УДК 004.032.26
DOI https://doi.org/10.32782/2663-5941/2023.2.1/22

Галаган Р.М.
Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

Андреєв С.М.
Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

Петрик В.Ф.
Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

Баженов В.Г.
Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

Лисенко Ю.Ю.
Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

ВИЯВЛЕННЯ ДЕФЕКТІВ БЕТОННИХ КОНСТРУКЦІЙ НА ОСНОВІ АНАЛІЗУ ЗОБРАЖЕНЬ ЗА ДОПОМОГОЮ ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ

Своєчасне виявлення зовнішніх дефектів бетонних конструкцій (зокрема, бетонних стін, бетонних опор мостів) є актуальною задачею, оскільки внаслідок їх неконтрольованого розвитку може відбутися руйнування. Сьогодні основним підходом до оцінки зовнішнього стану бетонних конструкцій є візуальний огляд або аналіз фотографій людиною, що привносить суб'єктивний фактор та не дозволяє автоматизувати аналіз та процес прийняття рішень. Одним із способів автоматизації процесу виявлення дефектів та їх аналізу є застосування нейромережевих технологій.

У роботі описано структуру програмного забезпечення, за допомогою якого відбувається автоматизоване виявлення дефектів на зображеннях бетонних конструкцій. Воно складається із трьох модулів: модуля попередньої обробки зображення, модуля класифікації та модуля автоматичного аналізу і візуалізації. Завдяки модульності програмне забезпечення легко підтримується, розширюється та дозволяє впроваджувати нові функціональні можливості.

Запропоновано використовувати згорткову нейронну мережу VGG16, яка дозволяє досягти більшої точності на меншій кількості даних у порівнянні із подібними реалізаціями. Показано, що найбільш оптимальним для вирішення поставлених задач є використання мережі VGG16 у режимі Transfer Learning. Створена модель нейронної мережі налаштована таким чином, щоб виконувати бінарну класифікацію (дефектна та бездефектна зона). Проте вона має потенціал до розширення та можливість виконувати класифікацію за різними типами дефектів. Розроблене програмне забезпечення було застосоване до набору зображень бетонних елементів мостових конструкцій CODEBRIM, до якого були додані ще й власні зображення, зроблені на цифрову фотокамеру при денному освітленні. Після навчання мережа дозволила виявляти дефекти типу тріщин та сколів із вірогідністю безпомилкового визначення (precision) 96,3%.

Ключові слова: *бетонна конструкція, дефект бетону, аналіз зображень, нейронна мережа, VGG16.*

Постановка проблеми. Будівельні конструкції бувають найрізноманітніших форм та видів, однак для усіх них неминучим є фізичне та моральне старіння конструктивних елементів та матеріалів. Руйнівні процеси, що протікають у конструкціях, призводять до утворення пошкоджень – тріщин, прогинів, деформацій, окислення, корозії металевих деталей тощо. Вони можуть бути зовнішніми чи прихованими. Одними із складових будівельних конструкцій, до яких завжди можна отримати

доступ і які можуть надати значну інформацію про стан об'єкту в цілому, є зовнішні елементи, наприклад, стіни будинків, опорні бетонні конструкції мостів тощо. Зокрема, за поверхневими тріщинами у стінах можна судити про ступінь зношення та міцність матеріалу в цілому. Тріщини з'являються не лише від недостатньої здатності стін підтримувати навантаження, а й через поганий стан інших конструкцій: основ, фундаментів тощо.

Для оцінки зовнішнього стану елементів будівельних конструкцій зазвичай застосовують або візуальний огляд конструкції, або аналіз знімків, що зроблені цифровими фотокамерами. За наявності невеликого об'єму інформації оператор може самостійно впоратися із завданням аналізу цифрових знімків, хоча тут може бути присутній суб'єктивний фактор. Проте за наявності значного об'єму візуальної інформації ефективність роботи оператора різко знизиться, при цьому підвищиться ризик прийняття помилкового рішення.

Ефективним рішенням автоматизації процесу аналізу цифрових знімків для виявлення дефектів бетонних конструкцій є застосування нейромережевих технологій спільно із системою комп'ютерного зору. Дефектом може бути: тріщина, корозія конструкційної сталі, осип будівельного матеріалу з подальшим оголенням арматури та інших несучих елементів, напливи матеріалу, дефектні шви тощо. Система аналізу зображень бетонних конструкцій може мати широке застосування в галузі виробництва будівельних матеріалів та будівництва для автоматизованого контролю якості продукції та споруд. Система може бути розміщена на об'єктах інфраструктури (наприклад, мостах) для прогнозування та контролю за термінами служби споруд за зовнішніми ознаками.

Аналіз останніх досліджень і публікацій. Застосування нейронних мереж (НМ) для аналізу зображень сьогодні вже є чимось звичним. Існують різноманітні бази даних із зображенням, які використовуються для тренування та перевірки працездатності тієї чи іншої мережі. Проте в контексті вирішуваної задачі потрібні не просто набори зображень, а зображення саме бетонних конструкцій (точніше, їх частин) із дефектами. Аналіз останніх досліджень показує, що існує проблема із наборами даних, які містять зображення саме бетонних конструкцій з дефектами і без них. Наприклад, у роботі [1] для навчання та тестування НМ використовувався набір із 3500 зображень бетонних поверхонь, причому основною метою було дослідження впливу певних параметрів моделі НМ на точність класифікації. У роботі [2] порівнюються різні моделі НМ та підходи до класифікації дефектів бетонних конструкцій, а для навчання та тестування моделі використовуються 487 зображень, із яких за певним алгоритмом виділені 3186 графічних зон, із яких 527 містять дефекти, а 2659 – ні. У роботі [3] також пропонується використовувати НМ для класифікації дефектів різних будівельних конструкцій, причому для навчання мережі використовувались знайдені за допомогою звичайного пошуку в інтернеті зображення, серед яких було 278 зображень зі сколами та 954 – із тріщинами. У роботі [4] авторами пропонується використання архітектур НМ з метанавчанням (для тестування НМ було створено набір із 1500 зображень).

Як видно із наведених прикладів, усі набори даних в розглянутих роботах є досить малими. Тому в кожній роботі було застосовано підхід, який полягає у «нарізуванні» великих зображень на менші частини з метою збільшення вибірки даних. Такий самий підхід буде використано і у цій роботі.

Постановка завдання. Метою дослідження є розробка окремих модулів програмного забезпечення (ПЗ) для системи комп'ютерного зору, яка дозволить із заданою вірогідністю виявляти дефекти бетонних конструкцій. В основі ПЗ має бути НМ. Головним критерієм якості моделі пропонується використати метрику precision, яка визначає долю правильно класифікованих дефектів на зображеннях, які насправді є дефектами (фактично, показує ймовірність правильних передбачень системи):

$$P = \frac{TP}{TP + FP},$$

де TP – істинно-позитивні передбачення моделі, FP – хибно-позитивні передбачення моделі.

На першому етапі розробки поставлена задача лише автоматизованого виявлення зовнішніх неоднорідностей бетонних стін без їх мультикласової класифікації. Це означає, що на даному етапі неможливо буде сказати, яким саме дефектом є неоднорідність.

Вихідні дані та обладнання. Основним джерелом вихідних даних, що використовувалися для навчання та тестування НМ, є набір фотографій COncrete DEfect BRidge IMage Dataset [5]. Цей набір містить більше 1500 фотографій високої роздільної здатності (максимально 6000x4000 пікселів) і призначений для навчання та тестування різних нейромереж для пошуку зовнішніх дефектів у бетонних елементах мостових конструкцій.

Також до цього набору була додана деяка кількість власних зображень бетонних стін.

Важливо зауважити, що самі вихідні фотографії неможливо використовувати для навчання та тренування НМ, оскільки, по-перше, їх замало, а, по-друге, вони містять багато зайвої інформації, яка може негативно вплинути на процес навчання мережі. Тому спочатку була виконана попередня обробка даних, яка полягає у «нарізуванні» вихідних фотографій на окремі частини заданих розмірів (мінімально 256х256 пікселів). У результаті попередньої обробки було отримано кілька десятків тисяч фрагментів, із яких вручну були відібрані близько 4000 інформативних фрагментів, а усі інші фрагменти, що не містили жодної корисної інформації, були відсіяні. Інформативні фрагменти були порівну розділені на два класи: дефектний і бездефектний. Підготовка даних у ручному режимі для навчання й тестування НМ була зроблена лише у межах виконання цієї роботи. У режимі роботи на реальних об'єктах «нарізування» вихідних зображень має відбуватись автоматично.

Для розробки моделі НМ була використана бібліотека Keras мови програмування Python. Технічні характеристики обладнання, на якому виконувалась розробка та тестування НМ, представлені у табл. 1.

Опис архітектури програмного забезпечення. Розроблене програмне забезпечення складається з трьох модулів: модуль завантаження та попередньої обробки зображення (МЗПОЗ), модуль комп'ютерного зору – класифікатор (МКЗК) та модуль автоматичного аналізу і візуалізації (МААВ).

Модуль МКЗК складається із згорткової НМ з архітектурою VGG16, у результаті роботи якої отримують активаційні шари та передбачення (prediction), що передається в модуль візуалізації МААВ.

Модуль МААВ є керівним модулем, який приймає вихідне зображення та проводить його «пірамідальну» обробку та нарізку. Після цього модуль МААВ почергово передає нарізані зображення у модулі МЗПОЗ і МКЗК, звідки приймає передбачення і активаційні шари, за допомогою яких проводиться візуалізація. Проаналізувавши всі частини зображення, модуль МААВ складає загальну активаційну карту і позначає області зображення з позитивним (дефектним) передбаченням.

Реалізація модуля МЗПОЗ. Завантажувальний модуль містить функцію читання цифрового зображення, що повертає тривимірний масив колірної схеми RGB, значення кожного елементу якого лежать у діапазоні від 0 до 255:

$$IMG_{m,n} = \begin{pmatrix} RGB_{1,1} & RGB_{1,2} & \dots & RGB_{1,n} \\ RGB_{2,1} & RGB_{2,2} & \dots & RGB_{2,n} \\ \vdots & \vdots & \ddots & \vdots \\ RGB_{m,1} & RGB_{m,2} & \cdots & RGB_{m,n} \end{pmatrix},$$

де $IMG_{m,n}$ – цифрове зображення, $RGB_{i,j}$ = (RED GREEN BLUE).

Після завантаження зображення відбувається його нормалізація, яка передбачає перетворення кольорового зображення у градації сірого. Таке перетворення виконується з метою покращення «узгодженості» (або «однорідності») даних.

Також модуль МЗПОЗ виконує ще одну важливу функцію. Хоча, як було показано у попередньому розділі, кількість відібраних інформативних фрагментів склала близько 4000, проте цих даних все ж замало для перевірки працездатності розробленої НМ, оскільки частина зображень використовується для навчання, частина – для тренування і валідації. Тому, враховуючи, що детермінант дефектного класу (дефект на зображенні) не має певної стандартної орієнтації на зображенні і не визначається своїми розмірами, було прийнято рішення у модулі МЗПОЗ використовувати аугментацію зображень. Ця техніка використовується для штучного збільшення розміру навчального набору даних шляхом створення модифікованих версій зображень цього набору даних. Навчання моделей НМ на більшій кількості даних може призвести до створення більш точних моделей, а техніка доповнення дозволяє створювати варіації зображень, які можуть поліпшити здатність моделей узагальнювати отримані знання на нові зображення. Модуль МЗПОЗ виконує аугментацію за правилами, що описані у табл. 2.

Таблиця 1

Технічні характеристики обладнання

Складові обладнання	Опис
CPU	i7-8750H 6 Cores, 12 Threads, 2.20 GHz, 9 MB Cache, 8 GT/s
GPU	GTX 1050 TI 4GB VRAM
RAM	32 GB DDR4-2666
SDD	1000 GB

Таблиця 2

Правила аугментації

Діапазон повороту (у градусах)	**[-15, 15]**
Діапазон масштабування	width = 0.1, height = 0.1
Діапазон яскравості	[0.5, 1.25]
Обертання	vertical = True, horizontal = True

Реалізація модуля МКЗК. Потужною архітектурою НМ, що призначена для обробки зображень, є згорткова НМ CNN [6], яка містить у собі вхідний, навчальний і вихідний шари. Вхідний шар зчитує зображення і переносить його на навчальні шари, які виконують операції згортки та фільтрацію для видобутку особливостей зображення. Вихідний шар класифікує зображення відповідно до цільових категорій, використовуючи особливості, отримані у навчальних шарах. НМ може бути навчена, призначаючи цільові категорії зображенням у набір навчальних даних та ітеративно змінюючи значення фільтрів за допомогою зворотного розповсюдження до тих пір, поки не буде досягнуто бажаної точності.

У роботі було прийнято рішення використовувати поширену архітектуру згорткової нейронної мережі VGG16 [7]. У подібних дослідженнях, що були проведені раніше департаментами цивільної та природної розробки університетів штату Юта і Кларксона, використовувалась модель AlexNet [8]. За результатами досліджень було зроблено висновок, що у цьому випадку варто застосовувати сучасніші та «важкі» моделі НМ. Модель VGG16 досконаліша за AlexNet та дозволяє досягти більшої точності на меншій кількості даних.

Архітектура використовуваної моделі VGG16 у вигляді списку шарів наведена у табл. 3. Фактично, це стандартна модель VGG16, проте у ній було модифіковано вхідний та класифікаційні шари з метою зменшення кількості параметрів. Це зроблено із двох причин. По-перше, у класичній імплементації моделі VGG16 у вихідних шарах використовується зв'язка з шару max_pooling з наступними двома парами шарів почергово dense та dropout розмірністю 4096 вузлів кожен. Однак у такому випадку ми отримуємо 134 мільйони параметрів, що потребує великих обчислювальних потужностей та унікальних даних. Використовуване нами обладнання не змогло б за адекватний час впоратись із поставленим завданням. По-друге, завдяки зменшенню кількості параметрів була знижена ймовірність перетренування моделі, оскільки вихідні дані не мають достатньої внутрішньокласової диференціації.

Таблиця 3

Перелік шарів використовуваної моделі НМ

Layer (type)	**Output Shape**	**Param #**
input_1 (InputLayer)	None, 256, 256, 3	
block1_conv1 (Conv2D)	None, 256, 256, 64	1792
block1_conv2 (Conv2D)	None, 256, 256, 64	36928
block1_pool (MaxPooling2D)	None, 256, 256, 64	
block2_conv1 (Conv2D)	None, 128, 128, 128	73856
block2_conv2 (Conv2D)	None, 128, 128, 128	147584
block2_pool (MaxPooling2D)	None, 64, 64, 128	
block3_conv1 (Conv2D)	None, 64, 64, 256	295168
block3_conv2 (Conv2D)	None, 64, 64, 256	590080
block3_conv3 (Conv2D)	None, 64, 64, 256	590080
block3_pool (MaxPooling2D)	None, 32, 32, 256	
block4_conv1 (Conv2D)	None, 32, 32, 512	1180160
block4_conv2 (Conv2D)	None, 32, 32, 512	2359808
block4_conv3 (Conv2D)	None, 32, 32, 512	2359808
block4_pool (MaxPooling2D)	None, 16, 16, 512	
block5_conv1 (Conv2D)	None, 16, 16, 512	2359808
block5_conv2 (Conv2D)	None, 16, 16, 512	2359808
block5_conv3 (Conv2D)	None, 16, 16, 512	2359808
block5_pool (MaxPooling2D)	None, 8, 8, 512	
global_average_pooling2d	None, 512	
flatten (Flatten)	None, 512	
dense (Dense)	None, 256	131328
dense_1 (Dense)	None, 1	257
Total params: 14,846,273 **Trainable params**: 131,585 **Non-trainable params**: 14,714,688		

Кожен шар моделі VGG16, що представлені у табл. 3, виконує певні задачі. Шари, які включають у своїй назві «conv», є стандартними згортковими шарами мережі. По своїй суті вони є набором матриць, які називаються картами ознак, кожна з яких має свій фільтр-ядро. Далі, алгоритмічно програма проходить цим ядром (яке у свою чергу є все тією ж матрицею) по картах, при цьому результат множення сегмента карти на ядро записується у результуючу матрицю. Схематично це представлено на рис. 1.

Шари MaxPooling використовуються для ущільнення попередньої матриці ознак. Вони отримують із попереднього шару квадратні матриці розміром 2x2, в яких знаходять найбільший елемент і повертають його як елемент нової матриці. Наприклад, отримавши результат, що представлений на рис. 1, шар MaxPooling поверне число 3. Ця операція дозволяє зменшити розмірність, щоб модель не перенавчалася на більше не потрібних деталях зображення.

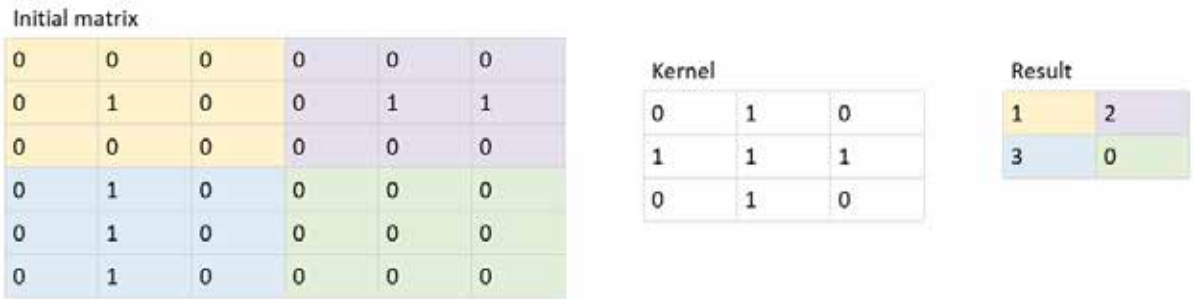

Рис. 1. Алгоритм згортки, що виконується внутрішніми шарами НМ (хоча тут показано, що ядро ухається із кроком 3 клітинки, проте це лише спрощення для більш зрозумілої візуалізації, зазвичай воно зсувається лише на одну клітинку)

Global_average_pooling є операцією об'єднання, яка розроблена для заміни повністю пов'язаних шарів у класичних мережах CNN. Ідея полягає у створенні однієї карти ознак для кожної відповідної категорії задачі класифікації.

Шар Flatten виконує трансформацію усіх матриць у вектор-рядок, який надалі використовуватиметься шарами Dense для класифікації. Останнім шаром моделі є dense_1, який містить бінарні ваги.

Модель VGG16 має реалізації, які дозволяють використовувати її як у режимі FT (Fully Trained), так і у режимі TL (Transfer Learning). Режим FT передбачає тренування моделі з нуля, а режим TL передбачає наявність готової моделі, яка пройшла тренувальний етап на великому об'ємі інформації.

Для вибору найбільш оптимального режиму було виконано тестування розробленої моделі НМ, причому у TL режимі модель VGG16 була навчена на наборі даних ImageNet, який є відкритим (open source) [9], зі зміною вхідних та вихідних (класифікаційних) шарів. У табл. 4 наведені метрики моделі VGG16 у режимах FT і TL, що була застосована до вхідного набору даних. В обох режимах модель пройшла 25 тренувальних епох із поверненням найоптимальнішого стану моделі.

Таблиця 4

Порівняння метрик моделі VGG16 у режимах FT і TL

Параметр	TL	FT
TP	1926	823
TN	1962	1269
FP	74	1177
FN	38	731
Overall	4000	4000
Accuracy	97.2%	52.3%
Precision	96,3%	41,2%
Recall	98,1%	52,9%

Аналіз даних у табл. 4 однозначно свідчить, що режим TL є точнішим за режим FT за усіма метриками. Зокрема, якщо брати як основну метрику precision, то різниця становить 55,1%. Також можна звернути увагу, що у режимі TL модель має досить збалансований розподіл P/N передбачень і не має суттєвого зсуву до одного з класів, тоді як режим FT набагато гірше справляється з пошуком дефектів і має властивість точніше виявляти бездефектні ділянки.

Реалізація модуля МААВ. Модуль автоматичного аналізу та візуалізації створено з метою передачі до модуля МКЗК попередньо обробленої інформації для подальшої її класифікації та візуалізації. Для визначення відносного розташування дефекту використовується «пірамідальна» передобробка вихідних зображень, яка полягає у «нарізуванні» вихідного зображення на рівні частини встановленого розміру *S*. Після чого відбувається взяття частини більшого розміру та його згортання у зображення того самого розміру *S*. Ця процедура виконується з метою аналізу частини зображення з різним масштабом.

Далі вся інформація, отримана описаним вище шляхом, надходить послідовно модуль у модулі МЗПОЗ і МКЗК. Якщо МКЗК передає позитивне передбачення (тобто, наявність дефекту), модуль МААВ запам'ятовує квадрат, який він передав до МЗПОЗ. У тому випадку, якщо МКЗК повертає позитивний результат на частину зображення з іншим масштабом і цей фрагмент перетинається з іншим позитивним фрагментом, то модуль МААВ вибирає позитивним фрагмент, який мав максимальну кількість перетинів з іншими фрагментами (рис. 2).

Модуль МААВ також реалізує метод післяопераційного спостереження Grad-CAM [10], який відображає останній активаційний шар у вигляді теплової карти та застосовується до вже навченої НМ після завершення навчання та фіксації параметрів. Основна ідея Grad-CAM полягає у тому, що для того, щоб визначити, які частини вхідного зображення були важливими для прийняття класифікаційного рішення, використовується просто-

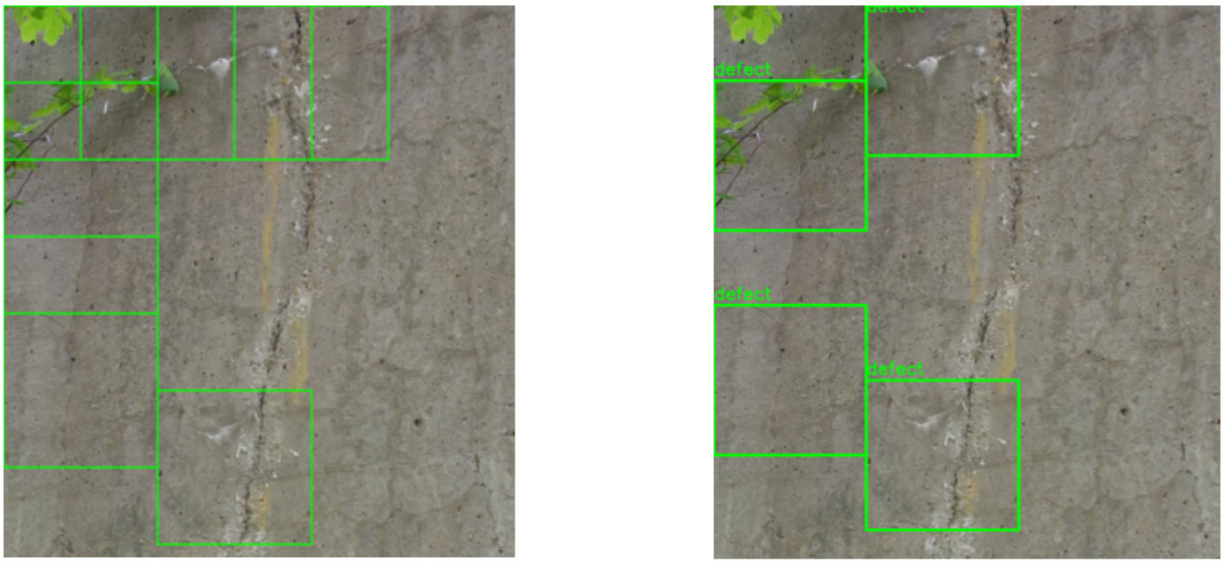

а *б*

Рис. 2. Виділення елементів зображення: *а* – початкові рамки, *б* – рамки після додаткової обробки

рова інформація, яка зберігається через згорткові шари. Оскільки ця технологія використовує вже підраховані результати роботи НМ, з'являється можливість використовувати її для потокової візуалізації стану об'єкта, не виділяючи при цьому додаткових обчислювальних ресурсів. Окрім звичайної візуалізації роботи алгоритму, ця технологія дозволяє виконувати розмітку даних для задач сегментації зображень.

На рис. 3 представлена теплова карта активаційного шару згорткової мережі, що отримана на одному із вихідних зображень. Ця карта візуалізує ті ознаки, на основі яких модель НМ прийняла позитивне рішення, тобто, визначила наявність дефекту на зображенні.

Висновки. Розроблене програмне забезпечення дозволяє вирішити завдання виявлення зовнішніх дефектів бетонних конструкцій, зокрема стін. Причому його можна застосувати як для аналізу окремих зображень, так і відео. Це рішення може бути корисним для моніторингу об'єктів інфраструктури у режимі реального часу з метою проведення своєчасного ремонту.

На даний момент система не проводить класифікацію дефектів за типами, а тільки виконує бінарну класифікацію, тобто фіксує наявність певної неоднорідної області на зображенні. Внаслідок цього, наприклад, як неоднорідність може бути визначене листя дерев на фоні стіни, написи на стіні тощо. Це можна віднести до недоліків, оскільки наразі система не є гнучкою. Проте, як було показано в основній частині статті, застосування НМ до зображень із бетонними конструкціями (стінами), за умови, що вони містять тільки стіну та неоднорідності

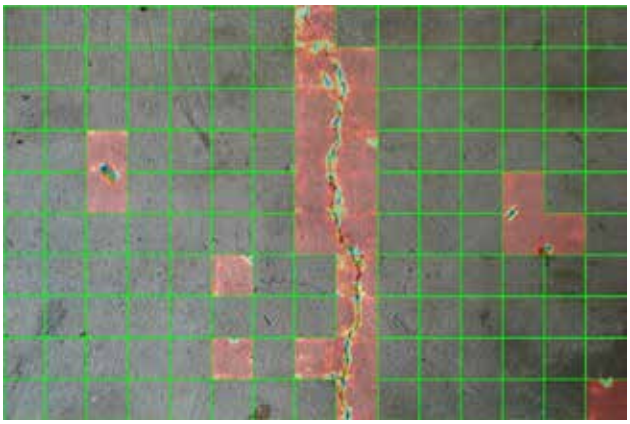

Рис. 3. Бінарна класифікація повного зображення з розбиттям на фрагменти розмірами 256x256 пікселів

у вигляді сколів і тріщини, дає дуже високу ймовірність виявлення. Для того, щоб зробити систему більш гнучкою, необхідно перейти від бінарної до мультикласової моделі згорткової мережі.

Робота має кілька напрямків для продовження. По-перше, необхідно розробити метод сегментації, який допоможе, крім виявлення дефекту, ще й відстежувати його зміни та параметри. По-друге, окрім виявлення, необхідно реалізувати можливість визначення ступеню ризику, що обумовлена тим чи іншим видом дефектів, а також придатність до подальшої експлуатації. По-третє, існуючі набори даних (dataset) замалі для адекватного тестування розробленої моделі НМ, тому для досягнення повністю робочого стану системи потрібно провести збір та обробку багаторазово більшого обсягу даних із різними варіаціями.

Список літератури:

1. Wilson R. L. da Silva and Diogo S. de Lucena. Concrete Cracks Detection Based on Deep Learning Image Classification. *International Conference on Experimental Mechanics (ICEM18)*. 2018. 2(8). 489. URL: https://doi.org/10.3390/ICEM18-05387

2. 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). P. 725-738. URL: https://doi.org/10.1177/1475921718768747

3. Liang Yang, Bing Li, Wei Li, Zhaoming Liu, Guoyong Yang and Jizhong Xiao. Deep Concrete Inspection Using Unmanned Aerial Vehicle Towards CSSC Database. *International Conference on Intelligent Robots and Systems (IROS)*. 2017. URL: https://ericlyang.github.io/img/IROS2017/IROS2017.pdf

4. Martin Mundt, Sagnik Majumder, Sreenivas Murali, Panagiotis Panetsos, Visvanathan Ramesh. Meta-learning Convolutional Neural Architectures for Multi-target Concrete Defect Classification with the COncrete DEfect BRidge IMage Dataset. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2019. URL: https://doi.org/10.48550/arXiv.1904.08486

5. CODEBRIM: COncrete DEfect BRidge IMage Dataset. URL: https://doi.org/10.5281/zenodo.2620293

6. Saad A., Tareq A. M., Saad A.-Z. Understanding of a convolutional neural network. *International Conference on Engineering and Technology (ICET)*. 2017. URL: https://doi.org/10.1109/ICEngTechnol.2017.8308186

7. Karen Simonyan and Andrew Zisserman. Very Deep Convolutional Networks for Large-Scale Image Recognition. URL: https://doi.org/10.48550/arXiv.1409.1556

8. Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton. ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems 25 (NIPS 2012)*. 2012. URL: https://papers.nips.cc/paper/2012/hash/c399862d3b9d6b76c8436e924a68c45b-Abstract.html

9. ImageNet database. URL: https://www.image-net.org/

10. Ramprasaath R. Selvaraju, Michael Cogswell et al. Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization. *International Conference on Computer Vision (ICCV'17)*. 2017. URL: https://doi.org/10.48550/arXiv.1610.02391

Galagan R.M., Andreiev S.M., Petryk V.F., Bazhenov V.G., Lysenko L.L.

DETECTION OF DEFECTS IN CONCRETE STRUCTURES BASED ON IMAGE ANALYSIS USING CONVOLUTIONAL NEURAL NETWORKS

Timely detection of external defects of concrete structures (in particular, concrete walls, concrete bridge supports) is an urgent task, as their uncontrolled development can lead to destruction. Today, the main approach to assessing the external condition of concrete structures is visual inspection or human analysis of photographs, which introduces a subjective factor and does not allow for automated analysis and decision-making. One of the ways to automate the process of defect detection and analysis is the use of neural network technologies.

This paper describes the structure of the software used for automated defect detection in images of concrete structures. Software consists of three modules: an image preprocessing module, a classification module, and an automatic analysis and visualization module. Due to its modularity, the software is easy to maintain, expand, and introduce new functionality.

It is proposed to use the VGG16 convolutional neural network, which allows to achieve greater accuracy on a smaller amount of data compared to similar implementations. It is shown that the VGG16 network in the Transfer Learning mode is the most optimal for solving the tasks. The neural network model used is configured to perform binary classification (defective and defect-free area). However, it has the potential for expansion and the ability to perform classification by different types of defects. The developed software was applied to a set of images of CODEBRIM concrete elements of bridge structures, to which were also added own images taken with a digital camera in daylight. After training, the network made it possible to detect defects such as cracks and chips with a precision of 96.3%.

Key words: *concrete structure, concrete defect, image analysis, neural network, VGG16.*