

УДК 004.932

Р. В. Маслій, В. В. Гармаш, П. П. Ковальчук, В. В. Кабачій

## АНАЛІЗ МЕТОДІВ ЗНАХОДЖЕННЯ АНОМАЛІЙ У ЗОБРАЖЕННЯХ

Вінницький національний технічний університет, Вінниця

**Анотація.** Автоматичне виявлення аномалій має велике значення в промисловості, дистанційному зондуванні та медицині. Важливо мати можливість автоматично обробляти великі обсяги даних для виявлення, наприклад, хімічних об'єктів на багатоспектральних та гіперспектральних супутникових зображеннях, морських мін на сонарних зображеннях бічного зондування, або дефектів у виробничих моніторингових застосуваннях. Автоматичне виявлення аномальних структур на довільних зображеннях стосується задачі пошуку невідповідних шаблонів відносно нормального стану зображення. Це важка задача в комп'ютерному зорі, оскільки не існує чіткого і прямолінійного визначення того, що є нормальним чи не нормальним для даного довільного зображення. Практична важливість проявляється у розробці алгоритмів та моделей, які автоматично можуть виявляти незвичайні або аномальні образи у зображеннях. Проведено аналіз методів знаходження аномалій у зображеннях з точки зору можливості застосування до довільних зображень. Наведена класифікація методів виявлення аномалій за критеріями залучених підходів та моделей що використовуються для моделювання фону. Розглянуті методи, які використовують машинне навчання, такі як однокласовий метод опорних векторів та варіаційний автоенкодер, методи виявлення аномалій на основі найближчих сусідів, на основі кластеризації, статистичне виявлення аномалій, спектральне виявлення аномалій, виявлення аномалій за допомогою інформаційної теорії. Основна увага приділена методам, що класифікують за підходом до моделювання фону. Розглянуто п'ять категорій методів, що моделюють фон, базуючись на функції щільності ймовірності, глобальній та локальній однорідності, розрідженості та самоподібності. Для застосувань виявлення аномалій рекомендовано використовувати методи, у яких модель фону найкраще описує очікуваний фон, на якому відсутні аномалії, оскільки це, як правило, призводить до найкращої ефективності. На основі досліджень було встановлено, що ефективна універсальна модель виявлення аномалій у довільних зображеннях повинна: використовувати лише самоподібну чи розріджену модель фону; обробляти залишкове зображення як стохастичний процес для виявлення аномалій, як аномалій у кольоровому шумі; попередньо обробляти залишкове зображення перед виявленням аномалій.

**Ключові слова:** моделювання, обробка зображення, виявлення аномалій, фонові модель, машинне навчання.

**Abstract.** Automatic anomaly detection is of great importance in industry, remote sensing, and medicine. It is important to be able to automatically process large amounts of data to detect, for example, chemical objects in multispectral and hyperspectral satellite images, sea mines in side-scan sonar images, or defects in industrial monitoring applications. Automatic detection of anomalous structures on arbitrary images refers to the task of finding inappropriate patterns relative to the normal state of the image. This is a difficult task in computer vision, since there is no clear and straightforward definition of what is normal or not normal for a given arbitrary image. The practical importance is manifested in the development of algorithms and models that can automatically detect unusual or anomalous patterns in images. An analysis of methods for finding anomalies in images from the point of view of the possibility of application to arbitrary images has been carried out. The classification of anomaly detection methods according to the criteria of the involved approaches and models used for modeling the background is presented. Methods that use machine learning, such as one-class support vector method and variational autoencoder, nearest neighbor-based anomaly detection, clustering-based anomaly detection, statistical anomaly detection, spectral anomaly detection, anomaly detection using information theory are discussed. The main attention is paid to the methods classified according to the background modeling approach. Five categories of background modeling methods based on probability density function, global and local homogeneity, sparsity, and self-similarity are considered. For anomaly detection applications, it is recommended to use methods in which the background model best describes the expected anomaly-free background, as this generally results in the best performance. On the basis of research, it was established that an effective universal model for detecting anomalies in arbitrary images should: use only a self-similar or sparse background model; process the residual image as a stochastic process to detect anomalies, such as anomalies in color noise; preprocess the residual image before detecting the anomaly.

**Key words:** modeling, image processing, anomaly detection, background model, machine learning.

**DOI:** <https://doi.org/10.31649/1999-9941-2024-59-1-13-22>.

### Вступ

У сучасному світі машинне навчання стає все більш важливою і перспективною галуззю, яка викликає значний інтерес серед дослідників і фахівців. Вже зараз його застосування суттєво змінює багато аспектів нашого повсякденного життя, включаючи медицину, фінанси, автономну навігацію, розпізнавання мови та інші галузі. Одним із важливих напрямків машинного навчання є виявлення аномалій у зображеннях.

Автоматичне виявлення аномальних структур на довільних зображеннях стосується задачі пошуку невідповідних шаблонів відносно нормального стану зображення. Це важка задача в комп'ютерному зорі, оскільки не існує чіткого і прямолінійного визначення того, що є нормальним чи не нормальним для даного довільного зображення.

### Актуальність

Виявлення аномалій у зображеннях має велику практичну важливість та є досить актуальним. Практична важливість проявляється у розробці алгоритмів та моделей, які автоматично можуть виявляти незвичайні або аномальні образи у зображеннях. Серед таких аномалій можуть бути неочікувані об'єкти,

пошкодження зображень, помилки під час зйомки або будь-які інші зміни, які відхиляються від звичайного стану.

Автоматичне виявлення аномалій має велике значення в промисловості, дистанційному зондуванні та медицині. Важливо мати можливість автоматично обробляти великі обсяги даних для виявлення, наприклад, хімічних об'єктів на багатоспектральних та гіперспектральних супутникових зображеннях, морських мін на сонарних зображеннях бічного зондування, або дефектів у виробничих моніторингових застосуваннях [1]. Це виявлення може бути виконано за допомогою будь-якого пристрою для зображень, від камер до скануючих електронних мікроскопів.

Останнім часом методи виявлення аномалій у зображеннях стрімко розвиваються, тому у іноземних виданнях з'являється велика кількість статей присвячених цій задачі, зокрема і оглядових, наприклад робота [1], в україномовних же виданнях таких статей обмаль. Крім того, у оглядових статтях присвячених даній тематиці в переважній більшості розглядаються методи виявлення аномалій, які є залежними від конкретного застосування без врахування можливості використання кожного методу в інших застосуваннях, тобто без оцінки його універсальності. Наприклад, методи виявлення аномалій розроблені для медичних зображень, скоріш за все не будуть працювати достатньо надійно при їх використанні у промисловій інспекції якості продукції. Саме тому виникає потреба у проведенні аналізу методів виявлення аномалій, з акцентування уваги на довільних зображеннях для створення нового універсального методу, що може бути ефективно використаний у різних сферах застосування.

### Мета

Метою дослідження є порівняння методів виявлення аномалій на довільних зображеннях та визначення більш універсального, для якого визначені основні параметри.

### Задачі

1. Розглянути класифікацію методів виявлення аномалій за критеріями залучених підходів та моделей що використовуються для моделювання фону
2. Здійснити аналіз літературних джерел методів згідно класифікації до моделювання фону.
3. Здійснити аналіз розглянутих методів виявлення аномалій з точки зору можливості застосування до довільних зображень.

### Розв'язання задач

У оглядовій статті [1] встановлюється розрізнення між точковими аномаліями, контекстуальними аномаліями, колективними аномаліями, в залежності від того, чи є фон сталим чи змінним і чи має аномалія більший масштаб, ніж початкові вибірки. Також робиться розрізнення між контрольованим, частково контрольованим та не контрольованим навчанням для виявлення аномалій. Крім того, автори пропонують таку класифікацію залучених підходів до виявлення аномалій у зображеннях:

1. Методи, які використовують машинне навчання. У цих методах класифікатор навчається відрізнити звичайні дані від аномальних у просторі ознак. Класифікація може бути багатокласовою (нормальні та аномальні дані) або однокласовою (класифікатор навчається визначити лише нормальні дані, тобто навчається знаходити межі навколо нормальних даних).

2. Виявлення аномалій на основі найближчих сусідів. Основне припущення цих методів полягає в тому, що нормальні екземпляри даних у просторі ознак знаходяться близько один до одного, тоді як аномалії знаходяться далеко від своїх найближчих сусідів. Це може бути виміряно за допомогою відстані до  $k$ -го найближчого сусіда або за відносною щільністю.

3. Виявлення аномалій на основі кластеризації. Ці методи припускають, що екземпляри нормальних даних належать до кластера у просторі ознак, тоді як аномалії визначаються як ті, що знаходяться далеко від центру їхнього найближчого кластера.

4. Статистичне виявлення аномалій. Аномалії визначаються як спостереження, ймовірно невірні для генерації стохастичною моделлю фону. Таким чином, аномалії знаходяться в областях з низькою ймовірністю моделі фону.

5. Спектральне виявлення аномалій. Основним інструментом цих методів є аналіз головних компонентів (АГК) та його узагальнення. Принцип полягає в тому, координати аномалій відхиляються відносно нормальних координат АГК.

6. Виявлення аномалій за допомогою інформаційної теорії. Ці підходи аналізують інформаційний зміст набору даних за допомогою мір інформаційної теорії, таких як колмогорова складність, ентропія, відносна ентропія та інші.

Більшість досліджень в галузі виявлення аномалій проводяться шляхом моделювання розподілів фонових даних для оцінки ймовірності того, що тестові дані не належать до таких розподілів [1]. Тому основні методи виявлення аномалій можна класифікувати за їхнім підходом до моделювання фону.

Кожен метод виявлення повинен виконувати три завдання:

а) моделювати "фон" без аномалій. Ця модель фону може бути створена з вибірок різного розміру, взятих з даного зображення (або бази даних зображень): пікселі (наприклад, у гіперспектральних зображеннях), фрагменти, локальні ознаки (наприклад, вейвлет коефіцієнти).

б) визначити вимір, який оцінює, наскільки віддалені вибірки спостережуваних даних від їхньої моделі фону. Зазвичай ця міра - це ймовірність помилкового спрацювання (або, очікування кількості помилкових спрацювань), пов'язане з кожною вибіркою.

в) визначити відповідне (емпірично або статистично обґрунтоване) значення порогу на вимірі, отриманому у пункті б.

Класифікація методів здійснюється за структурою їхньої моделі фону та способом обчислення відстані між вибірками та моделлю фону.

Розглянемо докладно п'ять загальних структур для фону:

1. Фон може бути моделюваний функцією щільності ймовірності, яка може бути параметричною, такою як гауссова, гауссова суміш, або отримана інтерполяцією з вибірок за допомогою методу оцінки щільності ядра; ця структура веде до виявлення аномалій шляхом перевірки статистичних гіпотез;

2. Фон глобально однорідний (використовується еталонне зображення, глобальна трансформація Фур'є або модель згорткової нейронної мережі, як правило, з наступним відніманням фону);

3. Фон локально просторово однорідний (методи "центру-околу");

4. Фон є розрідженим у визначеному словнику або базі (моделі варіаційного розкладання).

Фон є самоподібним (у нелокальному розумінні, що для кожної вибірки існують інші подібні вибірки у зображенні).

#### *Стохастичні моделі фону*

Принцип роботи цих методів виявлення аномалій полягає в тому, що аномалії виникають в областях з низькою ймовірністю за фонову моделлю.

*Гауссова модель фону.* Припущення про гаусівський фон може застосовуватися до фрагментів зображень. У [2] запропонували побудувати гауссову модель фону на основі випадкових  $2 \times 2$  фрагментів зображення в гіперспектральному зображенні. Якщо отримано цю модель фону ( $\mu$ ;  $\Sigma$ ), то аномальні ( $2 \times 2$ ) фрагменти виявляються за допомогою порогового значення для їх відстані Махаланобіса до гауссової моделі фону. Вибір блоків зображень для оцінки гауссової моделі фрагмента ( $\mu$ ;  $\Sigma$ ) виконується за допомогою процедури RANSAC вибираючи випадкові фрагменти зображення і поступово виключаючи аномальні.

У роботі [3] виконується оцінка фону в локальному просторі ознак головних компонентів (це також передбачає побудову гауссової моделі). Потім для виявлення аномальних пікселів, а саме тих, що мають надзвичайно велику відстань Махаланобіса до нормального розподілу, використовується перевірка статистичних гіпотез. Це виявляє потенційно аномальні пікселі, які потім групуються і фільтруються морфологічними операторами. Використання цього фільтру вказує на те, що перший етап може давати багато помилкових спрацювань.

*Оцінка щільності розподілу функції ймовірності.*

У роботі [4] автори використовують моделі гауссових випадкових полів Маркова для виявлення дефектів у тканинах. У цих методах розраховують ймовірність наявності дефектів у фрагментах розміром  $32 \times 32$  або  $64 \times 64$ , використовуючи модель, навчену на даних без дефектів. Потім застосовують тест відношення ймовірностей для класифікації цих фрагментів як аномальних або таких, у яких відсутні дефекти.

*Модель гауссової суміші.* Ідея, яка була представлена в роботі [5], полягає у навчанні моделі текстур на основі теорії текстонів Джулеза. Текстони інтерпретуються як фрагменти зображень, які відповідають гауссовій моделі. Таким чином, випадковий фрагмент зображення розглядається як відповідний моделі гауссової суміші, яка оцінюється на основі зразкових зображень за допомогою алгоритму максимізації очікування. Метод функціонує на кількох масштабах у гауссовій піраміді з фіксованими розмірами фрагментів. Пороги для виявлення аномалій навчаються на зразках без дефектів: на кожному масштабі обчислюється мінімальна ймовірність в моделі гауссової суміші для всіх фрагментів, і ці значення служать порогами для виявлення аномалій. Фрагмент вважається аномальним, якщо ймовірність його наявності менше, ніж мінімальна ймовірність, яка була визначена на текстурах без аномалій на двох послідовних діапазонах масштабів у гауссовій піраміді. Карта помітності (saliency map) створюється шляхом підсумовування цих послідовних значень ймовірності. Цю модель можна перетворити з карти помітності в систему виявлення аномалій за допомогою гіпотетичного тестування на фоновій моделі гауссової суміші.

Моделювання гауссової суміші вже давно вважається класичним методом у гіперспектральних зображеннях для виявлення аномалій. У цьому випадку, не потрібно використовувати фрагменти, оскільки кожен гіперспектральний піксель вже містить багатовимірну інформацію [1].

*Гауссовий процес.* У роботі [6] пропонують метод, який моделює фонове зображення як гауссовий стаціонарний процес, який також може бути модельований як результат згортки моделі білого гауссового шуму з довільним ядром, іншими словами, кольоровим шумом. Ця модель фону є досить обмеженою, але точною і простою для оцінки.

*Висновки.* У методах, які ґрунтуються на стохастичних моделях фону, аномалії виявляються як неспільні з імовірнісним розподілом, оціненим на основі вхідного зображення. Поріг виявлення аномалій є статистичним тестом на ймовірність, побудованим на основі навченої фонові моделі. Цей тест надає  $p$ -значення для кожного виявлення. Таким чином, змінюючи пороги виявлення, можна легко контролювати кількість помилкових спрацювань.

#### *Моделі фону однорідного типу*

Ці методи оцінюють фон та зазвичай віднімають його від зображення, щоб отримати залишкове (residual) зображення, на якому в кінцевому підсумку виконується виявлення.

*Модель фону Фур'є.* Можливо, найбільш успішним методом на основі фону є виявлення аномалій в періодичних патернах текстилю [7], [8]. Це може бути зроблено, шляхом вирівнювання певних частот в області Фур'є та застосування порогового значення до залишкових зображень для виявлення дефектів. У роботі [8] пропонують автоматизований метод виявлення дефектів на поверхнях із випадковими текстурями, які зустрічаються в шліфованому папері, виробках із чавуну, шкірі та інших промислових матеріалах. Запропонований метод ґрунтується на відніманні фону в області Фур'є. Він передбачає, що розподіл частотних компонентів в просторі спектру є ізотропним і має форму, яка близька до кола. Знаходячи відповідний радіус в просторі спектру та встановлюючи на нуль частотні компоненти поза вибраним колом, відбираються періодичні, повторювані патерни статистичних текстур. У відновленому зображенні однорідні області у вихідному зображенні стають майже плоскими, але дефектна область залишається незмінною. За словами авторів, це перетворює виявлення дефектів в текстурах у просте завдання порогового вибору в нетекстурованих зображеннях. Цей поріг встановлюється за допомогою методу бінаризації статистичного керування процесами (SPC):

$$f_b(x, y) = \begin{cases} 255, & \text{if } \mu - k\sigma \leq f(x, y) \leq \mu + k\sigma \\ 0, & \text{otherwise} \end{cases}$$

де  $k$  – параметр керування,  $\mu$  – середнє значення залишкового зображення, а  $\sigma^2$  – його дисперсія. Області, встановлені на нуль, потім виявляються.

У роботі [7] зосереджуються на виявленні аномалій під час виробництва болтів і гайок. Метод розпочинається зі створення 2D нормалізованого розгорнутого зображення виробу, отриманого з послідовності часткових зображень виробу. Перший крок полягає в видаленні «фону», встановлюючи на нуль деякі коефіцієнти Фур'є. Фоновий малюнок, будучи дуже періодичним, практично повністю видаляється, після видалення великих коефіцієнтів Фур'є. Потім обчислюють середнє значення  $\mu$  та дисперсію  $\sigma^2$  залишкового зображення і воно бінаризується за допомогою методу SPC.

*Модель фону на основі нейронних мереж.* Загальна ідея полягає в тому, щоб вивчити модель фону, використовуючи нейронну мережу, навчену на нормальних даних.

Можливо, найважливішим застосуванням виявлення аномалій у промисловості є виявлення дефектів на поверхні. У роботі [9] пропонується ефективна техніка для виявлення дефектів на поверхні. Самоорганізаційна карта Кохонена (SOM) навчається на даних без дефектів при використанні двох основаних на гістограмах методах текстурного аналізу - матриць співвідношення та локальних бінарних шаблонів. Потім SOM може виявити аномалії, які, ймовірно, мають відмінний від зображень без дефектів розподіл ознак. Автори зауважують, що обидва методи демонструють задовільні результати, але локальні бінарні шаблони видаються ефективнішими з точки зору обчислювальної швидкості. Багато з методів виявлення дефектів на поверхні працюють схожим чином, вони обирають текстурні ознаки, а дефекти визначаються як ті, які недостатньо пояснюються моделлю ознак [1].

Генеративні нейронні мережі, зокрема, варіаційний автокодуювальник (VAE) часто використовуються у методах виявлення аномалій [1]. VAE складається з кодувальника, декодувальника та латентного простору. Кодувальник бере вхідні дані, зазвичай позначені як  $x$ , і відображає їх у латентний простір. Виходом кодувальника є середнє значення  $\mu$  та логарифм дисперсії  $\log(\sigma^2)$  мультіваріативного гаусівського розподілу, що представляє латентний простір:

$$q_\phi(z | x) = N(\mu_\phi(x), \sigma_\phi^2(x)),$$

де  $z$  – це зразок з латентного простору, а  $\phi$  представляє параметри мережі кодувальника.

Після отримання середнього значення та дисперсії від кодера, вибирається зразок  $z$  з вивченого розподілу. Це досягається за допомогою трюку репараметризації, де  $z$  вибирається зі стандартного нор-

мального розподілу  $N(0, I)$  та потім трансформується для отримання бажаного середнього значення та дисперсії.

$$z = \mu_\phi(x) + e \cdot \sigma_\phi^2(x),$$

де  $e$  – це зразок з  $N(0, I)$ .

Декодуювальник бере вибіркового латентний вектор  $z$  та відображає його назад у простір даних з метою відтворення вхідних даних  $x$ .

$$p_\theta(x | z) = N(\mu_\theta(z), \sigma_\theta^2(z)),$$

$$L(\phi, \theta; x) = -E_{q_\phi(z|x)}[\log(p_\theta(x | z))] + KL[q_\phi(z | x) \| N(0, I)],$$

де  $\theta$  представляє параметри мережі декодера.

Під час навчання VAE прагне мінімізувати помилку відтворення та регулювати латентний простір. Для цього використовується функція втрат, що складається з втрат відтворення (обчислюється різниця між вихідними даними та відтвореними даними) та розбіжності Кульбака-Лейблера між навченим розподілом та стандартним нормальним розподілом.

Після навчання VAE на нормальних даних його можна використовувати для виявлення аномалій, оцінюючи помилку відтворення. Високі помилки відтворення характерні для екземплярів, які відхиляються від навченого нормального розподілу. У роботі [10] запропоновано навчити VAE й обчислити на його основі середню ймовірність відновлення, яка використовується як оцінка аномалії

*Модель гладкого або фіксованого фону.* Багато методів виявлення дефектів на поверхні належать до цієї категорії. Наприклад, загальна процедура виявлення дефектів у напівпровідниках полягає у використанні фіксованого еталонного чистого зображення та застосуванні певної процедури для виявлення різниці між спостережуваним зображенням і еталонним зображенням. Оскільки для різних мікросхем ймовірність наявності дефектів у тому ж самому місці дуже низька, можна отримати стандартне еталонне зображення, об'єднавши принаймні три зображення (шляхом заміни пікселів, розташованих у області дефекту, на пікселі, розташовані у відповідному місці іншого зображення) [1].

Ефективним методом виявлення аномалій у гладких матеріалах є метод, запропонований у [11]. У цій статті автори розробляють метод для повністю автоматичного виявлення аномалій на поверхнях коліс. Спочатку зображення коліс ресструються в фіксованому положенні. Для кожної ділянки колеса в заданому положенні розробляється лінійна детермінована фонові модель. Основа моделі складається з кількох поліномів низького ступеня в поєднанні з невеликою кількістю базисних функцій, вивчених як перші власні вектори методу головних компонент, застосованого до еталонних даних. Шуми, що виникають під час зйомки, точно моделюються за допомогою двопараметричного пуассонівського шуму. Параметри легко оцінюються з даних. Оцінка фону є проекцією кожного спостережуваного фрагмента у фоновий підпростір. Залишкове зображення, обчислене як різниця між вхідними і проекційними даними, може містити лише шум та аномалії. Отже, класичне статистичне тестування на норму залишкових значень кожного фрагмента надасть автоматичний поріг виявлення.

*Висновки.* Методи виявлення аномалій на основі моделей однорідного фону показують гарні результати та використовуються в широкому спектрі застосувань. Вони уникнуть пропозиції стохастичної моделі для часто складного фону, розраховуючи відстань до фону або виконуючи віднімання фону. Однак ця спрощення має свою ціну: деякі алгоритми важко узагальнювати для нових застосувань, і механізм прийняття рішення про виявлення, як правило, не має статистичного обґрунтування, за винятком деяких методів, наприклад, як у роботі [11].

#### *Моделі фону локальної однорідності*

Методи моделювання локальної однорідності, такі як методи центр-околу (*centr-surround*), часто використовуються для створення карт помітності. Їх основна ідея полягає в тому, що аномалії (або об'єкти на картах помітності) виникають як локальні події, які контрастують з оточуючими об'єктами.

У роботі [12] представлений загальний метод, який призначений для роботи з усіма типами зображень. Основна ідея полягає в тому, що вони намагаються оцінити ймовірність для фрагментів у зображенні, зумовлену областями, що оточують ці фрагменти. Метод оцінки використовує аналіз незалежних компонентів та перетворення Кархунена-Лоева (KLT) для зменшення розмірності та пошуку компактного представлення простору фрагменту та його околу, де елементи є якнайбільш незалежними. Аномалія визначається як фрагмент з низькою умовною ймовірністю відносно свого околу.

У роботі [13] було розширено використання методу опорних векторів (SVM) для розв'язання проблеми однокласової класифікації. Загальний концепт методу, що отримав назву Support Vector Data Description (SVDD), полягає у тому, що за умови, що лише малий обсяг навчальних даних представляє собою аномалії, можна оптимізувати функцію класифікатора для визначення, чи належить точка нормальному класу чи ні. Більш детально метод можна описати так. Нехай  $X \subseteq R$  – простір вхідних даних і  $\phi_k(x_i) : X \rightarrow Hk$  – функція відображення з ядром  $k : X \times X \rightarrow [0, +\infty)$ .  $Hk$  – простір ознак. Нехай вхідний набір даних задано як  $D = \{x_1, \dots, x_n\}$  з  $x_i \in X$ . Основною метою SVDD є знаходження гіперсфери мінімального розміру, так щоб містити більшість об'єктів даних у  $Hk$ . Задачу SVDD можна описати так:

$$\min R^2 + \frac{1}{\nu n} \sum_{i=1}^n \xi_i,$$

$$s.t. \quad \|\phi_k(x_i) - a\|^2 \leq R^2 + \xi_i \quad \forall i, \xi_i \geq 0,$$

де  $R$  і  $a$  – відповідно радіус і центр сфери;  $\xi_i$  – змінна послаблення, яка дозволяє деяким зразкам даних бути за межами сфери;  $\nu \in (0, 1]$  – це штрафний параметр, який контролює компроміс між обсягом сфери та кількістю відхилених зразків даних, таким чином забезпечуючи ефективний спосіб вимірювання частки аномальних даних для навчання.

У роботі [14] представлений підхід до виявлення аномалій з використанням глибокого навчання, який надихнувся тими ж ідеями. Метод, названий Deep SVDD, тренує глибоку нейронну мережу, щоб виділяти нормальні екземпляри даних та створювати навколо них найменшу можливу описову область. Аномаліями будуть вважатися точки що віддалені від цієї області Цей метод дозволяє ефективно виявляти аномалії у високорозмірних даних.

Зазвичай ці методи створюють карту помітності, оскільки такі карти мають простий і ефективний механізм для вимірювання рідкості. Однак вони не надають механізму визначення порогового значення виявлення аномалії. Декілька з оглянутих вище методів центр-околу намагаються виправити це, але це призводить до значного збільшення обчислювальної складності методу через потребу у визначенні локальної стохастичної моделі як для центру, так і для околу. Як наслідок, зазвичай доводиться використовувати двохкласову класифікацію зі значно більшою складністю методології.

#### Моделі фону на основі розрідженості

Одним із недавніх не параметричних напрямків виявлення аномалій є навчання розрідженого словника, що представляє фон (тобто нормальність), та визначає аномалії за їхньою не розрідженістю. У роботі [15] запропонований метод побудови карт помітності за допомогою поєднання виразності образів та виразності кольорів при обчисленні статистичних характеристик фрагментів зображення. Таке поєднання дозволило покращити точність знаходження унікальних фрагментів зображення, забезпечуючи також високу швидкість обробки.

У роботі [16] автори представили низькорангове та розріджене тензорне представлення даних гіперспектральних зображень на основі спостереження того, що об'єм цих даних часто має низькорангову структуру через значні кореляції в спектрах сусідніх пікселів. У роботі [17] фонову моделлю є навчений словник фрагментів з бази даних без аномалій. Хоча метод виглядає загальним, автори розглянули задачу виявлення аномалій в складних однорідних текстурах, таких як мікрволокна. Модель фрагментів побудована як словник  $D$ , отриманий з усіх фрагментів  $p_i$  шляхом мінімізації

$$J_\lambda(X, D) = \|DX - P\|_F^2 + \lambda \|X\|_1,$$

де  $P$  – матриця, стовпцями якої є навчальні фрагменти; словник  $D$  представлений у вигляді матриці, де стовпці – це елементи словника;  $X$  – це матриця, де  $i$ -й стовпець представляє коефіцієнти фрагмента  $p_i$  у  $D$ . Помилка підгонки даних вимірюється нормою Фробеніуса першої складової формули. Норму  $l_1$  матриці  $X$  слід розуміти як суму абсолютних значень усіх його коефіцієнтів.

Після отримання моделі фрагментів, той самий функціонал використовується для пошуку розрідженого представлення  $x$  для кожного тестового фрагмента  $p$  шляхом мінімізації

$$J_\lambda(X) = \left\| \hat{D}X - p \right\|^2 + \lambda \|X\|_1.$$

Для відповіді на питання, як з цієї мінімізації визначити, що тестовий фрагмент  $p$  є аномальним автори пропонують прив'язати до кожного фрагменту пару значень

$$\phi(p) = \left( \left\| \hat{D}X - p \right\|^2, \lambda \|X\|_1 \right).$$

Перший компонент визначає, наскільки добре фрагмент представлений у словнику  $D$ . Другий компонент вимірює розрідженість (і, отже, адекватність) цього представлення. Емпірична двовимірна гауссова модель  $(\mu, \Sigma)$  отримується для всіх фрагментів навчального набору даних без аномалій. Відповідно до цього можна визначити область нормальності для моделі фрагментів шляхом встановлення порогу  $\gamma$  відстані Маханалобіса зразків до цієї гауссової моделі.

Великою перевагою моделей фону, які передбачають розрідженість, є те, що вони роблять дуже загальне структурне припущення щодо фону і створюють варіаційну модель, яка залежить лише від одного або двох параметрів, а саме від відносної ваги, яку вони надають термінам енергії, яку потрібно мінімізувати.

#### Моделі фону на основі нелокальної самоподібності

Принцип нелокальної самоподібності застосовується в багатьох методах відновлення зображень, зокрема в методах зменшення шуму у зображенні, таких як білатеральний фільтр або нелокальні середні.

Основне припущення цієї загальної моделі фону, яке застосовується до більшості зображень, полягає в тому, що в нормальних даних кожен фрагмент зображення належить до щільного кластеру в просторі фрагментів зображення. Аномалії, навпаки, знаходяться далеко від своїх найближчих сусідів. Це визначення аномалії може бути реалізоване шляхом кластеризації фрагментів зображення (аномалії виявляються, якщо вони знаходяться далеко від центроїда свого власного кластера) або за допомогою пошуку найближчих сусідів, що призводить до прямого вимірювання рідкості.

Модель, яка інспірується нелокальними середніми. У роботі [18] у детекторі аномалій, що базується на нелокальній самоподібній моделі фону, пропонується вимірювати рідкісність як обернену функцію подібності. У кожному пікселі  $i$  дескриптор  $F_i$  вимірює схожість пікселя до свого околу. Потім цей дескриптор  $F_i$  порівнюється з відповідними дескрипторами пікселів у більш широкому okolí. Помітність пікселя  $i$  вимірюється за допомогою

$$s_i = \frac{1}{\sum_{j=1}^N e^{\left( \frac{\rho(F_i, F_j) - 1}{h^2} \right)}}, \quad (1)$$

де  $\rho(F_i, F_j)$  – косинусна відстань між двома дескрипторами,  $F_i$  – локальна ознака, а  $F_j$  для  $j = 1, \dots, N$ ,  $N$  найближчих ознак до  $F_i$  в okolí, та  $0 < h < 1$  є параметром.

Якщо всі  $F_j$  не корелюються з  $F_i$ , всі експоненти в (1) будуть малими, а отже, помітність буде високою. Якщо натомість лише один  $F_j$  добре корелює з  $F_i$ , помітність буде близькою до одиниці, і якщо  $k$  різних  $F_j$  добре корелюють з  $F_i$ , помітність  $i$ -го пікселя  $S_i$  приблизно дорівнюватиме  $1/k$ . Недоліком методу є відсутність чіткого механізму встановлення порогу помітності для виявлення аномалій.

У роботі [19] наведений метод в значній мірі інспірований нелокальними середніми: для фрагменту зображення  $p$ , параметра схожості  $h^2$  і набору  $n$  сусідніх фрагментів  $(p_j)$ , аномалія виявляється, коли

$$\sum_{j=1}^N e^{\left( \frac{-\|p - p_j\|_2^2}{h^2} \right)} \leq \tau,$$

де  $\tau$  – емпіричний параметр.

У роботі [20] автори запропонували моделювання фону на залишковому зображенні, отриманому шляхом віднімання фону. Так як, згадані вище методи, що базуються на самоподібності, припускають, що фон є самоподібним, то для його видалення застосовується модифікація алгоритму нелокальних середніх. Моделювання фону полягає в заміні кожного фрагмента зображення середнім арифметичним з найбільш схожих фрагментів. Для запобігання збереженню аномалій із деякою самоподібною структурою в фоні ці схожі фрагменти шукають за межами «охоронної області зображення», центрованої на фрагменті, що розглядається.

Модель фону на основі ядра PCA. Метод ядра головних компонент (kernel PCA) зменшує обчислювальні витрати завдяки рівномірній випадковій вибірці невеликої частини даних, які з високою імовірністю не містять аномалій. Метод ядра головних компонент для виявлення аномалій, запропонований у роботі [21], визначає гауссове ядро на наборі даних  $x_i$ ,  $i = 1 \dots M$ , встановлюючи

$$k(x_i, x_j) = e^{-\frac{1}{h^2} \|x_i - x_j\|^2}, \quad i, j = 1, \dots, M.$$

Передбачається, що це «ядро» представляє скалярний добуток між векторами ознак вибірок  $\Phi(x_i)$  та  $\Phi(x_j)$  в просторі високої розмірності (де  $\Phi$  визначається неявно). Суть методу полягає в тому, що аналіз головних компонент виконується неявно в цьому просторі ознак з використанням обчислень, які включають лише  $k$ . Відстань між  $\Phi(z)$  та  $\Phi_0 = \sum_{i=1}^M \Phi(x_i)$  можливо обчислити, використовуючи лише  $k$ :

$$p(z) = k(z, z) - \frac{2}{M} \sum_{i=1}^M k(z, x_i) + \frac{1}{M^2} \sum_{i,j=1}^M k(x_i, x_j).$$

Оскільки перший член дорівнює одиниці, а останній член є сталим, випливає, що

$$p(z) = C - \frac{2}{M} \sum_{i=1}^M k(z, x_i),$$

що є протилежним до оцінки щільності Парзена вибірки з використанням гауссового ядра зі стандартним відхиленням  $h$ . Таким чином, аномалії будуть виявлені шляхом встановлення порогового значення на цій щільності, що обчислена з фонових вибірок. Можливо виконати більш повне віднімання фону, віднявши його перші  $q$  головні компоненти.

*Висновки щодо самоподібності.* Подібно до розрідженості, самоподібність є потужною якісною моделлю, але недоліком є те, що у більшості її застосуваннях, відсутній жорсткий механізм для визначення порогу виявлення аномалій. Одним з винятків є робота [20], яка розширює метод з роботи [6] і, таким чином, отримує жорсткий поріг виявлення аномалій за умови, що залишкове зображення є гауссовим випадковим полем.

### Висновки

1. Оскільки аномалії досить важко змоделювати, у центрі уваги більшості методів виявлення аномалій знаходиться фонові модель. Методи, які використовують стохастичну модель фону, є досить ефективними при обробці зображень, які належать до обмеженого класу однорідних об'єктів, таких як текстиль або гладкофарбовані поверхні. Такі методи отримують пороги виявлення на основі оціненої функції щільності ймовірності. Однак, стохастичне моделювання фону не може бути застосоване до довільних зображень. З цієї ж причини однорідні моделі фону мають обмежену застосовність, крім того вони не мають статистично обґрунтованих механізмів для визначення порогів виявлення аномалій. Методи центр-околу успішно використовуються для підвищення яскравості, але, загалом, вони знову ж не мають механізмів виявлення аномалій. Методи центр-околу, які пропонують поріг виявлення, повинні оцінювати дві стохастичні моделі, одну для центру і одну для околу, тому є досить складними для практичного використання. Останні дві категорії розглянутих методів, а саме ті що використовують моделі розрідженості та самоподібності мають велику перевагу - універсальність: їх можна застосовувати до всіх фонових зображень, однорідних чи неоднорідних, стохастичних чи не стохастичних..

2. Для застосувань виявлення аномалій рекомендовано використовувати методи, у яких модель фону найкраще описує очікуваний фон, на якому відсутні аномалії, оскільки це, як правило, призводить до найкращої ефективності. Крім того, для того, щоб методи стали універсальними, потрібно контролювати кількість хибних виявлень. Насправді, більшість методів що розглядалися, як правило, пропонують емпіричний поріг.

3. Ефективна універсальна модель повинна:

- а) використовувати лише самоподібну чи розріджену модель фону;
- б) обробляти залишкове зображення як стохастичний процес для виявлення аномалій, як аномалій у кольоровому шумі;
- в) попередньо обробляти (вибілювати) залишкове зображення перед виявленням аномалій.

### Список літератури

- [1] Ghamry, Fatma M., et al. "Survey of Image Anomaly Detection." (2022). <https://assets.researchsquare.com/files/rs-1890977/v1/2ce2b06a-890a-428d-810e-3ad8173caf7b.pdf?c=1660897768>
- [2] Du, B., Zhang, L.: Random-selection-based anomaly detector for hyperspectral imagery. IEEE Transactions on Geoscience and Remote sensing 49(5), 1578-1589 (2011)

- [3] Goldman, A., Cohen, I.: Anomaly detection based on an iterative local statistics approach. *Signal Processing* 84(7), 1225-1229 (2004)
- [4] Cohen, F.S., Fan, Z., Attali, S.: Automated inspection of textile fabrics using textural models. *IEEE Transactions on Pattern Analysis & Machine Intelligence* (8), 803-808 (1991)
- [5] Xie, X., Mirmehdi, M.: Texems: Texture exemplars for defect detection on random textured surfaces. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 29(8), 1454-1464 (2007)
- [6] Grosjean, B., Moisan, L.: A-contrario detectability of spots in textured backgrounds. *Journal of Mathematical Imaging and Vision* 33(3), 313-337 (2009)
- [7] Perng, D.B., Chen, S.H., Chang, Y.S.: A novel internal thread defect auto-inspection system. *The International Journal of Advanced Manufacturing Technology* 47(5-8), 731-743 (2010)
- [8] Tsai, D.M., Huang, T.Y.: Automated surface inspection for statistical textures. *Image and Vision computing* 21(4), 307-323 (2003)
- [9] Iivarinen, J.: Surface defect detection with histogrambased texture features. In: *Intelligent robots and computer vision xix: Algorithms, techniques, and active vision*, vol. 4197, pp. 140-146. *International Society for Optics and Photonics* (2000)
- [10] An, J.: Variational Autoencoder based Anomaly Detection using Reconstruction Probability. *Arxiv* (2016)
- [11] Tout, K., Cogranne, R., Retraint, F.: Fully automatic detection of anomalies on wheels surface using an adaptive accurate model and hypothesis testing theory. In: *2016 24th European Signal Processing Conference*, pp. 508-512. *IEEE* (2016)
- [12] Honda, T., Nayar, S.K.: Finding "anomalies" in an arbitrary image. In: *2001. IEEE International Conference on Computer Vision*, vol. 2, pp. 516-523. *IEEE* (2001)
- [13] Tax, D.M., Duin, R.P.: Support vector data description. *Machine learning* 54(1), 45-66 (2004)
- [14] Ruff, L., Gornitz, N., Deecke, L., Siddiqui, S.A., Vandermeulen, R., Binder, A., Muller, E., Kloft, M.: Deep one-class classification. In: *International Conference on Machine Learning*, pp. 4390-4399 (2018)
- [15] Margolin, R., Tal, A., Zelnik-Manor, L.: What makes a patch distinct? In: *IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1139-1146 (2013)
- [16] Li, S., Wang, W., Qi, H., Ayhan, B., Kwan, C., Vance, S.: Low-rank tensor decomposition based anomaly detection for hyperspectral imagery. In: *2015 IEEE International Conference on Image Processing*, pp. 4525-4529 (2015)
- [17] Boracchi, G., Carrera, D., Wohlberg, B.: Novelty detection in images by sparse representations. In: *2014 IEEE Symposium on Intelligent Embedded Systems*, pp. 47-54. *IEEE* (2014)
- [18] Seo, H.J., Milanfar, P.: Static and space-time visual saliency detection by self-resemblance. *Journal of vision* 9(12), 15-15 (2009)
- [19] Zontak, M., Cohen, I.: Defect detection in patterned wafers using anisotropic kernels. *Machine Vision and Applications* 21(2), 129-141 (2010)
- [20] Davy, A., Ehret, T., Morel, J.M., Delbraccio, M.: Reducing anomaly detection in images to detection in noise. In: *2018 IEEE International Conference on Image Processing*, pp. 1058-1062. *IEEE* (2018)
- [21] Hoffmann, H.: Kernel pca for novelty detection. *Pattern recognition* 40(3), 863-874 (2007)

Стаття надійшла: 18.01.2024

#### References

- [1] Ghamry, Fatma M., et al. "Survey of Image Anomaly Detection." (2022). <https://assets.researchsquare.com/files/rs-1890977/v1/2ce2b06a-890a-428d-810e-3ad8173caf7b.pdf?c=1660897768>
- [2] Du, B., Zhang, L.: Random-selection-based anomaly detector for hyperspectral imagery. *IEEE Transactions on Geoscience and Remote sensing* 49(5), 1578-1589 (2011)
- [3] Goldman, A., Cohen, I.: Anomaly detection based on an iterative local statistics approach. *Signal Processing* 84(7), 1225-1229 (2004)
- [4] Cohen, F.S., Fan, Z., Attali, S.: Automated inspection of textile fabrics using textural models. *IEEE Transactions on Pattern Analysis & Machine Intelligence* (8), 803-808 (1991)
- [5] Xie, X., Mirmehdi, M.: Texems: Texture exemplars for defect detection on random textured surfaces. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 29(8), 1454-1464 (2007)
- [6] Grosjean, B., Moisan, L.: A-contrario detectability of spots in textured backgrounds. *Journal of Mathematical Imaging and Vision* 33(3), 313-337 (2009)
- [7] Perng, D.B., Chen, S.H., Chang, Y.S.: A novel internal thread defect auto-inspection system. *The International Journal of Advanced Manufacturing Technology* 47(5-8), 731-743 (2010)
- [8] Tsai, D.M., Huang, T.Y.: Automated surface inspection for statistical textures. *Image and Vision computing* 21(4), 307-323 (2003)

- [9] Iivarinen, J.: Surface defect detection with histogrambased texture features. In: Intelligent robots and computer vision xix: Algorithms, techniques, and active vision, vol. 4197, pp. 140-146. International Society for Optics and Photonics (2000)
- [10] An, J.: Variational Autoencoder based Anomaly Detection using Reconstruction Probability. Arxiv (2016)
- [11] Tout, K., Cогranne, R., Retraint, F.: Fully automatic detection of anomalies on wheels surface using an adaptive accurate model and hypothesis testing theory. In: 2016 24th European Signal Processing Conference, pp. 508-512. IEEE (2016)
- [12] Honda, T., Nayar, S.K.: Finding " anomalies" in an arbitrary image. In: 2001. IEEE International Conference on Computer Vision, vol. 2, pp. 516-523. IEEE (2001)
- [13] Tax, D.M., Duin, R.P.: Support vector data description. Machine learning 54(1), 45-66 (2004)
- [14] Ruff, L., Gornitz, N., Deecke, L., Siddiqui, S.A., Vandermeulen, R., Binder, A., Muller, E., Kloft, M.: Deep one-class classification. In: International Conference on Machine Learning, pp. 4390-4399 (2018)
- [15] Margolin, R., Tal, A., Zelnik-Manor, L.: What makes a patch distinct? In: IEEE Conference on Computer Vision and Pattern Recognition, pp. 1139-1146 (2013)
- [16] Li, S., Wang, W., Qi, H., Ayhan, B., Kwan, C., Vance, S.: Low-rank tensor decomposition based anomaly detection for hyperspectral imagery. In: 2015 IEEE International Conference on Image Processing, pp. 4525-4529 (2015)
- [17] Boracchi, G., Carrera, D., Wohlberg, B.: Novelty detection in images by sparse representations. In: 2014 IEEE Symposium on Intelligent Embedded Systems, pp. 47-54. IEEE (2014)
- [18] Seo, H.J., Milanfar, P.: Static and space-time visual saliency detection by self-resemblance. Journal of vision 9(12), 15-15 (2009)
- [19] Zontak, M., Cohen, I.: Defect detection in patterned wafers using anisotropic kernels. Machine Vision and Applications 21(2), 129-141 (2010)
- [20] Davy, A., Ehret, T., Morel, J.M., Delbracio, M.: Reducing anomaly detection in images to detection in noise. In: 2018 IEEE International Conference on Image Processing, pp. 1058-1062. IEEE (2018)
- [21] Hoffmann, H.: Kernel pca for novelty detection. Pattern recognition 40(3), 863-874 (2007)

#### Відомості про авторів

**Маслій Роман Васильович** – к.т.н., доцент, доцент кафедри автоматизації та інтелектуальних інформаційних технологій

**Maslii Roman Vasyliovych** – candidate of technical sciences, associate professor in the department of automation and intelligent information technologies

**Гармаш Володимир Володимирович** – к.т.н., доцент, доцент кафедри автоматизації та інтелектуальних інформаційних технологій

**Garmash Volodymyr Volodymyrovych** – candidate of technical sciences, associate professor in the department of automation and intelligent information technologies

**Ковальчук Петро Петрович** – аспірант кафедри автоматизації та інтелектуальних інформаційних технологій

**Kovalchuk Petro Petrovych** – postgraduate, department of automation and intelligent information technologies

**Кабачій Владислав Володимирович** – к.т.н., доцент, доцент кафедри автоматизації та інтелектуальних інформаційних технологій

**Kabachii Vladyslav Volodymyrovych** – candidate of technical sciences, associate professor in the department of automation and intelligent information technologies

R.V. Maslii, V. V. Garmash, P. P. Kovalchuk, V. V. Kabachii

## ANALYSIS OF ANOMALY DETECTION METHODS IN IMAGES

Vinnitsia National Technical University, Vinnitsia