

**М. О. МОЛЧАНОВА**

доктор філософії з комп'ютерних наук,  
старший викладач кафедри комп'ютерних наук  
Хмельницький національний університет  
ORCID: 0000-0001-9810-936X

**Б. О. САВЕНКО**

молодший науковий співробітник  
Хмельницький національний університет  
ORCID: 0000-0001-5647-9979

**О. О. ЗАЛУЦЬКА**

асистент кафедри комп'ютерних наук  
Хмельницький національний університет  
ORCID: 0000-0003-1242-3548

**О. В. МАЗУРЕЦЬ**

кандидат технічних наук, доцент,  
доцент кафедри комп'ютерних наук  
Хмельницький національний університет  
ORCID: 0000-0002-8900-0650

## ДОСЛІДЖЕННЯ ВПЛИВУ АУГМЕНТАЦІЇ ЗОБРАЖЕНЬ НА ТОЧНІСТЬ НЕЙРОМЕРЕЖЕВОЇ КЛАСИФІКАЦІЇ ТЕКСТИЛЬНИХ ВІДХОДІВ

У роботі досліджено вплив аугментації зображень на якість нейромережевої класифікації текстильних матеріалів за мікрозображеннями для задач автоматизованого сортування текстильних відходів за складом волокна. Вихідні дані отримано з відкритого набору «Fabric Fiber Composition Micro Image Dataset», сформованого авторами та оприлюдненого на платформі Kaggle; вибірка містить 756 мікрозображень трьох класів («30 – 50», «50 – 70», «70 – 100») із близьким до рівномірного розподілом. Експеримент виконано за фіксованим протоколом поділу даних із виділенням незалежної тестової множини 50% та навчальної та валідаційної частин 40%/10%. Як базову модель застосовано компактний класифікатор на основі MobileNetV2 з попереднім навчанням на ImageNet у режимі замороженого екстрактора ознак і класифікаційної голови, навчання проводили протягом 3 епох за незмінних гіперпараметрів. Порівняно п'ять типів аугментації (горизонтальне віддзеркалення, поворот, масштабування, зміна контрасту, зсув) із базовим варіантом без аугментації; якість оцінювали за accuracy та macro-Precision, macro-Recall, macro-F<sub>1</sub> на валідаційній і тестовій множинах, а також за показниками по кожному класу та різницею  $\Delta F_1$  відносно базового варіанта. На тесті найкращий інтегральний результат показало масштабування: macro-F<sub>1</sub>=0.7968 проти 0.7814 без аугментації (приріст близько 0.015), тоді як на валідації максимальний macro-F<sub>1</sub> забезпечила зміна контрасту (0.7842). Клас-специфічний аналіз виявив неоднорідність ефектів: для класу «30 – 50» масштабування дало  $\Delta F_1=+0.067$ , тоді як для класу «70 – 100» поворот і масштабування знижували якість ( $\Delta F_1=-0.025$  та  $-0.023$  відповідно). Стабільність висновків підтверджено повторними запусками: для масштабування test macro-F<sub>1</sub>=0.8047±0.0052. Отримані результати обґрунтовують доцільність підбору аугментацій з урахуванням балансу якості між класами та перевірки відтворюваності на незалежній тестовій множині.

**Ключові слова:** аугментація зображень, класифікація мікрозображень тканин, текстильні відходи, склад волокна, комп'ютерний зір, MobileNetV2.

**М. О. MOLCHANOVA**

Doctor of Philosophy in Computer Science,  
Senior Lecturer at the Department of Computer Science  
Khmelnytskyi National University  
ORCID: 0000-0001-9810-936X



B. O. SAVENKO

Junior Researcher  
Khmelnyskyi National University  
ORCID: 0000-0001-5647-9979

O. O. ZALUTSKA

Assistant at the Department of Computer Science  
Khmelnyskyi National University  
ORCID: 0000-0003-1242-3548

O. V. MAZURETS

Doctor of Philosophy in Engineering Science, Associate Professor,  
Associate Professor at the Department of Computer Science  
Khmelnyskyi National University  
ORCID: 0000-0002-8900-0650

## RESEARCH INTO THE IMPACT OF IMAGE AUGMENTATION ON THE ACCURACY OF NEURAL NETWORK CLASSIFICATION OF TEXTILE WASTE

The paper investigates the impact of image augmentation on the quality of neural network classification of textile materials by microimages for tasks of automated sorting of textile waste by fiber composition. The initial data were obtained from the open set «Fabric Fiber Composition Micro Image Dataset», formed by the authors and published on the Kaggle platform; the sample contains 756 microimages of three classes («30 – 50», «50 – 70», «70 – 100») with a close to uniform distribution. The experiment was performed using a fixed data division protocol with the allocation of an independent test set of 50% and training and validation parts of 40%/10%. As a base model, a compact classifier based on MobileNetV2 was used with pre-training on ImageNet in the frozen feature extractor and classification head mode, training was carried out for 3 epochs with unchanged hyperparameters. Five types of augmentation (horizontal mirroring, rotation, scaling, contrast change, shift) were compared with the base version without augmentation; the quality was assessed by accuracy and macro-Precision, macro-Recall, macro- $F_1$  on the validation and test sets, as well as by the indicators for each class and the difference  $\Delta F_1$  relative to the base version. In the test, the best integral result was shown by scaling: macro- $F_1=0.7968$  versus 0.7814 without augmentation (an increase of about 0.015), while in the validation, the maximum macro- $F_1$  was provided by contrast change (0.7842). Class-specific analysis revealed heterogeneity of effects: for the class «30 – 50» scaling gave  $\Delta F_1=+0.067$ , while for the class «70 – 100» rotation and scaling reduced quality ( $\Delta F_1=-0.025$  and  $-0.023$ , respectively). The stability of the conclusions was confirmed by repeated runs: for scaling test macro- $F_1=0.8047\pm 0.0052$ . The obtained results justify the feasibility of selecting augmentations taking into account the quality balance between classes and checking reproducibility on an independent test set.

**Key words:** image augmentation, fabric micro-image classification, textile waste, fiber composition, computer vision, MobileNetV2.

### Постановка проблеми

Автоматизоване сортування текстильних відходів за складом волокна є критичною передумовою для вибору коректного сценарію вторинної переробки та підвищення її економічної доцільності. У практичних умовах зображення мікроструктури тканин отримуються з істотними варіаціями освітлення, контрасту, масштабу, орієнтації та положення фрагмента у кадрі [1]. Крім того, доступні навчальні вибірки зазвичай обмежені за обсягом і не можуть повністю відобразити різноманіття реальних спотворень, що призводить до перенавчання та деградації узагальнювальної здатності нейромережових класифікаторів [2]. Одним із типових інструментів підвищення стійкості моделі є аугментація даних, однак різні види аугментацій можуть по-різному впливати на класи, змінюючи дискримінативні текстурні ознаки. Тому виникає задача експериментально дослідити, які типи аугментації забезпечують статистично стабільне покращення якості класифікації мікрозображень текстильних матеріалів, а також визначити клас-специфічний ефект аугментацій за фіксованого протоколу навчання та тестування.

### Аналіз останніх досліджень і публікацій

Частіше опираються на моделі, які самі навчаються виділяти візуальні ознаки з прикладів. Зокрема, у роботі про розпізнавання переплетень запропоновано схему, де одночасно оцінюється положення ниток і визначається тип переплетення; наголос зроблено на необхідності великих і різноманітних наборів даних для стабільності результатів [3].

Окрема практична лінія використання аугментації як способу зробити модель стійкішою до поворотів, зміни масштабу й умов зйомки для класифікації тканих структур прямо застосовують аугментацію та попередньо навчені компоненти, щоб підвищити якість розпізнавання [4].

У роботі з розпізнавання текстур трикотажу також підкреслюють, що обмеженість відкритих наборів даних і відмінності в положенні, освітленні під час зйомки напряму впливають на якість, і тому потрібні рішення, стійкі до таких варіацій [5].

Окремо варто виділити мікрозображення волокон, де класифікація базується на формі та контурах поперечного перерізу волокна. Є підхід, у якому ідентифікацію категорій суміші волокон виконують через цифрову обробку мікрофото та обчислення формальних показників форми [6].

#### Формулювання мети дослідження

Експериментально визначити, як різні типи аугментації зображень впливають на точність нейромережевої класифікації текстильних матеріалів за мікрозображеннями, та встановити, які перетворення забезпечують найбільш стабільне й відтворюване підвищення якості розпізнавання.

#### Викладення основного матеріалу дослідження

У дослідженні експеримент організовано як послідовність узгоджених етапів, що забезпечують однакові умови навчання та оцінювання для всіх розглянутих варіантів аугментації. Така організація дозволяє коректно зіставляти результати та інтерпретувати відмінності саме як наслідок застосованих перетворень зображень, а не як ефект змін у моделі, параметрах навчання чи способі формування вибірок. Загальну логіку експерименту наведено на схемі (рисунк 1).



Рис. 1. Схема експерименту з оцінювання впливу аугментації на якість класифікації мікрозображень тканин

До вхідних даних належать мікрозображення тканин із розміткою за класами, отримані з відкритого набору даних «Fabric Fiber Composition Micro Image Dataset», у якому представлені три класи складу волокна 30–50, 50–70 та 70–100. Датасет зібрано авторами в межах виконання держбюджетної теми «Нейромережеві методи класифікації текстильних відходів для систем циркулярної економіки», загальний обсяг вибірки становить 756 зображень із близьким до рівномірного розподілом за класами. Для забезпечення порівнюваності результатів використовується фіксований протокол поділу даних, за якого 50% зображень відводяться під незалежне тестування, а решта формує навчальну та валідаційну множини (відповідно 40% і 10% від загального обсягу). Такий розподіл дає змогу оцінювати узагальнювальну здатність моделі на значній тестовій підмножині та мінімізує ризик оптимістичного зміщення оцінок якості [7].

Як базову архітектуру нейромережевого класифікатора застосовано компактну модель, придатну для швидких експериментів за обмеженої кількості епох. Зокрема використано MobileNetV2 [8] як згортковий екстрактор ознак із попереднім навчанням на ImageNet у режимі заморожених ваг. Вхідні зображення приводяться до розміру 224×224 та нормалізуються відповідно до стандартної процедури препроцесингу MobileNetV2. Над виходом екстрактора ознак розміщено легкий класифікаційний головний блок: Dropout (0.2) для регуляризації та щільний шар Dense(3, softmax) для отримання ймовірностей трьох класів. Навчання виконується протягом 3 епох із оптимізатором Adam, що дозволяє швидко порівняти вплив різних видів аугментації без зміни архітектури чи гіперпараметрів.

Перелік перетворень, що досліджуються, охоплює типові для комп'ютерного зору варіанти аугментації, які моделюють реальні варіації умов зйомки: горизонтальне віддзеркалення (flip), повороти (rotation), масштабування (zoom), зміни контрасту (contrast) та зсуви зображення (translation/shift) [9]. Для кожного виду аугментації модель навчається окремо, причому сама тестова множина залишається незмінною, що забезпечує коректність прямого порівняння. Додатково, для підвищення надійності висновків, експерименти повторюються з подальшим узагальненням результатів.

Блок «Обробка» на схемі відображає три узагальнені кроки. На першому кроці здійснюється підготовка даних: завантаження датасету, перевірка структури класів, формування списків файлів, а також фіксований поділ на train, val, test із збереженням розподілу класів. На другому кроці виконується навчання класифікатора за незмінних налаштувань; відмінність між експериментами полягає лише в типі аугментації, що застосовується до навчальних зображень під час тренування [10]. На третьому кроці проводиться оцінювання якості на валідаційній і тестовій множині із розрахунком стандартних показників (Accuracy, macro-Precision, macro-Recall, macro-F<sub>1</sub>), а також метрик по кожному класу. Додатково аналізується клас-специфічний ефект перетворень через різницю  $\Delta F_1$  відносно базового варіанта без аугментації (none), що дозволяє встановити, які перетворення покращують або погіршують розпізнавання окремих класів.

Вихідним результатом є порівняльний набір метрик для всіх видів аугментації на валідаційній і тестовій множині, зокрема узагальнені показники і показники по класах. У разі повторних прогонів додатково формуються статистики стабільності у вигляді середнього значення та стандартного відхилення  $\text{macro-F}_1$  на тесті, що підсилює обґрунтованість висновків щодо доцільності конкретних аугментацій у задачі класифікації текстильних матеріалів за мікрозображеннями.

Експеримент виконано у хмарному середовищі Google Colab, що забезпечує інтерактивне виконання коду в браузері та, за потреби, використання апаратного прискорення (GPU) [11]. Реалізацію експерименту подано у вигляді одного ноутбука, який містить усі етапи: завантаження даних, формування вибірок, навчання моделей для різних аугментацій, обчислення метрик і побудову підсумкових таблиць та графіків.

Як мову програмування використано Python. Для побудови та навчання нейромережі застосовано бібліотеку TensorFlow (Keras), що надає реалізації готових архітектур, шарів аугментації та стандартних процедур оптимізації. Завантаження датасету виконано за допомогою kagglehub, що дозволяє отримувати дані з Kaggle без ручного керування архівами та шляхами доступу [12]. Для розрахунку метрик якості та побудови матриць плутанини використано scikit-learn; для табличного узагальнення результатів pandas; для чисельних обчислень NumPy; для візуалізації Matplotlib [13]. Таким набором інструментів забезпечено повний цикл експериментального дослідження в межах одного середовища та уніфікований формат представлення результатів.

У таблиці 1 наведено узагальнені результати оцінювання якості класифікації для кожного варіанта аугментації за однакового протоколу навчання, окремо на валідаційній та незалежній тестовій множині.

Отримані результати демонструють, що за умов короткого навчання (3 епохи) та фіксованого тестового протоколу значення test Accuracy для більшості варіантів є близькими (переважно близько 0.80), тоді як  $\text{macro-F}_1$  краще відображає відмінності в балансі якості між класами. Найвищий показник test  $\text{macro-F}_1$  отримано для аугментації «zoom» (0.7968), що перевищує базовий варіант без аугментації («none», 0.7814), тобто спостерігається помірне покращення узагальнювальної здатності на незалежній тестовій множині.

Таблиця 1

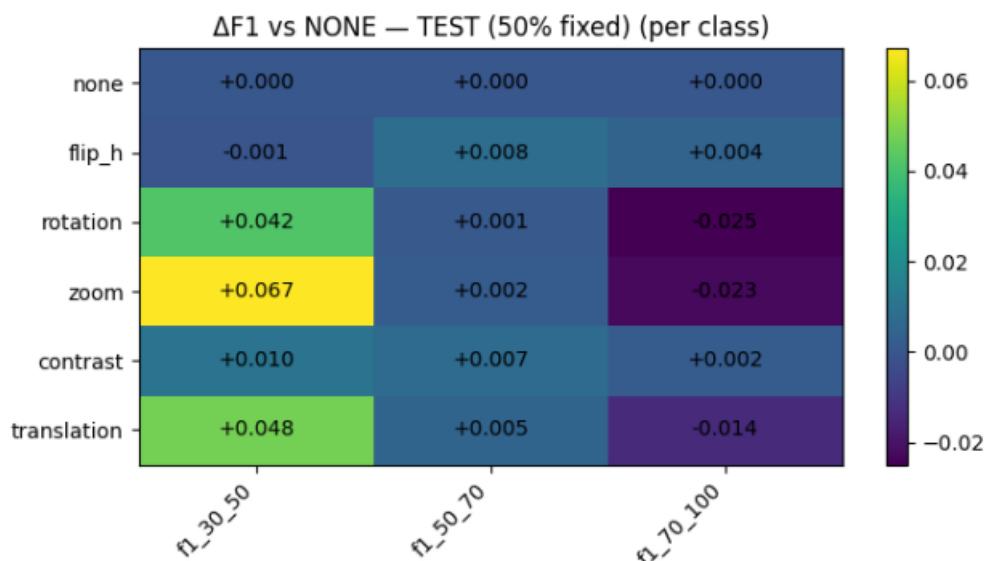
## Узагальнені метрики якості

Вид аугментації	Val Accuracy	Val Precision	Val Recall	Val F1	Test Accuracy	Test Precision	Test Recall	Test F1
zoom	0.763158	0.779825	0.760000	0.756052	0.801587	0.804715	0.800546	<b>0.796764</b>
translation	0.763158	0.763568	0.760000	0.750626	0.801587	0.799200	0.800165	0.794440
contrast	<b>0.802632</b>	<b>0.817284</b>	<b>0.800000</b>	<b>0.784153</b>	0.801587	0.800471	0.799467	0.787848
rotation	0.776316	0.782540	0.773333	0.766923	0.793651	0.791748	0.792355	0.787413
flip_h	0.763158	0.761294	0.760000	0.741996	0.801587	0.804102	0.799276	0.785294
none	0.776316	0.781129	0.773333	0.754238	0.796296	0.796709	0.794090	0.781419

Валідаційні результати мають іншу конфігурацію лідерів: максимальні значення val accuracy і val  $\text{macro-F}_1$  забезпечує «contrast» (0.8026 та 0.7842 відповідно), однак на тесті перевага контрастної аугментації зменшується (test  $\text{macro-F}_1 = 0.7878$ ) і поступається масштабуванню та зсувам. Така невідповідність між ранжуванням на валідації та тесті вказує на те, що окремі перетворення можуть краще підлаштовувати модель до варіацій у валідаційній підмножині, але не гарантувати пропорційного покращення на незалежних даних. Загалом відмінності між більшістю аугментацій на тесті є невеликими, що є очікуваним для невеликого датасету та обмеженої тривалості навчання, і обґрунтовує необхідність подальшої перевірки стабільності висновків через повторні запуски з різними значеннями seed та аналізом середніх значень і розкиду метрик.

Для деталізації впливу аугментацій було проаналізовано не лише інтегральні метрики, а й клас-специфічний ефект на незалежній тестовій множині (рисунок 2). Оскільки різні перетворення можуть по-різному змінювати інформативні текстурні ознаки, оцінювання виконано за приростом та втратою якості окремо для кожного класу відносно базового варіанта без аугментації. Як міру ефекту використано різницю  $\Delta F_1 = F_1(\text{augmentation}) - F_1(\text{none})$ , де додатні значення відповідають покращенню розпізнавання класу, а від'ємні погіршенню.

На рисунку 2 у вигляді теплової карти подано значення  $\Delta F_1$  для кожного класу складу волокна. Найбільш виражений позитивний ефект спостерігається для класу «30 – 50», де аугментації, пов'язані зі зміною масштабу та положення фрагмента, забезпечують приріст якості: «zoom» (+0.067), «translation» (+0.048) та «rotation» (+0.042). Для класу «50 – 70» зміни є незначними, що відображає близькість значень  $\Delta F_1$  до нуля; водночас помірний приріст демонструють «flip\_h» (+0.008) та «contrast» (+0.007). На відміну від цього, для класу «70 – 100» частина аугментацій зумовлює зниження  $F_1$ , зокрема «rotation» (-0.025) та «zoom» (-0.023), тоді як «contrast» (+0.002) і «flip\_h» (+0.004) мають слабо позитивний або практично нейтральний вплив. Таким чином, результати вказують на неоднорідність дії аугментацій за класами: перетворення, що покращують розпізнавання одного класу, можуть одночасно погіршувати інший, що підтверджує доцільність клас-орієнтованого аналізу при виборі політик аугментації для задач класифікації мікрозображень тканин [14].



**Рис. 2. Клас-специфічний ефект аугментацій на тестовій множині**

Обмеження дослідження та перспективи подальших досліджень. Отримані результати інтерпретуються в межах обраної експериментальної постановки та використаного набору даних. Датасет містить 756 мікрозображень трьох класів і хоча є відкритим та репрезентує типові варіації зйомки, він не охоплює повного спектра умов, характерних для промислового або польового отримання зображень (різні камери, оптика, відстань, освітлення, фон, ступінь забруднення). Конфігурація моделі орієнтована на швидкий порівняльний експеримент: застосовано попередньо навчений екстрактор ознак із замороженими вагами та короткий режим навчання (3 епохи), що обмежує потенціал моделі адаптуватися до доменно-специфічних мікротекстур і може зменшувати контраст між політиками аугментації [15]. Різниця між аугментаціями за інтегральними метриками на тесті є невеликими, тому висновки доцільно трактувати як порівняльні в рамках поточної конфігурації, а не як універсальну рекомендацію для будь-яких даних і моделей.

Подальші дослідження доцільно спрямувати на розширення експериментальної бази та підсилення доказовості висновків. Перспективним є доповнення набору зображень незалежними зразками з інших умов отримання, формування окремої зовнішньої тестової вибірки для перевірки переносності висновків між доменами. Доцільно дослідити сценарії часткового або повного донавчання базової мережі, що дозволить оцінити, чи зберігається ранжування аугментацій за більш глибокої адаптації моделі до текстур тканин.

### Висновки

У роботі проведено дослідження впливу аугментації зображень на точність нейромережевої класифікації текстильних відходів шляхом проведення серії контрольованих експериментів, спрямованих на кількісне оцінювання впливу аугментації зображень на якість класифікації мікроструктури тканин за складом волокна. На відкритому датасеті з трьома класами виконано фіксований стратифікований поділ із виділенням незалежної тестової множини (50%), після чого за незмінних налаштувань моделі та навчання послідовно перевірено кілька типів аугментації. Якість оцінювали на валідаційній і тестовій множині за інтегральними показниками (Accuracy, macro-Precision, macro-Recall, macro-F<sub>1</sub>) та за клас-орієнтованими метриками, а стабільність висновків додатково перевіряли повторними запусками з різними значеннями seed.

Найсуттєвіший результат полягає в тому, що аугментація масштабування забезпечує найкращу якість на незалежному тесті: test macro-F<sub>1</sub> = 0.7968 проти 0.7814 без аугментації (приріст близько +0.015), а за трьома повтореннями отримано 0.8047 ± 0.0052. Клас-специфічний аналіз підтверджує неоднорідність ефекту: для класу «30 – 50» масштабування дає найбільший позитивний внесок ( $\Delta F_1 = +0.067$ ), тоді як для класу «70 – 100» масштабування та повороти можуть знижувати якість ( $\Delta F_1 = -0.023$  та  $-0.025$  відповідно), що вказує на необхідність добору політики аугментації з урахуванням балансу якості між класами, а не лише за інтегральним значенням macro-F<sub>1</sub>.

### Список використаної літератури

1. Faghieh E., Saki Z., Moore M. A systematic literature review-AI-enabled textile waste sorting. *Sustainability*. 2025. Vol. 17, No. 10. P. 4264. DOI: <https://doi.org/10.3390/su17104264>.
2. Mazurets O., Zalutska O., Molchanova M., Sobko O., Bukhantsova L., Zakharkevich O. Deep Learning-Driven Fabric Classification: Distinguishing Natural and Synthetic Materials. *CEUR Workshop Proceedings*. 2025. Vol. 4164. P. 39–51.

3. Meng S., Pan R., Gao W., Zhou J., Wang J., He W. A multi-task and multi-scale convolutional neural network for automatic recognition of woven fabric pattern. *Journal of Intelligent Manufacturing*. 2021. Vol. 32, No. 4. P. 1147–1161. DOI: <https://doi.org/10.1007/s10845-020-01607-9>.
4. Iqbal Hussain M. A., Khan B., Wang Z., Ding S. Woven fabric pattern recognition and classification based on deep convolutional neural networks. *Electronics*. 2020. Vol. 9, No. 6. P. 1048. DOI: <https://doi.org/10.3390/electronics9061048>.
5. Tan L., Fu Q., Li J. An improved neural network model based on DenseNet for fabric texture recognition. *Sensors*. 2024. Vol. 24, No. 23. P. 7758. DOI: <https://doi.org/10.3390/s24237758>.
6. Lu S., Deng N., Xin B., Wang Y., Wang W. Investigation on image-based digital method for identification on polyester/cotton fiber category. *Fibers and Polymers*. 2021. Vol. 22, No. 6. P. 1774–1783. DOI: <https://doi.org/10.1007/s12221-021-0802-7>.
7. Sobko O., Mazurets O., Molchanova M., Krak I., Barmak O. Method for analysis and formation of representative text datasets. *CEUR Workshop Proceedings*. 2025. Vol. 3899. P. 84–98.
8. Molchanova M. O., Didur V. O., Mazurets O. V. Approach to Data Dimensionality Reduction and Defect Classification Based on Vibration Analysis for Maintenance of Rotating Machinery. *Radio Electronics, Computer Science, Control*. 2025 (1). P. 84–95. DOI: <https://doi.org/10.15588/1607-3274-2025-1-8>.
9. Kumar T., Brennan R., Mileo A., Bendeche M. Image data augmentation approaches: A comprehensive survey and future directions. *IEEE Access*. 2024. Vol. 12. P. 187536–187571. DOI: <https://doi.org/10.1109/ACCESS.2024.3470122>.
10. Molchanova M., Didur V., Mazurets O., Sobko O., Zakharkevich O. Method for Construction and Demolition Waste Classification Using Two-Factor Neural Network Image Analysis. *CEUR Workshop Proceedings*. 2025. Vol. 3970. P. 168–182.
11. Мазурець О. В., Жарновський О. В., Гладун О. В., Собко О. В. Нейромережеве виявлення фейкових зображень людей. *Вісник Хмельницького національного університету. Серія: Технічні науки*. 2025. № 5, Т. 1. С. 416–422.
12. Мазур С. В., Мазурець О. В., Кліменко В. І., Собко О. В., Залуцька О. О. Алгоритми та програмна архітектура інформаційної системи нейромережевого аналізу постави людини. *Вісник Хмельницького національного університету. Серія: Технічні науки*. 2025. № 3, Т. 1. С. 275–284.
13. Молчанова М. О., Мазурець О. В., Залуцька О. О., Кадинська В. Д., Масловська В. В. Інформаційна хмарна технологія нейромережевого аналізу зруйнованих споруд за візуальними даними з БПЛА. *Вісник Херсонського національного технічного університету*. 2025. № 3 (94), Т. 2. С. 345–351. DOI: <https://doi.org/10.35546/kntu2078-4481.2025.3.2.44>.
14. Xing W., Liu Y., Xin B., Zang L., Deng N. The application of deep and transfer learning for identifying cashmere and wool fibers. *Journal of Natural Fibers*. 2022. Vol. 19, No. 1. P. 88–104. DOI: <https://doi.org/10.1080/15440478.2020.1727817>.
15. Bai J., Wu D., Shelley T., Schubel P., Twine D., Russell J., Zhang J. A comprehensive survey on machine learning driven material defect detection. *ACM Computing Surveys*. 2025. Vol. 57, No. 11. P. 1–36. DOI: <https://doi.org/10.1145/3730576>.

#### References

1. Faghieh, E., Saki, Z., Moore, M. (2025). A systematic literature review-AI-enabled textile waste sorting. *Sustainability*, vol. 17, no. 10, pp. 4264. <https://doi.org/10.3390/su17104264>
2. Mazurets, O., Zalutska, O., Molchanova, M., Sobko, O., Bukhantsova, L., Zakharkevich, O. (2025). Deep learning-driven fabric classification: Distinguishing natural and synthetic materials. *CEUR Workshop Proceedings*, vol. 4164, pp. 39–51.
3. Meng, S., Pan, R., Gao, W., Zhou, J., Wang, J., He, W. (2021). A multi-task and multi-scale convolutional neural network for automatic recognition of woven fabric pattern. *Journal of Intelligent Manufacturing*, vol. 32, no. 4, pp. 1147–1161. <https://doi.org/10.1007/s10845-020-01607-9>.
4. Iqbal Hussain, M. A., Khan, B., Wang, Z., Ding, S. (2020). Woven fabric pattern recognition and classification based on deep convolutional neural networks. *Electronics*, vol. 9, no. 6, pp. 1048. <https://doi.org/10.3390/electronics9061048>.
5. Tan, L., Fu, Q., Li, J. (2024). An improved neural network model based on DenseNet for fabric texture recognition. *Sensors*, vol. 24, no. 23, pp. 7758. <https://doi.org/10.3390/s24237758>.
6. Lu, S., Deng, N., Xin, B., Wang, Y., Wang, W. (2021). Investigation on image-based digital method for identification on polyester/cotton fiber category. *Fibers and Polymers*, vol. 22, no. 6, pp. 1774–1783. <https://doi.org/10.1007/s12221-021-0802-7>.
7. Sobko, O., Mazurets, O., Molchanova, M., Krak, I., Barmak, O. (2025). Method for analysis and formation of representative text datasets. *CEUR Workshop Proceedings*, vol. 3899, pp. 84–98.
8. Molchanova, M. O., Didur, V. O., Mazurets, O. V. (2025). Approach to data dimensionality reduction and defect classification based on vibration analysis for maintenance of rotating machinery. *Radio Electronics, Computer Science, Control*, vol. 1, pp. 84–95. <https://doi.org/10.15588/1607-3274-2025-1-8>.

9. Kumar, T., Brennan, R., Mileo, A., Bendeche, M. (2024). Image data augmentation approaches: A comprehensive survey and future directions. *IEEE Access*, vol. 12, pp. 187536–187571. <https://doi.org/10.1109/ACCESS.2024.3470122>.
10. Molchanova, M., Didur, V., Mazurets, O., Sobko, O., Zakharkovich, O. (2025). Method for construction and demolition waste classification using two-factor neural network image analysis. *CEUR Workshop Proceedings*, vol. 3970, pp. 168–182.
11. Mazurets, O. V., Zharnovskiy, O. V., Hladun, O. V., Sobko, O. V. (2025). Neiomerezheve vyivlennia feikovykh zobrazhen liudei [Neural network detection of fake human images]. *Visnyk Khmelnytskoho natsionalnoho universytetu. Serii: Tekhnichni nauky*, vol. 5, no. 1, pp. 416–422.
12. Mazur, Ye. V., Mazurets, O. V., Klimenko, V. I., Sobko, O. V., Zalutska, O. O. (2025). Alhorytmy ta prohramna arkhitektura informatsiinoi systemy neiomerezhevoho analizu postavy liudyny [Algorithms and software architecture of a neural network system for human posture analysis]. *Visnyk Khmelnytskoho natsionalnoho universytetu. Serii: Tekhnichni nauky*, vol. 3, no. 1, pp. 275–284.
13. Molchanova, M. O., Mazurets, O. V., Zalutska, O. O., Kadinska, V. D., Maslovska, V. V. (2025). Informatsiina khmarna tekhnolohiia neiomerezhevoho analizu zruinovanykh sporud za vizualnymy danymy z BPLA [Cloud-based neural network technology for analysis of destroyed structures using UAV visual data]. *Visnyk Khersonskoho natsionalnoho tekhnichnoho universytetu*, vol. 3, no. 2, pp. 345–351. <https://doi.org/10.35546/kntu2078-4481.2025.3.2.44>.
14. Xing, W., Liu, Y., Xin, B., Zang, L., Deng, N. (2022). The application of deep and transfer learning for identifying cashmere and wool fibers. *Journal of Natural Fibers*, vol. 19, no. 1, pp. 88–104. <https://doi.org/10.1080/15440478.2020.1727817>.
15. Bai, J., Wu, D., Shelley, T., Schubel, P., Twine, D., Russell, J., ... Zhang, J. (2025). A comprehensive survey on machine learning driven material defect detection. *ACM Computing Surveys*, vol. 57, no. 11, pp. 1–36. <https://doi.org/10.1145/3730576>.

Дата першого надходження статті до видання: 18.02.2026

Дата прийняття статті до друку після рецензування: 25.03.2026

Дата публікації (оприлюднення) статті: 07.05.2026