

**МЕТОД СЕГМЕНТАЦІЇ МЕТАЛОГРАФІЧНИХ ЗОБРАЖЕНЬ З
ВИКОРИСТАННЯМ НЕЙРОННОЇ МЕРЕЖІ U-NET**

Д. Р. Горпенко, Д. М. Кривенко

Національний університет «Одеська політехніка»
1, Шевченко пр., Одеса, 65044, Україна
Emails: horpenko@op.edu.ua, d.krivenko.ilc@gmail.com

У роботі розглянуто завдання сегментації металографічних зображень. Проведено аналіз методів сегментації з використанням нейронних мереж. Запропоновано метод сегментації металографічних зображень з використанням нейронної мережі U-NET, яка демонструє високу якість сегментації навіть за обмеженого розміру навчальної вибірки. Основними процедурами запропонованого методу є попередня обробка, аугментація даних та класифікація об'єктів. Розроблений метод сегментації апробовано на типових металографічних зображеннях. Проведено порівняння результатів сегментації металографічних зображень запропонованим методом та методом вододілів. Оцінку якості сегментації виконано з використанням метрик точності (Accuracy, Precision), повноти (Recall), F-міри та матриці неточностей. На основі експериментальних досліджень визначено, що навчання нейронної мережі U-NET протягом однієї епохи з 500 ітераціями дозволяє отримати найкращі показники якості сегментації, а саме: точність (Accuracy) - 0.91, точність (Precision) - 0.82, повнота (Recall) - 0.87, F-міра - 0.85 при достатній оперативності. Метод вододілів забезпечує високу оперативність, однак якість сегментації виявилась нижчою. Таким чином, запропонований в роботі метод є ефективним для задач сегментації металографічних зображень, які потребують високої якості сегментації.

Ключові слова: сегментація; аугментація; нейронна мережа U-NET; метод вододілів, матриця неточностей

Вступ. Контроль якості продукції дозволяє виявити дефекти продукції на ранніх стадіях виробництва та запобігти випуску бракованих виробів з металу. Для проведення контролю якості виробів з металу проводять металографічні дослідження для чого підготовлюють мікрошліфи [1, 2] за допомогою спеціального обладнання [3]. Завдання сегментації металографічних зображень є одним із важливих етапів цифрової обробки зображень в автоматизованих системах контролю якості продукції, що базується на аналізі зображень мікрошліфів цієї продукції [4]. На сьогоднішній день для сегментації зображень не існує загальних методів сегментації, які вирішували б завдання з різних прикладних областей. В [5] автори зазначають, що методи, які застосовують для сегментації металографічних зображень можна розбити на дві групи: методи на основі інтенсивності пікселів або геометричних властивостей форми та методи, засновані на навчанні. До методів першої групи відносяться порогові методи, методи на основі активних контурів. До методів другої групи відносяться методи машинного навчання, які діляться на методи навчання: без вчителя (методи кластеризації, наприклад, метод k -середніх, Principal Component Analysis (PCA)) [6]; з вчителем (методи класифікації, наприклад, нейронні мережі, Support Vector Machine (SVM)) [7]; напівкероване навчання [8]. На сьогоднішній день для сегментації зображень мікрошліфів широко використовують методи із застосуванням нейронних мереж, що забезпечує високу якість сегментації і можуть бути використані в автоматизованих системах контролю якості виробів з металу. Проте використання методів із застосуванням нейронних мереж для сегментації зображень мікрошліфів вимагає значних обчислювальних ресурсів та часу на навчання моделей, що може бути обмеженням для деяких систем, а також вимагає наявності достатнього обсягу

кількості навчальної вибірки. Тому розробка нових методів сегментації, що дозволяють покращити якість сегментації при достатній оперативності та невеликій кількості навчальних даних, є актуальним завданням.

Аналіз літературних джерел та постановка проблеми. Завдання сегментації [9] полягає в розбитті зображення на однорідні за деякою ознакою області. Такими ознаками можуть бути колір, текстура, контури [10]. При використанні методів сегментації зображення в автоматичному режимі можливі такі помилки сегментації зображень: неправильне сегментування - розбіжність контурів сегментованих областей з межами об'єктів на зображенні; пересегментування – збільшення кількості сегментованих областей на зображенні; недосегментування – недостатня кількість сегментованих областей на зображенні. Вибір методу сегментації з урахуванням особливостей зображень – це один із способів зниження помилок при сегментуванні однорідних областей зображення. В результаті застосування методів сегментації одержують безліч однорідних за своєю текстурою областей або безліч контурів. Для різних прикладних завдань розробляються різні методи сегментації, що враховують характеристики об'єктів на зображеннях, що обробляються.

Вище було зазначено, що для сегментації металографічних зображень застосовують методи з допомогою нейронних мереж. Так у роботі [11] використовуються нейронні мережі MLP (Multi Layer Perceptron) та RBF (radial basis function). Складність використання нейронної мережі MLP полягає в тому, що для кожного конкретного завдання необхідно будувати відповідну структуру мережі, що вимагає побудови та налаштування структури мережі. Нейронні мережі RBF забезпечують високу швидкість збіжності. На вхід мережі RBF подається певна кількість вхідних значень та генерується набір вихідних значень, які визначаються вхідними значеннями та набором параметрів, таких як центри мас, вагові значення та інтервали ширини. Основною складністю при роботі з мережами RBF є вибір цього набору параметрів для навчання мережі.

Останнім часом для вирішення задачі сегментації зображень застосовують згорткову нейронну мережу (CNN - convolutional neural network) [12-14], що забезпечують високу якість сегментації. Однак для якісного навчання мережі потрібна велика кількість зображень.

Тому в роботі пропонується для сегментації металографічних зображень використовувати нейронну мережу U-NET, яка відноситься до CNN. Нейронна мережа U-NET забезпечує високу якість сегментації, при цьому потрібна навчальна вибірка невеликого розміру [15, 16].

Основна частина. Етап сегментації в системах контролю якості продукції дозволяє на металографічних зображеннях виділити зони інтересу, за якими згодом можна виконати оцінку розміру зерна, для дослідження властивостей металу [17]. На рисунку 1 представлено зображення мікроструктури металу.




Рис. 1. Приклад зображення мікроструктури металу

Запропонований метод сегментації металографічних зображень з використанням згорткової нейронної мережі U-NET включає наступні етапи. підготовка навчальної вибірки; налаштування параметрів моделі (розріджена згортка, функція оптимізації

(SGD, Adam); навчання мережі; класифікація об'єктів на зображенні; морфологічна обробка; порогова обробка; оцінка якості сегментації.

Для отримання навченої нейронної мережі була підготовлена навчальна вибірка, що складається з вхідних зображень і масок, що їм відповідають. Маска є картою розмічених класів на навчальних зображеннях [18]. У [19] авторами було описано алгоритм процедури аугментації навчальної вибірки на навчання нейронної мережі U-NET, основними етапами якого є: розтягування і обрізання; поворот на кут 45, 90, 180, 270; зміна яскравості та контрастності; додавання адитивної та імпульсної перешкод.

Для створення масок була запропонована процедура, функціональна схема якої представлена на рисунку 2. На етапі попередньої обробки зменшується рівень адитивного та імпульсного шуму який з'являється на зображеннях мікроструктури сплаву під час отримання зображень. Для зменшення адитивної перешкоди використовувався фільтр Гауса. Для зменшення імпульсного шуму, який виникає під час квантування в процесі отримання цифрового зображення застосовано медіанний фільтр.

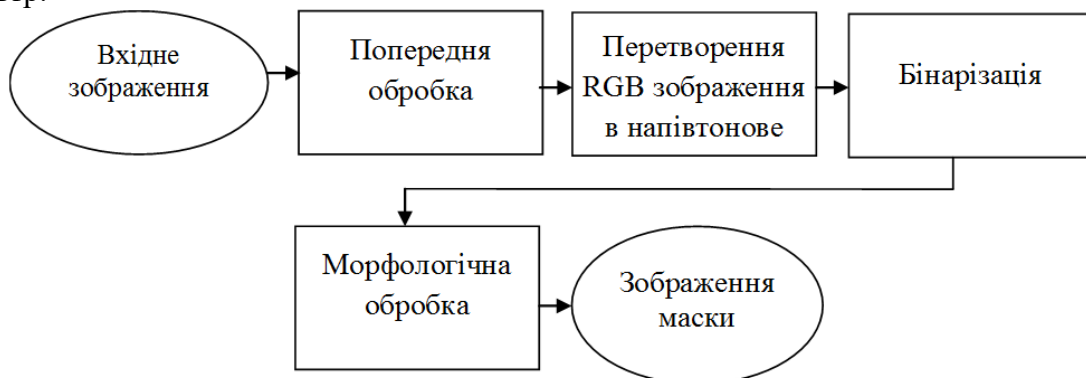


Рис. 2. Функціональна схема процедури створення масок

На етапі бінарізації до напівтонового зображення було застосовано метод Отсу [20]. Морфологічні операції (відкриття, закриття, дилатації, ерозії) [20] застосовувалися для усунення розривів контурів, заповнення областей, усунення дрібних плям на зображеннях після бінарізації.

Основним етапом запропонованого методу є класифікація об'єктів на зображенні за допомогою навченої нейронної мережі U-NET. Мережа U-NET має U-подібну архітектуру [21]. Обробка зображень цією мережею проходить два шляхи: шляху звуження і розширення. Звуження (зменшення розмірності зображення) є послідовним виконанням двох операцій згортки 3×3 до зображень з подальшим застосуванням функції активації ReLu (Rectified Linear Unit) [22]. Аналітичний вигляд функції активації ReLu наступний: $A(x) = \max(0, x)$, графік функції активації ReLu показано на рисунку 3.




Рис. 3. Графік функції активації ReLu

Застосування функції активації ReLU знижує витрати системних ресурсів та прискорює збіжність стохастичного градієнтного спуску. У результаті на вхід розширюючого шляху надходить інформація про властивості об'єктів, яка збільшується під час проходження через звужуючий шлях.

Обробка на розширюючому шляху полягає у застосуванні згортки 2x2 та об'єднанні з ознаками звужуючого шляху, що містять важливі розрізнявальні характеристики.

Експериментальне дослідження. Програмну реалізацію запропонованого методу сегментації металографічних зображень з використанням нейронної мережі U-NET виконано мовою Python.

Основними програмними модулями є: архітектура мережі (опис шарів); передобробка зображень; навчання мережі; класифікація; постобробка результатів класифікації.

При реалізації програмних модулів використовувалися бібліотеки:

Tkinter та matplotlib - для побудови інтерфейсу програмної реалізації;

Keras та TensorFlow - для побудова нейронної мережі U-NET.

На вхід розробленого програмного модуля надходили зображення мікроструктури металу (табл. 1). Зображення мікроструктури металу були отримані на спеціальному стенді під керівництвом проф. О. Г. Деревянченко.


Для зниження рівня адитивного та імпульсного шуму, присутнього на вхідних зображеннях, проводилася попередня обробка.

Фільтр Гауса застосовувався для зменшення адитивного шуму, а медіанний фільтр – для зниження імпульсних перешкод. Після цього виконувалося підсилення контрастності за допомогою еквалізації гистограми.

Вхідні зображення були програмно обрізані до розміру 512x512 пікселів для подачі на вхід мережі U-NET. Приклади тестових зображень наведено в таблиці 1.

Таблиця 1.

Приклади зображень тестової вибірки



Для порівняння результатів роботи нейронної мережі U-NET було проведено серію експериментів. Спочатку формувалася навчальна вибірка, після чого виконувалося навчання мережі за різної кількості епох та ітерацій.

Також було реалізовано метод вододілів [20] для сегментації зображень мікрошліфів.

Таким чином, було проведено:

Навчання мережі на 1 епосі та 50 ітераціях;

Навчання мережі на 1 епосі та 300 ітераціях;

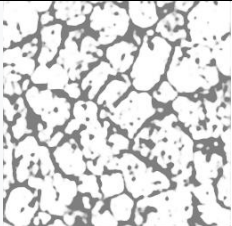
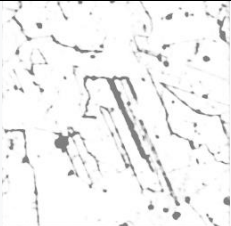

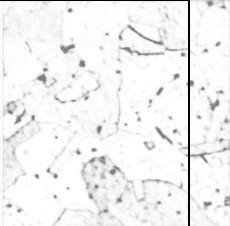
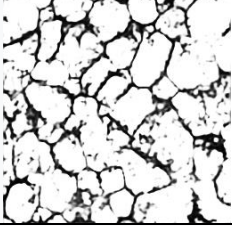
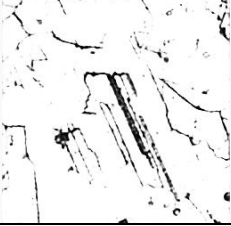

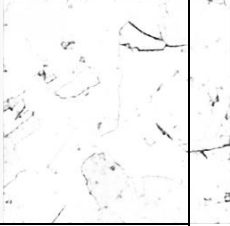
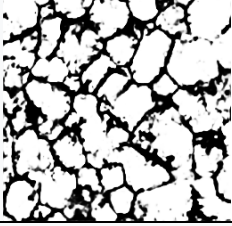

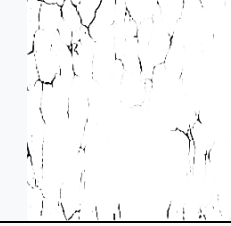
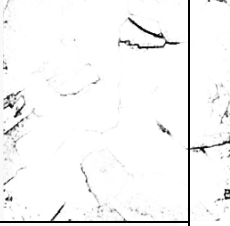
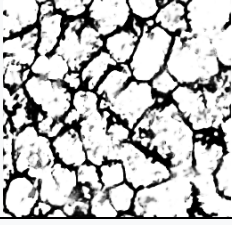
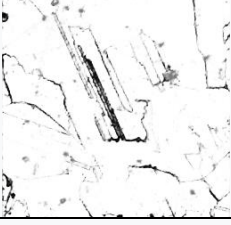
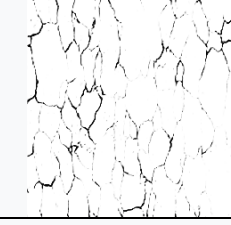
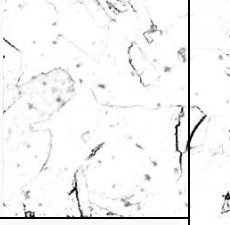
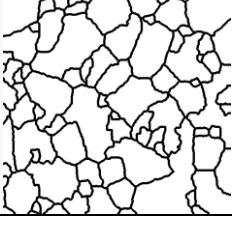
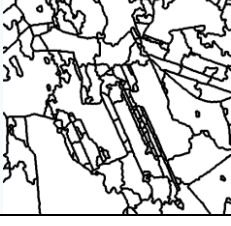
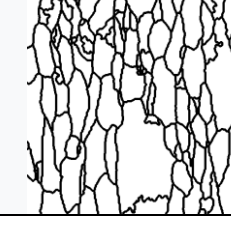

Навчання мережі на 1 епосі та 500 ітераціях;

Навчання мережі на 2 епохах за 300 ітераціями;

Сегментація методом вододілів [20] .

Результати роботи мережі після навчання з різною кількістю епох та ітерацій для зображень 1-4 з таблиці 1 представлені в таблиці 2.

Таблиця 2.

Результати тестування мережі			
навчання мережі на 1 епосі та 50 ітераціях			
			
навчання мережі на 1 епосі та 300 ітераціях			
			
навчання мережі на 1 епосі та 500 ітераціях			
			
навчання мережі на 2 епохах за 300 ітераціями			
			
сегментація методом вододілів			
			

Як видно з представлення результатів, при навчанні мережі на 1 епосі та 50 ітераціях мережа частково сегментувала зображення, при цьому час навчання було не великим, проте така кількість кроків була занадто малою для отримання хорошого результату сегментації.

При навчанні мережі на 1 епосі та 300 ітераціях якість сегментації значно покращилася завдяки збільшеній кількості кроків, при цьому час навчання збільшився.

При навчанні мережі на 1 епосі та 500 ітераціях якість сегментації покращилася, однак час навчання збільшився практично в два рази.

При навчанні мережі на 2 епохах та 300 ітераціях результат виявився близьким до результату при навчанні мережі на 1 епосі та 300 ітераціях.

Для оцінки якості сегментації зображення сегментовані за допомогою методу сегментації з використанням нейронної мережі U-NET при різній кількості епох та

ітерацій, а також методом вододілів, порівнювалися з еталонним зображенням, розміченим експертом (табл. 3).

Таблиця 3.

Порівняння результатів сегментації зображення, розміченого експертом із результатами експерименту

Зображення, розмічене експертом	Розмітка після навчання мережі на 1 епосі та 50 ітераціях	Розмітка після навчання мережі на 1 епосі та 300 ітераціях	Розмітка після навчання мережі на 1 епосі та 500 ітераціях	Розмітка після навчання мережі на 2 епохи за 300 ітераціями	Розмітка після методу вододілів
					

Оцінка якості сегментації зображень проводилася за допомогою матриці неточностей, елементами якої є величини помилок 1-го та 2-го роду (табл. 4) [9].

Таблиця 4.

Загальний вигляд матриці неточностей

Зображення, розмічене експертом	Розмітка зображення, отримана в результаті експерименту	
	Контур 1	Контур 2
Контур 1	TP (true positive)	FP (False positive)
Контур 2	FN (False negative)	TN (true negative)

Елементи матриці неточностей використовувалися для розрахунку оцінок якості сегментації: точності (Accuracy) (1), точності (Precision) (2), повноти (Recall) (3), F_1 -міри (4) [9]:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}, \quad (1)$$

$$P = \frac{TP}{TP + FP}, \quad (2)$$

$$R = \frac{TP}{TP + FN}, \quad (3)$$

$$F_1 = \frac{2 \cdot PR}{P + R}. \quad (4)$$

У задачі сегментації металографічних зображень помилка 1-го роду полягає у прийнятті неправильно класифікованого пікселя за правильний відгук, хоча нульова гіпотеза H_0 стверджує, що піксель на зображенні був класифікований правильно, але ця гіпотеза відкидається. Відповідно, помилка 2-го роду — це неправильно класифіковані пікселі, коли нульову гіпотезу приймають помилково.

У таблиці 5 представлені усереднені оцінки якості сегментації, розраховані для зображень, сегментованих за допомогою розробленого методу сегментації з використанням нейронної мережі U-NET за різної кількості епох та ітерацій, а також методом вододілів.

Таблиця 5.

Оцінки якості сегментації металографічних зображень

Показник якості	після навчання мережі на 1 епосі та 50 ітераціях	після навчання мережі на 1 епосі та 300 ітераціях	після навчання мережі на 1 епосі та 500 ітераціях	після навчання мережі на 2 епохи за 300 ітераціями	після методу вододілів
Accuracy	0,87	0,89	0,91	0,91	0,84
Precision	0,64	0,91	0,82	0,77	0,71
Recall	0,90	0,78	0,87	0,91	0,74
<i>F</i> -міра	0,75	0,84	0,85	0,83	0,72

Проведене експериментальне дослідження показало, що найкращі показники якості сегментації металографічних зображень були отримані при використанні запропонованого методу сегментації з використанням нейронної мережі U-NET, навчання якої проводилося на 1 епосі та 500 ітераціях.

Висновки. У роботі розроблено метод сегментації металографічних зображень із використанням нейронної мережі U-NET. Проведено дослідження якості сегментації зображень під час використання запропонованого методу сегментації з використанням нейронної мережі U-NET з різною кількістю епох та ітерацій, а також методом вододілів. Для збільшення обсягу навчальної вибірки в роботі було виконано процедуру аугментації даних, обсяг якої був збільшений у 10 разів. Крім того, був розроблений набір масок для кожного зображення з навчальної вибірки. Оцінка якості сегментації проводилася з використанням матриці неточності, на основі елементів якої були розраховані показники точності сегментації (Accuracy, Precision, Recall, *F* - міра). Порівняльний аналіз показав, що запропонований метод сегментації з використанням нейронної мережі U-NET, навчання якої проводилося на 1 епосі та 500 ітераціях забезпечило високу якість сегментації. Однак час навчання в цьому випадку зріс практично в 2 рази. Порівняно з методом вододілів, запропонований метод показав більше високу якість сегментації за всіма розглянутими показниками якості сегментації, що є більш пріоритетним, ніж швидкість обробки зображень.

Список літератури

1. Müller M., Stiefel M., Bachmann B.I., Britz D., Mücklich F. Overview: Machine Learning for Segmentation and Classification of Complex Steel Microstructures. *Metals*. 2024. V.14(5). P.553. URL: <https://doi.org/10.3390/met14050553>
2. Деревянченко А.Г. Некоторые результаты испытаний модуля программного комплекса для обработки изображений микроструктур материалов. *Новые и нетрадиционные технологии в энерго- и ресурсосбережении: материалы международной научно-технической конференции*. Одесса: ОНПУ, 2018. С. 44 – 47.
3. Schubert T., Schneider G., Ketzer-Raichle G., Bernthaler T. The Microstructural Development of Laser-Powder-Bed-Fusion Manufactured Tungsten Carbide–Cobalt Hard Metals. *Practical Metallography*. 2016. V.53(7). P.408-421. URL: <https://doi.org/10.3139/147.110410>
4. Волкова Н.П., Кривенко Д.М. Сегментація металографічних зображень із застосуванням U-NET мережі. *Project, Program, Portfolio Management: The Proceedings of the International Research Conference, 02 – 03 Desember, 2021, Odesa. Ukraine*, P. 123-125.
5. Luengo J., Moreno R., Sevillano I., Charte D., Pelaez-Vegas A., Fernandez-Moreno M., Herrera F. A tutorial on the segmentation of metallographic images: Taxonomy, new MetalDAM dataset, deep learning-based ensemble model, experimental analysis and

- challenges, *Information Fusion*. 2022. V. 78, P. 232-253. URL: <https://doi.org/10.1016/j.inffus.2021.09.018>
6. Kunselman C., Sheikh S., Mikkelsen M., Attari V., Arróyave R. Microstructure classification in the unsupervised context. *Acta Materialia*, 2022. V.223. P.117434. DOI:10.1016/j.actamat.2021.117434
 7. Gola J., Britz D., Staudt T., Winter M., Schneider A. S., Ludovici M, Mücklich F. Advanced microstructure classification by data mining methods. *Computational Materials Science*. 2018. V. 148. P. 324-335. URL: <https://doi.org/10.1016/j.commatsci.2018.03.004>
 8. Chen D., Sun D., Fu J., Liu S. Semi-supervised learning framework for aluminum alloy metallographic image segmentation. *IEEE Access*. 2021. No.9, P.30858-30867. DOI: 10.1109/ACCESS.2021.3059505.
 9. Krylov V.N., Volkova N.P. Vector-difference texture segmentation метод in technical and medical express diagnostic systems. *Herald of Advanced Information Technology*. 2020. Vol . 3, No. 4. P. 226 - 239. DOI: 10.15276/hait.04.2020.2
 10. Ghahremani M., Ghadiri H., Hamghalam M. Local features integration for content-based image retrieval based on color, texture, and shape. 2021. *Multimed Tools Appl* . V.80. P. 28245–28263. URL: <https://doi.org/10.1007/s11042-021-10895-z>
 11. Papa J.P., de Albuquerque V.H.C., Falcão A.X., Tavares J.M.R.S. (). Fast Automatic Microstructural Segmentation of Ferrous Alloy Samples Using Optimum-Path Forest. *Lecture Notes in Computer Science*. 2010. V. 6026. URL: https://doi.org/10.1007/978-3-642-12712-0_19
 12. Wankhade N.P., Sale V.P., Yadav R.S., Jikar P.C., Gadgekar S.R., Dhokey N.B. Metallurgical microstructure classification using CNN: A comprehensive study on heat treatment analysis for steel. *Materials Today: Proceedings*. 2024. URL: <https://doi.org/10.1016/j.matpr.2024.05.066>.
 13. Sun Y., Guan W., Zhang Y. Research on a deep-learning-based method for assessing the metallographic structure of steel used in thermal power plants *Proc. SPIE 13288, Fourth International Conference on Computer Graphics, Image, and Virtualization (ICCGIV)*. 2024. URL: <https://doi.org/10.1117/12.3045623>
 14. Sun Y., Guan W., Zhang Y. Research on a deep-learning-based method for assessing the metallographic structure of steel used in thermal power plants: *Fourth International Conference on Computer Graphics, Image, and Virtualization*. 2024. Vol. 13288. P. 428-435. DOI: 10.1117/12.3045623
 15. Motyl M., Madej Ł. Supervised pearlitic–ferritic steel microstructure segmentation by U-Net convolutional neural network. *Archiv.Civ.Mech.Eng*. 2022. V. 22, P. 206. URL: <https://doi.org/10.1007/s43452-022-00531-4>
 16. Polyakova M. V. Image segmentation with a convolutional neural network without pooling layers in dermatological disease diagnostics systems. *Radio Electronics, Computer Science, Control*. 2023. No.1. P. 51-51. DOI: 10.15588/1607-3274-2023-1-5
 17. Rusanovsky M., Beeri O., Oren G. An end-to-end computer vision methodology for quantitative metallography. *Sci.Rep*. 2022. V.12. P. 4776. URL: <https://doi.org/10.1038/s41598-022-08651-w>
 18. Пасинков М.К., Хачай М.Ю. Сегментація відбитків пальців з використанням згорткових нейронних мереж. *CEUR Workshop Proceedings*. 2017. V.1894. P.215-225 URL: <http://ceurspt.wikidata.dbis.rwth-aachen.de/Vol-1894/mpr3.html>
 19. Кривенко Д. М. Аугментація навчальної вибірки для навчання U - NET мережі для завдання сегментації металографічних зображень. *Сучасні інформаційні технології: матеріали X Міжнародної наукової конференції студентів та молодих вчених». Одеса: Наука та техніка, 2020. С. 68-70.*
 20. Гонсалес Р. Вудс Р. Цифрова обробка зображень. М. : Техносфера , 2005. 1072 с.

21. Siddique N., Paheding S., Elkin C. P., Devabhaktuni V. U-Net and Its Variants for Medical Image Segmentation: A Review of Theory and Applications. *IEEE Access*. 2021. V. 9. P. 82031-82057. DOI: 10.1109/ACCESS.2021.3086020.
22. Hara K., Saito D., Shouno H., Analysis of function of rectified linear unit used in deep learning. *International Joint Conference on Neural Networks (IJCNN), Killarney, Ireland*. 2015, P. 1-8. DOI: 10.1109/IJCNN.2015.7280578.

METHOD OF METALLOGRAPHIC IMAGES SEGMENTATION USING THE U-NET NEURAL NETWORK

D. R. Horpenko, D. M. Krivenko

National Odesa Polytechnic University
1, Shevchenko Ave., Odesa, 65044, Ukraine
Emails: horpenko@op.edu.ua, d.krivenko.ilc@gmail.com

This work addresses the problem of metallographic image segmentation. An analysis of segmentation methods using neural networks has been conducted. A segmentation method using the U-NET neural network has been proposed, which demonstrates high segmentation quality even with a limited training dataset size. The main procedures of the proposed method include preprocessing, data augmentation, and object classification. The developed segmentation method has been tested on typical metallographic images. A comparison of segmentation results using the proposed method and the watershed method has been conducted. The segmentation quality has been evaluated using accuracy (Accuracy), precision (Precision), recall (Recall), F-measure, and confusion matrix metrics. Based on experimental studies, it has been determined that training the U-NET neural network for one epoch with 500 iterations yields the best segmentation quality indicators, namely: accuracy (Accuracy) - 0.91, precision (Precision) - 0.82, recall (Recall) - 0.87, F-measure - 0.85, with adequate processing speed. The watershed method ensures high speed, but the segmentation quality is lower. Thus, the proposed method in this work is effective for metallographic image segmentation tasks that require high segmentation quality.

Keywords: segmentation; augmentation; U-NET neural network; watershed method; confusion matrix