

УДК 539.3

Артур Микитишин; Ігор Коноваленко, канд. техн. наук, доц.; Павло Марущак, докт. техн. наук, проф.

Тернопільський національний технічний університет імені Івана Пулюя, Україна

МЕТОДИКА ТА РЕЗУЛЬТАТИ ВИЯВЛЕННЯ ДЕФЕКТІВ СТАЛЕВОЇ ПЛАСТИНИ НА ОСНОВІ МЕРЕЖІ YOLO26

Робота присвячена розробленню та експериментальній перевірці моделі автоматичного виявлення дефектів металевих листів на основі архітектури YOLO26 для потреб швидкого промислового контролю якості. Дослідження проведено на наборі з 1350 кадрованих зображень, що містять три класи пошкоджень: подряпини (scratch), лінії (line) та потертості (attrition). Оцінювання моделі показало високу узагальнювальну здатність із метриками $mAP50=0.820$ та $F1=0.778$, причому найвища точність досягнута для класу потертостей, тоді як основний масив помилок припадає на слабконтрастні подряпини. Встановлено, що мережа YOLO26 є перспективною для точного розпізнавання дефектів, проте потребує подальшого вдосконалення алгоритмів локалізації ушкоджень екстремальної форми в умовах реального виробництва.

Ключові слова: виявлення об'єктів, розпізнавання в реальному часі, глибока нейронна мережа, дефекти.

Artur Mykytyshyn; Ihor Konovalenko, PhD, Assoc. prof.; Pavlo Maruschak, DSc, Prof. METHODOLOGY AND RESULTS OF DETECTION OF STEEL PLATE DEFECTS BASED ON THE YOLO26 NETWORK

This paper presents the development and experimental validation of an automated metal sheet defect detection model based on the YOLO26 architecture for rapid industrial quality control. The study utilizes a dataset of 1,350 cropped images encompassing three types of surface damage: scratches, lines, and attrition. The model demonstrated strong generalization, achieving $mAP50=0.820$ and $F1=0.778$, with the highest precision observed for the attrition class and most errors associated with low-contrast scratches. While YOLO26 proves highly effective and accurate for defect recognition, further improvements are required to localize extreme-shaped defects under varying industrial conditions accurately.

Keywords: object detection, real-time recognition, deep neural network, defects.

Автоматизація контролю якості металевих листів є важливою складовою сучасного цифрового виробництва, оскільки навіть незначні поверхневі пошкодження можуть призводити до зниження міцності, корозійної стійкості та якості готової продукції. Ручний візуальний контроль залишається дорогим, суб'єктивним та погано масштабованим, особливо в умовах великого потоку матеріалу та високих вимог до повторюваності рішень. Тому застосування методів комп'ютерного зору та глибокого навчання для промислової інспекції є актуальним і відповідає сучасним тенденціям розвитку інтелектуальних виробничих систем [1,2].

Технологічні дефекти на поверхні металопрокату успішно виявляються за допомогою оптико-цифрових систем і розпізнаються за допомогою згорткових нейронних мереж. Моделі сімейства YOLO належать до класу одноетапних методів виявлення об'єктів, що вирізняються високою швидкістю та точністю. Зображення з камер надходить на вхід мережі YOLO, де воно розбивається на сітку розміром $S \times S$. Якщо геометричний центр об'єкта потрапляє у певну комірку, вона генерує обмежувальну рамку для визначення його просторового положення та класу. Наразі

відомо значну кількість оригінальних технічних рішень на основі архітектури YOLO [3,4]. Зокрема, широкого застосування набула модель YOLOv8, яка вирізняється вдосконаленими стратегіями навчання. Це забезпечує значне підвищення точності та універсальності порівняно з попередніми версіями YOLOv1–YOLOv7.

Модель YOLOv8 набула поширення завдяки наявності Python API, сумісності з платформами TensorRT, CoreML та ONNX, а також завдяки варіативності масштабних модифікацій, що забезпечують оптимальний баланс між швидкістю та точністю залежно від завдань інференсу. Архітектури YOLOv9, 10 та 11 були розроблені послідовно, причому кожна наступна ітерація вдосконалювала базову архітектуру та підвищувала загальну продуктивність. Зокрема, у YOLOv9 інтегровано архітектуру GELAN (Generalized Efficient Layer Aggregation Network) та метод прогресивної дистиляції, що забезпечили поєднання обчислювальної ефективності з вищою репрезентативною здатністю мережі. Модель YOLOv10 відзначається оптимізованим співвідношенням точності та часу затримки завдяки гібридній стратегії призначення міток (label assignment), узгоджених із конкретними завданнями. YOLO11 продовжила розвиток концепції Ultralytics, забезпечивши вищу ефективність утилізації ресурсів графічних процесорів (GPU), що дозволило досягти високої продуктивності навіть під час обробки зображень із значною кількістю дрібних об'єктів.

Наступні версії, YOLOv12 та YOLOv13, є вдосконаленими архітектурами, орієнтованими на максимізацію точності на різноманітних наборах даних. Попри високі метрики якості, ці моделі значною мірою залежать від алгоритму придушення немаксимумів (NMS) та використання розподілу фокальних втрат (Distribution Focal Loss, DFL). Саме обмеження, пов'язані з постобробкою на базі NMS та складністю обчислення функцій втрат, стали передумовою для створення YOLO26 — моделі наступного покоління, оптимізованої для периферійних обчислень (edge computing). Слід також зазначити, що попередні версії зберігали вразливість до таких проблем, як втрата просторових ознак, а також наявність хибнопозитивних (false positives) та хибнонегативних (false negatives) результатів під час виявлення дрібних дефектів на складному фоні. Це суттєво ускладнювало одночасне задоволення вимог щодо роботи в режимі реального часу та високої точності. Для подолання зазначених недоліків у цьому дослідженні для аналізу дефектів металопрокату застосовано архітектуру YOLO26.

Метою роботи є розроблення та експериментальна перевірка моделі автоматичного виявлення дефектів металевих листів на основі архітектури YOLO26 для задачі швидкого промислового контролю якості поверхні. Для досягнення поставленої мети сформовано придатний для навчання набір даних дефектів, забезпечено коректну локалізацію пошкоджень на зображеннях металевої поверхні, класифіковано виявлені області за типом дефекту та оцінено баланс між швидкістю і точністю детекції. Також досліджено поведінку моделі на малих локальних фрагментах поверхні, де контраст дефектів може бути низьким, а форма ушкодження неоднорідною.

Для вирішення завдання розпізнавання дефектів використано модель YOLO26 середнього розміру (Medium), реалізовану на базі фреймворку Ultralytics та адаптовану до задачі детекції виробничих дефектів. Початковий набір даних було сформовано зі структурованих RGB-зображень та сегментаційних масок для трьох класів дефектів: scratch (подряпини), line (лінії) та attrition (потертості). Для проведення експерименту було створено набір даних із фрагментів розміром 256×256 пікселів. У результаті кадрування загалом сформовано 1350 зображень, які було розподілено на підвибірки для навчання, валідації та тестування. Кількісні характеристики набору даних наведено в табл. 1.

Таблиця 1. Структура набору даних, використаного для навчання та тестування

Split	К-сть зображень	К-сть об'єктів	scratch	line	attrition
train	1012	1616	435	565	616
val	202	303	100	71	132
test	136	242	68	76	98

Для підвищення узагальнювальної здатності застосовано лише геометричні аугментації, релевантні до промислового контролю: дискретні повороти на 90° та горизонтальні/вертикальні віддзеркалення з імовірністю 0,5.

Модель навчали протягом 250 епох. Оцінювання на незалежній тестовій вибірці показало хорошу узагальнювальну здатність моделі: $mAP50=0.820$, $precision=0.775$, $recall=0.781$, $F1=0.778$. Приклад результату розпізнавання моделі на кількох зображеннях тестової вибірки показано на рис. 1.



Рисунок 1. Приклад візуалізації прогнозу моделі

Аналіз матриці помилок і покласових тестових метрик показує домінування правильно класифікованих випадків по головній діагоналі та відсутність суттєвого міжкласового змішування. Основний внесок у помилки робить не плутанина між класами, а пропуски частини дефектів і залишкові false positive, насамперед для класу scratch. Для класу дефектів line модель демонструє найбільш збалансовану поведінку ($precision=recall=0.829$), тоді як клас attrition має найвищу $precision=0.911$. Це вказує, що подальше покращення моделі варто фокусувати на складних тонких і слабконтрастних scratch-дефектах.

Перелік посилань

1. Chen J., Liu Z., Wang H., Núñez A., Han Z. (2021). Surface Defect Detection Methods for Industrial Products: A Review. Applied Sciences, 11(16), 7657. <https://doi.org/10.3390/app11167657>
2. Akhyar F., Kama N., Ismail M.H., Ndzi D., Ahmad N. (2023). FDD-a deep learning-based steel defect detector. Neural Computing and Applications, 35, 12167-12188. <https://doi.org/10.1007/s00521-023-08455-1>
3. Chen C., Lee, H. & Chen, M. Steel surface defect detection method based on improved YOLOv9, Sci Rep., 2025, 15, 25098, <https://doi.org/10.1038/s41598-025-10647-1>
4. Liao L., Song C., Wu S., Fu J. A novel YOLOv10-based algorithm for accurate steel surface defect detection, Sensors, 2025, 25, 769. <https://doi.org/10.3390/s25030769>
5. CN121788531A Industrial surface defect detection methods and systems, Han Zhike; Wang Xing; Shao Jiayu; Fan Yexin, 2026-04-03 (in Chinese).