Journal of Iranian Association of Electrical and Electronics Engineers
Vol. 22 No. 4, 2025
DOI: 10.61882/jiaeee.22.4.28

Automatic Wafer Defect Detection in Integrated Circuits Using Deep Learning Models

Ali Souri[1], Samira Mavaddati [2*], Mohammad Gholami[3]

[1] MSc., Electronic Department, Faculty of Engineering and Technology, University of Mazandaran, Babolsar Iran, a.souri09@umail.umz.ac.ir
[2*] Associate Prot., Electronic Department, Faculty of Engineering and Technology, University of Mazandaran, Babolsar, Iran, s.mavaddati@umz.ac.ir
[3] Associate Prot., Electronic Department, Faculty of Engineering and Technology, University of Mazandaran, Babolsar, Iran, m.gholami@umz.ac.ir

Abstract:
This study proposes a deep learning-based framework for automatic wafer defect detection in integrated circuits. Several architectures, including Recurrent Neural Networks (RNN), VGG16, MobileNet, GoogleNet, ResNet-based models, and DenseNet121, were implemented and comparatively evaluated. The employed dataset consisted of wafer images with various defect types, which were preprocessed and augmented using techniques such as rotation, brightness adjustment, and noise injection. Model performance was assessed based on Accuracy, Sensitivity, Recall, and F-measure. The results clearly indicate that deep learning models significantly outperform traditional image processing methods, with DenseNet121 achieving the highest accuracy of 98.33%**.** Furthermore, the comparative analysis revealed that deeper architectures with advanced feature extraction capabilities substantially improve defect detection performance. This research not only highlights the effectiveness of deep models for semiconductor manufacturing but also provides a comprehensive reference for researchers and industry practitioners aiming to enhance defect detection systems and ensure higher quality in integrated circuits.

Keywords: Wafer defect detection, Semiconductor industry, Integrated circuits, Image processing, Convolutional neural networks, Deep learning

Article Type: Research

Received: 27. 10. 2024

Revised: 16. 08. 2025

Accepted: 11. 09. 2025

Corresponding author: S.Mavaddati

Corresponding author's address: Associate Professor, Electronic Department, Faculty of Engineering and Technology, University of Mazandaran, Babolsar, Iran

Copyright © 2025 The Authors. Published by Iranian Association of Electrical and Electronics Engineers.
This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International license (https://creativecommons.org/licenses/by-nc/4.0/). Non-commercial uses of the work are permitted, provided the original work is properly cited.

1. Motivation of the work

The rapid growth of semiconductor technology and the continuous scaling of integrated circuits have significantly increased the complexity of wafer manufacturing processes. As feature sizes shrink and circuit density increases, wafer defects become more diverse and harder to detect using conventional inspection methods. Even minor defects at the wafer level can lead to malfunctioning chips, increased production costs, and reduced yield, making reliable defect detection a critical requirement in modern semiconductor fabrication lines.

Traditional wafer inspection techniques are mainly based on manual visual inspection or classical image processing methods, such as thresholding and handcrafted feature extraction. These approaches suffer from several limitations, including sensitivity to noise, poor generalization to new defect patterns, and high dependency on expert knowledge. Moreover, manual inspection is labor-intensive and unsuitable for large-scale, high-throughput manufacturing environments.

Recent advances in deep learning, particularly convolutional neural networks, have demonstrated remarkable performance in visual inspection tasks due to their ability to learn discriminative features from raw images automatically. Motivated by these advances, this study investigates the effectiveness of various deep learning architectures for automatic wafer defect detection. The primary motivation is to identify a robust and accurate model that can handle diverse defect types while maintaining high reliability. The selection of deep architectures such as DenseNet121 is driven by their proven capability to extract hierarchical and fine-grained features, which are essential for accurate wafer defect classification.

2. Contributions

This study provides several important contributions to the field of intelligent wafer inspection. First, a comprehensive comparative analysis of multiple deep learning architectures, including RNN, VGG16, MobileNet, GoogleNet, ResNet-based models, and DenseNet121, is conducted under the same experimental conditions. Such a unified comparison offers a clear understanding of the strengths and weaknesses of each model in wafer defect detection tasks. Second, an effective preprocessing and data augmentation strategy is employed to improve model generalization and robustness. By incorporating rotation, brightness adjustment, and noise injection, the proposed framework enhances the ability of deep models to handle real-world variations in wafer images. Third, the study evaluates model performance using multiple evaluation metrics, including Accuracy, Sensitivity, Recall, and F-measure, providing a more comprehensive assessment than accuracy alone. This is particularly important in defect detection, where class imbalance and false negatives can have severe consequences. Finally, the superior performance of DenseNet121, achieving an accuracy of 98.33%, demonstrates the effectiveness of dense connectivity in capturing subtle defect features. The findings offer practical guidance for selecting appropriate deep learning models in industrial wafer inspection systems and contribute valuable insights to both researchers and practitioners.

3. Procedures

The proposed study follows a systematic experimental procedure to evaluate the performance of deep learning models for wafer defect detection. A dataset consisting of wafer images with various defect categories was used. The images represent different defect patterns commonly encountered in semiconductor manufacturing processes.

Prior to model training, all images were preprocessed to ensure consistency and improve learning efficiency. Preprocessing steps included image resizing, normalization, and noise reduction. To further enhance model robustness and mitigate overfitting, data augmentation techniques such as rotation, brightness variation, and noise injection were applied.

Several deep learning architectures were implemented and trained, including RNN, VGG16, MobileNet, GoogleNet, ResNet-based models, and DenseNet121. All models were trained using the same dataset split to ensure a fair comparison. Hyperparameters such as learning rate, batch size, and optimizer were selected based on experimental tuning. The trained models were evaluated on a test set using Accuracy, Sensitivity, Recall, and F-measure. Comparative analysis was performed to identify the most effective architecture in terms of detection performance and reliability.

4. Findings

The experimental results clearly demonstrate the effectiveness of deep learning models for wafer defect detection. All evaluated deep architectures significantly outperformed traditional image processing approaches reported in previous studies. Among the tested models, DenseNet121 achieved the highest performance, with an accuracy of 98.33%, along with superior Sensitivity, Recall, and F-measure values.

The results indicate that deeper architectures with advanced feature reuse and dense connections are more capable of capturing complex and subtle defect patterns in wafer images. Models such as MobileNet and VGG16 showed competitive performance but were less effective in distinguishing visually similar defect classes.

The findings confirm that data augmentation plays a crucial role in improving generalization, particularly in scenarios with limited training samples. Overall, the proposed framework demonstrates strong potential for real-world deployment in semiconductor manufacturing environments, offering high accuracy and reliability in automated wafer inspection systems.

5. Conclusion

This study presents a comprehensive deep learning-based framework for automatic wafer defect detection in integrated circuits. By evaluating multiple deep learning architectures under the same experimental setup, the

research provides valuable insights into the suitability of different models for wafer inspection tasks. The results show that DenseNet121 outperforms other architectures, achieving an accuracy of 98.33%, which highlights the importance of dense feature extraction in defect detection. The proposed approach significantly reduces dependency on manual inspection and traditional handcrafted features, offering a scalable and efficient solution for modern semiconductor manufacturing. Overall, the study demonstrates that deep learning models can substantially enhance defect detection accuracy and reliability, contributing to higher product quality and manufacturing efficiency. The findings serve as a useful reference for future research and industrial applications in intelligent wafer inspection.

نشریه مهندسی برق و الکترونیک ایران

نشریه مهندسی برق و الکترونیک ایران، سال بیست و دوم، شماره چهارم، زمستان ۱۴۰۴، صفحات ۲۸-۴۰

DOI: 10.61882/jiaeee.22.4.28

تشخیص خودکار عیوب ویفر در مدارهای مجتمع با بهره‌گیری از مدل‌های یادگیری عمیق

علی سوری[۱]، سمیرا مودّتی[۲]، محمد غلامی[۳]

۱- کارشناسی ارشد مهندسی برق- دانشکده مهندسی و فناوری- دانشگاه مازندران- بابلسر- ایران

a.souri09@umail.umz.ac.ir

۲- دانشیار - دانشکده مهندسی و فناوری- دانشگاه مازندران- بابلسر- ایران

s.mavaddati@umz.ac.ir

۳- دانشیار - دانشکده مهندسی و فناوری- دانشگاه مازندران- بابلسر- ایران

m.gholami@umz.ac.ir

چکیده: در این پژوهش، یک رویکرد مبتنی بر یادگیری عمیق برای تشخیص خودکار عیوب ویفر در مدارهای مجتمع ارائه شده است. برای این منظور، از چندین مدل عمیق شامل شبکه‌های بازگشتی(RNN)، VGG16، MobileNet، GoogleNet، معماری‌های مبتنی بر ResNet و DenseNet121 استفاده گردید. مجموعه‌داده‌ی به‌کاررفته شامل تصاویر ویفر دارای انواع مختلف نقص بوده و با روش‌های پیش‌پردازش و افزایش داده (مانند چرخش، تغییر روشنایی و افزودن نویز) آماده‌سازی شد. عملکرد مدل‌ها بر اساس معیارهایی از جمله دقت(Accuracy)، حساسیت(Sensitivity)، بازخوانی (Recall) و F-measure مورد ارزیابی و مقایسه قرار گرفت. نتایج نشان داد که مدل‌های یادگیری عمیق نسبت به روش‌های کلاسیک مبتنی بر پردازش تصویر عملکرد بسیار بهتری دارند و معماری DenseNet121 با دقت ۹۸/۳۳٪ بهترین نتیجه را به دست آورد. همچنین تحلیل معماری‌ها نشان داد که افزایش عمق شبکه و قابلیت استخراج ویژگی‌های پیچیده به‌طور مستقیم موجب بهبود تشخیص نقص‌ها می‌شود. این پژوهش ضمن ارائه‌ی یک مقایسه جامع بین مدل‌های مختلف، بر اهمیت بهره‌گیری از شبکه‌های عمیق در ارتقاء فرآیندهای کنترل کیفیت در صنعت نیمه‌هادی تأکید می‌کند و می‌تواند به‌عنوان مرجعی عملی برای محققان و صنعتگران در این حوزه مورد استفاده قرار گیرد.

کلمات کلیدی: تشخیص عیوب ویفر، صنعت نیمه‌هادی، مدارهای مجتمع، پردازش تصویر، شبکه‌های کانولوشنالی عمیق

نوع مقاله: پژوهشی

دریافت: ۱۴۰۳/۰۸/۰۶

بازنگری: ۱۴۰۴/۰۵/۲۵

پذیرش: ۱۴۰۴/۰۶/۲۱

نام نویسنده‌ی مسئول: دکتر سمیرا مودّتی

نشانی نویسنده‌ی مسئول: دانشیار گروه مهندسی برق- دانشکده مهندسی و فناوری- دانشگاه مازندران- بابلسر- ایران

حق انتشار این مستند، متعلق به نویسندگان آن است. ۱۴۰۴ ©. ناشر این مقاله، انجمن مهندسین برق و الکترونیک ایران است.

این مقاله تحت گواهی زیر منتشرشده و هر نوع استفاده غیرتجاری از آن مشروط بر استناد صحیح به مقاله و با رعایت شرایط مندرج در آدرس زیر مجاز است.

Creative Commons Attribution-NonCommercial 4.0 International license
(https://creativecommons.org/licenses/by-nc/4.0/)

۱- مقدمه

در دنیای امروز، صنعت الکترونیک و فناوری‌های مرتبط به سرعت در حال پیشرفت هستند و این امر باعث افزایش تقاضا برای محصولات الکترونیکی با کیفیت بالا و عملکرد بهینه شده است. یکی از جنبه‌های کلیدی در تولید این محصولات، فرآیند ساخت ویفرهای نیمه‌هادی است که در قلب مدارهای مجتمع قرار دارند. ویفرها به‌عنوان بستر اصلی برای ایجاد و نصب مدارها و ترانزیستورها، نقش حیاتی در عملکرد نهایی دستگاه‌های الکترونیکی ایفا می‌کنند. به همین دلیل، تشخیص عیوب ویفر به عنوان یک چالش اساسی در این صنعت شناخته می‌شود [۱-۲]. تشخیص خودکار عیوب ویفر از اهمیت ویژه‌ای برخوردار است زیرا هر گونه نقص یا ایراد در سطح ویفر می‌تواند به‌طور مستقیم بر کیفیت و عملکرد نهایی محصول تأثیر بگذارد. عیوب ممکن است شامل ترک‌ها، نقاط معیوب، و ناهماهنگی‌های سطحی باشند که می‌توانند منجر به خرابی‌های جدی در محصولات نهایی شوند. بنابراین، شناسایی و حذف این عیوب در مراحل اولیه تولید بسیار حائز اهمیت است. این کار نه تنها به بهبود کیفیت محصولات کمک می‌کند بلکه می‌تواند به کاهش هزینه‌های تولید و افزایش بهره‌وری خط تولید منجر شود[۳]. با استفاده از الگوریتم‌های یادگیری عمیق و تکنیک‌های پیشرفته پردازش تصویر، می‌توان به شناسایی دقیق‌تر و سریع‌تر عیوب دست یافت که این مسئله در نهایت به افزایش رضایت مشتریان و حفظ اعتبار برند کمک می‌کند. از سوی دیگر، کاربردهای تشخیص خودکار عیوب ویفر فراتر از صنعت الکترونیک است. این فناوری‌ها می‌توانند در صنایع مختلفی همچون تولید تجهیزات پزشکی، خودرو، و حتی صنایع فضایی مورد استفاده قرار گیرند. با توجه به اهمیت کیفیت در این صنایع، داشتن یک سیستم تشخیص دقیق و کارآمد می‌تواند به بهبود عملکرد و ایمنی محصولات کمک کند[۴]. در سال‌های اخیر، روش‌های یادگیری ماشین به ویژه یادگیری عمیق، به عنوان ابزارهای مؤثری در حل مسائل پیچیده مختلف، از جمله تشخیص عیوب ویفر در مدارهای مجتمع معرفی شده‌اند. این روش‌ها به دلیل توانایی در شناسایی الگوهای پیچیده و استخراج ویژگی‌های عمیق از داده‌های ورودی، به‌طور فزاینده‌ای در صنعت نیمه‌هادی و پردازش تصویر مورد استفاده قرار گرفته‌اند. این مقاله بر روی کارایی و توانایی مدل‌های عمیق به‌ویژه در تشخیص عیوب ویفر تمرکز خواهد داشت. با مقایسه عملکرد این مدل‌ها با الگوریتم‌های سنتی یادگیری ماشین، نشان داده خواهد شد که مدل‌های عمیق قادرند دقت و سرعت تشخیص را به‌طور معناداری افزایش دهند. همچنین، با توجه به اینکه مدل‌های عمیق قابلیت خودآموزی و بهبود مستمر را دارند، می‌توانند به عنوان ابزارهای کلیدی در بهبود فرآیندهای کنترل کیفیت در صنعت نیمه‌هادی‌ها به شمار آیند. با استفاده از تکنیک‌های پیشرفته یادگیری عمیق، این مقاله به بررسی توانایی‌های مدل‌های عمیق و نتایج حاصله در حل مسئله تشخیص عیوب ویفر پرداخته و تأثیر این رویکردها را در صنعت الکترونیک و نیمه‌هادی‌ها مورد بررسی قرار خواهد داد. در [۵]، روشی جدید برای طبقه‌بندی خودکار نقص در ویفرهای نیمه‌هادی با استفاده از یادگیری عمیق ارائه شده است. این روش از یک شبکه عصبی کانولوشنال [۱](CNN) برای استخراج ویژگی‌های موثر از تصاویر میکروسکوپ الکترونی روبشی استفاده می‌کند و سپس از الگوریتم نزدیکترین همسایه[۲] (K-NN) برای طبقه‌بندی نقص‌ها استفاده می‌نماید. این روش به طور قابل توجهی عملکرد طبقه‌بندی را نسبت به روش های سنتی بهبود می‌بخشد و می‌تواند نقص‌هایی را که در طول آموزش دیده نشده اند شناسایی کند. [۶]، یک روش مبتنی‌بر یادگیری ماشین و بینایی ماشین را برای طبقه‌بندی نقایص سطحی نیمه‌رساناها معرفی می‌کند. در این مقاله، دو روش برای استفاده از شبکه‌های عصبی پیچشی عمیق برای طبقه‌بندی تصاویر نقایص معرفی شده‌اند: آموزش یک CNN با پنج لایه پیچشی و استفاده از یک شبکه کانولوشنی بازگشتی[۳] (RCNN) پیش‌آموزش‌دیده با یادگیری انتقالی[۴]. یک روش جدید مبتنی‌بر قوانین برچسب‌گذاری در [۷] پیشنهاد شده که نسبت به چرخش و وارونگی الگوها حساس نیست. این مدل با تبدیل رادون و وارونگی هسته برای دستیابی به ناپایداری هندسی استفاده می‌کند. بررسی روش‌های مبتنی‌بر بینایی ماشین برای طبقه‌بندی خودکار نقایص ویفر در [۸] انجام شده است. به همین منظور، یک طبقه‌بند که نقایص نوع A و B را در ویفرها شناسایی می‌کند، پیشنهاد شده است. این طبقه‌بند بر پایه CNN با پنج لایه ساخته شده و با استفاده از ۲۵۰ تصویر از هر کلاس از مجموعه داده‌های نقشه بین ویفر عمل می‌نماید. در [۹] بیان شده است که تشخیص و طبقه‌بندی دقیق عیوب ویفر به عنوان یکی از اجزای مهم در تولید نیمه‌هادی‌ها محسوب می‌شود. اطلاعات قابل تفسیر برای یافتن علل احتمالی عیوب و اتخاذ اقدامات مدیریتی و بهبود کیفیت فراهم می‌گردد. در این مقاله معماری پیشرفته یولو[۵] (YOLO) برای مکان‌یابی و طبقه‌بندی دقیق عیوب ویفر ارائه شده است. در [۱۰]، از الگوریتم‌های یادگیری عمیق مانند شبکه‌های عصبی پیچشی برای طبقه‌بندی عیوب ویفر در صنعت نیمه‌هادی استفاده شده است. در این مقاله، یک رویکرد دو مرحله‌ای که ترکیبی از تکنیک‌های سنتی بینایی کامپیوتری و مدل سبک وزن SqueezeNet است، ارائه و با مدل‌هایCNN عمیق مقایسه شد. روشی نوین برای نمایش شکل الگوی عیب به صورت یک بردار با ابعاد محدود در [۱۱] پیشنهاد شده که به عنوان ورودی برای الگوریتم شبکه عصبی در طبقه‌بندی استفاده می‌شود. ایده اصلی این است که ویژگی‌های توپولوژیکی هر الگو با استفاده از نظریه هومولوژی پایدار از تحلیل داده‌های توپولوژیکی[۶] (TDA)استخراج شود. از طریق آزمایش‌هایی با یک مجموعه داده شبیه‌سازی شده، نشان داده شده که روش پیشنهادی سریع‌تر و با کارایی بالاتری در آموزش و دقت بالاتر نسبت به روش استفاده از شبکه‌های عصبی پیچشی که رایج‌ترین روش برای طبقه‌بندی الگوی عیب نقشه ویفر است، عمل می‌کند. در [۱۲] توضیح داده شده است که روشی رایج برای تحلیل عیوب در کارخانه تولید نیمه‌هادی، طبقه‌بندی خودکار عیوب[۷] (ADC) است که از تصاویر میکروسکوپ نوری یا میکروسکوپ الکترونی روبشی[۸] (SEM) برای طبقه‌بندی عیوب استفاده می‌نماید.

روش نوینی برای طبقه‌بندی الگوهای عیب نقشه ویفر با استفاده از یادگیری انتخابی عمیق در [۱۳] پیشنهاد شده است. روش پیشنهادی دارای گزینه رد است که در صورت بالا بودن خطر اشتباه در طبقه‌بندی، مدل از پیش‌بینی برچسب کلاس خودداری می‌کند و تعادلی بین پوشش پیش‌بینی و خطر اشتباه در طبقه‌بندی ایجاد می‌کند. به منظور دستیابی به شناسایی دقیق عیوب ویفر و بهبود کیفیت و بازده تولید، [۱۴] یک شبکه ادراکی ترکیب ویژگی‌های چندگانه[۹] (MFFP-Net) را پیشنهاد می‌دهد که از مکانیسم‌های ادراک بصری انسان الهام گرفته است. این روال می‌تواند اطلاعات را در مقیاس‌های مختلف پردازش کرده و سپس آن‌ها را تجمیع کند تا مرحله بعدی بتواند ویژگی‌ها را از مقیاس‌های مختلف به‌طور همزمان استخراج کند. در [۱۵]، به بررسی وظیفه طبقه‌بندی عیوب نقشه ویفر تحت نمونه‌های نامتعادل پرداخته شده است. برای بهبود تعداد نقشه‌های ویفر نامتعادل، مدلی مبتنی‌بر تصادف زدایی و پراش احتمالاتی با طبقه‌بند کمکی برای تولید نقشه‌های جدید ویفر پیشنهاد شده است. این مدل توسعه‌یافته دارای ساختار U-net با ورودی‌ها و خروجی‌های متعدد است که تصاویر ویفر، درجه نویز و ویژگی‌های دسته‌بندی را به عنوان ورودی و نویز پیش‌بینی شده و دسته‌بندی پیش‌بینی شده را به عنوان خروجی دریافت می‌کند. در [۱۶]، برای حل مشکل عدم توازن داده‌ها در طبقه‌بندی عیوب ویفر، از چارچوب مبتنی بر شبکه‌های مولدی متخاصم اتومالی[۱۰] استفاده شده است. این چارچوب شامل VAE-GAN برای تولید نمونه‌های جدید جهت حل مشکل عدم توازن و یک طبقه‌بند عیوب ویفر است. VAE-GAN، ترکیبی از مزایای خودرمزگذار احتمالاتی[۱۱] (VAE) و شبکه‌های مولدی متخاصم است که می‌تواند تصاویر جدید را بدون تغییر ویژگی‌های داده تولید کند و با استفاده از متمایزکننده، تصاویری نزدیک به نمونه‌های واقعی تولید کند و از تولید نمونه‌های نامعقول و مبهم جلوگیری کند. در [۱۷]، هدف طبقه‌بندی الگوهای عیب روی نقشه ویفر با استفاده از منابع و زمان کم بوده است. برای این منظور، یک مدل شبکه عصبی پیچشی کارآمد که به عملکرد پیشرفته، استفاده کمتر منابع و زمان پردازش سریع توجه داشته باشد، بررسی شد.

این مقاله با هدف بررسی و ارزیابی کارایی مدل‌های عمیق، به‌ویژه شبکه‌های عصبی بازگشتی، VGG16، مبتنی‌بر رزنت، مدل DenseNet121 و سایر مدل‌ها در شناسایی عیوب ویفر، اهمیت و کاربرد این تکنیک‌ها را در بهبود فرآیندهای تولید و افزایش کیفیت محصولات مورد تأکید قرار می‌دهد. یافته‌ها در این مقاله عبارتند از:

- یکی از مهم‌ترین یافته‌ها در این مقاله تأثیر مثبت استفاده از افزونگی داده‌ها بر کارایی مدل‌ها است. با افزایش تنوع و حجم داده‌های آموزشی، مدل‌ها توانستند به الگوهای پیچیده‌تری دست یابند و دقت شناسایی عیوب را افزایش دهند.
- استفاده از یادگیری انتقالی به عنوان یکی از رویکردهای مؤثر در این مقاله شناخته شده است. این روش با انتقال دانش از مدل‌های پیش‌آموخته شده به مدل‌های جدید، زمان آموزش را کاهش داد و دقت شناسایی عیوب را بهبود بخشید. این رویکرد به ویژه در شرایطی که داده‌های آموزشی محدود بودند، تأثیر قابل توجهی داشت.
- این پژوهش به بررسی نه کلاس مختلف از عیوب ویفر پرداخته است. شناسایی دقیق این کلاس‌ها نشان‌دهنده توانمندی مدل‌های یادگیری عمیق در تشخیص عیوب مختلف و تأثیر مثبت آن‌ها بر بهبود کیفیت و کارایی فرآیندهای تولید نیمه‌هادی‌ها است.
- این پژوهش نشان می‌دهد که با بکارگیری مدل‌های عمیق می‌توان به‌طور مؤثری از دقت سیستم در تشخیص عیوب در محیط‌های صنعتی استفاده کرد. این کار باعث کاهش هزینه‌ها و زمان تولید در صنعت نیمه‌هادی می‌شود.
- نتایج نشان می‌دهد که مدل‌های یادگیری عمیق به‌خصوص در شناسایی عیوب نادر و پیچیده، نسبت به روش‌های سنتی عملکرد بهتری دارند. این نکته به‌خصوص در مواردی که عیوب به‌صورت غیرقابل پیش‌بینی ایجاد می‌شوند، اهمیت دارد و نشان‌دهنده قدرت انعطاف‌پذیری مدل‌ها در تشخیص الگوهای پیچیده است.
- در این مقاله، بکارگیری مدل‌های بازگشتی، VGG16، MobileNet، GoogleNet، رزنت۳۴، رزنت۵۰، و DenseNet121 به‌عنوان رویکردهای مختلف یادگیری عمیق برای تشخیص عیوب ویفر در مدارهای مجتمع، یکی از مهم‌ترین یافته‌ها و مشارکت‌های این تحقیق است. استفاده از این مدل‌ها باعث بهبود قابل توجه دقت شناسایی عیوب در محیط‌های صنعتی و شناسایی الگوهای پیچیده‌تر در مقایسه با روش‌های سنتی شد.
- ارزیابی عملکرد روش‌های این مقاله به کمک مدل‌های نامبرده شده بر روی دو مجموعه داده MIR-WM811K، و WaferMap صورت گرفته است و نتایج با یکدیگر مقایسه شده است.
- مدل‌های پیچشی، و RNN به‌ویژه در پردازش دنباله‌های زمانی و ویژگی‌های فضایی تصاویر توانمندی بالایی نشان دادند، در حالی که مدل‌های DenseNet121 و مبتنی‌بر رزنت با توانایی در استخراج ویژگی‌های عمیق و پیچیده، عملکرد بسیار خوبی در شناسایی عیوب نادر و پیچیده از خود بروز دادند.
- این مقاله بر اهمیت استفاده از فناوری‌های نوین یادگیری عمیق در صنعت نیمه‌هادی تأکید و نشان می‌دهد که با بهره‌گیری از این فناوری‌ها، می‌توان به‌طور مؤثری مشکلات و چالش‌های موجود در فرآیند تولید را شناسایی و حل کرد. این یافته‌های ارزشمند به توسعه روش‌های جدید و بهبود کیفیت محصولات کمک نماید.

جدول ۱ پژوهش‌های اخیر مبتنی‌بر مفاهیم یادگیری عمیق در تشخیص عیوب ویفر در فرآیند تولید نیمه‌هادی‌ها را نمایش می‌دهد. این جدول مقایسه‌ای جامع از روش‌های پیشنهادی، اهداف تحقیقاتی، منابع داده‌ای، تعداد دسته‌های مورد استفاده در طبقه‌بندی، و سال‌های انتشار هر پژوهش را ارائه می‌کند. در بخش دوم این مقاله، رویکرد پیشنهادی با جزئیات تشریح می‌شود که شامل پایگاه داده، مراحل پیش‌پردازش، تبدیل داده‌ها، و تنظیمات پارامترهای معماری طراحی‌شده است. بخش

سوم به ارائه و تحلیل نتایج تجربی و ارزیابی عملکرد اختصاص دارد، و درنهایت، بخش پایانی به جمع‌بندی و نتیجه‌گیری از این پژوهش می‌پردازد.

۲- تشخیص نقص ویفر در روال تولید نمیه‌هادی در مدارهای مجتمع براساس مدل‌های عمیق

تشخیص نقص ویفر در فرآیند تولید نیمه‌هادی‌ها یکی از مراحل حیاتی برای تضمین کیفیت و عملکرد مطلوب محصولات الکترونیکی است. نقص‌های ویفر، از جمله ترک‌ها، ناهنجاری‌های سطحی، یا مشکلات ساختاری، می‌توانند منجر به خرابی نهایی بردها در مدارهای مجتمع شوند. با استفاده از مدل‌های یادگیری عمیق، به‌ویژه شبکه‌های عصبی پیچشی، امکان تشخیص دقیق نقص‌ها فراهم می‌شود. این مدل‌ها با تحلیل تصاویر با وضوح بالا از ویفرها، می‌تواند الگوهای پیچیده نقص‌ها را شناسایی و طبقه‌بندی دقیقی از نوع عیب‌ها ارائه دهند. بهره‌گیری از این رویکردها در مراحل تولید، باعث کاهش هزینه‌ها، افزایش بازدهی و بهبود کیفیت نهایی محصولات می‌شود[۱۸].

۲-۱- داده‌ها و مراحل پیش‌پردازش تصاویر

در این مقاله ارزیابی دسته‌بندی هشت کلاس رایج شدت نقص ویفر مدنظر قرار گرفته است که شامل موارد زیر است: نقص مرکز، به نقص‌هایی اطلاق می‌شود که در مرکز ویفر ظاهر می‌شوند. این نقص‌ها می‌توانند ناشی از آلودگی، حباب یا سایر مشکلات در مراحل اولیه فرآیند تولید باشند [۱۹]. نقص دونات، این دسته شامل نقص‌هایی شبیه به شکل دونات است، به‌گونه‌ای که دارای یک مرکز تاریک و لبه‌های روشن‌تر هستند. این نوع نقص به طور معمول به مشکلات مربوط به فرآیندهای فتولیتوگرافی یا اچ مرتبط است. نقص لبه-محلی، نقص‌هایی هستند که در لبه‌های ویفر و در نزدیکی محل قرارگیری قطعات ظاهر می‌شوند. منشأ این نقص‌ها می‌تواند آسیب‌های مکانیکی یا مشکلات مربوط به فرآیند بسته‌بندی باشد. نقص لبه-حلقه، به نقص‌هایی گفته می‌شود که به شکل حلقه در ناحیه لبه ویفر ایجاد می‌شوند. این نوع نقص غالباً ناشی از اختلال در فرآیند رسوب شیمیایی بخار است. نقص محلی، این دسته شامل نقص‌هایی است که در مکان‌های خاصی از ویفر مانند نواحی دروازه‌ها یا اتصالات رخ می‌دهند و معمولاً به طراحی یا فرآیند ساخت مرتبط هستند. نقص تصادفی، نقص‌هایی هستند که به‌طور پراکنده و نامنظم در سطح ویفر توزیع شده‌اند. این نوع نقص اغلب ناشی از آلودگی محیطی، گردوغبار یا عوامل مشابه است. نقص خراش، به خراش‌هایی اطلاق می‌شود که روی سطح ویفر ایجاد می‌شوند. این نقص‌ها می‌توانند بر اثر آسیب مکانیکی، تمیزکاری نامناسب یا خطا در جابه‌جایی ویفر به وجود آیند. نقص تقریباً کامل، شامل نقص‌هایی است که بخش عمده یا تقریباً کل سطح ویفر را دربر می‌گیرند. این نوع نقص غالباً در اثر مشکلات فرآیند اچ یا تمیزکاری ایجاد می‌شود [۲۰]. شکل ۱ نمونه‌ای از تصاویر مربوط به هر یک از کلاس‌های نقص در سطح ویفر را نشان می‌دهد. علاوه بر این کلاس‌های اصلی، ممکن است کلاس‌های فرعی دیگری نیز برای دسته‌بندی دقیق‌تر نقص‌ها استفاده شوند. یکی از مجموعه داده‌های جامع بکارگرفته شده در مقالات برای تشخیص نقص ویفر، مجموعه داده MIR-WM811K است. این مجموعه یک داده عمومی است که برای طبقه‌بندی نقص ویفر در صنعت نیمه‌هادی مورد استفاده قرار می‌گیرد [۲۱]. این مجموعه داده توسط آزمایشگاه تشخیص الگو MIR Lab در دانشگاه ملی سئول نگهداری می‌شود. این مجموعه داده به صورت رایگان در وب سایت آزمایشگاه تشخیص الگو در دسترس است و توسط محققان مختلف در سراسر جهان مورد استفاده قرار گرفته است، بنابراین نتایج به دست آمده با این مجموعه داده را می توان با سایر نتایج مقایسه نمود [۲۱]. این دیتاست شامل ۸۱۱۴۵۷ نقشه ویفر است که از ۴۶۳۹۳ دسته در فرآیند واقعی تولید جمع‌آوری شده‌اند. این اطلاعات نشان‌دهنده تنوع و حجم بالای داده‌ها در این مجموعه است، که می‌تواند به مدل‌های یادگیری عمیق در تشخیص نقص‌ها کمک کند. به‌منظور ارزیابی بهتر روش پیشنهادی در مقایسه با سایر مدل‌ها، از دیتاست WaferMapاستفاده شده است که شامل نه کلاس مختلف عیوب ویفر مطابق با آنچه در جدول ۲ نامبرده شده خواهد بود [۲۲]. این انتخاب به محققان اجازه می‌دهد تا عملکرد دقیقی از مدل‌ها را در شناسایی عیوب ویفر ارزیابی و نتایج را با سایر روش‌ها مقایسه نمایند. در این مقاله به بررسی و بکارگیری مدل‌های یادگیری عمیق برای تشخیص نقص‌های ویفر در مدارهای مجتمع پرداخته شده است.

ویفرها به عنوان بخش‌های حساس و کلیدی در مدارهای مجتمع، به دقت بالایی در فرآیند تشخیص نقص‌ها نیاز دارند. برای این منظور، از مدل‌های شبکه‌های عصبی بازگشتی، VGG16، MobileNet، GoogleNet، مدل‌های مبتنی‌بر رزنت، و DenseNet121 استفاده شده است که با توجه به توانایی آن‌ها در استخراج ویژگی‌های پیچیده و الگوهای دقیق از تصاویر، در تشخیص نقص‌ها بسیار کارآمد هستند.

۲-۲- افزونگی داده و یادگیری انتقالی

در تشخیص نقص ویفر، یکی از چالش‌های اصلی، عدم توازن یا کمبود داده‌های کافی از عیوب مختلف است. این مسئله می‌تواند منجر به عملکرد عملکرد ناپایدار و دقت پایین مدل‌های یادگیری عمیق شود. به منظور مقابله با این چالش، از تکنیک افزونگی داده استفاده می‌شود که با افزایش حجم و تنوع داده‌ها، عملکرد مدل‌ها بهبود می‌یابد. تکنیک افزونگی داده‌ها شامل تولید تصاویر جدید از داده‌های موجود با استفاده از تغییراتی مانند چرخش، برش، تغییر روشنایی، و انعکاس است. این تغییرات به مدل کمک می‌کنند تا ویژگی‌های پیچیده‌تری از داده‌ها را بیاموزد و به تعمیم‌پذیری بهتری برسد. در تشخیص نقص ویفر، این تکنیک می‌تواند مدل‌ها را در تشخیص بهتر الگوهای نادر و غیرمعمول توانمند سازد، چرا که با افزایش تعداد نمونه‌های آموزشی، شبکه عصبی

قابلیت بیشتری برای تفکیک و شناسایی عیوب پیدا می‌کند. افزونگی داده‌ها همچنین به مقابله با مشکل بیش‌برازش کمک می‌کند.

جدول (۱): پژوهش‌های اخیر در زمینه تشخیص نقص‌های ویفر در مدارات مجتمع براساس مدل‌های یادگیری عمیق

مرجع	وظیفه	کلاس‌ها	مجموعه دادگان	دسته‌بند	انتشار
[۵]	تشخیص/ دسته‌بندی	۵ کلاس (Spot, Rock-shaped particle, Ring-shaped particle, Misalignment, Scratch)	DatasetTT[12]/ Dataset-UN[13]	CNN	۲۰۱۹
[۶]	دسته‌بندی	۴ کلاس (Scrap, Random, Local, Center)	COCO/ KITTI	CNN	۲۰۲۰
[۷]	دسته‌بندی	۷ کلاس (Center, Donut, Edge-loc, Edge-Ring, Loc, Random, Scratch)	WM-811K wafer Defect	CNN	۲۰۲۳
[۸]	دسته‌بندی	۲ کلاس (Random, Edge-Ring)	WBM[14] dataset	CNN	۲۰۲۲
[۹]	تشخیص/ دسته‌بندی	۹ کلاس (Center, Donut, Edge-loc, Edge-Ring, Loc, Random, Scratch, Near-full, None)	WM-811K wafer Defect	YOLOv3/YOLOv4	۲۰۲۲
[۱۰]	تشخیص/ دسته‌بندی	۸ کلاس (NO Defect, Class A, Class B, Class C,) (Class D, Class E, Class F, Class G	Surface Defect Dataset	SqueezeNet CNN	۲۰۲۳
[۱۱]	دسته‌بندی	۵کلاس(Random, Ring, Scratch, Dense, Cluster)	WM-811K	CNN	۲۰۲۳
[۱۲]	دسته‌بندی	۱۲ کلاس (Defocus, ICP, Broken, OX residue, Partial etch, Poly bump, Poly residue, PR damage, PR residue, Scratch, Silicon, Surface particle)	-	DNN[15]	۲۰۲۲
[۱۳]	دسته‌بندی	۹ کلاس (Center, Donut, Edge-loc, Edge-Ring, Loc, Random, Scratch, Near-full, None)	WM-811K wafer Defect	CNN	۲۰۲۰
[۱۴]	دسته‌بندی	۸ کلاس (Center, Donut, Edge-loc, Edge-Ring, Loc, Random, Scratch, Near-full)	WM-811K/ WaferMap	MFFP-Net[16]	۲۰۲۳
[۱۵]	دسته‌بندی	۹ کلاس دیتاست اول/ ۲۹ کلاس دیتاست دوم	MIR-M811K /MixedWM38	مدل مبتنی‌بر رزنت	۲۰۲۴
[۱۶]	دسته‌بندی	۸ کلاس (Center, Donut, Edge-loc, Edge-Ring, Loc, Random, Scratch, Near-full)	WM-811K wafer Defect	VAE-GAN[17]	۲۰۲۲
روش پیشنهادی	دسته‌بندی	۹ کلاس (Center, Donut, Edge-loc, Edge-Ring, Loc, Random, Scratch, Near-full, None)	WM-811K wafer Defect	RNN/VGG16/ MobileNet/GoogleNet/ ResNet/DenseNet121	-

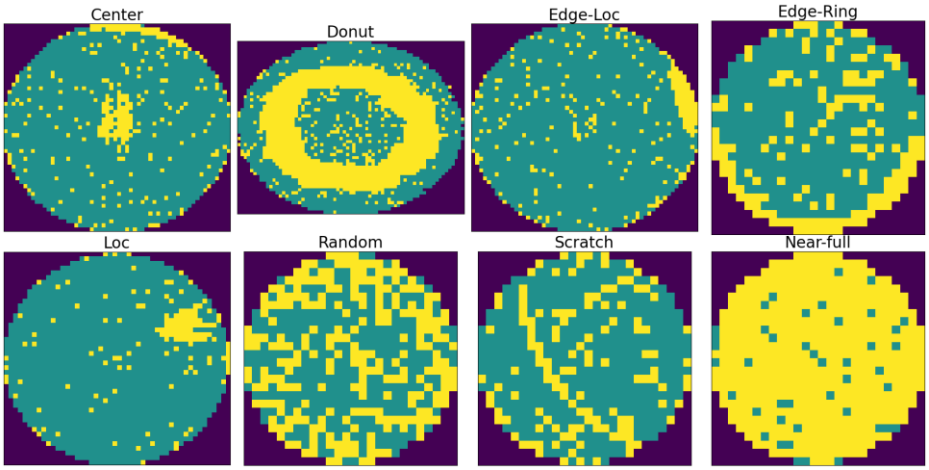

شکل (۱): نمونه‌ای از تصاویر نقص ویفر در کلاس‌های مرکز، دونات، لبه-محلی، حلقه-لبه، محلی، تصادفی، خراش، و به طور تقریبی کامل

زمانی که مدل‌ها با تعداد محدودی از داده‌های واقعی آموزش داده شوند، ممکن است به جای یادگیری ویژگی‌های عمومی و مؤثر، تنها به جزئیات خاص هر نمونه توجه کنند. این امر باعث کاهش دقت مدل در پیش‌بینی داده‌های جدید می‌شود. با استفاده از افزونگی داده، مدل‌ها تنوع بیشتری از نمونه‌ها را مشاهده می‌کنند و در نتیجه قادر به یادگیری ویژگی‌های پایدارتر و تعمیم‌پذیرتری خواهند بود[۲۳-۲۴]. برخی از تصاویر افزوده شده از مجموعه دادگان مربوط به هشت دسته نقص ویفر در شکل ۲ نمایش داده شده‌اند. در این بخش، به بررسی تعداد تصاویر مربوط به هر گروه از نقص‌های ویفر در مجموعه داده‌های آموزشی و تأثیر استفاده از

تکنیک‌های افزونگی داده بر عملکرد مدل‌های یادگیری عمیق پرداخته می‌شود. جدول ۲ نشان‌دهنده تعداد تصاویر هر دسته، قبل و پس از اعمال تکنیک‌های افزونگی است. تکنیک‌های افزونگی شامل تغییرات متنوعی مانند چرخش، تغییر اندازه، جابجایی و تنظیم روشنایی تصاویر هستند که با افزایش تنوع داده‌ها، به جلوگیری از بروز بیش‌برازش کمک می‌کنند. افزایش تعداد تصاویر در هر دسته از نقص‌ها، موجب ارتقای توانایی مدل‌ها در تعمیم به داده‌های جدید شده و دقت تشخیص عیوب ویفر را بهبود می‌بخشد. یادگیری انتقالی به عنوان یکی از رویکردهای مؤثر در بهبود عملکرد مدل‌های یادگیری عمیق مورد توجه قرار گرفته است. این تکنیک به مدل اجازه می‌دهد تا از دانشی که در یک حوزه دیگر آموخته، برای حل مسئله جدید استفاده نماید[۲۵]. در تشخیص نقص ویفر، به دلیل محدودیت داده‌های آموزشی، استفاده از مدل‌های از پیش آموزش‌دیده بر روی مجموعه داده‌های بزرگ‌تر و عمومی می‌تواند کمک شایانی به بهبود دقت و عملکرد مدل کند. به‌کارگیری یادگیری انتقالی در این زمینه به این شکل است که ابتدا مدل‌ها بر روی مجموعه داده‌های وسیع‌تری مانند ImageNet آموزش می‌بینند و سپس برای تشخیص عیوب ویفر، این مدل‌ها با داده‌های خاص‌تر مرتبط با ویفر تطبیق داده می‌شوند. این فرآیند باعث می‌شود که مدل از دانش عمومی یادگیری الگوهای پیچیده بهره‌مند شود و در مرحله دوم، یادگیری دقیق‌تری روی داده‌های خاص نقص‌های ویفر داشته باشد. این روش به کاهش نیاز به داده‌های بزرگ در مرحله دوم کمک می‌کند و باعث می‌شود که حتی با داده‌های محدود بتوان به نتایج قابل توجهی دست یافت. از دیگر مزایای یادگیری انتقالی می‌توان به کاهش زمان آموزش اشاره نمود. به دلیل اینکه مدل از قبل با یک مجموعه داده بزرگ‌تر آموزش دیده، نیازی به آموزش طولانی بر روی داده‌های ویفر نیست. این امر به‌ویژه در محیط‌های صنعتی که نیاز به سرعت بالا و دقت زیاد است، بسیار مؤثر بوده و می‌تواند فرآیند توسعه مدل را بهینه کند[۲۶-۲۷].

مدل‌های بازگشتی RNN، برای پردازش داده‌های دنباله‌ای مانند متن و سیگنال‌های زمانی طراحی شده‌اند و می‌توانند اطلاعات گذشته را در هر مرحله حفظ کنند. VGG16، به خاطر ساختار عمیق و ساده با استفاده از لایه‌های کانولوشنی عمیق و فشرده‌سازی ویژگی‌ها شناخته می‌شود و به طور معمول برای تشخیص تصویر و طبقه‌بندی استفاده می‌شود. MobileNet، که به طور خاص برای دستگاه‌های همراه و با محدودیت‌های محاسباتی طراحی شده، از یک ساختار سبک و موثر استفاده می‌کند که در آن از لایه‌های جداکننده عمقی بهره می‌برد.

GoogleNet، با استفاده از Inception، به دنبال بهبود کارایی و دقت در طبقه‌بندی تصویر است و امکان استخراج ویژگی‌های چند مقیاسی را فراهم می‌کند. مدل‌های رزنت۳۴ و رزنت۵۰ نیز به عنوان مدل‌های مبتنی‌بر بلوک‌های مانده شناخته شده و با استفاده از لایه‌های مانده عمق شبکه را افزایش می‌دهند. این امر به یادگیری ویژگی‌های پیچیده‌تر کمک نموده و مشکلات فرسایش گرادیان را کاهش می‌دهد [۲۸].

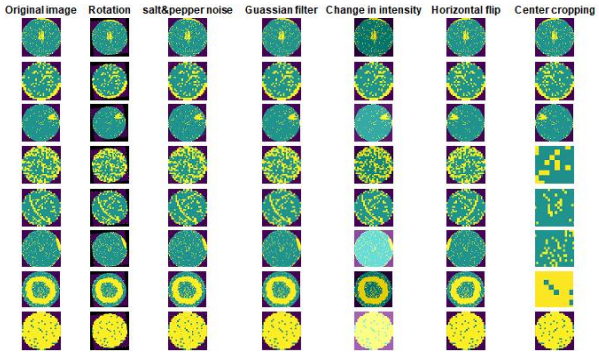

شکل (۲): نمونه‌ای از تصاویر با افزونگی داده شامل: ردیف اول) نقص Center، ردیف دوم) نقص Edge-Ring، ردیف سوم) نقص Loc، ردیف چهارم) نقص Random، ردیف پنجم) نقص Scratch، و ردیف ششم) نقص Edge-Loc، ردیف هفتم) نقص دونات، و ردیف هشتم) نقص Near-Full

جدول (۲): تعداد تصاویر هر دسته از نقص‌های ویفر پیش و پس از استفاده از تکنیک‌های افزونگی داده از مجموعه داده مجموعه داده MIR-WM811K

ردیف	نقصها	نام لاتین	کل داده	بعد از افزونگی	داده آموزش	داده آزمایش
۱	مرکز	Center	۲۱۶۰	۱۰۸۰۰	۸۶۴۰	۲۱۶۰
۲	دونات	Donut	۲۰۰۲	۱۰۰۱۰	۸۰۰۸	۲۰۰۲
۳	لبه-محلی	Edge-Loc	۲۳۶۸	۱۱۸۴۰	۹۴۷۲	۲۳۶۸
۴	لبه-حلقه	Edge-Ring	۲۰۴۶	۱۰۲۳۰	۸۱۸۴	۲۰۴۶
۵	محلی	Loc	۲۳۷۶	۱۱۸۸۰	۹۵۰۴	۲۳۷۶
۶	تصادفی	Random	۲۱۴۶	۱۰۷۳۰	۸۵۸۴	۲۱۴۶
۷	خراش	Scratch	۲۰۸۸	۱۰۴۴۰	۸۳۵۲	۲۰۸۸
۸	تقریباً کامل	Near-Full	۲۰۳۲	۱۰۱۶۰	۸۱۲۸	۲۰۳۲
۹	نرمال	None	۲۴۸۹	۱۲۴۴۵	۹۹۵۶	۲۴۸۹
	کل		**۱۹۷۰۷**	**۹۸۵۳۵**	**۷۸۸۲۸**	**۱۹۷۰۷**

شبکه‌های عصبی پیچشی، با لایه‌های مختلف خود می‌تواند الگوهای محلی و مهم را از تصاویر ویفر استخراج کند وDenseNet121[18] با ساختار منحصر به فرد خود، که از اتصالات متراکم بهره می‌برد، دقت و کارایی مدل را افزایش می‌دهد. در این پژوهش، با ارزیابی و مقایسه عملکرد این مدل‌ها، بهبود قابل توجهی در دقت تشخیص نقص‌ها مشاهده شده است. همچنین این مدل یکی دیگر از مدل‌های عمیق است که با طراحی خاص خود قابلیت بهبود دقت و کارایی در تشخیص نقص‌ها را فراهم می‌کند. ساختار DenseNet با استفاده از اتصالات متراکم بین لایه‌ها، این امکان را می‌دهد که هر لایه به تمام لایه‌های قبلی خود متصل شود. این ارتباط مستقیم باعث می‌شود اطلاعات و

گرادیان‌ها به‌طور موثرتری در سراسر شبکه جریان پیدا کنند و از مشکلات ناپدید شدن گرادیان که در شبکه‌های عمیق مشاهده می‌شود، جلوگیری شود. DenseNet121 از ۱۲۱ لایه تشکیل شده و یکی از نسخه‌های کارآمد این معماری است. این مدل با استفاده از ساختار متراکم خود، توانایی یادگیری ویژگی‌های غنی و پیچیده از تصاویر ویفر را داراست. اتصالات متراکم در DenseNet121 باعث می‌شود ویژگی‌های یادگرفته شده در لایه‌های اولیه در تمامی لایه‌های بعدی به‌کار گرفته شوند، که این امر به بهبود دقت و کارایی در تشخیص نقص‌های جزئی ویفر منجر می‌شود. همچنین، با توجه به کاهش تعداد پارامترها در مقایسه با شبکه‌های عمیق دیگر، DenseNet121 حافظه کمتری نیاز دارد و از لحاظ محاسباتی کارآمدتر است. در این پژوهش، این مدل‌ها به کار گرفته شده‌اند تا نقاط قوت هر کدام در استخراج ویژگی‌ها و شناسایی نقص‌های ویفر بررسی شود و عملکردشان با یکدیگر مقایسه گردد

.

۲-۳- روش پیشنهادی به منظور تشخیص نقص ویفرها به کمک مدل‌های عمیق

در روش پیشنهادی این پژوهش برای تشخیص نقص‌های ویفر، از مدل‌های یادگیری عمیق به‌منظور استخراج خودکار ویژگی‌ها و طبقه‌بندی نهایی استفاده شده است. ابتدا تصاویر ویفرها پس از انجام مراحل پیش‌پردازش شامل تغییر اندازه، نرمال‌سازی و در برخی موارد افزایش داده به‌عنوان ورودی به مدل‌های یادگیری عمیق داده می‌شوند. این مرحله به یکنواخت‌سازی داده‌ها و کاهش تأثیر نویز کمک می‌کند. در گام بعد، لایه‌های پیچشی به استخراج ویژگی‌های سطح پایین مانند لبه‌ها و بافت‌ها و سپس ویژگی‌های سطح بالاتر نظیر الگوهای تکرارشونده نقص‌ها می‌پردازند. پس از آن، لایه‌های تجمیع با کاهش ابعاد داده‌ها، مهم‌ترین اطلاعات مکانی و ساختاری را حفظ می‌کنند. خروجی این لایه‌ها به بخش تمام‌متصل ارسال می‌شود تا تصمیم‌گیری نهایی در مورد نوع نقص صورت گیرد. روش پیشنهادی به‌گونه‌ای طراحی شده است که بتواند انواع مختلف نقص‌های ویفر را با دقت بالا شناسایی کند. بدین منظور، از چند مدل یادگیری عمیق شامل شبکه‌های کانولوشنی، DenseNet121 و رزنت۵۰ استفاده شده و عملکرد آنها با یکدیگر مقایسه گردیده است. در بخش طبقه‌بندی، از لایه Softmax برای تخصیص احتمال به هر کلاس نقص استفاده شده است تا در نهایت، دسته‌بندی نهایی انجام شود.

در مدل DenseNet121، لایه‌ها به‌صورت متراکم به یکدیگر متصل هستند، به‌طوری که خروجی هر لایه به‌عنوان ورودی به تمام لایه‌های بعدی منتقل می‌شود. این ساختار باعث می‌شود بازاستفاده از ویژگی‌ها در سطوح مختلف شبکه به‌طور مؤثر انجام گیرد و اطلاعات از بین نرود. نتیجه این ویژگی، استخراج الگوهای پیچیده‌تر و کاهش مشکل محوشدگی گرادیان است که در نهایت منجر به دقت بالاتر در شناسایی انواع مختلف نقص‌های ویفر می‌شود.

در مقابل، رزنت۵۰ بر پایه استفاده از بلوک‌های باقی‌مانده طراحی شده است. در این ساختار، مسیرهای میان‌بر امکان عبور مستقیم گرادیان از لایه‌های عمیق را فراهم می‌کنند. این موضوع نه تنها یادگیری در شبکه‌های بسیار عمیق را تسهیل می‌کند، بلکه باعث افزایش پایداری و بهبود همگرایی مدل در فرآیند آموزش می‌شود. به‌ویژه برای داده‌های پیچیده و پرنویز مانند نقشه‌های ویفر، استفاده از رزنت۵۰ موجب افزایش توان مدل در جداسازی الگوهای نقص می‌گردد.

به‌طور کلی، ترکیب استخراج ویژگی‌های غنی توسط DenseNet121و پایداری و عمق یادگیری در رزنت۵۰ می‌تواند به نتایج بهینه در فرآیند تشخیص نقص ویفرها منجر شود. جریان کلی این فرآیند در شکل ۳ به‌صورت یک بلوک‌دیاگرام نمایش داده شده است. همان‌گونه که در شکل مشاهده می‌شود، مراحل مختلف شامل دریافت تصاویر ورودی، پیش‌پردازش، استخراج ویژگی توسط مدل‌های عمیق، و نهایتاً طبقه‌بندی نقص‌ها در یک چارچوب منسجم ادغام شده‌اند. این طراحی باعث می‌شود که مدل‌های پیشنهادی بتوانند بدون نیاز به استخراج دستی ویژگی‌ها، به‌طور خودکار الگوهای مرتبط با نقص‌ها را شناسایی و تفکیک نمایند.

۳- نتایج شبیه‌سازی

در این مقاله، به کاربرد مدل‌های یادگیری عمیق برای تشخیص خودکار نقص‌های ویفر در مدارهای مجتمع پرداخته شده است.

برای اجرای شبیه‌سازی، ابتدا مجموعه داده‌های MIR-WM811K و WaferMapپیش‌پردازش و با استفاده از تکنیک‌های افزونگی داده شامل چرخش، تغییر روشنایی و برش، تنوع و حجم داده‌ها افزایش یافت. سپس داده‌ها به دو بخش آموزش (۸۰٪) و آزمایش (۲۰٪) تقسیم شدند. مدل‌های DenseNet121 و رزنت۵۰ با پارامترهای از پیش تنظیم شده و نرخ یادگیری ۰/۰۰۱ آموزش داده شدند و تعداد ایپاک‌ها بسته به همگرایی مدل بین ۵۰ تا ۱۰۰ دوره تنظیم گردید. عملکرد مدل‌ها با معیارهایی همچون دقت (Accuracy)، حساسیت(Sensitivity) ، ویژگی (Specificity) و F1-score ارزیابی شد. علاوه بر این، برای اطمینان از پایداری نتایج، هر شبیه‌سازی سه بار با مقادیر اولیه تصادفی متفاوت اجرا و نتایج میانگین‌گیری شد. این مراحل جامع، امکان مقایسه دقیق بین مدل‌ها و تحلیل اثر هر بخش از معماری مدل‌ها بر دقت تشخیص نقص‌های ویفر را فراهم می‌آورد.

ویفرها نقش کلیدی در ساخت مدارهای مجتمع دارند و نقص‌های آن‌ها می‌توانند تاثیر منفی بر عملکرد نهایی محصول داشته باشند. تشخیص سریع و دقیق این نقص‌ها اهمیت زیادی در بهینه‌سازی فرآیند تولید و کاهش هزینه‌ها دارد. روش‌های سنتی عموماً زمان‌بر بوده و از دقت کافی برخوردار نیستند، به همین دلیل استفاده از مدل‌های پیشرفته یادگیری عمیق می‌تواند راه‌حلی موثر و نوآورانه ارائه دهد. در این پژوهش، این مدل‌ها با هدف بهبود دقت و سرعت تشخیص نقص‌ها به‌کار گرفته شده‌اند و نتایج حاصل نشان‌دهنده کارایی بالای این رویکرد در صنعت

تولید بردهای در مدارات مجتمع است. پیکربندی مدل‌ها در جدول ۳ نشان داده شده است.

این جدول شامل جزئیات مربوط به ساختار و تنظیمات هر مدل، از جمله تعداد لایه‌ها، تعداد فیلترها، اندازه هسته‌ها، و سایر پارامترهای مهم است که در فرایند آموزش و تست مدل‌ها به‌کار رفته‌اند. برای هر مدل، اطلاعات دقیقی مانند تعداد پارامترهای قابل آموزش، نوع تابع فعال‌سازی، و الگوریتم‌های بهینه‌سازی نیز ذکر شده است. این پیکربندی‌ها به‌منظور بهینه‌سازی عملکرد مدل‌ها و افزایش دقت در تشخیص نقص‌ها در ویفرها تنظیم شده‌اند. جدول ۴، پارامترهای مدل‌های مورد استفاده را نشان می‌دهد که شامل دوره، بهینه‌ساز، ابعاد دسته، ابعاد کرنل، تابع فعال‌ساز، نرخ یادگیری و تعداد لایه‌ها می‌باشد. بهینه‌ساز الگوریتمی است که برای به‌روزرسانی وزن‌ها و بهینه‌سازی مدل استفاده می‌شود. ابعاد کرنل اندازه فیلترهای پیچشی است که برای استخراج ویژگی‌ها از داده‌ها به‌کار می‌رود. تابع فعال‌ساز برای اضافه کردن غیرخطی بودن به مدل و کمک به یادگیری روابط پیچیده استفاده می‌شود. نرخ یادگیری[۱۹] مقدار تغییرات وزن‌ها در هر گام آموزشی را تعیین می‌کند و تعداد لایه‌ها نیز نشان‌دهنده تعداد لایه‌های مختلف مدل از جمله پیچشی، پوشش‌دهی و متصل است. این پارامترها به‌دقت تنظیم شده‌اند تا عملکرد بهینه مدل‌ها در تشخیص نقص‌های ویفرهای مدار مجتمع تضمین شود.

در این مقاله، برای تنظیم و بهینه‌سازی مدل‌های یادگیری عمیق از چندین پارامتر کلیدی استفاده شده است که تأثیر قابل توجهی بر عملکرد مدل‌ها دارند. در جدول ۴، پارامترهای مهم مربوط به مدل‌های یادگیری عمیق شامل RNN، VGG16، MobileNet، GoogleNet، رزنت۳۴، رزنت۵۰ و DenseNet121 مشخص شده‌اند. این پارامترها تأثیر قابل توجهی بر عملکرد و دقت مدل‌ها دارند و نتایج تنظیم این پارامترها از شبیه‌سازی‌های تجربی به دست آمده است. برای هر مدل، تعداد دوره‌های آموزشی، بهینه‌ساز، ابعاد دسته، ابعاد کرنل، تابع فعال‌ساز، نرخ یادگیری و تعداد لایه‌ها مشخص شده است. به عنوان مثال، مدل RNN برای ۱۵ دوره آموزش دیده و از بهینه‌ساز Adam با ابعاد دسته ۳۲، ابعاد کرنل ۳×۳، تابع فعال‌ساز ReLU و نرخ یادگیری در محدوده 10^{-3} استفاده شده است. مدل VGG16 برای ۲۰ دوره آموزش دیده و از بهینه‌ساز SGD استفاده کرده است، در حالی که MobileNet و GoogleNet هر کدام برای ۱۵ دوره آموزش داده شده و از بهینه‌ساز SGDبهره برده‌اند. همچنین، رزنت۳۴ و رزنت۵۰ به‌ترتیب برای ۳۰ دوره و ۳۰ دوره با بهینه‌سازهای آدام و ابعاد دسته ۳۲ و ۶۴ آموزش دیده‌اند. مدل DenseNet121 نیز برای ۴۰ دوره با بهینه‌ساز آدام و ابعاد دسته ۶۴ آموزش داده شده است. ابعاد کرنل در تمام مدل‌ها برابر با ۳×۳ تعیین شده است و بیشتر مدل‌ها از تابع فعال‌ساز ReLU استفاده شده، به‌جز MobileNet که از ReLU6 بهره می‌برد. این پارامترها به‌طور تجربی تنظیم شده‌اند تا بهترین عملکرد را برای هر مدل به‌دست آورند.

در این مقاله، برای ارزیابی عملکرد مدل‌ها از مجموعه‌ای از معیارهای متنوع استفاده شده است که شامل دقت(Acc)، ویژگی(Spe)، نرخ پیش‌بینی مثبت(Ppr)، حساسیت(Sen) یا یادآوری (R) و معیار F-Measureمی‌باشد. دقت به عنوان یک شاخص کلی عملکرد مدل، نشان‌دهنده نسبت پیش‌بینی‌های صحیح به مجموع پیش‌بینی‌ها است. با این حال، در داده‌های نامتوازن، دقت ممکن است نتایج دقیقی ارائه ندهد. ویژگی، که به نرخ تشخیص صحیح نمونه‌های منفی نیز معروف است، به ارزیابی توانایی مدل در شناسایی نمونه‌های منفی می‌پردازد.

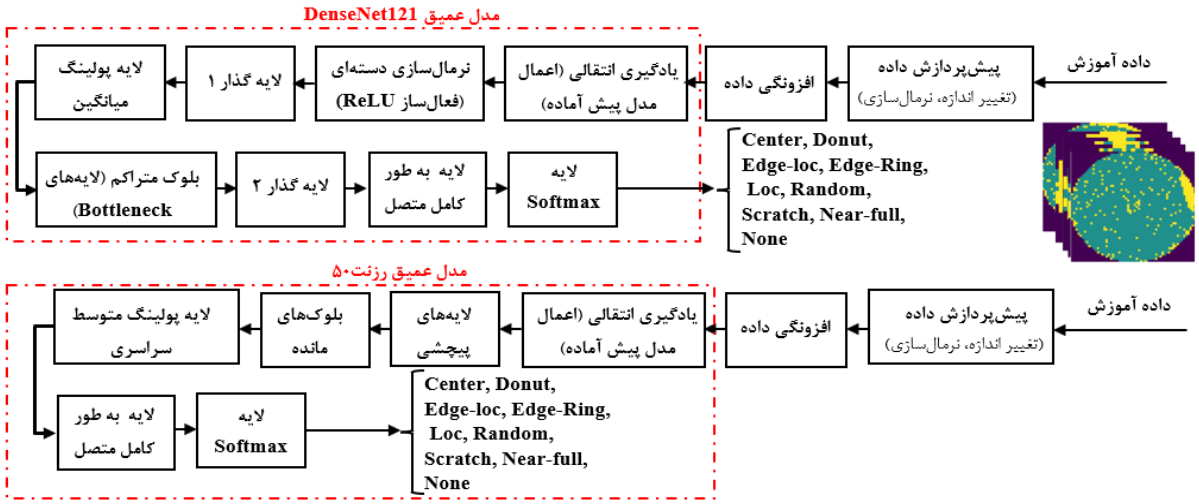

شکل (۳): بلوک دیاگرام روش پیشنهادی برای تشخیص نقص ویفرها با استفاده از مدل‌های یادگیری عمیق. این دیاگرام شامل مراحل پیش‌پردازش تصاویر، استخراج ویژگی‌ها با استفاده از مدل عمیق DenseNet121 و رزنت ۵۰ به منظور طبقه‌بندی نقص ویفر در مدارهای مجتمع

جدول (۳): پیکربندی مدل‌های بکار گرفته شده در شبیه‌سازی‌ها. به منظور بهینه‌سازی عملکرد تشخیص نقص‌های ویفر

DenseNet121	رزنت۵۰	VGG16	RNN
Input Image: 224×224×3	Input Image: 224×224×3	Input Image: 224×224×3	Input Image: 224×224×3
Conv2D/ReLU:224×224×32	Conv2D: 224×224×64	Conv2D/ReLU:224×224×32	Conv2D/ReLU: 224×224×64
MaxPooling: 112×112×32	Batch Normalization: 224×224×64	MaxPooling: 112×112×32	MaxPooling: 112×112×64
Conv2D/ReLU:112×112×64	ReLU: 224×224×64	Conv2D/ReLU:112×112×64	Conv2D/ReLU:112×112×128
MaxPooling: 56×56×64	MaxPooling: 112×112×64	MaxPooling: 56×56×64	MaxPooling: 56×56×128
Conv2D/ReLU: 56×56×128	Residual Block: 112×112×64	Conv2D/ReLU: 56×56×128	Conv2D/ReLU: 56×56×256
MaxPooling: 28×28×128	Residual Block: 112×112×64	MaxPooling: 28×28×128	MaxPooling: 28×28×256
Conv2D/ReLU:28×28×256	Residual Block: 56×56×128	Conv2D/ReLU: 28×28×256	Reshape: 28×28×256
MaxPooling: 14×14×256	Residual Block: 56×56×128	MaxPooling: 14×14×256	Reshape layer
Conv2D/ReLU:14×14×512	Residual Block: 28×28×256	Conv2D/ReLU:14×14×512	RNN layer
Global Average Pooling:14×14×512	Residual Block: 28×28×256	MaxPooling: 7×7×512	Global Average Pooling
Fully Connected (FC1): 4096	Residual Block: 14×14×512	Fully Connected (FC1): 4096	Fully Connected (FC1)
Dropout: 0.5	Residual Block: 14×14×512	Dropout: 0.5	Dropout: 0.5
Fully Connected (FC2): 4096	Global Average Pooling: 1×1×512	Fully Connected (FC2): 4096	Fully Connected (FC1): 512
Fully Connected (FC3): 1000	Fully Connected (FC1): 1000	Dropout: 0.5	Fully Connected (FC2): 256
		Fully Connected (FC3): 1000	Fully Connected (FC3):1 (Sigmoid)

حساسیت یا یادآوری، توانایی مدل در شناسایی صحیح نمونه‌های مثبت را ارزیابی می‌کند و در مسائلی که شناسایی دقیق نمونه‌های مثبت اهمیت بالایی دارد، از اولویت ویژه‌ای برخوردار است.

ترکیب این معیارها، امکان ارزیابی جامعی از عملکرد مدل‌ها را فراهم می‌آورد و به تحلیل دقیق‌تر نقاط قوت و ضعف آن‌ها در دسته‌بندی داده‌ها کمک می‌کند. معیارهای بکار رفته به شرح زیر تعریف شده‌اند[۱۹]:

$$Acc = (TP+TN)/(TP+TN+FP+FN) \quad (۱)$$

$$Spe = TN/(TN+FP) \quad (۲)$$

$$Ppr = TP/(TP+FP) \quad (۳)$$

$$Sen = TP/(TP+FN) \quad (۴)$$

$$F\text{-}Measure=2\times(Ppr\times Sen)/(Ppr+Sen) \quad (۵)$$

در این مقاله، برای مقایسه مدل‌های مختلف از معیارهای متنوعی استفاده شده است که به شرح زیر تعریف می‌شوند. TP[۲۰] به تعداد نمونه‌های مربوط به کلاس نقص که به درستی توسط مدل تشخیص داده شده‌اند، اشاره دارد. از سوی دیگر، TN[۲۱] تعداد نمونه‌هایی است که مدل به درستی آن‌ها را به کلاس غیرنقصی دسته‌بندی کرده است. FP[۲۲] به تصاویری اشاره می‌نماید که به اشتباه به عنوان نقص تشخیص داده شده‌اند، در حالی که در واقع متعلق به کلاس دیگری هستند.

جدول (۴): پارامترهای مدل‌های عمیق مورد استفاده به منظور تشخیص نقص‌های ویفر در مدارهای مجتمع

مدل	دوره	بهینه‌ساز	دسته	فعال‌ساز	یادگیری	لایه
RNN	۱۵	آدام[۲۳]	۳۲	ReLU[24]	۱۰$^{-۳}$	۱۰
VGG16	۲۰	SGD	۳۲	ReLU	۱۰$^{-۳}$	۱۶
MobileNet	۱۵	SGD	۳۲	ReLU6	۱۰$^{-۳}$	۲۸
GoogleNet	۱۵	SGD	۳۲	ReLU	۱۰$^{-۳}$	۲۲
رزنت۳۴	۳۰	آدام	۳۲	ReLU	۱۰$^{-۳}$	۳۴
رزنت۵۰	۳۰	آدام	۶۴	ReLU	۱۰$^{-۴}$	۵۰
DenseNet121	۴۰	آدام	۶۴	ReLU	۱۰$^{-۳}$	۱۲۱

در مقابل، FN[۲۵] به نمونه‌هایی مربوط می‌شود که به نادرستی به عنوان کلاس غیرنقصی طبقه‌بندی شده‌اند، در حالی که در واقع به کلاس نقص تعلق دارند. به‌طور کلی، هرچه تعداد TP وTN بیشتر و تعداد FP و FN کمتر باشد، مدل دقت بالاتری در طبقه‌بندی خواهد داشت و عملکرد بهتری از خود نشان می‌دهد[۱۹]. در این بخش، نتایج شبیه‌سازی روش پیشنهادی برای شناسایی نقص‌های ویفر با استفاده از مدل‌های یادگیری عمیق ارائه می‌شود. هدف از این شبیه‌سازی‌ها ارزیابی کارایی مدل‌های مختلف در تشخیص دقیق و مؤثر انواع نقص‌ها در تصاویر ویفرها است. برای این منظور، از داده‌های واقعی و شبیه‌سازی شده برای آموزش و

ارزیابی مدل‌ها استفاده شده است. در این فرآیند، انواع مختلف نقص‌ها از جمله ترک‌ها، خراش‌ها، و نواقص سطحی شبیه‌سازی شده و مدل‌های مختلف یادگیری عمیق نظیر CNN و DenseNet121 برای شناسایی این نواقص به‌کار گرفته شده‌اند. نتایج به‌دست‌آمده شامل ارزیابی‌های مختلف از جمله دقت، حساسیت، و ویژگی مدل‌هاست که به تحلیل عملکرد آن‌ها در شناسایی نقص‌ها کمک می‌کند. نتایج معیارهای ارزیابی عملکرد مدل‌های یادگیری عمیق مورد استفاده برای شناسایی نقص‌های ویفر در جدول ۵ ارائه شده است. این جدول شامل مقادیر مختلف برای هر کلاس نقص مانند ترک‌ها، خراش‌ها و نواقص دیگر است که توسط هر مدل شناسایی شده‌اند. به‌منظور ارزیابی دقیق‌تر کارایی مدل‌ها، مقادیر دقت، حساسیت، ویژگی و سایر معیارهای مرتبط برای هر کلاس نقص گزارش شده‌اند. علاوه بر این، برای مقایسه کلی عملکرد مدل‌ها، میانگین دقت مدل‌ها در شناسایی تمامی کلاس‌ها در جدول ۶ نمایش داده شده است. این مقادیر به‌طور خاص به تحلیل توانایی هر مدل در شناسایی نقص‌ها از منظرهای مختلف کمک می‌کند و اطلاعات مهمی در مورد نقاط قوت و ضعف مدل‌ها در شناسایی انواع مختلف نقص‌ها فراهم می‌آورد.در جدول ۶، مدل RNN در هر دو مجموعه داده MIR-WM811K و WaferMap عملکرد ضعیفی دارد، به‌ویژه در دسته‌هایی مانند Edge-Loc و Random، اما در دسته‌هایNear-Full و Scratchنتایج بهتری دیده می‌شود که به ساختار بازگشتی آن مرتبط است. VGG16، دقت بالاتری در هر دو مجموعه داده ارائه می‌دهد، به‌ویژه در دسته‌های None وNear-Full ، اما در برخی دسته‌ها مانند Locعملکرد ضعیف‌تری دارد. MobileNet نسبت به VGG16 دقت کمتری دارد، اما در دسته‌هایی مانند Near-Full وNone بهتر عمل می‌کند و برای داده‌های سبک‌تر مناسب‌تر است. GoogleNet، دقت متوسطی دارد، اما در دسته‌های Near-Full و None عملکرد خوبی نشان می‌دهد. رزنت۳۴ عملکرد بهتری نسبت به GoogleNet و MobileNetدارد و در دسته‌های Near-Full و None نتایج مطلوبی ارائه می‌دهد. رزنت۵۰، با بهبود معماری رزنت۳۴، دقت بالاتری به‌ویژه در دسته‌های Scratch و Near-Full دارد. DenseNet121 بهترین عملکرد را دارد که به دلیل استفاده از مسیرهای مستقیم بین لایه‌هاست که استخراج ویژگی‌های عمیق را بهبود می‌بخشد. همچنین ماتریس درهم ریختگی مربوط به برخی از مدل‌های عمیق منتخب در شکل ۴ نشان داده شده است که بر نتایج جداول ۵ و ۶ تاکید می‌کند. مدل‌های یادگیری عمیق مورد استفاده در این پژوهش پس از آموزش بر روی دیتاست MIR-WM811K به صورت آفلاین عمل می‌کنند و در طول استفاده بر روی داده‌های واقعی، به‌صورت خودکار آموزش مجدد انجام نمی‌دهند. با این حال، قابلیت به‌روزرسانی مدل‌ها با استفاده از داده‌های جدید در مراحل بعدی وجود دارد. این فرآیند که به fine-tuning یا آموزش مجدد معروف است، می‌تواند مدل را برای شرایط واقعی خطوط تولید تطبیق دهد و دقت تشخیص نقص‌ها را در محیط‌های عملیاتی افزایش دهد. به‌ویژه برای شناسایی نقص‌های نادر یا جدید که در دیتاست اولیه وجود نداشته‌اند، این امکان می‌تواند عملکرد سیستم را به شکل چشمگیری بهبود دهد. برای ارزیابی عملی بودن مدل پیشنهادی، زمان آموزش نیز مدنظر قرار گرفت. در این پژوهش، فرآیند یادگیری مدل‌ها بر روی یک سیستم مجهز به پردازنده گرافیکی NVIDIA Tesla T4با حافظه ۱۶GB و پردازنده مرکزی Intel Xeon انجام شد. با توجه به ساختار مدل و حجم داده‌ها، میانگین زمان آموزش برای هر دوره حدود ۱ دقیقه و کل فرآیند آموزش تا رسیدن به همگرایی به طور تقریبی ۶ ساعت به طول انجامید. بدیهی است که این مقدار بسته به سخت‌افزار مورد استفاده و بهینه‌سازی‌های احتمالی در کدنویسی و تنظیمات ابرپارامترها می‌تواند تغییر کند. همچنین، با استفاده از GPU های قدرتمندتر، مدت زمان آموزش به شکل محسوسی کاهش یافته و امکان پیاده‌سازی مدل در شرایط واقعی سریع‌تر فراهم خواهد شد.

۴- نتیجه‌گیری

این مقاله به بررسی و ارزیابی کارایی مدل‌های یادگیری عمیق در شناسایی و تشخیص عیوب ویفر در مدارهای مجتمع پرداخته است. با توجه به چالش‌های اساسی موجود در صنعت نیمه‌هادی‌ها و الکترونیک، به‌ویژه در رابطه با تشخیص عیوب ویفر، نتایج این پژوهش اهمیت بکارگیری تکنیک‌های یادگیری عمیق را در بهبود فرآیندهای تولید و افزایش کیفیت محصولات نهایی به وضوح نشان می‌دهد.

یافته‌های تجربی نشان می‌دهد که مدل‌های یادگیری عمیق، به ویژه DenseNet121، با قابلیت یادگیری ویژگی‌های پیچیده و عمیق از داده‌ها، به‌طور معناداری عملکرد بهتری نسبت به روش‌های سنتی تحلیل تصویر دارند. استفاده از تکنیک‌های پیش‌پردازش و افزونگی داده نیز به افزایش دقت و کارایی مدل‌ها کمک کرده است. این پژوهش همچنین به بررسی تأثیر ساختار و ویژگی‌های مدل‌های عمیق بر بهبود دقت تشخیص عیوب پرداخته و نشان داده که طراحی مناسب مدل‌ها می‌تواند منجر به عملکرد بالاتر در شناسایی عیوب شود. این پژوهش نه تنها به عنوان یک منبع معتبر برای محققان و مهندسان در زمینه ارتقاء سیستم‌های تشخیص عیوب در مدارهای مجتمع مطرح می‌شود، بلکه راهکارهای عملی برای بهبود فرآیندهای تولید در صنعت الکترونیک ارائه می‌دهد. ب‌کارگیری این تکنیک‌ها می‌تواند به کاهش خطاهای تولید و افزایش کارایی و بهره‌وری محصولات الکترونیکی کمک شایانی نماید. از این رو، این مطالعه می‌تواند مبنای مناسبی برای پژوهش‌های آینده در زمینه‌های مرتبط با تشخیص عیوب و بهبود کیفیت در صنعت نیمه‌هادی‌ها باشد.

براساس نتایج این پژوهش، تحقیقات آینده می‌تواند بر توسعه مدل‌های ترکیبی از یادگیری عمیق و الگوریتم‌های کلاسیک برای بهره‌برداری از نقاط قوت هر دو رویکرد تمرکز کند. همچنین، استفاده از مجموعه‌داده‌های بزرگ‌تر و متنوع‌تر شامل انواع عیوب و شرایط نوری مختلف، می‌تواند به بهبود دقت مدل‌ها کمک کند. بهبود روش‌های پیش‌پردازش، به‌ویژه در داده‌های نامتعادل، نیز از اهمیت بالایی برخوردار است. پیاده‌سازی این مدل‌ها در خطوط تولید واقعی و ارزیابی تأثیر آن‌ها

بر کیفیت و هزینه‌ها، نتایج کاربردی به همراه خواهد داشت. در نهایت، ارزیابی مدل‌های جدیدتر یادگیری عمیق، علاوه بر DenseNet121، می‌تواند به رفع نقاط ضعف مدل‌های فعلی و بهبود تشخیص عیوب ویفر کمک کند. شایان ذکر است که پیاده‌سازی روش پیشنهادی در این مطالعه به صورت نرم‌افزاری و با استفاده از داده‌های موجود انجام شده و توسعه یک نمونه سخت‌افزاری می‌تواند در تحقیقات آتی دنبال شود.

جدول (۵): ارزیابی عملکرد مدل‌ها در شناسایی نقص‌های ویفر با استفاده از معیارهای مختلف در استفاده از مجموعه داده MIR-WM811K

مدل		Center	Donut	Edge-Loc	Edge-Ring	Loc	Random	Scratch	Near-Full	None
RNN	دقت (%)	۸۸/۳۶	۸۸/۵۰	۸۴/۱۳	۸۷/۵۶	۸۳/۷۱	۸۷/۵۵	۸۴/۶۲	۹۰/۳۴	۸۹/۲۳
	Spe (%)	۹۲/۳۴	۹۱/۳۲	۸۹/۵۷	۸۸/۱۷	۸۶/۲۶	۹۰/۱۴	۸۵/۲۸	۹۴/۲۳	۹۲/۱۷
	Ppr (%)	۸۹/۵۷	۸۸/۳۶	۸۸/۷۳	۸۹/۴۲	۸۶/۹۰	۸۷/۲۴	۸۳/۱۷	۸۵/۴۱	۹۱/۲۶
	Sen (%)	۸۶/۲۵	۹۰/۷۳	۸۷/۵۱	۸۵/۳۳	۸۷/۶۶	۸۸/۵۶	۸۲/۴۰	۸۷/۹۱	۹۰/۲۹
	(%) F-Measure	۸۷/۸۸	۸۹/۵۳	۸۸/۱۱	۸۷/۳۲	۸۷/۳۸	۸۷/۸۹	۸۲/۷۸	۸۶/۶۴	۹۰/۷۷
VGG16 [۱۴]	دقت (%)	۹۴/۳۶	۹۴/۷۳	۹۳/۵۶	۹۴/۳۹	۹۴/۴۷	۹۵/۰۹	۹۳/۳۷	۹۴/۶۱	۹۵/۸۸
	Spe (%)	۹۳/۲۴	۹۴/۵۵	۹۴/۳۳	۹۴/۷۱	۹۳/۱۳	۹۵/۴۱	۹۴/۲۹	۹۴/۸۰	۹۵/۳۶
	Ppr (%)	۹۴/۱۳	۹۳/۲۶	۹۴/۱۸	۹۴/۵۶	۹۴/۰۹	۹۴/۲۲	۹۴/۴۱	۹۴/۷۲	۹۴/۸۹
	Sen (%)	۹۳/۵۵	۹۴/۱۹	۹۴/۲۵	۹۳/۷۸	۹۴/۵۱	۹۵/۰۱	۹۴/۱۸	۹۳/۶۹	۹۴/۷۸
	(%) F-Measure	۹۳/۸۴	۹۳/۷۲	۹۴/۲۱	۹۴/۱۷	۹۴/۳۰	۹۴/۶۱	۹۴/۲۹	۹۵/۷۱	۹۴/۸۳
MobileNet [۱۴]	دقت (%)	۸۹/۰۹	۸۸/۹۹	۸۷/۲۳	۸۹/۸۵	۸۷/۳۱	۸۸/۶۳	۸۷/۵۳	۸۸/۶۹	۹۰/۲۵
	Spe (%)	۹۱/۱۲	۹۰/۲۴	۸۹/۷۳	۸۸/۴۵	۸۸/۷۳	۸۷/۵۲	۸۷/۴۸	۸۸/۷۳	۹۰/۱۷
	Ppr (%)	۸۹/۵۲	۸۸/۴۳	۸۹/۷۳	۸۹/۴۳	۸۸/۵۷	۸۹/۷۱	۸۹/۴۷	۹۰/۸۳	۹۰/۴۲
	Sen (%)	۹۰/۵۳	۹۰/۲۴	۹۱/۱۳	۸۹/۸۸	۸۹/۴۶	۹۰/۳۲	۸۹/۵۵	۹۱/۰۹	۹۱/۱۴
	(%) F-Measure	۹۰/۰۲	۸۹/۳۲	۹۰/۴۲	۸۹/۶۵	۸۹/۰۱	۹۰/۰۱	۸۹/۵۱	۹۰/۹۶	۹۰/۷۸
GoogleNet [۱۴]	دقت (%)	۹۰/۱۶	۸۹/۲۱	۸۸/۵۳	۹۰/۳۲	۸۷/۵۱	۸۷/۲۲	۸۷/۴۳	۹۱/۲۹	۹۱/۳۴
	Spe (%)	۸۹/۳۲	۸۸/۷۷	۸۹/۲۶	۹۱/۵۳	۸۹/۱۷	۸۸/۵۵	۸۶/۴۳	۸۸/۵۱	۸۹/۷۳
	Ppr (%)	۸۹/۲۱	۸۹/۵۹	۸۷/۴۳	۸۹/۳۳	۸۸/۴۲	۸۹/۷۳	۸۹/۲۲	۹۰/۴۱	۹۰/۷۳
	Sen (%)	۹۰/۴۶	۸۹/۷۱	۸۸/۶۳	۸۹/۴۱	۸۹/۳۹	۹۰/۰۳	۸۹/۶۰	۸۹/۴۵	۹۰/۵۶
	(%) F-Measure	۸۹/۸۳	۸۹/۶۵	۸۳/۲۹	۸۹/۴۰	۸۸/۹۰	۸۹/۸۸	۸۹/۴۱	۸۹/۹۳	۹۰/۶۴
رزنت۳۴ [۱۵]	دقت (%)	۹۲/۱۴	۹۳/۰۹	۹۱/۴۱	۹۲/۲۴	۹۰/۷۱	۹۲/۴۶	۸۹/۵۲	۹۳/۴۸	۹۲/۷۱
	Spe (%)	۹۱/۸۱	۹۲/۳۹	۹۲/۵۶	۹۰/۳۴	۹۱/۳۳	۹۰/۲۵	۹۰/۶۵	۹۲/۵۴	۹۳/۶۳
	Ppr (%)	۹۱/۵۷	۹۳/۳۴	۹۲/۷۰	۹۱/۵۳	۹۱/۵۶	۹۲/۳۷	۹۱/۵۳	۹۱/۴۴	۹۲/۶۹
	Sen (%)	۹۲/۰۹	۹۲/۵۱	۹۱/۶۳	۹۱/۷۰	۹۲/۵۵	۹۲/۴۳	۹۰/۵۶	۹۲/۴۱	۹۲/۷۵
	(%) F-Measure	۹۱/۸۳	۹۲/۹۲	۹۲/۱۶	۹۱/۶۱	۹۲/۰۵	۹۲/۴۰	۹۱/۰۴	۹۱/۹۲	۹۲/۷۲
رزنت۵۰	دقت (%)	۹۵/۲۳	۹۵/۴۱	۹۳/۰۹	۹۴/۸۲	۹۳/۱۸	۹۴/۲۶	۹۴/۱۱	۹۵/۲۲	۹۵/۷۱
	Spe (%)	۹۴/۴۰	۹۵/۲۳	۹۴/۱۶	۹۴/۵۳	۹۴/۲۱	۹۳/۳۹	۹۴/۶۲	۹۴/۵۴	۹۴/۴۶
	Ppr (%)	۹۵/۷۳	۹۵/۰۳	۹۳/۷۲	۹۳/۴۱	۹۳/۵۶	۹۴/۲۹	۹۴/۵۱	۹۵/۳۶	۹۵/۶۹
	Sen (%)	۹۵/۹۱	۹۴/۲۶	۹۴/۰۶	۹۴/۳۲	۹۳/۵۱	۹۴/۶۶	۹۴/۸۷	۹۵/۵۹	۹۵/۲۷
	(%) F-Measure	۹۵/۸۲	۹۴/۶۴	۹۳/۸۹	۹۳/۸۶	۹۳/۵۳	۹۴/۴۷	۹۴/۶۹	۹۵/۴۷	۹۵/۴۸
DenseNet121	دقت (%)	**۹۸/۵۸**	**۹۸/۶۳**	**۹۶/۲۴**	**۹۸/۰۹**	**۹۷/۲۱**	**۹۷/۴۱**	**۹۶/۲۴**	**۹۸/۷۳**	**۹۸/۵۱**
	Spe (%)	**۹۶/۴۳**	**۹۷/۸۱**	**۹۵/۳۲**	**۹۵/۵۶**	**۹۶/۸۳**	**۹۷/۵۶**	**۹۷/۳۲**	**۹۸/۴۸**	**۹۸/۱۶**
	Ppr (%)	**۹۷/۶۶**	**۹۷/۴۳**	**۹۸/۵۱**	**۹۷/۱۴**	**۹۸/۱۳**	**۹۸/۲۲**	**۹۷/۰۹**	**۹۸/۵۲**	**۹۸/۲۶**
	Sen (%)	**۹۸/۰۸**	**۹۷/۲۱**	**۹۷/۷۳**	**۹۸/۵۶**	**۹۷/۳۱**	**۹۸/۰۵**	**۹۷/۵۱**	**۹۷/۴۹**	**۹۷/۳۹**
	(%) F-Measure	**۹۷/۸۷**	**۹۷/۳۲**	**۹۸/۱۲**	**۹۸/۱۵**	**۹۷/۷۲**	**۹۸/۱۳**	**۹۷/۳۰**	**۹۸/۰۰**	**۹۷/۸۲**

جدول (۶): دقت طبقه‌بندی نقص‌های ویفر با استفاده از مدل‌های مختلف یادگیری عمیق بر روی دو مجموعه داده

مدل	دادگان	Center	Donut	Edge-Loc	Edge-Ring	Loc	Random	Scratch	Near-Full	None	میانگین(٪)
RNN	MIR-WM811K	۸۸/۳۶	۸۸/۵۰	۸۴/۱۳	۸۷/۵۶	۸۳/۷۱	۸۷/۵۵	۸۴/۶۲	۹۰/۳۴	۸۹/۲۳	۸۷/۱۱
	WaferMap	۸۹/۵۲	۹۰/۷۳	۸۶/۱۲	۸۸/۴۲	۸۷/۲۵	۸۹/۶۲	۸۵/۷۳	۸۸/۲۴	۹۰/۳۵	۸۸/۴۴
VGG16 [۱۴]	MIR-WM811K	۹۴/۳۶	۹۴/۷۳	۹۳/۵۶	۹۴/۳۹	۹۴/۴۷	۹۵/۰۹	۹۳/۳۷	۹۴/۶۱	۹۵/۸۸	۹۴/۵۳
	WaferMap	۹۵/۷۳	۹۳/۲۱	۹۵/۴۲	۹۵/۵۶	۹۵/۳۲	۹۴/۸۱	۹۴/۷۳	۹۵/۸۷	۹۶/۳۲	۹۵/۲۲
MobileNet [۱۴]	MIR-WM811K	۸۹/۰۹	۸۸/۹۹	۸۷/۲۳	۸۹/۸۵	۸۷/۳۱	۸۸/۶۳	۸۷/۵۳	۸۸/۶۹	۹۰/۲۵	۸۸/۶۲
	WaferMap	۹۰/۱۷	۹۱/۵۳	۸۸/۴۳	۹۰/۵۶	۸۹/۷۳	۸۹/۴۱	۸۸/۳۳	۹۰/۹۰	۹۱/۳۹	۹۰/۰۵
GoogleNet [۱۴]	MIR-WM811K	۹۰/۱۶	۸۹/۲۱	۸۸/۵۳	۹۰/۳۲	۸۷/۵۱	۸۷/۲۲	۸۷/۴۳	۹۱/۲۹	۹۱/۳۴	۸۹/۲۲
	WaferMap	۹۱/۲۸	۸۸/۴۰	۸۷/۳۲	۸۹/۶۵	۸۹/۳۸	۸۸/۷۲	۸۶/۳۶	۹۰/۱۹	۹۱/۵۱	۸۹/۲۰
رزنت۳۴ [۱۵]	MIR-WM811K	۹۲/۱۴	۹۳/۰۹	۹۱/۴۱	۹۲/۲۴	۹۰/۷۱	۹۰/۷۱	۸۹/۵۲	۹۳/۴۸	۹۳/۴۸	۹۱/۹۷
	WaferMap	۹۳/۰۸	۹۳/۵۱	۹۳/۴۸	۹۴/۵۲	۹۰/۳۹	۹۰/۷۱	۹۰/۴۶	۹۲/۸۹	۹۲/۳۹	۹۲/۳۸
رزنت۵۰	MIR-WM811K	۹۵/۲۳	۹۵/۴۱	۹۳/۰۹	۹۴/۸۲	۹۳/۱۸	۹۴/۲۶	۹۴/۱۱	۹۵/۲۲	۹۵/۷۱	۹۴/۵۶
	WaferMap	۹۴/۳۶	۹۴/۷۷	۹۳/۴۱	۹۴/۵۶	۹۴/۶۹	۹۳/۳۹	۹۴/۵۶	۹۴/۸۷	۹۵/۱۲	۹۴/۴۱
DenseNet121	MIR-WM811K	۹۸/۵۸	۹۸/۶۳	۹۶/۲۴	۹۸/۰۹	۹۷/۲۱	۹۷/۴۱	۹۶/۲۴	۹۸/۷۳	۹۸/۵۱	**۹۷/۷۴**
	WaferMap	۹۸/۳۲	۹۹/۰۹	۹۷/۳۹	۹۸/۵۱	۹۷/۴۹	۹۷/۵۲	۹۸/۷۳	۹۹/۰۱	۹۸/۸۸	**۹۸/۳۳**

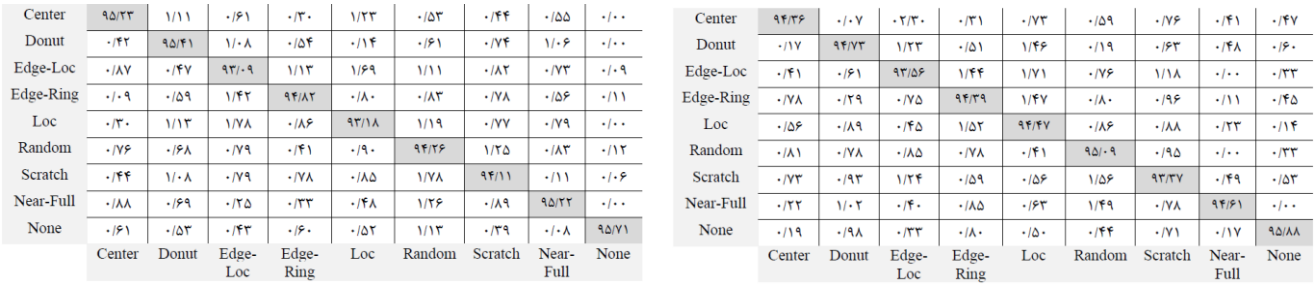

شکل (۴): ماتریس درهم ریختگی به منظور طبقه‌بندی نقص‌ها مبتنی‌بر الف) مدل VGG16، ب) مدل رزنت۵۰، و ج) مدل DenseNet121

مراجع

[1] J. Yu et al., "Wafer map defect recognition based on deep transfer learning-based densely connected convolutional network and deep forest", Engineering Applications of Artificial Intelligence, vol. 105, 2021.

[2] R. Li and Z. Kang, "Deep Learning for Wafer Map Defect Detection: A Review", in 2023 Global Reliability and Prognostics and Health Management Conference (PHM-Hangzhou), 2023, doi: 10.1109/PHM-Hangzhou58797.2023.10482800.

[3] U. Batool, M. I. Shapiai, M. Tahir, A. Elfakharany et al., "A Systematic Review of Deep Learning for Silicon Wafer Defect Recognition", IEEE Access, vol. 99, pp. 1-1, Aug. 2021, doi: 10.1109/ACCESS.2021.3106171.

[4] C.-Y. Hsu and J.-C. Chien, "Ensemble convolutional neural networks with weighted majority for wafer bin map pattern classification", Journal of Intelligent Manufacturing, vol. 33, no. 4, Feb. 2022, doi: 10.1007/s10845-020-01687-7.

[5] S. Cheon, H. Lee, C. O. Kim, and S. H. Lee, "Convolutional neural network for wafer surface defect classification and the detection of unknown defect class", IEEE Transactions on Semiconductor Manufacturing, vol. 32, no. 2, pp. 163-170, 2019, doi: 10.1109/TSM.2019.2902657.

[6] J. Chien, M. Wu, and J. Lee, "Inspection and classification of semiconductor wafer surface defects using CNN deep learning networks", Applied Sciences, 2020.

[7] I. Jeong, S. Y. Lee, K. Park et al., "Wafer map failure pattern classification using geometric transformation-invariant convolutional neural network", Scientific Reports, vol. 13, p. 8127, 2023, doi: 10.1038/s41598-023-34147-2.

[8] K. K. Chauhan, G. Joshi, M. M. Kaur, and R. Vig, "Semiconductor wafer defect classification using

convolution neural network: A binary case", IOP Conference Series: Materials Science and Engineering, vol. 1225, 2022.

[9] P. P. Shinde, P. P. Pai, and S. P. Adiga, "Wafer defect localization and classification using deep learning techniques", IEEE Access, vol. 10, pp. 39969-39974, 2022, doi: 10.1109/ACCESS.2022.3166512.

[10] F. López de la Rosa, J. Gómez-Sirvent, R. Morales, R. Sánchez-Reolid, and A. Fernández-Caballero, "Defect detection and classification on semiconductor wafers using two-stage geometric transformation-based data augmentation and SqueezeNet lightweight convolutional neural network", Computers & Industrial Engineering, vol. 183, p. 109549, 2023, doi: 10.1016/j.cie.2023.109549.

[11] S. Kim and D. Kim, "A novel approach for wafer defect pattern classification based on topological data analysis", Expert Systems with Applications, vol. 231, 2023, doi: 10.1016/j.eswa.2023.120765.

[12] Z. Li, Z. Wang, and W. Shi, "Automatic wafer defect classification based on decision tree of deep neural network", in 33rd Annual SEMI Advanced Semiconductor Manufacturing Conference (ASMC), 2022, pp. 1-6, doi: 10.1109/ASMC54647.2022.9792500.

[13] M. B. Alawieh, D. Boning, and D. Z. Pan, "Wafer map defect patterns classification using deep selective learning", in 57th ACM/IEEE Design Automation Conference (DAC), San Francisco, CA, USA, 2020, pp. 1-6, doi: 10.1109/DAC18072.2020.9218580.

[14] Y. Chen, M. Zhao, Z. Xu, K. Li, and J. Ji, "Wafer defect recognition method based on multi-scale feature fusion", Frontiers in Neuroscience, 2023, doi: 10.3389/fnins.2023.1202985.

[15] J. Li, T. Ran, C. Renxiang, C. Yongpeng, Z. Chengying, and H. Xianzhen, "Sample-imbalanced wafer map defects classification based on auxiliary classifier denoising diffusion probability model", Computers & Industrial Engineering, vol. 192, p. 110209, 2024.

[16] Y. Wang, Y. Wei, and H. Wang, "A class imbalanced wafer defect classification framework based on variational autoencoder generative adversarial network", Measurement Science and Technology, vol. 34, no. 2, 2023, doi: 10.1088/1361-6501

[17] E. Shin and C. D. Yoo, "Efficient convolutional neural networks for semiconductor wafer bin map classification", Sensors (Basel), vol. 23, no. 4, 2023, doi: 10.3390/s23041926.

[18] J. A. Mat-Jizat, A. P. Abdul Majeed, A. F. Ab. Nasir, and Z. Taha, "Evaluation of the machine learning classifier in wafer defects classification", ICT Express, vol. 7, pp. 535-539, 2021.

[19] J. Ma, T. Zhang, C. Yang, Y. Cao, L. Xie, H. Tian, and X. Li, "Review of Wafer Surface Defect Detection Methods", Electronics, vol. 12, p. 1787, 2023, doi: 10.3390/electronics12081787.

[20] A. Shawon, M. O. Faruk, M. B. Habib, and A. M. Khan, "Silicon Wafer Map Defect Classification Using Deep Convolutional Neural Network With Data Augmentation", in 2019 IEEE 5th International Conference on Computer and Communications (ICCC), Chengdu, China, 2019, pp. 1995-1999, doi: 10.1109/ICCC47050.2019.9064029.

[21] Kaggle, "WM811K Wafer Map Dataset", available: https://www.kaggle.com/datasets/qingyi/wm811k-wafer-map.

[22] Kaggle, "Wafermap Dataset", available: https://www.kaggle.com/datasets/shawon10/wafermap.

[23] S.-K. Fan and S.-H. Chiu, "A new ViT-Based augmentation framework for wafer map defect classification to enhance the resilience of semiconductor supply chains", International Journal of Production Economics, vol. 273, p. 109275, 2024.

[24] Y. Sheng, J. Yan, and M. Piao, "Improved wafer map defect pattern classification using automatic data augmentation based lightweight encoder network in contrastive learning", Journal of Intelligent Manufacturing, 2024, doi: 10.1007/s10845-024-02444-w.

[25] P. Bhatnagar, T. Arora, and R. Chaujar, "Semiconductor Wafer Map Defect Classification Using Transfer Learning", in 2022 IEEE Delhi Section Conference (DELCON), New Delhi, India, 2022, pp. 1-4, doi: 10.1109/DELCON54057.2022.9753436.

[26] S. Chen, Y. Zhang, M. Yi, J. Ma, and X. Hou, "Wafer maps defect recognition based on transfer learning of handwritten pre-training network", in 2021 International Symposium on Computer Technology and Information Science (ISCTIS), Guilin, China, 2021, pp. 280-283, doi: 10.1109/ISCTIS51085.2021.00064.

[27] S. Mavaddati and H. S. Azhari Lamraski, "Brain tumor detection and classification based on MRI images using deep learning and transfer learning models", Journal of Iranian Association of Electrical and Electronics Engineers, vol. 22, no. 2, pp. 129–141, 2025.

[28] A. Hatami and I. GanjKhani, "Long-term voltage stability assessment of an integrated transmission distribution system based on LSTM recurrent neural network", Journal of Iranian Association of Electrical and Electronics Engineers, vol. 21, no. 4, pp. 123–133, 2024.

زیرنویس‌ها

[1] Convolutional Neural network

[2] K-Nearest neighbor

[3] Recurrent Convolutional neural network

[4] Transfer Learning

[5] You only Look once

[6] Topological data analysis

[7] Automatic defect Classification

[8] Scanning electron microscopy

[9] Multi-Feature fasion perceptual network

[10] Variational autoencoder generative adversarial network

[11] Variational autoencoder

[12] Dataset-Train & Test

[13] Dataset-Unknown

[14] Wafer bin map

[15] Deep neural network

[16] Multi-Feature fusion perceptual network

[17] Variational autoencoder generative adversarial

[18] Dense convolutional network

[19] Learning Rate

[20] Adaptive Moment Estimation

[21] Rectified Linear unit

[22] Ture positive

[23] True Negative

[24] Learning Rate

[25] False Positive