

ПІДВИЩЕННЯ ЕФЕКТИВНОСТІ ДІАГНОСТИКИ ВЕЛИКОГАБАРИТНИХ КОНСТРУКЦІЙ НА ОСНОВІ ВИКОРИСТАННЯ БПЛА ТА НЕЙРОННИХ МЕРЕЖ

Л.М. Лобанов, І.Л. Шкурат, Д.І. Стельмах, О.П. Шуткевич, В.В. Савицький

ІЕЗ ім. Є. О. Патона НАН України. 03150, м. Київ, вул. Казимира Малевича, 11. E-mail: innashkurat2909@gmail.com

У статті представлено підхід до дистанційної діагностики пошкоджень великогабаритних інженерних конструкцій із використанням безпілотних літальних апаратів (БПЛА) і згорткових нейронних мереж. Дослідження було проведено з метою автоматизації процесу виявлення структурних дефектів конструкції Київської телевежі. Методологія дослідження передбачала збір і попередню обробку 14187 зображень та розробку модифікованої архітектури нейронної мережі U-Net для сегментації пошкоджень. Експериментальне дослідження різних архітектурних налаштувань моделі продемонструвало ефективність запропонованих модифікацій, які дозволили знизити похибку виявлення дефектів на 3...5 % порівняно з базовими моделями. Встановлено, що оптимальна кількість ітерацій навчання становить 15–20 епох. Розроблена модель продемонструвала здатність виявляти пошкодження, які можуть бути пропущені оператором, що підтверджує потенціал автоматизованих систем діагностики на основі штучного інтелекту. Дослідження надає нові перспективи для підвищення ефективності моніторингу інфраструктурних об'єктів, особливо в умовах обмеженого доступу або підвищених ризиків для персоналу. Бібліогр. 41, табл. 2, рис. 6.

Ключові слова: дистанційна діагностика, дефекти, штучний інтелект, нейронні мережі, сегментація зображень, БПЛА

Вступ. Систематичний моніторинг технічного стану великогабаритних об'єктів є важливим для оцінки їх структурної цілісності. З часом конструкції зазнають змін, спричинених корозією, старінням матеріалів, впливом навантажень і зовнішніх факторів.

Для безпечної та безперервної експлуатації великогабаритних об'єктів необхідно здійснювати періодичний моніторинг і своєчасно виявляти дефектні ділянки, визначати необхідні профілактичні заходи та планувати першочергові ремонтні роботи. Це особливо актуально у військовий та післявоєнний періоди, коли інфраструктурні об'єкти зазнають значних ушкоджень.

Методи неруйнівного контролю (NDT) широко використовуються як інструмент діагностики інженерних споруд для оцінки їх технічного стану [1–4]. Традиційні методи неруйнівного контролю якості, зокрема ультразвуковий контроль [5, 6], магнітно-порошковий метод [7], акустична емісія [8, 9], інфрачервона термографія [10, 11] та ін., хоча й демонструють значний прогрес, проте мають ряд обмежень. Зокрема, їхня точність залежить від зовнішніх факторів (вологості, температури, рівня шуму), а інтерпретація результатів може ускладнюватися через суб'єктивний фактор оператора. Окрім того, такі методи є трудомісткими, потребують високих фінансових витрат і пе-

редбачають безпосередню участь персоналу, що підвищує рівень ризиків, особливо при обстеженні великогабаритних і важкодоступних конструкцій.

Одним із найефективніших способів візуального обстеження інженерних конструкцій є використання безпілотних літальних апаратів (БПЛА). Завдяки швидкому розвитку технологій БПЛА інтегрувалися в систему дистанційного моніторингу інфраструктурних об'єктів, демонструючи високу ефективність у важкодоступних місцях, де застосування традиційних методів є обмеженим [12–17]. Порівняно з традиційними методами, дослідження з використанням БПЛА виконуються значно швидше та забезпечують високу просторову роздільну здатність зображень. Це дозволяє отримувати деталізовані дані з високою точністю, що є важливим для аналізу стану об'єктів і прийняття обґрунтованих рішень [18]. Їх використання не лише покращує точність і швидкість моніторингу, але й суттєво знижує витрати людських і часових ресурсів, одночасно мінімізуючи ризики для обслуговуючого персоналу [19–22].

У зв'язку з поширенням і вдосконаленням штучного інтелекту (ШІ) та нейронних мереж (НМ) процес виявлення дефектів великогабаритних конструкцій поступово розвивається в напрямку автоматизації та інтелектуалізації. Ця методика базується на високій ефективності ней-

Лобанов Л.М. – <https://orcid.org/0000-0001-9296-2335>, Шкурат І.Л. – <https://orcid.org/0009-0003-1888-4203>,
Стельмах Д.І. – <https://orcid.org/0000-0002-0412-9747>, Шуткевич О.П. – <https://orcid.org/0000-0001-5758-2396>,
Савицький В.В. – <https://orcid.org/0000-0002-2615-1793>

© Л.М. Лобанов, І.Л. Шкурат, Д.І. Стельмах, О.П. Шуткевич, В.В. Савицький, 2025

ронних мереж при виявленні та обробці ознак, сприяючи вдосконаленню якості та точності процесу визначення дефектних ділянок.

Застосування ШІ та НМ у сфері аналізу даних визначається їх здатністю до автоматичного навчання та адаптації до різноманітних вхідних умов, що робить ці технології перспективними в контексті підвищення надійності та швидкості процесів локалізації дефектів на елементах великогабаритних конструкцій.

Існують підходи до розпізнавання дефектів, що базуються на використанні різних архітектур НМ, методів навчання та вибору гіперпараметрів. Гіперпараметри НМ задаються вручну або автоматично перед початком процесу навчання: кількість шарів у НМ, тип активаційної функції, оптимізатор та ін. Вибір гіперпараметрів суттєво впливає на точність моделі, швидкість навчання та якість отриманих результатів. Зокрема, глибокі згорткові НМ (Convolutional Neural Networks (CNN)) досить ефективно застосовуються для вирішення задач класифікації, сегментації, розпізнавання та виявлення дефектів на зображеннях.

Із розвитком обчислювальних потужностей та зростанням обсягів баз даних зображень [23] архітектури CNN продовжують вдосконалюватися [24]. У порівнянні зі стандартними НМ прямого поширення, згорткові НМ мають значно менше зв'язків і параметрів, що робить їх менш ресурсомісними у навчанні. CNN використовують припущення про локальність піксельних взаємодій, що дозволяє ефективно виділяти ключові структурні елементи зображення, зменшуючи кількість параметрів, які необхідно оптимізувати [25].

Згорткові НМ є особливо ефективними для задач обробки зображень, оскільки вони автоматично ідентифікують різноманітні ознаки зображень на різних рівнях їхнього подання. Завдяки застосуванню операції згортки CNN здатні виявляти структурні особливості у вхідних даних, що забезпечує високу точність у задачах класифікації [26], сегментації [27, 28] та розпізнавання об'єктів [29, 30].

Протягом останніх років наукова спільнота досягла значного прогресу в застосуванні методів машинного навчання в різних сферах. Зокрема, НМ активно використовуються для виявлення дефектних ділянок на основі зображень, у тому числі виявлення тріщин у бетоні [31], процесів відшарування та розшарування поверхонь [32], втомних тріщин [33], корозії сталевих конструкцій [34]. Запроваджені методи обробки зображень дозволяють частково замінити традиційний моніторинг, що здійснюється операторами на місцях, забез-

печуючи ефективніше й точніше виявлення ознак дефектів на бетонних і металевих поверхнях [35–38]. Значний інтерес становлять дослідження, що демонструють ефективність застосування БПЛА у поєднанні з методами глибокого навчання для точної ідентифікації дефектних ділянок [39, 40].

Таким чином, впровадження ШІ в дистанційну діагностику великогабаритних конструкцій є актуальним напрямком розвитку автоматизованої діагностики, спрямованим на підвищення ефективності моніторингу, оптимізацію ресурсів і покращення точності, швидкості й надійності виявлення дефектних ділянок.

Методологія. Збір і підготовка даних до навчання нейронної мережі. Як об'єкт дослідження була обрана Київська телевежа, яка зазнала структурних пошкоджень внаслідок ракетного удару. Для проведення дистанційної діагностики нижнього ярусу Київської телевежі використовувався БПЛА з роздільною здатністю камери 5280×3956 пікселів. Планування траєкторії обльоту є важливим етапом, що безпосередньо впливає на ефективність реалізації завдань дистанційного моніторингу та збору даних.

Методологія обльоту передбачала наступні етапи:

- визначення траєкторії польоту, що забезпечує оптимальний огляд об'єкта з урахуванням вимог до точності просторового позиціонування;
- урахування впливу зовнішніх факторів, таких як: погодні умови (вітер, кут падіння сонячних променів, опади), правила безпеки (висотні обмеження, зони обмеженого польоту), вимоги до точності (роздільна здатність, покриття).

Дистанційний моніторинг нижнього ярусу Київської телевежі складався з відеосканування зовнішньої поверхні знизу–вгору, корекції траєкторії бічним рухом, а також подальшого сканування у зворотному напрямку (зверху–вниз). З огляду на геометричні параметри та конфігурацію ліфтової шахти, виконання обльоту здійснювалося за круговою траєкторією. Замкнута траєкторія польоту навколо шахти мінімізує ризики втрати просторового покриття.

Для мінімізації впливу нерівномірного освітлення моніторинг проводився за стабільних погодних умов із рівномірним розподілом природного світла. Це дозволило уникнути різких контрастів і покращити якість зображень для подальшої аналітики.

Було проведено аналіз можливих ризиків, що передбачали:

- альтернативні маршрути польоту;

- резервні точки зльоту та посадки;
- алгоритми аварійного повернення БПЛА у разі втрати зв'язку.

Збір даних здійснювався при мінімально можливій відстані до об'єкта в режимі «повільного польоту», що сприяло підвищенню просторової роздільної здатності та якості отриманих зображень. Оптимізація кута огляду досягалася шляхом динамічного регулювання нахилу камери для мінімізації затінення та забезпечення повного охоплення структурних елементів. Висота польоту варіювалася залежно від розмірів конструктивних елементів нижнього ярусу телевежі для отримання високодеталізованих зображень із різних ракурсів.

Після збору даних проводилась обробка зображень, яка передбачала такі етапи:

- кадрування, у результаті якого було згенеровано набір зображень із роздільною здатністю 5472×3078 пікселів;
- адаптацію розмірів для подальшої обробки нейронною мережею, а саме, кожне зображення було розділене на менші фрагменти розміром 128×128 пікселів із перекриттям 50 % за шириною та висотою. Такий підхід забезпечив рівномірне покриття зображень і створення різноманітного навчального набору. У результаті було отримано 14187 сегментів, підготовлених для тренування НМ;
- анування дефектних ділянок, яке здійснювалося у програмному середовищі Labelme із використанням полігональних міток, що дозволяло точно позначати контури об'єктів шляхом апроксимації полігонами;
- нормалізацію яскравості та контрастності у програмному середовищі Labelme, що дозволяло виявити низькоконтрастні пошкодження, які не були чітко видимими на вихідних зображеннях;

- класифікацію пошкоджень на зображеннях за двома типами: корозію та значні структурні дефекти (отвори, тріщини);

– створення масок, які використовувалися для сегментації пошкоджень і виділення ключових областей аналізу.

Архітектура нейронної мережі. Виявлення дефектів конструкції на зображеннях – це задача сегментації, яка передбачає класифікацію кожного пікселя вхідного зображення. Для вирішення подібних завдань застосовуються згорткові нейронні мережі (CNN), зокрема архітектура U-Net та її модифікації. Відмінності між варіаціями U-Net: кількість шарів і фільтрів, використання нормалізації, тип функції активації, функція втрат тощо [41].

З метою підвищення ефективності сегментації було проведено серію експериментів з різними конфігураціями архітектури U-Net (рис. 1). Варіювалися такі параметри, як: початкова кількість фільтрів згорткових шарів, кількість рівнів згорткових операцій та функцій активації.

Для покращення продуктивності НМ на основі архітектури U-Net використовувалися такі вдосконалення:

- додавання механізму зчеплення (concatenation) відповідних шарів енкодера та декодера для збереження просторової інформації;
- подвоєння кількості згорткових шарів для покращення здатності моделі до вилучення ознак;
- нормалізація вхідних даних для підвищення стабільності процесу навчання.

Навчання нейронної мережі. Моделі НМ були реалізовані мовою Python 3.10.12 із використанням бібліотек TensorFlow та Keras, версія 2.9.0. При навчанні НМ її параметри зберігалися після кожної епохи навчання.




Рис. 1. Архітектура U-Net моделі: а – базова модель; б – з додатковим зчепленням шарів

Створений набір даних був розділений на тренувальний, валідаційний і тестовий набори, у співвідношенні 80 до 20 %. Тренувальний набір даних (зображення з відповідними мітками) використовувався для навчання моделі, при цьому враховувались параметри навчання, такі як: кількість епох, розмір пакету, швидкість навчання та функція втрат. Додатково використовувалися оптимізатори для адаптації ваг моделі з метою мінімізації функції втрат під час тренування та для забезпечення ефективного навчання та конвергенції моделі.

Для підвищення узагальнюючої здатності моделі, тобто її здатності коректно працювати на нових, раніше не бачених даних, застосовувалася аугментація даних. Це – штучне збільшення різноманітності навчального набору, яке покращує стійкість моделі. Для зображень аугментація передбачала такі методи, як: обертання, зміна кольору тощо.

Оптимізація параметрів здійснювалася за допомогою алгоритму Adam з функцією втрат Sparse Categorical Crossentropy, де Adam є алгоритмом, який допомагає неймережі швидше й точніше знаходити оптимальні ваги під час навчання. Sparse Categorical Crossentropy – спосіб вимірювання помилки НМ при класифікації, коли кожне зображення або об'єкт належить до одного з кількох класів.

Було також протестовано вплив різних функцій активації в останньому шарі мережі, зокрема лінійної та Softmax, що дозволило оцінити їхню ефективність при розпізнаванні класів дефектів (табл. 1).

Softmax function – це функція активації, яка часто використовується в машинному навчанні, особливо в задачах класифікації з кількома класами [41]. Вона перетворює вектор довільних чисел (вихідні значення нейронної мережі) у вектор ймовірностей, де кожне значення відповідає ймовірності належності до певного класу. Для вектора $z = [z_1, z_2, \dots, z_n]$, де z_i – вихід нейронної мережі

для i -го класу, функція Softmax обчислюється за формулою:

$$\text{Softmax}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^n e^{z_j}}$$

де e^{z_i} – експонента i -го елемента вектора z ; $\sum_{j=1}^n e^{z_j}$ – сума експонент усіх елементів вектора z .

Softmax – це вектор ймовірностей, де кожне значення знаходиться в діапазоні від нуля до одиниці, а сума всіх значень дорівнює 1.

Табл. 1 містить результати навчання НМ, де досліджується вплив початкової кількості фільтрів згорткового шару та функції активації вихідного шару на точність моделі. Оцінка проводиться на основі показників функції втрат для навчального (loss) та тестового (val_loss) наборів даних, кількості епох, необхідних для навчання, а також загальної кількості параметрів моделі.

Порівняння двох варіантів вихідного шару (лінійна активація та Softmax) показує, що використання Softmax забезпечує нижчу тестову похибку (val_loss) в усіх конфігураціях. Це свідчить про кращу здатність моделі до узагальнення, особливо при меншій кількості фільтрів.

Збільшення кількості фільтрів (від 4 до 16) призводить до зростання кількості параметрів моделі, що може покращувати її здатність до навчання, але також підвищує ризик перенавчання, коли модель демонструє високу точність на навчальних даних, втрачаючи здатність до узагальнення на нових, раніше не бачених тестових або реальних даних, особливо при використанні великої кількості фільтрів (base = 16). Це підтверджується зростанням похибки на тестовому наборі (val_loss) після 15–20 епох навчання, що свідчить про можливий перехід від узагальнюючої здатності до перенавчання.

На рис. 2 наведено залежність функції втрат (loss) для навчального та тестового наборів даних від кількості епох під час тренування НМ при використанні моделі з лінійною функцією активації та базовою кількістю фільтрів 4 (base = 4).

Таблиця 1. Вплив функцій активації на моделі U-Net з різною кількістю фільтрів і параметрів, що розраховуються під час навчання

Початкова кількість фільтрів (base)	Похибка на навчальному датасеті (loss)	Похибка на тестовому датасеті (val_loss)	Кількість епох	Кількість параметрів моделі
Лінійна функція активації останнього шару				
4	0,0907	0,1131	20/50	49267
8	0,0520	0,0874	33/50	196451
16	0,0761	0,0894	15/50	784579
Активация останнього шару Softmax				
4	0,0561	0,0758	43/50	49267
8	0,0486	0,0824	30/50	196451
16	0,0626	0,1012	16/50	784579

На початкових етапах навчання (0–10 епох) спостерігається стрімке зменшення обох похибок (loss та val_loss), що свідчить про ефективне навчання моделі. Однак після 20-ї епохи похибка на навчальному наборі даних (train_loss) продовжує зменшуватися, тоді як похибка на тестовому наборі даних (val_loss) починає зростати. Це є ознакою перенавчання, коли модель втрачає здатність до узагальнення на нових даних. Таким чином, оптимальна кількість ітерацій навчання складає 20 епох, що запобігає надмірному запам'ятовуванню навчальних зразків.

Однією з основних характеристик, які визначають ефективність НМ, є похибка сегментації (val_loss) на зображеннях, що не використовувались для навчання CNN моделі. У результаті проведених досліджень встановлено, що похибка виявлення дефектів становить від 7 до 11 % (табл. 1).

Оптимальною конфігурацією моделі для узагальнення результатів є використання восьми фільтрів разом із функцією активації Softmax. Така конфігурація забезпечує найнижче значення тестової похибки (0,0824).




Рис. 2. Залежність функції втрат (loss) для навчального та валідаційного наборів даних від кількості епох під час тренування нейронної мережі

Результати тестування різних модифікацій архітектури U-Net з варіацією початкової кількості фільтрів, кількості згорткових шарів, використанням нормалізації та збільшенням кількості блоків наведено в табл. 2.

Було досліджено три варіанти архітектури моделей U-Net:

- базову модель з додатковим зчепленням блоків;
- базову модель з подвоєною кількістю згорткових шарів зі зчепленням блоків;
- базову модель з подвоєною кількістю згорткових шарів, зчепленням блоків і нормалізацією.

Кожна з цих архітектур тестувалася з різною початковою кількістю фільтрів (base = 4, 8, 16), що загалом сформувало 9 різних конфігурацій моделей.

Базова модель зі збільшеною кількістю блоків демонструє покращені результати порівняно з початковою архітектурою, проте її точність обмежена, особливо при малій кількості фільтрів. Додавання додаткових згорткових шарів дозволяє знизити похибку на навчальному наборі, але без нормалізації спостерігається нестабільність на тестових даних, що особливо помітно при початковій кількості фільтрів, base = 4 (val_loss = 0,1342). Використання нормалізації у поєднанні зі збільшенням кількості блоків і згорткових шарів дозволяє досягти мінімального значення похибки на тестовому наборі val_loss = 0,0518 при base = 4, що свідчить про ефективність такого підходу для менш складних архітектур. Таким чином, оптимальним варіантом є архітектура з подвоєною кількістю згорткових шарів, збільшенням блоків і нормалізацією, що дозволяє мінімізувати похибку при контрольованій складності моделі.

На рис. 3 наведено залежності функції втрат (loss) для навчального та тестового наборів даних від кількості епох під час тренування базової моделі з додатковим зчепленням блоків, а також вдо-

Таблиця 2. Результати тестування вдосконалених моделей U-Net

Початкова кількість фільтрів (base)	Похибка на навчальному датасеті (loss)	Похибка на тестовому датасеті (val_loss)	Кількість епох	Кількість параметрів моделі
Базова модель + зчеплення блоків				
4	0,0683	0,0703	36/50	61507
8	0,0601	0,0599	18/50	245411
16	0,0314	0,0656	36/50	980419
Базова модель з подвоєною кількістю згорткових шарів + зчеплення блоків				
4	0,1335	0,1342	26/50	86107
8	0,0483	0,0841	21/50	343571
16	0,0658	0,0527	10/50	1372579
Базова модель з подвоєною кількістю згорткових шарів + зчеплення блоків + нормалізація				
4	0,0403	0,0518	48/50	86587
8	0,0292	0,0575	15/50	344531
16	0,0308	0,0598	14/50	1374499




Рис. 3. Залежність функції втрат (loss) для навчального та тестового наборів даних зображень: *a* – базова модель з додатковим зчепленням блоків, *б* – вдосконала модель U-Net з подвоєною кількістю згорткових шарів, зчепленням блоків і нормалізацією шарів

сконаленої моделі U-Net з подвоєною кількістю згорткових шарів, зчепленням блоків і нормалізацією шарів.

Базова модель з додатковим зчепленням блоків (рис. 3, *a*) демонструє швидке навчання, однак схильна до перенавчання, що підтверджується зростанням похибки на тестовому наборі даних (val_loss) після 20-ти епох.

При порівнянні з рис. 2 можна бачити суттєве зниження різниці значень похибки під час навчання до 3...5 %, що свідчить про точніший розрахунок параметрів моделі порівняно з використанням базової архітектури U-Net (рис. 3, *a*).

На початкових етапах навчання (0–10 епох) вдосконаленої моделі U-Net (рис. 3, *б*) значення функції втрат для тренувального (loss) і тестового (val_loss) наборів швидко зменшуються. Близькі значення цих похибок на старті пояснюються тим, що модель ще не сформувала складні закономірності й узагальнення, тому її продуктивність на тренувальних і тестових даних є подібною. У процесі подальшого навчання модель адаптується до особливостей тренувальних даних. Після 15–20 епох тренувальна та тестова похибки стабілізуються без значного розходження, що свідчить про гарне узагальнення та відсутність перенавчання.

Це свідчить про те, що модель досягла оптимальної продуктивності та може ефективно узагальнюватися на нових даних. Таким чином, запропоновані модифікації архітектури U-Net дозволили підвищити точність моделі при виявленні дефектів на зображеннях конструкцій.

Аналіз отриманих результатів. На рис. 4 наведено результати автоматичного визначення пошкоджених ділянок на зображеннях за допомогою базової моделі з кількістю фільтрів base = 4. Візуальне порівняння областей, позначених оператором (рис. 4, *б*), та сегментованих областей, отриманих нейронною мережею (рис. 4, *в*), демонструє, що модель здатна виявляти пошкодження, які залишилися непоміченими оператором. Однак результат сегментації, отриманий за допомогою нейронної мережі, має значну похибку, пропущені області, що вказує на недостатню точність.

На рис. 5 наведено результати застосування вдосконаленої моделі U-Net, кількість фільтрів base = 16 і з Softmax-активацією, які показують точнішу сегментацію дефектних ділянок, зменшуючи кількість помилкових класифікацій у порівнянні з базовою версією (рис. 4).

На рис. 6 наведено приклад, коли НМ успішно ідентифікувала дефектну область, спричинену




Рис. 4. Автоматичне визначення пошкоджених ділянок моделі з параметрами: base = 4, останній активаційним шар – лінійний: *a* – фрагмент зображення пошкодженого вузла, *б* – пошкоджені ділянки, які позначені оператором жовтим кольором, *в* – результат сегментації, отриманий нейронною мережею (зелений колір)




Рис. 5. Автоматичне визначення пошкоджених ділянок з використанням вдосконаленої моделі U-Net з параметрами: base = 16, останній активаційним шар – Softmax, *a* – фрагмент зображення пошкодженого вузла, *б* – пошкоджені ділянки, які позначені оператором жовтим кольором, *в* – результат сегментації, отриманий нейронною мережею (зелений колір)




Рис. 6. Автоматичне визначення пошкоджених ділянок з використанням удосконаленої моделі U-Net з параметрами: base = 16, останній активаційним шар – Softmax, *a* – фрагмент зображення з пошкодженими ділянками, *б* – пошкоджені ділянки, які позначені оператором, *в* – результат сегментації, отриманий нейронною мережею. Зелений колір позначає корозійне пошкодження, жовтий – отвір. Модель, кількість фільтрів – 16 (base = 16) з останнім активаційним шаром Softmax

проникненням уламків крізь стінку трубчастого елементу телевежі, яка була пропущена оператором при створенні анотації. Порівняння масок (рис. 6, *б* і рис. 6, *в*) показує, що прогнозовані області пошкоджень добре збігаються з реальними даними. Це підтверджує ефективність моделі. Отримані результати підтверджують здатність моделі виявляти пошкодження, які можуть залишатися непоміченими, тим самим мінімізуючи вплив людського фактора при проведенні візуальної діагностики конструкцій.

Отримані результати демонструють ефективність нейронної мережі U-Net для автоматичного виявлення пошкоджень. Проте неповне або неточне маркування дефектних ділянок оператором у навчальному наборі даних може негативно впливати на якість моделі, оскільки її навчання залежить від відповідності міткам, які були позначені оператором. Отже, формування якісної бази даних з повним і точним маркуванням дефектів є важливим фактором для створення високоточної моделі НМ.

Висновки

Проведене дослідження підтвердило ефективність застосування нейронних мереж для автоматизованого виявлення дефектів, що сприяє підви-

щенню точності діагностики та мінімізації впливу суб’єктивного фактора.

Аналіз ефективності різних архітектур нейронних мереж показав, що моделі з більшою кількістю фільтрів забезпечують покращену здатність до ідентифікації дефектів, проте їх використання потребує значних обчислювальних ресурсів і часу на тренування. Модифіковані архітектури U-Net, зокрема шляхом додавання додаткових блоків і нормалізації, дозволили знизити похибку виявлення дефектів до 3...5 %, що є суттєвим покращенням порівняно з базовими моделями. Встановлено, що оптимальна кількість ітерацій для навчання моделей з модифікованою архітектурою становить 15–20, оскільки подальше навчання призводить до перенавчання та зростання похибки на тестових даних.

Використання модифікованих архітектур нейронних мереж із застосуванням механізмів нормалізації та адаптивного налаштування гіперпараметрів є перспективним напрямом для підвищення точності й надійності автоматизованої діагностики дефектів на основі аналізу зображень, що відкриває можливості для подальшої інтеграції таких систем у процес моніторингу.

Подяка

Опубліковані результати отримані в рамках реалізації проекту 022.01/0095 «Розробка технології дистанційної діагностики пошкоджених великогабаритних об'єктів на основі застосування безпілотних літальних апаратів (БПЛА) та фотограмметрії», за грантової підтримки Національного фонду досліджень України в рамках конкурсу «Наука для відбудови України у воєнний та повоєнний періоди»

Список літератури/References

1. Balayssac, J.-P., Garnier, V. et al. (2018) *Non-Destructive testing and evaluation of civil engineering structures*. STE Press Ltd., Elsevier Science. DOI: <https://doi.org/10.1016/C2016-0-01227-5>
2. Reddy, K.A. (2017) Non-destructive testing, evaluation of stainless steel materials. *Mater. Today Proc.*, 4(8), 7302–7312. DOI: <https://doi.org/10.1016/j.matpr.2017.07.060>
3. Deepak, J.R., Raja, V.K.B., Srikanth, D., Surendran, H., Nickolas, M.M. (2021) Non-destructive testing (NDT) techniques for low carbon steel welded joints: A review and experimental study. *Mater. Today Proc.*, 44(8), 3732–3737. DOI: <https://doi.org/10.1016/j.matpr.2020.11.578>
4. Polimeno, M., Roselli, I., Luprano, V.A.M., Mongelli, M., Tati, A., De Canio, G. (2018) A non-destructive testing methodology for damage assessment of reinforced concrete buildings after seismic events. *Engineering Structures*, 163, 122–136. DOI: <https://doi.org/10.1016/j.engstruct.2018.02.053>
5. Bahonar, M., Safizadeh, M. (2021) Investigation of real delamination detection in composite structure using air-coupled ultrasonic testing. *Composite Structures*, 280, 114939. DOI: <https://doi.org/10.1016/j.compstruct.2021.114939>
6. Chen, Y., Kang, Y., Feng, B., Li, Y., Cai, X. (2022) Automatic defect identification in magnetic particle testing using a digital model aided de-noising method. *Measurement*, 198, 111427. DOI: <https://doi.org/10.1016/j.measurement.2022.111427>
7. Van Steen, C., Pahlavan, P., Wevers, M., Verstrynge, E. (2018) Localisation and characterisation of corrosion damage in reinforced concrete by means of acoustic emission and X-ray computed tomography. *Construction and Building Materials*, 197, 21–29. DOI: <https://doi.org/10.1016/j.conbuildmat.2018.11.159>
8. Suzuki, T., Ogata, H., Takada, R., Aoki, M., Ohtsu, M. (2010) Use of acoustic emission and X-ray computed tomography for damage evaluation of freeze-thawed concrete. *Construction and Building Materials*, 24, 2347–2352. DOI: <https://doi.org/10.1016/j.conbuildmat.2010.05.005>
9. Pedram, M., Taylor, S., Hamill, G., Robinson, D., O'Brien, E., Uddin, N. (2022) Experimental evaluation of heat transition mechanism in concrete with subsurface defects using infrared thermography. *Construction and Building Materials*, 360, 129531. DOI: <https://doi.org/10.1016/j.conbuildmat.2022.129531>
10. Shrestha, P., Avci, O., Rifai, S., Aba, F., Seek, M., Barth, K., Halabe, U. (2025) A review of infrared thermography applications for civil infrastructure. *Structural Durability & Health Monitoring*, 19(2), 193–231. DOI: <https://doi.org/10.32604/sdhm.2024.049530>
11. Lobanov, L.M., Stelmakh, D., Shkurat, I., Savitsky, V., Toldo, R., Alessi, A. (2025) Determination of a TV tower verticality using UAVs, RTK and photogrammetry. In: *VIIth International Conference «Welding and Related Technologies»*, Yaremche, Ukraine, 7–10 October 2024, pp. 149–153. DOI: <https://doi.org/10.1201/9781003518518-30>
12. Lobanov, L., Stelmakh, D., Savitsky, V., Diadin, V., Shutkevych, O., Shkurat, I. (2024) Damage detection and analysis using unmanned aerial vehicles (UAVs) and photogrammetry method. *Procedia Structural Integrity*, 59, 43–49. DOI: <https://doi.org/10.1016/j.prostr.2024.04.008>

13. Lobanov L.M., Stelmakh D.I., Saviцький В.В., Дядін В.П., Шуткевич О.П., Козачек А.Г. (2023) Дистанційна оцінка пошкоджень кийської телевежі на основі застосування аерофотозіомки та методу фотограмметрії. *Технічна діагностика та неруйнівний контроль*, 3, 16–20. DOI: <https://doi.org/10.37434/tdnk2023.03.03>
- Lobanov, L.M., Stelmakh, D.I., Savitsky, V.V., Diadin, V.P., Shutkevych, O.P., Kozachek, A.G. (2023) Remote assessment of damage to Kyiv TV tower based on the application of aerial photography and photogrammetry method. *Tekh. Diagnost. ta Neruiniv. Kontrol*, 3, 16–20 [in Ukrainian]. DOI: <https://doi.org/10.37434/tdnk2023.03.03>
14. Onososen, A., Musonda, I., Onatayo, D., Tjebane, M., Saka, A., Fagbenro, R. (2023) Impediments to construction site digitalization using unmanned aerial vehicles (UAVs). *Drones*, 7(1), 45. DOI: <https://doi.org/10.3390/drones7010045>
15. Albeaino, G., Gheisari, M., Franz, B.W. (2019) A systematic review of unmanned aerial vehicle application areas and technologies in the AEC domain. *J. of Information Technology in Construction (ITcon)*, 24, 381–405. DOI: <https://doi.org/www.itcon.org/2019/20>
16. Ham, Y., Han, K.K., Lin, J.J., Golparvar-Fard, M. (2016) Visual monitoring of civil infrastructure systems via camera-equipped unmanned aerial vehicles (UAVs): A review of related works. *Visualization in Engineering*, 4, 1. DOI: <https://doi.org/10.1186/s40327-015-0029-z>
17. Pant, S., Nooralishahi, P., Avdelidis, N.P., Ibarra-Castaneda, C., Genest, M., Deane, S. et al. (2021) Evaluation and selection of video stabilization techniques for uav-based active infrared thermography application. *Sensors*, 21, 1604. DOI: <https://doi.org/10.3390/s21051604>
18. Ciampa, E., De Vito, L., Rosaria Pecce, M. (2019) Practical issues on the use of drones for construction inspections. *J. of Physics: Conference Series*, 1249, 012016. DOI: <https://doi.org/10.1088/1742-6596/1249/1/012016>
19. Duque, L., Seo, J., Wacker, J. (2018) Synthesis of unmanned aerial vehicle applications for infrastructures. *J. Perform. Constr. Facil.*, 32(4). DOI: [https://doi.org/10.1061/\(ASCE\)CF.1943-5509.0001185](https://doi.org/10.1061/(ASCE)CF.1943-5509.0001185)
20. Rakha, T., Gorodetsky, A. (2018) A review of unmanned aerial system (UAS) applications in the built environment: Towards automated building inspection procedures using drones. *Aut. in Constr.*, 93, 252–264. DOI: <https://doi.org/10.1016/j.autcon.2018.05.002>
21. Wu, W., Qurishee, M.A., Owino, J., Fomunung, I., Onyango, M., Atolagbe, B. (2018) Coupling deep learning and UAV for infrastructure condition assessment automation. In: *2018 IEEE International Smart Cities Conference, ISC2, 2018 Sep 16–19, Kansas City, MO, USA*. DOI: <https://doi.org/10.1109/ISC2.2018.8656971>
22. Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G. (2016) Recent advances in convolutional neural networks. *Pattern Recognition*, 77, 354–377. DOI: <https://doi.org/10.1016/j.patcog.2017.10.013>
23. Gulgec, N.S., Takáč, M., Pakzad, S.N. (2017) Structural damage detection using convolutional neural networks. In: *Conference Proceedings of the Society for Experimental Mechanics Series*, pp. 331–337. DOI: https://doi.org/10.1007/978-3-319-54858-6_33
24. Krizhevsky, A., Sutskever, I., Hinton, G. (2012) Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25(2), 1097–1105. DOI: <https://doi.org/10.1145/3065386>
25. Lee, S.Y., Tama, B.A., Moon, S.J., Lee, S. (2019) Steel surface defect diagnostics using deep convolutional neural network and class activation map. *Applied Sciences*, 9(24), 5449. DOI: <https://doi.org/10.3390/app9245449>
26. Tabernik, D., Šela, S., Skvarc, J., Skocaj, D. (2020) Segmentation-based deep-learning approach for surface-defect detection. *J. of Intelligent Manufacturing*, 31(3), 759–776. DOI: <https://doi.org/10.1007/s10845-019-01476-x>
27. Prappacher, N., Bullmann, M., Bohn, G.; Deinzer, F.; Linke, A. (2020) Defect detection on rolling element surface scans using neural image segmentation. *Applied Sciences*, 10(9), 3290. DOI: <https://doi.org/10.3390/app10093290>

28. Li, J., Su, Z., Geng, J., Yin, Y. (2018) Real-time detection of steel strip surface defects based on improved YOLO detection network. *IFAC-PapersOnLine*, 51(21), 76–81. DOI: <https://doi.org/10.1016/j.ifacol.2018.09.412>
29. Wei, R., Song, Y., Zhang, Y. (2020) Enhanced faster region convolutional neural networks for steel surface defect detection. *ISIJ International*, 60(3), 539–545. DOI: <https://doi.org/10.2355/isijinternational.isijint-2019-335>
30. Cha, Y.-J., Choi, W., Buyukozturk, O. (2017) Deep learning-based crack damage detection using convolutional neural networks. *Computer-Aided Civil and Infrastructure Engineering*, 32(5), 361–378. DOI: <https://doi.org/10.1111/mice.12263>
31. Hutchinson, T., Chen, Z. (2006) Improved image analysis for evaluating concrete damage. *J. of Computing in Civil Engineering*, 20(3), 210–216. DOI: [https://doi.org/10.1061/\(ASCE\)0887-3801\(2006\)20:3\(210\)](https://doi.org/10.1061/(ASCE)0887-3801(2006)20:3(210))
32. Dung, C., Sekiya, H., Hirano, S., Okatani, T., Miki, C. (2019) A vision-based method for crack detection in gusset plate welded joints of steel bridges using deep convolutional neural networks. *Automation in Construction*, 102, 217–229. DOI: <https://doi.org/10.1016/j.autcon.2019.02.013>
33. Shen, H.-K., Chen, P.-H., Chang, L.-M. (2013) Automated steel bridge coating rust defect recognition method based on color and texture feature. *Automation in Construction*, 31, 338–356. DOI: <https://doi.org/10.1016/j.autcon.2012.11.003>
34. Xu, Y., Bao, Y., Chen, J., Zuo, W., Li, H. (2018) Surface fatigue crack identification in steel box girder of bridges by a deep fusion convolutional neural network based on consumer-grade camera images. *Structural Health Monitoring*, 18(3), 653–674. DOI: <https://doi.org/10.1177/1475921718764873>
35. Prasanna, P., Dana, K.J., Gucunski, N. et al. (2016) Automated crack detection on concrete bridges. *IEEE Transactions on Automation Science and Engineering*, 13(2), 591–599. DOI: <https://doi.org/10.1109/TASE.2014.2354314>
36. An, Y.-K., Jang, K.-Y., Kim, B., Cho, S. (2018) Deep learning-based concrete crack detection using hybrid images. In: *Proc. SPIE 10598, Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems*, 1059812. DOI: <https://doi.org/10.1117/12.2294959>
37. Chow, J.K., Su, Z., Wu, J., Tan, P.S. et al. (2020) Anomaly detection of defects on concrete structures with the convolutional autoencoder. *Advanced Engineering Informatics*, 45, 101105. DOI: <https://doi.org/10.1016/j.aei.2020.101105>
38. Miranda, J., Veith, J., Larnier, S., Herbulot, A., Devya, M. (2019) Machine learning approaches for defect classification on aircraft fuselage images acquired by an UAV. In: *Fourteenth International Conference on Quality Control by Artificial Vision*, Vol. 11172, 1117208. DOI: <https://doi.org/10.1117/12.2520567>
39. Avdelidis, N.P., Tsourdos, A., Lafiosca, P., Plaster, R., Plaster, A., Droznika, M. (2022) Defects recognition algorithm development from visual UAV inspections. *Sensors*, 22(13), 4682. DOI: <https://doi.org/10.3390/s22134682>
40. Ronneberger, O., Fischer, P., Brox, T. (2015) U-net: convolutional networks for biomedical image segmentation. In: *Proceedings of the Medical Image Computing and Computer-Assisted Intervention (MICCAI 2015)*, 234–241. <http://lmb.informatik.uni-freiburg.de/people/ronneber/u-net>
41. Ren, J., Wang, H. (2023) Calculus and optimization. In: *Mathematical Methods in Data Science, Chapter 3*. Elsevier, pp. 51–89. DOI: <https://doi.org/10.1016/B978-0-44-318679-0.00009-0>

ENHANCING LARGE-SCALE STRUCTURE DIAGNOSTICS THROUGH UAV-BASED DATA AND NEURAL NETWORK ANALYSIS

L.M. Lobanov, I.L. Shkurat, D.I. Stelmakh, O.P. Shutkevych, V.V. Savitsky

E.O. Paton Electric Welding Institute of the NAS of Ukraine. 11 Kazymyr Malevych Str., 03150, Kyiv, Ukraine.

E-mail: innashkurat2909@gmail.com

The article presents an approach to remote diagnostics of damage to large-sized engineering structures using unmanned aerial vehicles (UAVs) and convolutional neural networks. The study was conducted to automate the process of detecting structural defects in the Kyiv TV tower. The research methodology involved the collection and preprocessing of 14187 images and the development of a modified architecture of the U-Net neural network for damage segmentation. An experimental study of different architectural settings of the model demonstrated the effectiveness of the proposed modifications, which reduced the error of defect detection by 3...5 % compared to the baseline models. It was found that the optimal number of training iterations is 15–20 epochs. The developed model demonstrated the ability to detect damage that may be missed by the operator, which confirms the potential of automated diagnostic systems based on artificial intelligence. The study provides new prospects for improving the efficiency of monitoring infrastructure facilities, especially in conditions of limited access or increased risks to personnel. 41 Ref., 2 Tabl., 6 Fig.

Keywords: remote diagnostics, defects, artificial intelligence, neural networks, image segmentation, UAVs

Отримано 06.03.25

Отримано у переглянутому вигляді 04.04.25

Прийнято 08.05.25

3D ДРУК ДЕТАЛЕЙ З РІЗНИХ КОМБІНАЦІЙ МЕТАЛІВ

Дослідники зробили значний прорив у галузі 3D друку металів, розробивши технологію створення легких і міцних багатокомпонентних деталей.

Вченим вдалося успішно об'єднати в одній деталі сталь і алюміній, що раніше вважалося складним завданням через ризик утворення крихких з'єднань різних металів.

Ключем до успіху стала лазерна порошкова плавка Laser Powder Bed Fusion (L-PBF).

Завдяки 3D друку можна створювати деталі з унікальною геометрією, що дасть змогу оптимізувати конструкцію автомобілів і знизити їхню вагу. Крім того, нова технологія дасть змогу виробляти екологічно чистіші транспортні засоби, оскільки 3D друк дає змогу скоротити кількість відходів виробництва.



За матеріалами Інтернету