

Р. Л. ОНАЦЬКИЙ, С. Ю. МІСЮРА

РОЗРОБКА МЕТОДИКИ ШВИДКОЇ ОЦІНКИ МІЦНОСТІ ПОСУДИН З ВМ'ЯТИНАМИ ЗАСОБАМИ ШІ НА ПРИКЛАДІ ФОРМУВАННЯ ДАТАСЕТУ ДЛЯ ПЛАСТИН ПІД ТИСКОМ

Посудини, що працюють під тиском, є ключовими елементами у хімічній та нафтогазовій промисловості. Забезпечення їх надійності є актуальною проблемою. Зі зростанням кількості пошкоджень внаслідок тривалої експлуатації та зокрема триваючих бойових дій в Україні, особливо поширеними стали такі види дефектів, як вм'ятини на циліндричних оболонках. Вм'ятини можуть становити значну небезпеку, що вимагає розробки швидких та точних інструментів для оцінки міцності. У даній роботі запропоновано методику формування навчального датасету для тренування моделей штучного інтелекту (ШІ) для оцінки міцності та напружено-деформованого стану посудин з локальними дефектами типу вм'ятин. Для апробації підходу та валідації методики розглядається спрощена модель тонкостінної прямокутної пластини, жорстко закріпленої по контуру та навантаженої рівномірним тиском. Детально описано процедуру створення датасету з використанням мови програмування Python, яка включає: генерацію широкого діапазону вхідних параметрів (геометрія, матеріал, навантаження); автоматизоване моделювання методом скінченних елементів (МСЕ) кожної конфігурації в Ansys, для отримання максимальних прогинів та інтенсивності напружень за Мізесом; аналітичний розрахунок прогину для верифікації МСЕ. Усі згенеровані та розраховані дані (вхідні, МСЕ, аналітичні) консолідується у файл. Для сформованого датасету проведено поглиблений аналіз: візуалізація розподілів параметрів за допомогою гістограм, розрахунок та аналіз матриці кореляцій Пірсона для виявлення взаємозв'язків, а також валідації результатів МСЕ шляхом порівняння з аналітичними розрахунками. Обґрунтовано перспективи використання створеного датасету та методики для навчання ШІ моделей, здатних виконувати експрес-діагностику стану конструкцій та вирішувати зворотні задачі механіки, зокрема для оцінки міцності циліндричних оболонок з реальними дефектами. Це сприятиме створенню ефективних інструментів для підтримки прийняття інженерних рішень.

Ключові слова: машинне навчання, метод скінченних елементів, вм'ятини, пластини, оболонки, датасет, прогнозування міцності.

R. ONATSKYI, S. MISURA

DEVELOPMENT OF A RAPID STRENGTH ASSESSMENT METHOD FOR DENTED PRESSURE VESSELS USING AI: A CASE STUDY OF DATASET FORMATION FOR RECTANGULAR PLATES UNDER PRESSURE

Pressure vessels are key components in the chemical and oil and gas industries. Ensuring their reliability is a current challenge. With an increasing number of damages due to prolonged operation and, notably, ongoing military activities in Ukraine, defects such as dents on cylindrical shells have become particularly prevalent. Dents can pose a significant hazard, necessitating the development of rapid and accurate tools for strength assessment. This paper proposes a methodology for creating a training dataset for artificial intelligence (AI) models aimed at evaluating the strength and stress-strain state of vessels with local dent-type defects. To test the approach and validate the methodology, a simplified model of a thin-walled rectangular plate, rigidly clamped at its edges and subjected to uniform pressure, is considered. The dataset creation procedure using the Python programming language is described in detail. This includes: generating a wide range of input parameters (geometry, material, load); automated finite element method (FEM) modeling of each configuration in Ansys to obtain maximum deflections and equivalent von Mises stresses; and analytical calculation of deflection for FEM verification. All generated and calculated data (input, FEM, analytical) are consolidated into a single file. A thorough analysis of the generated dataset was conducted, including: visualization of parameter distributions using histograms; calculation and analysis of the Pearson correlation matrix to identify interdependencies; and validation of FEM results by comparison with analytical calculations. The prospects of using the created dataset and methodology for training AI models capable of performing rapid structural diagnostics and solving inverse problems in mechanics, particularly for assessing the strength of cylindrical shells with real defects, are substantiated. This will contribute to the development of effective tools to support engineering decision-making.

Keywords: machine learning, finite element method, dents, plates, shells, dataset, strength prediction.

Вступ. Тонкостінні, зварні циліндричні посудини широко використовуються в промисловості для зберігання і транспортування речовин під тиском [21]. Пошкодження, зокрема вм'ятини, можуть виникати як через тривалу експлуатацію, так і внаслідок екстремальних умов, включаючи воєнні дії. Такі локальні дефекти можуть змінювати механічну поведінку оболонок і потребують оперативної оцінки міцності та залишкового ресурсу.

Традиційні методології оцінки міцності конструкцій з дефектами включають: класичні теоретичні підходи, нормативні методики та метод скінченних елементів. Класичні підходи, що базуються на теоріях пластин і оболонок (Кірхгофа, Лява [1; 2], Тимошенко [3]), та більш сучасних працях [6; 7], дозволяють швидко отримати аналітичні рішення, проте часто дають консервативну оцінку для спрощених моделей конструкцій і не враховують залишкові деформації та складність реальних дефектів

та умов експлуатації [22]. Нормативні методики, такі як галузеві стандарти України, стандарти підприємств, а також міжнародні коди (наприклад, європейські стандарти EN (European Norm), ASME (American Society of Mechanical Engineers) [18]), надають регламентовані процедури оцінки, але обмежені для нестандартних випадків.

Натомість, метод скінченних елементів [4-5; 14] є більш універсальним інструментом, що дозволяє моделювати, як складні геометрії, так і враховувати нелінійну поведінку матеріалу та залишкові деформації. Загалом, це забезпечує вищу точність результатів, однак є складним у моделюванні і вимагає значних обчислювальних ресурсів та часу на проведення розрахунків.

Незважаючи на відзначені переваги використання МСЕ, його ресурсоемність обмежує застосування для задач, що потребують оперативної оцінки. Наприклад, при масовому обстеженні конструкцій або в системах

моніторингу в реальному часі. З іншого боку, інженерам потрібні швидші й надійніші інструменти для аналізу та прийняття рішень. У цьому контексті, як альтернативний варіант для швидкої та достовірної оцінки міцності, все більшої уваги набувають методики, які б базувались на застосуванні методів штучного інтелекту, зокрема, машинного навчання (МН). ШІ може допомогти, оскільки він здатен навчатися на великих обсягах даних і робити точні прогнози.

Коротко розглянемо, чому це стало можливим саме зараз. Ідея машинного навчання не нова. Основи теорії були розроблені ще в середині XX століття такими вченими, як Вінер, Гебб, Тюрінг, Розенблатт, Відроу та Хофф та іншими [9; 13; 23; 24]. Однак у минулому обчислювальні потужності комп'ютерів були надто обмеженими, що ускладнювало навчання моделей, особливо для складних інженерних задач. Тому ці ідеї тривалий час залишалися переважно теоретичними.

Сьогодні ситуація кардинально змінилася. Ми маємо доступ до потужних комп'ютерів, хмарних обчислень, високопродуктивних графічних процесорів та розвиненого програмного забезпечення. Це дозволяє навчати складні моделі на тисячах прикладів за години, а не тижні, що раніше було неможливим.

На початкових етапах впровадження ШІ в інженерну практику застосовувалися переважно прості моделі машинного навчання, такі як регресійні [16] моделі, прямі нейронні мережі, а згодом і більш складні архітектури [14; 15], такі як згорткові або графові нейронні мережі [24] та мережі глибокого навчання [17; 24]. Ці моделі навчаються виключно на даних, ігноруючи фундаментальні фізичні закони, що лежать в основі моделювання процесів. Такий підхід може призводити до нефізичних або помилкових прогнозів, особливо в задачах механіки деформівного твердого тіла, де точність і надійність є критично важливими.

Натомість, фізично-поінформовані нейронні мережі (PINNs) (Physics-Informed Neural Networks) [7; 8] працюють інакше. Вони інтегрують фізичні закони безпосередньо в процес навчання. Наприклад, під час навчання PINNs можуть використовувати рівняння з теорії пружності, такі як рівняння рівноваги, умови сумісності деформацій та закони поведінки матеріалів (наприклад, закон Гука) [10; 11]. Це дозволяє створювати моделі, здатні не лише апроксимувати дані, але й дотримуватися базових фізичних принципів, що значно підвищує їх точність та надійність. Зростання обсягів даних і розвиток обчислювальних потужностей загалом стимулювали впровадження машинного навчання та, зокрема, PINNs [10; 11] для задач механіки. Ці підходи дозволяють створювати моделі, здатні швидко прогнозувати напружено-деформований стан та оцінювати міцність конструкцій на основі попередньо згенерованих датасетів, що є особливо актуальним для задач експрес-діагностики та оптимізації.

Ключовим аспектом для успішного застосування МН і схожих підходів ШІ є наявність якісного та репрезентативного датасету, який би охоплював широкий діапазон можливих геометрій, матеріалів та умов навантаження. Саме формуванню такого датасету, як першого кроку до розробки надійних моделей, присвячена дана робота. У статті запропоновано комплексну методику, що поєднує генерацію параметрів та автоматизоване моделювання методом скінченних елементів для створення бази даних, призначеної для навчання моделей та прогнозування міцності тонкостінних пластин.

Поточна робота над датасетом для пластин є основою для подальшого аналізу більш складних конструкцій та валідації запропонованих підходів. В перспективі, планується використовувати PINNs для оцінки міцності циліндричних оболонок із вм'ятинами, що дозволить швидше й надійніше прогнозувати поведінку таких конструкцій.




Рис.1 – Модель пластини навантаженої розподіленим тиском і закріпленої по периметру де, a – довжина сторони пластини; t – товщина пластини; p – інтенсивність рівномірно розподіленого тиску

Постановка задачі. Метою даного дослідження є розробка програмного забезпечення для формування комплексного датасету, який може бути використано для тренування моделей в комплексній методиці машинного навчання, призначеній для прогнозування

складових напружено-деформованого стану (НДС) та оцінки міцності тонкостінних квадратних пластин.

Розглядається сталева пластина з жорстко закріпленими краями, що знаходиться під дією рівномірно розподіленого тиску (див. рис. 1).

Вхідними параметрами для моделювання є:

- геометричні характеристики: довжина сторони пластини a та її товщина t ;
- фізико-механічні властивості матеріалу: модуль пружності E та коефіцієнт Пуассона ν ;
- параметри навантаження: інтенсивність рівномірно розподіленого тиску p .

Цільовими вихідними характеристиками, які необхідно прогнозувати, є:

- максимальний прогин у центрі пластини w_{max} ;
- максимум інтенсивності напружень за Мізесом σ_{eqv} , що виникають у пластині.

Додатково, для повноти аналізу, можуть розглядатися компоненти тензора напружень (σ_x, σ_y) та

деформацій ($\varepsilon_x, \varepsilon_y$), тому їх також буде збережено в повному датасеті.

Діапазони зміни вхідних параметрів обрано таким чином, щоб вони відповідали реальним конструкційним сталям та типовим умовам експлуатації:

- довжина сторони a від 0.5 до 1.5 м,
- товщина t від 0.02 до 0.04 м,
- модуль пружності E від 2.0 до $2.1 \cdot 10^5$ МПа,
- коефіцієнт Пуассона ν від 0.27 до 0.3,
- тиск p від 0.01 до 0.05 МПа.



Рис. 2 – Загальна схема методики оцінки міцності із використанням моделей ІІІ

При формуванні датасету важливо забезпечити фізичну коректність змодельованих даних. Зокрема, необхідно, щоб були враховані умови малих прогинів (максимальний прогин не перевищує товщину пластини, $w_{max} < t$) для відповідності класичним теоріям згину пластин і оболонок [3].

Методика формування датасету. Загальна схема методики оцінки міцності пластин і оболонок наведена на рис. 2. Варто зазначити, що подібна принципова схема, у перспективі, буде використана і для оболонок з дефектами. На даному етапі дослідження ми сфокусуємось лише на послідовності формування датасету (див. рис 2. перші три блоки).

Зазначена послідовність включає такі ключові етапи:

- генерація широкого спектру вхідних параметрів, що характеризують геометрію, матеріал та навантаження конструкції;
- для кожної комбінації параметрів виконується детальне чисельне моделювання МСЕ для отримання значень НДС (цей етап також включає верифікацію і валідацію через аналітичний розрахунок)
- результати обох підходів об'єднуються, формуючи повний датасет готовий для тренування моделей МН

Сформований датасет необхідно проаналізувати на предмет повноти, розподілу даних та виявлення кореляцій. А також перевірити відповідність умови малих прогинів.

Датасет повинен бути придатним для тренування в подальшому моделей машинного навчання, зокрема фізично-поінформованих нейронних мереж.

Генерація вхідних даних для визначених діапазонів. На першому етапі формування датасету визначаються ключові вхідні параметри, що описують геометрію пластини, властивості матеріалу та умови навантаження. Для забезпечення репрезентативності та різноманітності даних було розроблено скрипт, написаний з використанням мови програмування Python, і використанням бібліотек NumPy та pandas.

Генерація параметрів відбувається випадковим чином у заздалегідь визначених фізично обґрунтованих діапазонах, а саме:

- довжина сторони a від 0.5 до 1.5 м,
- товщина t від 0.02 до 0.04 м,
- модуль пружності E від 2.0 до $2.1 \cdot 10^5$ МПа,
- коефіцієнт Пуассона ν від 0.27 до 0.3,
- тиск p від 0.01 до 0.05 МПа.

Скрипт забезпечує рівномірний розподіл значень у вказаних діапазонах, а також, з 50% імовірністю, обирає округлені до цілих значення з попередньо визначеного набору для спрощення подальшої

валідації та аналітичної перевірки, в тому числі і ручних перевірок за відомими аналітичними формулами. Для кожного набору згенерованих параметрів реалізовано перевірку на унікальність та фізичну допустимість комбінацій, щоб уникнути нереалістичних сценаріїв. Згенеровані дані зберігаються у файл (*input_data.csv*) для подальшої

обробки. Загальний вигляд даних приведено у таблиці 1 (див. перші п'ять колонок). Гістограми розподілу даних можна переглянути на рис. 6.1 – 6.2.

Таблиця 1 – Зведена таблиця датасету згенерованих даних і розрахункових

Case	a , м	t , мм	E , 10^5 МПа	ν	p , Па	$W_{\max}^{\text{FEA}}$, мм	$W_{\max}^{\text{analytical}}$, мм	σ_{eqv} , МПа	σ_x , МПа	σ_y , МПа
1	0.70	3.50	2.050	0.28	15000.00	0.005955	0.005764	0.8191	0.8198	0.8198
2	1.069	2.59	2.0255	0.2879	41206.20	0.2144	0.2132	9.595	9.613	9.613
3	1.50	2.50	2.100	0.29	40000.00	0.8604	0.8587	19.72	19.78	19.78
4	1.10	3.50	2.050	0.29	10000.00	0.02350	0.02318	13.54	13.56	13.56
5	1.00	2.00	2.000	0.28	10000.00	0.08786	0.08792	33.99	34.06	34.06
6	0.50	2.00	2.050	0.29	20000.00	0.01085	0.01061	17.16	17.18	17.18
7	1.131	3.10	2.0537	0.2892	12007.38	0.04506	0.04466	21.86	21.90	21.90
8	1.364	3.72	2.0077	0.2928	26025.85	0.1219	0.1206	47.96	48.04	48.04
9	1.20	2.50	2.100	0.3	45000.00	0.3948	0.3913	143.10	143.43	143.43
10	0.60	3.00	2.100	0.3	40000.00	0.01312	0.01272	22.17	22.19	22.19
...										
455	1.087	2.78	2.0498	0.2815	47289.88	0.2115077	0.2107	98.46	98.62	98.62
...										
998	0.978	3.94	2.05087	0.2987	26273.68	0.02743	0.02669	22.51	22.53	22.53
999	1.50	4.00	2.100	0.3	15000.00	0.07878	0.07774	29.13	29.18	29.18
1000	0.60	2.50	2.050	0.29	10000.00	0.005773	0.005630	7.911	7.919	7.919

Автоматизоване МСЕ-моделювання в Ansys.

Наступним кроком є детальне моделювання поведінки пластини методу скінченних елементів в програмному комплексі Ansys[20]. Для цього для кожної комбінації згенерованих вхідних параметрів, виконується чисельний розрахунок.

Процес автоматизовано за допомогою скриптів з використанням мови APDL (Ansys Parametric Design Language)[19].



Рис. 3 – Головна послідовність отримання розрахункових даних для одного кейсу датасету

Основний скрипт містить головний цикл, який ітеративно виконує розрахунки і записує результати у файл. Принципову діаграму послідовності однієї ітерації можна побачити на рис. 3. Згідно діаграми скрипт спочатку зчитує черговий набір параметрів (геометрія, властивості матеріалу, навантаження) з вхідного файлу (*input_data.csv*). Далі, на основі цих даних автоматично будується геометрична модель пластини, генерується скінченно-елементна сітка, прикладаються граничні умови (жорстке закріплення по контуру) та навантаження рівномірним тиском.

Перед проведенням масових розрахунків було виконано дослідження збіжності сітки МСЕ. Розглядалися різні варіанти з різною густиною та розміром скінченних елементів, щоб забезпечити достатню точність результатів при оптимальних обчислювальних витратах. На рисунку 4 наведена фінальна версія скінченно-елементної сітки моделі пластини. Ця модель містить 2000 скінченних елементів.

Додатково, для моделювання пластини використовувалися два типи скінченних елементів: оболонкові елементи і об'ємні елементи.

Використання обох типів елементів було обумовлене необхідністю валідації моделі та підготовкою методики до майбутнього переходу на моделювання пластин та оболонок з локальними дефектами типу вм'ятин, де об'ємні елементи можуть бути більш доцільними для точного опису геометрії дефекту.






Рис. 4 – Сітка СЕ моделі пластини

Після визначення оптимальних параметрів сітки, вони були використані для всіх подальших розрахунків.

Рис. 5 – Розподіл прогину, w_{max} та інтенсивності напружень по Мізесу, σ_{eqv}

Аналітичний розрахунок прогину для верифікації МСЕ. Для валідації результатів, отриманих за допомогою МСЕ-моделювання в Ansys, було проведено аналітичний розрахунок максимального прогину в центрі пластини. Цей розрахунок базується на класичній теорії згину тонких пластин Кірхгофа-Лява [3; 12]. Згідно якої максимальний прогин w_{max} для квадратної пластини з жорстко закріпленими краями під дією рівномірного розподіленого тиску p визначається за формулою:

$$w_{max} = \alpha \frac{pa^4}{D} \quad (1)$$

$$D = \frac{Et^3}{12(1-\nu^2)} \quad (2)$$

де: a – довжина сторони пластини; D – циліндрична жорсткість пластини, що обчислюється згідно формули 2; E – модуль пружності матеріалу; t – товщина пластини; ν – коефіцієнт Пуассона; α – безрозмірний коефіцієнт, який залежить від співвідношення сторін пластини та типу граничних умов.

Для квадратної пластини з жорстко закріпленими краями $\alpha \approx 0.00126$ (згідно з [12]).

Аналітичні розрахунки виконувались для кожної комбінації вхідних параметрів і порівнювались з

результатами моделювання МСЕ в центрі пластини визначались: прогин w_{max} , інтенсивність напружень за Мізесом σ_{eqv} , а також компоненти тензора напружень (σ_x , σ_y) та деформацій (ϵ_x , ϵ_y). Отримані значення записувались у файл (*fem_results.csv*). Додатково зберігались зображення розподілення прогину та напружень у файли. Приклад таких зображень для однієї ітерації наведено на рис. 5.

З рисунку 5 видно, що максимальний прогин w_{max} знаходиться в центрі пластини, а розподіл напружень є симетричним відносно обох площин симетрії.

Значення прогинів і напружень в центрі пластини для деяких випадків наведено в таблиці 1. (див. колонки: w_{max}^{FEA} , σ_{eqv} , σ_x , σ_y). Із аналізу розподілу на напружень σ_x , σ_y видно, що вони однакові, що відповідає фізичній поведінці розрахункової моделі.


результатами моделювання МСЕ. Процес обчислення було автоматизовано за допомогою Python-скрипта. Результат розрахунку зведено в таблицю (див. табл. 1, колонка $w_{max}^{analytical}$).

В результаті, дозволило проводити оцінку точності чисельних моделей на кожній ітерації для підтвердження коректності налаштувань Ansys.

Об'єднання даних у базу даних. Кінцевим етапом формування датасету є консолідація всіх отриманих даних в єдину базу даних, у вигляді таблиці, яка собою представляє файл (*full_dataset.csv*), що включає об'єднання:

- вхідних параметрів (*input_data.csv*);
- результатів моделювання (*fem_results.csv*)
- результатів аналітичного розрахунку.

Кожний рядок цього файлу відповідає одному унікальному набору вхідних параметрів та містить відповідні їм розрахункові значення. Такий формат забезпечує зручність подальшої обробки, аналізу та використання даних для тренування моделей машинного навчання. Приклад даних наведено в табл. 1.

Рис. 6.1 – Гістограма розподілення параметру p

Аналіз даних. Після формування консолідованого датасету було проведено його детальний аналіз з метою виявлення основних статистичних характеристик, взаємозв'язків між параметрами та перевірки якості даних.

Цей етап є важливим для розуміння структури даних та підготовки їх до використання в моделях машинного навчання.

Розподіл вхідних та вихідних параметрів. Для візуалізації розподілу кожного з вхідних (геометричні розміри, властивості матеріалу, навантаження) та вихідних (прогини, напруження) параметрів були

побудовані гістограми. Це дозволило не лише оцінити діапазони значень змінних, а й виявити потенційні викиди, перевірити повноту покриття заданих інтервалів, а також визначити характер розподілу - рівномірний, нормальний чи зсунутий.

Гістограма розподілу навантаження у вигляді розподіленого тиску p наведена на рисунку 6.1.

Гістограми для довжини сторони пластини a , товщини t , модуля пружності E та коефіцієнта Пуассона ν представлені на рисунку 6.2.

Аналіз гістограм показує, що згенеровані вхідні параметри покривають визначені діапазони без значних перекосів у бік крайніх значень. Для змінних a і p спостерігається більш рівномірний розподіл, тоді як інші демонструють невеликі скупчення в центральних і крайових зонах діапазону, що зумовлено особливостями алгоритму генерації та фізичними обмеженнями моделі.

Розподіли вихідних параметрів, таких як максимальний прогин та напруження, також аналізувалися для розуміння їх статистичних властивостей.





 a  b  ν  ν

Рис. 6.2 – Гістограми параметрів датасету (продовження)

a – довжина сторони, b – товщина, ν – модуль пружності, ν – коефіцієнт Пуассона.

Кореляційний аналіз. Для виявлення лінійних взаємозв'язків між різними параметрами датасету була розрахована та візуалізована матриця кореляцій Пірсона[24]. Кожен елемент матриці показує коефіцієнт кореляції між двома змінними, який варіюється від -1, що характеризує сильний негативний

зв'язок (на тепловій мапі позначено більш синім кольором) до +1, що являє собою сильний позитивний зв'язок (на тепловій мапі позначено червоним кольором), при цьому 0 означає відсутність лінійної кореляції (сірий колір на тепловій мапі).

Кореляційна матриця представлена на рисунку 7. Проаналізувавши отримані співвідношення можна зазначити наступні закономірності. Явно прослідковуються сильні позитивні кореляції між довжиною сторони пластини a та максимальним прогином w (0.601), а також між a та напруженнями σ_x , σ_y (0.617) і деформаціями ε_x , ε_y (0.618). Це узгоджується з теоретичними уявленнями, оскільки збільшення розміру пластини при тому ж навантаженні очікувано призводить до зростання прогинів та напружень.

Товщина пластини t демонструє очікувану помірну негативну кореляцію з прогином w (-0.421) та напруженнями/деформаціями (близько -0.473). Збільшення товщини підвищує жорсткість пластини, що веде до зменшення її деформованості та рівня напружень.

Тиск p має помірну позитивну кореляцію з прогином w (0.314) та сильнішу позитивну кореляцію з напруженнями σ_x , σ_y (0.475) і деформаціями ε_x , ε_y (0.476), що відображає пряму залежність НДС від величини прикладеного навантаження.

Дуже високі позитивні кореляції (близько 0.95-0.99) спостерігаються між максимальним прогином w та компонентами напружень і деформацій, а також між самими компонентами напружень (σ_x , σ_y) та деформацій (ε_x , ε_y). Це є наслідком фізичних співвідношень теорії пружності та тим фактом, що задача є симетричною відносно відповідних осей (наприклад, σ_x та σ_y мають коефіцієнт кореляції 1.0, що очікувано для центральної точки симетрично навантаженої квадратної пластини).

Цікаво відзначити, що модуль пружності E та коефіцієнт Пуассона ν показують дуже слабкі кореляції (менше 0.06) з більшістю вихідних параметрів. Це може бути пояснено доволі вузьким діапазоном їх варіації у згенерованому датасеті. Хоча ці параметри фундаментально впливають на жорсткість, їх незначна зміна в межах датасету не призводить до сильних лінійних залежностей порівняно з параметрами, що змінюються в ширших діапазонах, як наприклад a або p .




Рис. 7 – Кореляційна матриця параметрів датасету

Загалом, результати кореляційного аналізу підтверджують фізичність згенерованого датасету та вказують на ключові параметри, що визначають напружено-деформований стан пластини. Ця інформація є важливою для подальшого відбору ознак та побудови моделей машинного навчання.

Висновки. В роботі було проаналізовано актуальність проблематики вм'ятин на циліндричних оболонках і зазначено, що вони можуть становити серйозну загрозу для безпеки посудин під тиском. Також зазначено, що відомі традиційні методи аналізу їх міцності є часозатратними та вимагають високої кваліфікації інженерів. Як альтернатива було запропоновано методику швидкої оцінки міцності на основі методів штучного інтелекту.

Для апробації методики в роботі представлено послідовність формування датасету, для оцінки напружено-деформованого стану, на прикладі спрощеної моделі, а саме тонкостінних квадратних пластин під тиском, що є підготовчим етапом до більш комплексного аналізу міцності посудин з вм'ятинами.

В ході дослідження було розроблено програмне забезпечення на основі Python-скриптів для автоматизації процесу генерації даних, для формування вхідних параметрів, автоматизованого MCE-моделювання в Ansys для розрахунку прогинів та напружень, та аналітичні розрахунки для верифікації.

Проведено дослідження збіжності MCE та валідацію результатів, що підтвердило коректність сформованого датасету.

Отриманий датасет слугуватиме основою для навчання моделей машинного навчання, зокрема PINNs, здатних виконувати експрес-діагностику та прогнозування міцності.

Запропонована методика формування датасету для швидкої оцінки міцності пластин продемонструвала свою ефективність і може бути розширена для створення датасетів для циліндричних оболонок з вм'ятинами.

Це дослідження показує, що підходи із застосуванням штучного інтелекту, зокрема на базі таких датасетів, можуть запропонувати новий потужний інструмент для швидкої оцінки стану пошкоджених конструкцій.

У подальшому планується розширення датасету та застосування розробленої методики до реальних геометрій циліндричних оболонок з дефектами. Щоб дозволити інженерам приймати швидші та більш обґрунтовані рішення щодо безпеки експлуатації, особливо в критичних ситуаціях, пов'язаних з промисловими аваріями або військовими ризиками.

Список літератури

1. Love A. E. H. A Treatise on the Mathematical Theory of Elasticity. Cambridge: Cambridge University Press, 2013. – 662 p. – ISBN 978-1-107-61809-1.
2. Ozenda O., Virga E. G. On the Kirchhoff–Love Hypothesis (Revised and Vindicated). Journal of Elasticity. 2021;143(2):359–384. DOI: <https://doi.org/10.1007/s10659-021-09819-7>

3. Timoshenko S. P., Woinowsky-Krieger S. Theory of plates and shells. 2nd ed. New York: McGraw-Hill, 1989. – 580 p. – (McGraw-Hill International Series)
4. Zienkiewicz O. C., Taylor R. L., Govindjee S. The Finite Element Method: Its Basis and Fundamentals. 8th ed. Oxford: Butterworth-Heinemann, 2024. – 650 p.
5. Bathe K. J. Finite Element Procedures. 2nd ed. Watertown, MA: Klaus-Jürgen Bathe, 2014. – 1037 p.
6. Gerasimidis S., Hutchinson J. W. Dent imperfections in shell buckling: the role of geometry, residual stress, and plasticity // Journal of Applied Mechanics. – 2021. – Vol. 88, № 3. <https://doi.org/10.1115/1.4048807>
7. Derveni F., Abbasi A., Reis P. M. Defect-defect interactions in the buckling of imperfect spherical shells // Journal of Applied Mechanics. – 2025. – Vol. 92, No. 4. <https://doi.org/10.1115/1.4062774>
8. Goodfellow I., Bengio Y., Courville A. Deep Learning. – Cambridge, MA: MIT Press, 2016. – 775 p. – ISBN 9780262035613.
9. Bishop C. M. Pattern Recognition and Machine Learning. – New York: Springer, 2006. – 738 p. – ISBN 9780387310732
10. Raissi M., Perdikaris P., Karniadakis G. E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations // Journal of Computational Physics. – 2019. – Vol. 378. – P. 686–707. <https://doi.org/10.1016/j.jcp.2018.10.045>
11. Karniadakis G. E., Kevrekidis I. G., Lu L., Perdikaris P., Wang S., Yang L. Physics-informed machine learning // Nature Reviews Physics. – 2021. – Vol. 3. – P. 422–440. <https://doi.org/10.1038/s42254-021-00314-5>
12. Imrak C. E., Gerdemeli İ. An exact solution for the deflection of a clamped rectangular plate under uniform load // Applied Mathematical Sciences. – 2007. – Vol. 1, No. 43. – P. 2129–2137. <https://doi.org/10.1007/s10778-007-0069-8>
13. McCulloch W. S., Pitts W. A logical calculus of the ideas immanent in nervous activity // Bulletin of Mathematical Biophysics. – 1943. – Vol. 5, No. 4. – P. 115–133. <https://doi.org/10.1007/BF02478259>
14. Nath D., Ankit, Neog D. R., et al. Application of machine learning and deep learning in finite element analysis: a comprehensive review // Archives of Computational Methods in Engineering. – 2024. – Vol. 31. – P. 2945–2984. <https://doi.org/10.1007/s11831-024-10063-0>
15. Rumelhart D. E., Hinton G. E., Williams R. J. Learning representations by back-propagating errors // Nature. – 1986. – Vol. 323. – P. 533–536. <https://doi.org/10.1038/323533a0>
16. Vapnik V. The Nature of Statistical Learning Theory. – New York: Springer, 1995. – 314 p. – ISBN 9780387987804 <https://doi.org/10.1007/978-1-4757-2440-0>
17. Le Cun Y., Bengio Y., Hinton G. Deep learning // Nature. – 2015. – Vol. 521. – P. 436–444. <https://doi.org/10.1038/nature14539>
18. API 579-1/ASME FFS-1:2021. Fitness for Service. 4th ed. Washington, D.C.: American Petroleum Institute; American Society of Mechanical Engineers, 2021. – 1478 c.
19. Miller E., Strain J., PADT Inc., Introduction to the ANSYS Parametric Design Language (APDL). 2nd ed. – [S.l.]: PADT Inc., 2016. – Paperback. – ISBN 978-0-692-52696-1.
20. Thompson M. K., Thompson J. M. ANSYS Mechanical APDL for Finite Element Analysis. 1st ed. – Oxford: Butterworth-Heinemann, 2017. – ISBN 978-0-12-813110-7 <https://doi.org/10.1016/B978-0-12-812981-4.00001-0>
21. Мікульонюк І. О. Виготовлення обладнання хімічних виробництв. – Київ : КНІ ім. Ігоря Сікорського», 2022. – 233 с
22. Reissner, E. The Effect of Transverse Shear Deformation on the Bending of Elastic Plates. Journal of Applied Mechanics, 1945, vol. 12, p69–77. <https://doi.org/10.1115/1.4009435>
23. Rosenblatt, F.. The Perceptron: A Perceiving and Recognizing Automaton. Report – 1957, 85-60-1. Cornell Aeronautical Laboratory, Buffalo, New York.
24. Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. – 2nd ed. – New York: Springer, 2009. – 745 p <https://doi.org/10.1007/978-0-387-84858-7>

References (transliterated)

1. Love A. E. H. A Treatise on the Mathematical Theory of Elasticity. Cambridge: Cambridge University Press, 2013. – 662 p. – ISBN 978-1-107-61809-1.
2. Ozenda O., Virga E. G. On the Kirchhoff-Love Hypothesis (Revised and Vindicated). Journal of Elasticity. 2021;143(2):359–384. DOI: <https://doi.org/10.1007/s10659-021-09819-7>
3. Timoshenko S. P., Woinowsky-Krieger S. Theory of plates and shells. 2nd ed. New York: McGraw-Hill, 1989. – 580 p. – (McGraw-Hill International Series)
4. Zienkiewicz O. C., Taylor R. L., Govindjee S. The Finite Element Method: Its Basis and Fundamentals. 8th ed. Oxford: Butterworth-Heinemann, 2024. – 650 p.
5. Bathe K. J. Finite Element Procedures. 2nd ed. Watertown, MA: Klaus-Jürgen Bathe, 2014. – 1037 p.
6. Gerasimidis S., Hutchinson J. W. Dent imperfections in shell buckling: the role of geometry, residual stress, and plasticity // Journal of Applied Mechanics. – 2021. – Vol. 88, № 3. <https://doi.org/10.1115/1.4048807>
7. Derveni F., Abbasi A., Reis P. M. Defect-defect interactions in the buckling of imperfect spherical shells // Journal of Applied Mechanics. – 2025. – Vol. 92, No. 4. <https://doi.org/10.1115/1.4062774>
8. Goodfellow I., Bengio Y., Courville A. Deep Learning. – Cambridge, MA: MIT Press, 2016. – 775 p. – ISBN 9780262035613.
9. Bishop C. M. Pattern Recognition and Machine Learning. – New York: Springer, 2006. – 738 p. – ISBN 9780387310732
10. Raissi M., Perdikaris P., Karniadakis G. E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations // Journal of Computational Physics. – 2019. – Vol. 378. – P. 686–707. <https://doi.org/10.1016/j.jcp.2018.10.045>
11. Karniadakis G. E., Kevrekidis I. G., Lu L., Perdikaris P., Wang S., Yang L. Physics-informed machine learning // Nature Reviews Physics. – 2021. – Vol. 3. – P. 422–440. <https://doi.org/10.1038/s42254-021-00314-5>
12. Imrak C. E., Gerdemeli İ. An exact solution for the deflection of a clamped rectangular plate under uniform load // Applied Mathematical Sciences. – 2007. – Vol. 1, No. 43. – P. 2129–2137. <https://doi.org/10.1007/s10778-007-0069-8>
13. McCulloch W. S., Pitts W. A logical calculus of the ideas immanent in nervous activity // Bulletin of Mathematical Biophysics. – 1943. – Vol. 5, No. 4. – P. 115–133. <https://doi.org/10.1007/BF02478259>
14. Nath D., Ankit, Neog D. R., et al. Application of machine learning and deep learning in finite element analysis: a comprehensive review // Archives of Computational Methods in Engineering. – 2024. – Vol. 31. – P. 2945–2984. <https://doi.org/10.1007/s11831-024-10063-0>
15. Rumelhart D. E., Hinton G. E., Williams R. J. Learning representations by back-propagating errors // Nature. – 1986. – Vol. 323. – P. 533–536. <https://doi.org/10.1038/323533a0>
16. Vapnik V. The Nature of Statistical Learning Theory. – New York: Springer, 1995. – 314 p. – ISBN 9780387987804 <https://doi.org/10.1007/978-1-4757-2440-0>
17. LeCun Y., Bengio Y., Hinton G. Deep learning // Nature. – 2015. – Vol. 521. – P. 436–444. <https://doi.org/10.1038/nature14539>
18. API 579-1/ASME FFS-1:2021. Fitness for Service. 4th ed. Washington, D.C.: American Petroleum Institute; American Society of Mechanical Engineers, 2021. – 1478 s.
19. Miller E., Strain J., PADT Inc., Introduction to the ANSYS Parametric Design Language (APDL). 2nd ed. – [S.l.]: PADT Inc., 2016. – Paperback. – ISBN 978-0-692-52696-1.
20. Thompson M. K., Thompson J. M. ANSYS Mechanical APDL for Finite Element Analysis. 1st ed. – Oxford: Butterworth-Heinemann, 2017. – ISBN 978-0-12-813110-7 <https://doi.org/10.1016/B978-0-12-812981-4.00001-0>
21. Mikulonok I. O. Vyhotovlennia obladnannia khimichnykh vyrobnystv. – Kyiv : KPI im. Ihoria Sikorskoho», 2022. – 233 c
22. Reissner, E. The Effect of Transverse Shear Deformation on the Bending of Elastic Plates. Journal of Applied Mechanics, 1945, vol. 12, p69–77. <https://doi.org/10.1115/1.4009435>
23. Rosenblatt, F. The Perceptron: A Perceiving and Recognizing Automaton. Report – 1957, 85-60-1. Cornell Aeronautical Laboratory, Buffalo, New York.

24. Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. – 2nd ed. – New York: Springer, 2009. – 745 p <https://doi.org/10.1007/978-0-387-84858-7>

Надійшла (received) 02.06.2025
Прийнята до друку (accepted) 01.09.2025
Опублікована (published) 03.09.2025

Відомості про авторів / About the Authors

Онацький Роман Леонідович (Onatskyi Roman) – Національний технічний університет «Харківський політехнічний інститут», аспірант кафедри Математичного моделювання та інтелектуальних обчислень в інженерії; м. Харків, Україна; тел.: (098) 591-39-30; ORCID: <https://orcid.org/0009-0004-6305-8442>; e-mail: roman.onatskyi@infiz.khpi.edu.ua

Місюра Сергій Юрійович (Misura Serhii) – кандидат технічних наук, доцент, Національний технічний університет «Харківський політехнічний інститут», доцент кафедри Математичного моделювання та інтелектуальних обчислень в інженерії; м. Харків, Україна; тел.: (050) 984-57-15; ORCID: <https://orcid.org/0000-0002-5048-1610>; e-mail: misurasy@gmail.com