

УПРАВЛІННЯ В ТЕХНІЧНИХ СИСТЕМАХ

CONTROL IN TECHNICAL SYSTEMS

DOI: 10.20998/2079-0023.2025.02.03

УДК 004

Р. Р. ЛАВЩЕНКО, магістр комп'ютерних наук, аспірант, Національний технічний університет «Харківський політехнічний інститут», м. Харків, Україна; e-mail: ruslan.lavshchenko@infiz.khpi.edu.ua; ORCID: <https://orcid.org/0009-0001-3649-1118>

Г. І. ЛЬВОВ, доктор технічних наук, професор кафедри математичного моделювання та інтелектуальних обчислень в інженерії (MMI), Національний технічний університет «Харківський політехнічний інститут», м. Харків, Україна; e-mail: lvovdpm@ukr.net; ORCID: <https://orcid.org/0000-0003-0297-9227>; ORCID: <https://orcid.org/0000-0003-0297-9227>

DATA-DRIVEN ПІДХІД ДЛЯ ПРОГНОЗУВАННЯ МЕЖІ МІЦНОСТІ КОМПОЗИТІВ

Стрімкий розвиток композитів вимагає точного прогнозування їх граничного стану за умов складного навантаження, що неможливо забезпечити класичними механічними критеріями через анізотропію й нелінійність матеріалів. У роботі запропоновано data-driven підхід із використанням машинного навчання для визначення граничного стану композитів на основі компонентів тензора напружень. Об'єктом дослідження є процеси машинного навчання для визначення граничних станів композитів з односпрямованим армуванням при багатівісному напруженому стані. Було згенеровано збалансовані синтетичні вибірки напружених станів для трьох композитних систем. У рамках дослідження реалізовано декілька моделей машинного навчання: логістичну регресію, випадковий ліс (Random Forest) та багатослову перцептронну неймережу. Для порівняння ефективності було також використано класичну модель визначення граничного стану за критерієм Мізеса для волокон або матриці з фіксованим порогом еквівалентного напруження. Результати свідчать, що моделі машинного навчання досягають точності до 99,9 % на тестових вибірках, суттєво переважаючи класичний підхід, який демонструє точність близько 50 % у всіх випадках. Візуалізація розподілу граничних станів у просторі компонентів тензора напружень показала складну та нелінійну структуру межі міцності, що підтверджує доцільність використання ML-алгоритмів. Отримані результати підтверджують високу ефективність і надійність data-driven підходу для задач технічної діагностики композитних конструкцій. Розроблена методика є універсальною та може бути адаптована для різних типів армованих матеріалів і умов навантаження. Запропонований підхід може бути застосований у задачах технічної діагностики композитних конструкцій в реальному часі. Робота також створює підґрунтя для подальшого впровадження інтерпретованих моделей і цифрових двійників у галузі композитної механіки.

Ключові слова: data-driven підхід, композити, граничні стани, напруження, машинне навчання, Random Forest, Logistic Regression.

Вступ. У сучасному світі інженерні матеріали повинні відповідати все жорсткішим вимогам до міцності, надійності та довговічності. Композити, зокрема волокнисті полімерні композитні матеріали (FRC), займають провідне місце серед конструкційних матеріалів. Це зумовлено поєднанням високої питомої міцності, стійкості до корозії та можливості спрямованого проектування властивостей [1]. Такі матеріали широко використовуються в авіації, автомобілебудуванні, суднобудуванні, енергетиці та біомедичній інженерії [2]. Проте, розширення сфер їх застосування потребує точного та достовірного прогнозування межі міцності, що є критично важливою характеристикою для оцінки надійності та безпеки конструкцій.

Традиційні підходи до оцінки механічних властивостей композитів спираються на аналітичні або напівемпіричні моделі, які часто базуються на гіпотезах про ізотропність чи спрощене представлення анізотропної природи композиту [3]. Такі моделі, як правило, вимагають проведення великої кількості фізичних експериментів для калібрування та ідентифі-

кації параметрів, що є трудомістким, дорогим і обмеженим у масштабах застосування. Крім того, в умовах складних напружених станів (наприклад, комбінованого навантаження або позаосевої дії сил) класичні моделі часто демонструють низьку точність.

Окрему проблему становить значна варіативність мікроструктури композитів, яка може бути зумовлена випадковим розташуванням волокон, дефектами виготовлення, неоднорідністю матриці тощо [4]. Такі фактори суттєво впливають на локальні механічні властивості, але важко піддаються прямому аналітичному опису. У цьому контексті особливої уваги заслуговують data-driven методи, що дозволяють опрацювати великі масиви чисельних або експериментальних даних без необхідності формулювання явної конститутивної моделі матеріалу [5].

Поява концепції data-driven computational mechanics, започаткованої Kirchdoerfer і Ortiz, відкрила нову парадигму в обчислювальній механіці твердого тіла [6]. В її рамках матеріальні рівняння замінюються базою даних напружено-деформованих станів, а

© Лавщенко Р. Р., Львов Г. І., 2025



Research Article: This article was published by the publishing house of NTU "KhPI" in the collection "Bulletin of the National Technical University "KhPI" Series: System analysis, management and information technologies." This article is licensed under an international license [Creative Commons Attribution \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/). **Conflict of Interest:** The author/s declared no conflict of interest.



розв'язання задачі зводиться до пошуку найближчої точки в цьому датасеті. Такий підхід демонструє високу точність та узагальненість, особливо у випадках, коли класичні підходи зазнають невдачі. І хоча data-driven підходи успішно використовуються для моделювання пружних, в'язкопластичних та тривких матеріалів, їх застосування для прямого прогнозування межі міцності композитів поки залишається обмеженим і фрагментарним.

Окремим напрямом, який активно розвивається, є поєднання мікромеханічного аналізу (наприклад, метод кінцевих елементів для представницької об'ємної комірки) із методами машинного навчання. Такий симбіоз дозволяє створювати високоточні бази даних, що враховують реальну геометрію й механіку волокон і матриці, та згодом використовувати їх для тренування прогновної моделі. Це особливо актуально для задач, пов'язаних з неоднорідними або спрямованими композитами, де класичні підходи до оцінки міцності виявляються недостатньо гнучкими або точними.

Водночас, незважаючи на численні спроби застосування машинного навчання [7] для прогнозування властивостей композитів, ця тематика залишається відкритою. Зокрема, межа міцності як категорія «гібридного порогу» (між пружним і руйнівним станом) досі недостатньо досліджена з позицій data-driven підходу. Більшість наявних робіт зосереджуються на оцінці модуля пружності, стискальної або динамічної міцності, але ігнорують детальну багатовимірну реконструкцію граничного стану в координатах напружень. Тому, виникає потреба у нових підходах, які б поєднували:

- мікромеханічне моделювання на рівні представницького елемента;
- автоматизовану генерацію датасетів граничних станів за різних сценаріїв навантаження;
- створення прогностичної моделі з використанням сучасних ML-методів, з подальшою візуалізацією й інтерпретацією межі міцності.

Таким чином, існує потреба в комплексному підході до прогнозування межі міцності композитних матеріалів, заснованому на поєднанні мікромеханічного аналізу та інструментів машинного навчання. Отримані результати матимуть потенціал для практичного застосування в системах інженерного проектування, автоматизованого тестування нових матеріалів та розробки цифрових двійників складних композитних структур. Тому дослідження, присвячені розробці інтелектуальних методів аналізу граничного стану композитів, є актуальними, оскільки вони сприяють підвищенню надійності та ефективності сучасних інженерних конструкцій.

Аналіз літературних даних і постановка проблеми. Протягом останніх років значно зріс інтерес до застосування методів машинного навчання для прогнозування механічних властивостей композитних матеріалів. Автори в роботах [8, 9] акцентують увагу на потенціалі машинного навчання для покращення точності моделювання та зниження залежності від емпіричних моделей. Зокрема, в [9] застосовано data-driven

підхід для побудови поверхні текучості волокнистих композитів, замінюючи традиційні аналітичні функції на дискретні набори даних з чисельного аналізу. Ці підходи є перспективними, проте залишаються теоретично орієнтованими і не демонструють повного циклу моделювання – від даних до рішення. Їхній підхід варто було б доповнити прикладною частиною.

Деякі дослідники поєднують deep learning з мікромеханічними моделями. Так, в статті [10] запропоновано фреймворк глибокого навчання для передбачення напружень у гетерогенних середовищах, а в дослідженні [11] реалізовано інтелектуальну багатомасштабну симуляцію композитів. Це потужні методи, однак вони передбачають наявність повної структурної інформації та високі обчислювальні витрати.

Значна частина досліджень присвячена передбаченню міцності полімерних композитів, армованих вуглецевими волокнами чи нанотрубками. Автори роботи [12] використовують ML для оцінки властивостей карбонових композитів, а в [13] досліджують вплив нанотрубок на міцність композиту. Ці роботи фокусуються переважно на регресійних моделях та прогнозуванні одного параметра, тоді як ігнорується задача класифікації граничного стану, що є критичнішим для задач технічного моніторингу.

У статті [14] застосовано SHAP для інтерпретації моделі, що передбачає міцність бетонів, демонструючи можливість поєднання прогностичної здатності з інтерпретованістю результатів. Це справді важливий напрям, що розглядається як перспективне розширення даного дослідження.

У роботах [15, 16] провели систематичні огляди застосування ML у будівельних матеріалах, включаючи волокнисті композити та армовані бетони. Вони демонструють широке розмаїття моделей (RF, SVM, ANN) і їхню ефективність у прогнозуванні механічних характеристик. Більшість робіт у цих оглядах зосереджені на бетонах, тоді як іншим матеріалам не приділено достатньої уваги.

Деякі роботи, на кшталт [17], спрямовані на автоматизацію та контроль якості у виробництві композитів. Це цінний напрям, однак він стосується переважно виробничої фази, тоді як представлене в цій роботі дослідження має на меті експлуатаційний моніторинг. У роботі [18] представлена можливість оптимізації армування за допомогою моделей штучного інтелекту. Це є суміжним підходом, але з іншим практичним фокусом – оптимізація конструкції, а не оцінка граничного стану. У [19] автори розробили глибоку нейронну мережу для аналізу ударних пошкоджень у композитах. Їхній підхід вимагає сенсорних даних, що може суттєво ускладнювати завдання.

У [20, 21] застосовано нейронні мережі для прогнозування міцності бетону різного складу. Незважаючи на різницю в матеріалах, концепція data-driven прогнозування міцності є спільною. Ефективність цих методів беззаперечна, однак у випадку складніших композитів виникає потреба в особливому підході до класифікації.

Результати досліджень [22, 23] доводять ефективність нелінійних алгоритмів (зокрема SVM та

XGBoost) у прогнозуванні характеристик геополімерного бетону. Це підтверджує доцільність застосування нелінійних моделей і у випадку представленого дослідження. У [24] використано Random Forest для оцінки міцності базальтового бетону, що схоже за структурою на один з матеріалів (Basalt/PP), що досліджено в цій роботі. В цьому дослідженні також застосовано RF як одну з найстабільніших моделей у контексті класифікації граничного стану композитів.

Проаналізовані в цьому огляді джерела [8–24] підтверджують високу ефективність методів машинного навчання та data-driven підходів у прогнозуванні механічних властивостей композитних матеріалів. Проте є низка незаповнених ніш:

- недостатнє використання експериментально-чисельних даних (особливо з мікромеханічного FEM-аналізу) як вхідних даних для ML-моделей;
- мало досліджень, спрямованих саме на прогнозування межі міцності, на відміну від більш популярної теми стискальної міцності чи модуля пружності;
- недостатньо робіт, що поєднують FEM-симуляції з ML в рамках єдиної data pipeline, із подальшою побудовою інтерпретованих моделей;
- обмежена увага до прямої залежності міцності (анізотропія), особливо у волокнистих композитах.

Мета та задачі дослідження. Метою роботи є розробка data-driven підходу до прогнозування граничного стану композитних матеріалів на основі компонентів тензора напружень. Це дасть можливість здійснювати безруйнівну діагностику конструкцій, оперативно оцінювати залишковий ресурс матеріалів, а також інтегрувати моделі у системи онлайн-моніторингу та цифрові двійники інженерних об'єктів.

Для досягнення мети були поставлені наступні задачі:

- побудувати та протестувати кілька моделей машинного навчання (Logistic Regression, Random Forest, MLP) для задачі класифікації граничного стану, порівнявши їх точність із класичним критерієм міцності фон-Мізеса;
- проаналізувати ефективність моделей за допомогою графічної візуалізації (2D-проекції, гістограми, порівняння точності), виявити межі застосування класичних і data-driven методів та обґрунтувати доцільність використання ML для прогнозування граничного стану композитів.

Матеріали та методи досліджень. Об'єктом дослідження є застосування методів машинного навчання

для визначення граничних станів односпрямованих композитів під багатовісним напруженням. Аналіз охоплює три поширені в авіаційній, будівельній та транспортній галузях матеріали: Carbon/Ероху, Glass/Polyester і Basalt/PP.

Основна гіпотеза полягає в тому, що граничний стан композиту можна точно визначати за допомогою моделей машинного навчання, які використовують компоненти тензора напружень як вхідні параметри.

Передбачається ідеально односпрямоване армування, циліндрична форма волокон і відомий або розрахований напружений стан матеріалу; дефекти та міжфазні неоднорідності не враховуються.

Розглянуті три типи волокнистих полімерних композитів, що широко застосовуються у високотехнологічних сферах. Вони різняться властивостями волокон і матриць, що дає змогу порівняти поведінку як високомодульних, так і більш пластичних систем під багатовісним навантаженням.

Механічні параметри волокон і матриць, наведені в табл. 1, використовуються як вихідні параметри для генерації напружених станів у моделі. Ці характеристики враховуються під час побудови граничної умови – умовної межі міцності композиту, яка слугує цільовою ознакою у моделі класифікації.

Композит Carbon/Ероху є одним із найбільш розповсюджених матеріалів у конструкціях літальних апаратів та легких несучих елементів. Вуглецеві волокна характеризуються надзвичайно високим модулем пружності (230 ГПа) та значною міцністю (~1000 МПа) за одночасно низького коефіцієнта Пуассона (0,20), що зумовлює їхню високу ефективність у напрямку армування. Епоксидна матриця, попри відносно невелику міцність (80 МПа), забезпечує надійне зчеплення з волокнами та характеризується високою термостійкістю.

Композит Glass/Polyester вирізняється кращою ізотропністю властивостей і широко застосовується у будівництві, трубопровідних системах, панельних конструкціях та елементах автомобільної промисловості. Скловолокно має нижчий модуль пружності (72 ГПа), проте характеризується підвищеною здатністю до деформації та доволі високою межею міцності (1500 МПа).

Поліестерова матриця забезпечує добру змочувальність волокон і сприяє швидкому формуванню виробів, хоча її механічна міцність (50 МПа) є нижчою порівняно з епоксидною матрицею.

Таблиця 1 – Механічні характеристики розглянутих композитів

Композитна система	Компонент	Модуль пружності E, ГПа	Межева міцність σ_{feil} , МПа	Коефіцієнт Пуассона ν
Carbon/Ероху	Волокно	230.0	1000	0.20
	Матриця	3.0	80	0.35
Glass/Polyester	Волокно	72.0	1500	0.22
	Матриця	2.5	50	0.34
Basalt/PP	Волокно	89.0	1200	0.25
	Матриця	1.3	30	0.42

Композит Basalt/Polypropylene, утворений поєднанням базальтового волокна та поліпропіленової матриці, розглядається як перспективний матеріал для легких, недорогих і водостійких конструкцій. Базальтове волокно є природним мінеральним матеріалом і характеризується збалансованим співвідношенням між модулем пружності (89 ГПа) та міцністю (1200 МПа), а також кращою термостійкістю порівняно зі скловолокном. Поліпропілен, що виступає термопластичною матрицею, забезпечує гнучкість, високу технологічність переробки та ударну в'язкість, проте має найнижчі значення модуля (1,3 ГПа) та межі міцності (30 МПа) серед розглянутих систем.

Для кожної з розглянутих систем передбачається односпрямоване армування, при якому волокна можуть мати як регулярне (ідеалізоване) розташування, так і випадкову структуру з домінуючим напрямком орієнтації. Така модельна схема дає змогу наблизити умови симуляції до реальних інженерних конфігурацій. З огляду на обмежений доступ до великих масивів експериментальних даних, синтетичні набори даних для навчання прогностичних моделей були отримані шляхом умовного моделювання напружених станів та визначення відповідних граничних умов. Вхідні ознаки (features) – це шість компонент тензора напружень у 3D-постановці: σ_x , σ_y , σ_z – нормальні напруження (МПа), τ_{xy} , τ_{yz} , τ_{xz} – дотичні напруження (МПа). Вихідна змінна (індикатор граничного стану) χ дорівнює 1, якщо матеріал переходить межу міцності, і 0 – якщо напружений стан є допустимим. Кожний набір даних містить 20 000 зразків.

Для кращого розуміння структури вхідних даних та ідентифікації граничних умов було виконано візуальний аналіз залежності індикатора граничного стану χ від компонент тензора напружень. З цією метою побудовано серію 2D-проекцій які відображають розподіл граничних станів за різних значень окремих компонент тензора, із застосуванням кольорового кодування змінної

$$\chi \in \{0 \text{ (допустимий)}, 1 \text{ (граничний)}\}.$$

На рис. 1–3 наведено типові зрізи у площинах $\sigma_x - \sigma_y$, $\sigma_x - \tau_{xy}$, $\tau_{xy} - \tau_{yz}$ тощо.

Для композиту Carbon/Ероху граничні стани сконцентровані на всіх графіках у верхніх правих квадрантах, що вказує на переважання руйнування при високих значеннях осевих напружень (σ_x , σ_y) та контактних зсувів (τ_{xy}).

Це узгоджується з анізотропною природою вуглецевого волокна, яке характеризується високою міцністю вздовж напрямку армування та зниженою стійкістю за багатовісних комбінацій навантаження, де істотну роль відіграють слабші міжволоконні зв'язки. На проекції $\sigma_{vm} - \sigma_x$ спостерігається виразне відділення класів, що підтверджує коректність застосування еквівалентної напруги σ_{vm} як граничного показника для оцінювання напруженого стану матеріалу.




Рис. 1. Розподіл граничних станів для різних значень компонентів тензора напружень для композиту Carbon/Ероху: а – для площини $\sigma_x - \sigma_y$;

б – для площини $\sigma_y - \sigma_z$; в – для площини $\sigma_x - \tau_{xy}$;

г – для площини $\sigma_y - \tau_{xy}$; д – для площини $\tau_{xy} - \tau_{yz}$;

е – для площини $\sigma_{vm} - \sigma_x$




Рис. 2. Розподіл граничних станів для різних значень компонентів тензора напружень для композиту Glass/Polyester: а – для площини $\sigma_x - \sigma_y$;

б – для площини $\sigma_y - \sigma_z$; в – для площини $\sigma_x - \tau_{xy}$;

г – для площини $\sigma_y - \tau_{xy}$; д – для площини $\tau_{xy} - \tau_{yz}$;

е – для площини $\sigma_{vm} - \sigma_x$

Це вказує на менш різко окреслену межу міцності та підсилений вплив усіх компонент тензора напружень, що є типовим для більш рівномірно армованих або менш жорстких композитів. На графіку $\sigma_{vm} - \sigma_x$ спостерігається ширший розкид червоних точок, що ускладнює класифікацію за простими критеріями та додатково підтверджує обґрунтованість використання нелінійних моделей.

Для композиту Basalt/Polypropylene характерний ще вищий ступінь перекриття між класами $\chi = 0$ та $\chi = 1$. Граничні стани розташовані менш компактно, що свідчить про менш виражену граничну поверхню та ймовірну залежність від поєднання кількох компонент напруження одночасно, а не домінування однієї з них. За таких умов задача моделювання ускладнюється, оскільки класична модель не здатна чітко визначити пороговий стан. Натомість ML-моделі демонструють значно кращу здатність до апроксимації такої складної структури.




Рис. 3. Розподіл граничних станів для різних значень компонентів тензора напружень для композиту Basalt/PP: а – для площини $\sigma_x - \sigma_y$; б – для площини $\sigma_y - \sigma_z$; в – для площини $\sigma_x - \tau_{xy}$; г – для площини $\sigma_y - \tau_{xy}$; д – для площини $\tau_{xy} - \tau_{yz}$; е – для площини $\sigma_{vm} - \sigma_x$

У цьому дослідженні проведено порівняння таких моделей:

1. Критерій фон-Мізеса [25] – референтна модель, яка оцінює граничний стан матеріалу за значенням еквівалентного напруження фон-Мізеса:

$$\sigma_{vm} = \sqrt{\frac{1}{2}((\sigma_x - \sigma_y)^2 + (\sigma_y - \sigma_z)^2 + (\sigma_z - \sigma_x)^2 + 3(\tau_{xy}^2 + \tau_{yz}^2 + \tau_{xz}^2))}. \quad (1)$$

Тоді $\chi = 1$, якщо:

$$\sigma_{vm} \geq \min(\sigma_\chi^f, \sigma_\chi^m). \quad (2)$$

Модель має просту структуру та зручна для інтерпретації, проте не враховує анізотропних властивостей композитного матеріалу та ігнорує напрям дії напружень. Тому служить лише як базовий порівняльний критерій.

2. Logistic Regression [26] – математична модель, яка оцінює ймовірність належності класу $\chi = 1$ як:

$$P(\chi = 1 | X) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 \sigma_x + \dots + \beta_6 \tau_{xz})}}. \quad (3)$$

Даний метод є лінійним класифікатором, який добре працює при простому розділенні класів. Він був обраний як референтна ML-модель з високою інтерпретованістю.

3. Random Forest Classifier [27] – ансамблева модель, що формує прогноз шляхом агрегування результатів великої кількості дерев рішень (decision trees), де підсумковий клас визначається за принципом більшості голосів:

$$\chi = \text{mod } e[T_1(X), T_2(X), \dots, T_n(X)]. \quad (4)$$

Ця модель характеризується високою ефективністю на вибірках із нелінійними та багатовимірними залежностями, демонструє стійкість до перенавчання та забезпечує можливість проводити аналіз важливості ознак (feature importance).

4. MLP (Multilayer Perceptron Neural Network) [28] – це нейронна мережа прямого поширення, що апроксимує складні нелінійні функції. Вихід нейронної мережі можна виразити наступним рівнянням:

$$\chi = f(X) = \sigma(W_2 * \text{ReLU}(W_1 X + b_1) + b_2), \quad (5)$$

де W – матриці ваг;

σ – сигмоїдна функція;

ReLU – функція активації.

MLP використовується для моделювання складної поведінки композиту, з урахуванням взаємодії напружень.

Для реалізації data-driven підходу з використанням моделей машинного навчання створені збалансовані синтетичні вибірки граничних станів для трьох типів композитних матеріалів (Carbon/Епоху, Glass/Polyester, Basalt/PP) при навантаженні шестикординатними напруженнями. Для знаходження граничних станів односпрямоване армованих композитів використане умовне моделювання напружених станів. Механічні параметри волокон та матриць для трьох типів композитних матеріалів подано у табл. 1. Зазначені характеристики слугують базовими вихідними даними для генерації напружених станів у моделі.

Побудова моделей машинного навчання та перевірка їх точності. Для задачі прогнозування граничного стану композитних матеріалів розроблено і навчено три моделі на основі класифікаторів: логістичної регресії (LR), випадкового лісу (RF) та багатошарової нейронної мережі (MLP). Вхідними даними є шість компонентів тензора напружень (σ_x , σ_y , σ_z ,

$\tau_{xy}, \tau_{yz}, \tau_{xz}$), а цільовою змінною – $\chi \in \{0,1\}$, що відображає допустимий чи граничний стан матеріалу. Дані попередньо нормалізовано та розділено на навчальну (80 %) і тестову (20 %) вибірки.

1. Logistic Regression (LR) – лінійний базовий класифікатор, вибраний для забезпечення інтерпретованості та контролю впливу кожної компоненти тензора.

Застосовано регуляризацію L2 (Ridge) для зменшення мультиколінеарності ознак і контролю overfitting.

Параметр C тестувався у діапазоні [0.01; 100] з кроком 0.5. Застосовано метод добору GridSearchCV (5-fold cross-validation), результатом роботи якого є такі налаштування: $C = 1.0$, $\text{solver} = \text{liblinear}$, $\text{penalty} = \text{l2}$, $\text{tol} = 1e-4$, $\text{max_iter} = 10000$. Цей обраний набір параметрів показав найкращий баланс між точністю та узагальнюваністю на валідаційній вибірці. Як оптимізатор застосовано liblinear, що є ефективним для малих і середніх за розміром даних. Додаткові параметри: критерій зупинки: $\text{tol} = 1e-4$, $\text{max_iter} = 10000$ для забезпечення повної збіжності.

2. Random Forest Classifier (RF) – ансамблевий алгоритм на основі bagging та побудови множини дерев рішень. Обраний для моделювання нелінійних взаємодій та виявлення складних комбінацій напружень, що призводять до руйнування.

Параметри для оптимізації: кількість дерев ($n_estimators$), максимальна глибина (max_depth), застосовується для запобігання перенавчанню, мінімальні розміри вузлів, для контролю overfitting (min_samples_split , min_samples_leaf), кількість ознак, що враховуються при розщепленні (max_features). Застосовано метод добору RandomizedSearchCV (100 ітерацій, 5-fold cross-validation). В результаті обрані налаштування: $n_estimators = 200$, $\text{max_depth} = 10$, $\text{min_samples_split} = 2$, $\text{min_samples_leaf} = 1$, $\text{max_features} = \text{'sqrt'}$, $\text{criterion} = \text{'gini'}$.

Аналіз важливості ознак через mean decrease in impurity (MDI) показав, що найбільший внесок у класифікацію мали σ_x , σ_y , та τ_{xy} .

3. Модель багатопарового перцептрона (Multilayer Perceptron, MLP) була застосована як нейромережева апроксимаційна модель для відтворення складної багатовимірної поверхні міцності, яку неможливо описати у замкненому аналітичному вигляді. Архітектура мережі включала:

- Вхідний шар: 6 нейронів відповідно до кількості вхідних ознак;
- Приховані шари: два шари на 64 та 32 нейрони відповідно з функціями активації ReLU;
- Вихідний шар: 1 нейрон із сигмоїдальною активацією, інтерпретований як оцінка ймовірності реалізації стану $\chi = 1$;
- Ініціалізація ваг: метод Xavier uniform;
- Регуляризація: застосування Dropout із параметром $p = 0.2$ на кожному прихованому шарі;

- Оптимізація: алгоритм Adam ($\alpha = 0.001$, $\beta_1 = 0.9$, $\beta_2 = 0.999$);

- Функція втрат: Binary Cross-Entropy;

- Режим навчання: batch size = 64, кількість epoch = 200 з використанням early stopping (patience = 20) та адаптивного зменшення швидкості навчання при досягненні плато.

Підбір гіперпараметрів архітектури здійснювався методом байєсівської оптимізації (Optuna), де цільовою метрикою виступала AUC-ROC на валідаційній вибірці.

Обрана конфігурація продемонструвала найкращі показники збіжності та стійкості до перенавчання при роботі з синтетично згенерованими даними.

Для порівняльного аналізу ефективності моделей машинного навчання було використано критерій міцності фон Мізеса як еталонний фізично обґрунтований підхід. Це дозволило кількісно оцінити перевагу нелінійних моделей у випадках складного багатовісного напруженого стану та анізотропії матеріалу, де класичні методи демонструють обмежену точність.

Аналіз ефективності моделей машинного навчання. Для оцінки точності результатів застосовано такі метрики: Accuracy – частка правильно класифікованих прикладів, AUC-ROC (площа під ROC-кривою) – показник здатності моделі відділяти класи; для класичної моделі: precision, recall, f1-score. Значення метрик досліджуваних моделей наведені в табл. 2, класичної моделі – в табл. 3.

Таблиця 2 – Значення метрик оцінювання досліджуваних моделей

Матеріал	Модель	Accuracy	AUC-ROC
Glass/Polyester (GP)	Random Forest	0.99525	0.99696
	MLP	0.99425	0.99673
	Logistic Regression	0.94450	0.98653
Carbon/Epoxy (CE)	Random Forest	0.99950	0.99943
	MLP	0.99900	0.99939
	Logistic Regression	0.98850	0.99891
Basalt/PP (BPP)	Random Forest	0.98225	0.98921
	MLP	0.97825	0.98645
	Logistic Regression	0.87850	0.95014

Таблиця 3 – Значення метрик оцінювання класичної моделі

Матеріал	Accuracy	Recall ($\chi = 1$)	Precision ($\chi = 1$)	F1-score
GP	0.500	1.00	0.50	0.67
CE	0.500	1.00	0.50	0.67
BPP	0.500	1.00	0.50	0.67

Результати табл. 3 свідчать, що модель класифікує всі приклади як граничні ($\chi = 1$), що призвело до того, що здатність розділяти класи була повністю втрачена. Це демонструє обмеженість застосування порогових фізичних критеріїв у випадках, коли система має складну та анізотропну поведінку. Хоча класична модель може служити еталоном, вона не досягає такої точності, як у сучасних data-driven методах. На рис. 4 зображено гістограми за метрикою Accurasy для кожної моделі та матеріалу.




Рис. 4. Гістограми точності прогнозування граничного стану

Графік наочно демонструє, що моделі машинного навчання забезпечують суттєво вищу точність порівняно з традиційними методами. Найкращі результати спостерігаються для Random Forest і MLP, які вирізняються універсальністю та здатністю стабільно працювати з різнорідними даними. Важливо підкреслити, що тип матеріалу істотно впливає на складність задачі класифікації: саме фізичні властивості матеріалів формують характерні патерни напружень. Візуалізація їх просторового розподілу (рис. 1–3) дає змогу чітко простежити ці відмінності та зрозуміти, чому певні моделі краще пристосовуються до специфіки окремих матеріалів. Такий аналіз робить інтерпретацію результатів більш послідовною та методологічно виваженою.

Отримані результати (табл. 1) свідчать про високу ефективність усіх трьох розроблених у межах даної роботи моделей машинного навчання – Logistic Regression (LR), Random Forest (RF) та Multilayer Perceptron (MLP) – у задачі класифікації граничного стану композитних матеріалів.

Для матеріалу Glass/Polyester (GP) найвищі показники досягнуто моделлю RF (Accurasy = 0.99525, AUC-ROC = 0.99696), тоді як MLP продемонструвала дуже близький результат (Accurasy = 0.99425). Подібна ефективність пояснюється чітким розділенням класів у просторі напружень, що забезпечує придатність як ансамблевих методів, так і нейромережових підходів. Лінійна модель LR (Accurasy = 0.94450) показала нижчу точність через обмежену здатність відтворювати нелінійні залежності.

Для Carbon/Ероху (CE) обидві нелінійні моделі (RF, MLP) практично досягають максимальної точності (Accurasy > 0.999), що зумовлено нелінійною, але добре відокремлюваною межею руйнування. LR (Accurasy = 0.98850) також демонструє високі показ-

ники, що вказує на можливість апроксимації граничного стану за допомогою лінійної моделі у випадку цього матеріалу.

У випадку Basalt/PP (BPP) точність зменшується для всіх моделей (Accurasy = 0.98225 для RF та 0.97825 для MLP), що пов'язано зі значним перетином класів і підвищеною варіативністю механічної відповіді матеріалу. Модель LR (Accurasy = 0.87850) демонструє істотно гірші результати через неспроможність відтворити складну форму поверхні розділення. При цьому показник AUC-ROC для всіх моделей та матеріалів залишається стабільно високим (більше 0.95), що підтверджує їхню стійкість до зміни порогу класифікації.

У табл. 3 наведено результати для критерію фон Мізеса, який у даній роботі використано як фізично обґрунтований еталон. Його Accurasy становить ≈ 0.50 для всіх матеріалів, при Recall ($\chi = 1$) = 1.00 та низькому Precision ≈ 0.50 . Це свідчить про схильність критерію до надмірної класифікації станів як граничних, що призводить до підвищеної кількості хибнопозитивних рішень.

Таким чином, запропоновані моделі машинного навчання не лише підвищують загальну точність класифікації, але й забезпечують більш оптимальний баланс між Recall і Precision, що є критично важливим для практичних задач моніторингу технічного стану матеріалів і попередження їхнього руйнування.

У сучасних дослідженнях [1, 25] домінують аналітичні та напівемпіричні критерії міцності (критерій фон Мізеса та його модифікації), які ефективні для ізотропних матеріалів, але не враховують анізотропію композитів і складні багатовісні стани напружень. У роботах, присвячених ML-підходам [26–28], зазвичай застосовувалися окремі моделі (LR, RF або MLP) для специфічних задач без глибокої оптимізації гіперпараметрів, а також без системного порівняння з класичними критеріями міцності.

У запропонованому дослідженні:

- вперше проведено комплексну оптимізацію трьох різних типів моделей (LR, RF, MLP) під задачу класифікації граничного стану композитів;
- реалізовано повний цикл налаштування гіперпараметрів: GridSearchCV для LR, RandomizedSearchCV для RF та Bayesian Optimization (Optuna) для MLP;
- здійснено зіставлення з критерієм фон Мізеса, яке показало перевагу ML-моделей на 5–15 % за Accurasy та AUC-ROC.

Обмеження дослідження полягають у тому, що навчання моделей здійснювалося на синтетичних та обмежених експериментальних даних, що може впливати на узагальнювальну здатність результатів. Крім того, модель MLP потребує значних обчислювальних ресурсів, особливо при збільшенні обсягу вибірки. Також у даній роботі не враховано мікροструктурні характеристики матеріалів, які можуть суттєво впливати на їхні міцнісні властивості та потенційно підвищити точність прогнозування.

Висновки. У роботі було розроблено та оптимізовано три моделі машинного навчання: Logistic Regression (LR), Random Forest (RF) та Multilayer Perceptron (MLP) – спеціально для задачі прогнозування граничних станів у трьох типах полімерних композиційних матеріалів з односпрямованим армуванням: Glass/Polyester (GP), Carbon/Ероху (CE) та Basalt/PP (BPP). Підібрані архітектури, гіперпараметри та методи навчання забезпечили високу прогностичну здатність, особливо для RF та MLP, які досягли точності класифікації до 99,9 % на тестових даних. Усі розроблені моделі значно перевершили класичний критерій фон-Мізеса, точність якого для всіх матеріалів не перевищувала 50 %, що свідчить про обмеженість аналітичних підходів у задачах з високою нелінійністю простору ознак.

Порівняльний аналіз (табл. 2) підтвердив, що RF та MLP стабільно забезпечують найкращі результати для всіх типів композитів, з найвищою точністю для Carbon/Ероху, де класова межа у просторі напружень є найбільш структурованою та чіткою. Для Basalt/PP спостерігалось певне зниження точності через сильніше перекриття класів, що вказує на складність задачі та підтверджує доцільність використання саме нелінійних алгоритмів.

Візуалізація 2D-зрізів компонент тензора напружень показала, що межа між допустимим і граничним станом має складну нелінійну геометрію, яка значно варіюється залежно від типу композиту: для Carbon/Ероху вона найбільш виразна, тоді як для Basalt/PP спостерігається значне перекриття класів. Це підкреслює обмеженість простих лінійних критеріїв і водночас пояснює ефективність розроблених нелінійних ML-моделей.

Отримані результати узгоджуються з тенденціями, описаними у попередніх дослідженнях застосування машинного навчання до механічного аналізу композитів, але суттєво їх розширюють: у даній роботі вперше зосереджено увагу саме на класифікації граничного стану, а не на загальному прогнозуванні механічних характеристик, і при цьому запропоновано метод, який не вимагає розширених матеріалознавчих чи технологічних даних. Це робить підхід придатним для швидкої інтеграції в системи інженерного моніторингу, оцінки залишкового ресурсу та контролю працездатності композитних конструкцій в авіаційній, будівельній та транспортній галузях.

Подальші напрями роботи включають розширення набору ознак за рахунок мікроструктурних параметрів, впровадження інтерпретованих моделей машинного навчання (SHAP, LIME) для пояснення впливу компонент тензора напружень, збільшення обсягу навчальних вибірок шляхом додавання експериментальних та FEM-даних, а також адаптацію моделей до режимів онлайн-діагностики. Крім того, перспективним є розроблення цифрового двійника композитної структури на основі інтеграції ML-алгоритмів із фізично обґрунтованими критеріями міцності.

Таким чином, результати цієї роботи не лише підтверджують високу точність прогнозування граничного стану композитних матеріалів, але й формують

підґрунтя для розроблення нового покоління інтелектуальних систем моніторингу. Такі системи можуть поєднувати гнучкість методів машинного навчання з надійністю фізично обґрунтованих механічних моделей, забезпечуючи більш ефективне виявлення критичних станів і підвищену безпеку експлуатації композитних конструкцій.

Список використаної літератури

1. Hamzat A. K., Murad M. S., Adediran I. A., Asmatulu E., Asmatulu R. Fiber-reinforced composites for aerospace, energy, and marine applications: an insight into failure mechanisms under chemical, thermal, oxidative, and mechanical load conditions. *Advanced Composites and Hybrid Materials*. 2025. Vol. 8, no. 1, article 152. DOI: <https://doi.org/10.1007/s42114-024-01192-y>.
2. De B., Bera M., Bhattacharjee D., Ray B. C., Mukherjee S. A comprehensive review on fiber-reinforced polymer composites: Raw materials to applications, recycling, and waste management. *Progress in Materials Science*. 2024. Vol. 146, article 101326. DOI: <https://doi.org/10.1016/j.pmatsci.2024.101326>.
3. Petru M., Novak O., Pacurar R. (ed.) FEM analysis of mechanical and structural properties of long fiber-reinforced composites. *Finite Element Method – Simulation, Numerical Analysis and Solution Techniques. Chapter 1*. London: IntechOpen, 2017. DOI: <https://doi.org/10.5772/intechopen.71881>.
4. Markopoulos I., Kouris L.-A., Konstantinidis A. On the use of microstructure characteristics to predict metal matrix composites' macroscopic mechanical behavior. *Applied Sciences*. 2023. Vol. 13, no. 8. Article 4989. DOI: <https://doi.org/10.3390/app13084989>.
5. Kibrete F., Trzepieciński T., Gebremedhen H. S., Woldemichael D. E. Artificial intelligence in predicting mechanical properties of composite materials. *Journal of Composites Science*. 2023. Vol. 7, no. 9. Article 364. DOI: <https://doi.org/10.3390/jcs7090364>.
6. Kirchdoerfer T., Ortiz M. Data-driven computational mechanics. *Computer Methods in Applied Mechanics and Engineering*. 2016. Vol. 304. P. 81–101. DOI: <https://doi.org/10.1016/j.cma.2016.02.001>.
7. Steingrimsson B., Fan X., Kulkarni A., Gao M. C., Liaw P. K. Machine learning and data analytics for design and manufacturing of high-entropy materials exhibiting mechanical or fatigue properties of interest. *High-Entropy Materials: Theory, Experiments, and Applications*. 2021. P. 115–238. DOI: https://doi.org/10.1007/978-3-030-77641-1_4.
8. Liu X., Tian S., Tao F., Du H., Yu W. How machine learning can help the design and analysis of composite materials and structures? *arXiv preprint*, 2020. *arXiv:2010.09438*. URL: <https://arxiv.org/abs/2010.09438> (дата звернення: 10.10.2025).
9. Lvov G., Kostromytska O. A data-driven approach to the prediction of plasticity in composites. *Integrated Computer Technologies in Mechanical Engineering*. 2020. P. 3–10. DOI: https://doi.org/10.1007/978-3-030-37618-5_1.
10. Feng H., Prabhakar P. Difference-based deep learning framework for stress predictions in heterogeneous media. *Composite Structures*. 2021. Vol. 269. Article 113957. DOI: <https://doi.org/10.1016/j.compstruct.2021.113957>.
11. Liu Z., Wei H., Huang T., Wu C. T. Intelligent multiscale simulation based on process-guided composite database. *arXiv preprint*, 2020. *arXiv:2003.09491*. URL: <https://arxiv.org/abs/2003.09491> (дата звернення: 10.10.2025).
12. Shah V., Zadorian S., Yang C., Zhang Z., Gu G. X. Data-driven approach for the prediction of mechanical properties of carbon fiber reinforced composites. *Materials Advances*. 2022. Vol. 3, no. 19. P. 7319–7327. DOI: <https://doi.org/10.1039/D2MA00698G>.
13. Le T.-T. Prediction of tensile strength of polymer carbon nanotube composites using practical machine learning method. *Journal of Composite Materials*. 2021. Vol. 55, no. 6. P. 787–811. DOI: <https://doi.org/10.1177/0021998320953540>.
14. Wu Y., Zhou Y. Hybrid machine learning model and Shapley additive explanations for compressive strength of sustainable concrete. *Construction and Building Materials*. 2022. Vol. 330. Article 127298. DOI: <https://doi.org/10.1016/j.conbuildmat.2022.127298>.
15. Nunez I., Marani A., Flah M., Nehdi M. L. Estimating compressive strength of modern concrete mixtures using computational

- intelligence: A systematic review. *Construction and Building Materials*. 2021. Vol. 310. Article 125279. DOI: <https://doi.org/10.1016/j.conbuildmat.2021.125279>.
16. Kumar P., Arora H. Ch., Bahrami A., Kumar A., Kumar K. Development of a reliable machine learning model to predict compressive strength of FRP-confined concrete cylinders. *Buildings*. 2023. Vol. 13, no. 4. Article 931. DOI: <https://doi.org/10.3390/buildings13040931>.
 17. Sacco C., Baz Radwan A., Anderson A., Harik R., Gregory E. Machine learning in composites manufacturing: A case study of Automated Fiber Placement inspection. *Composite Structures*. 2020. Vol. 250. Article 112514. DOI: <https://doi.org/10.1016/j.compstruct.2020.112514>.
 18. Brayek B. E. B., Sayed S., Mînză V., Tarfaoui M. Machine learning predictions for the comparative mechanical analysis of composite laminates with various fibers. *Processes*. 2025. Vol. 13, no. 3. Article 602. DOI: <https://doi.org/10.3390/pr13030602>.
 19. Jung K.-Ch., Chang S.-H. Advanced deep learning model-based impact characterization method for composite laminates. *Composites Science and Technology*. 2021. Vol. 207. Article 108713. DOI: <https://doi.org/10.1016/j.compscitech.2021.108713>.
 20. Salami B. A., Olayiwola T., Oyeohan T. A., Raji I. A. Data-driven model for ternary-blend concrete compressive strength prediction using machine learning approach. *Construction and Building Materials*. 2021. Vol. 301. Article 124152. DOI: <https://doi.org/10.1016/j.conbuildmat.2021.124152>.
 21. Moradi M. J., Khaleghi M., Salimi J., Farhangi V., Ramezani-pour A. M. Predicting the compressive strength of concrete containing metakaolin with different properties using ANN. *Measurement*. 2021. Vol. 183. Article 109790. DOI: <https://doi.org/10.1016/j.measurement.2021.109790>.
 22. Azimi-Pour M., Eskandari-Naddaf H., Pakzad A. Linear and non-linear SVM prediction for fresh properties and compressive strength of high volume fly ash self-compacting concrete. *Construction and Building Materials*. 2020. Vol. 230. Article 117021. DOI: <https://doi.org/10.1016/j.conbuildmat.2019.117021>.
 23. Ahmad A., Ahmad W., Aslam F., Joyklad P. Compressive strength prediction of fly ash-based geopolymer concrete via advanced machine learning techniques. *Case Studies in Construction Materials*. 2022. Vol. 16. Article e00840. DOI: <https://doi.org/10.1016/j.cscm.2021.e00840>.
 24. Li H., Lin J., Lei X., Wei T. Compressive strength prediction of basalt fiber reinforced concrete via random forest algorithm. *Materials Today Communications*. 2022. Vol. 30. Article 103117. DOI: <https://doi.org/10.1016/j.mtcomm.2021.103117>.
 25. Kouhestani E., Fakoor M. Extension of von-Mises failure criterion for comprehensive mixed-mode I/II fracture assessment of orthotropic materials. *International Journal of Solids and Structures*. 2025. Vol. 315. Article 113363. DOI: <https://doi.org/10.1016/j.ijsolstr.2025.113363>.
 26. Jiang F., Guan Z., Li Z., Wang X. A method of predicting visual detectability of low-velocity impact damage in composite structures based on logistic regression model. *Chinese Journal of Aeronautics*. 2021. Vol. 34, no. 1. P. 296–308. DOI: <https://doi.org/10.1016/j.cja.2020.10.006>.
 27. Lim D. K., Mustapha K. B., Pagwiwoko C. P. Delamination detection in composite plates using random forests. *Composite Structures*. 2021. Vol. 278. Article 114676. DOI: <https://doi.org/10.1016/j.compstruct.2021.114676>.
 28. Li M., Li S., Tian Y., Fu Y., Pei Y., Zhu W., Ke Y. A deep learning convolutional neural network and multi-layer perceptron hybrid fusion model for predicting the mechanical properties of carbon fiber. *Materials & Design*. 2023. Vol. 227. Article 111760. DOI: <https://doi.org/10.1016/j.matdes.2023.111760>.
- References (transliterated)**
1. Hamzat A. K., Murad M. S., Adediran I. A., Asmatulu E., Asmatulu R. Fiber-reinforced composites for aerospace, energy, and marine applications: an insight into failure mechanisms under chemical, thermal, oxidative, and mechanical load conditions. *Advanced Composites and Hybrid Materials*. 2025, vol. 8, no. 1, article 152. DOI: <https://doi.org/10.1007/s42114-024-01192-y>.
 2. De B., Bera M., Bhattacharjee D., Ray B. C., Mukherjee S. A comprehensive review on fiber-reinforced polymer composites: Raw materials to applications, recycling, and waste management. *Progress in Materials Science*. 2024, vol. 146, article 101326. DOI: <https://doi.org/10.1016/j.pmatsci.2024.101326>.
 3. Petrů M., Novák O., Pácurar R. (ed.) FEM analysis of mechanical and structural properties of long fiber-reinforced composites. *Finite Element Method – Simulation, Numerical Analysis and Solution Techniques. Chapter 1*. London: IntechOpen, 2017. DOI: <https://doi.org/10.5772/intechopen.71881>.
 4. Markopoulos I., Kouris L.-A., Konstantinidis A. On the use of microstructure characteristics to predict metal matrix composites' macroscopic mechanical behavior. *Applied Sciences*. 2023, vol. 13, no. 8, article 4989. DOI: <https://doi.org/10.3390/app13084989>.
 5. Kibrete F., Trzepieciński T., Gebremedhen H. S., Woldemichael D. E. Artificial intelligence in predicting mechanical properties of composite materials. *Journal of Composites Science*. 2023, vol. 7, no. 9, article 364. DOI: <https://doi.org/10.3390/jcs7090364>.
 6. Kirchdoerfer T., Ortiz M. Data-driven computational mechanics. *Computer Methods in Applied Mechanics and Engineering*. 2016, vol. 304, pp. 81–101. DOI: <https://doi.org/10.1016/j.cma.2016.02.001>.
 7. Steingrímsson B., Fan X., Kulkarni A., Gao M. C., Liaw P. K. Machine learning and data analytics for design and manufacturing of high-entropy materials exhibiting mechanical or fatigue properties of interest. *High-Entropy Materials: Theory, Experiments, and Applications*. 2021, pp. 115–238. DOI: https://doi.org/10.1007/978-3-030-77641-1_4.
 8. Liu X., Tian S., Tao F., Du H., Yu W. How machine learning can help the analysis and analysis of composite materials and structures? *arXiv preprint*, 2020. *arXiv:2010.09438*. Available at: <https://arxiv.org/abs/2010.09438> (accessed 10.11.2025).
 9. Lvov G., Kostromyska O. A data-driven approach to the prediction of plasticity in composites. *Integrated Computer Technologies in Mechanical Engineering*. 2020, pp. 3–10. DOI: https://doi.org/10.1007/978-3-030-37618-5_1.
 10. Feng H., Prabhakar P. Difference-based deep learning framework for stress predictions in heterogeneous media. *Composite Structures*. 2021, vol. 269, article 113957. DOI: <https://doi.org/10.1016/j.compstruct.2021.113957>.
 11. Liu Z., Wei H., Huang T., Wu C. T. Intelligent multiscale simulation based on process-guided composite database. *arXiv preprint*, 2020. *arXiv:2003.09491*. Available at: <https://arxiv.org/abs/2003.09491> (accessed 10.11.2025).
 12. Shah V., Zadourian S., Yang C., Zhang Z., Gu G. X. Data-driven approach for the prediction of mechanical properties of carbon fiber reinforced composites. *Materials Advances*. 2022, vol. 3, no. 19, pp. 7319–7327. DOI: <https://doi.org/10.1039/D2MA00698G>.
 13. Le T.-T. Prediction of tensile strength of polymer carbon nanotube composites using practical machine learning method. *Journal of Composite Materials*. 2021, vol. 55, no. 6, pp. 787–811. DOI: <https://doi.org/10.1177/0021998320953540>.
 14. Wu Y., Zhou Y. Hybrid machine learning model and Shapley additive explanations for compressive strength of sustainable concrete. *Construction and Building Materials*. 2022. Vol. 330. Article 127298. DOI: <https://doi.org/10.1016/j.conbuildmat.2022.127298>.
 15. Nunez I., Marani A., Flah M., Nehdi M. L. Estimating compressive strength of modern concrete mixtures using computational intelligence: A systematic review. *Construction and Building Materials*. 2021, vol. 310, article 125279. DOI: <https://doi.org/10.1016/j.conbuildmat.2021.125279>.
 16. Kumar P., Arora H. Ch., Bahrami A., Kumar A., Kumar K. Development of a reliable machine learning model to predict compressive strength of FRP-confined concrete cylinders. *Buildings*. 2023, vol. 13, no. 4, article 931. DOI: <https://doi.org/10.3390/buildings13040931>.
 17. Sacco C., Baz Radwan A., Anderson A., Harik R., Gregory E. Machine learning in composites manufacturing: A case study of Automated Fiber Placement inspection. *Composite Structures*. 2020, vol. 250, article 112514. DOI: <https://doi.org/10.1016/j.compstruct.2020.112514>.
 18. Brayek B. E. B., Sayed S., Mînză V., Tarfaoui M. Machine learning predictions for the comparative mechanical analysis of composite laminates with various fibers. *Processes*. 2025, vol. 13, no. 3, article 602. DOI: <https://doi.org/10.3390/pr13030602>.
 19. Jung K.-Ch., Chang S.-H. Advanced deep learning model-based impact characterization method for composite laminates. *Composites*

- Science and Technology. 2021, vol. 207, article 108713. DOI: <https://doi.org/10.1016/j.compscitech.2021.108713>.
20. Salami B. A., Olayiwola T., Oyeohan T. A., Raji I. A. Data-driven model for ternary-blend concrete compressive strength prediction using machine learning approach. *Construction and Building Materials*. 2021, vol. 301, article 124152. DOI: <https://doi.org/10.1016/j.conbuildmat.2021.124152>.
 21. Moradi M. J., Khaleghi M., Salimi J., Farhangi V., Ramezani-pour A. M. Predicting the compressive strength of concrete containing metakaolin with different properties using ANN. *Measurement*. 2021, vol. 183, article 109790. DOI: <https://doi.org/10.1016/j.measurement.2021.109790>.
 22. Azimi-Pour M., Eskandari-Naddaf H., Pakzad A. Linear and non-linear SVM prediction for fresh properties and compressive strength of high volume fly ash self-compacting concrete. *Construction and Building Materials*. 2020, vol. 230, article 117021. DOI: <https://doi.org/10.1016/j.conbuildmat.2019.117021>.
 23. Ahmad A., Ahmad W., Aslam F., Joyklad P. Compressive strength prediction of fly ash-based geopolymer concrete via advanced machine learning techniques. *Case Studies in Construction Materials*. 2022, vol. 16, article e00840. DOI: <https://doi.org/10.1016/j.cscm.2021.e00840>.
 24. Li H., Lin J., Lei X., Wei T. Compressive strength prediction of basalt fiber reinforced concrete via random forest algorithm. *Materials Today Communications*. 2022, vol. 30, article 103117. DOI: <https://doi.org/10.1016/j.mtcomm.2021.103117>.
 25. Kouhestani E., Fakoor M. Extension of von-Mises failure criterion for comprehensive mixed-mode I/II fracture assessment of orthotropic materials. *International Journal of Solids and Structures*. 2025, vol. 315, article 113363. DOI: <https://doi.org/10.1016/j.ijsolstr.2025.113363>.
 26. Jiang F., Guan Z., Li Z., Wang X. A method of predicting visual detectability of low-velocity impact damage in composite structures based on logistic regression model. *Chinese Journal of Aeronautics*. 2021, vol. 34, no. 1, pp. 296–308. DOI: <https://doi.org/10.1016/j.cja.2020.10.006>.
 27. Lim D. K., Mustapha K. B., Pagwiwoko C. P. Delamination detection in composite plates using random forests. *Composite Structures*. 2021, vol. 278, article 114676. DOI: <https://doi.org/10.1016/j.compstruct.2021.114676>.
 28. Li M., Li S., Tian Y., Fu Y., Pei Y., Zhu W., Ke Y. A deep learning convolutional neural network and multi-layer perceptron hybrid fusion model for predicting the mechanical properties of carbon fiber. *Materials & Design*. 2023, vol. 227, article 111760. DOI: <https://doi.org/10.1016/j.matdes.2023.111760>.

Надійшло (received) 13.11.2025

UDC 004

R. R. LAVSHCHENKO, Master of Computer Science, postgraduate student, National Technical University "Kharkiv Polytechnic Institute", Kharkiv, Ukraine; e-mail: ruslan.lavshchenko@infiz.khpi.edu.ua; ORCID: <https://orcid.org/0009-0001-3649-1118>

G. I. LVOV, Doctor of Technical Sciences, Professor at the Department of mathematical modeling and intelligent computing in engineering, National Technical University "Kharkiv Polytechnic Institute", Kharkiv, Ukraine; e-mail: lvovdpm@ukr.net; ORCID: <https://orcid.org/0000-0003-0297-9227>

DATA-DRIVEN APPROACH TO PREDICT THE STRENGTH OF COMPOSITES

The rapid development of composites requires accurate prediction of their limit state under complex loading conditions, which cannot be provided by classical mechanical criteria due to the anisotropy and nonlinearity of materials. The paper proposes a data-driven approach using machine learning to determine the limit state of composites based on the components of the stress tensor. The object of study is machine learning processes for determining the limit states of unidirectional reinforced composites under a multiaxial stress state. The aim of the study is to create a universal and accurate model capable of detecting the moment of reaching the strength limit without numerical modeling and large-scale experiments. Balanced synthetic samples of stress states were generated for three composite systems. Several machine learning models were implemented in the study: logistic regression, random forest, and multilayer perceptron neural network. To compare the effectiveness, the classical model for determining the limit state according to the von Mises criterion, with a fixed equivalent stress threshold for the fibres or the matrix, was also employed. The results show that the machine learning models achieve an accuracy of up to 99.9 % on test samples, significantly outperforming the classical approach, which demonstrates an accuracy of about 50 % in all cases. Visualization of the stress state in the form of 2D sections showed a complex and nonlinear structure of the boundary surface, which confirms the feasibility of using ML algorithms. The obtained results confirm the high effectiveness and reliability of the data-driven approach for structural health assessment of composite systems. The developed methodology is universal and can be adapted to various types of reinforced materials and loading conditions. The proposed approach can be applied in real-time technical diagnostics of composite structures. The work also creates a basis for further implementation of interpreted models and digital twins in the field of composite mechanics

Keywords: data-driven approach, composites, limit states, stress, machine learning, Random Forest, Logistic Regression.

Повні імена авторів / Author's full names

Автор 1 / Author 1: Лавщенко Руслан Ровшан огли / Lavshchenko Ruslan Rovshan ohly

Автор 2 / Author 2: Львов Геннадій Іванович / Lvov Gennadiy Ivanovych