



ЗРГИМ

XV^{TO} СТРУЧНО СОВЕТУВАЊЕ НА ТЕМА:
Технологија на подземна и површинска експлоатација на
минерални сировини

ПОДЕКС – ПОВЕКС '24

Струга
18 – 20. 10. 2024 год.

ПРИМЕНА НА ML ПРИ ПРОЦЕНКА НА ГЕОТЕХНИЧКА СТАБИЛНОСТ НА КОСИНИ НА ПОВРШИНСКИ КОПОВИ

Зоран Панов¹, Душан Биков², Радмила Каранакова Стефановска¹

¹Факултет за природни и технички науки, Универзитет „Гоце Делчев“, Штип,
Северна Македонија

²Факултет за информатика, Универзитет „Гоце Делчев“, Штип, Северна
Македонија

Апстракт: Овој труд претставува концептуален пристап за користење на машинско учење (ML) како алатка во рамките на вештачката интелигенција за проценка на геотехничката стабилност на површинските копови. Методологијата се заснова на алгоритам кој ги пресметува параметрите за стабилност на косините, наместо некои од традиционални методи на гранична рамнотежа. Пристапот користи Python софтвер со библиотеката PyTorch за развој на модели. Моделот се фокусира на оптимизирање на вредностите за аголот на косините (етажен и завршен агол на површинскиот коп) како и минималната ширина на етажите. Овој метод обезбедува нова перспектива за проценка на стабилноста на косините со интегрирање на техниките за машинско учење со традиционалните геотехнички пресметки. Развиениот пристап нуди иновативен начин за справување со различни геотехнички предизвици, особено во контекст на оптимизирање на стабилноста на косините на етажите при површинската експлоатација.

Клучни зборови: ML, површински копови, етажи, косини, широчина на етажа, оптимизација

APPLICATION OF ML IN ESTIMATING OF GEOTECHNICAL SLOPE STABILITY IN OPEN PIT MINES

Zoran Panov¹, Dushan Bikov², Radmila Karanakova Stefanovska¹

¹Faculty of Natural and Technical Sciences, Goce Delcev University, Stip, North Macedonia

²Faculty of Computer Science, Goce Delcev University, Stip, North Macedonia

Abstract: This paper presents a conceptual approach to using machine learning (ML) as a tool within artificial intelligence for assessing the geotechnical stability of surface mines. The methodology is based on an algorithm that calculates slope stability parameters, rather than the traditional Bishop boundary equation method. The approach employs Python software and utilizes the PyTorch library for model development. The ML model in this study focuses on optimizing values for the slope angle and the minimum width of the benches, as well as other geotechnical parameters. This method provides a new perspective on slope stability assessment by integrating machine learning techniques with traditional geotechnical calculations. The developed approach offers an innovative way to address various geotechnical challenges, particularly in the context of optimizing slope stability in surface mining operations.

Key Words: ML, open pit mines, ML, bench, slope, bench width, optimization

1. ВОВЕД

Стабилноста на косините во површинските копови е критичен фактор за обезбедување безбедност и ефикасност на рударските операции. Традиционалните методи за проценка на геотехничката стабилност често се потпираат на емпириски формули, методи на гранична рамнотежа и обемни податоци од теренот. Сепак, овие методи може да се ограничат со нивната зависност од веќе постоечките податоци и нивната способност да се прилагодат на сложени и динамични геотехнички услови.

Неодамнешниот напредок во машинското учење (ML) нуди нови начини за подобрување на проценките на стабилноста на косините. ML алгоритмите, даваат можност да се анализираат огромни бази на податоци и да се применат релативно сложени пресметки. Ново развиените пристапи со примена на ML, потенцијално можат да ја подобрат веродостојноста на геотехничката проценка на стабилност на косините со оптимизирање на нејзините параметри. Интеграцијата на ML во рударството од аспект на геотехничкото инженерство претставува значителна промена од традиционалните пристапи, кон нови вклучувајќи примена на вештачката интелигенција во проценките на стабилноста на косините.

2. МЕТОДОЛОГИЈА

Во трудот е интегрирано машинското учење (ML) со традиционалните геотехнички методи за проценка на стабилноста на косината. Основниот концепт на овој пристап се заснова на методите на гранична рамнотежа, кои се широко користена за проценка на стабилноста на косините поради нејзината ефикасност за вклучување на различните фактори кои влијаат врз стабилноста на косините [10]. Но во трудот се користат принципи слични на оние што се наоѓаат во анализата на стабилноста на косините, но не е искористен директно методот на Бишоп [1]. Наместо тоа, следи прилагоден пристап за пресметување на параметрите за стабилност на косините, кој вклучува проектирање на етажните агли и генералниот агол, пресметување на силите и одредување на факторот на безбедност врз основа на овие пресметки. Методот на гранична равенка на Bishop е пристап на гранична рамнотежа што се користи за анализа на стабилноста на косините со пресметување на факторот на сигурност (F_s). Овој метод претпоставува дека површината на клизната површина е кружна и ги проценува отпорните сили наспроти движечките сили [2] и [10]. Овој метод е едноставен и ефективен во различни геотехнички услови [3]. Модифицираниот пристап во трудот се базира на проценка на геотехничката стабилност на косините со помош на равенки кои се поврзани со геометријата на косината, силите на смолкнување и нормалните сили. Во продолжение се дадени равенките за проценка на стабилноста на косините кои ќе бидат користени во овој модел.

Пресметката на генералниот агол на косината (β) на површинскиот коп е аголот кој е формиран како заеднички агол со вклучени проекции на секој етажен агол и сите опфатени берми на етажите, односно:

$$\beta = \arctan\left(\frac{H}{n(b+x)}\right) \quad (1)$$

Каде:

x – проекција на етажната косина на x оската и
n – број на етажи,
b - ширина на етажа (берма),

Силата на смолкнување е составена од две компоненти: кохезија и тежина на средината. Во основа ова е силата кое го спречува смолкнувањето на косината, т.е. ја држи во стабилна состојба. Се пресметува како:

$$\sigma_s = c A + \gamma H \sin(\alpha) \cos(\alpha) \quad (2)$$

Каде:

c – кохезија,
 γ - зафанинска тежина во природна состојба,
A – проекција на контактната површина на етажата, $A = b x$
H - висина (длабина) на површинскиот коп и
 α - етажен агол (работен или завршен).

Нормалната сила е онаа која сака да ја дестабилизира косината, а зависи од притисокот на средината врз контактната површина на етажата. Односно:

$$\sigma_N = \gamma b H \sin(\alpha) \quad (3)$$

Факторот на сигурност го претставува односот помеѓу силата на смолкнување и нормалната сила и е главен показател за стабилноста на косината:

$$F_s = \frac{\sigma_s}{\sigma_N(1-\tan(\varphi))} \quad (4)$$

Каде:

φ – агол на внатрешно триење.

Со попош на претходно прикажата процедура за пресметка на геотехничката стабилност е развиен модел со примена на ML (машинско учење, сл. 1).

3. ML МОДЕЛ ЗА ПРОЦЕНКА НА СТАБИЛНОСТА НА КОСИНТЕ

ML моделот користен во овој труд е развиен со користење на Python и библиотеката PyTorch. Користењето на библиотеката PyTorch е избрана поради нејзината флексибилност и ефикасност во решавањето на задачите за ML и DL (eng. deep learning, длабоко учење) [11]. Библиотеката PyTorch го олеснува развојот и обуката на моделот на невронска мрежа, обезбедувајќи поддршка за автоматска диференцијација и оптимизација [11]. Развојот на овој ML моделт ги вклучува следните чекори:

Собирање или генерирање на податоци: Генерирана е база на податоци што се состои од геотехнички параметри, податоци за стабилноста на косините и геотехнички проценки. Податоците треба претходно да се обработат за да ги моделираат вредностите што недостасуваат, како и да се нормализираат карактеристиките со поделба на сетови за обука и тестирање [2].

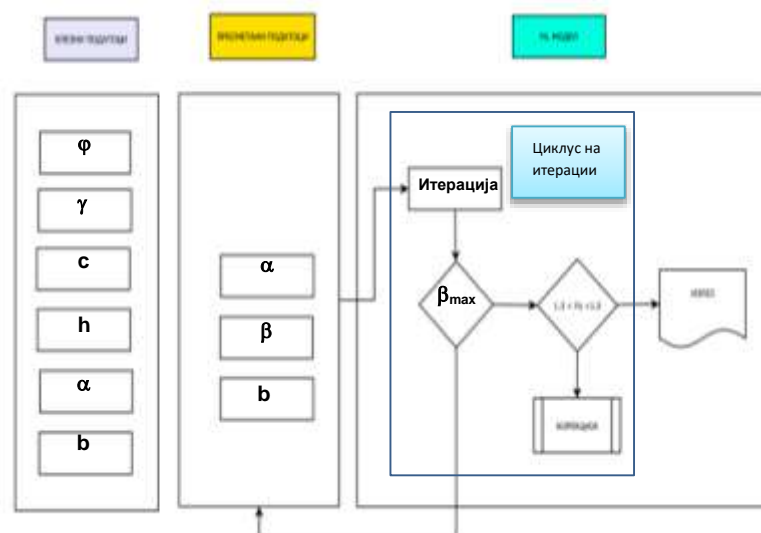
Избор на карактеристики: Релевантните карактеристики кои влијаат на стабилноста на косините, како што се својствата на средината (карпи и почви), геометријата на косините, појавените пукнатини, нивоата на на подземните води

и др., се избираат врз основа на знаењето за реалниот модел за кој е наменета анализата на зависности [2] [8].

Обука и валидација на моделот: Архитектурата на невронска мрежа е дизајнирана со користење на библиотеката PyTorch. Моделот е потврден со помош на техники за вкрстена валидација со цел обезбедување на неговата робусност и генерализираност. Процесот на т.н. учење (обука) вклучува прилагодување на хиперпараметрите и примена на техники како што се „регулација“ на отстапувањата и дефинирање на истите, со цел да се спречи „преоптоварување“ на моделот [9]

Оптимизација: ML моделот (сл. 1) се користи за оптимизирање на критичните параметри, вклучувајќи го етажниот агол и минималната широчина на етажата (берма). Процесот на оптимизација има за цел да го максимизира генералниот агол на површинскиот коп а со тоа да ги минимизирање на трошоците за ископување и одржување на оперативната ефикасност на рудникот. При тоа факторот на сигурност (F_s) е ограничен со максимална и минимална вредност кое е во интервал од ($F_s = (1.3, 1.5)$). Ова значи дека основната цел е да се избере модел кој ќе ги задоволува условите за стабилност ($F_s > 1.3$), но нема да биде „непотребно“ сигурен со преголеми вредности за ($F_s > 1.5$). Преголеми вредности на факторот на сигурност ($F_s \gg 1.3$) ќе предизвика можност за дефинирање на релативно мал генерален агол на косините на површинскиот коп а со тоа и преголеми маси за ископ.

Евалуација: Перформансите на ML моделот се оценуваат врз основа на неколку метрики: прецизност, губитоци и резултат. Евалуацијата вклучува споредување на предвидувањата на моделот со традиционалните методи и проценка на неговата ефикасност во различни геотехнички сценарија. Резултатите се анализирани за да се одреди веродостојноста и применливоста на моделот во практични рударски примени. Ова значи, дали резултатот за оптималните вредности за берма, етажен и генерален агол треба да се во интервал на очекуваните вредности според искуствата во рударската пракса.



Слика 1. Блок дијаграм на ML моделот

ML моделот е имплементиран со користење на Python, со дополнителни библиотеки како што се NumPy [6] за нумерички пресметки и Matplotlib [5] за визуелизација на податоците.

Во моделот една итерација претставува една обука, односно еден циклус на обработка на сите податоци кои се користат за пресметка во моделот. Целата „обука“ на моделот вклучува повеќе од една итерација на учење со цел постигнување подобра прецизност и оптимизирање на параметрите на моделот. Ова значи за секоја итерација, моделот се обидува да ја минимизира разликата помеѓу предвидените и реалните вредности со оптимизирање на параметрите [7]. Тоа значи дефинирање на отстапувања (корекции или губитоци) - разлики на претходна со идна вредност. Со отстапувањето се корегираат параметрите на моделот, со цел да се постигне подобра прецизност (слика 1). По завршувањето на предвидените 200 итерации на обука, се избира моделот кој дава најдобри резултати. Функцијата на цел е избор на варијанта со минимален генерален агол на косините на површинскиот коп (β_{\min}). Предноста на оваа методологија е таа што веќе за секоја наредна итерација моделот ги има веќе „изучено“ отстапувањата и истите ги валоризира во сетови од по 10 итерации на обуки, што за вкупен број од 200 итерации на обуки, генерира 20 сета по модел. Конкретно, оптимизацијата на моделот се врши со дефинирање на варијатни решенија (модели) со почетни вредности на етажниот агол од 45° , па се до 70° , со чекор од 1 степен. Во исто време почетната вредност на широчината на етажната берма е од 7.5 m. Односно, широчината на етажната берма е во интервал од 7.5 m до 12.5 метри. Овие два интервала во основа се и интервали на доверба (можни решенија од моделирањето). Според условите ќе има вкупно 26 модели, односно модел 1 – со почетен етажен агол (α) од 45° , модел 2 со 46° , па се до модел 26 кои има почетна вредност на етажниот агол од 70° .

5. РЕЗУЛТАТИ И ДИСКУСИЈА

ML моделот е тестиран со избор на влезни податоци со кои би се добиле информации кои би послужиле за компарација со реалните. Со нив ќе ја оцениме точност на излезните резултати од примената на ML моделот. Во продолжение се дадени генерално два примера:

Пример 1

- кохезија $c = 500$ kPa,
- агол на ватрешно триење $\varphi = 25^\circ$ и
- зафатнински тежина во природна состојба $\gamma = 25$ kN/m³

Пример 2

- кохезија $c = 700$ kPa
- агол на ватрешно триење $\varphi = 30^\circ$ и
- зафатнински тежина во природна состојба $\gamma = 25$ kN/m³

Како еден од моделите за пример 1, од вкупно 26 – те модели (модел 1 за почетен етажен агол (α) од 45° , па се до последниот 26 – ти модел за агол од 70° . е избран 21 – тиот со етажен агол од 65° . Резултатите од примената на ML за овој модел се дадени во табела 1.


Табела 1. Резултати од ML оптимизацијата (пример 1, модел 21)

Бр, на сет	Итерација на обука		Корекција	a	b	b	Fs
	од	до		°deg	m	°deg	
1	1	10	0.447530746	64.42705	9.74000	41.85431	0.85247
2	11	20	0.162266374	58.65222	9.63918	38.91722	1.13773
3	21	30	0	53.71579	9.55325	36.27678	1.45797
4	31	40	0	54.29582	9.56050	36.33163	1.45104
5	41	50	0	55.19839	9.57449	36.84011	1.38429
6	51	60	0	55.54985	9.57994	37.03818	1.35908
7	61	70	0	55.68478	9.58203	37.11430	1.34951
8	71	80	0	55.73591	9.58282	37.14317	1.34589
9	81	90	0	55.75509	9.58312	37.15401	1.34454
10	91	100	0	55.76222	9.58323	37.15805	1.34403
11	101	110	0	55.76485	9.58327	37.15953	1.34385
12	111	120	0	55.76582	9.58329	37.16008	1.34378
13	121	130	0	55.76618	9.58329	37.16028	1.34375
14	131	140	0	55.76631	9.58329	37.16036	1.34374
15	141	150	0	55.76635	9.58329	37.16039	1.34374
16	151	160	0	55.76637	9.58329	37.16040	1.34374
17	161	170	0	55.76637	9.58329	37.16040	1.34374
18	171	180	0	55.76637	9.58329	37.16040	1.34374
19	181	190	0	55.76637	9.58329	37.16040	1.34374
20	191	200	0	55.76637	9.58329	37.16040	1.34374

Според табела 1 веќе од 151 – та итерација на обука, моделот е оптимизиран и вредностите на α , b и β конвергираат кон вредностие 55.77° , 9.6 m и 37.16° , соодветно. Факторот на сигурност е 1.34. Овие вредности се оптимални за овој модел.

Како еден од моделите за пример 2, од вкупно 26 – те модели (модел 1 за почетен етажен агол (α) од 45° , па се до последниот 26 – ти модел за агол од 70° . е избран 15 – тиот со етажен агол од 59° . Резултатите од примената на ML за овој модел се дадени во табела 2.

Дијаграмите на оптимизирање на вредноста на те на факторот на сигурност во однос на бројот на итерациите на обуки за пример 1 и 2 се дадени на слика 2и3.




Слика 2. Фактор на сигурност во функција на бројот на итерации на обуки за пример 1, модел 21

Табела 2. Резултати од ML оптимизацијата (пример 2, модел 15)

Бр. на сет	Итерација на обука		Корекција	a	b	b	Fs
	од	до		°deg	m	°deg	
1	1	10	0.482556224	59.57296	9.76000	38.64058	1.98256
2	11	20	0	65.18737	9.85809	41.51612	1.48941
3	21	30	0.025910616	67.51135	9.89906	42.99251	1.27409
4	31	40	0	66.26224	9.87832	42.36039	1.36326
5	41	50	0	65.74369	9.86969	42.06898	1.40571
6	51	60	0	65.54179	9.86633	41.95550	1.42247
7	61	70	0	65.46427	9.86504	41.91190	1.42895
8	71	80	0	65.43489	9.86455	41.89536	1.43141
9	81	90	0	65.42387	9.86437	41.88915	1.43233
10	91	100	0	65.41976	9.86430	41.88683	1.43268
11	101	110	0	65.41826	9.86428	41.88598	1.43281
12	111	120	0	65.41771	9.86427	41.88567	1.43285
13	121	130	0	65.41751	9.86427	41.88556	1.43287
14	131	140	0	65.41743	9.86427	41.88551	1.43288
15	141	150	0	65.41742	9.86427	41.88550	1.43288
16	151	160	0	65.41742	9.86427	41.88550	1.43288
17	161	170	0	65.41742	9.86427	41.88550	1.43288
18	171	180	0	65.41742	9.86427	41.88550	1.43288
19	181	190	0	65.41742	9.86427	41.88550	1.43288
20	191	200	0	65.41742	9.86427	41.88550	1.43288

Според табела 2 од 141 – та итерација на обука, моделот е оптимизиран и вредностите на α , b и β конвергираат кон вредностие 65.42° , 9.9 m и 41.89° , соодветно. Факторот на сигурност е 1.43. Овие вредности се оптимални за овој модел.

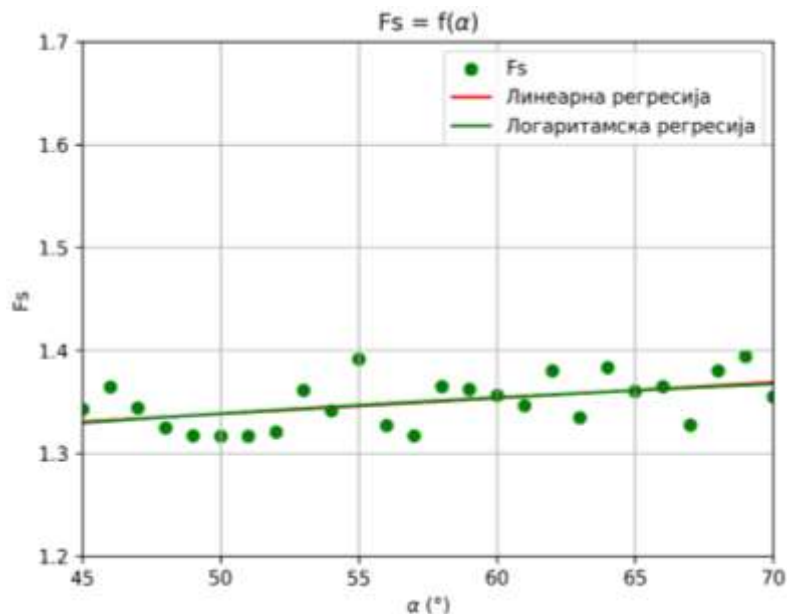


Слика 3. Фактор на сигурност во функција на бројот на итерации на обуки за пример 2, модел 15

Анализата на резултатите од табела 1 и 2, покажува дека оптимизацијата направена со примена на ML моделот дава можност за добивање на релативно веродостојни податоци (вредности споредени според претходни искуствени податоци од примена на методите на гранична рамнотежа). Секако, примената


на методите на гранична рамнотежа дава посигурни и поточни резултати. Но, можноста за нивно оптимизирање е речиси и незводливо.

За да се добие прва почетна пресметка на факторот на сигурност со одредени влезни параметри е потребна посложена постапка со примена на соодветни софтверски решенија. Ако резултатите од геотехничката анализа не ги задоволуваат планираните услови треба да се продолжи итеративно со промена на некои од влезните параметри. На пример, ако итерацијата е со пресметан фактор на сигурност F_s изразито поголем од 1.3, потребно е ново редифинирање на влезот и нова постапка (итерација). Постапката би одела понатаму се додека донесителот на одлуката не заклучи дали добиените вредности се оптимални за него и дали истите ќе ги усвои. Оптимизација во ваков случај има голема субјективност поради вклучувањето во одлучувањето на донесителот на одлуката. За разлика од класичниот пристап, пристапот со примена на ML дава можност за потполно автоматизирана оптимизација на одредувањето на вредностите на основните параметри во функција на задоволување на факторот на сигурност и тоа во даден интервал. Со ова во исто време се максимизира генералниот агол на косините на површинскиот коп. Колку овој агол е поголем толку и количините на јаловина ќе бидат помали а со тоа и ќе се минимизираат и трошоците за експлоатација. На наредните слики (слика 4 и 5) се дадени дијаграмите на функционалните зависимости на добиените оптимални вредности за пример 1. Дијаграмите се креирани во Python со користење на библиотеката matplotlib и користење на библиотеката numpy (линеарна и логаритамска регресија).



Слика 4. Дијаграм на зависност на $F_s = f(\alpha)$

На слика 4 е прикажана зависноста на факторот на сигурност (F_s) од оптимизирани вредности на етажниот агол (α). Според дијаграмот се гледа дека минимизирани вредности на факторот на сигурност благо се зголемуваат со зголемување на етажниот агол.



Слика 5. Дијаграм на зависност на $\beta = f(\alpha)$

Најсликовит приказ е даден ан сл. 5. Овде е прикажана зависноста на генералниот агол (β) во функција на етажниот агол (α), при исполнување на условите за стаилност на косините на површинскиот коп. Со зголемување на оптималните вредности на етажниот агол речиси линеарно се зголемува генералниот агол на косините на површинскиот коп.

Најзначаен е фактот што според дијаграмот на сл. 4, факторот на сигурност е минимизиран на вредности од 1.3 – 1.4 што е речиси „идеализирана“ планирана состојба која ќе го максимизира генералниот агол на површинскиот коп. Очигледно е дека примената на машинското учење дава добри резултати, по изведување на 100 – ци итеративни обуки. Според досегашните искуства од примената на современи софтверски решенија за геотехнички анализи со користење на методите на гранична рамнотежа, многу тешко или речиси неизводливо е да се дојде до овој степен на оптимизирање на вредноста на факторот на сигурност во релативно мал интервал (1.3 – 1.5).

6. ЗАКЛУЧОК

Во овој труд е разработен концептуален пристап за примената на машинско учење (ML) како алатка за проценка на геотехничката стабилност на косините во површинските копови. Во трудот се користи методологија заснована на методот на гранична рамнотежа со алгоритам и скрипта во Python со вклучување на функции од PyTorch библиотеката. Со примената на техниката за машинско учење, можеме да ги оптимизираме критичните параметри како што се етажните агли и генералниот агол на површинскиот коп и широчината на бермите, а со тоа да ја подобриме целокупната стабилност и безбедност на операциите на површинскиот копови од една страна и да добиеме минимизирање на количините на јаловината, од друга страна.

Целите на овој труд се двојни: прво, да се демонстрира изводливоста за интегрирање на ML со традиционалните геотехнички методи и второ, да се обезбеди пристап за примена на ML за проблемите со стабилноста на косините во геотехниката. Преку овој пристап, се придонесува во развојот на полето на геотехничкото инженерство и се добиваат нови сознанија за оптимизирање на основната геометрија на површинските копови. Анализата на резултатите од

примената на ML моделот покажа дека примената е можна и веродостојна. Предностите на оваа методологија се состојат и во автономната работа без интервенции и одлучувања од страна на носителот на одлуките. Самиот алгоритам на ML преку предвидените техники на неуронските мрежи, доаѓа до автоматски избор на оптимални решенија. Со ова, субјективноста во донесувањето на одлуките речиси е во целост минимизирана. Не добро дефинирани модели на ML водат кон дивергентни решенија кои навидум можат да направат и забуна со добивање на речиси сомнителни решенија.

КОРИСТЕНА ЛИТЕРАТУРА

- [1] Bishop, A.W. (1955) The Use of the Slip Circle in the Stability Analysis of Slope. *Geotechnique*, 10, 129-150. <https://doi.org/10.1680/geot.1955.5.1.7>
- [2] Chollet, F. (2018). *Deep Learning with Python*. Manning Publications.
- [3] Fredlund, D. G., & Rahardjo, H. (1993). *Soil Mechanics for Unsaturated Soils*. Wiley.
- [4] Guyon, I., & Elisseeff, A. (2003). An introduction to variable and feature selection. *Journal of Machine Learning Research*, 3, 1157-1182.
- [5] Hunter, J. D. (2007). Matplotlib: A 2D graphics environment. *Computing in Science & Engineering*, 9(3), 90–95.
- [6] Harris, C.R., Millman, K.J., van der Walt, S.J. et al. Array programming with NumPy. *Nature* 585, 357–362 (2020). <https://doi.org/10.1038/s41586-020-2649-2>
- [7] Hashim, Sabih. (2024). Prediction of rock slope failure using multiple ML algorithms. *Geomechanics and Engineering*. 36. 489-509. 10.12989/gae.2024.36.5.489.
- [8] Kurnaz, T.Fikret & Erden, Caner & Dağdeviren, Uğur & Demir, Alparslan & Kökçam, Abdullah. (2024). Comparison of machine learning algorithms for slope stability prediction using an automated machine learning approach. *Natural Hazards*. 120. 1-24. 10.1007/s11069-024-06490-8.
- [9] Mishra, Chandrasahas & Gupta, D.. (2017). Deep Machine Learning and Neural Networks: An Overview. *IAES International Journal of Artificial Intelligence (IJ-AI)*. 6. 66. 10.11591/ijai.v6.i2.pp66-73.
- [10] Панов, З. (2011), *Механика на карпи*, учебник, Универзитет „Гоце Делчев“ – Штип, Штип
- [11] Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., et. al. (2019). PyTorch: An Imperative Style, High-Performance Deep Learning Library. In *Advances in Neural Information Processing Systems* 32 (pp. 8024–8035). Curran Associates, Inc.