

Р.В. Мисюк, П.Р. Кулик, О.В. Гусак, О.С. Чмихало, В.О. Парубочий  
**МЕТОД ОЦІНЮВАННЯ СТАНУ ЕЛЕМЕНТУ ІНЖЕНЕРНОЇ  
КОНСТРУКЦІЇ З ВИКОРИСТАННЯМ ПОЯСНЮВАЛЬНОГО ШТУЧНОГО  
ІНТЕЛЕКТУ ТА МУЛЬТИМОДАЛЬНИХ ДАНИХ**

*Анотація.* У сучасних умовах розвитку технологій штучного інтелекту особливої актуальності набуває розробка інтелектуальних методів оцінювання технічного стану елементів інженерних конструкцій, здатних забезпечувати не лише автоматизовану класифікацію, а й інтерпретованість отриманих результатів. Це є важливим для задач моніторингу трубопроводів, будівельних конструкцій та інших відповідальних об'єктів, де своєчасне виявлення дефектів дозволяє знизити ризик аварійних ситуацій. Метою роботи є розробка підходу до оцінювання стану елемента інженерної конструкції з використанням методів машинного навчання та пояснювального штучного інтелекту на основі мультимодальних даних. У роботі сформовано набір даних, що включає частку дефектної області поверхні (*DefectRatio*), а також параметри вологості та температури. На основі цих ознак здійснювалося визначення технічного стану конструкції за трьома класами: «Норма», «Попередження» та «Критичний». Для побудови моделей класифікації використано алгоритми *Random Forest*, *XGBoost*, *LightGBM*, *Support Vector Machine* та *Logistic Regression* із застосуванням гіперпараметричної оптимізації та перехресної валідації. Експериментальні результати показали, що найвищу точність класифікації на тестовій вибірці забезпечили моделі *Random Forest* та *XGBoost* (0,90), тоді як *Logistic Regression*, *SVM* та *LightGBM* продемонстрували нижчі результати (0,80, 0,70 та 0,60 відповідно). Аналіз важливості ознак підтвердив домінуючу роль показника *DefectRatio* у формуванні класифікаційного рішення, тоді як параметри зовнішнього середовища мають допоміжний контекстний вплив. Для підвищення прозорості прийняття рішень застосовано підходи пояснювального штучного інтелекту, зокрема *Permutation Importance*, *SHAP*-аналіз та правилоорієнтовані пояснення, що дозволило отримати як глобальну, так і локальну інтерпретацію результатів роботи моделей. Отримані результати підтверджують доцільність використання поєднання машинного навчання, мультимодального аналізу та ХАІ для побудови інтелектуальних систем моніторингу технічного стану інженерних конструкцій.

*Ключові слова:* пояснювальний штучний інтелект, інженерія ознак, обробка мультимодальних даних, обробка зображень, інтелектуальний моніторинг, класифікація машинного навчання, аналіз ризиків, поверхневі дефекти, тріщина.

**Вступ.** Процес оцінювання технічного стану елементів інженерних конструкцій є складним завданням, що потребує значних часових, обчислювальних та інтелектуальних ресурсів. Основними ознаками, що використовуються під час такого оцінювання, є геометричні характеристики дефектів, зокрема довжина та ширина тріщин, рівень достовірності їх виявлення, а також зовнішні фактори впливу, такі як температура та вологість середовища. У зв'язку з цим особливий інтерес становить застосування рішень на основі штучного інтелекту, машинного навчання та пояснювальних підходів, що демонструють високу ефективність у задачах структурного моніторингу та технічної діагностики. Обробка великого обсягу мультимодальних даних дозволяє здійснювати ефективний контроль стану конструкцій, виявляти ознаки деградації, прогнозувати ризики пошкодження та приймати обґрунтовані рішення щодо експлуатації об'єктів.

Задача розробки інтелектуальних моделей, що забезпечують високу точність оцінювання технічного стану елементів інженерних конструкцій за мінімальних обчислювальних та часових витрат, а також надають можливість інтерпретації отриманих результатів. Вирішення цього завдання сприятиме розвитку цифрових технологій у сфері технічного моніторингу, підвищенню рівня безпеки експлуатації інженерних об'єктів та своєчасному виявленню критичних змін у їхньому стані.

Метою роботи є розробка методу оцінювання стану елементу інженерної конструкції з використанням пояснювального штучного інтелекту та перевірка роботи його на практиці.

**Аналіз останніх досліджень і публікацій.** Оцінювання технічного стану елементів інженерних конструкцій є одним із ключових напрямів сучасного структурного моніторингу, оскільки своєчасне виявлення дефектів, прогнозування їх розвитку та інтерпретація ознак пошкодження безпосередньо впливають на безпеку експлуатації інфраструктурних об'єктів. Упродовж останніх років у цій галузі спостерігається активне впровадження методів штучного інтелекту, комп'ютерного зору, мультимодальної обробки даних та пояснювального машинного навчання. Аналіз сучасних досліджень свідчить, що наукові праці в цій сфері можна умовно поділити на чотири основні напрями: автоматичне виявлення дефектів за зображеннями, оцінювання стану за сенсорними сигналами, мультимодальне поєднання даних та забезпечення інтерпретованості рішень моделей.

Попередні дослідження демонструють ефективність використання роботизованих платформ та IoT для автоматизованого виявлення дефектів у інфраструктурних об'єктах [1, 2]. Аналіз відеопотоків з застосуванням методів машинного навчання дозволяє класифікувати тріщини та пошкодження з високою точністю, що підтверджується експериментальними даними [2, 3]. Використання доступних сенсорів і мікрокомп'ютерів, таких як Raspberry Pi, забезпечує масштабоване і економічне рішення для моніторингу стану трубопроводів та дорожніх покриттів [4].

Значна частина сучасних досліджень присвячена **автоматизованому виявленню тріщин на поверхнях інженерних конструкцій** із використанням методів комп'ютерного зору та глибокого навчання. У роботі [5] показано ефективність глибо-

ких нейронних мереж для виявлення тріщин усередині конструкцій. У дослідженні [6] запропоновано підхід до оцінювання стану бетонних конструкцій на основі автоматизованого виявлення тріщин для різних типів бетонних поверхонь. Подібно, у праці [7] розглянуто застосування глибокого навчання не лише для детектування, а й для прогнозування розвитку тріщин у задачах структурного моніторингу. Ці роботи підтверджують високу ефективність візуального аналізу для виявлення дефектів, однак здебільшого зосереджуються саме на факті пошкодження, а не на комплексному оцінюванні технічного стану.

Окремий напрям досліджень стосується використання **сенсорних даних** для моніторингу інженерних конструкцій. У роботі [8] запропоновано метод структурного моніторингу на основі Bluetooth-мережі тензометричних датчиків та алгоритмів машинного навчання для виявлення і локалізації тріщин. У дослідженні [9] розглянуто автоматизовану ідентифікацію тріщин за акустичними хвильовими сигналами із застосуванням глибокого навчання. Такі підходи демонструють, що фізичні вимірювальні канали можуть слугувати важливим джерелом інформації про стан конструкції навіть без прямого візуального спостереження за дефектом.

Водночас сучасні дослідження все частіше орієнтуються на **інтеграцію різнорідних джерел інформації**. У роботі [10] наведено комплексний огляд розвитку штучного інтелекту для структурного моніторингу, де підкреслюється доцільність поєднання візуальних, сенсорних і часових даних для підвищення достовірності оцінювання технічного стану. У праці [11] запропоновано підхід до дослідження тріщиноутворення на основі поєднання реальних інженерних даних із фізичними обмеженнями, що є перспективним напрямом для побудови більш надійних і стійких моделей аналізу пошкоджень.

Особливої актуальності в задачах структурного моніторингу набуває **пояснювальний штучний інтелект (ХАІ)**, оскільки в критично важливих інженерних застосуваннях недостатньо лише отримати точне рішення — необхідно також пояснити причини його прийняття. У роботі [12] наведено критичний огляд підходів до побудови довірених та пояснюваних систем моніторингу мостів із залученням експерта до процесу аналізу. У дослідженні [13] продемонстровано використання ХАІ для імовірного оцінювання стану залізобетонних балок на основі зображень тріщин, що підтверджує перспективність застосування пояснювальних моделей у задачах технічної діагностики.

Незважаючи на наявність значної кількості досліджень у сфері структурного моніторингу, залишається актуальною задача побудови інтелектуального методу, який би одночасно забезпечував високу точність оцінювання стану конструкції, інтеграцію мультимодальних даних та інтерпретованість результатів, що й зумовило постановку задачі даної роботи.

**Виклад основного матеріалу.** У ході дослідження було сформовано набір мультимодальних даних, що описує технічний стан елементу інженерної конструкції у часовій динаміці. До складу вхідних ознак включено параметри виявлених дефектів, зокрема факт наявності дефекту типу тріщини, а також зовнішні фактори середовища,

такі як температура та вологість. На основі цих параметрів було обчислено інтегральний показник небезпечності дефекту та сформовано узагальнену оцінку технічного стану конструкції. У системі моніторингу стану конструкцій, реалізованій на базі Nvidia Jetson Nano з використанням камери та сенсора DHT22 [3, 4], оцінка тріщин проводиться на основі відношення дефектних пікселів до загальної площі зображення (DefectRatio), що формуються сегментаційним алгоритмом [1]. Параметри температури та вологості вимірюються сенсором DHT22 і відображають зовнішні умови всередині труби.

Для класифікації технічного стану елементу інженерної конструкції використано різні алгоритми машинного навчання, які дозволяють автоматизувати процес віднесення об'єкта до відповідного класу стану. У роботі реалізовано поділ стану конструкції на класи «критичний», «попередження» та «норма», що відповідають підвищеному та критичному рівням ризику. Для оцінювання якості побудованої моделі використано стандартні метрики класифікації, зокрема **accuracy**, **precision**, **recall** та **F1-score**, а також матрицю помилок.

З метою інтерпретованості результатів моделювання використано підходи **пояснювального штучного інтелекту**, зокрема аналіз важливості ознак, правилоорієнтоване пояснення та метод **SHAP (SHapley Additive exPlanations)**. Це дозволило не лише отримати високоточну модель оцінювання стану конструкції, а й визначити внесок кожного параметра у прийняття фінального рішення, що є важливим для практичного використання інтелектуальних систем у задачах структурного моніторингу та технічної діагностики.

*Збір та обробка даних.* Для дослідження запропонованого методу оцінювання стану елементу інженерної конструкції з використанням пояснювального штучного інтелекту було опрацьовано набір мультимодальних даних, що відображає зміну технічного стану конструкції в часовій динаміці. Такий підхід дозволив перевірити умови частини об'єкта структурного моніторингу, в яких стан об'єкта визначається не лише наявністю дефекту, а й супровідними фізичними умовами експлуатації.

У межах дослідження (Рис. 1) зібрано 32 кадри відео. Для кожного з часових кроків сформовано набір ознак: частка сегментованих дефектів на зображенні (DefectRatio), температура, відносна вологість та цільову змінну стану (ризик). На основі цих показників обчислюється комплексний індикатор стану об'єкта RiskScore, який дозволяє класифікувати кадри за трьома категоріями: «Норма», «Попередження» та «Критичний». Такий підхід забезпечує інтеграцію візуальних і сенсорних даних для комплексної оцінки стану конструкцій, дозволяючи оперативно визначати наявність дефектів, їхню серйозність та вплив зовнішніх факторів. Система може застосовуватися як для локального моніторингу на пристрої Jetson Nano, так і для віддаленого контролю стану конструкцій у реальному часі.




Рисунок 1 – Результат кадрування відео на 32 зображення з сегментованими дефектами на ділянці труби

Початкові значення параметрів дефектів моделювали наявність невеликих пошкоджень на зображеннях, які поступово збільшувалися у часі. Рівень дефектності визначався через DefectRatio, тобто частку пікселів, помічених як дефектні, а також через Confidence, що відображає ймовірність коректної детекції алгоритмом комп'ютерного зору. Для кількісного опису серйозності дефекту було введено інтегральний показник ConditionScore, який об'єднує значення DefectRatio, Confidence, а також показники температури і вологості. На основі цього показника (Рис. 2) формувалися класи стану конструкції: «Норма», «Попередження» та «Критичний».

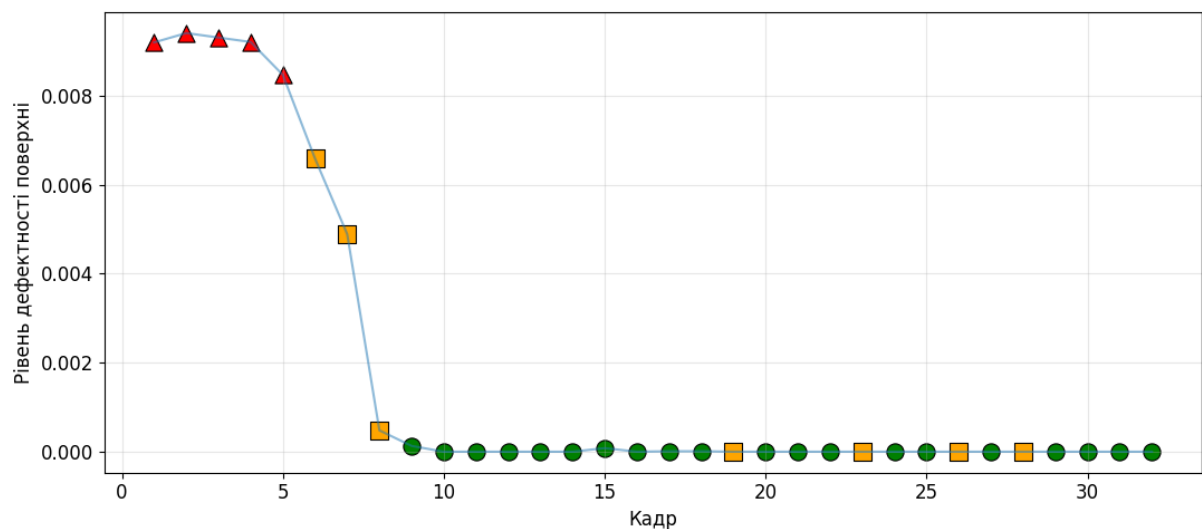


Рисунок 2 – Динаміка показника дефектності поверхні по кадрах

На першому етапі було сформовано набір експериментальних даних на основі 32 послідовних кадрів спостереження, для яких обчислювалися значення площі дефектів, а також супутні сенсорні параметри середовища. Аналіз часової динаміки дефектності

поверхні показав, що на початкових кадрах спостерігалася підвищена частка пошкодженої області, яка поступово зменшувалася до нульових або майже нульових значень. Така тенденція свідчить про перехід системи від станів із підвищеним рівнем дефектності до стабільного нормального стану.

Додатково було проаналізовано зміну параметрів середовища (Рис. 3). Отримані результати засвідчили плавне зростання вологості та температури протягом послідовності кадрів, що відображає зміну зовнішніх умов експлуатації або експериментального середовища. Введення порогових значень для вологості та температури дозволило візуально оцінити моменти, у яких середовище потенційно могло впливати на зміну стану поверхні.

Зменшення кількості виявлених дефектів при підвищенні температури та вологості найчастіше пов'язане з термічним розширенням матеріалу та зміною умов освітленості. Нагрівання конструкції (особливо на сонячній стороні) призводить до лінійного розширення елементів, що спричиняє механічне «затягування» мікротріщин та стикувальних зазорів, роблячи їх менш помітними для алгоритмів сегментації. Крім того, пряме сонячне світло в моменти закінчення моніторингу створює високу інтенсивність випромінювання, що може призводити до оптичного засвічування та зниження контрастності зображення. Це ускладнює диференціацію дефектів від фону, оскільки тіні, які зазвичай підкреслюють текстуру пошкоджень, зникають.




Рисунок 3 – Зміна вологості та температури по кадрах

Вибір порогів у 65% для вологості та 22°C для температури зазвичай базується на стандартах експлуатації та точці роси. Вологість 65% часто є критичною межею, вище якої активуються процеси гігроскопічної конденсації та інтенсивної атмосферної корозії. При перевищенні цього рівня на поверхні металу утворюється мікроскопічна плівка води, що є каталізатором окислення.

Температура 22°C у поєднанні з вологістю часто є основною точкою для розрахунку вологоутримання повітря. Для багатьох конструкційних матеріалів саме цей

діапазон вважається межею між «стабільним» та «активним» тепловим режимом, що впливає на в'язкість захисних покриттів та напружено-деформований стан.

Після попередньої обробки даних було здійснено навчання моделей із використанням гіперпараметричної оптимізації для ансамблевих алгоритмів.

*Побудова моделі класифікації технічного стану.* Отримані результати свідчать про те, що більшість використаних моделей успішно відтворюють логіку класифікації технічного стану на основі сформованих ознак. Особливо важливо, що моделі не лише правильно розпізнавали клас «Норма», але й коректно ідентифікували приклади класу «Попередження», який є проміжним та більш складним для розмежування. Це вказує на достатню інформативність ознаки DefectRatio, а також на допоміжну роль параметрів вологості та температури в задачі оцінювання стану.

Окремий інтерес становлять результати моделі LightGBM, яка виявилася менш стабільною в межах даної вибірки. Аналіз показників precision, recall та F1-score показав, що ця модель коректно класифікувала лише зразки класу «Норма», однак не змогла правильно розпізнати жодного зразка класу «Попередження». Це може бути пояснено дуже малою кількістю прикладів цього класу в тестовій вибірці, а також загалом невеликим обсягом навчальних даних, що є типовим обмеженням для задач із вузькою експериментальною вибіркою. Для наочного порівняння ефективності алгоритмів було побудовано стовпчикову діаграму значень точності.

Візуальний аналіз підтверджує, що чотири моделі демонструють ідентично високий рівень класифікації, тоді як LightGBM поступається їм за якістю розпізнавання. Значення основних метрик класифікації наведено в Табл. 1.

Таблиця 1

Порівняння точності моделей класифікації

Модель	Точність	Клас	Precision	Recall	F1-score	Support
RandomForest	0.9	Критичний	1.00	1.00	1.00	2
		Норма	0.86	1.00	0.92	6
		Попередження	1.00	0.50	0.67	2
XGBoost	0.9	Критичний	1.00	1.00	1.00	2
		Норма	0.86	1.00	0.92	6
		Попередження	1.00	0.50	0.67	2
LightGBM	0.8	Критичний	0.67	1.00	0.80	2
		Норма	0.86	1.00	0.92	6
		Попередження	0.00	0.00	0.00	2
SVM	0.7	Критичний	1.00	1.00	1.00	2
		Норма	0.80	0.67	0.73	6
		Попередження	0.33	0.50	0.40	2
LogReg	0.6	Критичний	0.00	0.00	0.00	2
		Норма	0.60	1.00	0.75	6
		Попередження	0.00	0.00	0.00	2

Для найкращої моделі було також побудовано кореляційну **матрицю помилок (Рис. 4)**, яка показала повну відповідність між реальними та передбаченими класами тестової вибірки. Усі зразки класу «**Норма**» та всі зразки класу «**Попередження**» були класифіковані без помилок. Це підтверджує високу здатність моделі до відокремлення нормального та потенційно проблемного стану поверхні в межах досліджуваної вибірки.




Рисунок 4 – Матриця помилок для Random Forest

*Гіперпараметрична валідація та інженерія ознак.* Оптимізація здійснювалася з використанням перехресної валідації, що дозволило оцінити узагальнювальну здатність кожної моделі ще до тестування на вибірці. Найвищі значення середньої точності перехресної валідації (Best CV score = 0.7738) продемонстрували моделі Random Forest та Logistic Regression, що свідчить про їхню найкращу здатність до стабільної класифікації в межах сформованого набору даних. Для моделі Random Forest оптимальними виявилися параметри: кількість дерев 200, максимальна глибина дерева 3 та мінімальна кількість об'єктів для розщеплення вузла 4.

Модель Logistic Regression також продемонструвала високий результат перехресної валідації, причому найкращим виявився параметр регуляризації  $C = 0.1$  при використанні розв'язувача liblinear. Це свідчить про те, що навіть відносно проста лінійна модель може бути ефективною для даного завдання, якщо структура даних є достатньо впорядкованою, а ознаки мають виражений розділяючий потенціал.

Модель SVM забезпечила дещо нижчий, але також достатньо високий результат (Best CV score = 0.7262). Найкращими параметрами стали радіальна базисна функція ядра (RBF),  $C = 1$  та  $\gamma = \text{scale}$ , що вказує на здатність методу ефективно враховувати нелінійні межі між класами. Це є очікуваним для задачі, де вплив ознак може мати не лише лінійний характер.

Модель XGBoost продемонструвала середній рівень узагальнювальної здатності (Best CV score = 0.6845). Найкращими параметрами стали 50 дерев, глибина 2 та  $\text{learning rate} = 0.05$ .

Отримані значення свідчать про те, що для даного набору даних більш доцільним виявився обережний бустинговий підхід із неглибокими деревами, орієнтований на зменшення ризику перенавчання. Найнижчий результат перехресної валідації було зафіксовано для моделі LightGBM (Best CV score = 0.369), для якої оптимальними виявилися параметри: learning rate = 0.05, 50 дерев та num\_leaves = 15. У досліджуваному випадку, ознака DefectRatio має найбільше середнє абсолютне SHAP-значення, це свідчить про те, що саме вона робить найбільший внесок у зміну прогнозу моделі. Отже, рішення моделі щодо належності об'єкта до класів «Норма», «Попередження» або «Критичний» насамперед визначається ступенем дефектності поверхні.

Для інтерпретації рішень моделі було застосовано SHAP-аналіз (SHapley Additive exPlanations), який дозволяє оцінити внесок кожної ознаки у формування прогнозу. У результаті вдалося побудувати графік (Рис. 5) на основі SHAP, що забезпечує глобальне уявлення про вплив ознак на класифікацію.




Рисунок 5 – SHAP-візуалізація глобального впливу ознак на класифікацію технічного стану інженерної поверхні

У досліджуваному випадку, ознака DefectRatio має найбільше середнє абсолютне SHAP-значення, це свідчить про те, що саме вона робить найбільший внесок у зміну прогнозу моделі. Отже, рішення моделі щодо належності об'єкта до класів «Норма», «Попередження» або «Критичний» насамперед визначається ступенем дефектності поверхні.

З практичної точки зору важливим є не лише результат класифікації, а й можливість пояснення прийнятого рішення. Для цього було використано два підходи: **Permutation Importance** та **rule-based пояснення**. Аналіз важливості ознак показав, що найбільший внесок у прийняття рішення забезпечує показник **DefectRatio** (0.290), тобто частка площі, зайнятої дефектами. Саме ця ознака виявилася визначальною для розмежування технічних станів поверхні. Водночас параметри **вологості (0.055)** та **температури (0.03)** мали додатковий, але менший вплив, що свідчить про їхню роль як контекстних факторів середовища.

Порівняння реальних і прогнозованих станів для тестової вибірки

№	Рівень дефектності поверхні (DefectRatio)	Відносна вологість, %	Температура, °C	Реальний стан	Прогнозований стан
1	0.00489	61.85	17.57	Попередження	Попередження
2	0.00000	61.44	21.87	Попередження	Норма
3	0.00000	61.41	18.55	Норма	Норма
4	0.00920	56.24	17.98	Критичний	Критичний
5	0.00000	60.66	21.22	Норма	Норма
6	0.00008	57.46	20.16	Норма	Норма
7	0.00000	60.85	22.17	Норма	Норма
8	0.00000	74.63	22.56	Норма	Норма
9	0.00921	60.26	17.12	Критичний	Критичний
10	0.00000	68.30	23.39	Норма	Норма

Аналіз таблиці тестових прогнозів показує, що модель Random Forest у більшості випадків коректно відтворює реальний технічний стан спостережень. Зокрема, модель правильно класифікувала всі приклади класу «Норма», а також обидва приклади класу «Критичний», для яких спостерігалися підвищені значення DefectRatio (0.00920 та 0.00921). Це підтверджує високу чутливість моделі до об'єктів із вираженими дефектними ознаками. Водночас було виявлено один випадок помилкової класифікації, коли об'єкт із реальним класом «Попередження» був віднесений моделлю до класу «Норма». Для цього прикладу значення DefectRatio = 0.00000, а значення вологості (61.44%) та температури (21.87°C) також не перевищували критичних порогів. Це може свідчити про те, що даний об'єкт належить до прикордонних випадків, де стан визначається не настільки виражено, як у прикладах із очевидною дефектністю. У таких ситуаціях модель може схилитися до більш безпечного або статистично домінуючого класу.

Загалом, результати підтверджують, що модель приймає рішення на основі змістовно обґрунтованих фізичних параметрів, що є критично важливим для систем пояснювального штучного інтелекту (ХАІ).

*Правило-орієнтовані пояснення.* Пояснення для окремого тестового прикладу з Табл. 2 підтвердило виявлені моделлю закономірності. Для першого часового кроку з параметрами середовища тестової вибірки (№1) модель передбачила стан «Попередження», що повністю збігається з фактичним значенням. Основним чинником такого рішення було визначено помірний рівень дефектності поверхні (DefectRatio = 0.00489). При цьому показники вологості (61.85%) та температури (17.57°C) не перевищували встановлені критичні порогові, отже, не стали визначальними факторами при класифікації. Це демонструє здатність моделі ідентифікувати перехідний стан системи на основі візуальних дефектів навіть за умови відносно безпечних параметрів довкілля.

Для цього випадку прогноз моделі показав стан «попередження» з визначеною причиною: «Помірний рівень дефектності поверхні», що відповідає Табл. 3 з правилами пояснення прогнозу.

Таблиця 3

Правила пояснення прогнозу моделі

№	Умова	Інтерпретація	Пояснення
1	Рівень дефектності поверхні $> 0.01$	Високий рівень дефектності поверхні	Багато дефектів на поверхні
2	$0.001 < \text{Рівень дефектності поверхні} \leq 0.01$	Помірний рівень дефектності поверхні	Помірний рівень дефектності поверхні
3	Вологість $> 65\%$	Підвищена вологість середовища	Висока вологість
4	Температура $> 22^{\circ}\text{C}$	Підвищена температура середовища	Підвищена температура
5	Жодна умова не виконується	Відсутність виражених ризикових факторів	Немає критичних факторів

Узагальнюючи отримані результати, можна стверджувати, що побудована система класифікації здатна ефективно визначати технічний стан поверхні на основі поєднання візуальних ознак дефектності та сенсорних параметрів середовища. Разом із тим слід враховувати, що висока точність у даному експерименті частково пояснюється невеликим обсягом даних та чітко вираженою залежністю класів від показника DefectRatio. Тому подальші дослідження доцільно спрямувати на розширення вибірки, включення більшої кількості прикладів проміжних і критичних станів, а також використання додаткових ознак, що дозволить підвищити узагальнювальну здатність моделей.

Результати тестування демонструють, що модель найбільш упевнено розпізнає чітко виражені нормальні та критичні стани, тоді як найбільша складність виникає при класифікації проміжних або слабко виражених попереджувальних станів. Це є типовим явищем для задач технічної діагностики, де саме перехідні стани часто є найбільш складними для автоматизованого виявлення.

Таким чином, локальний SHAP-аналіз дозволяє пояснити не лише загальні закономірності моделі, а й **індивідуальні рішення для кожного окремого випадку**, що є надзвичайно важливим у системах підтримки прийняття рішень.

Сукупність отриманих результатів свідчить про те, що запропонований метод є ефективним як з точки зору **точності класифікації**, так і з точки зору **пояснюваності рішень**. На відміну від класичних підходів, де модель виконує лише автоматичну класифікацію, використання пояснювального штучного інтелекту дозволяє:

- визначати найбільш значущі фактори ризику;
- формувати зрозумілі текстові пояснення;
- аналізувати причини конкретних рішень моделі;
- підвищувати довіру до автоматизованих систем моніторингу.

Практична цінність запропонованого підходу полягає в можливості його застосування у складі інтелектуальних систем моніторингу трубопроводів, мостів, несучих конструкцій, резервуарів, промислових об'єктів та інших інженерних систем. У таких умовах система може не лише автоматично сигналізувати про погіршення стану, але й надавати оператору обґрунтування, які саме ознаки вказують на потенційну небезпеку.

Окремо слід зазначити, що запропонований підхід є масштабованим і може бути розширений за рахунок включення нових джерел даних, таких як вібраційні сигнали, акустичні емісії, термографічні зображення або результати ультразвукового контролю. Це відкриває перспективи для побудови більш складних інтелектуальних систем структурного моніторингу на основі мультимодальної інтеграції даних та пояснювального штучного інтелекту.

Для забезпечення зручної взаємодії користувача з розробленим методом оцінювання стану елементу інженерної конструкції було реалізовано програмне середовище аналізу, яке забезпечує обробку мультимодальних даних, класифікацію технічного стану та формування пояснень до отриманих результатів. Вищеописаний підхід дозволяє виконувати аналіз без необхідності ручного опрацювання числових показників і створює основу для подальшої інтеграції методу у складі інтелектуальних систем структурного моніторингу.

У процесі реалізації програмної частини було використано мову програмування високого рівня Python, що забезпечила гнучкість розробки, зручність роботи з науковими бібліотеками та можливість швидкого прототипування компонентів системи. Як середовище розробки застосовувалося Visual Studio Code, що забезпечило зручну організацію програмного коду, модульну структуру реалізації та ефективну інтеграцію із засобами аналізу даних і машинного навчання. Реалізація програмного рішення здійснювалася з використанням бібліотек NumPy, Pandas, Matplotlib, Scikit-learn та SHAP. Застосування зазначених інструментів дозволило реалізувати повний цикл обробки даних: від формування модельованого мультимодального набору спостережень до побудови моделі класифікації технічного стану та інтерпретації її рішень. Уся логіка аналізу була організована у вигляді окремих функціональних модулів, що включають генерацію та попередню обробку даних, формування інтегральних ознак, навчання моделі, оцінювання результатів та побудову пояснень.

Завдяки використанню аналізу важливості ознак, правило-орієнтованих пояснень та SHAP-інтерпретацій, система дозволяє користувачу не лише отримати фінальний клас стану, але й визначити, які саме параметри мали найбільший вплив на прийняте рішення. Це є важливою перевагою у порівнянні з традиційними «чорними скриньками» машинного навчання. Тестування запропонованого рішення проводилося відповідно до поставлених завдань і включало перевірку коректності формування даних, стабільності навчання моделі, точності класифікації, а також адекватності згенерованих пояснень.

У процесі експериментальної перевірки було підтверджено, що програмна реалізація коректно виконує всі основні етапи аналізу: формування ознакового простору,

обчислення інтегральних показників, класифікацію технічного стану, побудову графічних залежностей, матриці помилок, оцінювання важливості ознак та локальних пояснень для окремих прикладів.

За результатами випробувань встановлено, що розроблена система функціонує стабільно, забезпечує високий рівень автоматизації процесу оцінювання стану конструкції та демонструє необхідний рівень точності й інтерпретованості.

Додатково було підтверджено, що використаний підхід може бути реалізований на обчислювальних пристроях середнього рівня без потреби у спеціалізованому графічному обладнанні, що робить його придатним для практичного застосування у задачах технічної діагностики та структурного моніторингу.

*Обмеження та подальші дослідження.* Разом із тим, запропонований підхід має певні обмеження, які необхідно враховувати під час інтерпретації отриманих результатів. Насамперед, дослідження було проведено на невеликій вибірці даних, сформованій на основі обмеженої кількості спостережень, що може впливати на узагальнювальну здатність побудованих моделей. Крім того, цільова змінна технічного стану визначалася на основі заздалегідь встановлених порогових правил, пов'язаних переважно з показником DefectRatio, унаслідок чого модель значною мірою відтворює закладену логіку класифікації. Це пояснює отримання дуже високих показників точності, однак водночас обмежує можливість робити висновки щодо поведінки моделі в умовах реальних, більш складних і шумових даних. Додатковим обмеженням є те, що в дослідженні враховано лише три вхідні ознаки частку дефектної області, температуру та вологість, тоді як у практичних задачах технічної діагностики стан конструкції може залежати також від геометричних характеристик дефекту, динаміки його розвитку, механічних навантажень, вібраційних параметрів та інших експлуатаційних чинників. У зв'язку з цим подальші дослідження доцільно спрямувати на розширення вибірки, використання реальних експериментальних даних, включення додаткових ознак та розширення шкали технічного стану, що дозволить підвищити надійність, стійкість та прикладну цінність запропонованої системи.

**Висновки.** У роботі розроблено метод до оцінювання стану елемента інженерної конструкції з використанням методів машинного навчання та пояснювального штучного інтелекту, що базується на аналізі мультимодальних даних, які поєднують візуальні ознаки дефектності поверхні та параметри зовнішнього середовища. У межах дослідження було сформовано набір даних, що включав частку дефектної області поверхні (DefectRatio), а також вологість і температуру. На основі цих ознак здійснювалося автоматизоване визначення технічного стану конструкції за класами «Норма», «Попередження» та «Критичний». Для розв'язання задачі класифікації було досліджено кілька алгоритмів машинного навчання, зокрема Random Forest, XGBoost, LightGBM, Support Vector Machine (SVM) та Logistic Regression, із застосуванням гіперпараметричної оптимізації та перехресної валідації. За результатами експериментального дослідження встановлено, що найкращі показники на тестовій вибірці продемонстрували моделі Random Forest та XGBoost, для яких точність класифікації становила 0.90. Модель Logistic Regression забезпечила точність 0.80, SVM — 0.70, тоді як LightGBM про-

демонструвала найнижчий результат (0.60). З урахуванням якості класифікації та стабільності результатів перехресної валідації найбільш доцільною для подальшого використання було визначено модель Random Forest.

Проведений аналіз показав, що найбільший вплив на результат класифікації має ознака DefectRatio, яка характеризує частку площі поверхні, охопленої дефектами. За результатами Permutation Importance її важливість становила 0.290, що суттєво перевищує внесок ознак Humidity (0.055) та Temperature (0.030). Це свідчить про те, що саме ступінь дефектності поверхні є основним критерієм для розмежування технічних станів, тоді як параметри зовнішнього середовища виконують допоміжну, контекстну роль. Особливістю запропонованого підходу є використання засобів пояснювального штучного інтелекту (ХАІ), які дозволили підвищити прозорість, інтерпретованість та обґрунтованість прийнятих рішень. У роботі застосовано Permutation Importance, SHAP-аналіз та правило-орієнтовані пояснення, що дало змогу не лише оцінити глобальний вплив ознак на результат класифікації, але й пояснити причини віднесення окремого прикладу до конкретного класу. Зокрема, локальний аналіз показав, що для тестового прикладу зі значенням DefectRatio = 0.00489 модель обґрунтовано віднесла об'єкт до класу «Попередження», оскільки саме помірний рівень дефектності поверхні виступив основною причиною такого рішення.

Отримані результати підтвердили, що запропонований підхід є придатним для побудови інтелектуальних систем моніторингу технічного стану інженерних конструкцій, у яких важливими є не лише точність автоматизованої оцінки, а й зрозумілість логіки прийняття рішення. Водночас проведене дослідження має певні обмеження, пов'язані з невеликим обсягом вибірки, частковим дисбалансом класів та модельованим характером даних, що могло вплинути на стабільність оцінювання. У зв'язку з цим подальші дослідження доцільно спрямувати на розширення набору ознак, збільшення кількості реальних спостережень, а також удосконалення механізмів виявлення критичних станів у реальних умовах експлуатації конструкцій.

#### ЛІТЕРАТУРА

1. Mysiuk R., Yuzevych V., Mysiuk I. et al. Detection of surface defects inside concrete pipelines using trained model on JetRacer kit // *In 2023 IEEE 13th International Conference on Electronics and Information Technologies (ELIT)*, 2023, pp. 21–24. IEEE., doi: 10.1109/ELIT61488.2023.10310691
2. Mysiuk R., Mysiuk I., Pawlowski G. et al. Video-based concrete road damage assessment using JetRacer kit // *In 2023 17th International Conference on the Experience of Designing and Application of CAD Systems (CADSM)*. 2023. pp. 1–4. IEEE., doi: <https://doi.org/10.1109/CADSM58174.2023.10076528>.
3. Mysiuk, R. (2024). Towards Information Flows in Recognition and Prediction Tasks with Internet of Things // *Path of Science*. 2024. Vol. 10(1). 1001-1004. DOI: <http://dx.doi.org/10.22178/pos.100-10>

4. Mysiuk R., Yuzevych V. IoT-based solution for detection defects in infrastructure objects using Raspberry Pi // *Electronics and Information Technologies*. 2023. Vol. 21. 45–56. 10.30970/eli.21.5
5. Moreh F., Lyu H., Rizvi Z. H. et al. Deep neural networks for crack detection inside structures // *Scientific Reports*. 2024. Vol. 14. Article 4439. DOI: <https://doi.org/10.1038/s41598-024-54494-y>.
6. Shalaby Y. M., Badawy M., Ebrahim G. A. et al. Condition assessment of concrete structures using automated crack detection method for different concrete surface types based on image processing // *Discover Civil Engineering*. 2024. Vol. 1. Article 81. DOI: <https://doi.org/10.1007/s44290-024-00089-5>.
7. Roy S., Yogi B., Majumdar R. et al. Deep learning-based crack detection and prediction for structural health monitoring // *Discover Applied Sciences*. 2025. Vol. 7. Article 674. DOI: <https://doi.org/10.1007/s42452-025-07272-y>.
8. Shah Mansouri T., Lubarsky G., Finlay D., McLaughlin J. Machine learning-based structural health monitoring technique for crack detection and localisation using Bluetooth strain gauge sensor network // *Journal of Sensor and Actuator Networks*. 2024. Vol. 13, No. 6. Article 79. DOI: <https://doi.org/10.3390/jsan13060079>.
9. Barbosh M., Ge L., Sadhu A. Automated crack identification in structures using acoustic waveforms and deep learning // *Journal of Infrastructure Preservation and Resilience*. 2024. Vol. 5. Article 10. DOI: <https://doi.org/10.1186/s43065-024-00102-2>.
10. Spencer B. F., Sim S.-H., Kim R. E., Yoon H. Advances in artificial intelligence for structural health monitoring: A comprehensive review // *KSCE Journal of Civil Engineering*. 2025. Vol. 29, Issue 3. DOI: <https://doi.org/10.1016/j.kscej.2025.100203>.
11. Si H., Wang Q., Ruan X. et al. Framework for investigating structure cracking using real engineering data combined with physics constraints // *Scientific Reports*. 2025. Vol. 15. Article 6344. DOI: <https://doi.org/10.1038/s41598-024-85079-4>.
12. Sun Z., Chen T., Meng X., Bao Y., Hu L., Zhao R. A critical review for trustworthy and explainable structural health monitoring and risk prognosis of bridges with human-in-the-loop // *Sustainability*. 2023. Vol. 15, No. 8. Article 6389. DOI: <https://doi.org/10.3390/su15086389>.
13. Chen Q., Li B. Explainable artificial intelligence (XAI)-driven probabilistic image-based structural health monitoring of reinforced concrete beams with shear reinforcements // *Automation in Construction*. 2025. Vol. 180. DOI: <https://doi.org/10.1016/j.autcon.2025.106549>.

## REFERENCES

1. Mysiuk, R., Yuzevych, V., Mysiuk, I., Tyrkalo, Y., Pavlenchyk, A., & Dalyk, V. (2023). Detection of surface defects inside concrete pipelines using trained model on JetRacer kit. In 2023 IEEE 13th International Conference on Electronics and Information Technologies (ELIT) (pp. 21–24). IEEE., doi: <https://doi.org/10.1109/ELIT61488.2023.10310691>
2. Mysiuk, R., Mysiuk, I., Pawlowski, G., Yuzevych, V., Yasynskyi, M., & Tyrkalo, Y. (2023). Video-based concrete road damage assessment using JetRacer kit. In 2023 17th International Conference on the Experience of Designing and Application of CAD Systems (CADSM) (pp. 1–4). IEEE., doi: <https://doi.org/10.1109/CADSM58174.2023.10076528>.

3. Mysiuk, R. (2024). Towards Information Flows in Recognition and Prediction Tasks with Internet of Things. *Path of Science*, 10(1), 1001-1004. doi: <https://doi.org/10.22178/pos.100-10>
4. Mysiuk, R., & Yuzevych, V. (2023). IoT-based solution for detection defects in infrastructure objects using Raspberry Pi. *Electronics and Information Technologies*, 21, 45–56. [10.30970/eli.21.5](https://doi.org/10.30970/eli.21.5)
5. Moreh, F., Lyu, H., Rizvi, Z. H., et al. (2024). Deep neural networks for crack detection inside structures. *Scientific Reports*, 14, 4439. <https://doi.org/10.1038/s41598-024-54494-y>
6. Shalaby, Y. M., Badawy, M., Ebrahim, G. A., et al. (2024). Condition assessment of concrete structures using automated crack detection method for different concrete surface types based on image processing. *Discover Civil Engineering*, 1, 81. <https://doi.org/10.1007/s44290-024-00089-5>
7. Roy, S., Yogi, B., Majumdar, R., et al. (2025). Deep learning-based crack detection and prediction for structural health monitoring. *Discover Applied Sciences*, 7, 674. <https://doi.org/10.1007/s42452-025-07272-y>
8. Shah Mansouri, T., Lubarsky, G., Finlay, D., & McLaughlin, J. (2024). Machine learning-based structural health monitoring technique for crack detection and localisation using Bluetooth strain gauge sensor network. *Journal of Sensor and Actuator Networks*, 13(6), 79. <https://doi.org/10.3390/jsan13060079>
9. Barbosh, M., Ge, L., & Sadhu, A. (2024). Automated crack identification in structures using acoustic waveforms and deep learning. *Journal of Infrastructure Preservation and Resilience*, 5, 10. <https://doi.org/10.1186/s43065-024-00102-2>
10. Spencer, B. F., Sim, S.-H., Kim, R. E., & Yoon, H. (2025). Advances in artificial intelligence for structural health monitoring: A comprehensive review. *KSCE Journal of Civil Engineering*, 29(3). <https://doi.org/10.1016/j.kscej.2025.100203>
11. Si, H., Wang, Q., Ruan, X., et al. (2025). Framework for investigating structure cracking using real engineering data combined with physics constraints. *Scientific Reports*, 15, 6344. <https://doi.org/10.1038/s41598-024-85079-4>
12. Sun, Z., Chen, T., Meng, X., Bao, Y., Hu, L., & Zhao, R. (2023). A critical review for trustworthy and explainable structural health monitoring and risk prognosis of bridges with human-in-the-loop. *Sustainability*, 15(8), 6389. <https://doi.org/10.3390/su15086389>
13. Chen, Q., & Li, B. (2025). Explainable artificial intelligence (XAI)-driven probabilistic image-based structural health monitoring of reinforced concrete beams with shear reinforcements. *Automation in Construction*, 180. <https://doi.org/10.1016/j.autcon.2025.106549>

Received 10.04.2026.  
Accepted 13.04.2026.  
Published 30.04.2026

***Method for assessing the condition of an engineering structure element  
using explanatory artificial intelligence and multimodal data***

*Assessing the technical condition of engineering structural elements is an important task for ensuring operational safety, reliability, and timely maintenance. Conventional inspection approaches are often labor-intensive, time-consuming, and dependent on expert judgment. This study proposes an intelligent approach for structural condition assessment based on machine learning and explainable artificial intelligence (XAI) using multimodal da-*

*ta that combine visual and environmental information. In the developed approach, the condition of a structural surface is evaluated using three input features: the defect area ratio (DefectRatio), humidity, and temperature. Based on these features, the structural state is automatically classified into three condition categories: Normal, Warning, and Critical. To solve the classification task, several machine learning algorithms were investigated, including Random Forest, XGBoost, LightGBM, Support Vector Machine (SVM), and Logistic Regression, with the application of hyperparameter optimization and cross-validation. Experimental results showed that Random Forest and XGBoost achieved the highest classification accuracy on the test dataset (0.90), while Logistic Regression, SVM, and LightGBM demonstrated lower performance, with accuracies of 0.80, 0.70, and 0.60, respectively. The obtained results indicate that the selected feature set is sufficiently informative for distinguishing between different structural condition states, while also revealing differences in the generalization ability of the investigated models. To improve transparency and interpretability, the proposed approach incorporates explainable artificial intelligence techniques, including Permutation Importance, SHAP-based analysis, and rule-based explanations. These methods made it possible to identify the most influential features and explain the reasoning behind model predictions. The analysis confirmed that DefectRatio is the dominant factor in structural condition assessment, whereas humidity and temperature play a supporting contextual role. The proposed approach was implemented in Python using libraries such as NumPy, Pandas, Matplotlib, Scikit-learn, XGBoost, LightGBM, and SHAP. The obtained results demonstrate the feasibility of combining machine learning, multimodal analysis, and XAI for interpretable and automated structural condition monitoring, which can be useful for preventive diagnostics, risk assessment, and decision support in engineering applications..*

*Keywords: explanatory artificial intelligence, feature engineering, multimodal data processing, image processing, intelligent monitoring, ML classification, risk analysis, surface defects, crack.*

**Мисюк Роман Володимирович** – доктор філософії, доцент кафедри системного проектування Львівського національного університету імені Івана Франка.

ORCID: <https://orcid.org/0000-0002-7843-7646>

**Кулик Петро Русланович** – асистент кафедри системного проектування Львівського національного університету імені Івана Франка.

ORCID: <https://orcid.org/0009-0008-1193-8578>

**Гусак Олег Васильович** – асистент кафедри системного проектування Львівського національного університету імені Івана Франка.

ORCID: <https://orcid.org/0009-0000-6026-4081>

**Чмихало Олександр Сергійович** – асистент кафедри системного проектування Львівського національного університету імені Івана Франка.

ORCID: <https://orcid.org/0009-0001-5409-5119>

**Парубочий Віталій Олегович** – асистент кафедри системного проектування Львівського національного університету імені Івана Франка.

ORCID: <https://orcid.org/0000-0002-9847-6968>

**Mysiuk Roman** – PhD (Computer Science), associate professor department of system design, Ivan Franko National University of Lviv, Lviv, Ukraine.

ORCID: <https://orcid.org/0000-0002-7843-7646>

**Kulyk Petro** – assistant department of system design, Ivan Franko National University of Lviv, Lviv, Ukraine.

ORCID: <https://orcid.org/0009-0008-1193-8578>

**Husak Oleg** – assistant department of system design, Ivan Franko National University of Lviv, Lviv, Ukraine.

ORCID: <https://orcid.org/0009-0000-6026-4081>

**Chmyhalo Oleksandr**– assistant department of system design, Ivan Franko National University of Lviv, Lviv, Ukraine..

ORCID: <https://orcid.org/0009-0001-5409-5119>

**Parubochyi Vitalii** – assistant department of system design, Ivan Franko National University of Lviv, Lviv, Ukraine.

ORCID : <https://orcid.org/0000-0002-9847-6968>