

МЕТОДИ РОЗПІЗНАВАННЯ ПОВЕРХНЕВИХ ДЕФЕКТІВ НА ТОНКОЛИСТОВИХ МАТЕРІАЛАХ ДЛЯ АВТОМАТИЗАЦІЇ ВІЗУАЛЬНОГО КОНТРОЛЮ (Огляд)

А.С. Новодранов

ІЕЗ ім. Є.О. Патона НАН України. 03150, м. Київ, вул. Казимира Малевича, 11. E-mail: artur19940731@gmail.com

Використання методів розпізнавання поверхневих дефектів з метою автоматизації процесу візуального неруйнівного контролю на виробництвах прокату тонколистових матеріалів стає все актуальнішою задачею. Застосування автоматизованих систем розпізнавання поверхневих дефектів призводить до завчасного виявлення пошкоджень, визначення їх класу та рівня безпеки. Після класифікації дефекту система без участі оператора приймає рішення про подальші дії. Наявність таких систем запобігає простою обладнання та знижує вплив людського фактора на виробництво. Визначено показники ефективності класифікатора, а також проведено аналіз наявних методів розпізнавання поверхневих дефектів. Визначено переваги та недоліки методів. Проаналізовано доцільність використання методу залежно від типу поверхні та геометричних характеристик дефекту. Визначено доцільність використання декількох методів для забезпечення більшої точності розпізнавання поверхневих дефектів. Відзначено значну перспективність застосування методів машинного навчання на базі нейронних мереж. Перспективність застосування нейронних мереж у системах автоматизованого розпізнавання поверхневих дефектів обумовлена можливістю автоматичного виділення ознак із зображення, а також обробки складних структур. Бібліогр. 32, табл. 1, рис. 7.

Ключові слова: поверхневі дефекти, методи пошуку дефектів, листові матеріали, автоматизований моніторинг, розпізнавання дефектів, обробка зображень

Вступ. Інтенсивний розвиток промисловості ставить завдання підвищення якості продукції. Зважаючи на це, автоматизований моніторинг поверхневих дефектів тонколистових матеріалів має важливе значення в багатьох галузях промисловості [1–4]. Якість тонколистових виробів визначається рядом механічних характеристик і наявністю дефектів залежно від матеріалу, з якого він виготовлений. Наявність дефектів призводить до простою виробничого обладнання через необхідність зупинки формуючої машини, усунення обриву або дефекту, що негативно відображається на продуктивності виробництва. Разом з тим, сучасні комп'ютерні технології та методи штучного інтелекту дозволяють досягти суттєвого ефекту при вдосконаленні систем керування. Виявлення незначних дефектів на ранніх стадіях виробництва може попередити появу браку та забезпечити відповідність продукції стандартам якості. Застосування промислових камер стандарту GigE дає змогу передавати RAW зображення без компресії на сервер зі швидкістю до 5 Гбіт/с для подальшої обробки та аналізу [5]. Використовуючи методи виявлення та розпізнавання поверхневих дефектів на основі статистичних даних, а саме розміру, частоти виявлення та типу дефектів, спектру яскравості або кольору, а також машинного навчання, можливо з високою точністю визначати та класифікувати дефекти за їхнім ступенем небезпеки. Під терміном «точність визначення» слід ро-

зуміти правильність оцінювання наявності дефекту, а саме здатність методу виявляти, чи присутній дефект на отриманому зображенні. При цьому точність класифікації відображає, наскільки вірно метод встановлює клас виявленого дефекту. За результатами класифікації автоматизована система приймає рішення про подальші кроки.

Мета роботи полягає в аналізі та систематизації методів автоматизованого розпізнавання поверхневих дефектів на тонколистових матеріалах для визначення їхніх переваг, недоліків та потенційних областей застосування.

Постановка задачі розпізнавання та класифікації дефектів. Первинною інформацією в задачі розпізнавання та класифікації дефектів виступає двовимірне кольорове зображення поверхні тонколистового матеріалу. Зображення отримуються шляхом сканування поверхні за допомогою системи цифрових CCD камер. Розмір і форма дефектів, типових для відповідного виробництва, можуть значно відрізнятися. У загальному випадку автоматизовані системи моніторингу поверхні тонколистових матеріалів здатні виявляти дефекти від 1...2 мм². Для перевірки якості розпізнавання методів використано збільшене зображення наскрізного дефекту прокату паперового полотна розміром 5,8×30,9 мм. Для виявлення дефектів листових матеріалів за їх цифровими зображеннями обрано поширені методи на базі аналізу статистичних даних, а також визначено методи на основі спектрального аналізу, які є менш поширеними при розв'язанні задач машинного бачення. На протива-

гу традиційним методам розпізнавання обрано методи на базі машинного навчання.

Показники ефективності класифікатора.

Оцінка результатів застосування методів виявлення поверхневих дефектів відбувається на основі наступних статистичних категорій (рис. 1):

- TP – істинно позитивна, яка вказує, що реальний дефект визначено як дефект;
- TN – істинно негативна, яка вказує, що реальний дефект визначено як фон;
- FP – хибно позитивна, яка вказує, що фон помилково визначено як дефект;
- FN – хибно негативна, яка вказує, що реальний фон вірно визначено як фон.

Категорії TP, FN, TN, FP є загальноприйнятими та широко застосовуються в багатьох галузях науки, включаючи машинне навчання і комп'ютерний зір [7]. Отже, для високого відсотка виявлення поверхневих дефектів необхідно, щоб переважали TP і FN категорії. Якщо серед категорій виявлення переважають TN і FP, необхідно покращувати відповідні пошукові алгоритми та/або методи. На основі вищезазначених категорій можна розрахувати показники ефективності класифікатора:

- Істинно позитивний показник:

$$TPR = \frac{TP}{TP + FN} \quad (1)$$

- Істинно негативний показник:

$$TNR = \frac{TN}{TN + FP} \quad (2)$$

- Хибно позитивний показник:

$$FPR = \frac{FP}{FP + TN} \quad (3)$$

- Хибно негативний показник:

$$FNR = \frac{FN}{FN + TP} \quad (4)$$

- Показник влучності:

$$Precision = \frac{TP}{FP + TP} \quad (5)$$

- Показник повноти:

$$Recall = \frac{TP}{TN + TP} \quad (6)$$

- Показник точності:

$$Accuracy = \frac{TP + TN}{TN + TP + FP + FN} \quad (7)$$

- G-середнє:

$$G_{mean} = \sqrt{TPR \cdot TNR} \quad (8)$$

- F-міра:

$$F_{measure} = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall} \quad (9)$$

Серед цих показників особливо слід зазначити G-середнє та F-міру. G-середнє – це величина, що оцінює точність на основі істинно позитивного та істинно негативного показника. F-міра визначає загальну продуктивність процесу виявлення поверхневих дефектів на основі параметрів повноти та влучності. Найбільшим показником F-міри є 1, що вказує на ідеальну влучність і повноту.

Методи розпізнавання поверхневих дефектів. Загальна класифікація методів розпізнавання поверхневих дефектів зображена на рис. 2. Для забезпечення максимально ефективного рівня розпізнавання дефектів доцільно комбінувати зазначені методи та підходи залежно від поставленої задачі та умов виробництва.

1. Статистичні підходи. Застосування статистичних підходів виправдано в тих випадках, коли характер дефектів пов'язаний із текстурою поверхні. Тому виявлення, опис або класифікація ознак на основі текстурних характеристик поверхні, таких як ентропія, контраст, кореляція тощо, є важливим елементом задачі розпізнавання поверхневих дефектів [8].

1.1 Метод виділення країв. Важливим етапом розпізнавання дефектів на RAW зображеннях є метод виділення країв. Існує декілька операторів (рис. 3) для виявлення країв поверхневих дефектів на зображеннях.

Оператор Собеля (Sobel operator) є одним із найпопулярніших. Для виявлення горизонтальних і вертикальних країв він використовує згортку ядра. До переваг даного оператора варто віднести його простоту реалізації, а також невеликий час виконання [9, 10]. Однак слід відзначити шорсткість виділених країв у порівнянні з наступним оператором, а саме Кенні (Canny operator) [11].




Рис. 1. Матриця невідповідностей [6]




Рис. 2. Класифікація методів розпізнавання поверхневих дефектів




Рис. 3. Результат застосування операторів виділення країв

На першому етапі при його застосуванні виконується згладжування зображення. Далі вираховується градієнт яскравості для кожного пікселя зображення. На наступному етапі застосовується не максимальне придушення та порогове значення для отримання гладкіших країв у порівнянні з оператором Собеля. До недоліків слід віднести складність реалізації, а також більший час виконання. Схожим на оператор Собеля є оператор

Прюїтта (Prewitt operator). Однаковим для цих методів є використання згортки для виявлення змін яскравості на зображеннях. До відмінностей можна віднести різні характеристики ядра, меншу чутливість до зміни інтенсивності, а також меншу величину градієнта оператора Прюїтта [12]. Також інколи застосовують оператор Робертса, який є одним із найпростіших методів виявлення країв, оператор Кірша, а також оператор Лапласа.

Кількісні характеристики якості розпізнавання за допомогою методу виділення країв наведено в таблиці.

1.2 Локальний бінарний шаблон. Застосування методу локального бінарного шаблону (LBP) має найефективніший результат розпізнавання поверхневих дефектів при їх впливі на текстурні характеристики поверхні. Суть метода (рис. 4) полягає у визначенні для кожного пікселя зображення локального навколишнього контексту. На наступному кроці відбувається порівняння параметра яскравості центрального пікселя з яскравістю пікселів обраного контексту. Далі створюється бінарний шаблон для кожного пікселя шляхом встановлення значення «1» у випадку, коли яскравість центрального пікселя менша або дорівнює яскравості поточного, а також встановленням «0» в іншому випадку. Далі для кожної області зображення створюється гістограма LBP кодів. Дана гістограма відображає кількість появ кожного LBP коду у відповідній області [13–15]. Значною перевагою метода LBP є можливість виявляти зміни текстури на зображенні. Також слід зазначити високу швидкість розрахунків.

Кількісні характеристики якості розпізнавання за допомогою методу локального бінарного шаблону наведено в таблиці.

1.3 Трансформація Хафа. Даний статистичний підхід використовується для виявлення прямих ліній, круглих або еліпсоїдальних форм на зображенні. Алгоритм пошуку прямих ліній складається з наступних кроків. На першому кроці кожна точка зображення переноситься у параметричний простір. У такому просторі пряма лінія представлена двома значеннями: кутом нахилу та відстанню до початку координат. На другому кроці для кожної точки зображення будується графік у параметричному просторі. Цей графік буде відображати гіпотетичну пряму, яка проходить через поточну точку. У випадку, коли декілька точок зображення лежать на одній прямій, їх графіки в параметричному просторі перетинаються в одній точці. Програмування такого алгоритму для виділення прямих ліній засновано на аналізі вищевказаних перетинів у параметричному просторі [16, 17]. Для пошуку об'єктів круглої форми на зображенні застосовується тривимірний простір для наведеного алгоритму, в якому об'єкти пошу-

ку будуть представлені координатами центру та радіусом. Щодо виявлення об'єктів еліпсоїдальної форми, то в такому випадку об'єкт пошуку буде представлений координатами центру, віссю еліпса та кутом нахилу.

Кількісні характеристики якості розпізнавання за допомогою методу трансформації Хафа наведено в таблиці.

1.4 Матриця спільного виникнення. Матриця спільного виникнення являє собою структуру даних, яку використовують для оцінки ступеня схожості або збігу між областями або шаблонами зображення в процесі виявлення поверхневих дефектів. При застосуванні даного методу спершу виокремлюються текстурні характеристики, кольорова інформація, форма, розмір та інші атрибути із зображень, які можуть вказувати на поверхневі дефекти. Виділені ознаки порівнюються з ознаками еталонних шаблонів, які створюються заздалегідь на основі інформації про типи дефектів. На наступному кроці створюється матриця для кожної області зображення, кожна комірка якої містить значення порівняння. Далі відбувається аналіз отриманої матриці для виявлення збігу з еталонними шаблонами [18]. На основі аналізу матриці спільного виникнення система може приймати рішення про наявність дефекту та планувати подальші дії.

Кількісні характеристики якості розпізнавання за допомогою матриці спільного виникнення наведено в таблиці.

1.5 Статистика рівня сірого. Застосування статистики рівня сірого виправдано у тому випадку, коли яскравість і контраст зони дефекту відрізняється від області, яка його оточує. Залежно від задачі даний метод можна використовувати як незалежно, так і в комбінації з іншими методами для кращого результату виявлення поверхневих дефектів. Одним із найзастосовуваніших методів є встановлення порогу яскравості. Встановивши порогове значення рівня сірого та виділивши всі пікселі, яскравість яких перевищує це значення, можна виділити вірогідні поверхневі дефекти, яскравість пікселів яких відрізняється від пікселів навколо нього. На наступному кроці аналізуються отримані гістограми для визначення текстурних особливостей зображення. За результатами аналізу можливо визначити текстурні особливості,




Рис. 4. Принцип роботи методу LBP

які можуть виявитися поверхневими дефектами. Для підвищення вірогідності наявності дефекту за текстурними особливостями поверхні доцільно застосувати один з методів нейронних мереж [19, 20]. Також інколи використовують метод зміни контрасту. Суть цього метода полягає у порівнянні контрасту пікселів вірогідного дефекту та області, що його оточує. Високий рівень контрасту може свідчити про наявність поверхневого дефекту. Кількісні характеристики якості розпізнавання за допомогою методу статистики рівня сірого наведено в таблиці.

До недоліків статистичних методів можна віднести ненадійність у випадку зміни освітленості, а також інтерференції псевдоефектів.

2. Методи, що ґрунтуються на основі аналізу спектра. Дані методи застосовуються для виявлення та аналізу частотних характеристик текстурних особливостей поверхневих дефектів тонколистових матеріалів.

2.1 Перетворення Фур'є. Для аналізу частотних характеристик текстур і деталей на зображеннях поверхневих дефектів часто застосовується перетворення Фур'є. Суть методу полягає в переході від просторового представлення зображення до частотного. Дане перетворення дозволяє аналізувати зображення в частотній області, а також виділяти основні частоти в зображенні, що буде корисним при виділенні країв і текстур. У результаті даного перетворення отримується спектр зображення у вигляді двовимірної матриці, яка містить в собі інформацію про частотні компоненти та їх фазово-частотну характеристику. На наступному кроці відбувається виділення та розпізнавання дефектів на зображенні шляхом аналізу частотних характеристик спектра. Внаслідок того, що дефекти можуть змінювати частотний склад вхідного зображення, тобто містити високочастотні компоненти або шум, тим самим забезпечується видимість вірогідних дефектів у спектрі. Застосування даного перетворення дає змогу виділити дефекти або зміни структури за допомогою придушення небажаних компонентів або підсилення необхідних частот. Після аналізу частотних характеристик можливо повернутися до просторового представлення зображення за допомогою оберненого перетворення Фур'є. На наступному кроці застосовується метод порогової фільтрації для виділення та методи класифікації для визначення типу дефекту [21, 22]. До недоліку методу перетворення Фур'є слід віднести неможливість опису просторової моделі інформаційного сигналу, через що більшість інформації локального опису ігнорується.

Кількісні характеристики якості розпізнавання за допомогою методу перетворення Фур'є наведено в таблиці.

2.2 Вейвлет-перетворення. Даний метод аналізу зображень є досить потужним, а тому часто застосовується для розпізнавання поверхневих дефектів тонколистових матеріалів. Суть методу полягає у розкладі вхідного зображення за масштабами та орієнтаціями за допомогою вейвлет-перетворення. Результатом перетворення виступають вейвлет-коефіцієнти, які представлені у вигляді масштабів та орієнтацій деталей вхідного зображення. Для виділення необхідних дефектів на зображенні треба застосувати фільтрацію відповідних коефіцієнтів. На наступному кроці виконується обернене вейвлет-перетворення для трансформації зображення в піксельну систему координат. Результатом оберненого перетворення є зображення із виділеними поверхневими дефектами. У випадку недостатньої інтенсивності виділених дефектів доцільно застосувати метод порогової фільтрації. Завершальним кроком є застосування алгоритмів класифікації для визначення типу та рівня небезпеки розпізнаного дефекту. За допомогою даного методу можливо розпізнавати дефекти різного розміру шляхом аналізу текстурних особливостей, а також локалізації дефектів різної просторової частоти. До недоліків методу слід віднести чутливість при обранні вейвлетів і параметрів розкладу [23, 24]. Кількісні характеристики якості розпізнавання за допомогою вейвлет-перетворення наведено в таблиці.

2.3 Фільтр Габора. Даний метод ефективніше описує просторову модель інформаційного сигналу, у порівнянні із методом перетворення Фур'є, шляхом модулювання функції ядра Гауса синусоїдальною хвилею певної частоти. Іншими словами, фільтр Габора – це математичний фільтр, який використовують для аналізу структурних і текстурних поверхневих дефектів. Суть методу полягає у визначенні параметрів фільтра, таких як частота, орієнтація та розмір. На основі цих параметрів створюється ядро фільтра, що являє собою двовимірну функцію вигляду синусоїдальної хвилі, обмеженої функцією Гауса. За допомогою оператора згортки отримане ядро функції застосовується до зображення. Таке застосування допомагає виявити текстурні та структурні особливості за допомогою підсилення текстурних деталей у зображенні, які відповідають частотним параметрам фільтра. У результаті застосування фільтра Габора створюється карта реакцій, яка відображає ступінь відповідності текстурних особливостей кожного пікселя зображення. Великі значення на цій карті можуть означати наявність поверхневого дефекту. Карта реакцій надалі опрацьовується за допомогою методу порогової фільтрації для виділення областей дефекту [25, 26]. До недоліків методу слід віднести його неортогональність, внаслідок

лідок чого існує надлишок компонентів ознак, що призводить до зниження ефективності аналізу текстурних зображень. Кількісні характеристики якості розпізнавання за допомогою фільтра Габо наведено в таблиці.

3. Підходи на основі машинного навчання.

Машинне навчання – це набір алгоритмів і методів штучного інтелекту (ШІ), за допомогою яких комп’ютер проходить процес самонавчання без прямих інструкцій. До основних методів машинного навчання слід віднести:

- контрольоване навчання або навчання із вчителем;
- навчання без контролю;
- навчання з підкріпленням.

Найзастосовуванішим алгоритмом машинного навчання є штучна нейронна мережа. Застосування нейронної мережі потребує великого обсягу даних (datasets) для навчання. У якості навчальних даних виступають набори зображень із необхідним типом дефектів і без них. Необхідний набір зображень з дефектами обирається в залежності від поверхні матеріалу, на якій буде проводитись розпізнавання. Типовими дефектами для паперово-картонного виробництва вважаються обрив полотна, зминання та дефекти країв полотна, блукаюча тріщина та ін. На противагу паперово-картонному виробництву, типовими дефектами для металопрокатних виробництв є подряпини, корозія та іржа, відлущування, сліди обробки та ін.

Нейронна мережа в загальному випадку (рис. 5) складається з вхідного шару, відповідального за нормалізацію даних, певної кількості прихованих шарів, які виконують обчислювальні функції, а також вихідного шару.

Методи навчання нейронної мережі поділяються на методи прямого та зворотного розповсюдження помилки. Під час прямого розпов-

сюдження помилки відбувається безпосереднє передбачення відповіді. При зворотному розповсюдженні помилки відбувається мінімізація похибки між відповіддю та передбаченням.

3.1 Контрольоване навчання. Суть метода полягає у навчанні моделі з вчителем на базі розмічених даних, а саме зразків, які мають відому мітку або клас. Контрольоване машинне навчання використовується для навчання моделі класифікатора поверхневих дефектів. На першому кроці створюється база даних із зображеннями ділянок виробу з типовими дефектами із зазначенням їх типу та координат (x, y) зони дефекту. На другому кроці здійснюється відбір із зображень характерних ознак, які можуть бути використані для класифікації дефектів. До характерних ознак належать геометричні або текстурні особливості та ін. Далі обирається відповідна модель машинного навчання, а саме CNN, SVM, RF або інша. Після цього починається процес навчання моделі на розмічених даних із використанням вилучених характерних особливостей дефектів. Під час навчання модель нейронної мережі налаштовується на характеристики зображення, які відповідають різноманітним класам дефектів. Після завершення процесу навчання перевіряється оцінка точності розпізнавання за допомогою набору тестових даних. У разі недостатньої точності проводиться повторне навчання на іншому наборі даних, поки не буде досягнута необхідна точність. До недоліків метода можна віднести необхідність великого обсягу якісно розмічених даних для навчання. До переваг слід віднести високу точність при правильному налаштуванні та навчанні [28, 29].

Слід зазначити, що для розв’язання задач комп’ютерного зору найкраще підходять згорткові нейронні мережі (CNN) внаслідок спеціалізованої архітектури (рис. 6), масштабованості, а також інваріантності до зміщень і спотворень. За допомогою загорткових шарів відбувається автоматичне виділення ознак для виявлення дефектів. Наступним кроком застосовуються шари субдискретизації для зменшення розмірності даних. Для розв’язання задачі класифікації застосовують повнозв’язкові шари.

Обравши модель нейронної мережі YOLOv4 та провівши навчання на тестовій вибірці зображень, яка містила типові дефекти паперового полотна, вдалося досягти наступного результату (рис. 7). Навчальна вибірка розмічених даних складала 80 зображень. Тестова та валідаційна вибірки містили по 10 зображень кожна. Наявність тестової та валідаційної вибірки обумовлені необхідністю перевірки адекватності процесу навчання.

Кількісні характеристики якості розпізнавання за допомогою метода контрольованого навчання наведено в таблиці.




Рис. 5. Загальна структура нейронної мережі [27]




Рис. 6. Типова архітектура CNN мережі [27]




Рис. 7. Результат виявлення та класифікації дефекту за допомогою методу контрольованого навчання

3.2 Навчання без контролю. Даний метод машинного навчання в якості вхідних даних приймає не розмічені дані. Під час навчання модель сама повинна знаходити закономірності або шаблони без інформації про класи можливих дефектів. Принцип кластеризації полягає у прагненні моделі самостійно згрупувати зображення за схожими ознаками без визначених класів. Принцип зниження розмірності полягає у збереженні якомога більшої кількості інформації при зменшенні розмірності даних. Застосування методу навчання

без контролю дає змогу виявляти скриті шаблони або характеристики для подальшого аналізу або кластеризації даних, знаходження аномалій або асоціацій. Але існує складність визначення точності виявлення внаслідок відсутності «правильних» відповідей [30].

3.3 Навчання з підкріпленням. Даний метод машинного навчання полягає у взаємодії агента із навколишнім середовищем. В якості агента виступає нейронна мережа, яка приймає рішення на основі вхідних даних. За прийняті рішення агент отримує позитивну або негативну оцінку. Головною задачею агента є максимізація отримання позитивних оцінок під час навчання та обрання оптимальної стратегії взаємодії. Процес навчання нейронної мережі з підкріпленням базується на ітеративній взаємодії агента із середовищем, з яким він контактує. Таким чином, агент навчається на своїх діях, а також накопиченому досвіді взаємодії із навколишнім середовищем. Даний метод максимально підходить для навчання роботів і автономних систем управління безпілотними транспортними засобами [31, 32].

Слід зазначити, що отримано незадовільні метрики оцінки якості розпізнавання за допомогою методів машинного навчання, а саме, навчання без контролю та навчання з підкріпленням, через складність архітектури і, як наслідок, складного налаштування. У свою чергу варто зазначити, що

Значення метрик оцінки якості розпізнавання розглянутих методів

Номер	Метод	F-міра	Показник точності, %	Показник влучності, %	Показник повноти, %	Час виконання, мс
1	Виділення країв					
	Оператор Кенні	0,96	93,00	96,79	95,44	8,57
	Оператор Прюїтта	0,92	92,34	92,34	90,83	4,12
	Оператор Собеля	0,86	81,00	85,41	86,67	5,36
2	Локальний бінарний шаблон	0,83	82,00	84,51	81,70	21,41
3	Трансформація Хафа	0,78	72,00	75,57	80,18	27,49
4	Матриця спільного виникнення	0,74	73,00	73,46	74,71	24,85
5	Статистика рівня сірого	0,69	66,00	69,26	69,26	11,51
6	Перетворення Фур'є	0,65	63,00	65,77	64,72	36,21
7	Вейвлет-перетворення	0,85	82,00	88,85	80,69	67,32
8	Фільтр Габора	0,85	81,00	84,14	85,44	81,92
9	Контрольоване навчання	0,94	93,00	95,00	93,58	12,38*

Примітка. *Час виконання без урахування часу для навчання нейронної мережі.

метод контрольованого навчання показав високий результат якості розпізнавання. Однак параметр «впевненості» (рис. 7) виявився на рівні 87 %, що можна пояснити недостатньо великим набором навчальних даних. Кожен із наведених вище методів машинного навчання можна використовувати разом для ефективнішого процесу навчання на обмеженому наборі вхідних даних.

Кількісні характеристики якості розпізнавання дефектів на цифрових зображеннях за допомогою розглянутих методів наведено у таблиці.

Висновки

За результатами аналізу методів розпізнавання поверхневих дефектів можна зробити висновок, що методи машинного навчання, а саме загорткових нейронних мереж найкраще підходять для застосування в автоматизованих системах контролю якості виготовлення тонколистових матеріалів. Застосування методів машинного навчання є перспективним внаслідок автоматичного відділення ознак із зображення, а також можливості обробки складних структур даних. До недоліків даних методів слід віднести необхідність великого обсягу даних для навчання. Але правильно налаштована нейронна мережа на вихідному масиві даних для навчання буде тільки підвищувати точність розпізнавання. Розглянуті методи статистичного підходу, а також методи, що ґрунтуються на аналізі спектра, доцільно використовувати у поєднанні з іншими методами для досягнення більшої точності розпізнавання. Застосування методів виявлення країв, статистики рівня сірого, локального бінарного шаблону та ін. у деяких випадках раціонально використовувати як попередню обробку для формування бази навчальних даних для методів машинного навчання. Також визначено випадки та обставини, у яких застосування того чи іншого метода доцільніше через низку причин. Наприклад, визначено, що метод трансформації Хафа показує найвищу ефективність при розпізнаванні геометричних фігур на зображеннях, таких як лінії, кола та еліпси.

Список літератури/References

1. Lv, X., Duan, F., Jiang, J., Fu, X., Gan, L. (2020) Deep metallic surface defect detection: The new benchmark and detection network. *Sensors*, **20**, 1562. DOI: <https://doi.org/10.3390/s20061562>
2. Lv, X., Duan, F., Jiang, J., Fu, X., Gan, L. (2020) Deep active learning for surface defect detection. *Sensors*, **20**, 1650. DOI: <https://doi.org/10.3390/s20061650>
3. Ghorai, S., Mukherjee, A., Gangadaran, M., Dutta, P.K. (2013) Automatic defect detection on hot-rolled flat steel products. *IEEE Trans. Instrum. Meas.*, **62**, 612–621. DOI: <https://doi.org/10.1109/TIM.2012.2218677>
4. Song, K., Yan, Y. (2013) A noise robust method based on completed local binary patterns for hot-rolled steel strip surface defects. *Appl. Surf. Sci.*, **285**, 858–864. DOI: <https://doi.org/10.1016/j.apsusc.2013.09.002>
5. Luo, Q., He, Y. (2016) A cost-effective and automatic surface defect inspection system for hot-rolled flat steel. *Robot. Comput. Integr. Manuf.*, **38**, 16–30. DOI: <https://doi.org/10.1016/j.rcim.2015.09.008>
6. Medium https://miro.medium.com/v2/resize:fit:640/format:webp/1*GDR0pLA0fmHHbk9IZoGPBg.png
7. Alaa Tharwat (2020) Classification assessment methods. *Applied Computing and Informatics*, **17**, 168–192. DOI: <https://doi.org/10.1016/j.aci.2018.08.003>
8. Xuewu, Z., Fang, G., Lizhong, X. (2012) Inspection of surface defects in copper strip using multivariate statistical approach and SVM. *Int. J. Comput. Appl. Technol.*, **43**, 44–50. DOI: <https://doi.org/10.1504/IJCAT.2012.045840>
9. Shi, T., Kong, J., Wang, X., Liu, Z., Zheng, G. (2016) Improved sobel algorithm for defect detection of rail surfaces with enhanced efficiency and accuracy. *J. Cent. South. Univ.*, **23**, 2867–2875. DOI: <https://doi.org/10.1007/s11771-016-3350-3>
10. Borselli, A., Colla, V., Vannucci, M., Veroli, M. (2010) A fuzzy inference system applied to defect detection in flat steel production. In: *Proc. of the IEEE Int. Conf. on Fuzzy Systems, Barcelona, Spain*, 1–6. DOI: <https://doi.org/10.1109/FUZZY.2010.5584036>
11. Shen, Y. (2010) Techniques of machine vision applied in detection of copper strip surface's defects. *Electron. Meas. Technol.*, **33**, 65–67. DOI: https://doi.org/10.1007/978-3-642-15621-2_34
12. Huang, X., Luo, X. (2014) A real-time algorithm for aluminum surface defect extraction on non-uniform image from CCD camera. In: *Proc. of the Int. Conf. on Machine Learning and Cybernetics (ICMLC), Lanzhou, China*, 556–561. DOI: <https://doi.org/10.1109/ICMLC.2014.7009668>
13. Ojala, T., Pietikainen, M., Harwood, D. (1996) A comparative study of texture measures with classification based on feature distributions. *Pattern Recognit.*, **29**, 51–59. DOI: [https://doi.org/10.1016/0031-3203\(95\)00067-4](https://doi.org/10.1016/0031-3203(95)00067-4)
14. Song, K.C., Yan, Y.H., Chen, W.H., Zhang, X. (2013) Research and perspective on local binary pattern. *Acta Automatica Sinica*, **39**, 730–744. DOI: [https://doi.org/10.1016/S1874-1029\(13\)60051-8](https://doi.org/10.1016/S1874-1029(13)60051-8)
15. Liao, S., Zhu, X., Lei, Z., Zhang, L., Li, S.Z. (2007) Learning multi-scale block local binary patterns for face recognition. In: *Proc. of the Int. Conf. on Biometrics, Seoul, Korea*, 828–836. DOI: https://doi.org/10.1007/978-3-540-74549-5_87
16. Sharifzadeh, M., Alirezaee, S., Amirfattahi, R., Sadri, S. (2008) Detection of steel defect using the image processing algorithms. In: *Proc. of the Inmic: Int. Multitopic Conf., 12th IEEE Int. Multitopic Conf., Karachi, Pakistan*, 125–127. DOI: <http://dx.doi.org/10.1109/INMIC.2008.4777721>
17. Bulnes, F.G., Garcia, D.F., Javier de la Calle, F., Usamentia-ga, R., Molleda, J. (2016) A non-invasive technique for on-line defect detection on steel strip surfaces. *J. Nondestruct. Eval.*, **35**, 1–18. DOI: <https://doi.org/10.1007/s10921-016-0370-8>
18. Tsai, D.-M., Chen, M.-C., Li, W.-C., Chiu, W.-Y. (2012) A fast regularity measure for surface defect detection. *Mach. Vis. Appl.*, **23**, 869–886. DOI: <https://doi.org/10.1007/s00138-011-0403-3>
19. Choi, J., Kim, C. (2012) Unsupervised detection of surface defects: A two-step approach. In: *Proc. of the 19th IEEE Int. Conf. on Image Processing (ICIP), Lake Buena Vista, FL, USA*, 1037–1040. DOI: <https://doi.org/10.1109/ICIP.2012.6467040>
20. Djukic, D., Spuzic, S. (2007) Statistical discriminator of surface defects on hot rolled steel. *Proc. of Image and Vision Computing New Zealand 2007*, 158–163.
21. Ai, Y., Xu, K. (2013) Surface detection of continuous casting slabs based on curvelet transform and kernel locality preserving projections. *J. Iron Steel Res. Int.*, **20**, 80–86. DOI: [https://doi.org/10.1016/S1006-706X\(13\)60102-8](https://doi.org/10.1016/S1006-706X(13)60102-8)
22. Paulraj, M.P., Shukry, A.M.M., Yaacob, S., Adom, A.H., Krishnan, R.P. (2010) Structural steel plate damage detection using DFT spectral energy and artificial neural network. In: *Proc. of the 6th Int. Colloquium on Signal Processing & its Applications, Mallaca City, Malaysia*, 1–6. DOI: <https://dx.doi.org/10.1109/CSPA.2010.5545247>

23. Wu, X., Xu, K., Xu, J. (2008) Application of undecimated wavelet transform to surface defect detection of hot rolled steel plates. In: *Proc. of the 1st Int. Congress on Image and Signal Processing, Sanya, China*, 528–532. DOI: <https://doi.org/10.1109/CISP.2008.278>
24. Li, X., Tso, S.K., Guan, X., Huang, Q. (2006) Improving automatic detection of defects in castings by applying wavelet technique. *IEEE Trans. Ind. Electron.*, **53**, 1927–1934. DOI: <https://doi.org/10.1109/TIE.2006.885448>
25. Choi, D.C., Jeon, Y.J., Yun, J.P., Kim, S.W. (2011) Pinhole detection in steel slab images using Gabor filter and morphological features. *Appl. Opt.*, **50**, 5122–5129. DOI: <https://doi.org/10.1364/AO.50.005122>
26. Chol, D.C., Jeon, Y.J., Kim, S.H., Moon, S., Yun, J.P., Kim, S.W. (2017) Detection of pinholes in steel slabs using gabor filter combination and morphological features. *ISIJ Int.*, **57**, 1045–1053. DOI: <https://doi.org/10.2355/isijinternational>. ISIJINT-2016-160
27. Amirhossein Yazdani Abyaneh, Ali Hosein Gharari Foumani, Vahid Pourahmadi (2018) *Deep Neural Networks Meet CSI-Based Authentication*. DOI: <https://doi.org/10.48550/arXiv.1812.04715>
28. Kang, G.W., Liu, H.B. (2005) Surface defects inspection of cold rolled strips based on neural network. In: *Proc. of the 4th Int. Conf. Machine Learning Cybernetics, Canton, China*, 5034–5037. DOI: <https://doi.org/10.1109/ICMLC.2005.1527830>
29. Chen, F., Jahanshahi, M.R. (2018) NB-CNN: Deep learning-based crack detection using convolutional neural network and naive bayes data fusion. *IEEE Trans. Ind. Electron.*, **65**, 4392–4400. DOI: <https://doi.org/10.1109/TIE.2017.2764844>
30. Bulnes, F.G., Usamentiaga, R., Garcia, D.F., Molleda, J. (2012) Vision-based sensor for early detection of periodical defects in web materials. *Sensors*, **12**, 10788–10809. DOI: <https://doi.org/10.3390/s120810788>
31. James Lindsay, Sidney Gigivi (2020) A Novel way of Training a Neural Network with Reinforcement Learning and without Back Propagation. In: *2020 Int. Joint Conf. on Neural Networks (IJCNN)*. DOI: <https://doi.org/10.1109/IJCNN48605.2020.9207659>
32. Seyed Sajad Mousavi, Michael Schukat, Enda Howley (2017) Deep Reinforcement Learning: An Overview. In: *Proc. of SAI Intelligent Systems Conf.*. DOI: <https://doi.org/10.48550/arXiv.1701.07274>

METHODS FOR DETECTING SURFACE DEFECTS ON THIN SHEET MATERIALS FOR VISUAL CONTROL AUTOMATION (REVIEW)

A.S. Novodranov

E.O. Paton Electric Welding Institute of NASU. 11 Kazymyr Malevich Str., 03150, Kyiv, Ukraine.

E-mail: artur19940731@gmail.com

The use of methods for recognizing surface defects in order to automate the process of visual non-destructive control in production of rolled thin-sheet materials is becoming an increasingly urgent task. The use of automated systems for recognizing surface defects leads to early detection of damage and determination of their class and level of danger. After classifying the defect, the system makes a decision on further actions without the operator participation. Presence of such systems prevents equipment downtime and reduces the impact of the human factor on production. The classifier performance metrics was determined and analysis of the current techniques for identifying surface flaws was performed. The advantages and disadvantages of the methods are determined. The feasibility of using the method was analyzed depending on the type of surface and geometric characteristics of the defect. The expediency of using several methods to ensure more accurate recognition of surface defects is determined. Significant prospects for the application of machine learning methods based on neural networks are noted. The prospect of using neural networks in systems for automated recognition of surface defects is due to the possibility of automatic selection of features from the image, as well as processing of complex structures. 32 Ref., 1 Tabl., 7 Fig.

Keywords: surface defects, defect detection methods, sheet materials, automated monitoring, defect recognition, image processing

Отримано 26.03.2024

Отримано у переглянутому вигляді 25.04.2024

Прийнято 30.05.2024

ПЕРЕДБАЧЕННЯ ТЕМПЕРАТУРИ ПЛАВЛЕННЯ МАТЕРІАЛІВ

Костя Траченко, який здобув ступінь доктора наук у Кембріджському університеті та магістра у Львівському, розробив нову теорію, яка вирішує давню проблему фізики — передбачення температури плавлення матеріалів. Його дослідження, опубліковане в журналі *Physical Review E*, є значущим кроком у розумінні фундаментальних властивостей матерії і фазових переходів. Протягом десятиліть учені стикалися з проблемою відсутності універсального опису лінії плавлення на фазових діаграмах температура-тиск. Але тепер теорія професора



Траченка, заснована на останніх досягненнях у теорії рідин, пропонує просте параболичне рівняння для опису цієї лінії. Це означає, що температуру плавлення можна передбачити з використанням фундаментальних фізичних констант. «Простота й універсальність цього результату особливо цікаві», — пояснює професор Траченко. «Це передбачає, що плавлення, незважаючи на його складність, демонструє фундаментальну єдність різних систем, від благородних газів до металів». Робота Траченка отримала 10 найкращих нагород за прорив у фізиці та премію EPSRC-CCP за «видатний внесок у теорію і моделювання фаз конденсованої речовини, включно з теорією рідкого стану».

Theory of Liquids. From Excitations to Thermodynamics

Kostya Trachenko

Queen Mary University of London

2023, 300 стор., ISBN: 9781009355476

