструктивных элементов тоннеля [146 и др.], оценку устойчивости тоннелей к деформациям и повреждениям [147 и др.],

выявление дефектов конструкций тоннеля [148 и др.], устойчивость забоя тоннеля [149 и др.], прогнозирование горных ударов в тоннеле (внезапного обрушения, сдвижения или выброса грунтов под действием горного давления) [150 и др.], интеллектуальное информационное моделирование зданий и сооружений [151 и др.].

И наконец, искусственный интеллект может использоваться для объединения различных дисциплин и обеспечения применения передовых численных моделей в процедурах территориального планирования регионального масштаба

[152]. Это может быть достигнуто с помощью суррогатных (упрощенных аппроксимационных) моделей [153, 154 и др.], которые воспроизводят результаты более сложных и требующих больших вычислительных затрат моделей при значительно меньших издержках. Примером является их использование для моделирования снижения риска камнепадов (рис. 5), когда оценка этого риска на региональном уровне выполняется геологами с помощью таких инструментов, как геоинформационные системы (ГИС), полевые изыскания и дистанционное зондирование, чтобы

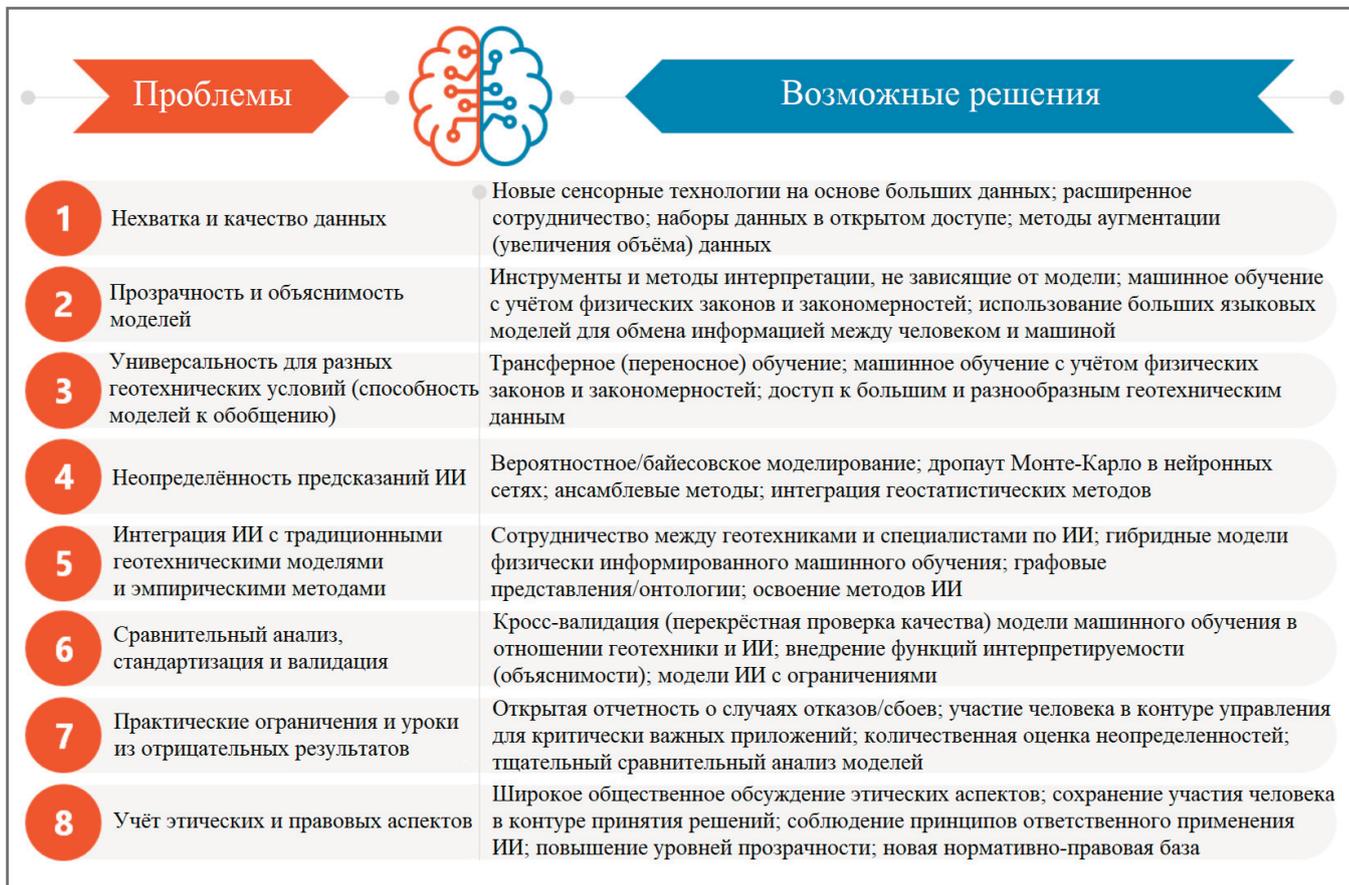


Рис. 6. Основные проблемы применения искусственного интеллекта в геотехнике и их возможные решения

предоставить информацию для моделей движения камнепадного материала [155]. На этом этапе для учета неопределенности измерений и природной вариабельности используется стохастический анализ, что приводит к сотням тысяч прогнозов модели (вычислительных экспериментов), для которых применение стандартных численных процедур было бы неосуществимым.

### ОСНОВНЫЕ ПРОБЛЕМЫ ПРИМЕНЕНИЯ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ГЕОТЕХНИКЕ ▶

На рисунке 6 показаны ключевые проблемы, препятствующие широкому внедрению искусственного интеллекта в геотехнику. Общее для них связано с тем, как методы использования ИИ в геотехнике вписываются в более широкий контекст инженерного освоения подземного пространства. Несмотря на то что существуют возможности для обмена данными и моделями с целью получения более целостного представления о подземной среде, для создания стандартизированной системы такого обмена требуются общие формализованные способы представления и структурирования знаний (онтологии) и со-

вместимость данных. Далее эти проблемы и возможные пути их решения рассматриваются подробнее.

#### Проблема 1: нехватка и качество данных ▶

Все процессы, основанные на данных, зависят от размера и качества обучающей выборки. Поэтому одним из существенных препятствий для широкого применения ИИ в геотехнике является нехватка высококачественных, аннотированных и разнообразных данных. Наборы геотехнической информации требуют тщательного аннотирования, в ходе которого специалисты в соответствующей области присваивают данным «метки» с точными и подробными сведениями о свойствах грунтов, геологических особенностях и геотехнических параметрах, а также комментариями по процедурам испытаний.

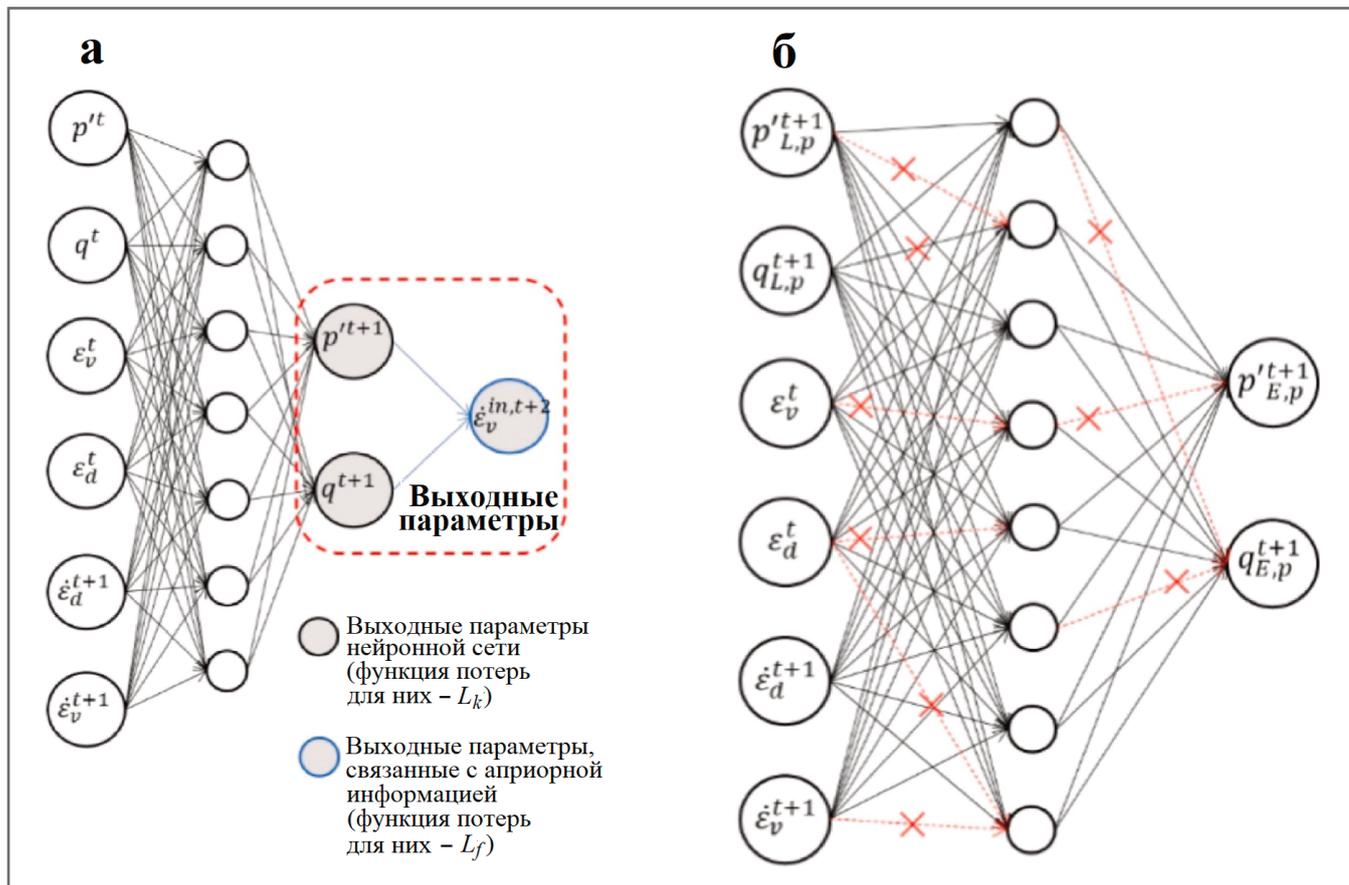
Достоверно установлено, что ограниченная доступность данных оказывает существенное влияние на машинное обучение [156], повышая риск неточностей, слабой способности к обобщению и, в крайних случаях, ложных прогнозов, возникающих из-за переобучения.

Имеется настоятельная необходимость в установлении единых стандар-

тов оценки качества геотехнических данных с учетом различий в надежности испытаний, связанных с человеческим фактором, методами тестирования или используемыми приборами.

Недавно были предложены структурированные подходы к оценке качества данных при геотехническом мониторинге [157 и др.] – и стандарты обмена данными, такие как AGS и DIGGS, снова актуальны. В условиях недостатка данных разработчики моделей часто прибегают к вероятностным суррогатным моделям [9], к использованию аугментации (увеличения объема) данных с учетом специфики предметной области или к трансферному обучению (при котором модель, обученная для одной задачи, повторно используется для решения другой, связанной с первой).

Перспективное направление для решения рассматриваемой проблемы – объединение обученных моделей разных заинтересованных сторон, которое позволит преодолеть трудности, связанные с обменом данными в геотехническом сообществе. Обычно такой подход предполагает обучение общей модели на разных децентрализованных наборах данных, хранящихся у разных участников. При этом каждый владелец



**Рис. 7.** Схема моделирования, принятая в работе Чжана и др. [163]: а – архитектура, показывающая входные параметры модели, а также взаимодействие между выходными параметрами нейронной сети и ограничениями, обусловленными законами физики (обведено красным), при использовании в данном примере инкрементального нелинейного моделирования; б – пример отключения части связей нейронной сети при дропауте по методу Монте-Карло (отключенные связи показаны красным)

данных обучает модель локально, а обмен осуществляется только обновлениями модели (но не исходными данными). Для координации обучения на разных площадках используется единый набор параметров и гиперпараметров. Данная стратегия также соответствует принципам операционных процессов машинного обучения (Machine Learning Operations, MLOps), которые обеспечивают отслеживаемое, воспроизводимое и масштабируемое управление моделями.

Проблему нехватки данных помогут смягчить и современные методы их сбора, например передовые сенсорные технологии (такие как распределенные волоконно-оптические датчики [158], беспроводные ячеистые сети [157]) и дистанционное зондирование (например, спутниковая интерферометрическая радиолокация с синтезированной апертурой (InSAR) [159]).

Также можно повысить доступность разнообразной информации путем совместных усилий по обмену анонимизированными наборами данных и по установлению стандартизированных форматов данных. Примером может по-

служить база данных испытаний свай на нагрузку DINGO [160].

Кроме того, для расширения существующих наборов данных могут применяться методы науки о данных, такие как аугментация данных, трансферное обучение и генерация синтетических данных. Это позволит моделям ИИ лучше обобщать информацию и эффективно работать при различных геотехнических сценариях, несмотря на изначальный недостаток данных.

## Проблема 2. Прозрачность и объяснимость моделей ►

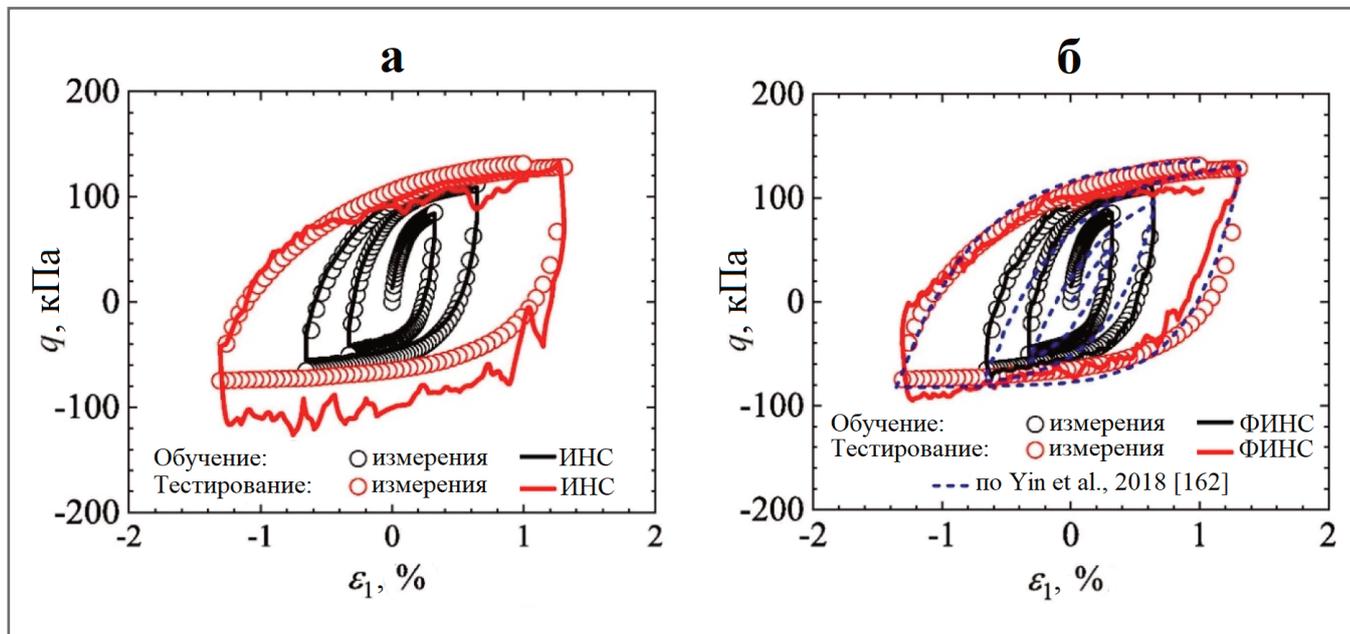
Алгоритмы искусственного интеллекта (в частности, глубокого обучения) часто воспринимаются как «черные ящики», которые практически не позволяют понять лежащие в их основе процессы принятия решений. В геотехнике, где прозрачность и понимание прогнозов моделей имеют решающее значение для обоснованного принятия решений, отсутствие объяснимости является серьезным препятствием.

Для решения этой проблемы требуются новые методы, позволяющие из-

влекать осмысленные сведения из сложных моделей ИИ. Например, для обучения модели на стандартах по геотехническому проектированию с целью проверки соответствия проектных решений нормативным требованиям может использоваться обработка естественного языка.

К дополнительным методам можно отнести: универсальные инструменты интерпретации, не зависящие от модели; анализ чувствительности; механизмы внимания, которые позволяют анализировать результаты работы модели и, как следствие, выявлять наиболее значимые факторы, влияющие на геотехнические прогнозы.

Перспективным направлением также является машинное обучение с учетом физических законов (физически информированное), которое позволяет интегрировать в модели ИИ знания по предметной области, что дает возможность использовать относительные преимущества моделей, основанных на физических законах, и методов, основанных на данных, для повышения как интерпретируемости, так и надежности прогнозов [161].



**Рис. 8.** Сопоставление прогнозов модели с результатами лабораторных испытаний на трехосное сжатие стандартного калибровочного кварцевого песка Тойура (добываемого в районе одноименного города на японском острове Хонсю) при использовании: а – искусственной нейронной сети (ИНС); б – нейронной сети, основанной на априорной информации, то есть физически информированной нейронной сети (ФИНС) [163]. Буквенные обозначения параметров:  $q$  – девиаторное напряжение, или разность между главным/осевым и боковым напряжениями ( $\sigma_1 - \sigma_3$ );  $\varepsilon_1$  – относительная осевая деформация образца

Недавние успехи в создании физически информированных конститутивных моделей [162 и др.] также показывают, что к более достоверным прогнозам может приводить основанное на данных моделирование с ограничениями, обусловленными законами физики (физически ограниченное). Кроме того, может использоваться метод стохастического отключения узлов/нейронной сети (метод дропаута), причем не только в качестве регуляризатора во время обучения, но и для генерации стохастических выборок на этапе вывода с применением дропаута по методу Монте-Карло, иногда называемого просто дропаутом Монте-Карло. Среднее значение предсказаний и их дисперсия, соответственно, отражают наилучшую оценку и эпистемическую (вызванную неполнотой знаний) неопределенность выходных данных модели (рис. 7, 8).

Были предприняты целенаправленные усилия по повышению интерпретируемости моделей машинного обучения. Среди предложенных подходов можно в том числе выделить:

- декомпозицию модели [164], при которой сложные модели разбиваются на более простые и легко понимаемые компоненты;
- извлечение правил [165], когда сложные модели аппроксимируются более простыми моделями, построенными на основе правил типа «если, ...то»;

- оценку важности признаков [166], когда выделяются признаки, оказывающие наибольшее влияние на выходные данные модели, с помощью специальных методов, например технического инструмента для интерпретации моделей машинного обучения под названием SHAP (SHapley Additive exPlanations – «Аддитивные объяснения на основе значений Шепли»), который позволяет оценивать вклад каждого признака в конкретный прогноз модели;
- отчеты по модели [167], включающие документацию по ее разработке, эффективности и предполагаемых случаях применения с полным отслеживанием версий модели и истории разработки с помощью автоматизированных конвейеров полного цикла разработки и эксплуатации моделей машинного обучения (Machine Learning Operations pipelines – MLOps pipelines).

### Проблема 3. Универсальность для разных геотехнических условий (способность моделей к обобщению) ▶

Обобщение моделью закономерностей на основе данных по широкому спектру типов грунтов, геологических формаций и факторов окружающей среды является сложной задачей. Основная трудность заключается в создании моделей, которые не только хорошо работают на основе обучающих данных, но

и сохраняют надежность в случаях применения к новым условиям, по данным для которых не проводилось обучение.

Перспективное решение этой проблемы – использование методов трансферного обучения, когда модели, обученные на данных для одних геотехнических условий, на втором этапе корректируются (настраиваются) для адаптации к различным сценариям. Чжоу с соавторами [28] уже продемонстрировали эффективность таких подходов для определения границ между слоями грунтов: на первом этапе для предварительного обучения модели использовалась общедоступная исходная база данных, а на втором выполнялась ее донастройка на целевой базе данных, относящейся к конкретному участку (рис. 9).

Кроме того, благодаря машинному обучению с учетом физических законов (физически информированному) модели могут учитывать фундаментальные геотехнические механизмы, что обеспечивает надежную экстраполяцию на разные условия [163 и др.].

Решающее значение для повышения способности моделей к обобщению имеет также обеспечение как репрезентативности обучающих наборов данных, так и достаточного их разнообразия.

Преодоление рассматриваемой проблемы позволит создавать более универсальные и надежные модели ИИ, пригодные для широкого применения

на практике в целях решения реальных геотехнических задач.

#### Проблема 4. Неопределенность предсказаний искусственного интеллекта ▶

Оценки неопределенности в геотехнике особенно необходимы из-за высокой цены, которую приходится платить за ошибки. Однако получение таких оценок с помощью моделей искусственного интеллекта остается сложным.

Надежные и научно обоснованные средства учета неопределенности можно получить с помощью вероятностного моделирования, основанного на байесовских методах машинного обучения. В частности, показано, что с моделированием геотехнической неопределенности на фундаментальном уровне можно хорошо справиться с использованием регрессии на основе гауссовского процесса [6, 9 и др.] (рис. 10). Даже для детерминированных моделей ИИ существуют методы оценки эпистемической (обусловленной недостатком знаний) неопределенности. Например, для нейронных сетей одним из наиболее распространенных методов проверки чувствительности выходных данных модели к ее конкретной архитектуре является дропаут по методу Монте-Карло. Имеются и такие популярные подходы, как ансамблевые методы, например бутстрэппинг (выборка с возвращением).

Разработка систем, в которых геостатистические методы интегрированы с моделями искусственного интеллекта, также позволит получить более полное представление о пространственных неопределенностях. Признание наличия и учет неопределенности грунтовых условий в прогнозах ИИ не только повысят доверие к таким геотехническим моделям, но и предоставят геотехникам и лицам, принимающим решения, ценную информацию для обоснованного выбора.

#### Проблема 5. Интеграция искусственного интеллекта с традиционными геотехническими моделями и эмпирическими методами ▶

Несмотря на то что искусственный интеллект способен анализировать большие многомерные наборы геотехнических данных, для обеспечения точности и содержательности интерпретаций решающую роль играет включение профессиональных знаний и понимания контекста.

Не менее значимой задачей является обеспечение соответствия моделей ИИ

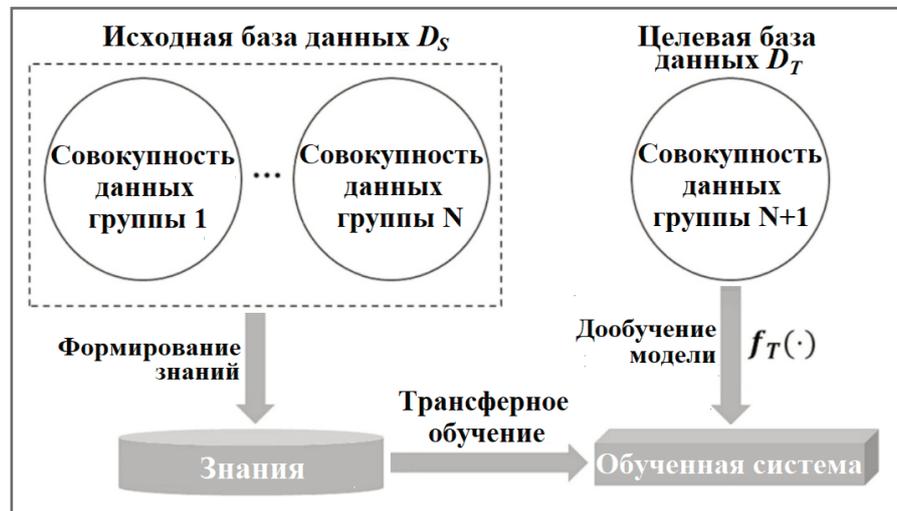


Рис. 9. Схема применения метода трансферного обучения для определения границ между слоями грунтов (по [28]). Буквенное обозначение:  $f_T(\cdot)$  – функция дообучения модели на целевых данных (точка по центру строки в скобках используется вместо ее аргумента, который здесь не конкретизирован)

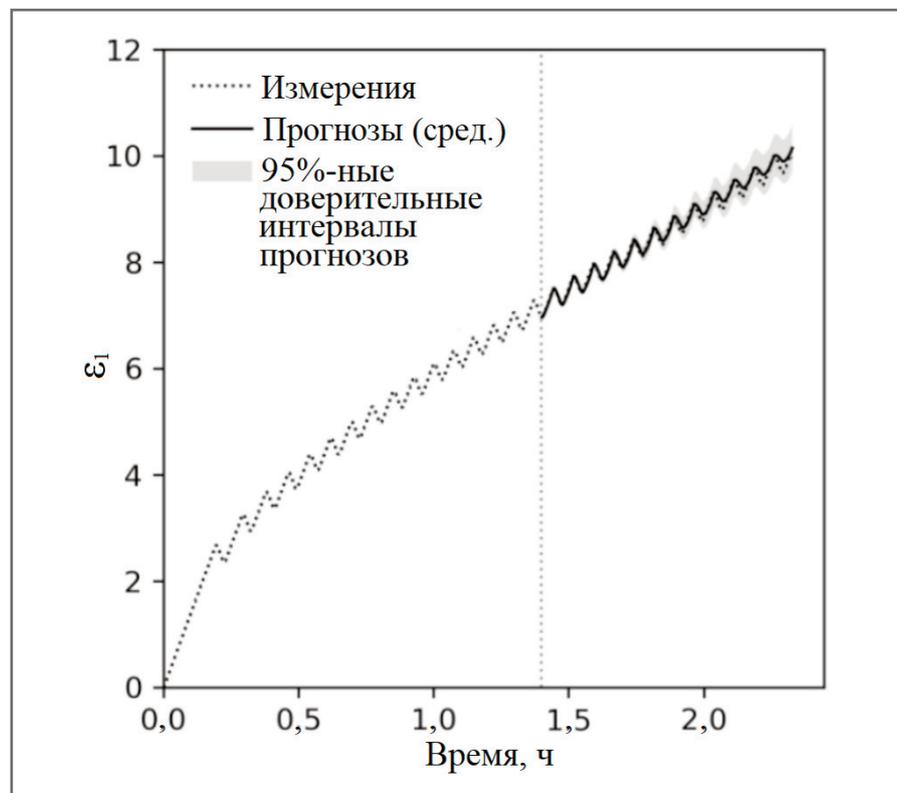


Рис. 10. Сопоставление относительных осевых деформаций ( $\epsilon_1$ ), измеренных при циклическом трехосном сжатии в недренированных условиях и спрогнозированных с помощью модели регрессии на основе гауссовского процесса с ковариационной функцией  $LE+SE*PER$ , где SE, LE и PER – экспоненциальная, квадратичная, линейная и периодическая компоненты ковариационной функции соответственно [9]

общепризнанным в геотехнике принципам, нормативно-правовым документам и теориям. Одним из перспективных направлений решения этой задачи может стать автоматизированная проверка соответствия проектных геотехнических решений, основанных на данных, требованиям нормативных документов [168 и др.].

Также необходим междисциплинарный подход, предполагающий сотрудничество между специалистами в сферах искусственного интеллекта и геотехники.

Сильные стороны методов, основанных на данных и базирующихся на знаниях физических законов, могут сочетаться в гибридных моделях, дающих более интерпретируемые (объяснимые)

и заслуживающие доверия результаты. Кроме того, можно явно задавать и объединять профессиональные знания в моделях ИИ с помощью графов знаний и онтологий.

В долгосрочной перспективе эффективное решение рассматриваемой проблемы, вероятно, потребует повышения квалификации современных геотехников, чтобы они могли анализировать не только данные, но и модели, основанные на этих данных. Крайне важно, чтобы решения на основе искусственного интеллекта вырабатывались в русле профессионального мышления и необходимых геотехнических знаний.

### Проблема 6. Сравнительный анализ, стандартизация и валидация ▶

Вероятность возникновения переобучения и, как следствие, выдачи ложных прогнозов для алгоритмов искусственного интеллекта существенно выше, чем для традиционных проектных моделей, что объясняется их сильно нелинейными составляющими. В отличие от традиционных численных моделей, результаты работы которых проверяются с помощью упрощенных аналитических моделей в целях подтверждения их обоснованности, для алгоритмов ИИ может не быть подобного механизма валидации.

Валидация моделей ИИ в геотехнике обычно проводится с использованием  $k$ -кратной перекрестной проверки (по  $k$  подвыборкам) или с помощью тестирования на отложенной выборке, не участвовавшей в обучении. При этом для оценки способности к обобщению применяются такие показатели эффективности, как среднее квадратическое отклонение, коэффициент детерминации  $R^2$ , средняя абсолютная ошибка, а также, все чаще, границы неопределенности (интервал возможной ошибки модели). Однако специфические для предметной области проблемы (например, автокорреляция геопространственных данных для участка изысканий) требуют особенно тщательной разработки методики валидации.

Внедрение искусственного интеллекта в геотехнику требует баланса между точностью, временем обучения и вычислительными ресурсами, которые также сильно зависят от настройки гиперпараметров. Основные параметры (например, скорость обучения, глубина архитектуры, параметры, отвечающие за регуляризацию) требуют систематической настройки, часто с использованием поиска по сетке гиперпараметров

(перебора их фиксированных комбинаций) или с помощью байесовского поиска (с применением байесовской вероятностной модели).

Простые модели (например, на основе деревьев решений или линейные) быстро обучаются даже на стандартных ноутбуках, тогда как модели глубокого обучения (например, для 3D данных или задач, интегрирующих в модель физические законы) могут требовать часов или дней работы даже с помощью высокопроизводительных графических процессоров (GPU). Процесс вывода прогнозов обычно проходит быстро, однако обучение может быть дорогостоящим для небольших организаций, если не использовать предварительно обученные модели или облачные сервисы.

Существующие геотехнические модели (например, модифицированная модель «Кэм-кэй» – Sam Clay) являются по своей сути детерминированными, давая согласованные результаты независимо от конкретных данных, использованных для обучения. Геотехники могут опираться на устоявшиеся принципы и математические формулы, лежащие в основе этих моделей, чтобы с высокой степенью уверенности прогнозировать поведение геотехнических материалов. Такая предсказуемость позволяет практикам понимать сильные и слабые стороны, а также области применения конкретной комплексной геомеханической (конститутивной) модели, что делает возможной ее эффективную валидацию путем сравнения ее прогнозов с экспериментальными или полевыми данными. Устойчивость и согласованность, присущие конститутивным моделям, являются ключевыми факторами их непреходящей ценности в геотехнике.

Напротив, модели ИИ, будучи основанными на данных и зависящими от разнообразных наборов данных, использованных при обучении, могут демонстрировать вариативность результатов, что затрудняет создание универсально надежной системы предсказаний.

Для решения этой проблемы необходимо создать основу для перекрестной проверки между выходными данными моделей ИИ и результатами использования традиционных геотехнических методов. Такой подход может включать применение искусственного интеллекта в качестве дополнительного инструмента, а не отдельного решения, что позволит постоянно сравнивать результаты с устоявшимися геотехническими знаниями.

Дополнительно поспособствовать выявлению потенциальных расхождений и

повысить доверие к результатам работы искусственного интеллекта в контексте геотехнической практики может интеграция в модели ИИ возможностей интерпретируемости, например алгоритмов, обеспечивающих объяснимость.

Еще одним эффективным решением являются ограничения моделей ИИ, обусловленные известными и общепринятыми теоретическими или эмпирическими концепциями.

### Проблема 7. Практические ограничения и уроки из отрицательных результатов ▶

В опубликованных работах по применению искусственного интеллекта в геотехнике результаты исследований редко относят к неуспешным, однако в публикациях более широкого спектра фиксируются повторяющиеся типы неудач, которые явно следует признать. К ним относятся:

- переобучение на малых или однородных наборах данных;
- очень сильное снижение эффективности работы модели при изменении области ее применения (в случаях новых типов грунтов, траекторий напряжений или измерительных систем);
- утечка данных (например, попадание информации из тестовой или валидационной части данных в процесс обучения модели) при перекрестной валидации;
- ошибочно помеченные или неточно заданные цели обучения (типы выходных данных);
- галлюцинации или ложные рассуждения виртуальных помощников, использующих большие языковые модели;
- игнорирование важных для модели физических законов, приводящее к нереалистичным экстраполяциям [3, 9, 169–172].

Тенденция к публикации только положительных итогов затрудняет формирование полного и точного представления об эффективности работы моделей, что говорит о важности открытых и прозрачных сообщений о негативных результатах.

Таким образом, целесообразно выделить области, для которых на сегодняшний день могут быть предпочтительнее традиционные подходы:

1) принятие проектных решений, регулируемых нормативно-правовыми документами и/или аналитическими методами с использованием надежно подтвержденных запасов прочности;

2) проекты на основе крайне ограниченных или гетерогенных данных, когда

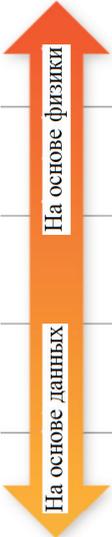
Тип модели	Описание
 <p>5 Физические модели с обновлением на основе машинного обучения</p>	Модель основана на физических законах; машинное обучение используется только для обновления входных параметров для лучшей согласованности с наблюдениями
<p>4 Машинное обучение с ограничениями, основанными на законах физики (физически ограниченное)</p>	Физические законы встроены в архитектуру модели, поэтому физические ограничения соблюдаются строго
<p>3 Машинное обучение с учётом физических законов (физически информированное)</p>	Архитектура модели напоминает архитектуру традиционной модели, основанной на данных, за исключением того, что функции потерь теперь содержат слагаемые, основанные на физических законах; физические ограничения применяются в незначительной степени
<p>2 Предобученная модель машинного обучения</p>	Модель предварительно обучена на данных, сгенерированных физической моделью. Последующее обучение проводится без дополнительных ограничений
<p>1 Машинное обучение, полностью основанное на данных</p>	Нет ограничений, основанных на физических законах. Прогнозы модели строятся исключительно на основе обучающих данных

Рис. 11. Различные уровни применения ограничений, обусловленных законами физики, в моделях машинного обучения

проведение строгой валидации модели невозможно;

3) отчетная документация, подаваемая в регулирующие органы, которая требует полной прослеживаемости параметров;

4) экстраполяция и/или применение модели за пределами диапазона ее обучения (например, при новых геологических условиях или других схемах нагружения) в случае отсутствия встроенных в модель знаний о физических законах;

5) критически важные для безопасности решения в режиме реального времени, если границы неопределенности недоступны или не отслеживаются.

### Проблема 8. Учет этических и правовых аспектов ▶

Модели искусственного интеллекта, которые основаны исключительно на данных, особенно подвержены непреднамеренному воспроизведению искажений, которые присутствовали в обучающих данных. Также возможно, что ключевым вопросом в будущих судебных разбирательствах станет тема ответственности и подотчетности, что сыграет большую роль в формировании правового регулирования применения ИИ в геотехнике. Кажется крайне важным, чтобы геотехническое сообщество быстро и проактивно включилось в дискуссии по этическим аспектам, связанным с использованием технологий ИИ в преподавании, научных исследованиях и промышленной практике в отрасли.

Прежде всего следует отметить, что применение искусственного интеллекта

в геотехнике в обозримом будущем будет подразумевать участие человека в цикле принятия решений, то есть ИИ будет использоваться как инструмент, а не как полностью автономный агент.

Тем не менее потребуются руководящие принципы, определяющие ответственные подходы к применению искусственного интеллекта. Возможно также, что использование ИИ потребует значительно большей прозрачности, чтобы обеспечить интерпретируемость (объяснимость) прогнозов и удовлетворительный уровень подотчетности. Развивающееся правовое регулирование в этом направлении, вероятно, приведет к разработке нормативно-правовых документов и методических руководств, которые позволят сбалансировать технологические достижения с этическими соображениями.

### СОВРЕМЕННЫЕ ТЕХНОЛОГИЧЕСКИЕ ВОЗМОЖНОСТИ И ПЕРСПЕКТИВЫ ▶

#### Моделирование на основе искусственного интеллекта с ограничениями, связанными с законами физики ▶

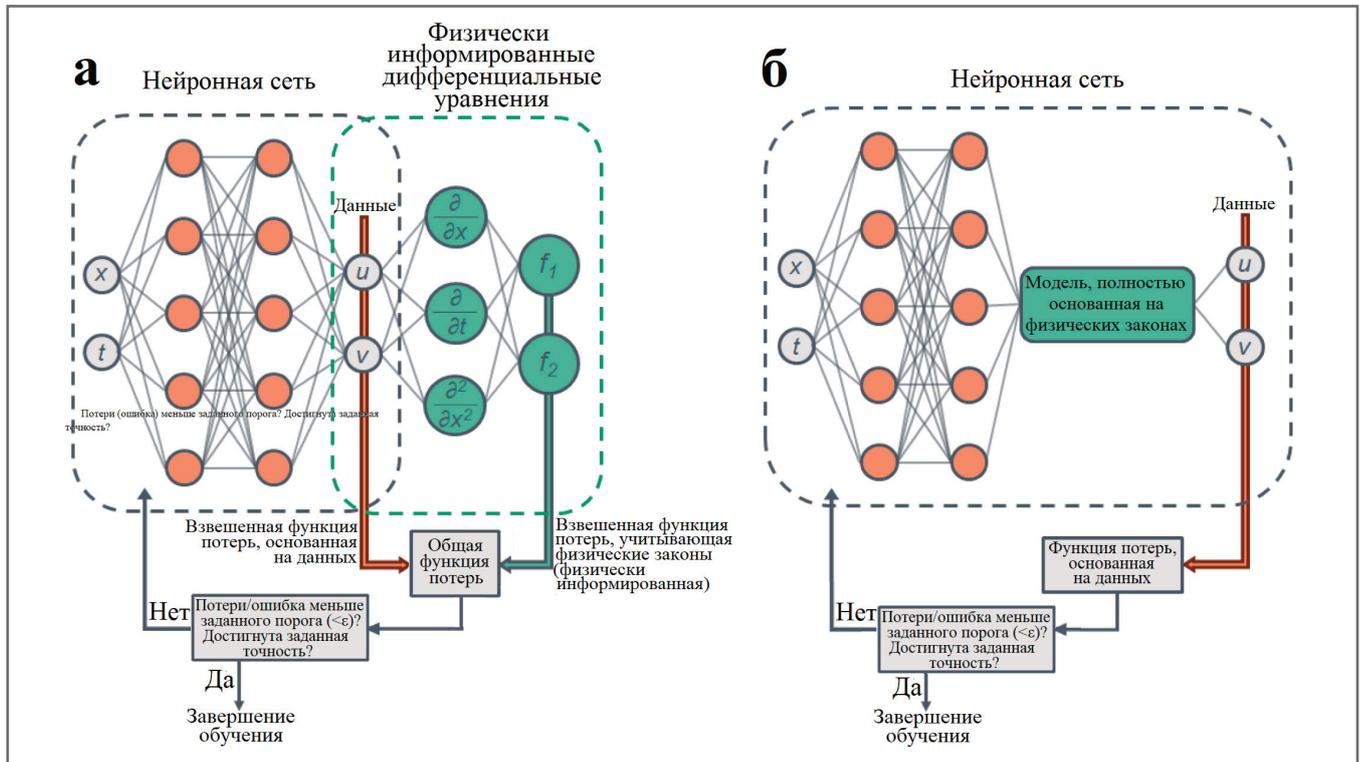
Создание моделей ИИ с ограничениями, обусловленными законами физики (физически ограниченными), было определено как многообещающее решение многих упомянутых выше проблем и, следовательно, стало считаться одним из приоритетных путей. На рисунке 11 представлены различные уровни, на ко-

торых модели машинного обучения могут быть ограничены физическими принципами, – от полностью основанных на данных (без ограничений) до полностью основанных на физических моделях (но с обновлениями через машинное обучение). Например, на уровнях 3 и 4 физические ограничения могут вводиться соответственно в небольшой степени или строго. Это иллюстрирует рисунок 12 на примере нейронной сети.

Также стоит отметить, что последние достижения в области динамических моделей, основанных на данных, показали возможность решения с их помощью сложных физических задач при ограниченном объеме данных измерений [173 и др.].

Таким образом, степень, в которой модель должна быть ограничена физическими законами, будет зависеть от нескольких факторов, включая объем и качество обучающих данных, сложность моделируемой задачи, риск появления ложных прогнозов и степень признания соответствующих физических законов в геотехническом сообществе.

Недавние работы продемонстрировали применимость нейронных сетей, обучаемых с учетом физических законов (физически информированных) для решения ключевых геотехнических задач, таких как трехмерное обобщение теории консолидации Терцаги [174], прогнозирование несущей способности буровых свай [175], оценка фильтрации через противотрационные завесы [176] и др. Эти работы сообщают о точности в пределах  $\pm 5\%$  по сравнению с



**Рис. 12.** Схематическое представление: а – модели машинного обучения, учитывающей физические законы, в которой физические ограничения применяются в незначительной степени (физически информированной модели); б – модели машинного обучения со строгими ограничениями, обусловленными физическими законами (физически ограниченной модели). *Примечание к рисунку «б»:* функция потерь, основанная на физических законах, встроена в модель и жестко контролирует обучение на каждом шаге в соответствии с физическими ограничениями и не зависит от проверки на выходе, поэтому в конце обучения проверяется только функция потерь, основанная на данных

**Таблица 1. Примеры уровней точности для геотехники**

Уровень точности/достоверности		Описание
Самый высокий	1	Высококачественные полевые измерения
	2	Высококачественные лабораторные измерения
	3	3D численный анализ (моделирование)
	4	2D численный анализ (моделирование)
	5	1D численный анализ (моделирование)
Самый низкий	6	Приблизительные эмпирические оценки

эталонными численными решениями проверенных моделей при многократном ускорении расчетов.

**Моделирование с использованием разных уровней достоверности (многоуровневое) ►**

Основная идея многоуровневого моделирования заключается в использовании:

1) наборов данных с низкими уровнями достоверности, таких как упрощенные аналитические зависимости или численные модели, которым может до некоторой степени не хватать

точности, но которые позволяют сформировать большие обучающие выборки при минимальных вычислительных затратах;

2) наборов данных с высокими уровнями достоверности, таких как результаты полевых и/или лабораторных измерений, обладающих наибольшей точностью, но недостаточных для обучения ИИ из-за их, как правило, ограниченных объемов и высокой стоимости получения (таблица 1).

Также следует отметить, что в рамках этой общей классификации уровней точности/достоверности есть дополнительные подклассы (например, подклассы

внутри первого уровня точности выделяют в зависимости от типа испытания и типа материала). Многоуровневые модели могут принимать различные формы, но обычно они включают обучение одной модели на данных низкой достоверности и привлечение другой модели для изучения взаимосвязей между наборами данных низкого и высокого уровней точности, как показано на рисунке 13.

Хотя на рисунке 13 для наглядности представлен всего лишь двухэтапный процесс, в современных методах многоуровневого моделирования часто используются более сложные взаимодействия

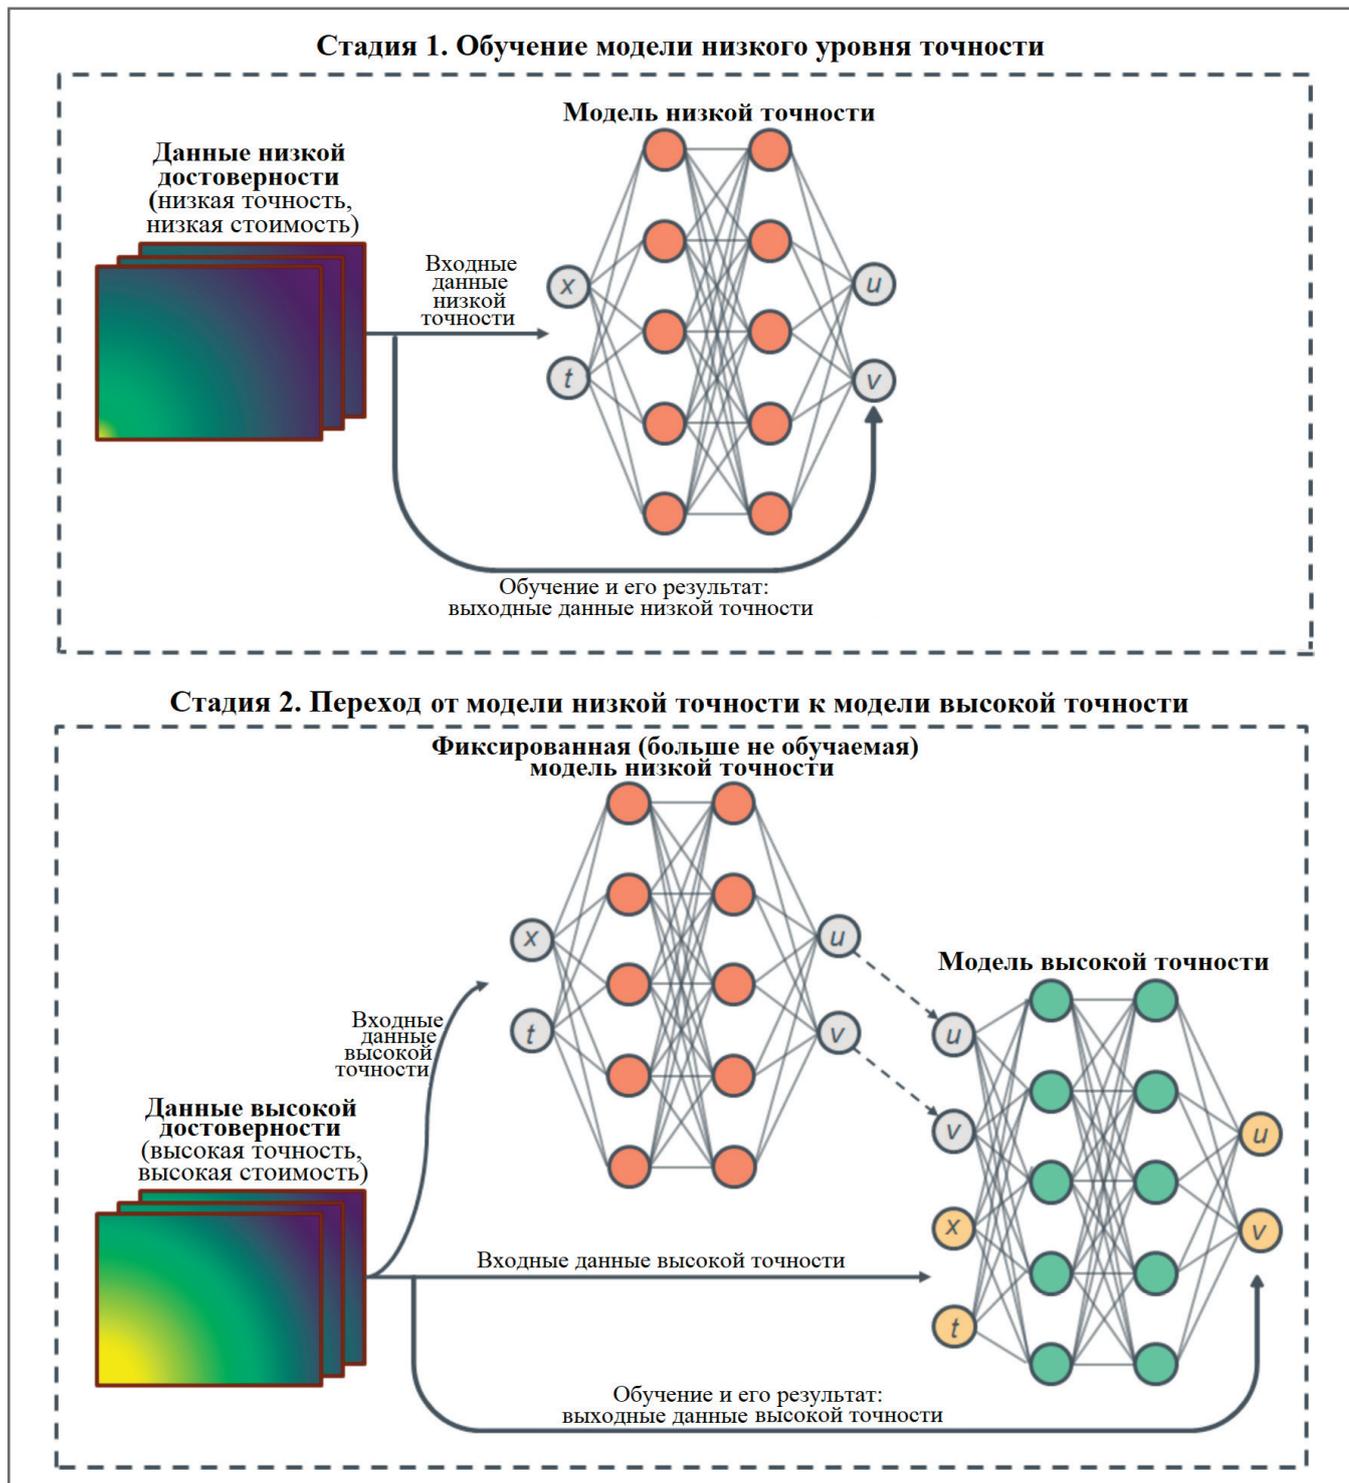


Рис. 13. Схема упрощенного примера последовательного моделирования с разными уровнями точности/достоверности (двухэтапного)

ствия. Распространены следующие способы усовершенствования:

1) совместное обучение (когда две модели или более обучаются параллельно, обмениваясь информацией о своих предсказаниях, чтобы улучшить свою обобщающую способность и общую эффективность) или иерархическое обучение на остаточных ошибках/поправках (когда модель высокой точности рекурсивно обучается на корректировках выходных данных модели низкой точности, постепенно повышая точность через иерархическую последовательность корректировок) [177 и др.];

2) методы байесовского слияния данных (с последовательным обновлением вероятностных оценок о параметрах модели по мере поступления новых данных на основе теоремы Байеса), учитывающие неопределенность моделей низкой и высокой точности при формировании комбинированного предсказания [178 и др.];

3) глубокие нейросети (архитектура глубокого обучения) для многоуровневого моделирования, которые одновременно для всех уровней достоверности обучаются преобразованиям выходных данных модели низкой точности в высокоточные предсказания в рамках одной сети [179 и др.];

4) итеративные петли обратной связи, когда этапы обучения проходятся пошагово с многократными повторениями и обратной связью на каждом

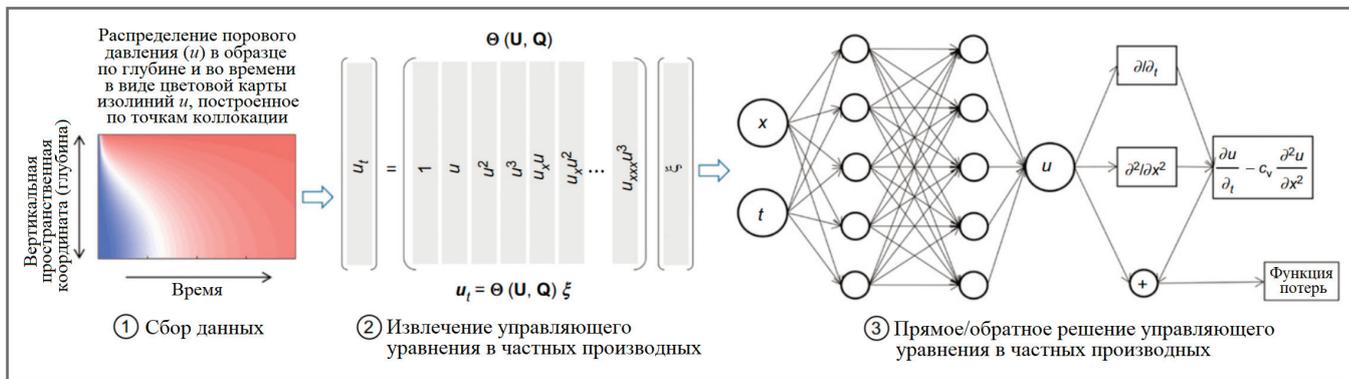


Рис. 14. Пример извлечения закономерностей, соответствующих теории консолидации Терцаги, на основе данных с использованием физически информированных нейронных сетей [186]

этапе, для повышения согласованности моделей и калибровки границ неопределенности [180 и др.].

Эти передовые подходы обеспечивают более надежную способность моделей к обобщению и количественную оценку уверенности в предсказаниях при решении сложных геотехнических задач. Направления дальнейшего развития этой области могут включать:

- усовершенствование методов для согласованного объединения моделей разной точности;
- оптимизацию их интеграции с помощью алгоритмов машинного обучения;
- разработку адаптивных стратегий, динамически распределяющих вычислительные ресурсы в зависимости от требований конкретной задачи.

Недавние достижения в области геотехники включают:

- многоуровневую нейронную сеть DeerONet, которая объединяет процессно-ориентированные модели на основе метода конечных элементов (с низкой достоверностью) с разреженными данными полевого мониторинга (с высокой достоверностью) для прогнозирования осадок при механизированной проходке тоннелей в реальном времени [179];
- многомасштабную генеративно-сопоставительную нейронную сеть (Generative Adversarial Network, GAN), которая строит разрезы подповерхностной среды по смешанным наборам данных изысканий с низкой и высокой точностью [181];
- физически информированные многоуровневые остаточные нейронные сети, которые используют механистические модели (основанные на законах механики) и лабораторные данные в ограниченном объеме для моделирования гидромеханических реакций грунтов и их механического поведения, описываемого конститутивными моделями [182–184].

### Извлечение знаний ▶

Извлечение знаний на основе данных откроет большие перспективы для трансформации геотехники. Двумя наиболее распространенными методами в этой сфере являются динамическое моделирование на основе данных [185] и машинное обучение с учетом физических закономерностей (физически информированное).

Например, Чжан с коллегами [186] недавно продемонстрировали способность физически информированного машинного обучения самостоятельно извлекать закономерности, соответствующие теории консолидации Терцаги, непосредственно на основе данных, полученных при испытаниях на консолидацию. На рисунке 14 представлена схема процесса обратного моделирования с помощью физически информированной нейронной сети, где сначала на основе данных извлекается управляющее уравнение в частных производных (описывающее поведение процесса) а затем оно решается для определения неизвестных параметров (в данном случае коэффициентов консолидации). Этот процесс является итеративным и использует физически информированную функцию потерь, что позволяет минимизировать ошибку предсказания во всей исследуемой пространственно-временной области.

По мере расширения доступа к геотехническим данным будут открываться все новые возможности извлечения новых представлений, принципов и механических закономерностей из сложных геотехнических процессов, которые в настоящее время описываются только эмпирическими методами.

### Создание цифровых двойников ▶

Согласованная интеграция цифровых моделей с информацией о рабочих про-

цессах и поведении физических систем позволяет создавать цифровые копии реальных объектов в реальном времени (цифровых двойников) для возможности моделирования и прогнозирования разных сценариев. Цифровой двойник постоянно обновляется, сохраняя актуальность, на основе данных, получаемых от физических датчиков, что позволяет проводить диагностику состояния объекта и его виртуальный контроль. Алгоритмы машинного обучения обеспечивают автономные обновления и прогнозы, делая создание цифровых двойников важнейшим подходом для будущей роботизации и автоматизации работ на строительных площадках. В геотехнике это направление будет развиваться в сторону интегрированных цифровых двойников, объединяющих модели грунтовых оснований, фундаментов, инженерных сетей и сооружений, что позволит формировать целостное понимание взаимодействий и взаимозависимостей в общей системе (рис. 15).

В последнее время начинается работа по внедрению в практику цифровых двойников для подземных и геотехнических систем. Связанные с этим исследования в области гражданской инфраструктуры (например, создание цифрового двойника железнодорожного моста, снабженного системой мониторинга, на основе статистического метода конечных элементов [3]) демонстрируют возможность использования методов интеграции данных и физических знаний с учетом неопределенностей также и в геотехнике. Так, Латиф с соавторами [171] осуществили потоковую передачу эксплуатационных данных цифровому двойнику на базе машинного обучения для прогнозирования характеристик и визуализации проходки тоннеля в реальном времени. Аподжи с коллегами [187] представили концеп-

цию уровней принятия решений с использованием искусственного интеллекта для будущих механизированных тоннелепроходческих работ на основе анализа больших данных. Чжао с соавторами [188] исследовали, как функции цифровых двойников могут поддерживать процессы строительства, обеспечения безопасности и управления жизненным циклом тоннелей.

### Человеко-машинное взаимодействие с использованием больших языковых моделей ▶

Большие языковые модели (например, GPT-4) обладают значительным потенциалом для развития взаимодействия человека с алгоритмами ИИ в геотехнике. Развив подходы, заложенные в более ранних моделях обработки естественного языка, они способны извлекать из текстов более глубокие знания и открывают новые возможности для сотрудничества специалистов с искусственным интеллектом. Интерфейсы, основанные на больших языковых моделях, обещают сделать применение таких систем более интуитивным и динамичным (например, рис. 16).

Однако универсальные (для широкого спектра задач) большие языковые модели часто имеют затруднения при ответах на специализированные геотехнические запросы, выходящие за рамки данных, использованных на этапе предварительного обучения. Это ограничение можно преодолеть с помощью малозатратной доработки модели или генерации текста с помощью расширенного поиска и извлечения информации (Retrieval-Augmented Generation, RAG) из специализированного корпуса/набора текстов, сформированного и периодически обновляемого группой специалистов.

Первые исследования в этом направлении показали, что большая языковая модель GPT-4 способна отвечать на вопросы учебного уровня по геотехнике с точностью около 70% и составлять проекты технических заданий на инженерно-геологические изыскания [189]. Кумар [172] продемонстрировал достоверную интерпретацию геотехнических данных с использованием тщательно разработанных запросов, а Сюй с коллегами [190] представили GeoLLM – специализированную большую языковую модель, дообученную для интеллектуальной автоматизации геотехнического проектирования. В недавних исследованиях также рассматривается применение методов на основе больших языковых моделей,

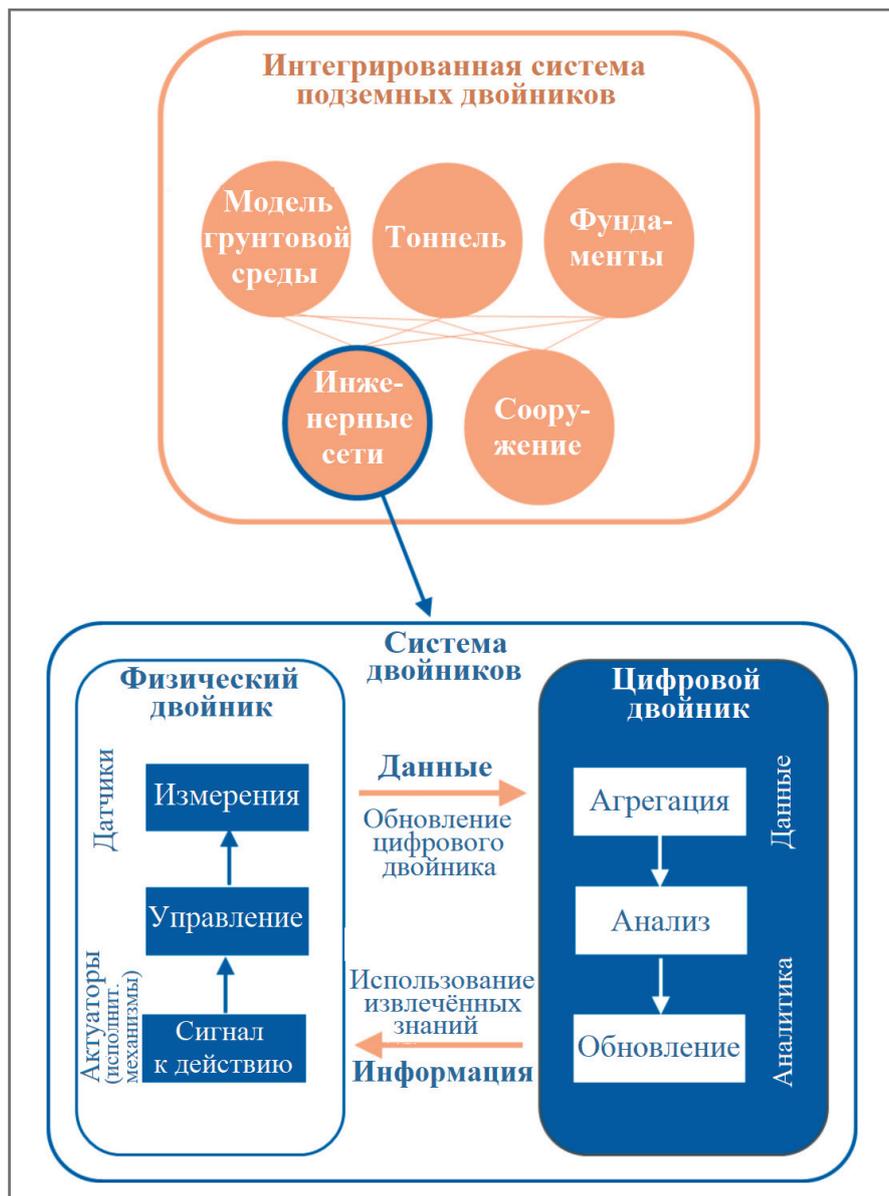


Рис. 15. Схема работы интегрированной системы подземных двойников

например генерации текста с использованием расширенного поиска (RAG) и обучения на небольшом числе примеров, для решения различных задач геотехнического проектирования, включая планирование организации работ на строительной площадке [191], геологическое моделирование [192] и проектирование фундаментов [193]. Эти работы подтверждают практический потенциал больших языковых моделей, в то же время подчеркивая необходимость управления проблемами, связанными с качеством запросов и с возможными «галлюцинациями» модели.

### Генеративное моделирование (моделирование с генерацией данных) ▶

Генеративный искусственный интеллект, основанный на генеративно-соста-

зательных сетях [194] и получивший дальнейшее развитие с помощью генеративных моделей на основе диффузии (диффузионных) [195], открывает для геотехники три основные возможности.

Во-первых, он может генерировать реалистичные синтетические наборы данных, что способствует улучшению многоуровневого моделирования и численных расчетов.

Во-вторых, генеративный ИИ способен автоматизированно осуществлять процессы проектирования с учетом ограничений, позволяя быстро исследовать и оценивать результаты геотехнического планирования, сокращать итерационные циклы и находить новые решения.

В-третьих, обучаясь на исторических и специфичных для конкретной строительной площадки данных, генератив-



Рис. 16. Концептуальная схема интерфейса на основе большой языковой модели для взаимодействия между человеком и системой искусственного интеллекта

ные модели могут предсказывать потенциальные сценарии разрушений/отказов и обеспечивать информацией разработку проактивных стратегий снижения рисков.

В совокупности эти возможности открывают путь к еще более инновационной геотехнической практике, более быстрому и безопасному выполнению работ в отрасли.

Среди недавних адаптаций для геотехнической отрасли – генеративно-сопоставительная нейросеть SchemaGAN [196], которая создает правдоподобные геотехнические модели подповерхностной среды на основе разреженных данных статического зондирования конусом (СРТ) и превосходит по достоверности результаты применения метода интерполяции, основанного на кригинге.

Чжоу и Ши [181] при построении двумерных разрезов применили многомасштабную генеративно-сопоставительную нейросеть для объединения данных изысканий различной степени достоверности, что позволило значительно снизить среднеквадратическую ошибку по сравнению с классическими методами инверсии.

Для задач анализа временных рядов данных Ге с соавторами [197] представили RGAN-LS – рекуррентную генеративно-сопоставительную нейросеть, которая увеличивает объем ограниченных данных по смещениям и повышает точность прогнозирования движения оползней в «слепых» тестах (с заранее не известными исходными данными или ответами) на величину вплоть до 18%.

### Обучение моделей преобразования данных (операторов) и графовые модели ▶

Для решения задач вычислительной механики недавно были адаптированы

фреймворки нейронных операторов, то есть платформы для обучения нейронных моделей преобразования данных, такие как Wavelet Neural Operator (нейронный оператор с использованием вейвлет-преобразований) и Physics-Informed Geometry-Aware Neural Operator (нейронный оператор с учетом физических законов и геометрических параметров). Они обеспечили ускорение вычислений, не связанное с размером или детализацией сетки дискретизации пространства, в 50–100 раз по сравнению с методом конечных элементов и в то же время позволили сохранить согласованность с физическими законами [198, 199].

Одновременный прогресс в разработке вычислительных моделей (симуляторов) на основе графовых нейронных сетей позволяет эффективно рассчитывать поведение гранулярных потоков на уровне отдельных частиц. Например, Цзян с соавторами [200] показали, что такие симуляторы способны точно прогнозировать динамику разрушения гранулярных тел и эффективно оптимизировать параметры метода дискретных элементов. При одном из более поздних исследований дифференцируемая суррогатная (замещающая) модель на основе нейросети воспроизвела динамику сползания слагавшего склон многослойного грунтового массива в 145 раз быстрее по сравнению с методом материальной точки, при этом поддерживая возможность обратного определения параметров модели [201].

Эти подходы, основанные на обучении моделей преобразования данных (операторов) и на графовых моделях (графовых симуляторах), открывают путь к созданию многомасштабных дифференцируемых вычислительных моделей геомеханических систем в реальном времени.

### ЗАКЛЮЧЕНИЕ ▶

В данной статье описан потенциал внедрения искусственного интеллекта в геотехнику, обусловленного необходимостью решения трудных задач, возникающих при сложных взаимодействиях инженерных сооружений, грунтов, подземных вод и других элементов окружающей среды. Освещены недавние достижения в популярных направлениях применения ИИ в геотехнике, включая интеллектуальные инженерные изыскания, моделирование поведения грунтов и оптимизацию процессов геотехнического проектирования. Также продемонстрировано, как технологии искусственного интеллекта уже способствуют созданию более точных прогнозных моделей и упрощению рабочих процессов. С помощью приведенных примеров наглядно показано, что ИИ способен приносить ощутимую пользу отрасли уже сегодня.

Однако выявлено несколько характерных для геотехники ключевых проблем, которые надо решить, чтобы полностью реализовать потенциал использования в ней искусственного интеллекта. Важнейшей проблемой остается нехватка данных, которая может препятствовать машинному обучению моделей из-за сложных взаимодействий в любом геотехническом проекте. Сложность корректного применения ИИ в геотехнике также связана с объяснимостью моделей, их универсальностью (адаптацией к разным условиям) и учетом факторов неопределенности. Критически важно объединить технологии искусственного интеллекта с традиционными геотехническими моделями, а также создать эталонные тесты и критерии оценки моделей, чтобы обеспечить согласованность моделей ИИ с существующими геотехническими знаниями.

ми, преодолеть возможные несоответствия и повысить доверие геотехнического сообщества к такой интеграции.

И наконец, в статье рассмотрены приоритетные направления развития технологий искусственного интеллекта в геотехнике, включая человеко-машинное взаимодействие с использованием больших языковых моделей, моделирование с разными уровнями достоверности, извлечение знаний, создание цифровых двойников, генеративные модели, обучение моделей преобразования данных (операторов), графовые модели (графовые симуляторы).

Для достижения прогресса в этой области в соответствии с существующими геотехническими принципами, по мнению авторов, необходим междисциплинарный подход, предполагающий сотрудничество между исследователями в области ИИ и геотехниками.

Этические аспекты, в частности вопросы необъективности и подотчетности, говорят о важности ответственного использования искусственного интеллекта в рамках правового поля. **И**

*Данная работа в первоначальном виде была представлена на Первом симпозиуме по применению искус-*

*ственного интеллекта в геотехнике, проведенном в мае 2023 года в городе Глазго (Великобритания). Это мероприятие было организовано с финансовой поддержкой гранта британского Национального института имени Алана Тьюринга по развитию анализа данных и искусственного интеллекта (Alan Turing Development Award) при софинансировании со стороны Фонда ускорения внедрения результатов исследований Научного совета по инженерным и физическим наукам Великобритании (EPSRC Impact Acceleration Account) при Университете Глазго.*

## ИСТОЧНИК ДЛЯ ПЕРЕВОДА ►

### (SOURCE FOR THE TRANSLATION) ►

Sheil B., Anagnostopoulos C., Buckley R., Ciantia M.O., Febrianto E., Fu J., Gao Z., Geng X., Gong B., Hanley K., He P., Kolomvatsos K., Lopes B.C.F.L., Ninic J., Previtali M., Rezanian M., Ruiz-Lopez A., Sun J., Suryasentana S., Taborda D., Utili S., Whyte S., Zhang P. Artificial intelligence transformations in geotechnics: progress, challenges and future enablers // *Computers and Geotechnics*. Elsevier, 2026. Vol. 189. Article 107604. URL: <https://doi.org/10.1016/j.compgeo.2025.107604> (in press).

## СПИСОК ЛИТЕРАТУРЫ, ИСПОЛЬЗОВАННОЙ АВТОРАМИ ПЕРЕВЕДЕННОЙ СТАТЬИ ►

### (REFERENCES USED BY THE AUTHORS OF THE TRANSLATED PAPER) ►

- Jiang F., Jiang Y., Zhi H., Dong Y., Li H., Ma S., Wang Y., Dong Q., Shen H., Wang Y. Artificial intelligence in healthcare: past, present and future // *Stroke Vascular Neurol*. 2017. Vol. 2. № 4.
- Goodell J.W., Kumar S., Lim W.M., Pattnaik D. Artificial intelligence and machine learning in finance: identifying foundations, themes, and research clusters from bibliometric analysis // *J. Behav. Exp. Financ*. 2021. Vol. 32. Article 100577.
- Febrianto E., Butler L., Girolami M., Cirak F. Digital twinning of self-sensing structures using the statistical finite element method // *Data-Centric Eng*. 2022. Vol. 3. № e31.
- Sun F., Febrianto E., Fernando H., Butler L., Cirak F., Hoult N. Data-informed statistical finite element analysis of rail buckling // *Comput. Struct*. 2023. Vol. 289. Article 107163.
- Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A.N., Kaiser Ł., Polosukhin I. Attention is all you need // *Adv. Neural Informat. Process. Syst*. 2017. Vol. 30.
- Sheil B.B., Suryasentana S.K., Cheng W.C. Assessment of anomaly detection methods applied to microtunneling // *J. Geotech. Geoenviron. Eng*. 2020. Vol. 146. № 9. Article 04020094.
- Sheil B.B., Suryasentana S.K., Mooney M.A., Zhu H. Machine learning to inform tunnelling operations: recent advances and future trends // *Proc. Inst. Civil Eng. – Smart Infrastruct. Constr*. 2020. Vol. 173. № 4. P. 74–95.
- Stuyts B., Suryasentana S.K. Applications of data science in offshore geotechnical engineering: state of practice and future perspectives // 9th International SUT OSIG Conference. 2023.
- Suryasentana S.K., Sheil B.B. Demystifying the connections between Gaussian process regression and kriging // 9th International SUT OSIG Conference. 2023. P. 1–8.
- Russell S.J., Norvig P. *Artificial intelligence: a modern approach*. London, 2010.
- MacKay D.J.C. *Information Theory, Inference and Learning Algorithms*. Cambridge University Press, 2003.
- Kennedy M.C., O'Hagan A. Bayesian calibration of computer models // *J. R. Stat. Soc. Ser. B (Stat Methodol.)*. 2001. Vol. 63. P. 425–464.
- Girolami M., Febrianto E., Yin G., Cirak F. The statistical finite element method (statFEM) for coherent synthesis of observation data and model predictions // *Comput. Methods Appl. Mech. Eng*. 2021. Vol. 375. Article 113533.
- Hu J.Z., Zhang J., Huang H.W., Zheng J.G. Value of information analysis of site investigation program for slope design // *Comput. Geotech*. 2021. Vol. 131. Article 103938.
- Zhao T., Wang Y. Determination of efficient sampling locations in geotechnical site characterization using information entropy and Bayesian compressive sampling // *Can. Geotech. J*. 2019. Vol. 56. № 11. P. 1622–1637.
- Yoshida I., Tasaki Y., Tomizawa Y. Optimal placement of sampling locations for identification of a two-dimensional space // *Georisk: Assessment and Management of Risk for Engineered Systems and Geohazards*. 2022. Vol. 16. № 1. P. 98–113.

17. Li J., Cassidy M.J., Huang J., Zhang L., Kelly R. Probabilistic identification of soil stratification // *Geotechnique*. 2016. Vol. 66. № 1. P. 16–26.
18. Wang Y., Huang K., Cao Z. Probabilistic identification of underground soil stratification using cone penetration tests // *Can. Geotech. J.* 2013. Vol. 50. № 7. P. 766–776.
19. Houlsby N.M.T., Houlsby G.T. Statistical fitting of undrained strength data // *Geotechnique*. 2013. Vol. 63. № 14. P. 1253–1263.
20. Ching J., Wang J.-S., Juang C.H., Ku C.-S. Cone penetration test (CPT)-based stratigraphic profiling using the wavelet transform modulus maxima method // *Canadian Geotechnical J.* 2015. Vol. 52. № 12. P. 1993–2007.
21. Suryasentana S.K., Lawler M., Sheil B.B., Lehane B.M. Probabilistic soil strata delineation using DPT data and Bayesian changepoint detection // *J. Geotech. Geoenviron. Eng.* 2023. Vol. 149. № 4. Article 06023001.
22. Wang Y., Hu Y., Zhao T. Cone Penetration test (CPT)-based subsurface soil classification and zonation in two-dimensional vertical cross section using Bayesian compressive sampling // *Can. Geotech. J.* 2020. Vol. 57. № 7. P. 947–958.
23. Cao Z.J., Zheng S., Li, D.Q., Phoon K.K. Bayesian identification of soil stratigraphy based on soil behavior type index // *Can. Geotech. J.* 2019. Vol. 56. № 4. P. 570–586.
24. Gong W., Zhao C., Juang C.H., Tang H., Wang H., Hu X. Stratigraphic uncertainty modelling with random field approach // *Comput. Geotech.* 2020. Vol. 125. Article 103681.
25. Shuku T., Phoon K.K., Yoshida I. Trend estimation and layer boundary detection in depth-dependent soil data using sparse Bayesian lasso // *Comput. Geotech.* 2020. Vol. 128. Article 103845.
26. Hegazy Y.A., Mayne P.W. Objective site characterization using clustering of piezocone data // *J. Geotech. Geoenviron. Eng.* 2002. Vol. 128. № 12. P. 986–996.
27. Zhao T., Wang Y. Interpolation and stratification of multilayer soil property profile from sparse measurements using machine learning methods // *Eng. Geol.* 2020. Vol. 265. Article 105430.
28. Zhou X., Shi P., Sheil B., Suryasentana S. Knowledge-based U-Net and transfer learning for automatic boundary segmentation // *Adv. Eng. Inf.* 2024. Vol. 59. Article 102243.
29. Suryasentana S.K., Sheil B.B., Lawler M. Assessment of Bayesian changepoint detection methods for soil layering identification using cone penetration test data // *Geotechnics*. 2024. Vol. 4. № 2. P. 382–398.
30. Firouzianbandpey S., Ibsen L.B., Griffiths D.V., Vahdatirad M.J., Andersen L.V., Sørensen J.D. Effect of spatial correlation length on the interpretation of normalized CPT data using a kriging approach // *J. Geotech. Geoenviron. Eng.* 2015. Vol. 141. № 12. Article 04015052.
31. Cai Y., Li J., Li X., Li D., Zhang L. Estimating soil resistance at unsampled locations based on limited CPT data // *Bull. Eng. Geol. Environ.* 2019. Vol. 78. P. 3637–3648.
32. He X., Xu H., Sabetamal H., Sheng D. Machine learning aided stochastic reliability analysis of spatially variable slopes // *Comput. Geotech.* 2020. Vol. 126. Article 103711.
33. Rahman M.H., Abu-Farsakh M.Y., Jafari N. Generation and evaluation of synthetic cone penetration test (CPT) data using various spatial interpolation techniques // *Can. Geotech. J.* 2021. Vol. 58. № 2. P. 224–237.
34. Wang Y., Zhao T. Statistical interpretation of soil property profiles from sparse data using Bayesian compressive sampling // *Geotechnique*. 2017. Vol. 67. № 6. P. 523–536.
35. Wang Y., Li P. Data-driven determination of sample number and efficient sampling locations for geotechnical site investigation of a cross-section using Voronoi diagram and Bayesian compressive sampling // *Comput. Geotech.* 2021. Vol. 130. Article 103898.
36. Zhao T., Xu L., Wang Y. Fast non-parametric simulation of 2D multi-layer cone penetration test (CPT) data without pre-stratification using markov chain Monte Carlo simulation // *Eng. Geol.* 2020. Vol. 273. Article 105670.
37. Shi C., Wang Y. Development of subsurface geological cross-section from limited site-specific boreholes and prior geological knowledge using iterative convolution XGBoost // *J. Geotech. Geoenviron. Eng.* 2021. Vol. 147. № 9. Article 04021082.
38. Shi C., Wang Y. Nonparametric and data-driven interpolation of subsurface soil stratigraphy from limited data using multiple point statistics // *Can. Geotech. J.* 2021. Vol. 58. № 2. P. 261–280.
39. Sauvin G., Vanneste M., Vardy M.E., Klinkvort R.T., Carl Fredrik F. Machine learning and quantitative ground models for improving offshore wind site characterization // *Offshore Technol. Conf. (OTC 2019)*, Houston, Texas, USA. 2019. Vol. 2. P. 1323–1339. DOI:10.4043/29351-MS.
40. Wu S., Zhang J.M., Wang R. Machine learning method for CPTu based 3D stratification of New Zealand geotechnical database sites // *Adv. Eng. Inf.* 2021. Vol. 50. Article 101397.
41. Xie J., Huang J., Lu J., Burton G.J., Zeng C., Wang Y. Development of two-dimensional ground models by combining geotechnical and geophysical data // *Eng. Geol.* 2022. Vol. 300. Article 106579.
42. Huang J., Zheng D., Li D.Q., Kelly R., Sloan S.W. Probabilistic characterization of two-dimensional soil profile by integrating cone penetration test (CPT) with multi-channel analysis of surface wave (MASW) data // *Can. Geotech. J.* 2018. Vol. 55. № 8. P. 1168–1181.
43. Ghose R., Goudswaard J. Integrating S-wave seismic-reflection data and cone-penetration-test data using a multiangle multiscale approach // *Geophysics*. 2004. Vol. 69. № 2. P. 440–459.
44. Wellmann J.F., De La Varga M., Murdie R.E., Gessner K., Jessell M. Uncertainty estimation for a geological model of the Sandstone greenstone belt, Western Australia – insights from integrated geological and geophysical inversion in a Bayesian inference framework // *Geol. Soc. Lond. Spec. Publ.* 2018. Vol. 453. № 1. P. 41–56.

45. Medina-Cetina Z., Son J., Moradi M. Bayesian stratigraphy integration of geophysical, geological, and geotechnical surveys data // *Offshore Technol. Conf. (OTC 2019)*, Houston, Texas, USA. 2019. Vol. 5. P. 3431–3440.
46. Xu J., Wang Y., Zhang L. 2021. Interpolation of extremely sparse geo-data by data fusion and collaborative Bayesian compressive sampling // *Comput. Geotech.* Vol. 134. Article 104098.
47. Xu J., Wang Y., Zhang L. Fusion of geotechnical and geophysical data for 2D subsurface site characterization using multi-source Bayesian compressive sampling // *Can. Geotech. J.* 2022. Vol. 59. № 10. P. 1756–1773.
48. Christensen C.W., Harrison E.J., Pfaffhuber A.A., Lund A.K. A machine learning-based approach to regional-scale mapping of sensitive glaciomarine clay combining airborne electromagnetics and geotechnical data // *Near Surf. Geophys.* 2021. Vol. 19. № 5. P. 523–539.
49. Chen J., Vissinga M., Shen Y., Hu S., Beal E., Newlin J. Machine learning-based digital integration of geotechnical and ultrahigh-frequency geophysical data for offshore site characterizations // *J. Geotech. Geoenviron. Eng.* 2021. Vol. 147. № 12. Article 04021160.
50. Coelho B.Z., Karaoulis M. Data fusion of geotechnical and geophysical data for three-dimensional subsoil schematisations // *Adv. Eng. Inf.* 2022. Vol. 53. Article 101671.
51. Roscoe K.H., Schofield, A.N., Wroth C.P. On the yielding of soils // *Geotechnique*. 1958. Vol. 8. № 1. P. 22–53.
52. Schofield A.N., Wroth C.P. *Critical state soil mechanics*. London, UK: McGraw Hill, 1968.
53. Been K., Jefferies M.G. A state parameter for sands // *Geotechnique*. 1985. Vol. 35. № 2. P. 99–112.
54. Reynolds O. LVII. On the dilatancy of media composed of rigid particles in contact. With experimental illustrations // *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*. 1885. Vol. 20. № 127. P. 469–481. DOI:10.1080/14786448508627791.
55. Taylor D.W. *Fundamentals of Soil Mechanics*. New York: John Wiley & Sons, 1948.
56. Bolton M.D. The strength and dilatancy of sands // *Geotechnique*. 1986. Vol. 36. № 1. P. 65–78.
57. Bishop A.W. The strength of soils as engineering materials // *Geotechnique*. 1966. Vol. 16. P. 91–128.
58. Amarasinghe S.F., Parry R.H. Anisotropy in heavily overconsolidated kaolin // *J. Geotech. Eng. Div. ASCE*, 1975. Vol. 101. № GT12. P. 1277–1292.
59. Burland J.B. On the compressibility and shear strength of natural clays // *Geotechnique*. 1990. Vol. 40. № 3. P. 329–378.
60. Leroueil S., Vaughan P.R. The general and congruent effects of structure in natural soils and weak rocks // *Geotechnique*. 1990. Vol. 40. № 3. P. 467–488.
61. Liu W.Z., Shi M.L., Miao L.C., Xu L.R., Zhang D.W. Constitutive modeling of the destructuration and anisotropy of natural soft clay // *Comput. Geotech.* 2013. Vol. 51. P. 24–41.
62. Lade P.V., Duncan J.M. Stress-path dependent behavior of cohesionless soil // *J. Geotech. Eng. Div.* 1976. Vol. 102. № 1. P. 51–68.
63. Suklje L. The analysis of the consolidation process by the isotaches method // *Proc. 4th Int. Conf. Soil Mech Found. Eng., London, 1957*. Vol. 1. P. 200–206.
64. Bjerrum L. Engineering geology of Norwegian normally consolidated marine clays as related to the settlements of buildings // *Geotechnique*. 1967. Vol. 17. № 2. P. 83–119.
65. Roscoe K.H., Bassett R.H., Cole E.R.L. Principal axes observed during simple shear of a sand // *Proc., Geotechnical Conf. on Shear Strength Properties of Natural Soils and Rocks*, Oslo, Norwegian Geotechnical Society, 1967. P. 231–237.
66. Kim Y.T., Leroueil S. Modeling the viscoplastic behaviour of clays during consolidation: application to Berthierville clay in both laboratory and field conditions // *Can. Geotech. J.* 2001. Vol. 38. № 3. P. 484–497.
67. Yin Z.-Y., Karstunen M., Chang C.S., Koskinen M., Lojander M. Modeling time-dependent behavior of soft sensitive clay // *J. Geotech. Geoenviron. Eng.* 2011. Vol. 137. № 11. P. 1103–1113.
68. Su D., Yang Z.X. Drained analyses of cylindrical cavity expansion in sand incorporating a bounding-surface model with state-dependent dilatancy // *App. Math. Model.* 2019. Vol. 68. P. 1–20.
69. Kang X., Xia Z., Chen R., Ge L., Liu X. The critical state and steady state of sand: a literature review // *Mar. Georesour. Geotec.* 2019. Vol. 37. № 9. P. 1105–1118.
70. Wan R.G., Guo P.J. A simple constitutive model for granular soils: modified stress-dilatancy approach // *Comput. Geotech.* 1988. Vol. 22. P. 109–133.
71. Su L.-J., Yin J.-H., Zhou W.-H. Influences of overburden pressure and soil dilation on soil nail pull-out resistance // *Comput. Geotech.* 2010. Vol. 37. № 4. P. 555–564.
72. Dafalias Y.F. An anisotropic critical state soil plasticity model // *Mech. Res. Comm.* 1986. Vol. 13. № 6. P. 341–347.
73. Yin Z.Y., Chang C.S., Karstunen M., Hicher P.Y. An anisotropic elastic–viscoplastic model for soft clays // *Int. J. Solids Struct.* 2010. Vol. 47. № 5. P. 665–677.
74. Kang X., Xia Z., Chen R.P. Measurement and correlations of  $K_0$  and  $V_s$  anisotropy of granular soils // *Proc. Inst. Civil Eng.-Geotech. Eng.* 2020. Vol. 173. № 6. P. 546–561.
75. Hu X., Zhang Y., Guo L., Wang J., Cai Y., Fu H., Cai Y. Cyclic behavior of saturated soft clay under stress path with bidirectional shear stresses // *Soil Dyn. Earthq. Eng.* 2018. Vol. 104. P. 319–328.
76. Tian Y., Yao Y.P. Modelling the non-coaxiality of soils from the view of cross-anisotropy // *Comput. Geotech.* 2017. Vol. 86. P. 219–229.

77. Zhou M.M., Meschke G. A three-phase thermo-hydro-mechanical finite element model for freezing soils // *Int. J. Numer. Anal. Meth. Geomech.* 2013. Vol. 37. № 18. P. 3173–3193.
78. Dafalias Y.F., Manzari M.T. Simple plasticity sand model accounting for fabric change effects // *Journal of Engineering Mechanics.* 2004. Vol. 130. № 6. P. 622–634.
79. Ghaboussi J., Carret J., Wu X. Material modelling with neural networks // *Proceedings of the international conference on numerical methods in engineering: theory and applications*, Swansea, UK, 1990. P. 701–717.
80. Ghaboussi J., Carret J., Wu X. Knowledge-based modelling of material behaviour with neural networks // *J. Eng. Mech. Div.* 1991. Vol. 117. № 1. P. 132–153.
81. Ellis G.W., Yao C., Zhao R. Neural network modeling of the mechanical behavior of sand // *Proc. of the 9th ASCE Conference on Engineering Mechanics*, Texas, 1992. P. 421–424.
82. Ellis G.W., Yao C., Zhao R., Penumadu D. Stress-strain modeling of sands using artificial neural networks // *ASCE J. Geotech. Eng. Div.* 1995. Vol. 121. № 5. P. 429–435.
83. Ghaboussi J., Sidarta D.E. New nested adaptive neural networks (NANN) for constitutive modeling // *Comput. Geotech.* 1998. Vol. 22. № 1. P. 29–52.
84. Penumadu D., Zhao R. Triaxial compression behavior of sand and gravel using artificial neural networks (ANN) // *Comput. Geotech.* 1999. Vol. 24. № 3. P. 207–230.
85. Javadi A.A., Rezanian M., Applications of artificial intelligence and data mining techniques in soil modeling // *Geomech. Eng.* 2009. Vol. 1. № 1. P. 53–74.
86. Shin H.S., Pande G.N. On self-learning finite element code based on monitored response of structures // *Comput. Geotech.* 2000. Vol. 27. P. 161–178.
87. Lefik M., Schrefler B.A. Artificial neural network as an incremental non-linear constitutive model for finite element code // *Comput. Methods Appl. Mech. Eng.* 2003. Vol. 192. P. 3265–3283.
88. Hashash Y.M.A., Jung S., Ghaboussi J. Numerical implementation of a neural network based material model in finite element analysis // *Int. J. Numer. Meth. Eng.* 2004. Vol. 59. P. 989–1005.
89. Javadi A.A., Rezanian M. Intelligent finite element method: an evolutionary approach to constitutive modeling // *Adv. Eng. Inf.* 2009. Vol. 23. № 4. P. 442–451.
90. Raissi M., Perdikaris P., Karniadakis G.E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations // *J. Comput. Phys.* 2019. Vol. 378. P. 686–707.
91. Masi F., Stefanou I., Vannucci P., Maffi-Berthier V. Thermodynamics-based artificial neural networks for constitutive modeling // *J. Mech. Phys. Solids.* 2021. Vol. 147. Article 104277.
92. Masi F., Stefanou I. Multiscale modeling of inelastic materials with thermodynamics-based artificial neural networks (TANN) // *Comput. Methods Appl. Mech. Eng.* 2022. Vol. 398. Article 115190.
93. Weinan E., Yu B. The deep ritz method: a deep learning-based numerical algorithm for solving variational problems // *Commun. Math. Stat.* 2018. Vol. 6. P. 1–12.
94. Liu D., Wang Y. Multi-fidelity physics-constrained neural network and its application in materials modeling // *J. Mech. Des.* 2019. Vol. 141. № 12. Article 121403.
95. Sun L., Gao H., Pan S., Wang J.-X. Surrogate modeling for fluid flows based on physics-constrained deep learning without simulation data // *Comput. Meth. Appl. Mech. Eng.* 2020. Vol. 361. Article 112732.
96. Cuomo S., Di Cola V.S., Giampaolo F., Rozza G., Raissi M., Piccialli F. Scientific machine learning through physics-informed neural networks: where we are and what's next // *J. Sci. Comput.* 2022. Vol. 92. Article 88.
97. Vlassis N.N., Sun W. Sobolev training of thermodynamic-informed neural networks for interpretable elasto-plasticity models with level set hardening // *Comput. Meth. Appl. Mech. Eng.* 2021. Vol. 377. Article 113695.
98. Flaschela M., Kumar S., De Lorenzis L. Unsupervised discovery of interpretable hyperelastic constitutive laws // *Comput. Meth. Appl. Mech. Eng.* 2021. Vol. 381. Article 113852.
99. Zhang P., Yin Z.Y., Sheil B. Interpretable data-driven constitutive modelling of soils with sparse data // *Comput. Geotech.* 2023. Vol. 160. Article 105511.
100. Zhang J., Wang Z., Hu J., Xiao S., Shang W. Bayesian machine learning-based method for prediction of slope failure time // *J. Rock Mech. Geotech. Eng.* 2022. Vol. 14. № 4. P. 1188–1199.
101. Das B.M. Principles of geotechnical engineering. Cengage Learning, 2021.
102. Provenzano P., Ferlisi S., Musso A. Interpretation of a model footing response through an adaptive neural fuzzy inference system // *Comput. Geotech.* 2004. Vol. 31. № 3. P. 251–266.
103. Shahnazari H., Tutunchian M.A. Prediction of ultimate bearing capacity of shallow foundations on cohesionless soils: an evolutionary approach // *KSCE J. Civ. Eng.* 2012. Vol. 16. P. 950–957.
104. Tsai H.C., Tyan Y.Y., Wu Y.W., Lin Y.H. Determining ultimate bearing capacity of shallow foundations using a genetic programming system // *Neural Comput. & Appl.* 2013. Vol. 23. P. 2073–2084.

105. Lawal A.I., Kwon S. Development of mathematically motivated hybrid soft computing models for improved predictions of ultimate bearing capacity of shallow foundations // *J. Rock Mech. Geotech. Eng.* 2023. Vol. 15. № 3. P. 747–759.
106. Shahin M.A., Maier H.R., Jaksa M.B. Predicting settlement of shallow foundations using neural networks // *J. Geotech. Geoenviron. Eng.* 2002. Vol. 128. № 9. P. 785–793.
107. Shahin M.A., Maier H.R., Jaksa M.B. Settlement prediction of shallow foundations on granular soils using B-spline neurofuzzy models // *Comput. Geotech.* 2003. Vol. 30. № 8. P. 637–647.
108. Rezaia M., Javadi A.A. A new genetic programming model for predicting settlement of shallow foundations // *Can. Geotech. J.* 2007. Vol. 44. № 12. P. 1462–1473.
109. Samui P., Sitharam T.G. Least-square support vector machine applied to settlement of shallow foundations on cohesionless soils // *Int. J. Numer. Anal. Meth. Geomech.* 2008. Vol. 32. № 17. P. 2033–2043.
110. Zhang J., Dias D., An L., Li, C. Applying a novel slime mould algorithm-based artificial neural network to predict the settlement of a single footing on a soft soil reinforced by rigid inclusions // *Mech. Adv. Mater. Struct.* 2022. Vol. 31. № 1.
111. Vergote T.A., Raymackers S. Building a framework for probabilistic assessment accounting for soil, spatial, operational and model uncertainty, applied to pile driveability // *Ocean Eng.* 2022. Vol. 266. Article 113181.
112. Buckley R., Chen Y.M., Sheil B., Suryasentana S., Xu D.D., James R.M. Bayesian optimization for CPT-based prediction of impact pile drivability // *J. Geotech. Geoenviron. Eng.* 2023. Vol. 149. № 11. Article 04023100.
113. Pal M., Deswa S. Modelling pile capacity using Gaussian process regression // *Comput. Geotech.* 2010. Vol. 37. № 7–8. P. 942–947.
114. Alkroosh I., Nikraz H. Correlation of pile axial capacity and CPT data using gene expression programming // *Geotech. Geol. Eng.* 2011. Vol. 29. P. 725–748.
115. Kordjazi A., Nejad F.P., Jaksa M.B. Prediction of ultimate axial load-carrying capacity of piles using a support vector machine based on CPT data // *Comput. Geotech.* 2014. Vol. 55. P. 91–102.
116. Kardani N., Zhou A., Nazem M., Shen S.L. Estimation of bearing capacity of piles in cohesionless soil using optimised machine learning approaches // *Geotech. Geol. Eng.* 2020. Vol. 38. P. 2271–2291.
117. Alexander J.S., Buckley R.M., Whyte S.A. Machine learning to expedite concept monopile design // *Proceedings of the XVIII ECSMGE “Geotechnical Engineering Challenges to Meet Current and Emerging Needs of Society”, Lisbon, 2024.* P. 2760–2763.
118. Suryasentana S.K., Burd H.J., Byrne B.W., Aghakouchak A., Sorensen T. Comparison of machine learning models in a data-driven approach for scalable and adaptive design of laterally-loaded monopile foundations // *International Symposium on Frontiers in Offshore Geotechnics. Deep Foundations Institute (DFI), USA, 2020.* ISBN9780976322948.
119. Muduli P.K., Das S.K., Das M.R. Prediction of lateral load capacity of piles using extreme learning machine // *Int. J. Geotech. Eng.* 2013. Vol. 7. № 4. P. 388–394.
120. Taherkhani A.H., Mei Q., Han F. Capacity prediction and design optimization for laterally loaded monopiles in sandy soil using hybrid neural network and sequential quadratic programming // *Comput. Geotech.* 2023. Vol. 163. Article 105745.
121. Nejad F.P., Jaksa M.B., Kakhi M., McCabe B.A. Prediction of pile settlement using artificial neural networks based on standard penetration test data // *Comput. Geotech.* 2009. Vol. 36. № 7. P. 1125–1133.
122. Jebur A.A., Atherton W., Al Khaddar R.M., Loffill E. Settlement prediction of model piles embedded in sandy soil using the Levenberg-Marquardt (LM) training algorithm // *Geotech. Geol. Eng.* 2018. Vol. 36. P. 2893–2906.
123. Ge Q., Li C., Yang F. Support vector machine to predict the pile settlement using novel optimization algorithm // *Geotech. Geol. Eng.* 2023. Vol. 41. № 7. P. 1–15.
124. Khatti J., Samadi H., Grover K.S. Estimation of settlement of pile group in clay using soft computing techniques // *Geotech. Geol. Eng.* 2023. Vol. 42. № 3. P. 1–32.
125. Alm T., Hamre L. Soil model for pile driveability predictions based on CPT interpretations // *Proc. of the 15th Int. Conf. on Soil Mechanics and Geotechnical Engineering. Boca Raton, FL, USA: CRC Press, 2001.* P. 1297–1302.
126. Sheil B.B., Suryasentana S.K., Templeman J.O., Phillips B.M., Cheng W.C., Zhang L. Prediction of pipe-jacking forces using a Bayesian updating approach // *J. Geotech. Geoenviron. Eng.* 2022. Vol. 148. № 1. Article 04021173.
127. Deng L., Smith A., Dixon N., Yuan H. Machine learning prediction of landslide deformation behaviour using acoustic emission and rainfall measurements // *Eng. Geol.* 2021. Vol. 293. Article 106315.
128. Xu H., He X., Shan F., Niu G., Sheng D. Machine learning in the stochastic analysis of slope stability: a state-of-the-art review // *Modelling.* 2023. Vol. 4. № 4. P. 426–453.
129. Luo Z., Bui X.N., Nguyen H., Moayedi H. A novel artificial intelligence technique for analyzing slope stability using PSO-CA model // *Eng. Comput.* 2021. Vol. 37. P. 533–544.
130. Mahmoodzadeh A., Mohammadi M., Farid H.A.H., Hashim I.H., Nariman A.S., Nejati H.R. Prediction of safety factors for slope stability: comparison of machine learning techniques // *Natural Hazards.* 2022. Vol. 111. P. 1771–1799.
131. Aminpour M., Alaie R., Khosravi S., Kardani N., Moridpour S., Nazem M., Slope stability machine learning predictions on spatially variable random fields with and without factor of safety calculations // *Comput. Geotech.* 2023. Vol. 153. Article 105094.
132. Xiao T., Zhang L.M., Cheung R.W.M., Lacasse S. Predicting spatio-temporal man-made slope failures induced by rainfall in Hong Kong using machine learning techniques // *Geotechnique.* 2023. Vol. 73. № 9. P. 749–765.

133. Guardiani C., Soranzo E., Wu W. Time-dependent reliability analysis of unsaturated slopes under rapid drawdown with intelligent surrogate models // *Acta Geotech.* 2022. Vol. 17. P. 1071–1096.
134. Lin Y., Zhou K., Li J. Prediction of slope stability using four supervised learning methods // *IEEE Access.* 2018. Vol. 6. P. 31169–31179.
135. Zeng P., Zhang T., Li T., Jimenez R., Zhang J., Sun X. Binary classification method for efficient and accurate system reliability analyses of layered soil slopes // *Georisk: Assessment and Management of Risk for Engineered Systems and Geohazards.* 2022. Vol. 16. № 3. P. 435–451.
136. Novellino A., Cesarano M., Cappelletti P., Di Martire D., Di Napoli M., Ramondini M., Sowter A., Calcaterra D. Slow-moving landslide risk assessment combining machine learning and InSAR techniques // *Catena.* 2021. Vol. 203. Article 105317.
137. Bayaraa M., Rossi C., Kalaitzis F., Sheil B. Entity embeddings in remote sensing: application to deformation monitoring for infrastructure // *Remote Sens.* 2023. Vol. 15. № 20. Article 4910.
138. Cao B.T., Obel M., Freitag S., Mark P., Meschke G. Artificial neural network surrogate modelling for real-time predictions and control of building damage during mechanised tunnelling // *Adv. Eng. Softw.* 2020. Vol. 149. Article 102869.
139. Ninic J., Gamra A., Ghiassi B. Real-time assessment of tunnelling-induced damage to structures within the building information modelling framework // *Underground Space.* 2024. Vol. 14. P. 99–117.
140. Mokhtari S., Mooney M.A. Feasibility study of EPB shield automation using deep learning // *Tunnels and Underground Cities: Engineering and Innovation Meet Archaeology, Architecture and Art.* Boca Raton, FL, USA: CRC Press, 2019. P. 2691–2699.
141. Chen X., Li X., Zhu H. Condition evaluation of urban metro shield tunnels in Shanghai through multiple indicators multiple causes model combined with multiple regression method // *Tunn. Undergr. Space Technol.* 2019. Vol. 85. P. 170–181.
142. Li X., Lin X., Zhu H., Wang X., Liu Z. Condition assessment of shield tunnel using a new indicator: the tunnel serviceability index // *Tunn. Undergr. Space Technol.* 2017. Vol. 67. P. 98–106.
143. Zhu M., Zhu H., Guo F., Chen X., Ju J.W. Tunnel condition assessment via cloud model-based random forests and self-training approach // *Comput. Aided Civ. Inf. Eng.* 2021. Vol. 36. № 2. P. 164–179. DOI:10.1111/mice.12601.
144. Sheil B.B., Suryasentana S.K., Mooney M.A., Zhu, H., McCabe B.A., O'Dwyer K.G. Discussion: machine learning to inform tunnelling operations: recent advances and future trends // *Proc. Inst. Civil Eng.-Smart Infrastruct. Constr.* 2020. Vol. 173. № 1. P. 180–181.
145. Yu Y., Workman A., Grasmick J.G., Mooney M.A., Hering A.S. Space-time outlier identification in a large ground deformation data set // *J. Qual. Technol.* 2018. Vol. 50. № 4. P. 431–445.
146. Xue Y.D., Zhang S. A fast metro tunnel profile measuring method based on close-range photogrammetry // *Information Technology in Geo-engineering: Proceedings of the 3rd International Conference (ICITG), Guimaraes, Portugal.* Cham, Switzerland: Springer, 2019. P. 57–69.
147. Khetwal S., Pei S., Gutierrez M. A data-driven approach for direct assessment and analysis of traffic tunnel resilience // *Information Technology in Geo- engineering: Proceedings of the 3rd International Conference (ICITG), Guimaraes, Portugal.* Cham, Switzerland: Springer, 2019. P. 168–177.
148. Ding H., Liu S., Cai S., Xia Y. Big data analysis of structural defects and traffic accidents in existing highway tunnels // *Information Technology in Geoengineering: Proceedings of the 3rd International Conference (ICITG), Guimaraes, Portugal.* Cham, Switzerland: Springer, 2019. P. 189–195.
149. Hayashi H., Miyataka M., Gomi H., et al. Prediction of forward tunnel face score of rock mass classification for stability by applying machine learning to drilling data // *Information Technology in Geoengineering: Proceedings of the 3rd International Conference (ICITG), Guimaraes, Portugal.* Cham, Switzerland: Springer, 2019. P. 268–278.
150. Liu Y., Hou S. Rockburst prediction based on particle swarm optimization and machine learning algorithm // *Information Technology in Geoengineering: Proceedings of the 3rd International Conference (ICITG), Guimaraes, Portugal.* Cham, Switzerland: Springer, 2019. P. 292–303.
151. Zhao W., Wei Y., Liu B., Liu S., Xiao L. Design and application of automatic monitoring and BIM technology to the construction of shield-bored underneath building // *Information Technology in Geoengineering: Proceedings of the 3rd International Conference (ICITG), Guimaraes, Portugal.* Cham, Switzerland: Springer, 2019. P. 493–501.
152. Charles J.A., Gourvenec S., Vardy M.E. Recovering shear stiffness degradation curves from classification data with a neural network approach // *Acta Geotech.* 2023. Vol. 18. № 10. P. 1–15.
153. Lambert S., Toe D., Mentani A., Bourrier F., 2021. A meta-model-based procedure for quantifying the on-site efficiency of rockfall barriers // *Rock Mech. Rock Eng.* Vol. 54. P. 487–500.
154. Previtali M., Ciantia M.O., Spadea S., Castellanza R., Crosta G. Assessing rockfall barrier performance through block propagation codes and meta-models // *Proceedings of the 16th International Conference of the International Association for Computer Methods and Advances in Geomechanics.* Cham, Switzerland: Springer International Publishing, 2022. P. 291–298.
155. Lanfranconi C., Sala G., Frattini P., Crosta G.B., Valagussa A. Assessing the rockfall protection efficiency of forests at the regional scale // *Landslides.* 2020. Vol. 17. P. 2703–2721.
156. Bao Y., Chen Z., Wei S., Xu Y., Tang Z., Li H. The state of the art of data science and engineering in structural health monitoring // *Engineering.* 2019. Vol. 5. № 2. P. 234–242.
157. Jeong S., Ko J., Kim J. The effectiveness of a wireless sensor network system for landslide monitoring // *IEEE Access.* 2019. Vol. 8. P. 8073–8086.

158. Soga K., Luo L. Distributed fiber optics sensors for civil engineering infrastructure sensing // *J. Struct. Integrity Maint.* 2018. Vol. 3. № 1. P. 1–21.
159. Bayaraa M., Sheil B., Rossi C. InSAR and numerical modelling for tailings dam monitoring – the Cadia failure case study // *Geotechnique*. 2024. Vol. 74. № 10. P. 985–1003.
160. Voyagaki E., Crispin J.J., Gilder C.E., Ntassiou K., O’Riordan N., Nowak P., Sadek T., Patel D., Mylonakis G., Vardanega P.J. The DINGO database of axial pile load tests for the UK: settlement prediction in fine-grained soils // *Georisk: Assess. Manage. Risk Eng. Syst. Geohazards*. 2022. Vol. 16. № 4. P. 640–661.
161. Vahab M., Shahbodagh B., Haghighat E., Khalili N. Application of physics-informed neural networks for forward and inverse analysis of pile-soil interaction // *Int. J. Solids Struct.* 2023. Vol. 277. Article 112319.
162. Zhang P., Yin Z.Y., Sheil B. Interpretable data-driven constitutive modelling of soils with sparse data // *Comput. Geotech.* 2023. Vol. 160. Article 105511.
163. Zhang P., Yin Z.Y., Jin Y.F., Sheil B. Physics-constrained hierarchical data-driven modelling framework for complex path-dependent behaviour of soils // *Int. J. Numer. Anal. Meth. Geomech.* 2023. Vol. 46. № 10. P. 1831–1850.
164. Ribeiro M.T., Singh S., Guestrin C. Why should i trust you? Explaining the predictions of any classifier // *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*. 2016. P. 1135–1144.
165. Guidotti R., Monreale A., Ruggieri S., Turini F., Giannotti F., Pedreschi D. A survey of methods for explaining black box models // *ACM Comput. Surv. (CSUR)*. 2018. Vol. 51. № 5. P. 1–42.
166. Lundberg S.M., Lee S.I. A unified approach to interpreting model predictions // *Proceedings of the 31st Conference on Neural Information Processing Systems (NIPS 2017)*, Long Beach, CA, USA, 4-9 December 2017. P. 4768-4777.
167. Mitchell M., Wu S., Zaldivar A., Barnes P., Vasserman L., Hutchinson B., Spitzer E., Inioluwa D.R., Timnit G. Model cards for model reporting // *Proceedings of the Conference on Fairness, Accountability, and Transparency*, 2019. P. 220–229.
168. Peng J., Liu X. Automated code compliance checking research based on BIM and knowledge graph // *Sci. Rep.* 2023. Vol. 13. № 1. Article 7065.
169. Shahin M.A., Jaksa M.B., Maier H.R. State of the art of artificial neural networks in geotechnical engineering // *Electron. J. Geotech. Eng.* 2008. Vol. 8. № 1. P. 1–26.
170. Baghbani A., Choudhury T., Costa S., Reiner J. Application of artificial intelligence in geotechnical engineering: a state-of-the-art review // *Earth Sci. Rev.* 2022. Vol. 228. Article 103991.
171. Latif K., Sharafat A., Seo J. Digital twin-driven framework for TBM performance prediction, visualization, and monitoring through machine learning // *Appl. Sci.* 2023. Vol. 13. № 20. Article 11435.
172. Kumar K. Geotechnical parrot tales (gpt): Harnessing large language models in geotechnical engineering // *J. Geotech. Geoenviron. Eng.* 2024. Vol. 150. № 1. Article 02523001.
173. Erichson N.B., Mathelin L., Yao Z., Brunton S.L., Mahoney M.W., Kutz J.N., Shallow neural networks for fluid flow reconstruction with limited sensors // *Proc. Roy. Soc.* 2020. Vol. A476. № 2238. Article 20200097.
174. Yuan B., Heitor A., Wang H., Chen X. Physics-informed deep learning to solve three-dimensional Terzaghi consolidation equation: forward and inverse problems // *Arabian Journal for Science and Engineering*. 2025. 24 September. <https://doi.org/10.1007/s13369-025-10602-2>.
175. Ouyang W., Li G., Chen L., Liu S.-W. Machine learning-based prediction of drilled-shaft capacity // *Soils and Foundations*. 2024. Vol. 64. № 2. P. 262–274.
176. Tao R., Pan Y., Liu Z., et al. A physics-inspired machine learning approach for water-tightness estimation of defective cut-off walls with random construction errors // *Acta Geotech.* 2023. Vol. 18. P. 5959–5982. <https://doi.org/10.1007/s11440-023-02030-z>.
177. Perdikaris P., Raissi M., Damianou A., Lawrence N.D., Karniadakis G.E. Nonlinear information fusion algorithms for data-efficient multi-fidelity modelling // *Proc. Roy. Soc. A: Math. Phys. Eng. Sci.* 2017. Vol. 473. 2198. № 2198. Article 20160751.
178. Le Gratiet L., Garnier J. Recursive co-kriging model for design of computer experiments with multiple levels of fidelity // *Int. J. Uncertain. Quantif.* 2014. Vol. 4. № 5. P. 365–386.
179. Xu C., Cao B.T., Yuan Y., Meschke G. A multi-fidelity deep operator network (DeepONet) for fusing simulation and monitoring data: application to real-time settlement prediction during tunnel construction // *Eng. Appl. Artif. Intel.* 2024. Vol. 133. Article 108156.
180. Lam R., Allaire D.L., Willcox K.E. Multifidelity optimization using statistical surrogate modeling for non-hierarchical information sources // *56th AIAA/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials Conference*, 2015. Article 0143.
181. Zhou X., Shi P. Multi-scale generative adversarial network for 2D subsurface reconstruction using multi-fidelity geological exploration data // *Adv. Eng. Inf.* 2025. Vol. 66. Article 103482.
182. Zhang P., Yin Z.Y., Jin Y.F., Yang J., Sheil B. Physics-informed multifidelity residual neural networks for hydromechanical modeling of granular soils and foundation considering internal erosion // *J. Eng. Mech.* 2022. Vol. 148. № 4. Article 04022015.
183. He G.F., Zhang P., Yin Z.Y., Jin Y.F., Yang Y. Multi-fidelity data-driven modelling of rate-dependent behaviour of soft clays // *Georisk: Assessment and Management of Risk for Engineered Systems and Geohazards*. 2023. Vol. 17. № 1. P. 64–76.
184. Zhang P., Yin Z.Y., Sheil B. Multifidelity constitutive modeling of stress-induced anisotropic behavior of clay // *J. Geotech. Geoenviron. Eng.* 2024. Vol. 150. № 3. Article 04024003.

185. Brunton S.L., Proctor J.L., Kutz J.N. Discovering governing equations from data by sparse identification of nonlinear dynamical systems // Proc. Natl. Acad. Sci. 2016. Vol. 113. № 15. P. 3932–3937.
186. Zhang P., Yin Z.-Y., Sheil B. A physics-informed data-driven approach for consolidation analysis // Geotechnique. 2023. Vol. 74. № 7. P. 620–631.
187. Apoji D., Sheil B., Soga K. Shaping the future of tunneling with data and emerging technologies // Data-Centric Eng. 2023. Vol. 4. Article e29.
188. Zhao Y., Liu Y., Mu E. A review of intelligent subway tunnels based on digital twin technology // Buildings. 2024. Vol. 14. № 8. Article 2452.
189. Chen L., Tophel A., Hettiyadura U., Kodikara J. An investigation into the utility of large language models in geotechnical education and problem solving // Geotechnics. 2024. Vol. 4. № 2. P. 470–498.
190. Xu H.R., Zhang N., Yin Z.Y., Njock P.G.A. GeoLLM: a specialized large language model framework for intelligent geotechnical design // Comput. Geotech. 2025. Vol. 177. Article 106849.
191. Qian Z., Shi C. Large language model-empowered paradigm for automated geotechnical site planning and geological characterization // Autom. Constr. 2025. Vol. 173. Article 106103.
192. Li H., Shi C. Few-shot learning of geological cross-sections from sparse data using large language model // Geodata and AI. 2025. Vol. 2. Article 100010.
193. Xu H.R., Zhang N., Yin Z.Y., Njock P.G.A. Multimodal framework integrating multiple large language model agents for intelligent geotechnical design // Autom. Constr. 2025. Vol. 176. Article 106257.
194. Goodfellow I., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Courville A., Bengio Y. Generative adversarial nets // Adv. Neural Inform. Process. Syst. 2014. Vol. 3. № 11.
195. Song Y., Sohl-Dickstein J., Kingma D.P., Kumar A., Ermon S., Poole B. Score-based generative modeling through stochastic differential equations // ArXiv preprint. 2020. arXiv:2011.13456v1 [cs.LG] 26 Nov 2020.
196. Montero F.C., Coelho B.Z., Smyrniou E., Taormina R., Vardon P.J. SchemaGAN: a conditional generative adversarial network for geotechnical subsurface schematisation // Comput. Geotech. 2025. Vol. 183. Article 107177.
197. Ge Q., Li J., Lacasse S., Sun H., Liu Z. Data-augmented landslide displacement prediction using generative adversarial network // J. Rock Mech. Geotech. Eng. 2024. Vol. 16. № 10. P. 4017–4033.
198. Tripura T., Chakraborty S. Wavelet Neural Operator for solving parametric partial differential equations in computational mechanics problems // Computer Methods in Applied Mechanics and Engineering. 2023. Vol. 404. Article 115783.
199. Zhong W., Meidani H. 2025. Physics-informed geometry-aware neural operator // Comput. Methods Appl. Mech. Eng. Vol. 434. Article 117540.
200. Jiang Y., Byrne E., Glassey J., Chen X. Integrating graph neural network-based surrogate modeling with inverse design for granular flows // Ind. Eng. Chem. Res. 2024. Vol. 63. № 20. P. 9225–9235.
201. Choi Y., Macedo J., Liu C. Differentiable graph neural network simulator for forward and inverse modeling of multi-layered slope system with multiple material properties // ArXiv preprint. 2025. arXiv:2504.15938.



Телеграм-канал журнала

Независимый электронный журнал  
**ГеоИнфо**

- Новости
- Статьи
- Обсуждения

<https://t.me/geoinfonews>