

АВТОМАТИЗОВАНЕ РОЗПІЗНАВАННЯ ДЕФЕКТІВ НА ЗОБРАЖЕННЯХ МАГНІТОПОРОШКОВОГО КОНТРОЛЮ НА ОСНОВІ МОДЕЛІ YOLO11

А.С. Момот¹, В.С. Яקותюк¹, Ю.Ю. Лисенко^{1,3}, Р.М. Галаган¹, Й. Мірчев^{2,3}

¹Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського». 03056, м. Київ, Берестейський проспект, 37. E-mail: j.lysenko@kpi.ua

²Інститут механіки Болгарської академії наук. 1113, м. Софія, вул. акад. Г. Бончева, Болгарія

³Центр компетенцій з мехатроніки та чистих технологій «Мехатроніка, інновації, робототехніка, автоматизація та чисті технології» – MIRACle. Болгарія. E-mail: a.momot@kpi.ua

У роботі розглянуто можливості застосування моделей глибокого навчання сімейства YOLO11 у задачі автоматизації детектування дефектів на зображеннях магнітопорошкового контролю, який широко використовують для перевірки феромагнітних деталей, а рішення за його результатами впливають на безпечність експлуатації та витрати. Водночас зображення магнітопорошкового контролю часто містять зернистий фон, нерівномірне освітлення та відблиски, через що слабоконтрастні магнітні візерунки маскуються, а надійність простих методів аналізу знижується. Запропоновано програмний підхід, у якому кадри з камери автоматично опрацьовуються нейронною мережею, а на виході формуються рамки локалізації дефектів і виконується їхня класифікація за видом. Для навчання моделей використано реальні зображення, кількість яких була збільшена за допомогою аугментації шляхом перетворень, що імітують типові відхилення параметрів зйомки. Набір даних було розмічено за трьома класами дефектів і поділено на навчальну, валідаційну та тестову множини. Проведено навчання та порівняння моделей YOLO11n, YOLO11s, YOLO11m і YOLO11l за метриками Precision, Recall, mAP50 і mAP50-95 та за часом опрацювання кадру. Показано, що збільшення розміру моделі не дає пропорційного приросту якості на наявному наборі даних. Найкращий баланс між точністю та швидкістю забезпечила модель YOLO11m із показником mAP50-95 на рівні 0,238 із часом опрацювання кадру 29,5 мс. Аналіз результатів навчання засвідчив вищу якість детектування лінійних дефектів і складність під час виявлення дрібних групових дефектів, що обумовлено дефіцитом навчальних даних і зашумленим фоном. Надано рекомендації щодо методів зниження хибних спрацювань і розширення даних для покращення репрезентативності навчального набору. Бібліогр. 16, табл. 4, рис. 5.

Ключові слова: магнітопорошковий контроль, детектування дефектів, комп'ютерний зір, штучний інтелект, нейронні мережі

Вступ. Магнітопорошковий контроль (МПК) є одним із найпоширеніших методів неруйнівного контролю феромагнітних матеріалів. Його застосовують насамперед для виявлення поверхневих несутцільностей, зокрема тріщин або пор. МПК здатний виявляти й дефекти, розташовані безпосередньо під поверхнею, однак чутливість методу зменшується зі зростанням глибини залягання [1]. Перевага МПК полягає у високій чутливості до поверхневих і приповерхневих дефектів та у швидкому отриманні результатів. Метод є відносно простим у застосуванні та економічно вигіднішим порівняно з низкою інших підходів, тому його часто використовують як у промислових, так і в польових умовах. Найпоширеніші сфери застосування охоплюють контроль зварних з'єднань, литва та поковок, а також авіаційну, автомобільну, виробничу та енергетичну галузі.

Практична значущість МПК визначається тим, що за результатами контролю ухвалюють рішення, які впливають на безпечність експлуатації, надій-

ність і витрати, пов'язані з ремонтом, простоями та бракуванням. У той же час підсумкова якість контролю часто залежить від інтерпретації його результатів, оскільки висновок формується спеціалістом на основі візуального аналізу. Унаслідок впливу суб'єктивних факторів можливі відмінності між оцінками різних спеціалістів і неоднозначність висновків за різних умов роботи. Це знижує повторюваність результатів, а отже, підсилює потребу в автоматизації аналізу зображень МПК.

Зображення МПК зазвичай являють собою фотографії поверхні виробу після підмагнічування та нанесення магнітопорошкових суспензій [2]. Магнітні частинки концентруються в зонах витoku магнітного потоку, і дефект проявляється як локальне скупчення або смуга частинок, помітна під білим або ультрафіолетовим освітленням. Саме цю картину розподілу частинок зазвичай фіксують камерою для подальшого аналізу та документування та прийняття рішення про наявність дефектів.

Автоматизацію аналізу таких зображень ускладнюють особливості зйомки, за яких формуються шуми та неоднорідності. Значну роль тут відіграють зернистість і фон, а також варіації

© Момот А.С., Яקותюк В.С., Лисенко Ю.Ю., Галаган Р.М., Мірчев Й., 2026.

Стаття опублікована за умовами відкритого доступу за ліцензією CC BY-NC (<https://creativecommons.org/licenses/by-nc/4.0/>)

освітлення та локальні відблиски, що маскують слабконтрастні дефекти. Окремою проблемою є хибні детекції, які виникають через властивості поверхні. Через це корисні ознаки дефектів частково маскуються, а надійність простих правил обробки зображень помітно знижується [3].

За таких умов для автоматизації процесу аналізу зображень МПК доцільно використовувати методи комп'ютерного зору на основі глибоких нейронних мереж, оскільки вони здатні навчатися на фактичних прикладах і враховувати узагальнені контекстні ознаки наявності дефектів. Тому актуальною є потреба у розробці надійних програмних рішень на основі штучного інтелекту (ШІ), які будуть завадостійкими та стабільними в умовах неоднорідності вхідних даних.

Аналіз стану проблеми. Магнітопорошковий контроль залишається одним із найпрактичніших методів неруйнівного контролю феромагнітних деталей, особливо в задачах виявлення поверхневих і приповерхневих дефектів. У промисловості він цінується за чутливість до тріщиноподібних дефектів і відносну технологічну простоту, але саме етап візуальної інтерпретації зображень досі часто залежить від досвіду оператора. Огляд сучасних робіт показує, що фокус автоматизації МПК зміщується від механізації процесу намагнічування та нанесення суспензії до створення програмних методів розпізнавання дефектів на зображеннях із урахуванням вимог роботи в реальному часі та інтеграції прямо у виробничі лінії. У літературі окремо підкреслюють, що значними викликами для автоматизації МПК є різноманітні умови формування зображень та потреби у зменшенні впливу шумів ще до етапу розпізнавання [4].

Для задач контролю якості принципово важливо не лише встановити факт наявності дефекту, а й визначити його положення та розміри. Тому підходи, що зводять автоматизований аналіз зобра-

жень МПК до задачі класифікації, виявляються недостатньо інформативними для реального інженерного застосування. На практиці часто потрібно не лише виявити дефект, а й виконати відповідне маркування, провести повторний огляд, а інколи й позначити просторове положення дефекту. Наприклад, у [5], присвяченій флуоресцентному МПК, показано логіку переходу від простого виявлення дефектів до задачі їхньої локалізації та подальшого уточнення параметрів, де ключовими викликами стають відсікання фону та робота з малорозмірними дефектами на великих полях зображення. Автори прямо пов'язують цю постановку з реальною практикою, коли дефекти на немеханічних поверхнях необхідно відполірувати та перевірити повторно.

Типові проблеми для автоматизації аналізу зображень МПК пов'язані з тим, що відбитки дефектів формуються на фоні неоднорідної текстури, відблисків і локальних перепадів яскравості, а також можуть маскуватися зернистістю та паразитними світловими ефектами (рис. 1). На знімках одночасно присутні корисні структури та завади, які змінюються від деталі до деталі, тому один і той самий дефект може виглядати по-різному залежно від освітлення та стану поверхні. Це створює ситуацію, коли слабкі протяжні дефекти потрібно відокремити від великої площі неінформативного фону, і саме на цьому етапі багато класичних методів стають нестійкими. У багатьох роботах прямо підкреслюється складність виділення мікротріщин на тлі великого фону, а також залежність якості детектування від того, наскільки точно визначено попередню область інтересу. Практика впровадження методів комп'ютерного зору для МПК показує, що поєднання нейромережевого аналізу з контрольованими умовами зйомки та попередньою підготовкою даних дозволяє отримати передбачуваніші результати у виробничих умовах [6].




Рис. 1. Приклади зображень МПК

Еволюція підходів у МПК добре ілюструється переходом від ручного визначення правил обробки зображень до моделей ШІ, що навчаються на великих наборах даних. У ранніх роботах із використання глибокого навчання для автоматизації аналізу зображень МПК вже розглядалися декілька варіантів постановок цієї задачі. Зокрема автори [7] описують задачі класифікації, детектування та семантичної сегментації й показують, що правильний вибір постановки прямо визначає придатність рішення до виробничого застосування. Це важливо, бо навіть за якісної зйомки один і той самий магнітний візерунок може вимагати різної інтерпретації залежно від контексту поверхні та геометрії деталі. Автори також підкреслюють, що передбачувана швидкодія є не менш важливим параметром автоматизації ніж точність, оскільки контроль часто прив'язаний до темпу виробництва та до обмеженості часу огляду.

З погляду правильної постановки задачі важливо розрізняти кілька рівнів відповіді, яку може давати алгоритм. Задача класифікації відповідає на запитання: «Чи є на зображенні ознаки дефекту та якого саме?», але не показує конкретне місце його розташування. Задача детектування об'єктів дозволяє чітко вказати ділянку зображення, на якій виявлено дефект, а також одночасно визначити його клас (вид). Задача сегментації дозволяє не лише локалізувати дефекти та класифікувати їх, але й отримати контури дефектів у вигляді маски пікселів. Це зручно для опису форми та для подальших вимірювань розмірів. У практичному застосуванні ці задачі часто поєднують, оскільки попереднє детектування дозволяє зменшити область інтересу для детального аналізу, а подальша сегментація у цій області дозволяє уточнити межі дефектів і визначити їхній клас навіть там, де контраст є низьким.

Останнім часом окремим трендом у задачах аналізу зображень неруйнівного контролю стало поширення нейромережових моделей для детектування об'єктів сімейства YOLO. Ці моделі мають просту й зрозумілу процедуру навчання та оцінювання якості, а також високу швидкодію, що робить їх придатними до опрацювання зображень у режимі реального часу. Для МПК це особливо доречно у разі необхідності швидкої локалізації дефектів, а також забезпечення високої якості детектування в умовах швидкого виробничого темпу. У публікаціях останніх років для задач, близьких за складністю автоматизації до МПК, демонструються модифікації YOLO з акцентом на здатність визначення дрібних дефектів на складному фоні, зокрема дефектів друкованих плат [8].

Паралельно з розвитком моделей ШІ зростає увага до інженерних аспектів їхнього впровадження, зокрема до спрощення моделей і зниження обчислювальних витрат без втрати якості. У [9] для флуоресцентного МПК запропоновано підхід на основі перенесення навчання, згідно з яким попередньо навчена для інших задач модель донавчається для детектування дефектів на зображеннях МПК. У публікації наведено приклад, де середня точність детектування (mean Average Precision, mAP) підвищується на 5 % по відношенню до варіанту навчання моделі без перенесення навчання. Також показано зростання швидкості детектування з 20,57 до 35,25 кадрів/с, що підкреслює практичну цінність такого підходу саме для контролю в реальному часі. Це вписується в загальну тенденцію, коли рішення щодо вибору ШІ-моделі оцінюють не лише за часткою правильних класифікацій, а й за затримкою відповіді, стабільністю та вартістю обчислювальних ресурсів.

Ще одна виразна тенденція пов'язана з особливостями наборів навчальних даних, а саме, з дефіцитом навчальних зображень і їхньою доменною специфікою. У [10] показано, що недостатня кількість якісних зображень може обмежувати навчання моделей, а до приросту якості часто призводить не ускладнення архітектури, а грамотне розширення та аугментація даних. Автори застосовують поетапний синтез штучних зображень із використанням дифузійної моделі та комплексування зображень, а також додаткове підсилення контрасту магнітних візерунків відносно фону за допомогою модифікації тональної кривої. У роботі повідомляється, що такі підходи підвищують середню точність детектування для моделі YOLOv5s на 35,2 % порівняно з варіантом без аугментації і попередньої обробки зображень. Для моделі YOLOv8s зазначено підвищення на 27,6 %. Разом із тим підкреслюється, що синтезовані дані можуть відрізнятися від зображень, отриманих за допомогою реальної зйомки. Тому навчена модель потребує перевірки на реальних кадрах саме того виробництва, де планується впровадження.

Щільні та розгалужені магнітні візерунки становлять окрему проблему. Наприклад, складною є ситуація коли тріщини розташовані близько та погано відокремлюються одна від одної. У [11] для флуоресцентного МПК заклепок застосовано модель для детектування та сегментації дефектів, яка дозволяє розділяти близько розташовані тріщини як окремі об'єкти. Запропоновано спосіб розмітки даних зі зменшенням перекриття рамок у щільних областях і постобробку для підвищення пов-

ноти виявлення дефектів у зонах густих тріщин. У наведених результатах повідомляють про mAP на рівні 90,3 %, що демонструє практичний потенціал використання сегментації саме для розпізнавання в умовах складних флуоресцентних візерунків.

Узагальнюючи сучасний стан розвитку автоматизації, МПК можна описати як перехід до відтворюваних програмних систем, де ключовими стають локалізація та класифікація дефектів, виявлення малорозмірних дефектів на зашумленому фоні та підвищення якості навчальних наборів даних для ШІ-моделей. Аналіз поточних робіт доводить, що в реальних умовах особливості формування магнітних візерунків і високі рівні шумів не дозволяють використовувати традиційні методи автоматизованого аналізу зображень, оскільки вони не будуть мати необхідної стійкості. Зокрема для аналізу зображень зрізів зі зразків мідної руди запропоновано методи сегментації на основі кольорних моделей [12], що демонструють практичну ефективність у задачах оцінювання вмісту мінералів, однак їхнє застосування обмежується стабільністю умов зйомки та однорідністю освітлення. Практичні дослідження також показують, що найбільшого приросту якості автоматизованого розпізнавання дефектів часто досягають шляхом поєднання правильної постановки задачі, визначення інженерно придатної моделі ШІ та коректної підготовки навчальних даних. Так, у [13] показано, що метод аугментації на основі злиття зображень із вейвлет-перетворенням статистично значуще підвищує точність класифікації нейронних мереж при тепловому НК, що підтверджує важливість вибору методу розширення навчальних даних. У цьому контексті перспективним напрямком розвитку є поєднання використання швидких ШІ-моделей для детектування об'єктів, зокрема сімейства YOLO, з аугментацією даних і правильною розміткою навчального набору з урахуванням особливостей, характерних для МПК.

Метою даного дослідження є аналіз ефективності застосування моделей нейронних мереж сімейства YOLO11 для автоматизованого виявлення дефектів на зображеннях МПК. Даний підхід має забезпечити автоматичне визначення розташування дефектів на поверхні та їхню класифікацію за видом. Задача ускладнена тим, що зображення часто містять шуми та неоднорідності, а магнітні візерунки, що супроводжують дефекти, можуть бути слабконтрастними та змінюватися залежно від умов зйомки. Додатковим ускладнюючим фактором є дефіцит зображень МПК у відкритому доступі для формування навчального набору даних.

У запропонованій системі зображення об'єкта контролю надходять до програмного модуля інтелектуального опрацювання з камери, встановленої на виробничій дільниці або над виробом під час огляду. Далі зображення автоматично опрацьовуються нейронною мережею, а на виході отримується результат детектування, де дефекти виділяються рамками та відносяться до відповідних класів. Важливим етапом створення такої системи є коректний вибір найефективнішої ШІ-моделі для виявлення об'єктів на зображеннях, оскільки необхідно забезпечити баланс між достовірністю та швидкодією. Тому актуальним завданням є порівняння ефективності роботи різних модифікацій сучасної моделі YOLO11 на наборі даних, який складається з реальних зображень МПК.

Опис нейромережевої моделі. YOLO – це сімейство нейромережевих моделей для автоматизованого детектування об'єктів на зображеннях, яке відоме поєднанням високої швидкодії та точності. Такий баланс є важливим для задач МПК, де потрібно виявляти дефекти за візуальними магнітними візерунками, зберігаючи високу швидкість контролю. Базовий принцип YOLO як однокрокового методу детектування описано в [14].

Ключові особливості версії YOLO11 пов'язані з оновленням архітектури та методів навчання, які дають кращу точність і вищу швидкість порівняно з більш ранніми версіями за близької або меншої обчислювальної складності. У матеріалах розробників підкреслюється, що YOLO11 підвищує точність виявлення об'єктів на зображеннях і водночас складається з меншої кількості параметрів у порівнянні з YOLOv8 [15]. Це спрощує використання моделі в задачах потокової обробки зображень і в умовах обмежених обчислювальних ресурсів. Для задач автоматизованого аналізу зображень МПК це важливо, оскільки даний підхід дозволяє використовувати компактніші моделі без істотної втрати чутливості до дрібних дефектів на складному фоні, що також зменшує ризики затримок під час проведення контролю на виробництві.

У той же час, моделі YOLO мають типові обмеження, які важливо враховувати в задачах автоматизації МПК. Найчастіше складнощі пов'язані з детектуванням малих за розміром об'єктів, поганим детектуванням за низької контрастності та якщо фон містить структури, схожі на корисні ознаки об'єктів. За таких умов модель повинна відрізняти слабкий корисний сигнал від нерівномірностей зйомки та текстури поверхні, внаслідок чого можуть виникати помилки локалізації або пропуски дрібних дефектів.

З точки зору архітектури всі моделі YOLO зберігають логіку послідовного перетворення зображення у набір ознак, їх об'єднання на кількох масштабах і подальшого прогнозування рамок об'єктів та їхніх класів. Спочатку згорткові прошарки формують ієрархічний набір ознак, після цього ознаки різних просторових масштабів узгоджуються в об'єднаній частині мережі, а далі вихідні прошарки прогнозують координати рамок і визначають класи дефектів. Така схема є доречною для МПК, оскільки дефекти можуть мати різний характер і розмір, а фон часто містить завади, які потрібно відкидати за рахунок контекстних ознак.

Важливою практичною рисою є можливість масштабування моделі. Розміри YOLO11 визначаються наборами коефіцієнтів, що змінюють глибину й ширину мережі. Завдяки цьому одна й та сама за ідеєю архітектура може бути подана як компактна високошвидкісна модель або як більша і повільніша модель, яка потенційно забезпечує вищу якість детектування за рахунок більшої кількості параметрів. Для попередньої оцінки співвідношення складності моделі та якості детектування можна використовувати результати тестування моделей на стандартному наборі даних COCO [15]. Ці результати наведено в табл. 1. Надмірне збільшення моделі підвищує потенційну якість детектування, проте потребує значно більше обчислювальних ресурсів і може ускладнювати швидкодію застосування в реальному часі, що негативно впливає на час проведення контролю.

Отже, вибір конкретної модифікації YOLO11 для автоматизації процесу аналізу зображень МПК є окремим інженерним завданням, оскільки саме це визначатиме баланс між точністю локалізації дефектів і практичною швидкодією. У зв'язку з цим у подальшому будуть розглядатися результати порівняння модифікацій YOLO11 на власному наборі навчальних зображень МПК за узгодженими метриками та єдиною процедурою навчання й тестування.

Метрики для детектування об'єктів. Для порівняння модифікацій YOLO11 у задачі детектування дефектів на зображеннях МПК необхідно використовувати метрики, які одночасно відображають точність локалізації рамок навколо дефектів і якість класифікації. Це важливо, оскільки модель має не лише знайти дефект, а й окреслити його по-

ложення на кадрі так, щоб результат був придатним для подальшого аналізу та повторного огляду. У даній роботі в якості метрик використовуються IoU, Precision, Recall, mAP50 і mAP50-95, які є типовими для задач детектування об'єктів [16].

Метрика Intersection over Union (IoU) описує ступінь перекриття прогнозованої моделлю рамки навколо дефекту та еталонної рамки. Значення IoU наближається до одиниці, якщо рамки майже збігаються, і зменшується до нуля, якщо перекриття майже відсутнє. У задачах МПК це прямо пов'язано з тим, наскільки точно модель виділяє границі дефекту на фоні шумів і неоднорідностей зйомки.

Метрики Precision і Recall визначаються шляхом підрахунку кількості правильних і неправильних класифікацій моделі. Обидві метрики можуть мати значення 0...1. Високе значення Precision означає, що модель зрідка виявляє дефект там, де його насправді немає. Висока Recall означає, що модель зрідка пропускає дефекти, які насправді присутні на зображенні. Для МПК ці показники слід інтерпретувати разом, оскільки зниження порога впевненості мережі часто підвищує Recall, але може погіршити Precision через появу хибних детектувань на ділянках із вираженими магнітними візерунками фону.

Метрика Average Precision (AP) узагальнює компроміс між Precision і Recall для кожного класу дефектів. На практиці для визначення AP будується крива залежності Precision від Recall за різних порогів впевненості моделі, після чого AP розраховується як площа під цією кривою. У випадку кількох класів використовується середнє значення AP–mAP. Позначення mAP50 означає, що під час розрахунку враховуються лише ті виявлені мережею об'єкти, для яких значення IoU перевищує 50 %. Інші об'єкти, для яких IoU є меншими за вказаний поріг, визнаються хибними детекціями та відкидаються в результаті роботи алгоритму Non-max suppression (NMS). Позначення mAP50-95 відповідає усередненому значенню mAP за набором порогів $t \in \{0,50; 0,55; \dots; 0,95\}$. У порівнянні з mAP50, метрика mAP50-95 жорсткіше оцінює якість локалізації, оскільки штрафує за рамки, які входять дефект, але неточно відтворюють його межі.

Окремо під час процесу навчання моделі відстежуються складові функції втрат, які показують,

Таблиця 1. Порівняння модифікацій YOLO11

Модель	Швидкодія без графічного прискорювача, мс	Кількість параметрів, млн	mAP50-95
YOLO11n	56,1 ± 0,8	2,6	0,395
YOLO11s	90,0 ± 1,2	21,5	0,470
YOLO11m	183,2 ± 2,0	68,0	0,515
YOLO11l	238,6 ± 1,4	86,9	0,534
YOLO11x	462,8 ± 6,7	194,9	0,547

де саме модель помиляється та як змінюється ця помилка в процесі оптимізації. Box loss (або L_{box}), відображає точність визначення координат рамки дефекту. Class loss (або L_{cls}) відповідає за правильність віднесення виявленого дефекту до певного класу. DFL loss (або L_{dfl}) є складовою функції втрат, яку в сучасних реалізаціях YOLO застосовують для уточнення координат рамки дефекту. Вона дозволяє точніше наближати координати, особливо коли дефект малий або має слабкий контраст на фоні магнітних візерунків.

Формування навчального набору даних. Зображення магнітних візерунків на поверхнях дефектних і бездефектних деталей, отримані під час проведення МПК, були надані авторам приватним підприємством «ДП-ТЕСТ». Початковий набір даних складав 99 зображень, що є недостатнім для стійкого навчання моделі для детектування дефектів за реальних умов зйомки. Тому базовий набір було штучно розширено до 5510 зображень за рахунок аугментації даних, що дозволило отримати різноманітні варіації навчальних зображень і зменшити ризик перенавчання або недонавчання.

Процес аугментації даних включав застосування перетворень, які відтворюють типові відхилення реальної зйомки. Зокрема до початкових зображень застосовувалися відображення по горизонталі та вертикалі, обертання в межах $-15...+15^\circ$, зсуви до $\pm 11^\circ$ по горизонталі та до $\pm 6^\circ$ по вертикалі, а також зміни насиченості в межах $\pm 10\%$. Додатково до зображень додавався нормально розподілений шум з інтенсивністю до $0,97\%$ та імітувалась дисперсія коефіцієнта підсилення матриці камери на рівні $0,09$. Також використовувалися масштабування та випадкове кадрування, розмиття для імітації нечіткості через рух або недосконалого фокусування, а також зміни яскравості та контрасту для відтворення неоднорідного освітлення та впливу особливостей поверхні. Усі перелічені параметри змінювались у межах $\pm 10\%$ відносно початкових характеристик зображення. У результаті кожен навчальний приклад отримував до десяти варіантів перетворень.

Для розмітки даних було визначено три класи дефектів: лінійні (такі як лінійні тріщини або подряпини), групові (скупчення пор, дрібних тріщин тощо) та інші дефекти для узагальнення інших аномалій. Під час формування набору даних виконувалось масштабування розміру всіх зображень до 640×640 пікселів.

Набір даних було розділено на навчальну, валідаційну та тестову множини. Розподіл кількості зображень за множинами наведено в табл. 2. Такий розподіл одразу демонструє дисбаланс за кла-

сами, особливо для дефектів класу «групові», що необхідно враховувати під час інтерпретації метрик і підбору параметрів навчання.

Навчання моделей. Для проведення дослідження ефективності різних моделей YOLO11 було використано хмарне середовище Google Colab із графічним процесором T4 та програмну бібліотеку Ultralytics. Для розмітки та організації набору даних застосовувалось середовище Roboflow SDK, яке також забезпечувало експорт розмічених зображень і формування структури набору даних у форматі, сумісному з YOLO11.

Навчання проводилось для всіх моделей YOLO11, окрім YOLO11x. Це пов'язано з тим, що обчислювальних можливостей графічних процесорів, наданих у користування середовищем Google Colab, не вистачало для навчання настільки великої моделі. У той же час, як вже було зазначено раніше, YOLO11x початково й не розглядалась авторами з причин надмірної складності та низької швидкодії.

Моделі ініціалізувались із попередньо навченими на наборі даних MS COCO вагами, що прискорювало збіжність і підвищувало стабільність навчання за обмеженої кількості вихідних зображень. Навчання проводилось протягом 30 епох, розмір зображення на вході кожної мережі складав 640×640 пікселів, розмір батчу становив 16. Налаштування набору даних виконувалось із використанням YAML-файлу, який містив шляхи до навчальної, валідаційної й тестової множин і опис класів дефектів. Гіперпараметри моделей у даному дослідженні не змінювались і використовувались значення за замовчуванням.

У процесі навчання відстежувались усі складові функції втрат, які вирізняють помилки локалізації та класифікації. Контролювались L_{box} як показник точності рамок, L_{cls} як показник якості класифікації, а також L_{dfl} як складова, що відображає штраф за відхилення передбачених координат рамки від еталонних. Приклад графіків навчання для моделі YOLO11m наведено на рис. 2.

Динаміка цих кривих демонструє рівномірне зменшення значень протягом епох, що узгоджується з коректною роботою алгоритму оптимізації та відсутністю ознак різкого розходження між навчальними (train) та валідаційними (val) показниками. Паралельно з втратами контролювали-

Таблиця 2. Розподіл зображень за множинами у навчальному наборі даних

Клас дефектів	Навчальна	Валідаційна	Тестова
Лінійні	959	62	101
Групові	110	11	9
Інші	173	16	21
Разом (усі)	1242	89	131




Рис. 2. Графіки навчання моделі YOLO11m: 1 – results, 2 – smooth

ся метрики Precision, Recall, mAP50 і mAP50-95, які поступово зростали, що означає зменшення хибних спрацьовувань і збільшення частки знайдених дефектів, включно з дрібними та низькоконтрастними.

Аналіз результатів. Результати оцінки ефективності моделей, що досліджувались, на тестовій множині наведено в табл. 3. Спостерігається закономірне зростання рівня якості детектування під час переходу від більш компактних модифікацій моделі до середніх, проте подальше збільшення розміру моделі не дає пропорційного приросту. Для YOLO11n і YOLO11s значення Precision, Recall, mAP50 і mAP50-95 збігаються, хоча обчислювальна складність і час опрацювання відрізняються. Це можна пояснити тим, що складний фон зображень МПК і дисбаланс класів обмежують ефект від збільшення потужності моделі без додаткового напруження різноманіття навчальних даних.

Найкраще значення mAP50-95 показала модель YOLO11m. Модель YOLO11l має дещо вищі Precision і Recall, але mAP50-95 при цьому зменшується. Це означає, що збільшення моделі не обов’язково покращує точність локалізації рамок дефектів як мінімум на даному наборі зображень.

З точки зору швидкодії YOLO11n забезпечує найменший час опрацювання 7,1 мс на зображення, тоді як YOLO11m потребує 29,5 мс. Проте приріст Recall для YOLO11m становить 0,071,

а приріст mAP50-95 становить 0,009 у порівнянні з YOLO11n. У зв’язку з цим модель YOLO11m є більш збалансованим варіантом для подальшого розгляду, оскільки підвищує повноту знаходження дефектів без різкого погіршення продуктивності.

У табл. 4 наведено деталізовані результати для обраної моделі YOLO11m. Оцінювання виконано для всіх розмічених об’єктів і окремо для класів лінійних, групових та інших дефектів. Важливо звернути увагу на такий розподіл, оскільки класи відрізняються не лише видом і формою дефектів, а й кількістю їхніх прикладів у тестовій множині.

Загалом модель досягає Precision 0,643 і Recall 0,611 при mAP50 0,607. Найкращі показники отримано для лінійних дефектів. Для класу інших дефектів значення mAP50-95 близьке до загального рівня та свідчить про стабільне виявлення на різноманітному фоні. Найскладнішим виявився клас групових дефектів. Це можна пояснити малою кількістю прикладів у навчальному наборі даних, а також тим, що дрібні магнітні візерунки часто мають низький контраст і легко змішуються із зернистим фоном.

На рис. 3 показано приклади правильного детектування моделлю YOLO11m на зображеннях із тестової множини. Можна помітити, що рамки досить точно охоплюють лінійні дефекти та більші об’єкти класу інших дефектів. Для точкових дефектів межі рамок частіше зміщуються, що узгоджується з нижчим значенням mAP50-95. У

Таблиця 3. Зведені результати тестування навчених моделей

Модель	Обчислювальна складність, GFLOPs	Precision	Recall	mAP50	mAP50-95	Час опрацювання зображення, мс
YOLO11n	6,3	0,618	0,540	0,536	0,229	7,1
YOLO11s	21,3	0,618	0,540	0,536	0,229	12,9
YOLO11m	67,7	0,643	0,611	0,607	0,238	29,5
YOLO11l	86,6	0,647	0,616	0,608	0,216	37,8

Таблиця 4. Результати тестування моделі YOLO11m

Клас дефекту	Кількість зразків	Precision	Recall	mAP50	mAP50-95
Всі	131	0,643	0,611	0,607	0,238
Лінійні	101	0,744	0,775	0,792	0,337
Групові	9	0,442	0,440	0,405	0,109
Інші	21	0,745	0,619	0,623	0,268




Рис. 3. Приклади коректного детектування різних класів дефектів моделлю YOLO11m




Рис. 4. Приклади хибного детектування дефектів моделлю YOLO11m

практичному застосуванні це означає, що для точкового класу потрібне додаткове уточнення даних і перевірка налаштувань порогів моделі.

Результати хибного виявлення дефектів показано на рис. 4. У цих прикладах видно, що модель може дублювати рамки для одного й того самого дефекту та позначати окремі елементи фону як дефект. Найчастіше це проявляється на ділянках із вираженою текстурою та локальними відблисками, де магнітні візерунки мають лінійну форму. Такі помилки знижують значення Precision, оскільки збільшують кількість хибних спрацювань. Їх можна зменшити через підвищення порога впевненості мережі, коректне налаштування алгоритму NMS, а також шляхом додавання до навчального набору більшої кількості прикладів зі складним фоном без дефектів.

На рис. 5 наведено нормалізовану матрицю помилок мережі на тестовій множині. Матриця показує, як часто модель відносить розмічені об'єкти до кожного класу або фону. Можна помітити, що більшість лінійних та інших дефектів класифікуються правильно, проте частина фонових областей

помилково відноситься до класу лінійних. Це узгоджується з прикладами на рис. 4 і вказує на чутливість моделі до лінійних структур фону.

У той же час оцінки для групових дефектів потребують обережної інтерпретації, оскільки їхня кількість у тестовій множині є незначною. У зв'язку з цим доцільно додатково перевірити якість мо-




Рис. 5. Нормалізована матриця помилок моделі YOLO11m

делі на розширеній вибірці та в умовах із більшою варіативністю магнітних візерунків фону.

У цілому порівняння модифікацій YOLO11 показало, що модель середнього розміру забезпечує найкращий баланс між якістю та швидкодією на наявному наборі даних. Результати підтверджують перспективність використання моделей глибинного навчання для автоматизації аналізу зображень МПК. Ключовими викликами залишаються зменшення хибних спрацювань на складному фоні та нарощування навчальних даних про рідкісні дефекти.

Висновки

У роботі проведено порівняльний аналіз ефективності автоматизованого виявлення дефектів на зображеннях магнітопорошкового контролю із застосуванням моделей сімейства YOLO11. Отримані результати підтверджують, що вибір конкретної модифікації моделі є критичним етапом побудови системи на практиці, оскільки він визначає баланс між точністю виявлення дефектів та обчислювальними витратами. Це особливо важливо для зображень МПК, де зернистий фон і локальні відблиски можуть маскувати слабоконтрастні магнітні візерунки та провокувати хибні спрацювання.

Порівняння модифікацій YOLO11 показало, що найкраще значення mAP50-95 на рівні 0,238 на наявному наборі даних забезпечує модель YOLO11m. Модель YOLO11l демонструє дещо вищі Precision і Recall, однак її mAP50-95 є нижчим, що вказує на те, що збільшення розміру моделі не обов'язково покращує якість локалізації рамок дефектів у даних умовах. У зв'язку з цим YOLO11m можна розглядати як найзбалансованіший варіант для подальшого розвитку системи, оскільки вона підвищує повноту виявлення без непропорційного погіршення швидкодії.

Детальні результати для YOLO11m показали, що на поточному наборі даних найкраще виявляються лінійні дефекти, тоді як найскладнішими залишаються групові дефекти, для яких mAP50-95 становить лише 0,109. Додатково встановлено, що хибні спрацювання частіше виникають на ділянках із вираженою текстурою та локальними відблисками, тому для практичного застосування доцільно перевіряти вплив порога впевненості та інших налаштувань моделі й доповнювати навчальний набір прикладами складного фону без дефектів.

Результати свідчать про перспективність використання моделей глибинного навчання для автоматизації аналізу зображень МПК. Якість такого детектування помітно залежить від різноманіття даних і представленості рідкісних класів дефектів. У подальших дослідженнях доцільно розши-

рити тестування на зображеннях із різними режимами освітлення та різною геометрією деталей, а також перевірити вплив налаштувань гіперпараметрів моделі на стабільність метрик. При цьому слід враховувати, що запропонований підхід є інструментом автоматизації процедури, але кінцеве рішення щодо критичності дефекту та придатності виробу має приймати кваліфікований фахівець із неруйнівного контролю.

Подяка

Цю роботу виконав Центр компетенцій з мехатроніки та чистих технологій «Мехатроніка, інновації, робототехніка, автоматизація та чисті технології» – MIRACle за фінансової підтримки контракту № BG16RFPR002-1.014-0019-C01, що фінансується Європейським фондом регіонального розвитку (ЄФРР) через Програму «Дослідження, інновації та цифровізація для розумної трансформації» (PRIDST) 2021–2027.

Список літератури/References

1. International Organization for Standardization (2016) ISO 9934-1:2016 *Non-destructive testing. Magnetic particle testing. Pt 1 General principles*. Geneva, ISO.
2. Яקותюк В.С., Глабець С.М., Лисенко Ю.Ю., Момот А.С. (2025) Практичний досвід застосування та аналіз ефективності різних магнітних суспензій. *Технічна діагностика та неруйнівний контроль*, 4, 44–48. DOI: <https://doi.org/10.37434/tdnk2025.04.06>
3. Yakotiuk, V.S., Hlabets, S.M., Lysenko, Yu.Yu., Momot, A.S. (2025) Practical experience of using and analyzing the efficiency of various magnetic suspensions. *Technical Diagnostics and Non-Destructive Testing*, 4, 44–48 [in Ukrainian]. DOI: <https://doi.org/10.37434/tdnk2025.04.06>
4. Yang, Y., Yang, Y., Li, L. et al (2022) Automatic defect identification method for magnetic particle inspection of bearing rings based on visual characteristics and high-level features. *Appl. Sci.*, 12(3), 1293. DOI: <https://doi.org/10.3390/app12031293>
5. Mao, Z., Wu, Q., Qin, X. et al (2023) Magnetic particle inspection. Status, advances, and challenges. Demands for automatic non-destructive testing. *NDT & E International*, 143, 103030. DOI: <https://doi.org/10.1016/j.ndteint.2023.103030>
6. Wu, Q., Qin, X., Dong, K. et al (2023) A learning-based crack defect detection and 3D localization framework for automated fluorescent magnetic particle inspection. *Expert Systems with Applications*, 214, 118966. DOI: <https://doi.org/10.1016/j.eswa.2022.118966>
7. Tout, K., Meguenani, A., Urban, J.-P., Cudel, C. (2021) Automated vision system for magnetic particle inspection of crankshafts using convolutional neural networks. *The International J. of Advanced Manufacturing Technology*, 112(8), 3307–3326. DOI: <https://doi.org/10.1007/s00170-020-06467-4>
8. Chen, J., Tong, J., Su, J. (2025) Design of a real-time abnormal detection system for rotating machinery based on YOLOv8. *Frontiers in Mechanical Engineering*, 11, 1683572. DOI: <https://doi.org/10.3389/fmech.2025.1683572>
9. Momot, A., Kretsul, V., Muraviov, O., Galagan, R. (2024) Automated defect detection in printed circuit boards based on the YOLOv5 neural network. *The Paton Welding J.*, 4, 46–52. DOI: <https://doi.org/10.37434/tpwj2024.04.07>
10. Shi, A., Wu, Q., Qin, X. et al (2024) Lightweight detector based on knowledge distillation for magnetic particle inspection of forgings. *NDT & E International*, 143, 103052. DOI: <https://doi.org/10.1016/j.ndteint.2024.103052>
11. Wu, Q., Qin, X., Xiong, X. (2025) Investigating the effects of data and image enhancement techniques on crack detection

- accuracy in FMPI. *Advanced Engineering Informatics*, 65(PA), 103169. DOI: <https://doi.org/10.1016/j.aei.2025.103169>
11. Wang, H., Du, W., Xu, G. et al (2024) Automated crack detection of train rivets using fluorescent magnetic particle inspection and instance segmentation. *Sci. Reports*, **14**, 10666. DOI: <https://doi.org/10.1038/s41598-024-61396-6>
 12. Ivasenko, I.B., Vorobel, R.A., Uchanin, V.M. et al. (2023) Detection of chalcopyrite in digital images of copper ore sample sections. *Information Extraction and Processing*, 51(127), 52–61. DOI: <https://doi.org/10.15407/vidbir2023.51.052>
 13. Storozhyk, D., Protasov, A., Kuts, Yu. et al. (2024) Enhancing neural network efficiency in automated image analysis for thermal nondestructive testing. *J. of Theoretical and Applied Mechanics*, **54**, 242–252. DOI: <https://doi.org/10.55787/jtams.24.54.2.242>
 14. Redmon, J., Divvala, S., Girshick, R., Farhadi, A. (2016) You only look once: Unified, real-time object detection. In: *Proce. of the IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*, 779–788. DOI: <https://doi.org/10.48550/arXiv.1506.02640>
 15. Wang, J., Wang, Y., Li, X. et al (2025) SCI-YOLO11: An improved defect detection algorithm for transmission line insulators based on YOLO11. *Plos One*, 20(10), e0322561. DOI: <https://doi.org/10.1371/journal.pone.0322561>
 16. Everingham, M., Van Gool, L., Williams, C.K.I. et al (2010) The PASCAL visual object classes (VOC) challenge. *Int. J. of Comput. Vis.*, **88**, 303–338. DOI: <https://doi.org/10.1007/s11263-009-0275-4>

AUTOMATION OF THE DEFECTS DETECTION PROCESS IN MAGNETIC PARTICLE INSPECTION IMAGES

A.S. Momot¹, V.S. Yakotyuk¹, Iu.Yu. Lysenko^{1,3}, R.M. Galagan¹, Y. Mirchev^{2,3}

¹National Technical University of Ukraine «Igor Sikorsky Kyiv Polytechnic Institute». 37 Beresteysky Ave., 03056, Kyiv, Ukraine.

E-mail: j.lysenko@kpi.ua

²Institute of Mechanics at the Bulgarian Academy of Sciences. 1113, Acad. G. Bonchev Str., Sofia, Bulgaria

³Center of Competence for Mechatronics and Clean Technologies «Mechatronics, Innovation, Robotics, Automation and Clean Technologies» – MIRACle, Bulgaria. E-mail: a.momot@kpi.ua

This paper considers the possibilities of applying deep learning models of the YOLO11 family to the task of automating defect detection in magnetic particle inspection images. Magnetic particle inspection is widely used to test ferromagnetic parts, and decisions based on its results affect operational safety and costs. At the same time, magnetic particle inspection images often contain a grainy background, uneven lighting and glare, which masks low-contrast magnetic patterns and reduces the reliability of simple analysis methods. A software approach is proposed in which camera frames are automatically processed by a neural network, and the output forms defect localization frames and classifies them by type. Real images were used to train the models, the number of which was increased by augmentation through transformations that simulate typical deviations in shooting parameters. The dataset was labelled according to three defect classes and divided into training, validation, and test sets. Training and comparison of the YOLO11n, YOLO11s, YOLO11m, and YOLO11l models were performed using the Precision, Recall, mAP50, and mAP50-95 metrics and frame processing time. It was shown that increasing the size of the model does not provide a proportional increase in quality on the available dataset. The best balance between accuracy and speed was provided by the YOLO11m model with an mAP50-95 score of 0.238 and a frame processing time of 29.5 ms. Analysis of the training results showed higher quality detection of linear defects and complexity in detecting small group defects, which is due to the lack of training data and noisy background. Recommendations are given on methods to reduce false positives and expand data to improve the representativeness of the training set. 16 Ref., 4 Tabl., 5 Fig.

Keywords: magnetic particle inspection, defect detection, computer vision, artificial intelligence, neural networks

Acknowledgment

This work was accomplished by the Center of Competence for Mechatronics and Clean Technologies «Mechatronics, Innovation, Robotics, Automation and Clean Technologies» – MIRACle, with the financial support of contract No. BG16RFPR002-1.014-0019-C01, funded by the European Regional Development Fund (ERDF) through the Programme «Research, Innovation and Digitalisation for Smart Transformation» (PRIDST) 2021–2027.

ORCID

Момот А.С. – <https://orcid.org/0000-0001-9092-6699>, Якотюк В.С. – <https://orcid.org/0009-0006-5253-4241>,
Лисенко Ю.Ю. – <https://orcid.org/0000-0001-9110-6684>, Галаган Р.М. – <https://orcid.org/0000-0001-7470-8392>,
Мірчев Й. – <https://orcid.org/0009-0002-4882-5282>

КОНФЛІКТ ІНТЕРЕСІВ

Автори заявляють про відсутність конфлікту інтересів

АВТОР ДЛЯ ЛИСТУВАННЯ

А.С. Момот

Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського». 03056, Україна, м. Київ, Берестейський проспект, 37.

E-mail: a.momot@kpi.ua

РЕКОМЕНДОВАНЕ ЦИТУВАННЯ

А.С. Момот, В.С. Якотюк, Ю.Ю. Лисенко, Р.М. Галаган, Й. Мірчев (2026) Автоматизоване розпізнавання дефектів на зображеннях магнітопорошкового контролю на основі моделі YOLO11. *Технічна діагностика та неруйнівний контроль*, **03**, 38–47. DOI: <https://doi.org/10.37434/tdnk2026.03.03>

ГОЛОВНА СТОРІНКА ЖУРНАЛУ

<https://patonpublishinghouse.com/ukr/journals/tdnk>

Отримано 01.06.2026

Отримано у переглянутому вигляді 29.07.2026

Підписано до друку 06.09.2026

Оприлюднено 22.09.2026