

А. П. СЛЮСАР

аспірант кафедри комп'ютерно-інтегрованих технологій,
автоматизації, робототехніки та безпекової інженерії
Харківський національний університет радіоелектроніки
ORCID: 0009-0005-1960-7851

І. Ш. НЕВЛЮДОВ

доктор технічних наук, професор,
завідувач кафедри кафедри комп'ютерно-інтегрованих технологій,
автоматизації, робототехніки та безпекової інженерії
Харківський національний університет радіоелектроніки
ORCID: 0000-0002-9837-2309

С. В. ХРУСТАЛЬОВА

кандидат технічних наук, доцент
доцент кафедри кафедри комп'ютерно-інтегрованих технологій,
автоматизації, робототехніки та безпекової інженерії
Харківський національний університет радіоелектроніки
ORCID: 0000-0003-3363-4547

ІНТЕЛЕКТУАЛЬНА АВТОМАТИЗОВАНА СИСТЕМА МОНІТОРИНГУ ДЕФЕКТІВ КОНВЕЄРНИХ СТРІЧОК НА ОСНОВІ НЕЙРОМЕРЕЖЕВИХ АЛГОРИТМІВ КОМП'ЮТЕРНОГО ЗОРУ

У статті розглянуто актуальну науково-прикладну проблему забезпечення надійності стрічкових конвеєрів шляхом впровадження інтелектуальної автоматизованої системи моніторингу дефектів конвеєрних стрічок на промислових підприємствах. Стрічкові конвеєри є критичними елементами технологічних процесів у гірничодобувній, металургійній, цементній, харчовій та багатьох інших галузях, і від їх безперервної роботи залежить функціонування цілих виробничих ліній. Водночас, традиційні методи діагностики стрічок – переважно візуальні огляди персоналом – мають суттєві обмеження, пов'язані з людським фактором, необхідністю зупинки обладнання та неможливістю забезпечити цілодобовий контроль.

Метою дослідження є розроблення та експериментальне обґрунтування ефективності системи комп'ютерного зору для автоматизованого виявлення дефектів стрічки в умовах реального виробництва. Запропоновано комплексну архітектуру системи діагностики, що включає три рівні: модуль класифікації загального стану стрічки (на основі ResNet-18), модуль детекції типових дефектів (Fast R-CNN), а також модуль сегментації пошкоджень для точного виділення контурів та оцінки площі дефектів (Mask R-CNN). Навчання моделей здійснювалося на базі експериментального набору зображень, зібраного з відеопотоку промислової камери.

Отримані результати свідчать про високу точність розпізнавання несправностей і можливість адаптації системи до умов українських підприємств. Модель класифікації демонструє похибку менше 7 %, а детектор і сегментатор забезпечують якісне виявлення та локалізацію дефектів. Показано, що застосування запропонованої системи дозволяє переходити від реактивного технічного обслуговування до предиктивного (прогнозного), мінімізуючи аварії та витрати на ремонт. У перспективі розглядається інтеграція системи з платформами MES/ERP для формування повноцінного цифрового контуру управління технічним станом обладнання у відповідності до концепції Industry 4.0.

Ключові слова: комп'ютерний зір, стрічковий конвеєр, дефекти стрічки, нейромережеві алгоритми, ResNet-18, Fast R-CNN, Mask R-CNN, автоматизована діагностика, сегментація, промислова безпека.

А. П. SLIUSAR

Postgraduate Student at the Department of Computer-Integrated Technologies,
Automation, Robotics and Security Engineering
Kharkiv National University of Radio Electronics
ORCID: 0009-0005-1960-7851



I. SH. NEVLIUDOV

Doctor of Technical Sciences, Professor,
Head of the Department of Computer-Integrated Technologies,
Automation, Robotics and Security Engineering
Kharkiv National University of Radio Electronics
ORCID: 0000-0002-9837-2309

S. V. KHRUSTALOVA

Candidate of Technical Sciences, Associate Professor,
Associate Professor at the Department of Computer-Integrated Technologies,
Automation, Robotics and Security Engineering
Kharkiv National University of Radio Electronics
ORCID: 0000-0003-3363-4547

INTELLIGENT AUTOMATED SYSTEM FOR MONITORING DEFECTS IN CONVEYOR BELTS BASED ON NEURAL NETWORK ALGORITHMS OF COMPUTER VISION

The article addresses a relevant scientific and applied problem of ensuring the reliability of belt conveyors through the implementation of an intelligent automated system for monitoring conveyor belt defects at industrial enterprises. Belt conveyors are critical components of technological processes in the mining, metallurgical, cement, food, and many other industries, and the functioning of entire production lines depends on their continuous operation. At the same time, traditional belt diagnostic methods – primarily visual inspections performed by personnel – have significant limitations associated with the human factor, the need to stop equipment, and the inability to provide continuous monitoring.

The aim of this study is to develop and experimentally substantiate the effectiveness of a computer vision system for automated belt defect detection under real production conditions. A comprehensive diagnostic system architecture is proposed, consisting of three levels: a general belt condition classification module (based on ResNet-18), a typical defect detection module (Fast R-CNN), and a damage segmentation module for precise contour extraction and defect area estimation (Mask R-CNN). The models were trained using an experimental image dataset collected from the video stream of an industrial camera.

The obtained results demonstrate high fault recognition accuracy and the feasibility of adapting the system to the conditions of Ukrainian enterprises. The classification model shows an error rate below 7 %, while the detector and segmenter provide high-quality defect identification and localization. It is shown that the application of the proposed system enables the transition from reactive maintenance to predictive maintenance, minimizing failures and repair costs. Future work considers integrating the system with MES/ERP platforms to establish a full digital loop for equipment condition management in accordance with the Industry 4.0 concept.

Key words: computer vision, belt conveyor, belt defects, neural network algorithms, ResNet-18, Fast R-CNN, Mask R-CNN, automated diagnostics, segmentation, industrial safety.

Постановка проблеми

Конвеєрні системи – один з основних елементів сучасного промислового виробництва, що забезпечує безперервність технологічних процесів. Зокрема, стрічкові конвеєри масово використовуються в гірничодобувній, металургійній, переробній, та логістично-складській галузях, гарантуючи безперервну подачу сировини на наступні етапи виробництва. Від надійності стрічкових конвеєрів залежить робота цілих виробничих ліній: будь-який раптовий вихід з ладу стрічки призводить до вимушених простоїв та значних втрат. Середній строк служби конвеєрної стрічки становить приблизно 1–2 роки, але цей показник дуже варіюється і визначається багатьма факторами експлуатації (навіть в межах одного підприємства час служби двох аналогічних стрічок може суттєво відрізнятись). Вчасне виявлення дефектів стрічки та їхнє усунення є критично важливим для продовження ресурсу конвеєра та зменшення незапланованих простоїв [1].

Традиційна практика діагностики стрічкових конвеєрів на українських підприємствах базується на періодичних оглядах обладнання ремонтним персоналом. Такий підхід має істотні недоліки.

По-перше, в процесі роботи стрічка часто вкрита транспортованим матеріалом, тому оглядати її поверхню важко без зупинки конвеєра.

По-друге, на великих виробництвах неможливо одночасно зупинити всі конвеєри для перевірки, через що частина дефектів може залишатися непоміченою. Людський фактор також відіграє роль: пропущений людиною початковий дефект здатний розвинути у аварійну ситуацію, раптово зупинивши весь технологічний ланцюг. Крім того, різні дефекти мають неоднаковий вплив на виробництво: незначні пошкодження стрічки дозволяють планово виконати ремонт, тоді як критичні розриви потребують негайного втручання. Отже, актуально впроваджувати автоматизовані системи моніторингу стану стрічки в реальному часі, що виключають суб'єктивні помилки та забезпечують диференційований підхід до обслуговування різного обладнання. Одним із передових рішень є використання

комп'ютерного зору та глибокого навчання для безперервної діагностики конвеєрних стрічок. У контексті української промисловості така система дозволить підвищити надійність конвеєрів, знизити аварійність та інтегруватися у сучасні концепції Industry 4.0 (промислова автоматизація та цифровізація виробництва) [8].

Типові пошкодження конвеєрних стрічок, що призводять до відмов:

– абразивний знос стрічки. Поступове стирання гумового робочого шару під дією абразивних властивостей вантажу викликає тонке протирання та деформації стрічки. З часом це призводить до утворення небезпечних протертих ділянок;

– механічні розриви стрічки. Поява наскрізних розривів унаслідок потрапляння неперероблюваних сторонніх предметів (металевих уламків, каміння тощо) в матеріал на стрічці. Такі предмети, затиснуті між барабаном і стрічкою, можуть прорізати полотно конвеєра.

– порушення цілісності покриття через тепловий або хімічний вплив. Транспортування матеріалів із підвищеною температурою або оброблених реагентами (протизмерзаючими сумішами в зимовий період) прискорює старіння та розтріскування гумового шару стрічки. Навіть використання спеціальних маслостійких стрічок не повністю вирішує проблему: під дією агресивних хімікатів їхня поверхня поступово розм'якшується, втрачає еластичність і деформується.

Значна кількість зовнішніх факторів, що впливають на довговічність стрічок, унеможливує встановлення єдиного нормативного строку служби конвеєрного обладнання. У цих умовах автоматизована система діагностики конвеєрів, позбавлена описаних недоліків людського контролю, здатна оперативно і точно виявляти дефекти стрічки, попереджаючи серйозні аварії та забезпечуючи стабільну роботу виробничих ліній. Таким чином, створення системи технічного зору для контролю стану конвеєрних стрічок є актуальною науково-практичною задачею для сучасної промисловості.

Аналіз останніх досліджень і публікацій

За останні роки спостерігається активний розвиток методів штучного інтелекту для діагностики стану конвеєрів. Значна увага приділяється застосуванню глибокого навчання та комп'ютерного зору як ефективних інструментів моніторингу технічного стану стрічок [2]. У літературі описані як контактні методи контролю (на основі сенсорів напруги, акустичних датчиків тощо), так і безконтактні методи (машинний зір, тепловізійний аналіз) для виявлення дефектів стрічок. Безконтактні візуальні системи діагностики стрічки наразі є пріоритетним напрямом через можливість раннього виявлення пошкоджень без втручання в роботу конвеєра.

Численні дослідження демонструють ефективність нейромережевих алгоритмів у задачах розпізнавання пошкоджень конвеєрних стрічок. Наприклад, Zhang і співавт. (2021) розробили вдосконалений метод виявлення дефектів стрічки на основі алгоритму YOLOv3 з використанням нейронної мережі EfficientNet як базової моделі [3]. Цей підхід дозволив одночасно детектувати кілька типів пошкоджень стрічки та досягти середньої точності детекції ~97,3 % при швидкості ~42 кадри/с, що на 10,4 % точніше та 45,9 % швидше порівняно з базовим алгоритмом YOLOv3.

В іншій роботі тієї ж групи (Zhang et al., 2022) акцент зроблено на превентивному виявленні сторонніх об'єктів на конвеєрі, здатних пошкодити стрічку [4]. Запропоновано полегшену глибоку модель (покрощена YOLOv4) для швидкого розпізнавання сторонніх предметів у потоці вугілля; вона досягла точності ~93,7 % та швидкодії 70 кадрів/с, що на 1,7 % точніше і більш ніж втричі швидше за оригінальний YOLOv4. Впровадження такого рішення дозволяє завчасно виявити чужорідний об'єкт у матеріалі та попередити розрив стрічки, істотно підвищуючи безпеку транспортування вугілля на конвеєрі.

Окремою задачею є подолання дефіциту даних для навчання нейромереж у сфері діагностики конвеєрів. Wang et al. (2024) запропонували інноваційний підхід AC-SNGAN – генеративну змагальну мережу з додатковим класифікатором для аугментації (розширення) вибірки зображень дефектів стрічки [5]. Ця модель генерує високоякісні синтетичні зображення кількох типів дефектів, що дозволяє суттєво збільшити обсяг навчальної вибірки. Результати показали, що використання AC-SNGAN дає змогу досягти точності детекції пошкоджень ~99,3 % навіть при навчанні з обмеженого набору (~200 зображень кожного класу). Таким чином, генеративні алгоритми допомагають компенсувати нестачу реальних даних про дефекти конвеєрів та підвищують надійність роботи детекторів.

Інший перспективний напрям – оптимізація нейромережевих моделей для роботи в реальному часі та на вбудованих пристроях. Так, Guo et al. (2023) розробили метод діагностики пошкоджень стрічки на основі нейромережі CenterNet із використанням технології Knowledge Distillation (передавання знань від глибокої моделі-вчителя до легшої моделі-учня) [6]. Такий підхід дозволив отримати компактний та швидкодіючий детектор дефектів без істотної втрати точності, що придатно для реалізації на периферійних обчислювальних пристроях (edge computing).

Крім комп'ютерного зору, розвиваються й сенсорні системи діагностики стрічок. Наприклад, Bzinkowski et al [1]. (2024) описують реалізацію моніторингу стрічкового конвеєра на основі тензометричних датчиків натягу стрічки та аналізу сигналів з використанням ML-алгоритмів. Експериментально показано, що така система в реальному часі розпізнає зміни навантаження на стрічку (класифікуючи тип вантажу з точністю до 100 %) і виявляє заздалегідь створені дефекти, підтверджуючи перспективність застосування машинного навчання для діагностики та предиктивного ремонту конвеєрів.

Важливим аспектом сучасних досліджень є забезпечення інтерпретованості роботи нейромережових діагностичних систем. Оскільки від цих алгоритмів залежить безпека та безперебійність промислових процесів, виникає потреба пояснювати їхні рішення.

В оглядовій роботі Górgiz et al. (2023) відзначено, що глибоке навчання вже демонструє рівень точності на рівні людини в задачах технічної діагностики та автоматизації, але для широкого впровадження в критичних галузях необхідні зрозумілі пояснення для оператора [2]. Розвиток напрямку Explainable AI підвищує довіру до нейромережових моделей та спрощує інтеграцію таких систем у виробничі процеси.

Окрім технічних рішень, література акцентує увагу на питанні готовності підприємств до впровадження подібних інновацій. Зокрема, Martell et al. (2023) пропонують діагностичний інструмент для оцінювання рівня автоматизації і цифровізації виробництва як метод визначення готовності підприємства до реалізації концепції Industry 4.0 [7]. Наявність інтелектуальних систем моніторингу (таких як діагностика конвеєрів на основі нейромереж) виступає однією зі складових «цифрової зрілості» підприємства. Таким чином, аналіз останніх досліджень показує, що поєднання сучасних нейромережових алгоритмів, достатньої кількості якісних даних та врахування практичних вимог (реального часу, пояснюваності, інтеграції) є ключем до успішної реалізації систем автоматичної діагностики конвеєрного обладнання.

Формулювання мети дослідження

Метою даного дослідження є розроблення методики автоматизованої діагностики стрічкового конвеєрного обладнання на основі алгоритмів глибокого навчання, яка забезпечує своєчасне виявлення дефектів конвеєрної стрічки та підвищення надійності роботи конвеєрів в умовах сучасної промисловості.

Для досягнення цієї мети вирішуються такі завдання:

- створення та анування вибірки зображень конвеєрної стрічки з різними типами дефектів;
- навчання нейронної мережі-класифікатора для розпізнавання загального технічного стану стрічки;
- навчання нейромережового детектора для локалізації дефектів на зображенні стрічки;
- навчання моделі сегментації для точного визначення контурів і площі пошкоджень;
- оцінка ефективності запропонованої системи діагностики та визначення її переваг у порівнянні з традиційними підходами.

Викладення основного матеріалу дослідження

Для реалізації поставленої мети розроблено багаторівневу систему комп'ютерного зору для моніторингу стану конвеєрної стрічки. Система складається з трьох послідовних модулів: класифікації, детекції об'єктів та сегментації. Такий підхід дозволяє спочатку визначити загальний стан стрічки (наявність дефектів), далі локалізувати виявлені дефекти на зображенні, а врешті – побудувати точні маски пошкоджених ділянок для оцінки їх площі. Навчання та тестування моделей здійснювалося на експериментальному наборі зображень, зібраному в умовах реального виробництва [10]. Нижче наведено детальний опис кожного модуля системи та отримані результати.

Класифікатор технічного стану конвеєрної стрічки.

Класифікація зображень стрічки полягає у автоматичному визначенні стану стрічки (справна чи з дефектом певного типу) на основі аналізу її зображення. Для підготовки даних було використано відеопотік з високошвидкісної камери (частота 250 кадрів/с), встановленої над рухомою стрічкою. З відео виділено тисячі окремих кадрів, на кожному з яких видно фрагмент стрічки. Кожне отримане зображення вручну віднесено до одного з класів залежно від домінуючого дефекту на стрічці. Наприклад, якщо на кадрі зафіксовано розрив або великі тріщини стрічки, таке зображення отримувало мітку класу «Розрив стрічки» – як найбільш критичний тип дефекту з точки зору безаварійної роботи обладнання. Аналогічно виділено класи інших пошкоджень (пошкодження краю стрічки, поверхневі тріщини тощо), а зображення без дефектів віднесено до класу «Нормальний стан». Для підвищення універсальності роботи класифікатора на обмеженій вибірці здійснено аугментацію даних – створено додаткові навчальні приклади шляхом випадкових геометричних та колірних трансформацій вихідних зображень (приклад наведено на рис. 1).

В якості моделі для класифікації використано згорткову нейронну мережу ResNet-18, попередньо навченої на великому наборі зображень (ImageNet). Модель імпортовано з бібліотеки PyTorch (Torchvision) і донаведено під цю задачу. Архітектура ResNet-18 складається з послідовності згорткових шарів, які виділяють ознаки зображення, та вихідного повнозв'язного шару, що виконує класифікацію. Згортка – базова операція CNN – обчислюється як розгорнутий скалярний добуток матриці ваг фільтра на відповідний фрагмент пікселів зображення. Формально результат 2D-згортки можна записати так:

$$y[m, n] = \sum_{k=1}^c \sum_{i=1}^H \sum_{j=1}^W x_k[m+i, n+j] \cdot W_k[i, j] + b, \quad (1)$$

де $y[m, n]$ – значення вихідного зображення (тензора ознак) у позиції (m, n) після застосування фільтра;

x_k – значення вхідного зображення в k -му каналі (колірному) за координатами $[m+i, n+j]$;

W_k – значення ваги фільтра (ядра згортки) для k -го каналу в положенні $[i, j]$;

b – зміщення (константа), яка додається до суми.




Рис. 1. Результати аугментації даних

При донавчанні ResNet-18 заморожено ваги всіх згорткових шарів (тобто градієнти на них не рахувалися, щоб зберегти наперед вивчені ознаки) і замінено лише вихідний повнозв'язний шар новим – з кількістю нейронів, що відповідає цільовим класам (у даному випадку 4 класи технічного стану стрічки).

В якості функції втрат обрана крос-ентропія CrossEntropyLoss(), оптимізація параметрів виконувалася методом Adam (Adaptive Moment Estimation) з навчальною вибіркою, збільшеною аугментаціями. Модель-класифікатор навчалася протягом 20 епох, після чого значення функції втрат стабілізувалося на рівні $\sim 0,07$ (тобто умовна похибка класифікації $\sim 7\%$). Результат роботи класифікатора на тестових зображеннях ілюструє рисунок 2, де показано приклад розпізнавання: модель віднесла зображення до класу «Стрічка з пошкодженим краєм».



Рис. 2. Результати роботи моделі «Стрічка з пошкодженим краєм»

Отриманий класифікатор пропонується використовувати на першому рівні діагностичної системи – для контролю наявності дефектів стрічки під час роботи конвеєра. У разі, якщо модель сигналізує про виявлення пошкодження, видається попередження для служби експлуатації щодо необхідності огляду конкретного конвеєра. Таким чином, простий у реалізації алгоритм класифікації дозволяє автоматично стежити за справним станом десятків конвеєрів одночасно і оперативно ідентифікувати стрічки, що потребують уваги фахівців. На відміну від періодичних ручних перевірок, така система моніторингу працює безперервно та не відволікає персонал, доки не буде реально зафіксовано ознаки дефекту.

Детектор дефектів конвеєрної стрічки.

Детекція об'єктів (у даному випадку – дефектів) – це задача комп'ютерного зору, яка полягає в знаходженні на зображенні об'єктів певних класів і визначенні координат їхнього розташування. На відміну від класифікації, що лише видає клас для всього зображення, детектор повертає також положення кожного знайденого об'єкта, зазвичай у вигляді координат рамки, що його обмежує. Для навчання моделі-детектора був підготовлений окремий набір даних: частина зображень стрічки (відібраних з відео) з різними дефектами була вручну розмічена за допомогою програми CVAT (Computer Vision Annotation Tool). Розмітка виконувалася у вигляді полігональних

областей на зображенні, які охоплюють видимий контур дефекту (тріщини, розриву або проблемного стику стрічки). Кожному зображенню при розмітці присвоєно унікальний ID, зазначено клас дефекту та координати полігона, що окреслює дефект. Якщо на одному фото присутні кілька дефектів, кожен із них розмічався окремо. Результати анотування збережено у форматі XML, після чого за допомогою скриптів Python ці дані конвертовано у зручну таблицю (dataframe): для кожного дефекту зберігається ім'я файлу зображення, розміри зображення, мітка класу дефекту і координати вершин полігональної області, яка його охоплює. На основі цих координат при навчанні моделі будувалися прямокутні рамки навколо дефектів – вони слугували цільовими рамками для алгоритму детекції (рис. 3).

```
Drawing box for label: 1 with confidence score: 0.9988231062889099
Drawing box for label: 2 with confidence score: 0.9869280457496643
```




Рис. 3. Результати розпізнавання

Як базову архітектуру детектора обрано модель Fast R-CNN – класичну згорткову нейромережу для виявлення об'єктів. В якості оптимізатора застосовано стохастичний градієнтний спуск (SGD). Правило оновлення ваг мережі при кожному кроці навчання описується виразом:

$$\theta_{t+1} = \theta_t - \eta \nabla J(\theta_t; x^{(t)}, y^{(t)}), \quad (2)$$

де θ_t – вектор параметрів моделі (вагових коефіцієнтів) на t -ій ітерації;

η – коефіцієнт швидкості навчання (learning rate);

$\nabla J(\theta_t; x^{(t)}, y^{(t)})$ – градієнт функції втрат J за параметрами θ , обчислений на випадковому навчальному прикладі $(x^{(t)}, y^{(t)})$.

Після навчання детектор успішно розпізнає дефекти на контрольних зображеннях стрічки, автоматично будує рамки навколо знайдених пошкоджень та оцінює ймовірність належності кожного об'єкта до того чи іншого класу. На рисунку 3 наведено приклад спрацювання моделі: програма коректно виявила на зображенні тріщину стрічки, позначивши її рамкою з відповідним класом. Розроблений детектор здатний розпізнавати основні типи дефектів стрічки – тріщини, пориви та проблеми зі стиком – у різних положеннях кадру.

Включення модуля детекції розширює можливості діагностики конвеєрів, дозволяючи не лише визначити сам факт наявності несправності, але й точно вказати місце розташування дефекту на стрічці. Це особливо корисно для обладнання, встановленого в важкодоступних місцях (транспортери під землею, під стелею цеху, в обмеженому просторі тощо), де оперативний доступ персоналу ускладнений. У таких випадках автоматичний детектор може повністю замінити первинний огляд: система сама «покаже», де саме на стрічці виникла проблема, і чи потребує вона негайного втручання. Таким чином, пропонується модель-детектор здатна знизити навантаження на сервісні служби та підвищити швидкість реагування на потенційно аварійні ситуації [9].

Сегментація дефектів стрічки.

Для поглибленого аналізу пошкоджень реалізовано модуль семантичної сегментації, задача якого – піксельно точно виділити область дефекту на зображенні. Сегментація ділить зображення на кілька областей, кожна з яких відповідає певному об'єкту чи частині об'єкту. У даному випадку сегментація дозволяє побудувати точну маску дефекту стрічки, тобто контур тріщини чи розриву (рис. 4).

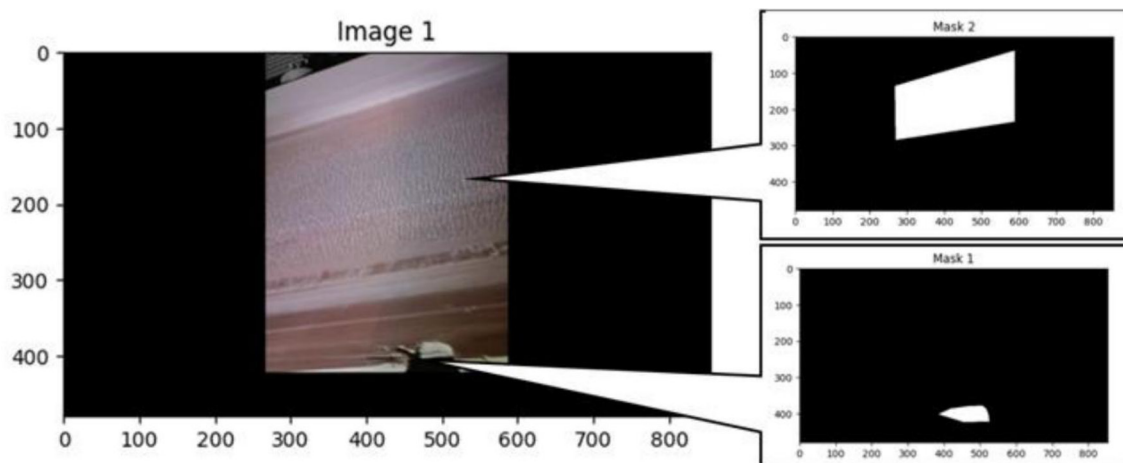


Рис. 4. Маски об'єктів типу «тріщина» та «розрив краю стрічки»

Це дає більш детальну інформацію про характер і розмір пошкодження, ніж проста рамка детектора. Для вирішення задачі сегментації використано нейромережеву модель Mask R-CNN – сучасне розширення архітектури R-CNN, що одночасно виконує і детекцію об'єктів, і побудову масок цих об'єктів. Головна відмінність Mask R-CNN від детектора Fast R-CNN полягає у додатковій гілці нейронної мережі, яка генерує бінарну маску для кожного знайденого об'єкта, а не лише координати рамки. Таким чином, Mask R-CNN може сегментувати об'єкти на зображенні, вирішуючи дану задачу.

Модель Mask R-CNN було ініціалізовано з відкритих попередньо навчених ваг (COCO dataset) і донавчено на датасеті анованих зображень стрічок. Оскільки для навчання сегментації потрібні точні маски дефектів, ми використали наявну полігональну розмітку: вона була перетворена у растрові маски відповідних областей. Таким чином, нейромережа отримала на вході зображення стрічки, а як правильний результат – карту сегментації, де пікселі дефекту позначені 1, фон – 0. Функція втрат моделі містила дві складові: похибку класифікації (для правильного розпізнавання класу дефекту) та похибку сегментації (для точності побудови маски). Після завершення навчання Mask R-CNN продемонструвала здатність правильно виділяти пікселі дефектів навіть у складних випадках (наприклад, коли тріщина межує з краєм стрічки або заповнена матеріалом).

Результати передбачення роботи моделі на тестовій вибірці зображень представлені рисунку 5.




Рис. 5. Виділення дефектів стрічки по контуру їх розташування

Математично вихід моделі сегментації для кожної виявленої області можна подати як:

$$m = \text{sigmoid}(W_m \cdot f(x_i)), \quad (3)$$

де m – двовимірний масив (маска сегментації) для i -тої області інтересу;

W_m – навчена матриця ваг сегментаційної гілки;

$f(x_i)$ – вектор ознак, виділених з ROI базовою CNN;

$\text{sigmoid}()$ – логістична функція активації, що перетворює вихідні значення у діапазон $[0; 1]$ (ймовірність належності пікселя до класу «дефект»).

У результаті застосування сигмоїди отримуємо маску, значення якої пороговуються для отримання бінарного зображення області дефекту.

Сегментація дефектів стрічки значно розширює можливості діагностики. По-перше, знаючи точну форму та площу дефектної області, можна кількісно оцінити ступінь пошкодження стрічки. Це, в свою чергу, дозволяє прогнозувати залишковий ресурс стрічки – наприклад, на основі площі наскрізних розривів або загальної довжини тріщин можна приблизно розрахувати, скільки часу стрічка ще зможе пропрацювати без аварій.

По-друге, характерні риси маски (форма дефекту, положення відносно країв стрічки) дають можливість ідентифікувати причини виникнення пошкодження. Зокрема, розташування тріщин вздовж напрямку руху може вказувати на перевантаження або неякісне центрування стрічки; множинні дрібні дефекти по всій ширині – на абразивний знос; пошкодження переважно по краях – на проблеми з роликками або траєкторією стрічки. Такий аналіз допомагає розробити коригувальні заходи для усунення або послаблення негативних чинників, що спричиняють деградацію стрічок.

Висновки

У роботі представлено підхід до автоматизованої діагностики стрічкового конвеєрного обладнання на основі нейромережових алгоритмів комп'ютерного зору, адаптований до умов сучасної промисловості. Розроблено трирівневу систему технічного зору, що включає: модуль класифікації для моніторингу загального стану стрічки, модуль детекції для локалізації дефектів та модуль сегментації для деталізованої оцінки пошкоджень. Експериментальні дослідження підтвердили ефективність запропонованого рішення. Класифікатор на базі ResNet-18 успішно розрізняє наявність дефектів на стрічці у реальному часі, що дозволяє оперативно виявити проблемний конвеєр і залучити персонал лише за потреби. Нейромережовий детектор (Fast R-CNN) забезпечує автоматичне знаходження типових дефектів (тріщин, розривів, несправних стиків) на зображеннях з високою точністю, усуваючи фактор людських помилок при огляді. Модуль сегментації (Mask R-CNN) надає повну картину пошкоджень – будує точні маски дефектних зон, що дозволяє розрахувати площу пошкодження і краще зрозуміти природу дефекту.

У цілому, впровадження такої системи дасть змогу перейти від реагування на аварії до їх попередження: модель фіксує дефект стрічки на ранній стадії, оцінює його критичність та інформує службу експлуатації, яка може завчасно спланувати ремонт з мінімальним впливом на виробництво.

Практична цінність отриманих результатів для української промисловості полягає в підвищенні надійності та безпечності роботи конвеєрів. Система комп'ютерного зору працює цілодобово і не потребує зупинки обладнання, тому ризик пропустити небезпечний дефект знижується до мінімуму.

Однак необхідно зазначити, що для стабільної роботи системи в польових умовах необхідно використовувати промислові відеокамери зі ступенем захисту не нижче IP64 (витримують пил і вологу). В ході дослідження було застосовано саме такі камери, що підтвердило їх придатність – отримані зображення достатньо якісні для аналізу алгоритмами.

Запропоноване рішення легко масштабується і інтегрується у ширші інформаційні системи підприємства. В перспективі дані, отримані від моделей діагностики (про місця та ступінь пошкоджень стрічок), можна використовувати для оптимізації графіка обслуговування різних конвеєрів за ступенем їх критичності для виробництва. Наприклад, конвеєри, відмови яких паралізують всю лінію, повинні оглядатися/замінюватися в першу чергу. Інтеграція системи моніторингу стрічок з корпоративними платформами рівня MES/ERP дозволить автоматично враховувати її показники при плануванні ремонтів і замовленні запасних частин, що відповідає концепції «розумного» виробництва (Industry 4.0). Загалом, результати роботи демонструють, що застосування нейромережових алгоритмів для діагностики конвеєрного обладнання є дієвим шляхом підвищення ефективності українських промислових підприємств, забезпечуючи безперервність та безпеку технологічних процесів.

Список використаної літератури

1. Application of machine learning algorithms in real-time monitoring of conveyor belt damage / D. Bzinkowski та ін. *Applied sciences*. 2024. Т. 14, № 22. С. 10464. URL: <https://doi.org/10.3390/app142210464>
2. Computational approaches to Explainable Artificial Intelligence: advances in theory, applications and trends / J. M. Górriz та ін. *Information fusion*. 2023. Т. 100. С. 101945. URL: <https://doi.org/10.1016/j.inffus.2023.101945>
3. Deep learning-based damage detection of mining conveyor belt / M. Zhang та ін. *Measurement*. 2021. Т. 175. С. 109130. URL: <https://doi.org/10.1016/j.measurement.2021.109130>
4. Proactive measures to prevent conveyor belt failures: deep learning-based faster foreign object detection / M. Zhang та ін. *Engineering failure analysis*. 2022. С. 106653. URL: <https://doi.org/10.1016/j.engfailanal.2022.106653>

5. AC-SNGAN: Multi-class data augmentation for damage detection of conveyor belt surface using improved ACGAN / G. Wang та ін. *Measurement*. 2023. С. 113814. URL: <https://doi.org/10.1016/j.measurement.2023.113814>
6. Machine vision based damage detection for conveyor belt safety using Fusion knowledge distillation / X. Guo та ін. *Alexandria engineering journal*. 2023. Т. 71. С. 161–172. URL: <https://doi.org/10.1016/j.aej.2023.03.034>
7. Evaluation of the degree of automation and digitalization using a diagnostic and analysis tool for a methodological implementation of industry 4.0 / F. Martell та ін. *Computers & industrial engineering*. 2023. С. 109097. URL: <https://doi.org/10.1016/j.cie.2023.109097>
8. Хрустальова С., Слюсар А. Використання новітніх логістичних технологій для оптимізації діяльності сучасних підприємств. *Радіоелектроніка та молодь у XXI столітті. Т. 2: Конференція «Автоматизовані системи та комп'ютеризовані технології радіоелектронного приладобудування»*. Харків, Україна, 2024. URL: <https://doi.org/10.30837/iyf.asctredb.2024.047>
9. Слюсар А. П., Хрустальова С. В. Методи та алгоритми локалізації RFID-міток: сучасні підходи та перспективи. *Виробництво & мехатронні системи 2024: матеріали VIII-ої Міжнар. конф., м. Kharkiv, 25–26 жовт. 2024 р. Kharkiv, 2024. С. 87–91.*
10. Application of bayes theory model to determine the optimal variant of technological process for production of MEMS components / I. Nevludov та ін. *2024 IEEE 19th international conference on the perspective technologies and methods in MEMS design (MEMSTECH)*, м. Zozuli, Ukraine, 16–19 трав. 2024 р. 2024. С. 24–28. URL: <https://doi.org/10.1109/memstech63437.2024.10620011>

References

1. Bzinkowski, D., Rucki, M., Chalko, L., Kilikevicius, A., Matijosius, J., Cepova, L., & Ryba, T. (2024). Application of machine learning algorithms in real-time monitoring of conveyor belt damage. *Applied Sciences*, 14(22), 10464. <https://doi.org/10.3390/app142210464>
2. Górriz, J. M., Álvarez-Illán, I., Álvarez-Marquina, A., Arco, J. E., Atzmueller, M., Ballarini, F., Barakova, E., Bologna, G., Bonomini, P., Castellanos-Dominguez, G., Castillo-Barnes, D., Cho, S. B., Contreras, R., Cuadra, J. M., Domínguez, E., Domínguez-Mateos, F., Duro, R. J., Elizondo, D., Fernández-Caballero, A.,... Ferrández-Vicente, J. M. (2023). Computational approaches to Explainable Artificial Intelligence: Advances in theory, applications and trends. *Information Fusion*, 100, 101945. <https://doi.org/10.1016/j.inffus.2023.101945>
3. Zhang, M., Shi, H., Zhang, Y., Yu, Y., & Zhou, M. (2021). Deep learning-based damage detection of mining conveyor belt. *Measurement*, 175, 109130. <https://doi.org/10.1016/j.measurement.2021.109130>
4. Zhang, M., Cao, Y., Jiang, K., Li, M., Liu, L., Yu, Y., Zhou, M., & Zhang, Y. (2022). Proactive measures to prevent conveyor belt failures: Deep learning-based faster foreign object detection. *Engineering Failure Analysis*, 106653. <https://doi.org/10.1016/j.engfailanal.2022.106653>
5. Wang, G., Yang, Z., Sun, H., Zhou, Q., & Yang, Z. (2023). AC-SNGAN: Multi-class data augmentation for damage detection of conveyor belt surface using improved ACGAN. *Measurement*, 113814. <https://doi.org/10.1016/j.measurement.2023.113814>
6. Guo, X., Liu, X., Gardoni, P., Glowacz, A., Królczyk, G., Incecik, A., & Li, Z. (2023). Machine vision based damage detection for conveyor belt safety using Fusion knowledge distillation. *Alexandria Engineering Journal*, 71, 161–172. <https://doi.org/10.1016/j.aej.2023.03.034>
7. Martell, F., López, J. M., Sánchez, I. Y., Paredes, C. A., & Pisano, E. (2023). Evaluation of the degree of automation and digitalization using a diagnostic and analysis tool for a methodological implementation of industry 4.0. *Computers & Industrial Engineering*, 109097. <https://doi.org/10.1016/j.cie.2023.109097>
8. Khrustaleva, S., & Slyusar, A. (2024). Using the latest logistics technologies to optimise the activities of modern enterprises. In *Radioelectronics and Youth in the 21st Century. Vol. 2: Conference 'Automated Systems and Computerised Technologies in Radioelectronic Instrument Engineering'*. Press of the Kharkiv National University of Radioelectronics. <https://doi.org/10.30837/iyf.asctredb.2024.047>
9. Slyusar, A. P., & Khrustalova, S. V. (2024). Methods and algorithms for localising RFID tags: Modern approaches and prospects. In *Production & Mechatronic Systems 2024* (pp. 87–91).
10. Nevludov, I., Khrustalova, S., Chala, O., & Slyusar, A. (2024). Application of bayes theory model to determine the optimal variant of technological process for production of MEMS components. У *2024 IEEE 19th international conference on the perspective technologies and methods in MEMS design (MEMSTECH)* (с. 24–28). IEEE. <https://doi.org/10.1109/memstech63437.2024.10620011>

Дата першого надходження статті до видання: 08.01.2026

Дата прийняття статті до друку після рецензування: 12.02.2026

Дата публікації (оприлюднення) статті: 30.04.2026