

<https://doi.org/10.31891/2219-9365-2026-86-3>

УДК 004.932.2

ВПШОВСЬКИЙ Юрій

Національний університет "Львівська політехніка"  
<https://orcid.org/0009-0007-9873-3753>  
[yurii.vipshovskyi.asp.2025@lpnu.ua](mailto:yurii.vipshovskyi.asp.2025@lpnu.ua)

МЕЛЬНИК Роман

Національний університет "Львівська політехніка"  
<https://orcid.org/0000-0002-4329-6740>  
[ramelnyk@polynet.lviv.ua](mailto:ramelnyk@polynet.lviv.ua)

ГРИЦЮК Юрій

Національний університет "Львівська політехніка"  
<https://orcid.org/0000-0001-8183-3466>  
[yurii.i.hrytsiuk@lpnu.ua](mailto:yurii.i.hrytsiuk@lpnu.ua)

## ВИЯВЛЕННЯ ДЕФЕКТІВ ПОВЕРХНІ МЕТАЛІВ ЗА ДОПОМОГОЮ РОЗПОДІЛЕНИХ ОЗНАК ІНТЕНСИВНОСТІ ЗОБРАЖЕННЯ

Запропоновано та досліджено підхід, який полягає у перетворенні зображень металевих поверхонь у кумулятивне відображення, придатного для подальшого аналізу. З'ясовано, що метод аналізу кумулятивних відображень здатен ефективно виявляти наявність дефектів на зображеннях поверхонь металів. Розроблено метод перетворення вхідного зображення у кумулятивне відображення, яке аналізують на наявність різких переходів між різними ділянками зображення, порівнюючи інтенсивності переходів у кожному із рядків чи стовбців цього відображення із найчастішою інтенсивністю на усьому зображенні. Вибрано та підготовлено набори даних із різними зображеннями дефектів поверхонь металів. Розроблено програмне забезпечення, що використовує даний метод аналізу зображень для виявлення дефектів металів. Програмне забезпечення дозволяє будувати кумулятивні візуалізації з різними вхідними параметрами, що дає змогу досліджувати ефективність методу у залежності від параметрів побудови кумулятивних візуалізацій. Програмне забезпечення аналізує отримане відображення і у залежності від параметра допустимого відхилення визначає наявність різких перепадів інтенсивності на відображенні та у разі наявності таких видає що на початковому зображенні присутні дефекти, або навпаки відсутні. Також програмне забезпечення має можливість аналізувати набір зображень, та визначати точність роботи методу на цьому наборі із заданими вхідними параметрами. Здійснено підбір допустимих значень параметрів, та проведено тестування на зображеннях із різних наборів даних. Встановлено, що запропонований алгоритм досягає високої точності виявлення дефектів – більше 80 % правильно класифікованих зображень, та до 95 % правильної класифікації зображень, зроблених в умовах з однаковим освітленням. Також встановлено, що метод є достатньо гнучким і його можна адаптувати до різних типів поверхонь і видів дефектів, що робить його універсальним для широкого спектру застосувань у металургійній, автомобільній, авіаційній та інших галузях промисловості.

Ключові слова: кумулятивна гістограма; аналіз зображень; комп'ютерний зір; виявлення дефектів металів.

VIPSHOVSKIY Yurii, MELNYK Roman, HRYTSIUK Yurii

Lviv Polytechnic National University

## DETECTION OF MATERIAL SURFACE DEFECTS USING DISTRIBUTED IMAGE INTENSITY FEATURES

A method has been proposed and investigated that transforms images of metallic surfaces into a cumulative representation suitable for further analysis. It has been shown that the analysis of cumulative representations can effectively detect the presence of defects on metal surface images. A technique has been developed for converting an input image into a cumulative representation, which is then examined for abrupt transitions between different regions of the image by comparing the intensity changes in each row or column with the most frequent intensity value across the entire image. Datasets containing various images of metallic surface defects were selected and prepared. Software was developed to implement this image analysis method for defect detection. The software enables the construction of cumulative visualizations with adjustable input parameters, allowing researchers to evaluate the method's effectiveness depending on the chosen visualization settings. It analyzes the resulting representation and, based on a specified deviation threshold, determines whether sharp intensity fluctuations are present. If such fluctuations are detected, the software reports the presence of defects on the original image; otherwise, the image is classified as defect-free. Additionally, the software can process entire sets of images and evaluate the accuracy of the method on a given dataset with selected parameters. Acceptable parameter ranges were determined, and testing was conducted across multiple datasets. The results indicate that the proposed algorithm achieves a high defect-detection accuracy, exceeding 80 percent correct classifications overall and up to 95 percent accuracy for images captured under uniform lighting conditions. The method was also found to be sufficiently flexible, allowing adaptation to different surface types and defect categories, making it suitable for a wide range of applications in metallurgical, automotive, aerospace, and other industrial sectors.

Keywords: cumulative histogram; image analysis; computer vision; metal defect detection.

Стаття надійшла до редакції / Received 11.03.2026  
Прийнята до друку / Accepted 16.04.2026  
Опубліковано / Published 31.05.2026



This is an Open Access article distributed under the terms of the [Creative Commons CC-BY 4.0](https://creativecommons.org/licenses/by/4.0/)

© ВПШОВСЬКИЙ Юрій, МЕЛЬНИК Роман, ГРИЦЮК ЮРІЙ

## ПОСТАНОВКА ПРОБЛЕМИ У ЗАГАЛЬНОМУ ВИГЛЯДІ ТА ЇЇ ЗВ'ЯЗОК ІЗ ВАЖЛИВИМИ НАУКОВИМИ ЧИ ПРАКТИЧНИМИ ЗАВДАННЯМИ

Проблема виявлення дефектів у конструкційних матеріалах є однією з ключових у сучасному матеріалознавстві та неруйнівному контролі, оскільки від неї залежать якість продукції, надійність виробів і зниження собівартості. У світовій науковій літературі їй присвячено численні дослідження з використанням методів комп'ютерного зору та цифрової обробки зображень. Активно розвиваються як класичні статистичні підходи до аналізу текстури, так і високопродуктивні нейромережеві моделі.

Незважаючи на значний прогрес, багато сучасних систем автоматизованого контролю якості поверхні залишаються обчислювально складними, потребують великих обсягів попередньо розмічених даних та часто обмежені у здатності виявляти дефекти, відмінні від тих, що були представлені в навчальних вибірках. Особливо виразно ці недоліки проявляються під час аналізу великоформатних зображень, де стискання та попередня редукція даних можуть призводити до втрати важливих інформативних ознак.

У цих умовах актуальною є потреба у підходах до виявлення дефектів, які поєднують статистичний аналіз зображень з можливістю ефективного обробки великих зображень без втрати суттєвої інформації. Перспективним напрямом виступає використання кумулятивних гістограм та споріднених статистичних характеристик розподілу інтенсивностей, що дає змогу зменшити обсяг даних, спростити структуру системи контролю та підвищити ефективність виявлення широкого класу поверхневих дефектів на різних виробничих лініях, зокрема під час контролю металів.

## АНАЛІЗ ОСТАННІХ ДОСЛІДЖЕНЬ ТА ПУБЛІКАЦІЙ

Сучасні системи виявлення поверхневих дефектів умовно ділять на дві групи: методи статистичного / кластерного оброблення зображень без навчання та підходи на основі глибинних нейронних мереж. Перші простіші, не потребують розмічених вибірок і зручні для реалізації, але чутливі до структури дефекту й умов освітлення. Другі забезпечують високу точність, проте вимагають великої кількості даних для навчання, значних обчислювальних ресурсів та ретельної організації оптичної частини системи.

У роботі [1] використано двокамерну систему та смугове освітлення для контролю великих поверхонь шаф (0,6×1,6 м). Зображення послідовно обробляються фільтром Гауса, оператором Собеля та пороговою сегментацією K3M, а велике зображення розбивається на малі блоки. Досягнуто близько 88 % точності, що перевищує інші протестовані методи (46–58 %), однак підхід орієнтований переважно на аналіз країв, а не глобальної структури дефектів. У роботі [2] розглянуто швидкі методи статистичної сегментації для біологічних мікрооб'єктів, які не потребують навчальних даних, але розраховані на великі кластери й можуть пропускати множинні дрібні пошкодження. У роботі [3] аналізуються методи кластеризації, що забезпечують гарну точність поділу зображення на кластери, проте час оброблення (до 16 с навіть для 2 кластерів) робить їх малоприматними для оперативного контролю якості.

Більшість новіших робіт використовують нейронні мережі. У роботі [4] запропоновано компактну згорткову мережу з Global Average Pooling для аналізу зображень кремнієвих кристалів розширенням 28 × 28. Така архітектура добре працює для малих об'єктів, але їй важко масштабувати на великі поверхні матеріалів, де надмірне зменшення розширення або надто дрібне фрагментування зображень є проблематичними. У роботі [5] застосовано нейромережу U-Net для виділення контурів дефектів металевого прокату: точність сегментації становить 60–70 %, при цьому ймовірність виявити сам факт наявності дефекту близька до 99 %, що достатньо для задач відбракування матеріалу. Головний недолік – потреба у великому масиві розмічених зображень з усіма типами дефектів, інакше зростає ризик хибної класифікації.

У роботі [6] описано двопотокову згорткову мережу для аналізу кольорових та градієнтних зображень алюмінієвих профілів, які нормуються до формату 227×227. Досягнуто точності близько 95 %, однак вимога квадратної форми та фіксованого розширення змушує робити багато знімків одного профілю, а наявність двох глибоких гілок із великою кількістю параметрів свідчить про значні обчислювальні витрати. У роботі [7] представлено простішу нейромережеву систему контролю металевих пластин, натреновану на невеликій вибірці, що завдяки ретельно спроектованому рівномірному освітленню досягає близько 99 % точності виявлення дефектів. Водночас дослідження виконано на малих зразках і обмеженій кількості прикладів, тож для великих пластин або змінного освітлення система потребує істотної модифікації.

Окремий клас становлять моделі на основі трансформерів зору й гібридних архітектур. У роботі [8] розроблено класифікатор дефектів шкіри, що аналізує кольорові зображення 224 × 224, розбиваючи їх на патчі 14 × 14 та моделюючи глобальні залежності між ними. Модель була натренована на 3600 зображеннях за кілька хвилин і досягла точності 93 % при часі оброблення близько 80 мс на зображення без складної попередньої оброблення, окрім зміни розширення. У роботі [9] запропоновано метод AGCN для виявлення дефектів сталі, який поєднує VGG16, RPN, RoI-модуль, RCNN та графові згорткові мережі з механізмами уваги. На 4000 зображеннях, при навчанні 100 епох із малими пакетами, отримано точність сегментації 85,8 %, що свідчить про високу ефективність, але також про значну складність і ресурсоємність моделі.

У роботі [10] описано комплексну систему для виявлення дефектів на рідкокристалічних екранах, яка поєднує спеціалізовану оптичну схему (зображення 2330×1750, 24 біти) та комбінацію алгоритмів:

згладжувальний фільтр і поріг Оцу для виділення контурів, аналіз локалізованої енергії та крос-проекцію для точного знаходження дефектів, детектор Кірша для класифікації яскравих і темних ушкоджень. Рівень виявлення дефектів сягає 100 % для низки елементів конструкції та 98,7 % для листів дифузора, при середньому часі оброблення 6 с, що більш ніж удвічі швидше за ручний контроль. Проте специфічна схема підсвічування орієнтована саме на плівкові структури й погано переноситься на товсті металеві матеріали.

Узагальнюючи аналіз останніх досліджень та публікацій можна зробити висновок, що статистичні та кластерні методи не потребують навчальних вибірок і простіші для впровадження, але втрачають чутливість до дрібних і множинних дефектів та обмежені умовами освітлення. Нейромережеві й трансформерні підходи забезпечують високу точність і гнучкість, проте потребують великих обсягів розмічених даних, акуратної оптичної системи та значних обчислювальних ресурсів, часто будучи жорстко прив'язаними до певного формату зображень. Спеціалізовані оптико-алгоритмічні комплекси демонструють майже еталонні результати в вузьких задачах, але важко масштабуються на інші типи поверхонь. Це обґрунтовує доцільність пошуку альтернативних методів статистичного аналізу, зокрема на основі кумулятивних гістограм яскравості, які не потребують глибоких нейронних мереж і великих навчальних наборів, але можуть бути придатними для контролю великих площ матеріалів при збереженні достатньої точності виявлення дефектів.

### МАТЕРІАЛИ ТА МЕТОДИ ДОСЛІДЖЕННЯ

Для виявлення дефектів на поверхнях металів вирішено використати приклади із двох наборів даних [11, 12]. Обидва набори даних місять різноманітні зображення дефектів у відтінках сірого. Набір даних NEU-DET містить 1800 квадратних зображень малого розширення (200×200) із 6 різними типами дефектів. Набір даних GC10-DET містить 8 566 прямокутних зображень великого розширення (2048×1000) з 10 різними типами дефектів.

Обрані набори даних дуже різноманітні, але на жаль у них відсутні зображення без дефектів, для цього із набору даних GC10-DET було вирізано частини зображення різного розширення, які можна класифікувати як бездефектні. Ці зображення поміщено у окрему зовнішню папку clear. Також з допомогою цих наборів даних було сформовано різні набори для дослідження точності визначення наявності дефектів.

Було відібрано зображення в такий спосіб:

1. Вибірка із невеликих зображень (розширення 200×200 пікселів), із набору даних NEU-DET, де для отримання бездефектних зображень були використані інструменти Photoshop для усунення дефектів. Розмір набору даних – 300 зображень.
2. Вибірка із великих зображень із набору даних GC10-DET з змінними розширеннями більше 1000×1000 пікселів, де для отримання бездефектних зображень вирізались частини зображень з набору даних так щоб на них не було дефектів. Розмір набору даних – 100 зображень.
3. Вибірка із зображень різної роздільної здатності, де було перемішано два набори даних створені вище. Розмір набору даних – 100 зображень.

Для зручного аналізу точності виявлення дефектів, зображення із дефектами були підписані з допомогою "\_defected" у кінці назви файлів.

### ФОРМУЛЮВАННЯ ЦІЛЕЙ СТАТТІ

*Об'єкт дослідження* – виявлення дефектів на зображеннях поверхонь матеріалів за розподіленими ознаками їхньої інтенсивності.

*Предмет дослідження* – методи і засоби виявлення дефектів на зображеннях поверхонь матеріалів, які базуються на розподілених ознаках їхньої інтенсивності, що дадуть змогу ефективно виділяти області з аномальними інтенсивностями, які відповідають дефектам поверхні.

*Мета роботи* – розробити та протестувати метод виявлення дефектів на зображеннях поверхонь матеріалів, робота якого базується на розподілених ознаках їхньої інтенсивності, що дасть змогу ефективно виділяти області з аномальними інтенсивностями, які відповідають дефектам поверхні, без потреби у великих навчальних вибірках або використанні великих обчислювальних потужностей.

Для досягнення зазначеної мети визначено такі основні завдання дослідження:

- здійснити аналіз літературних джерел щодо методів виявлення дефектів поверхонь матеріалів із зображень, що дасть змогу визначити переваги та недоліки наявних підходів і обґрунтувати вибір допустимих архітектур;
- розробити алгоритм аналізу зображень для виявлення дефектів металів, який забезпечить ефективне виявлення дефектів без навчання складних моделей;
- розробити програмне забезпечення виявлення дефектів на зображеннях металів, яке допоможе дослідити розроблений метод із різними вхідними параметрами, та визначити його точність на різних зображеннях;
- зібрати матеріали для тестування розробленого методу, які уможливають проведення різних тестів із запропонованим методом виявлення дефектів;

- здійснити тестування розробленого методу, що дозволить оцінити його придатність для подальшого використання у системах виявлення дефектів.

### ВИКЛАД ОСНОВНОГО МАТЕРІАЛУ

**Особливості запропонованого методу.** Запропоноване використання спеціальних кумулятивних гістограм. Основна ідея полягає в тому, щоб розбити зображення на рядки або стовпчики і проаналізувати їх по черзі за допомогою  $N$ -ної кількості гістограм. Кожна гістограма для роботи використовує лише один інтервал інтенсивності. Наш метод також передбачає визначення користувачем мінімальної ( $MinInt$ ) та максимальної ( $MaxInt$ ) інтенсивностей. За допомогою них будеться інтервал виявлення ( $detInt$ ), щоб метод міг пропустити не потрібні пікселі для аналізу. Наприклад, якщо фон зображення повністю чорний, то встановивши  $MinInt = 10$  всі пікселі з інтенсивністю менше 10 будуть проігноровані, аналогічно з білим фоном. Після цього метод обчислює інтервал інтенсивності для кожної кумулятивної гістограми за формулами:

$$\begin{aligned} detInt &= MaxInt - MinInt; \\ intRange &= \left\lfloor \frac{MaxInt - MinInt}{N} \right\rfloor; \\ intBeg_i &= intEnd_{i-1}, \forall i \in N; \\ intEnd_i &= i \cdot intRange + MinInt, i = \overline{0, N}, \end{aligned} \quad (1)$$

де:  $intBeg_1 = MinInt$ ;  $intEnd_N = MaxInt$ . Використовуючи формулу (1), для побудови кумулятивних відображень інтервали будуть однаковими за розміром, якщо  $(MaxInt - MinInt) / N := 0$ , в іншому випадку останній інтервал буде трохи більшим.

Після цього будуються кумулятивні гістограми для кожного рядка або стовпця для всіх інтервалів використовуючи формулу 2. Не зменшуючи загальності доведення, будемо працювати тільки зі рядками, з стовпцями все буде аналогічно.

$$hist[i][k] = \frac{\sum_{j=0}^W 1, if(intensity(column, j) == k)}{count(hist[i])}, \forall i \in N, k = \overline{intBeg_i, intEnd_{i-1}}, \quad (2)$$

де:  $k$  – поточна інтенсивність пікселя робочої гістограми,  $W$  – ширина зображення (кількість пікселів у рядку),  $intensity$  – функція отримання інтенсивності пікселя з координатами  $(x, y)$ ,  $count(hist[i])$  – підрахунок кількості пікселів у рядку, що потрапили до поточного інтервалу інтенсивності гістограми.

Метод використовує спеціальну візуалізацію кумулятивних гістограм, адже якщо просто візуалізувати усі гістограми у вигляді графіків, чи діаграм то це буде дуже малоінформативно для виявлення дефектів.

Найзручнішим способом для подальшого аналізу – є створення зображення рядка (або стовпчика, залежно від розбиття зображення, алгоритм побудови аналогічний) шириною в один піксель для кожної гістограми (рис. 1).




Рис. 1. Візуалізація зображення кумулятивної гістограми

Це зображення створюється за наступним алгоритмом:

1. Довжина рядка  $W$  дорівнює інтервалу гістограми.
2. Для кожного пікселя з інтенсивністю ( $k$ ) на гістограмі будуюмо піксель на візуалізації з інтенсивністю ( $p$ ) за формулою:

$$p = \lfloor \text{hist}[k] \cdot 255 \rfloor \quad p = \lfloor \text{hist}[k] \rfloor \quad (3)$$

3. Всі пікселі у рядку розміщуються за наступним правилом: піксель з початку інтервалу розміщується на початку рядка, наступний піксель розміщується правіше, а піксель з кінця інтервалу розміщується вкінці рядка.

Для одного рядка будуються  $N$  гістограм, візуалізувавши всі ці гістограми, розміщуємо рядок один за одним за їхнім індексом (рис. 2). Таким чином будуються кумулятивна візуалізація рядка зображення.



Рис. 2. Візуалізація рядка за допомогою 3 гістограм

Для аналізу зображення рекомендуємо створювати  $N = \text{MaxInt} - \text{MinInt}$  гістограм для кожного рядка. Це означає, що для кожної інтенсивності будуються окрема кумулятивна гістограма та її візуалізація. Після аналізу стовпчика зображення отримуємо рядок візуалізації шириною  $N$ , і кожен піксель у цьому рядку вказує на те, чи присутній піксель з такою інтенсивністю у рядку аналізованого зображення. Якщо він присутній у рядку візуалізації, то піксель є білим, інакше піксель є чорним, що відображено на рис. 3, проаналізувавши який можна зазначити що у рядку зображення присутні тільки 4 різні інтенсивності.




Рис. 3. Візуалізація рядка за допомогою 255

Під час аналізу зображення рядок за рядком, будуються нове зображення, об'єднуючи візуалізовані рядки один за одним. В результаті отримуємо кумулятивну візуалізацію зображення (рис. 4, зображення для аналізу взято із ресурсу freepic, візуалізація за стовбцями). З цієї візуалізації можна легко побачити, що вся картинка не має темних пікселів. Проте, на всьому зображенні є пікселі середніх тонів та яскраві пікселі. Також із візуалізації видно, що деякі темні елементи розміщені в центрі та в правій частині зображення (це гори внизу зображення).




Рис. 4. Кумулятивне відображення зображення

**Алгоритм виявлення дефектів.** Основна ідея дефектоскопії металу полягає в тому, щоб перевірити, чи присутній на зображенні будь-який дефект. Для цієї задачі розглянемо кумулятивне відображення з максимальною кількістю інтервалів. Зображення без дефектів повинно виглядати на відображенні як вузька лінія, оскільки метал чистий і при хорошому освітленні є монотонним. Якщо поверхня металу має якісь дефекти, то на фото можна замітити затемнені або освітлені плями, а на кумулятивній візуалізації – піки над, або під лінією основної інтенсивності. Наявність цих піків сигналізує про те, що поверхня металу має певні дефекти, що видно на візуалізаціях кумулятивних гістограм на рис. 5.




Рис. 5. Кумулятивна візуалізація зображення з дефектами: а) – аналіз по стовпчиках, б) – аналіз по рядках)

Для визначення наявності аномальних піків методу необхідно дізнатися від користувача толерантність виявлення у відсотках –  $DetTol$ . Це значення показує, наскільки широким може бути рядок, який алгоритм сприйматиме як такий, що не має дефекту. Наступним кроком для алгоритму є визначення інтенсивності чистої поверхні металу –  $MainInt$ . Для її визначення алгоритм обчислює інтенсивність з найбільшою частотою появи на фото, та приймає її як інтенсивність чистого металу, тому що якщо найчастіша інтенсивність належить до області дефекту, це означає, що принаймні 50 % поверхні пошкоджено. У цьому випадку наш алгоритм визначає чисту поверхню як дефектну, але результат аналізу зображення буде таким самим, тільки бездефектна область буде вважатись дефектною.

Після цього алгоритм створює інтервал допуску ( $tollInt$ ) інтенсивностей (формула 4), всередині якого всі пікселі не впливають на виявлення дефектів.

$$tollInt = [MainInt - DetTol] \quad (4)$$

де  $detInt$  – інтервал виявлення з формули 1.

Інтервал допуску потрібен тому, що освітлення поверхні не може бути ідеальним, і саме так алгоритм пропускає можливі дефекти освітлення. Якби освітлення поверхні було ідеальним, можна було б встановити допуск на виявлення від 0 до 1 %, і алгоритм ідентифікував би будь-які білі пікселі за межами  $MainInt$  як дефект, і це було б правильно, адже рівномірно освітлена поверхня була б однотонною.

Роботу алгоритму виявлення дефектів можна побачити на рис. 6, де зеленими лініями позначено інтервал на кумулятивній візуалізації, який ігнорується при виявленні дефектів.




Рис. 6. Зображення для аналізу – а), кумулятивне відображення із 5 % допуском виявлення дефектів – б), кумулятивне відображення із 15 % допуском виявлення дефектів в)

Після аналізу з 5 % допуском (рис. 6 б) алгоритм виявляє дефекти, і як можна помітити на рис. 6а, це може бути правильно, тому що метал не ідеальний і має деякі дивні градієнти. З допуском виявлення 15 % (рис. 6 в), всі білі пікселі знаходяться всередині інтервалу, і алгоритм каже нам, що дефектів на зображенні немає.

Таке зображення важко аналізувати не лише комп'ютеру, але й людині. Розглянемо зображення з явними дефектами (рис. 7). На цьому зображенні можна побачити, що з правого боку є дві чорні точки, які є очевидними дефектами.




Рис. 7. Зображення з явними дефектами

Спробуємо проаналізувати це зображення з 5 % (Рис. 8 а) і 15 % (Рис. 8 б) допуском на виявлення.




Рис. 8. Кумулятивні візуалізації з 5 % толерантності виявлення дефектів (а) та з 15 % толерантності виявлення дефектів (б)

Зображення на рис. 7 досить монотонне, але центр трохи яскравіший за боки, тому основна лінія інтенсивності не горизонтальна, а трохи нахилена донизу. З цієї причини 5 % допуску недостатньо. Щоб виявити тільки наявність дефектів, а не градієнт через нерівномірне освітлення, було встановлено 15 % допуску. В обох варіантах алгоритм виявляє дефекти на зображенні, але у варіанті 15 % алгоритм виявляє дефекти тільки через ці чорні точки, а у варіанті 5 % алгоритм також вказує на цей градієнт як на дефект.

Найскладнішою проблемою є визначення відсотка толерантності виявлення. Перш за все, користувач повинен створити систему освітлення та фотографування металевих поверхонь. Після цього зробити кілька різних знімків з дефектами і без них, щоб проаналізувати, наскільки сильним є градієнт. Потім підібрати відповідний допуск виявлення, щоб пропустити всі градієнти на фото через неідеальне освітлення. Наприклад, у нас є рис. 6а з темною верхньою частиною і світлою нижньою. Якщо вибрати допуск виявлення 8 %, та всі фотографії з того самого стенду матимуть подібні градієнти, і користувачу більше не потрібно буде змінювати допуск виявлення. Так само якщо проаналізувати зображення з рис. 7, можна побачити, що центральна частина зображення яскравіша, ніж бокові. Проаналізувавши дві або три фотографії, користувач вибирає допуск виявлення, наприклад, 10 % після чого програмне забезпечення може легко аналізувати фотографії з тієї ж системи, навіть якщо колір металу яскравіший або темніший, оскільки цей допуск на виявлення залежить від системи освітлення та фотосистеми, а не від поверхні металу.

Щоб виявити наявність дефекту, алгоритму не потрібно аналізувати усе зображення кумулятивною візуалізацією. Алгоритм використовує масив гістограм і перевіряє їх одну за одною (також цей процес можна розпаралелити і перевіряти усі зразу). У кожному стовпчику є  $N$  гістограм, і алгоритм перевіряє лише гістограми за межами  $tolInt$ . Якщо будь-яка гістограма має 1 (що означає білий піксель на візуалізації), то зупиняється аналіз і констатується факт виявленого дефекту. Якщо жодна гістограма не має 1, то констатується факт відсутності дефектів.

**Аналіз роботи досліджуваного алгоритму.** Для дослідження точності виявлення дефектів використані усі 3 набори даних описані вище. Розроблено програмне забезпечення, що реалізовує запропонований алгоритм, та обчислює метрики: Precision, Recall, F1-score та Accuracy [4].

Для забезпечення точності вимірювання було проведено по 3 експерименти із кожним порогом виявлення на усіх наборах даних, а значення отримані в результаті експериментів були усереднені, та зведені у таблицях 1-6.

Спочатку були проведені експерименти для кожного із наборів даних з кроком порогу виявлення дефектів від 2 % до 3 %, щоб виявити на якому інтервалі буде найбільша точність, після цього для вибраного інтервалу експерименти проводяться із кроком в 1 % щоб встановити найвищу можливу точність на кожному із наборів даних.

Таблиця 1.

**Дослідження точності на зображеннях малих розширень**

Поріг, %	Кількість правильно класифікованих	Кількість неправильно класифікованих	TP	TN	FP	FN
3 %	250	50	250	0	50	0
5 %	261	39	250	11	39	0
8 %	284	16	250	32	16	0
12 %	279	21	229	50	0	21
15 %	199	101	149	50	0	101
18 %	155	145	105	50	0	145

Найбільше правильно класифікованих зображень в околі порогу виявлення 8 % – 284 зображення, тому додаткові дослідження проведено для порогів від 6 % до 11 %, щоб встановити при якому саме значення порога виявлення дефектів результат буде найкращим на даному наборі даних.

Таблиця 2

**Детальніше дослідження точності на зображеннях малих розширень**

Поріг, %	Кількість правильно виявлених	Кількість неправильно виявлених	TP	TN	FP	FN
6 %	270	30	220	20	30	0
7 %	281	19	250	31	19	0
8 %	284	16	250	34	16	0
9 %	288	12	250	38	12	0
10 %	294	6	249	45	5	1
11%	292	8	243	49	1	7

Найвища точність досягнута при порозі виявлення 10 %. Для цього порогу обчислені метрики: Precision = 98.03 %, Recall = 99.6 %, F1 = 98.81 %, та Accuracy = 98 %, що є дуже хорошим результатом для зображень малої роздільної здатності.

Таблиця 3.

**Дослідження точності на зображеннях великих розширень**

Поріг, %	Кількість правильно виявлених	Кількість неправильно виявлених	TP	TN	FP	FN
5 %	70	30	70	0	30	0
8 %	73	27	70	3	27	0
12 %	78	22	70	8	22	0
15 %	86	14	69	17	13	1
18 %	76	24	57	19	11	13
20 %	69	31	48	21	9	22

Найвища точність для цього набору даних спостерігається на відрізку 12 % - 18 %, на якому були проведені детальніші дослідження точності роботи.

Таблиця 4.

**Детальніше дослідження точності на зображеннях великих розширень**

Поріг, %	Кількість правильно виявлених	Кількість неправильно виявлених	TP	TN	FP	FN
13 %	82	18	70	12	18	0
14 %	85	15	70	15	15	0
15 %	86	14	69	17	13	1
16 %	81	19	64	17	13	6
17 %	79	21	61	18	12	9

Найвища точність досягнута при порозі виявлення 15 % – Precision = 84.15 %, Recall = 98.57 %, F1 = 90.78 %, та Accuracy = 86 %, що є дуже результатом для зображень великої роздільної здатності, адже досягти на таких зображеннях рівномірного освітлення значно складніше, і як видно із експериментів поріг виявлення дефектів збільшився на 5 % при найкращій точності.

Таблиця 5.

**Дослідження точності на різних зображеннях**

Поріг, %	Кількість правильно виявлених	Кількість неправильно виявлених	TP	TN	FP	FN
5 %	56	44	50	6	44	0
8 %	69	31	50	19	31	0
12 %	80	20	50	30	20	0
15 %	83	17	45	38	12	5
18 %	75	25	35	40	10	15
20 %	74	26	32	42	8	18

Найвища точність для цього набору даних спостерігається на відрізку 12 % - 18 %, на якому були проведені детальніші дослідження точності роботи.

Таблиця 6.

**Детальніше дослідження точності на різних зображеннях**

Поріг, %	Кількість правильно виявлених	Кількість неправильно виявлених	TP	TN	FP	FN
12 %	80	20	50	30	20	0
13 %	83	17	49	34	16	1
14 %	82	18	46	36	14	4
15 %	83	17	45	38	12	5
16 %	77	23	39	38	12	11
17 %	77	23	38	39	11	12
18 %	75	25	35	40	10	15

У результаті експериментів видно що при 13 % та 15 % порогах виявлення кількість правильно класифікованих зображень рівна. Різниця є тільки у тому що при 13 % більше дефектних зображень виявлено, але також і більше бездефектних класифіковано як дефектні. Підраховано для обох випадків метрики.

Поріг 13 % – Precision = 75.38 %, Recall = 98 %, F1 = 85.21 %, та Accuracy = 83 %.

Поріг 15 % – Precision = 78.94 %, Recall = 90 %, F1 = 84.11 %, та Accuracy = 83 %.

З 13 % порогом виявлення метрика F1 краща, тому його в візьмем за найкращий варіант.

Отримані результати з усіх трьох наборів даних переконливо свідчать про надійність та практичну цінність запропонованого підходу, що базується на кумулятивному відображенні зображень. Незважаючи на значні відмінності у роздільній здатності, умовах освітлення та типах дефектів, алгоритм стабільно демонстрував високу точність, а оптимальні пороги забезпечували збалансовані значення точності та повноти. Це вказує на те, що метод не лише ефективно розпізнає реальні дефекти, але й підтримує низький рівень хибних спрацювань за умови правильно підібраних параметрів. Така стабільність на різномірних даних підтверджує, що кумулятивне перетворення дозволяє виокремити істотні структурні відмінності між дефектними та бездефектними ділянками зображення, що робить алгоритм дієвим та адаптивним інструментом для задач промислового контролю якості поверхонь металів.

**ОБГОВОРЕННЯ ОТРИМАНИХ РЕЗУЛЬТАТІВ ДОСЛІДЖЕННЯ**

Проведені експерименти підтверджують, що запропонований метод аналізу поверхонь металів на основі кумулятивних відображень забезпечує високу ефективність виявлення дефектів у різних умовах знімання. Для зображень малої роздільної здатності з набору даних NEU-DET (200×200 пікселів) було досягнуто точності понад 98 %, тоді як для великих зображень з набору даних GC10-DET (роздільна здатність понад 1000×1000 пікселів) точність перевищує 86 %. Це свідчить про універсальність методу щодо масштабу зображення та стійкість до зміни умов освітлення.

Отримані результати є конкурентоспроможними відносно відомих підходів до виявлення поверхневих дефектів. У роботі [1] для аналізу великих об'єктів використано поєднання фільтра Гауса, оператора Собеля та алгоритму сегментації КЗМ, що дало близько 88 % правильних класифікацій, але потребує розбиття зображення на велику кількість блоків та складнішого оброблення меж.

Нейромережеві рішення на базі U-Net, двопотокових CNN або трансформаторів зору демонструють високу точність для конкретних типів дефектів, але вимагають великих анотованих наборів даних і суттєвих обчислювальних ресурсів для навчання та інференсу.

На цьому тлі запропонований метод, що спирається на статистичний аналіз кумулятивних гістограм без обов'язкового навчання моделі, дає змогу досягти співмірної точності за значно простішої реалізації та нижчої вартості впровадження.

Важливою перевагою підходу є гнучкість налаштування інтервалу інтенсивностей та допуску виявлення. Використання параметрів *MinInt*, *MaxInt* та *DetTol* дає змогу компенсувати вплив неідеального освітлення і відфільтрувати суто освітлювальні градієнти, зосередившись на структурних відхиленнях текстури, що відповідають реальним дефектам.

Це робить метод придатним для різних виробничих ліній, де освітлення та оптична схема можуть відрізнятися, а переналаштування зводиться переважно до підбору порога толерантності для конкретного стенду.

Разом з тим результати експериментів показали низку обмежень. По-перше, коректність роботи алгоритму істотно залежить від правильно обраного значення *DetTol* – надто малий допуск призводить до хибних спрацювань на плавних освітлювальних градієнтах, тоді як надто великий може пропустити слабо виражені дефекти, особливо на поверхнях з неоднорідним рельєфом. Для кожної системи освітлення потрібен попередній етап калібрування на репрезентативних прикладах бездефектних та дефектних зразків. Що у подальших дослідженнях планується автоматизувати.

По-друге, запропонований метод орієнтований насамперед на виявлення факту наявності дефекту, але не виконує його детальної класифікації за типами, що певною мірою обмежує діагностичні можливості

системи. Для вирішення цієї проблеми у подальших дослідженнях планується: з допомогою запропонованого метода виділяти дефектні області на зображеннях, та уже класифікувати тільки виділені області а не усе зображення повністю, що дозволить використовувати простіші архітектури нейронних мереж, та працювати їм тільки з дефектними ділянками а не з цілими зображеннями, що має ефективно вплинути на точність та час аналізу зображень.

Отже, внаслідок виконаної роботи можна сформулювати такі наукову новизну та практичну значущість результатів дослідження.

*Наукова новизна отриманих результатів дослідження* – отримав подальший розвиток метод аналізу зображень для виявлення дефектів металів за допомогою розподілених ознак інтенсивності зображення, який, на відміну від наявних методів будує кумулятивні відображення, та використовує їх для визначення чи присутні дефекти на зображенні, що дає змогу ідентифікувати наявність будь-яких дефектів з високою точністю при використанні однакової системи освітлення поверхні металу.

*Практична цінність результатів дослідження* – розроблений метод може бути інтегрований у промислові системи технічного контролю як легкий попередній фільтр: він дає змогу швидко відсіяти зображення із підозрою на дефекти і передати їх на подальший аналіз більш складним, ресурсомістким моделям, зокрема нейронним мережам, відповідальним за класифікацію типів ушкоджень.

### ВИСНОВКИ З ДОСЛІДЖЕННЯ ТА ПЕРСПЕКТИВИ ПОДАЛЬШИХ РОЗВІДОК

У результаті проведеного дослідження розроблено та апробовано новий метод виявлення дефектів на поверхнях металів, що ґрунтується на аналізі кумулятивних гістограм інтенсивності зображення. Запропонований підхід дає змогу ефективно виділяти області з аномальними інтенсивностями, які відповідають дефектам поверхні, без потреби у великих навчальних вибірках або складних моделей глибинного навчання.

Розроблений алгоритм показав високу точність у процесі тестування на різних наборах даних. Для зображень малої роздільної здатності досягнуто точності понад 98 %, а для зображень великої роздільної здатності – понад 86 %. Це свідчить про універсальність методу та його здатність працювати з металами різного розміру і якості освітлення. Експерименти довели, що раціональний поріг толерантності виявлення залежить від системи освітлення та може бути налаштований індивідуально для кожного виробничого середовища.

Перевагами методу є простота реалізації, невисокі обчислювальні витрати та можливість швидкої адаптації до нових типів поверхонь без повторного навчання моделі. Алгоритм може бути інтегрований у промислові системи контролю якості для попереднього виявлення дефектів та зменшення частки бракованої продукції.

Перспективами подальших досліджень є поєднання запропонованого підходу з методами покращення зображень, для зменшення впливу систем освітлення на результати. Використання методу кумулятивних відображень для виділення країв дефектів на великих зображеннях, що у поєднанні із нейронними мережами дозволить швидко та ефективно класифікувати різні типи дефектів, а також оптимізація алгоритму для роботи в реальному часі з використанням графічних процесорів. Такий напрям розвитку сприятиме створенню повністю автоматизованих систем контролю якості матеріалів із високою точністю та швидкодією.

### References

1. Peng, Yeping, et al. (2019). Automated product boundary defect detection based on image moment feature anomaly. *IEEE access*, vol. 7, 52731–52742. <https://doi.org/10.1109/access.2019.2911358>
2. Bagan, Y. A. (2020). Texture segmentation algorithms based on statistical features. URL: [http://dspace.wnu.edu.ua/bitstream/316497/40538/1/Bagan\\_MP\\_2020.pdf](http://dspace.wnu.edu.ua/bitstream/316497/40538/1/Bagan_MP_2020.pdf)
3. Chmutov, Yu. (2021). Development of an image classification method using cluster structures for fast data retrieval. URL: <https://openarchive.nure.ua/items/d24e02b3-9e57-42e5-b055-f873bda6f6139>
4. Chen, Xiaoyan, et al. (2020). A light-weighted CNN model for wafer structural defect detection. *IEEE access*, vol. 8, 24006–24018. <https://doi.org/10.1109/access.2020.2970461>
5. Steshenko, Y. V. (2023). Improvement of algorithms for segmenting images of surface defects in metal products. Master's thesis, 151 "Automation and Computer-Integrated Technologies". Kyiv, 111 p. URL: [https://ela.kpi.ua/bitstream/123456789/56273/1/Steshenko\\_magistr.pdf](https://ela.kpi.ua/bitstream/123456789/56273/1/Steshenko_magistr.pdf)
6. Duan, C. (2020). Two-Stream convolutional neural network based on gradient image for aluminum profile surface defects classification and recognition. Chunmei Duan, Taochuan Zhang. *IEEE access*, vol. 8, 172152–172165. <https://doi.org/10.1109/access.2020.3025165>
7. Simões Hoffmann, L. F., Parquet Bizarria, F. C., & Parquet Bizarria, J. W. (2020). Detection of liner surface defects in solid rocket motors using multilayer perceptron neural networks. *Polymer testing*, vol. 88, article ID 106559. <https://doi.org/10.1016/j.polymeresting.2020.106559>
8. Smith, A. D., Du, Sh., & Kurien, A. (2023). Vision transformers for anomaly detection and localisation in leather surface defect classification based on low-resolution images and a small dataset. *Applied sciences*, vol. 13, no. 15, article ID 8716. <https://doi.org/10.3390/app13158716>
9. Zhang, C., Cui, J., & Liu, W. (2022). Multilayer feature extraction of AGCN on surface defect detection of steel plates. *Computational intelligence and neuroscience*, vol. 2022, 1–13. <https://doi.org/10.1155/2022/2549683>

10. Ngoc Tuyen Le, et al. (2020). Novel framework for optical film defect detection and classification. *IEEE access*, vol. 8, 60964–60978. <https://doi.org/10.1109/access.2020.2982250>
11. Chen Z., et al. (2023). Surface defect detection of industrial components based on vision. *Scientific Reports*, vol. 13, article number 22136 (2023). <https://doi.org/10.1038/s41598-023-49359-9>
12. Zhou C., et al. (2023). Metal surface defect detection based on improved YOLOv5. *Scientific Reports*, vol. 13, no. 15, article number 20803 (2023). <https://doi.org/10.1038/s41598-023-47716-2>