

О. С. КРАВЧЕНКО

ВИЯВЛЕННЯ ТА КЛАСИФІКАЦІЯ СУБМІКРОННИХ ДЕФЕКТІВ ПОВЕРХНІ ЗА ЇХ ІНТЕРФЕРЕНЦІЙНИМИ ЗОБРАЖЕННЯМИ ЗА ДОПОМОГОЮ ГЛИБОКОГО НАВЧАННЯ

Розроблено автоматизований метод виявлення та класифікації субмікронних дефектів поверхні дзеркал для високоточних оптичних систем на основі аналізу інтерференційних зображень із застосуванням глибокого навчання. Запропонований підхід замінює ручний аналіз нейромережею, що забезпечує швидшу й об'єктивнішу діагностику дефектів, усуваючи вплив людського фактора та прискорюючи контроль якості в умовах серійного виробництва оптичних компонентів. Для навчання моделі створено синтетичну вибірку інтерференційних зображень, яка моделює дефекти типу подряпин на дзеркальній поверхні за допомогою спеціального програмного забезпечення, заснованого на фізичній моделі інтерферометра Лінника. Вибірка охоплює три класи поверхонь: плоскі, з однією подряпиною та з численними подряпинами. Нейромережа побудована на базі MobileNetV2 із попереднім навчанням на ImageNet, із подальшим тонким налаштуванням останніх блоків для адаптації до специфіки задачі. До архітектури включено шари GlobalAveragePooling2D для стискання ознак, Dense із функцією активації ReLU та нормалізацією BatchNormalization, Dropout для запобігання перенавчання й вихідний шар із Softmax для класифікації трьох класів. Застосовано аугментацію даних і техніку soft voting для підвищення узагальнювальної здатності моделі. Точність класифікації оцінено за метрикою assiguasu: на синтетичних даних валідаційної вибірки вона становить 96%, на реальних зображеннях, отриманих із інтерферометра Лінника, — 82,7%. Найвища точність спостерігається для плоских поверхонь, найнижча — для численних подряпин, що відображає складність реальних умов через шуми та артефакти. Метод демонструє практичну цінність для автоматизації діагностики, а перспективи вдосконалення пов'язані з підвищенням реалістичності синтетичних даних шляхом додавання змодельованих шумів і адаптацією моделі до інших типів дефектів, таких як вм'ятини чи виступи, що розширить його застосовність у виробництві оптичних систем.

Ключові слова: субмікронні дефекти, інтерференційні зображення, глибоке навчання, нейромережа, MobileNetV2, класифікація.

О. KRAVCHENKO

DETECTION AND CLASSIFICATION OF SUBMICRON SURFACE DEFECTS BASED ON THEIR INTERFERENCE IMAGES USING DEEP LEARNING

An automated method for detecting and classifying submicron surface defects on mirrors used in high-precision optical systems has been developed, utilizing interferometric image analysis and deep learning. This approach replaces manual inspection with a neural network, delivering faster and more objective defect diagnostics, eliminating human bias, and accelerating quality control in serial production of optical components. A synthetic dataset of interferometric images was generated to train the model, simulating scratch-type defects on mirror surfaces through specialized software based on the Linnik interferometer model. The dataset encompasses three surface classes: flat surfaces, single scratches, and multiple scratches. The neural network is built upon MobileNetV2, pre-trained on ImageNet, with fine-tuning of its final blocks to adapt to the task's specifics. The architecture incorporates GlobalAveragePooling2D for feature compression, Dense layers with ReLU activation and BatchNormalization, Dropout to mitigate overfitting, and a Softmax output layer for classifying the three categories. Data augmentation and soft voting techniques were employed to enhance the model's generalization ability. Classification accuracy, assessed using the accuracy metric, achieves 96% on the synthetic validation set and 82.7% on real images acquired from a Linnik interferometer. The highest accuracy is observed for flat surfaces, while the lowest occurs for multiple scratches, highlighting challenges posed by real-world conditions such as noise and artifacts. The method proves its practical value for automated diagnostics, with future enhancements tied to improving synthetic data realism—potentially by incorporating modeled noise—and extending the model's adaptability to additional defect types like indentations or protrusions, thereby broadening its applicability in optical system manufacturing.

Keywords: submicron defects, interferometric images, deep learning, neural network, MobileNetV2, classification.

1. Вступ. Сучасні прецизійні оптичні системи, такі як телескопи, лазерні установки чи інтерферометри, значною мірою залежать від високоточних дзеркал. Ці елементи відіграють ключову роль у забезпеченні точності вимірювань, ефективності передачі світла та надійності роботи приладів. Проте навіть незначні вади на їхній поверхні, зокрема субмікронні подряпини чи вм'ятини, здатні суттєво вплинути на функціонування системи. Такі дефекти спотворюють оптичні сигнали, спричиняють локальні перегріву через концентрацію енергії та, як наслідок, скорочують термін служби дорогих компонентів.

До дзеркал у таких системах висуваються надзвичайно високі вимоги. Поверхня має не лише ідеально відповідати заданій геометрії, а й бути вільною від дефектів на мікро- та нанометровому рівні. Наприклад, у лазерних системах подряпина глибиною в десятки нанометрів може спричинити розсіювання світла, знижуючи інтенсивність корисного сигналу. В інтерферометрах подібні

дефекти порушують фазову когерентність, що унеможливує точні вимірювання. Таким чином, контроль якості поверхні є однією з пріоритетних задач у виробництві оптичних компонентів, а пошук ефективних методів діагностики залишається актуальною проблемою сучасної оптики [1].

Для виявлення дефектів поверхні розроблено численні підходи, серед яких особливе місце посідають оптичні методи, оскільки вони забезпечують високу чутливість до субмікронних нерівностей та не потребують прямого контакту з поверхнею. Однією із найпоширеніших є методика інтерференційної діагностики, зокрема із застосуванням інтерферометра Лінника [2]. Цей метод дає змогу візуалізувати нерівності поверхні через інтерференційні картини (ІК) — смуги, форма та розташування яких залежать від рельєфу досліджуваного об'єкта. Завдяки високій чутливості до перепадів висот у нанометровому діапазоні інтерферометрію вважають стандартом для контролю якості дзеркал у високоточних системах.

© О. С. Кравченко, 2024

Утім, традиційний підхід до аналізу інтерференційних зображень має суттєві обмеження. Зазвичай його виконують вручну: оператор вивчає отримані картини, визначає наявність дефектів і класифікує їх. Такий процес потребує значних затрат часу та значною мірою залежить від кваліфікації фахівця. Один і той самий дефект може бути інтерпретований по-різному залежно від досвіду чи навіть втоми людини. До того ж, за великої кількості зразків, що перевіряються, імовірність помилок зростає, що знижує об'єктивність і відтворюваність результатів. Ці недоліки підкреслюють потребу в автоматизації діагностики, яка здатна усунути людський фактор і прискорити процес контролю.

У цій роботі поставлено завдання розробити автоматизований метод виявлення та класифікації субмікронних дефектів поверхні на основі аналізу інтерференційних зображень із застосуванням глибокого навчання. Передбачається, що ручну працю буде замінено нейромережею, яка швидко й точно визначатиме типи дефектів — від плоских поверхонь до складних структур із численними подряпинами. Такий підхід спрямований на підвищення швидкості діагностики та забезпечення її об'єктивності, що особливо важливо для серійного виробництва оптичних компонентів.

Новизна дослідження полягає у двох ключових аспектах. По-перше, створено синтетичну вибірку інтерференційних зображень, які моделюють дефекти дзеркальних поверхонь, що дало змогу провести навчання нейромережі без необхідності залучення великого масиву реальних даних. По-друге, розроблено та випробувано нейромережевий підхід, адаптований до специфіки ІК, що вирізняє цю роботу серед традиційних методів аналізу зображень. Ці кроки відкривають нові можливості для автоматизації контролю якості та можуть стати основою для подальших досліджень у галузі оптичної дефектоскопії [3].

2. Методика

2.1. Генерація синтетичної вибірки. Одним із ключових завдань дослідження було створення синтетичної вибірки, яка забезпечує навчання нейромережі без потреби залучення тисяч реальних інтерференційних зображень. Для цього розроблено програмне забезпечення, здатне моделювати дефекти на дзеркальній поверхні та генерувати відповідні ІК. Детальний опис алгоритму виходить за межі цієї статті й буде подано в наступних публікаціях, однак основні принципи роботи програмного забезпечення коротко викладено нижче.

Процес розпочинається з формування рельєфу поверхні у вигляді карти висот у форматі .csv — квадратної матриці розміром 3000×3000 , де кожне значення відповідає висоті (координаті z) у точці з координатами (x, y) . Ця карта відображає рельєф поверхні з урахуванням заданих дефектів, таких як подряпини. Далі карта висот перетворюється на інтерференційне зображення (рис. 1) на основі фізичної моделі інтерферометра Лінника [4]. Такий

підхід дає змогу гнучко варіювати параметри й отримувати дані, максимально наближені до реальних.

Особливу увагу приділено моделюванню подряпин як найпоширеніших дефектів. Їхні характеристики визначено так: довжина варіюється від 30 до 300 мкм, ширина — від 1 до 7 мкм, глибина — від 100 до 300 нм. Крім того, профіль подряпини вздовж довжини може змінюватися, що додає різноманітності до вибірки. Параметри ІК також не є сталими: регулюються ширина й нахил смуг, а також контрастність, щоб урахувати можливі варіації умов роботи інтерферометра.

Вибірка охоплює три класи поверхонь:

- плоска поверхня (plain_surface) — ідеальний випадок без дефектів.
- поверхня з однією подряпиною (single_scratch) — одиничний дефект.
- поверхня з численними подряпинами (multi_scratch) — від 2 до 7 подряпин на зображенні.




Рис. 1. Приклад 3D зображення синтетичної карти висот і інтерференційної картини для поверхні з однією подряпиною

Для кожного класу сформовано по 3000 зображень, що загалом становить 9000 прикладів для навчання [5]. Такий обсяг і різноманітність забезпечують надійну базу для підготовки нейромережі.

2.2. Архітектура нейромережі. Нейромережа приймає на вхід RGB-зображення розміром 3000×3000 пікселів, що відповідає роздільній здатності синтетичних ІК. Як базову модель обрано MobileNetV2 — легку й ефективну мережу, попередньо навчену на ImageNet [3]. Її використано з параметром `include_top=False`, щоб адаптувати вихідний шар до конкретної задачі, зберігши при цьому потужні можливості вилучення ознак.

Архітектуру побудовано наступним чином (рис. 2): початкові шари MobileNetV2 заморожені, щоб зберегти загальні знання, отримані на ImageNet, тоді як останні 2–3 блоки піддано тонкому налаштуванню (fine-tuning) із низьким значенням швидкості навчання та розкладом cosine annealing для поступової адаптації до даних [6]. Після цього застосовано шар GlobalAveragePooling2D, який стискає просторові ознаки у компактний вектор. Далі використано Dense-шар із 128 нейронами та активацією ReLU, доповнений BatchNormalization для стабілізації навчання й L2-регуляризацією (коефіцієнт 0.0001) для контролю wag. Щоб запобігти перенавчанню, додано Dropout із ймовірністю 0.5.

Нарешті, вихідний Dense-шар із 3 нейронами активацією softmax видає ймовірності належності (plain_surface, single_scratch, multi_scratch) і зображення до кожного класу [7].




Рис. 2. Схема архітектури нейромережі для класифікації інтерференційних зображень

Для підвищення стійкості моделі застосовано аугментацію через ImageDataGenerator: обертання, зсуви, масштабування та горизонтальне відображення. Додатково впроваджено вдосконалення: техніка soft voting узагальнює передбачення за кількома аугментованими версіями одного зображення, а функція втрат categorical cross-entropy із label smoothing (коефіцієнт 0.1) пом'якшує надмірну впевненість моделі, покращуючи узагальнення.

2.3. Навчання та верифікація. Синтетичну вибірку з 9000 зображень було поділено у співвідношенні 80% на навчання (7200) і 20% на валідацію (1800), щоб відстежувати прогрес моделі [8]. Для тестування підготовлено набір реальних даних, отриманий із допомогою інтерферометра Лінника: 300 зображень (по 100 на клас). Це дало змогу оцінити ефективність моделі як на "знайомих" даних, так і в умовах реальної діагностики.

Для оцінки якості класифікації було використано метрику accuracy, яка обчислюється за формулою:

$$\text{Accuracy} = \text{TC}/\text{N}, \quad (1)$$

де TC – кількість правильно класифікованих прикладів; N – загальна кількість прикладів.

Ця метрика відображає частку правильно класифікованих зображень у загальній кількості зображень, що відповідає її стандартному визначенню в задачах класифікації. Вона є простою для інтерпретації та добре підходить для цієї задачі завдяки збалансованості класів за кількістю прикладів. Показник зручно використовувати для порівняння результатів на різних наборах даних [9].

3. Результати

3.1. Приклади інтерференційних зображень. На початковому етапі оцінки методу проведено аналіз візуальних характеристик синтетичних інтерференційних зображень, які використано для навчання та тестування нейромережі. Визначено три основні класи поверхонь: плоска поверхня (plain_surface), поверхня з однією подряпиною (single_scratch) і поверхня з численними подряпинами (multi_scratch). Для кожного класу підготовлено типові приклади, щоб продемонструвати, як дефекти виявляються в інтерференційних картинах.

На рис. 3(а) зображено плоску поверхню: рівномірні інтерференційні смуги без викривлень свідчать про відсутність дефектів. Рис. 3(б) ілюструє випадок з однією подряпиною — смуги деформуються в зоні дефекту, утворюючи характерний злам, помітний навіть без спеціальних засобів. На рис. 3(в)

показано поверхню з декількома подряпинами. Ці візуальні особливості слугують основою для розпізнавання нейромережею, яка здатна ефективно ідентифікувати такі відмінності.

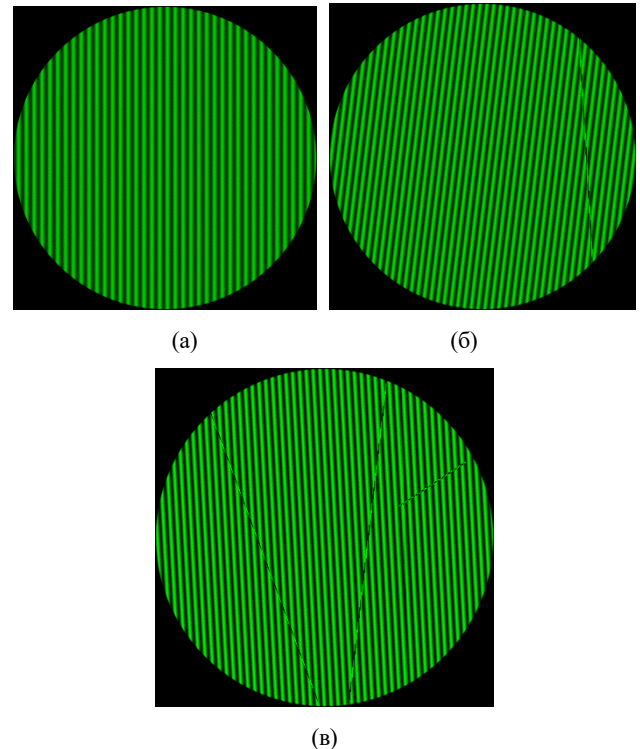


Рис. 3. Синтетичне інтерференційне зображення плоскої поверхні (plain_surface) (а), поверхні з однією подряпиною (single_scratch) (б), поверхні з численними подряпинами (multi_scratch) (в)

3.2. Точність класифікації. Кількісну оцінку роботи нейромережі проведено на двох тестових наборах: синтетичному та реальному. Синтетичну вибірку з 9000 зображень поділено на 80% для навчання (7200) і 20% для валідації (1800), і саме ці 1800 зображень (по 600 на клас) використано для оцінки точності на синтетичних даних. Результат становить 96%, що вказує на високу ефективність моделі в умовах, де зображення відповідають навчальній вибірці. На реальних даних, отриманих з інтерферометра Лінника (300 зображень, по 100 на клас), точність досягає 82,7%. Зниження точності на реальних зображеннях є передбачуваним через додаткові ускладнення, пов'язані з реальними умовами вимірювань.

Детальні показники точності для кожного класу наведено в табл. 1, з якої видно, що на синтетичних зображеннях модель демонструє стабільно високі

результати (95-97%), але на реальних даних розбіжність більша (77-88%). Такі дані свідчать, що складні дефекти (multi_scratch) є найскладнішими для класифікації в реальних умовах, ймовірно, через більшу кількість випадкових викривлень.

Таблиця 1 – Точність класифікації (accuracy) для синтетичних (валідація) і реальних інтерференційних зображень

Клас	Синтетичні дані (валідація), %	Реальні дані, %
Plain_surface	97	88
Single_scratch	96	83
Multi_scratch	95	77
Середнє	96	82,7

4. Обговорення

4.1. Аналіз результатів. Отримані результати свідчать про ефективність розробленого підходу: точність класифікації на синтетичних даних валідаційної вибірки (1800 зображень) становить 96% [10]. Цей показник підтверджує, що модель успішно виявляє та класифікує субмікронні дефекти, а синтетична вибірка достовірно відображає ключові особливості інтерференційних зображень. Такий високий рівень точності вказує на злагоджену роботу програмного забезпечення для генерації даних і архітектури нейромережі, що дає змогу чітко розрізняти плоскі поверхні, одиничні подряпини та складні випадки з численними подряпинами.

На реальних даних, отриманих з інтерферометра Лінника (300 зображень), точність знижується до 82,7%. Це зниження не є несподіваним. Реальні ІК містять додаткові ускладнення: шуми від обладнання, неоднорідність освітлення, дрібні артефакти, які важко врахувати в синтетичній моделі. Водночас показник 82,7% визнано досить переконливим, особливо з огляду на те, що навчання проводилося виключно на синтетичних даних. Це свідчить про задовільну узагальнювальну здатність моделі, хоча простір для вдосконалення зберігається.

Переваги запропонованого підходу очевидні. Процес аналізу повністю автоматизовано, що усуває залежність від людського фактора — суб'єктивні оцінки та трудомісткий ручний аналіз замінено об'єктивним машинним обробленням. Нейромережа забезпечує високу швидкість обробки зображень, що робить метод придатним для контролю якості в серійному виробництві оптичних компонентів. Завдяки аугментації даних і техніці soft voting модель виявляє стійкість до варіацій вхідних зображень, що має особливе значення для роботи в реальних умовах.

4.2. Обмеження та шляхи вдосконалення. Незважаючи на досягнуті результати, підхід має певні обмеження. Основним із них визнано розбіжності між синтетичними та реальними зображеннями, які впливають на точність класифікації. Синтетична вибірка, хоч і ретельно розроблена, не повною мірою відтворює специфіку реальних умов: шуми

обладнання, випадкові викривлення чи зміни контрастності, характерні для практичних вимірювань. Це пояснює зниження точності на реальних даних і визначає напрям для подальшого вдосконалення. Підвищення реалістичності синтетичних зображень, наприклад, шляхом додавання змодельованих шумів або випадкових артефактів, може зменшити розрив між двома наборами даних ("sim-to-real gap") [12].

Ще одна перспективна можливість пов'язана з розширенням сфери застосування методу. У поточному дослідженні основну увагу приділено подряпинам як найпоширенішим дефектам, однак дзеркальні поверхні можуть мати й інші вади: вм'ятини, виступи або комбінації різних типів дефектів. Архітектура нейромережі та підхід до генерації даних мають потенціал для адаптації до таких випадків. Додавання нових класів до синтетичної вибірки та незначна модифікація вихідного шару можуть перетворити модель на універсальний інструмент для діагностики різноманітних дефектів.

Ці обмеження розглядаються не як недоліки, а як можливості для розвитку. Запропонований метод уже зараз демонструє практичну цінність, а подальше вдосконалення синтетичних даних і налаштування моделі здатне підвищити його точність і універсальність [13].

5. Висновки. В роботі розроблено автоматизований метод класифікації субмікронних дефектів дзеркальних поверхонь на основі синтетичних інтерференційних зображень і глибокого навчання. Створено інструмент, який замінює ручний аналіз нейромережею, здатною швидко й об'єктивно визначати типи дефектів. Цей підхід усуває потребу в трудомістких процесах і забезпечує стабільність результатів.

Точність класифікації оцінено на двох наборах даних: на синтетичних зображеннях валідаційної вибірки (1800 прикладів) вона становить 96%, а на реальних даних, отриманих з інтерферометра Лінника (300 зображень), — 82,7%. Ці показники свідчать про високу ефективність моделі та якість синтетичної вибірки, а також про її здатність адаптуватися до реальних умов, попри певне зниження точності.

Запропонований метод відкриває перспективи для впровадження в виробництво високоточних оптичних систем, де контроль якості поверхні має вирішальне значення. Подальше вдосконалення синтетичної вибірки, зокрема підвищення її реалістичності, а також оптимізація архітектури нейромережі можуть додатково підвищити точність на реальних даних. Розроблений підхід не лише вирішує поточну задачу, а й створює основу для майбутніх досліджень і вдосконалень у галузі оптичної дефектоскопії [14].

Список літератури

- Goodfellow I., Bengio Y., Courville A. *Deep learning*. Cambridge: MIT Press, 2017. 800 p.

2. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional networks for biomedical image segmentation // *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015: 18th International Conference, Munich, Germany, October 5–9, 2015, Proceedings, Part III*. 2015. P. 234–241. https://doi.org/10.1007/978-3-319-24574-4_28
3. Howard A. G., Zhu M., Chen B., Kalenichenko D., Wang W., Weyand T., Andreetto M., Adam H. MobileNets: Efficient convolutional neural networks for mobile vision applications // arXiv preprint arXiv: 1704.04861. 2017. 9 p. <https://doi.org/10.48550/arXiv.1704.04861>
4. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition // *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, June 27–30, 2016. P. 770–778. <https://doi.org/10.1109/CVPR.2016.90>
5. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet classification with deep convolutional neural networks // *Communications of the ACM*. 2017. Vol. 60, No. 6. P. 84–90. <https://doi.org/10.1145/3065386>
6. Dosovitskiy A., Beyer L., Kolesnikov A. et al. An image is worth 16x16 words: Transformers for image recognition at scale // *International Conference on Learning Representations (ICLR) 2021*. 2021. 22 p. <https://doi.org/10.48550/arXiv.2010.11929>
7. Szegedy C., Vanhoucke V., Ioffe S. et al. Rethinking the inception architecture for computer vision // *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, June 27–30, 2016. P. 2818–2826. <https://doi.org/10.1109/CVPR.2016.308>
8. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition // *International Conference on Learning Representations (ICLR) 2015*. 2015. 14 p. <https://doi.org/10.48550/arXiv.1409.1556>
9. Chen L.-C., Papandreou G., Kokkinos I., Murphy K., Yuille A. L. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2018. Vol. 40, No. 4. P. 834–848. <https://doi.org/10.1109/TPAMI.2017.2699184>
10. Wang Z., Bovik A. C., Sheikh H. R., Simoncelli E. P. Image quality assessment: From error visibility to structural similarity // *IEEE Transactions on Image Processing*. 2004. Vol. 13, No. 4. P. 600–612. <https://doi.org/10.1109/TIP.2003.819861>
11. Daghigh V., Daghigh H., Lacy T. E., Naraghi M. Review of machine learning applications for defect detection in composite materials // *Machine Learning with Applications*. 2024. Vol. 18. P. 100600 (18 pages). <https://doi.org/10.1016/j.mlwa.2024.100600>
12. P. Trentsios, M. Wolf, D. Gerhard. Overcoming the Sim-to-Real Gap in Autonomous Robots // *Procedia CIRP*. 2022. Vol. 109. P. 287 - 292. <https://doi.org/10.1016/j.procir.2022.05.251>
13. Goodfellow I., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Courville A., Bengio Y. Generative adversarial nets // *Advances in Neural Information Processing Systems 27 (NIPS 2014)*. 2014. P. 2672–2680. <https://doi.org/10.48550/arXiv.1406.2661>
14. Russakovsky O., Deng J., Su H. et al. ImageNet large scale visual recognition challenge // *International Journal of Computer Vision*. 2015. Vol. 115, No. 3. P. 211–252. <https://doi.org/10.1007/s11263-015-0816-y>
15. Kingma D. P., Ba J. Adam: A method for stochastic optimization // *International Conference on Learning Representations (ICLR) 2015*. 2015. 15 p. <https://doi.org/10.48550/arXiv.1412.6980>

Надійшла (received) 05.11.2024

Відомості про авторів / Сведения об авторах / About the Authors

Кравченко Олександр Сергійович (Oleksandr Kravchenko) – аспірант кафедри комп’ютерної математики і аналізу даних, Національний технічний університет “Харківський політехнічний інститут”, Харків, Україна; e-mail: Oleksandr.Kravchenko@cs.khpi.edu.ua; ORCID: <https://orcid.org/0000-0002-6169-1250>.