

УДК 624.13:004.85: 631.6

© Д. И. Кацко, аспирант

© Е. В. Кузнецов, д-р техн. наук, профессор

(Кубанский государственный аграрный университет

им. И. Т. Трубилина, Краснодар, Россия)

E-mail: katsko99@mail.ru, dtn-kuz@rambler.ru

DOI 10.23968/1999-5571-2026-23-3-76-86

© D. I. Katsko, post-graduate student

© E. V. Kuznetsov, Dr. Sci. Tech., Professor

(Kuban State Agrarian University

named by I. T. Trubilin, Krasnodar, Russia)

E-mail: katsko99@mail.ru, dtn-kuz@rambler.ru

ОЦЕНКА УСТОЙЧИВОСТИ ОПОЛЗНЕВОГО СКЛОНА КАК РЕШЕНИЕ ЗАДАЧ РЕГРЕССИИ И КЛАССИФИКАЦИИ С ИСПОЛЬЗОВАНИЕМ МАШИННОГО ОБУЧЕНИЯ

LANDSLIDE SLOPE STABILITY ASSESSMENT AS A SOLUTION OF REGRESSION AND CLASSIFICATION PROBLEMS USING MACHINE LEARNING

Цель исследования — разработка программы для оперативного анализа устойчивости склона на местности. Для выявления оползневых участков проводится маршрутное (визуальное) обследование без компьютерной техники. Развитие технологий позволяет ставить и решать задачи, для решения которых не было алгоритмов обработки и не хватало вычислительных ресурсов. Рассматривается возможность оценки коэффициента устойчивости склона с использованием интерактивной аналитической панели (дашборда) RShiny. Подход к решению этой задачи основан на получении репрезентативного набора данных с помощью вычислительного эксперимента, реализованного с использованием программного комплекса PLAXIS.

Ключевые слова: оползневый склон, коэффициент устойчивости, вычислительный эксперимент, автоматизированное машинное обучение.

The purpose of the study is to develop a program for the operational analysis of slope stability on the ground. To identify landslide sites, a route (visual) survey is carried out without computer equipment. The development of technology makes it possible to set and solve problems for which there were no processing algorithms and not enough computing resources. The possibility of estimating the slope stability coefficient using the RShiny interactive analytical dashboard is considered. The approach to solving this problem is based on obtaining a representative data set using a computational experiment implemented using the PLAXIS software package.

Keywords: landslide slope, stability coefficient, computational experiment, automated machine learning.

Введение

В современной науке наблюдается тенденция к получению научных результатов на стыке нескольких дисциплин. И если примерно до 60-х гг. XX в. первое место в такой мультидисциплинарности занимала физика, то после (и особенно в настоящее время) ее содержательный приоритет дополняется вычислительными возможностями информатики (как науки о данных) и информационными технологи-

ями. Все это нашло отражение в современных тенденциях использования теории принятия решений при проведении мероприятий, которая опирается на три основных подхода [1]:

1) *physical-based methods (PhM)* — основан на физических моделях;

2) *knowledge-based methods (KBM)* — основан на знаниях;

3) *data-driven methods (DDM)* — основан на данных.

В настоящее время развитие компьютерной техники позволяет использовать машинное обучение (DDM) [2]. Для расчета коэффициента устойчивости склона (FS) достаточно пяти ключевых параметров: сцепление c , угол внутреннего трения φ , удельный вес γ , высота склона H и угол наклона β [3, 4]. Исходные данные могут быть как реальные, так и синтетические (созданные искусственно). В табл. 1 приведен анализ современных работ, посвященных этой проблеме.

Считается, что качество результатов машинного обучения тем лучше, чем больше объем данных. Однако все зависит от специфики поставленной задачи и характеристик качества обучения на тестовом множестве. Поэтому сравнение качества разных по условию задач не имеет смысла [5–15].

В настоящей статье рассматривается задача оценки устойчивости оползневого склона как реализация подхода, опирающегося на данные. Для его реализации (оценки коэффициента устойчивости склона) недостаточно использования только наблюдений, так как на практике не охватываются все возможные варианты состояния откосов и склонов [16–20]. Поэтому был проведен вычислительный эксперимент (рис. 1), в котором при заданных значениях геометрии склона (H — высота склона, $angle$ — угол склона) итеративно подбирались c_{ref} — сцепление и φ — угол внутреннего трения, доставляющие целевые значения коэффициента устойчивости ($FS > 1,0$ — склон устойчив, $FS > 1,28$ — устойчивость склона достаточна (СП 116.13330.2012. Инженерная защита территорий, зданий и сооружений от опасных

Таблица 1

Анализ работ, посвященных оценке устойчивости склона с использованием машинного обучения

№	Входные параметры	Данные
1	Сцепление c , угол внутреннего трения φ , угол откоса β , высота откоса H , коэффициент порового давления r_u , удельный вес грунта γ	117 случаев (реальные данные) [11]
2	Сцепление c , угол внутреннего трения φ , удельный вес грунта γ , коэффициент сейсмической нагрузки kh — всего четыре параметра	500 случаев (синтетические данные) [12]
3	1) $H, \beta, \gamma, c, \varphi$ — пять параметров; 2) $\gamma, c, \varphi, \beta, H, r_u$ — шесть параметров	1) 70 случаев; 2) 221 случай (реальные данные) [13]
4	Сцепление c , угол внутреннего трения φ , удельный вес γ , высота откоса H , угол откоса β — всего пять параметров	1500 случаев (синтетические данные) [14]
5	Восемь параметров, включая сцепление c , угол внутреннего трения φ и др.	897 случаев (реальные данные) [15]




Рис. 1. Расчет коэффициента устойчивости склона в программном комплексе PLAXIS с высотой $H = 35$ м и углом $angle = 30^\circ$

геологических процессов)), промежуточные значения также сохранялись; *psi* — угол дилатансии, *gammaUnsat* — удельный вес в естественном состоянии, — выбирались с использованием генератора случайных чисел (равномерный закон в диапазоне изменения).

Диапазон полученных в ходе эксперимента (после предобработки) значений коэффициента устойчивости FS_0_1 варьировался от 0,85 до 11,80. Был получен репрезентативный набор данных из 65 481 наблюдения (табл. 2), состоящий из следующих входных числовых переменных:

H — высота склона {5, ..., 60} — 16 уникальных значений;

angle — угол склона {10, ..., 85} — 16 уникальных значений;

cref — сцепление {1, ..., 54} — 76 уникальных значений;

phi — угол внутреннего трения {5, 10, ..., 85} — 75 уникальных значений;

psi — угол дилатансии {0, 3, ..., 8} — семь уникальных значений;

gammaUnsat — удельный вес грунта в естественном состоянии {17, ..., 22} — шесть уникальных значений.

Методы

Для решения поставленной задачи — получения модели регрессии (предсказания

непрерывного признака на основе входных данных), описывающей зависимость устойчивости склона от входных параметров (см. выше), — использовались интегрированная среда разработки (IDE — Integrated Development Environment) RStudio, а также платформа автоматизированного построения моделей машинного обучения (AutoML) и оптимизации — H2O (<https://h2o.ai/>). На имеющемся наборе данных обучалась машина градиентного бустинга (GBM — gradient boosting machine), реализованная в H2O. Суть работы GBM H2O — формирование ансамбля моделей, который объединяет множество слабых моделей (деревьев решений). Выбор AutoML H2O обоснован тем, что это одна из продвинутых платформ, имеющая высокую производительность за счет распределенных вычислений и работы в кластере; автоматизирован процесс подбора гиперпараметров (число деревьев регрессии, их глубина и т. д.).

Регрессия — это основная задача, рассматриваемая в настоящей статье. Сопутствующая задача — задача бинарной классификации: на основании имеющихся данных предсказывается основное событие, которое кодируется как «1», и его отрицание, которое кодируется как «0». Традиционно основным инструментом ее решения считается логистическая регрессия, но часто для улучшения результата используются модели машинного обучения, в нашем случае GBM H2O.

В данной статье рассматривалось две задачи классификации, суть которых заключалась в получении вероятностной оценки достоверности следующих событий:

FS_0_1 < 1,0 — «обрушение склона», или «склон не устойчив» (отрицание события «склон устойчив»);

FS_0_1 < 1,28 — «ниже требуемого значения», обеспечивающего безопасность при проектировании и строительстве (отрицание события «требуемое значение»).

Таблица 2

Фрагмент данных, полученных с использованием PLAXIS

№	<i>angle</i>	<i>H</i>	<i>cref</i>	<i>phi</i>	<i>psi</i>	<i>gammaUnsat</i>	FS_0_1
1	10	5	54	40	0	17	11,80
2	10	5	49	35	0	18	9,97
3	10	5	44	30	0	19	8,34
...	...	...	...	...	...	...	...
65 479	85	50	54	40	0	17	0,92
65 480	85	60	54	40	0	18	0,94
65 481	85	60	54	40	0	18	0,91

При построении модели регрессии переменные *H*, *angle*, *psi*, *gammaUnsat* рассматривались как категориальные (ввиду малого числа значений, менее 30), а переменные *cref*, *phi* — как непрерывные.

На рис. 2 представлена реализованная структура обработки данных (аналитический конвейер) для получения моделей классификации и регрессии с использованием GBM H2O.

Такая структура включает:

- загрузку и предобработку данных;
- инициализацию вычислительной среды (кластер H2O с параллельными вычислениями на шести ядрах процессора);
- построение моделей регрессии и классификации (пятикратная кросс-валидация позволяет утверждать, что переобучения нет);

- бутстрап (1000 итераций) для оценки доверительных интервалов;

- фиксацию результатов (метрик регрессии (RMSE, MAE, R^2), классификации (AUC, area under the curve — площадь под кривой)).

Результаты

В ходе проведения исследования получены характеристики (метрики) качества регрессионной модели: средняя ошибка предсказания (Root Mean Square Error) $RMSE = 0,026$; средняя абсолютная ошибка (Mean Absolut Error) $MAE = 0,018$; коэффициент детерминации,




Рис. 2. Аналитический конвейер: моделирование устойчивости откосов и склонов




Рис. 3. Зависимость предсказанных значений коэффициента устойчивости от фактических


характеризующей долю вариации FS_{0_1} , объясненную регрессией $R^2 = 0,997$ (рис. 3).

Таким образом, в среднем ошибка предсказания коэффициента устойчивости меньше 0,03 (приемлемо значение 0,05), полученная модель регрессии объясняет 99,7 % вариации коэффициента устойчивости.

Дальнейшее улучшение модели нецелесообразно, так как это приведет к переобучению. Процент покрытия (coverage) для переменной FS_{0_1} равен 100 %.

Для визуализации качества предсказания моделью регрессии можно использовать тепловую карту (heatmap) среднеквадратических ошибок предсказания (RMSE), которая в нашем случае представлена на рис. 4. Для удобства диапазоны изменения переменных c_{ref} и ϕ представлены как децили признаков.

Можно наблюдать, для каких диапазонов изменения переменных уменьшается или увеличивается среднеквадратическая

Рис. 4. Тепловая карта (heatmap) RMSE по координатам c_{ref} и ϕ




Рис. 5. ROC-кривые для Class 1.0 и Class 1.28

ошибка предсказаний коэффициента устойчивости. Например, для десятого дециля ϕ и десятого дециля c_{ref} значение RMSE порядка 0,01 независимо от значений второй переменной (рис. 5).

Модели классификации H2O (GBM) (см. рис. 5) также подтверждают высокое качество ($AUC > 0,99$). Важной характеристикой оценки коэффициента устойчивости является доверительный интервал, для получения которого использовался бутстрэп-метод. В нашем случае из первоначального

набора $k = 1000$ раз создали выборку с повторениями размером $N = 65\,481$ бутстрэп-образец. Тысячу раз обучили модель регрессии на каждом из образцов. Тысячу раз предсказали для всех 65 481 объекта из репрезентативного набора данных, полученных в ходе вычислительного эксперимента. Таким образом, каждый объект получил по 1000 предсказаний, а доверительный интервал берется как $q_{2,5}$ и $q_{97,5}$ — квантили 2,5 и 97,5 эмпирического распределения 1000 предсказаний соответственно.




Рис. 6. Эмпирическое распределение бутстрэп-предсказаний FS_0_1

Можно визуализировать эмпирическую функцию общего распределения вероятностей коэффициента устойчивости склона на основании 65 481 предсказания с 1000 повторений (рис. 6).

Две моды эмпирического распределения демонстрируют реализацию цели вычислительного эксперимента — итеративного подбора параметров *cref* и *phi* для достижения значений FS_0_1: 1,0 — границы устойчивости; 1,28 — достижения достаточной устойчивости. Изучение случайной выборки из 50 объектов позволяет отметить, что отклонение FS_0_1 от прогнозируемого значения в интервале от 1,5 до 2,0 не превышает значение средней ошибки 0,02–0,03, что вполне приемлемо (рис. 7).

Существенное отклонение от прогноза (превышающее 0,03–0,05) наблюдается для прогнозируемых значений FS_0_1 более 2–3, но в этом случае на расчет устойчивости склона это не влияет.

Использование бутстрап-метода позволяет оценить неопределенность предсказания,

опираясь на вариативность модели при разных обучающих выборках.

Для практического использования описанных выше результатов по оценке коэффициента устойчивости, опираясь на репрезентативный набор данных AutoML H2O (GBM) и полученные модели регрессии и классификации, было разработано интерактивное приложение RShiny, структура которого представлена на рис. 8 [21].

В результате была получена интерактивная аналитическая панель (дашборд) RShiny, которая позволяет запускать локальный кластер H2O и использовать модели регрессии и классификации, полученные в процессе машинного обучения с использованием машины градиентного бустинга H2O (GBM). В основной вкладке дашборда можно ввести параметры склона.

Если выбрать «Рассчитать» — запускается H2O-кластер, который позволяет, используя полученные ранее модели H2O (GBM), вычислить значение коэффициента устойчивости и вероятность того, что он будет меньше 1,0 или 1,28 (рис. 9).




Рис. 7. Доверительные интервалы прогноза FS_0_1 (95 %)

```

/Slope_Stability_ShinyApp      # Корень проекта
|
|-- app.R                      # Однофайловое приложение Shiny
|
|-- /data                     # Исходные данные
|   |-- df_concat.xls         # Исходный Excel файл с данными
|
|   |-- /models               # Папка с сохранёнными моделями H2O
|       |-- regression_model/GBM_model_R_1763363209191_1
|           # Папка с файлами модели регрессии
|
|       |-- classification_1_0_model/GBM_model_R_1763363209191_2
|           # Папка с моделью классификации P(FS_0_1 < 1,0)
|
|       |-- classification_1_28_model/GBM_model_R_1763363209191_2
|           # Папка с моделью классификации P(FS_0_1 < 1,28)
|
|-- /scripts                  # Скрипты для функций, обработки, предобработки
|   |-- bootstrap_analysis.R   # R-скрипт для бутстрап-анализа
|   |-- preprocess_data.R      # R-скрипт для подготовки данных
|
|-- /outputs                  # Итоговые результаты, графики, отчёты
|   |-- heatmap1.png          # Сохранённая визуализация (тепловая карта)
|   |-- final_report.pdf       # Итоговый отчёт
|
|-- bootstrap_predictions.rds  # Результаты бутстрап-анализа
|-- heatmap_dataset.rds       # Датасет для визуализации тепловых карт
|-- summary_metrics.rds       # Итоговые метрики качества моделей

```

Рис. 8. Структура папок для проекта RShiny с предобученными моделями H2O (GBM) и данными результатов обработки

Параметры склона

Угол склона (°):

10 — 35 — 85

Высота склона (м):

5 — 60

Сцепление (кПа):

1 — 18 — 70

Угол трения (°):

1 — 15 — 70

Объемный вес (кН/м³):

21

Угол дилатансии (°):

0

Рассчитать

Пример

Результаты анализа

1.174

Коэффициент устойчивости

РИСК

Статус устойчивости

Вероятностные показатели

Вероятность коэффициента устойчивости < 1.0:

1.1%

Вероятность коэффициента устойчивости < 1.28:

99.5%

Детальная интерпретация

Рис. 9. Вкладка интерактивной панели RShiny — «Оценка устойчивости склона»

Обсуждение

Развитие природообустройства как науки, обеспечивающей корректное использование природных ресурсов, ставит перед человеком новые задачи, связанные с оценкой и прогнозированием опасных природных явлений.

Оползневые процессы на склоновых ландшафтах относятся к часто встречающимся явлениям (если угол склона превышает 19° , а для глинистых грунтов — $5\text{--}7^\circ$) [16–20]. Поэтому предлагаемый подход является актуальным и важным — он позволяет при проведении маршрутных обследований быстро выявлять критические участки ландшафтов с точностью определения коэффициента устойчивости 0,01–0,03. В зависимости от вероятностной оценки степени оползневой опасности могут выводиться рекомендации по проведению мероприятий:

- рекомендуется регулярный мониторинг;
- рассмотреть профилактические мероприятия;
- ограничить строительную деятельность вблизи склона;
- провести дополнительный анализ при изменении условий и др.

Полученное приложение — интерактивная аналитическая панель¹ (дашборд) RShiny — может быть представлено в формате HTML, который доступен на смартфоне или планшете. Второй вариант — использование ноутбука с локальным кластером H2O для проведения расчетов с полученными ранее моделями H2O (GBM) и приложением RShiny с соответствующими библиотеками. Разработанный дашборд потенциально может быть представлен в виде исполняемого файла *.exe, который устанавливается на любой компьютер.

Выводы

Реализованный в настоящей статье подход — принятие решения о степени устой-

чивости оползневого склона на основе данных — является перспективным направлением современных исследований в природообустройстве. Оценка существующей или потенциальной степени опасности при проведении маршрутных обследований может быть упрощена и обоснована на базе использования интерактивных аналитических приложений, например, с использованием приложения RShiny.

Библиографический список

1. Кохендерфер М., Уилер Т., Рэй К. Алгоритмы принятия решений / пер. с англ. В. С. Яценкова. М.: ДМК Пресс, 2023. 684 с.
2. Nayek P. S., Gade M. Artificial neural network-based fully data-driven models for prediction of newmark sliding displacement of slopes // *Neural Computing & Applications*. 2022. Vol. 34 (11). Pp. 9191–9203.
3. Yadav D. K., Chattopadhyay S., Tripathy D. P., Mishra P., Singh P. Enhanced slope stability prediction using ensemble machine learning techniques // *Scientific Reports*. 2025. Vol. 15 (1). 7302.
4. Lin Sh., Zheng H., Han Ch., Han B., Li W. Evaluation and prediction of slope stability using machine learning approaches // *Frontiers of Structural and Civil Engineering*. 2021. Vol. 15 (4). Pp. 821–833.
5. Lei D., Zhang Ya., Lu Zh., Lin H., Fang B., Jiang Zh. Slope Stability Prediction Using Principal Component Analysis and Hybrid Machine Learning Approaches // *Applied Sciences (Switzerland)*. 2024. Vol. 14 (15). 6526.
6. Mahmoodzadeh A., Mohammadi M., Hawkar Hashim Ibrahim, Krikar M Gharrib Noori, Sazan Nariman Abdulhamid, Hunar Farid Hama Ali. Forecasting sidewall displacement of underground caverns using machine learning techniques // *Automation in Construction*. 2021. Vol. 123. 103530.
7. Yang H. Q., Zhang L., Pan Q., Phoon K.-K., Shen Zh. Bayesian estimation of spatially varying soil parameters with spatiotemporal monitoring data // *Acta Geotechnica*. 2021. Vol. 16 (11). Pp. 263–278.
8. He X., Xu H., Sabetamal H., Sheng D. Machine learning aided stochastic reliability analysis of spatially variable slopes // *Computers and Geotechnics*. 2020. Vol. 126. 103711.
9. Wei X., Zhang Lulu, Yang H. Q., Zhang Limin, Yao Ya.-P. Machine learning for pore-water pressure time-series prediction: Application of recurrent neural networks // *Geoscience Frontiers*. 2021. Vol. 12 (1). Pp. 453–467.

¹ Интерактивная аналитическая панель реагирует на действия пользователя (проводит расчеты и выводит результаты), информационная панель отражает только результаты мониторинга.

10. Yuan Ch., Moayedi H. Evaluation and comparison of the advanced metaheuristic and conventional machine learning methods for the prediction of landslide occurrence // *Engineering with Computers*. 2020. Vol. 36 (4). Pp. 1801–1811.
11. Yang Yu., Zhou W., Jiskani I. M., Lu X., Wang Zh., Luan B. Slope Stability Prediction Method Based on Intelligent Optimization and Machine Learning Algorithms // *Sustainability*. 2023. Vol. 15 (2). 1169.
12. Meng J., Mattsson H., Laue J. Three-dimensional slope stability predictions using artificial neural networks // *International Journal for Numerical and Analytical Methods in Geomechanics*. 2021. Vol. 45 (13). Pp. 1988–2000.
13. 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). Pp. 426–453.
14. Tun S. H., Zeng Ch., Jamil F. Prediction of slope stability based on five machine learning techniques approaches: a comparative study // *Multiscale and Multidisciplinary Modeling, Experiments and Design*. 2025. Vol. 8 (5). 224.
15. Mahmoodzadeh A., Mohammadi M., Hunar Farid Hama Ali, Hawkar Hashim Ibrahim, Sazan Nariman Abdulhamid, Nejati H. Prediction of safety factors for slope stability: comparison of machine learning techniques // *Natural Hazards*. 2022. Vol. 111 (3). Pp. 1771–1799.
16. Мацый С. И., Мацый В. С. Инженерная защита объектов от склоновых процессов. Краснодар: КубГАУ, 2023. 520 с.
17. Ламердонов З. Г., Хаширова Т. Ю., Журикова И. А. Способы расчета и усиления проволочных анкерных систем, устройства для их установки // *Мелиорация и гидротехника*. 2025. Т. 15, № 1. С. 232–245.
18. Ламердонов З. Г., Журикова И. А., Хаширова Т. Ю. Экспериментальные исследования комбинированных анкеров и варианты их практического применения // *Природообустройство*. 2024. № 2. С. 63–68.
19. Мацый С. И., Кацко Д. И. Вероятностные расчеты устойчивости оползневого склона // *Геориск*. 2021. Т. 15, № 3. С. 8–22.
20. Калинин Э. В., Кропоткин М. П. Методы расчета устойчивости склонов и откосов: российские подходы в сопоставлении с мировыми тенденциями // *Инженерная геология*. 2022. Т. XVII, № 4. С. 22–38.
21. Уикхем Х. Изучаем Shiny / пер. с англ. А. Ю. Гинько. М.: ДМК Пресс, 2022. 374 с.
- from English by Yatsenkov V. S. Moscow, DMK Press Publ., 2023, 684 p.
2. Nayek P. S., Gade M. Artificial neural network-based fully data-driven models for prediction of newmark sliding displacement of slopes. *Neural Computing & Applications*, 2022, vol. 34 (11), pp. 9191–9203.
3. Yadav D. K., Chattopadhyay S., Tripathy D. P., Mishra P., Singh P. Enhanced slope stability prediction using ensemble machine learning techniques. *Scientific Reports*, 2025, vol. 15 (1), 7302.
4. Lin Sh., Zheng H., Han Ch., Han B., Li W. Evaluation and prediction of slope stability using machine learning approaches. *Frontiers of Structural and Civil Engineering*, 2021, vol. 15 (4), pp. 821–833.
5. Lei D., Zhang Ya., Lu Zh., Lin H., Fang B., Jiang Zh. Slope Stability Prediction Using Principal Component Analysis and Hybrid Machine Learning Approaches. *Applied Sciences (Switzerland)*, 2024, vol. 14 (15), 6526.
6. Mahmoodzadeh A., Mohammadi M., Hawkar Hashim Ibrahim, Krikar M Gharrib Noori, Sazan Nariman Abdulhamid, Hunar Farid Hama Ali. Forecasting sidewall displacement of underground caverns using machine learning techniques. *Automation in Construction*, 2021, vol. 123, 103530.
7. Yang H. Q., Zhang L., Pan Q., Phoon K.-K., Shen Zh. Bayesian estimation of spatially varying soil parameters with spatiotemporal monitoring data. *Acta Geotechnica*, 2021, vol. 16 (11), pp. 263–278.
8. He X., Xu H., Sabetamal H., Sheng D. Machine learning aided stochastic reliability analysis of spatially variable slopes. *Computers and Geotechnics*, 2020, vol. 126, 103711.
9. Wei X., Zhang Lulu, Yang H. Q., Zhang Limin, Yao Ya.-P. Machine learning for pore-water pressure time-series prediction. Application of recurrent neural networks. *Geoscience Frontiers*, 2021, vol. 12 (1), pp. 453–467.
10. Yuan Ch., Moayedi H. Evaluation and comparison of the advanced metaheuristic and conventional machine learning methods for the prediction of landslide occurrence. *Engineering with Computers*, 2020, vol. 36 (4), pp. 1801–1811.
11. Yang Yu., Zhou W., Jiskani I. M., Lu X., Wang Zh., Luan B. Slope Stability Prediction Method Based on Intelligent Optimization and Machine Learning Algorithms. *Sustainability*, 2023, vol. 15 (2), 1169.
12. Meng J., Mattsson H., Laue J. Three-dimensional slope stability predictions using artificial neural networks. *International Journal for Numerical and Analytical Methods in Geomechanics*, 2021, vol. 45 (13), pp. 1988–2000.
13. 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), pp. 426–453.

References

1. Kokhenderfer M., Uiler T., Rey K. *Algoritmy prinyatiya resheniy* [Decision making algorithms]. Transl.

14. Tun S. H., Zeng Ch., Jamil F. Prediction of slope stability based on five machine learning techniques approaches: a comparative study. *Multiscale and Multidisciplinary Modeling, Experiments and Design*, 2025, vol. 8 (5), 224.

15. Mahmoodzadeh A., Mohammadi M., Hunar Farid Hama Ali, Hawkar Hashim Ibrahim, Sazan Nariman Abdulhamid, Nejati H. Prediction of safety factors for slope stability: comparison of machine learning techniques. *Natural Hazards*, 2022, vol. 111 (3), pp. 1771–1799.

16. Matsiy S. I., Matsiy V. S. *Inzhenernaya zashchita ob"ektov ot sklonovykh protsessov* [Engineering protection of objects from slope processes]. Krasnodar, KubGAU Publ., 2023, 520 p

17. Lamerdonov Z. G., Khashirova T. Yu., Zhirikova I. A. *Sposoby rascheta i usileniya provolochnykh ankernykh sistem, ustroystva dlya ikh ustanovki* [Methods of calculation and reinforcement of wire anchor systems, devices for their installation]. *Melioratsiya i gidrotekhnika – Melioration and hydraulic engineering*, 2025, vol. 15, no. 1, pp. 232–245.

18. Lamerdonov Z. G., Zhirikova I. A., Khashirova T. Yu. *Eksperimental'nye issledovaniya kombinirovannykh ankerov i varianty ikh prakticheskogo primeneniya* [Experimental studies of combined anchors and options for their practical application]. *Prirodoobustroystvo – Environmental management*, 2024, no. 2, pp. 63–68.

19. Matsiy S. I., Katsko D. I. *Veroyatnostnye raschety ustoychivosti opolzneвого sklona* [Probabilistic calculations of landslide slope stability]. *Georisk – Georisk*, 2021, vol. 15, no. 3, pp. 8–22.

20. Kalinin E. V., Kropotkin M. P. *Metody rascheta ustoychivosti sklonov i otkosov: rossiyskie podkhody v sopostavlenii s mirovymi tendentsiyami* [Methods for calculating the stability of slopes and slopes: Russian approaches in comparison with world trends]. *Inzhenernaya geologiya – Engineering Geology*, 2022, vol. XVII, no. 4, pp. 22–38.

21. Uikkhem Kh. *Izuchaem Shiny* [Studying Shiny]. Transl. From English by Gin'ko A. Yu. Moscow, DMK Press Publ., 2022, 374 p.