

**METHODOLOGICAL BASIS OF AN ALGORITHM
FOR CEMENT CONCRETE PAVEMENTS
DEFECT RECOGNITION DEVELOPMENT
OF CRITICAL INFRASTRUCTURE OBJECTS**

**МЕТОДОЛОГІЧНІ ОСНОВИ РОЗРОБКИ АЛГОРИТМУ
РОЗПІЗНАВАННЯ ДЕФЕКТІВ ЦЕМЕНТОБЕТОННИХ ПОКРИТТІВ
ОБ'ЄКТІВ КРИТИЧНОЇ ІНФРАСТРУКТУРИ**

Igor Gameliak¹

Anna Kharchenko²

DOI: <https://doi.org/10.30525/978-9934-26-499-3-7>

Abstract. The development of an algorithm for recognition of defects in cement concrete pavements of critical infrastructure facilities will contribute to a quick and accurate assessment of the condition of the facilities, which is a very important element in the management of the transport network in modern conditions. **The purpose** of the paper is to demonstrate the basis of an algorithm for cement concrete pavements defect recognition development of critical infrastructure objects. Solving such research tasks entails: systematization of achievements in the direction of recognizing defects in cement concrete coatings; identification of a number of problems encountered by other researchers and proposed solutions; systematization of methods for detecting cracks using machine learning; development of a sequence for analyzing images of damage to concrete elements of critical infrastructure objects; development of a research algorithm for building a methodology for recognizing defects; definition of tasks for future research. **Methodology** of the research is based on the methods of analysis and synthesis, systematization of achievements of theory and practice, systems analysis, mathematical modeling, programming. **Results** of the research

¹ Doctor of Technical Sciences, Professor,
Head of the Department of System Design of Transport Infrastructure and Geodesy,
National Transport University, Ukraine

² Doctor of Technical Sciences, Professor,
Professor of the Department of Transport Construction and Property Management,
National Transport University, Ukraine

define a clear algorithm that will allow in the future to develop appropriate software for recognizing defects in cement concrete pavements of critical infrastructure facilities using machine learning tools. This algorithm consists of six main stages that sequentially solve the problems of laborious processing of field data, defect classification, damage identification, and data calibration. It is proposed to use Deep Neural Network technologies to solve these problems. To evaluate the defect recognition performance, the harmonic F1 score is proposed, which is a key evaluation metric of a machine learning model. Since the data set on defects in cement-concrete elements of infrastructure structures is quite diverse, it is proposed to use the “one against all” method to calculate the F1 indicator, which will allow calculating individual indicators for each type of defect separately, with arithmetic averaging of the F1 estimate as a whole according to the algorithm. It is proposed to calibrate the machine learning algorithm taking into account the detected errors and the F1 score according to the priority of one of the scores that form the F1 indicator – reliability or recall. Thus, it was determined that the next stages of the research will be the development of an effective image segmentation model, which will be based on the application of machine learning (artificial intelligence) tools using the proposed algorithm.

1. Вступ

Виявлення дефектів і класифікації тріщин у бетонних елементах об’єктів критичної інфраструктури відіграють життєво важливу роль для забезпечення необхідного рівня обслуговування та продовження терміну служби конструкцій на системному рівні. Брак коштів на проекти критичної інфраструктури, потреба у відновленні об’єктів, які постраждали внаслідок війни, потреба в оперативному управлінні мережею, забезпечення спроможності доріг реагувати на військові виклики – все це породжує необхідність розробки та реалізації ефективних методичних рішень.

Традиційні методи виявлення та класифікування дефектів у бетонних елементах є доволі трудомісткими та вимагають багато часу на обробку даних. Сучасними методами відповідно до світової практики є методи обробки результатів фотофіксації пошкоджень доріг та елементів інфраструктури. В останні роки у науковій спільноті широко

обговорюються різноманітні методи обробки зображень, які використовуються у поєднанні із методами «комп'ютерного зору» – технології отримання інформації у вигляді зображень для виявлення тріщин у бетоні автоматизованим способом. Проте, незважаючи на те, що кожна схема обробки зображень має свої переваги, неможливо знайти таку універсальну схему, яка б працювала ефективно за будь-яких умов [1]. Також слід зазначити, що точність різних інструментів обробки зображень у контексті використання польових даних в реальних програмах залишається сумнівною. У випадку обробки польових даних існує велика ймовірність помилок за рахунок наявного «шуму», як наприклад, тіні інших об'єктів, сонячні відблиски тощо, що обмежує роботу схеми обробки зображень.

Таким чином, уточнені схеми обробки зображень вимагають попередніх знань про дефект та/або ймовірний «шум», який потрібно виділити або яким необхідно знехтувати. Хоча схема виявлення країв тріщин є можливим кандидатом для автоматичної ідентифікації безпосередньо самого дефекту, краї тріщин часто є роз'єднані, що ускладнює повномасштабну автоматизацію [1]. Зокрема, невеликі відокремлені сегменти дефекту бетонної конструкції можуть бути помилково сприйняті як фоновий шум. Таким чином, більшість дослідників цього напрямку прийшли до висновку, що можливим вирішенням проблем ефективної роботи схеми обробки зображень – є її поєднання з алгоритмами машинного навчання.

2. Аналіз публікацій та досліджень у напрямку розпізнавання дефектів цементобетонних покриттів

У світовій практиці питанню вивчення тріщин та інших дефектів у бетоні за допомогою аналізу зображень на основі машинного навчання за останні роки присвячено значна увага.

Зокрема, наприклад, в дослідженні [1] обговорюється запропонована авторами модель глибокого навчання (Deep Learning – DL), яка використовує штучні нейронні мережі для класифікації тріщин та руйнувань у бетоні в реальному часі. Крім того, дослідники розглядають перспективу використання даної моделі для вивчення природи «чорної скриньки» (алгоритму обробки даних, при якому внутрішні процеси залишаються прихованими від користувачів) у комбінації з поясню-

ваним штучним інтелектом (eXplainable Artificial Intelligence – XAI) – набору процедур і методів, які дозволяють користувачу зрозуміти процес прийняття рішення щодо зображення.

Відмічено [1], що сучасні моделі DL, такі як семантична сегментація, вимагають маркування для класифікації дефектів на рівні пікселів, а цей процес є доволі трудомісткий. Як варіант вирішення цієї проблеми пропонується фреймворк, що поєднує бінаризацію зображення та модель DL на основі Фур'є для швидкого виявлення та класифікації тріщин та руйнувань у бетоні. Відповідно запропонованого рішення бінаризація зображення виділяє можливі регіони-кандидати на тріщини і усуває структурний фон під час навчання та тестування DL. Запропонована модель дозволяє класифікувати тріщини та руйнування в режимі реального часу на рівні пікселів зі швидкістю 2 зображення/с на мобільній платформі з обмеженими обчислювальними можливостями. Було виконано навчання системи штучного інтелекту за 1492 зображеннями тріщин та 1321 зображенням без тріщин [1]. Проте, дана розробка знаходиться поки у тестовому режимі.

Наступне дослідження присвячене розробці автономної системи виявлення дефектів у бетонних конструкціях на основі згорткової нейронної мережі [2], яка може автоматично ідентифікувати тріщини та використовувати цю інформацію для розрахунку частки тріщиноутворення. Результати проведених авторами експериментів показали, що навчена модель може класифікувати тріщини в бетоні з точністю 99,9% [2]. Цікавим підходом є використання методу кластеризації зображень, який дозволяє чітко визначити відсоток тріщин і полегшує у подальшому прогнозування рівня пошкодження бетону з часом. Модель використовує гібридний набір даних про тріщини в бетоні, як результати фотофіксації, так і зображення, отримані тепловізором, тим самим підвищуючи надійність результатів обробки та масштабність виявлення тріщин. Проте результати дослідження ще не відкалібровано за параметрами ширини та глибини тріщини, впливу освітлення під час зйомки та типу апаратури.

В дослідженні [3] також запропоновано використовувати підхід бінаризації зображення для виділення регіонів-кандидатів на тріщини з подальшою побудовою прискорених надійних функцій і згорткової нейронної мережі. Автори розділили зображення на такі, що класифі-

ковані з тріщинами та дефектами, а також на такі, що мають шумові структури без тріщин. Було проведено кількісне та якісне порівняння отриманих методів ідентифікації тріщин за допомогою нових зображень поверхні бетону, що містить тріщини та без тріщин. Проте, дослідження сфокусоване лише на одному виді дефекту, тому неможливо оцінити, чи дійсно дослідниками вдалося досягнути необхідної точності у ідентифікації ображень.

Дослідниками [4] для виявлення на зображеннях бетонних конструкцій тріщин використовуються методи глибокої згорткової нейронної мережі (Deep Convolutional Neural Networks – DCNN) і метод трансферного навчання (Transfer Learning – TL), який зосереджений на перенесенні отриманих знань на подібні задачі. Аналізу передують процес сегментації зображення тріщин, за результатами якого формується набір даних про основні види дефектів та їх розміри. Результати показали, що моделі класифікаторів DCNN забезпечують хорошу продуктивність розпізнавання дефектів з показником середнього гармонійного F1 у діапазоні від 94,5% до 99,6%. Крім того, запропонований аналіз зображень із різною роздільною здатністю може сегментувати пікселі тріщин із 95,25% оцінки F1, що є доволі високим показником ефективності сегментації. Проте, розроблений алгоритм ще потребує належного тестування у польових умовах.

У дослідженні [5] використовується алгоритм посилення градієнта для сегментації зображення на основі нейронної мережі (Convolutional Neural Networks – CNN). Для оцінки ефективності розроблених моделей використано такі показники, як точність, варіація та F1-оцінка. Запропонована модель досягла рівня точності перевірки 98% із похибкою 0,3%. Хоча авторами і досягнуто високих показників точності розпізнавання дефектів, слід зазначити, що було використано набори даних з доступних бібліотек, але не було протестовано модель та алгоритм у польових умовах.

Цікавим підходом до виявлення дефектів на зображеннях є трьохетапний алгоритм, який використовує глибоке навчання та обробку зображень для класифікації, сегментації DL та вимірювання тріщин [6]. На перших двох етапах для класифікації та сегментації тріщин використовувалися спеціальні моделі CNN та U-Net. Останнім етапом є вимірювання ширини тріщини в міліметрах за допомогою нового

методу лазерного калібрування. Апробація запропонованої моделі класифікації та сегментації дала результати 99,22% і 96,54% точності відповідно, тоді як середня абсолютна похибка, що спостерігалася для вимірювання ширини тріщини, становила 0,16 мм [6]. Результати демонструють адекватність розробленого методу виявлення та вимірювання тріщин, а також показують, що розроблений метод глибокого навчання та лазерного калібрування сприяє більш безпечним і швидшим перевіркам зображень, що також зменшує похибку через людський фактор. Здатність цього методу вимірювати тріщини в міліметрах забезпечує більш глибоку оцінку структурних пошкоджень, що, порівняно з традиційними методами вимірювання на основі пікселів, є значним покращенням для практичних польових застосувань. Однак одним із основних обмежень методу є розмір навчального набору даних, особливо для моделі сегментації. Більший набір даних і налаштування гіперпараметрів моделі значно підвищують точність. Втім, за результатами дослідження [6] встановлено, що сегментація DL дала кращі результати порівняно зі звичайними алгоритмами обробки зображень. Крім того, DL пропонує краще узагальнення та швидшу сегментацію, і не потребує експерта для ручного підбору параметрів.

Візуальне виявлення пошкоджень інфраструктури [7] з використанням обчислювальних підходів на основі глибокого навчання (DL) може полегшити потенційне рішення для зменшення суб'єктивності, але підвищити точність діагностики пошкоджень і доступність у системі структурного моніторингу об'єктів критичної інфраструктури. Однак, незважаючи на значні успіхи моделей на основі DL, найбільш серйозними проблемами для досягнення наслідків у реальному часі є обмежені доступні бази даних зображень дефектів і вибір глибини мереж DL. Щоб вирішити ці проблеми, у дослідженні [7] було створено різноманітний набір даних із зображеннями бетонних тріщин (4087) і відколів (1100), що в подальшому було використано для оцінки стану пошкоджень за допомогою алгоритмів згорткової нейронної мережі (CNN). Моделі CNN-класифікатора використовуються для ідентифікації різних типів дефектів і семантичної сегментації для маркування шаблонів дефектів у зображенні. Моделі CNN-класифікатора були проаналізовані за допомогою двох оптимізаторів – стохастич-

ного градієнтного спуску (SGD), середньоквадратичного поширення (RMSprop) і швидкості навчання – 0,1, 0,001 і 0,0001. Однак моделі CNN-сегментації були оцінені за адаптивним моментом з трьома різними показниками навчання – 0,1, 0,01 і 0,0001, на основі точності, перетину над об'єднанням, запам'ятовування та оцінки F1 [7].

Однією з найбільших проблем, з якою зіткнулося це дослідження [7], є дисбаланс розміру набору даних про тріщини та глибокі дефекти. Набір даних про тріщини складається з 4087 зображень, тоді як набір даних про глибокі дефекти містить 1100 зображень (майже одна чверть набору даних про тріщини). Крім того, збирати зображення зі складним фоном, що відтворює вихідну схему аналізування зображень, відносно важко.

У дослідженні [8] йдеться про розробку системи штучного інтелекту на основі згорткові нейронні мережі CNN та алгоритму машинного навчання для оцінки фотографічних зображень бетонних поверхонь на наявність і характеристики тріщин. Одне з важливих завдань щодо розробки системи полягало в тому, щоб справжні тріщини можна було відрізнити від «нетріщин» елементів бетонних конструкцій. Після розробки систему штучного інтелекту (ШІ) було навчено використовувати 1900 зображень бетонних поверхонь з тріщинами та без тріщин. Потім було використано ще 1100 зображень для перевірки та тестування системи. Зображення були сегментовані або піксельовані для спрощення репрезентації зображення та полегшення визначення місцезнаходження об'єктів і меж. Підхід був удосконалений для оцінки довжини та середньої ширини тріщин на зображенні. Тестування протоколів показали, що модель штучного інтелекту була точною на 99,6% у класифікації зламаних і не зламаних ображення. Крім того, середня похибка розрахунку довжини та ширини тріщини становила 1,5 % та 5% відповідно. Ці результати є перспективними для розробки повноцінної системи ШІ для підтримки експлуатаційного стану та інспектування конструкцій інфраструктури.

Методи на основі глибокого навчання, особливо згорткові нейронні мережі, були розроблені для автоматичної обробки зображень для завдань ідентифікації об'єктів. Хоча методи, засновані на глибокому навчанні, претендують на дуже високу точність, вони часто ігнорують складність процесу збору зображень. На реальні зображення часто

впливають складні умови освітлення, тіні, випадкові форми та розміри тріщин, плями та відколи бетону [9]. Тому ряд останніх досліджень присвячений врахуванню «шуму» зображень та освітлення при використанні методів глибокого навчання для виявлення бетонних тріщин.

Хоча всі ці методи претендують на дуже високу точність, вони часто ігнорують складність самого процесу збору зображень. Майже всі опубліковані статті стосуються зображень, отриманих в ідеальних лабораторних умовах [9]. Ідентифікація та характеристика тріщин на зображеннях, що містять бетонні тріщини, є складним завданням. На зображення бетонних поверхонь із тріщинами, зроблені в реальних умовах, впливають складні умови освітлення, зокрема тіні та затемнення, колір бетону та розмір й глибина тріщини [9].

Сучасні методи, які спрямовані на моніторинг технічного стану дорожніх покриттів [10], дозволяють виявляти дефекти та руйнування поверхні. Незважаючи на це, бракує методів і систем, здатних ідентифікувати приховані тріщини (зокрема, тріщини, які розповсюджуються «знизу-вгору») і контролювати їх розростання з часом. Тому деякі дослідники пропонують для ідентифікації та класифікації дефектів дорожнього покриття з різними тріщинами додати параметр віброакустичної сигнатури [10]. Метод спрямований на збір цих сигнатур (з використанням акустичних датчиків, розташованих на узбіччі), з подальшою класифікацією дефектів за допомогою розпізнавання зображень та машинного навчання. Проте, в реальних умовах необхідно враховувати фактори, що можуть впливати на поширення сейсмічної хвилі, такі як модуль пружності, температура поверхні, відстань до джерела–приймача (геометричне затухання), затухання матеріалу (пов'язане з властивостями матеріалу та амплітуда вібрації), граничні умови та виникнення прихованих дистресів [10].

Аналізуючи останні дослідження у напрямку розпізнавання дефектів цементобетонних покриттів [1–10], можна дійти висновку, що дослідники намагалися вирішити проблему трудомісткості обробки зображень дефектів за допомогою застосування алгоритмів машинного навчання. Проте, за результатами цих досліджень було виявлено ряд проблем – брак даних бібліотек програмних комплексів з розпізнавання дефектів; потреба врахування «шуму» на знімках польо-

вих даних; не всі дефекти можуть бути ідентифіковані (особливо 3D дефекти); існує ймовірність наявності «прихованих» дефектів, які потребують додаткового інструментального обстеження (акустичне, вібраційне, тепловізійне дослідження) тощо. Таким чином, для вирішення цих питань є потреба у побудові ефективного алгоритму розпізнавання дефектів цементобетонних покриттів об'єктів критичної інфраструктури.

3. Методологія розробки алгоритму розпізнавання дефектів цементобетонних покриттів

Методи виявлення тріщин можна класифіковано на дві основні групи (рис. 1) [2]:

- методи, засновані на машинному навчанні;
- методи, засновані на обробці зображень.

Відповідно до цієї класифікації утворюється послідовна організаційна структура побудови можливих різноманітних методологій, що застосовуються в області виявлення тріщин у бетонних елементах конструкцій критичної інфраструктури.

Відповідно до акумульованого досвіду дослідницька програма з виявлення тріщин за допомогою машинного навчання має включати (рис. 2) [2] наступні кроки:

- збір та організація даних у набори даних за допомогою експериментів з подальшою попередньою обробкою та фільтрацією даних;
- покращення якості зображення та усунення фонових перешкод зображення за допомогою методів обробки зображення;
- використання моделей машинного навчання для виявлення та класифікації;
- ідентифікація областей тріщин за допомогою методів сегментації/кластеризації та виведення шуму;
- аналіз виявлених тріщин з використанням матриць та інших індексів оцінки, враховуючи різні характеристики класифікації моделі машинного навчання та ефекту кластеризації після обробки зображення.

Узагальнюючи закордонні дослідження та схеми розпізнавання дефектів із застосуванням машинного навчання, можна запропонувати загальний алгоритм дослідження (рис. 3).

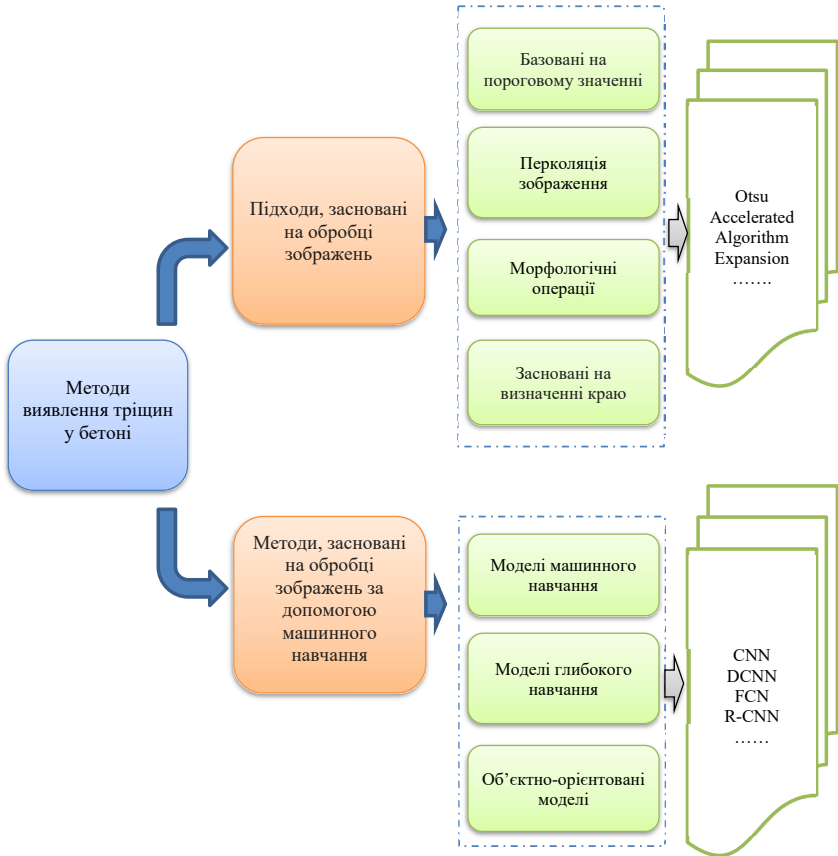


Рис. 1. Класифікація методів виявлення тріщин за допомогою машинного навчання (адаптовано з [2])

Першим кроком є виконання польових досліджень. На цьому етапі необхідно врахувати інструментальне обладнання, яке додатково до фотофіксації може надати інформацію для аналізування. Наприклад, на рисунку 4 наведені зразки обробки зображень у системі програмного комплексу «ОКО» (Україна), отримані мобільною діагностичною лабораторією ДП «Дорцентр» за результатами моніторингу стану



Рис. 2. Послідовність аналізування зображень пошкоджень бетонних елементів об'єктів критичної інфраструктури

доріг загального користування та вулично-дорожньої мережі м. Києва, які були використані для навчання моделі для розпізнавання дефектів цементобетонного покриття. Однак основними недоліками «ОКО», як і більшості подібних систем, є велика трудомісткість під час обробки отриманих зображень. Крім того, такі системи зазвичай не враховують об'ємні пошкодження (3D), які додатково слід досліджувати іншими інструментальними засобами, наприклад, тепловізійним методом (рис. 5).

Другим кроком є розпізнавання зображень. На цьому етапі необхідно обрати або розробити схему розпізнавання зображень та протестувати її на ефективність. Пропонується використати концепцію



Рис. 3. Загальний алгоритм дослідження для побудови методології розпізнавання дефектів




Рис. 4. Приклади обробки зображень у системі ОКО




Рис. 5. Приклади обробки результатів дослідження об'ємного пошкодження (вибоїна глибиною 3-5 см) тепловізійним методом

сегментації зображення, як метод поділу цифрового зображення на підгрупи (сегменти) з подальшим аналізуванням кожного сегмента зображення окремо [11]. Це необхідно зробити для наповнення в подальшому бібліотеки сегментами, які будуть ключовими для машинного навчання. На цьому ж етапі закладаються рішення з виявлення

і усунення «шумових» ефектів зображень, врахування кольору, освітлення, якості зображення, яскравості тощо.

Для ефективної роботи схеми розпізнавання для кожного виду дефекту необхідно розробити свій алгоритм сегментації. Для цього необхідно попередньо належним чином класифікувати дефекти та пошкодження цементобетонних об'єктів. В результаті підвищується точність обробки та скорочується час обробки зображень [11].

На третьому етапі відбувається безпосередньо машинне навчання за алгоритмами сегментації зображень. Особливо ефективним інструментом для вирішення таких завдань є використання технології глибоких нейронних мереж [12]. Існує два підходи до виконання ідентифікації об'єктів:

– регіональний підхід (виявлення схожості) – закладається алгоритм подібності і машинне навчання відбувається за принципом трансферного навчання (Transfer Learning);

– підхід на основі меж (виявлення розривів) – закладається алгоритм пошуку пікселів, які відрізняються (є протилежними) до закладених. В цьому випадку корисною є бінаризація процесу навчання.

На четвертому етапі виконується перевірка на коректність встановленого дефекту, визначаються показники точності алгоритму. Традиційно для оцінки продуктивності розпізнавання дефектів використовується показник середнього гармонійного F1 [4; 5; 7], який є ключовою оціночною метрикою моделі машинного навчання. Показник F1 базується на матриці невідповідностей [13] за кількістю зразків з оцінками розпізнавання «істинно позитивні» (True Positives, *TP*), «хибно позитивні» (False Positives, *FP*); «істинно негативні» (True Negatives, *TN*); «хибно негативні» (False Negatives, *FN*).

Математично показник F1 визначається наступним чином [13]:

$$f(F1) \in \begin{cases} D = \frac{TP}{TP + FP}, \\ R = \frac{TP}{TP + FN}, \end{cases} \quad (1)$$

де D – достовірність матриці;

R – оцінка «пригадування».

Показник F1 розраховується як середнє гармонійне значення оцінок достовірності та пригадування [13]:

$$F1 = \frac{2}{\frac{1}{D} + \frac{1}{R}} = \frac{2 \times D \times R}{D + R}, F1 \in [0; 100], \quad (2)$$

або

$$F1 = \frac{TP}{TP + \frac{1}{2}(FP + FN)}, F1 \in [0; 100]. \quad (3)$$

Чим вищий показник $F1$, тим краща якість класифікатора алгоритму машинного навчання.

Оскільки набір даних про дефекти цементобетонних елементів конструкцій інфраструктурних об'єктів є доволі різноманітним, то для обчислення показника $F1$ в даному випадку необхідно буде використати метод “один проти всіх”, що дозволить обчислити індивідуальні показники для кожного виду дефекту окремо, з арифметичним усередненням оцінки $F1$ в цілому за алгоритмом:

$$\overline{F1} = \frac{\sum_{i=1}^n F1_i}{n}, \overline{F1} \in [0; 100], \quad (4)$$

де n – кількість видів дефектів (класів).

П'ятим етапом є калібрування алгоритму машинного навчання, зокрема, уточнюються схеми сегментації з урахуванням виявлених похибок та оцінки $F1$. Це можливо здійснити, встановлюючи пріоритет одній з оцінок, які формують показник $F1$ – достовірності або пригадуванню:

$$F\beta = \frac{1 + \beta^2}{\frac{1}{D} + \frac{\beta^2}{R}}, F\beta \in [0; 100], \quad (5)$$

де β – ваговий коефіцієнт, при $\beta > 1$ перевага надається оцінці пригадування, при $\beta < 1$ перевага надається оцінці достовірності.

На останньому етапі отримуємо відкалібрований алгоритм машинного навчання.

Таким чином, оскільки основними недоліками систем обробки результатів польових даних є велика трудомісткість та низька точність, наступними етапами дослідження стане розробка ефективної моделі сегментації зображення, яка базуватиметься на застосуванні засобів машинного навчання (штучного інтелекту) за запропонованим алгоритмом.

4. Висновки

Транспортна інфраструктура є ключовим елементом розвитку економіки та суспільного прогресу, а стан дорожнього покриття визначає ефективність і безпеку дорожньої мережі. Оскільки на безпеку, довговічність і експлуатаційну придатність об'єктів інфраструктури негативно впливають саме структурні пошкодження, важливо виявляти дефекти та тріщини у бетонних елементах конструкцій ще під час експлуатаційного утримання та інспектування об'єктів критичної інфраструктури. В останні роки основний акцент дослідників присвячений розробці методології автоматизованого підходу для виявлення, розпізнавання та прогнозування тріщин та дефектів. Проте, ці дослідження знаходяться ще на стадії калібрування алгоритмів на польові умови та врахування особливостей процесів деградації матеріалів.

Щоб побудувати комплексну модель виявлення дефектів бетонних елементів, у майбутніх дослідженнях слід розробити набір даних про дефекти з оригінальних звітів про перевірку стану конструкцій в польових умовах, а також щоб побудувати картину потенційного розвитку пошкоджень. Майбутні дослідження мають також зосередитися на аналізі всіх можливих типів дефектів бетонних конструкцій, оскільки алгоритм їх розпізнавання за допомогою машинного навчання має враховувати особливості деградації бетонних елементів конструкцій об'єктів критичної інфраструктури. Це важливо для оцінки та прогнозування стійкості конструкцій об'єктів критичної інфраструктури, що особливо актуально в умовах воєнного часу. Слід зазначити, що збір польових даних про стан критичної інфраструктури є трудомістким, вимагає ретельної обробки та застосування таких технологій, як Big Data. Обробка фотографій дефектів бетонних елементів конструкцій за допомогою прикладного програмного забезпечення займає багато часу на обробку, потребує втручання людини та фактично не враховує 3D дефекти. Усе це зумовлює необхідність розробки методології, алгоритму та відповідного програмного забезпечення з розпізнавання дефектів цементобетонних покриттів об'єктів критичної інфраструктури з використанням засобів машинного навчання, що є сучасною перспективною практикою.

Публікацію підготовлено за матеріалами, отриманими в рамках проекту 2023.04/0097 « Створення технології і системи оперативного аналізу та управління станом цементобетонних покриттів об'єктів критичної інфраструктури за спектрально-фотоінформаційними образами», що фінансується Національний фонд досліджень України.

The publication was prepared based on the materials received as part of the project 2023.04/0097 "Creation of a technology and a system of operational analysis and management of cement-concrete pavement condition of critical infrastructure objects based on spectral photoinformational images", financed by the National Research Fund of Ukraine.

Список літератури:

1. Kolappan Geetha, G., & Sim, S. (2022). Fast identification of concrete cracks using 1D deep learning and explainable artificial intelligence-based analysis. *Automation in Construction*. DOI: <https://doi.org/10.1016/j.autcon.2022.104572>
2. Choi, Y., Park, H. W., Mi, Y., & Song, S. (2024). Crack Detection and Analysis of Concrete Structures Based on Neural Network and Clustering. *Sensors*, 24(6), 1725. DOI: <https://doi.org/10.3390/s24061725>
3. Kim H, Ahn E, Shin M, Sim S-H. Crack and Noncrack Classification from Concrete Surface Images Using Machine Learning. *Structural Health Monitoring*. 2019;18(3):725-738. DOI: <https://doi.org/10.1177/1475921718768747>
4. Iraniparast, M., Ranjbar, S., Rahai, M., & Nejad, F. M. (2023, August). Surface concrete cracks detection and segmentation using transfer learning and multi-resolution image processing. *In Structures*. Vol. 54, pp. 386-398. Elsevier. DOI: <https://doi.org/10.1016/j.istruc.2023.05.062>
5. Padmapoorani, P., & Senthilkumar, S. (2023). Application of machine learning for crack detection on concrete structures using CNN architecture. *Matéria (Rio de Janeiro)*, 28(1), e20230010. DOI: <https://doi.org/10.1590/1517-7076-rmat-2023-0010>
6. Nyathi, M. A., Bai, J., & Wilson, I. D. (2024). Deep Learning for Concrete Crack Detection and Measurement. *Metrology*, 4(1), 66-81. DOI: <https://doi.org/10.3390/metrology4010005>
7. Arafin P, Billah AM, Issa A. Deep learning-based concrete defects classification and detection using semantic segmentation. *Structural Health Monitoring*. 2024;23(1):383-409. DOI: <https://doi.org/10.1177/14759217231168212>
8. Gomera, M., & Ballim, Y. (2022). An artificial intelligence approach to detection and assessment of concrete cracks based on visual inspection photographs. *In MATEC Web of Conferences* (Vol. 364, p. 05020). EDP Sciences. DOI: <https://doi.org/10.1051/mateconf/202236405020>

9. Palevičius P, Pal M, Landauskas M, Orinaitė U, Timofejeva I, Ragulskis M. Automatic Detection of Cracks on Concrete Surfaces in the Presence of Shadows. *Sensors* (Basel). 2022 May 11;22(10):3662. doi: 10.3390/s22103662. PMID: 35632070; PMCID: PMC9145296.
10. Praticò, F. G., Fedele, R., Naumov, V., & Sauer, T. (2020). Detection and Monitoring of Bottom-Up Cracks in Road Pavement Using a Machine-Learning Approach. *Algorithms*, 13(4), 81. DOI: <https://doi.org/10.3390/a13040081>
11. Minaee, S., Boykov, Y., Porikli, F., Plaza, A., Kehtarnavaz, N., & Terzopoulos, D. (2021). Image segmentation using deep learning: A survey. *IEEE transactions on pattern analysis and machine intelligence*, 44(7), 3523–3542 (2021). DOI: <https://doi.org/10.1109/TPAMI.2021.3059968>
12. Image Segmentation: The Basics and 5 Key Techniques (2022). URL: <https://datagen.tech/guides/image-annotation/image-segmentation>
13. Показник F1 у машинному навчанні (2023). URL: <https://thetransmitted.com/adlucem/pokaznyk-f1-u-mashynnomu-navchanni/>

References:

1. Kolappan Geetha, G., & Sim, S. (2022). Fast identification of concrete cracks using 1D deep learning and explainable artificial intelligence-based analysis. *Automation in Construction*. DOI: <https://doi.org/10.1016/j.autcon.2022.104572>
2. Choi, Y., Park, H. W., Mi, Y., & Song, S. (2024). Crack Detection and Analysis of Concrete Structures Based on Neural Network and Clustering. *Sensors*, 24(6), 1725. DOI: <https://doi.org/10.3390/s24061725>
3. Kim H, Ahn E, Shin M, Sim S-H. Crack and Noncrack Classification from Concrete Surface Images Using Machine Learning. *Structural Health Monitoring*. 2019;18(3):725-738. DOI: <https://doi.org/10.1177/1475921718768747>
4. Iraniparast, M., Ranjbar, S., Rahai, M., & Nejad, F. M. (2023, August). Surface concrete cracks detection and segmentation using transfer learning and multi-resolution image processing. In *Structures*. Vol. 54, pp. 386-398. Elsevier. DOI: <https://doi.org/10.1016/j.istruc.2023.05.062>
5. Padmapoorani, P., & Senthilkumar, S. (2023). Application of machine learning for crack detection on concrete structures using CNN architecture. *Matéria (Rio de Janeiro)*, 28(1), e20230010. DOI: <https://doi.org/10.1590/1517-7076-rmat-2023-0010>
6. Nyathi, M. A., Bai, J., & Wilson, I. D. (2024). Deep Learning for Concrete Crack Detection and Measurement. *Metrology*, 4(1), 66-81. DOI: <https://doi.org/10.3390/metrology4010005>
7. Arafin P, Billah AM, Issa A. Deep learning-based concrete defects classification and detection using semantic segmentation. *Structural Health Monitoring*. 2024;23(1):383-409. DOI: <https://doi.org/10.1177/14759217231168212>
8. Gomera, M., & Ballim, Y. (2022). An artificial intelligence approach to detection and assessment of concrete cracks based on visual inspection photographs. In *MATEC Web of Conferences* (Vol. 364, p. 05020). EDP Sciences. DOI: <https://doi.org/10.1051/mateconf/202236405020>

9. Palevičius P, Pal M, Landauskas M, Orinaitė U, Timofejeva I, Ragulskis M. Automatic Detection of Cracks on Concrete Surfaces in the Presence of Shadows. *Sensors* (Basel). 2022 May 11;22(10):3662. doi: 10.3390/s22103662. PMID: 35632070; PMCID: PMC9145296.
10. Praticò, F. G., Fedele, R., Naumov, V., & Sauer, T. (2020). Detection and Monitoring of Bottom-Up Cracks in Road Pavement Using a Machine-Learning Approach. *Algorithms*, 13(4), 81. DOI: <https://doi.org/10.3390/a13040081>
11. Minaee, S., Boykov, Y., Porikli, F., Plaza, A., Kehtarnavaz, N., & Terzopoulos, D. (2021). Image segmentation using deep learning: A survey. *IEEE transactions on pattern analysis and machine intelligence*, 44(7), 3523–3542 (2021). DOI: <https://doi.org/10.1109/TPAMI.2021.3059968>
12. Image Segmentation: The Basics and 5 Key Techniques (2022). Available at: <https://datagen.tech/guides/image-annotation/image-segmentation>
13. F1 score in machine learning (2023). Available at: <https://thetransmitted.com/adlucem/pokaznyk-f1-u-mashynnomu-navchanni/>