Journal of Iranian Association of Electrical and Electronics Engineers
Vol. 22 No. 4, 2025
DOI: 10.61882/jiaeee.22.4.44

Application and Evaluation of Deep Learning Models for Defect Detection in Printed Circuit Boards

Hami Hosseini[1], Samira Mavaddati [2*]

[1] MSc., Electronic Department, Faculty of Engineering and Technology, University of Mazandaran, Babolsar Iran, h.hosseini02@umail.umz.ac.ir
[2*] Associate Professor, Electronic Department, Faculty of Engineering and Technology, University of Mazandaran, Babolsar, Iran
s.mavaddati@umz.ac.ir

Abstract:
This paper investigates the effectiveness of various deep learning models for automatic defect detection in printed circuit boards (PCBs). Given the critical impact of PCB defects on electronic device functionality, their rapid and precise identification is vital for ensuring product reliability and quality. In this study, several state-of-the-art deep neural networks, including Inception-v3, VGG16, ResNet18, ResNet50, ResNet101, and YOLOv5, are implemented and evaluated using datasets containing annotated PCB images. The selected models were chosen for their diverse architectures and proven performance in visual recognition tasks. Results reveal that these deep models are capable of extracting high-level features and significantly improving the accuracy of defect detection. Among the models, YOLOv5 demonstrated superior speed in identifying defects in real-time, while ResNet101 showed the highest classification accuracy. The outcomes validate the potential of deep learning to revolutionize PCB inspection by automating the detection process, reducing human error, and enhancing production line efficiency.

Keywords: Printed circuit board, defect Detection, Deep learning, Image processing, YOLOv5, ResNet, Inception-v3, VGG16, Transfer learning, Data augmentation

Article Type: Research

Received: 01. 10. 2024

Revised: 31. 05. 2025

Accepted: 13. 07. 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 quality and reliability of electronic devices heavily depend on the integrity of their printed circuit boards (PCBs). Even minor defects in PCBs can lead to significant functional failures, making defect detection a crucial phase in the manufacturing process. Traditional inspection techniques, including manual and rule-based visual inspection, suffer from limitations such as subjectivity, inconsistency, and inefficiency. The increasing complexity and miniaturization of PCBs further intensify the need for intelligent, scalable, and accurate inspection methods. Deep learning, known for its exceptional performance in image-based classification and object detection tasks, offers a promising solution by automating the defect detection process with high precision and speed. The motivation behind this study is to explore the application of various deep learning architectures in addressing these challenges effectively. The goal is not only to evaluate their accuracy in detecting various types of defects but also to assess their practical applicability in industrial settings. The authors selected a diverse set of convolutional neural networks (CNNs) and object detection models, including YOLOv5 and ResNet variants, to ensure a comprehensive comparison.

2. Contributions

This work offers several key contributions to the field of PCB defect detection. First, it provides a systematic evaluation of multiple deep learning models, Inception-v3, VGG16, ResNet18, ResNet50, ResNet101, and YOLOv5, across the same dataset, facilitating a fair comparison of their performance. Unlike prior studies that often focus on a single architecture, this research highlights the strengths and trade-offs of various CNN-based classifiers and object detectors in identifying defects in printed circuit boards. Second, the study leverages both classification and detection paradigms to address different types of defects, surface and structural, more comprehensively. YOLOv5, in particular, is tested for real-time detection capabilities, whereas deeper ResNet models are evaluated for classification accuracy. The experimental setup incorporates transfer learning and fine-tuning, improving model generalization while reducing training time and data dependency.

Third, the research introduces a practical benchmarking framework for PCB quality assurance by integrating modern deep learning tools with industrial inspection requirements. The comparative analysis guides practitioners in selecting the most suitable model based on accuracy, inference speed, and computational cost. The findings of this paper underscore the feasibility of deploying these models in production lines, paving the way for smart manufacturing systems. By doing so, this research helps bridge the gap between academic advancements in deep learning and their application in real-world electronic testing scenarios.

3. Procedures

In this study, a series of experiments were conducted to evaluate the effectiveness of deep learning models in detecting PCB defects. The research utilized an openly available dataset of printed circuit board images containing six distinct types of defects: Open, Short, Mouse bite, Spur, Copper, and Hole. Each image was labeled to indicate the presence and type of defect, enabling both classification and object detection tasks.

Six models were selected for evaluation: Inception-v3, VGG16, ResNet18, ResNet50, ResNet101, and YOLOv5. These models represent a range of convolutional neural network depths and architectures. The classification models (VGG16, ResNet variants, Inception-v3) were trained using image-level annotations to classify each image into one of the six defect categories. YOLOv5 was used to perform object detection, identifying and localizing defects within the PCB images.

The experiments were performed in a Python environment using TensorFlow and PyTorch libraries. Pretrained weights on ImageNet were used as initial parameters, and the models were fine-tuned using the PCB dataset. The dataset was split into training (70%), validation (15%), and test (15%) sets. Data augmentation techniques such as rotation, flipping, and zooming were applied to increase the dataset size and improve model robustness. Performance metrics, including accuracy, precision, recall, F1-score, and inference time, were measured to assess each model's effectiveness. Confusion matrices were generated to visualize classification performance, and precision-recall curves were analyzed to compare models. The YOLOv5 model was additionally evaluated using mean Average Precision (mAP) to quantify object detection performance. Results were then summarized to determine which architecture provides the optimal balance between detection accuracy and computational efficiency.

4. Findings

The evaluation of the six deep learning models on the PCB defect dataset yielded informative and promising results. Among the classification models, ResNet101 achieved the highest accuracy (over 99%), followed by ResNet50 and Inception-v3. These deeper networks were more effective in extracting detailed features and generalizing across various defect types. VGG16, while simpler and faster to train, exhibited slightly lower performance due to its limited depth and feature capacity.

YOLOv5 demonstrated excellent object detection capability, successfully identifying multiple defects in real-time with a mean Average Precision (mAP) exceeding 98%. Its strength lies in its ability to not only detect but also localize defects within high-resolution PCB images, making it especially suitable for deployment in automated inspection systems.

The experiments confirmed that using transfer learning significantly enhanced model performance, especially when the training dataset size was limited. Data augmentation also contributed to model generalization

and robustness. A comparative analysis revealed that while classification models are suitable for defect categorization, object detection models like YOLOv5 provide a more practical solution by pinpointing defect locations. From a computational perspective, ResNet18 and VGG16 required less training time and resources, making them ideal for low-power embedded systems, albeit with some trade-off in accuracy.

5. Conclusion

This research demonstrates the effectiveness of deep learning models in the automatic detection of PCB defects. The comparative evaluation of various architectures, including classification models and object detectors, shows that deep neural networks can significantly enhance the accuracy, speed, and reliability of the inspection process. ResNet101 emerged as the most accurate classifier, while YOLOv5 proved to be a powerful real-time object detection model capable of precisely localizing defects.

By integrating transfer learning and data augmentation techniques, the models achieved high performance even with limited data. The results suggest that deep learning provides a robust and scalable alternative to traditional inspection techniques, offering the potential to automate and optimize quality control in electronics manufacturing.

نشریه مهندسی برق و الکترونیک ایران

نشریه مهندسی برق و الکترونیک ایران، سال بیست و دوم، شماره چهارم، زمستان ۱۴۰۴، صفحات ۴۴-۵۶

DOI: 10.61882/jiaeee.22.4.44

بکارگیری و ارزیابی مدل‌های یادگیری عمیق به منظور تشخیص نقص‌ها در بردهای مدار چاپی

حامی حسینی[۱]، سمیرا مودّتی[۲]

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

h.hosseini02@umail.umz.ac.ir

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

s.mavaddati@umz.ac.ir

چکیده: نقص‌ها در بردهای مدار چاپی می‌توانند منجر به اختلالات جدی در عملکرد دستگاه‌های الکترونیکی شوند و شناسایی دقیق و سریع آن‌ها برای تضمین کیفیت تولید، امری ضروری است. در این مقاله، کارایی شش مدل یادگیری عمیق شامل Inception-v3، VGG16، رزنت۱۸، رزنت۵۰، رزنت۱۰۱ و یولو۵v در تشخیص خودکار نقص‌های بردهای مدار چاپی بررسی شده است. این نقص‌ها که می‌توانند باعث اختلالات جدی در عملکرد دستگاه‌های الکترونیکی شوند، نیازمند شناسایی سریع و دقیق برای تضمین کیفیت تولید هستند. هر یک از مدل‌ها با استفاده از مجموعه داده‌ای متشکل از تصاویر نقص‌های مختلف بردهای مدار چاپی آموزش دیده و با معیارهای دقت، حساسیت، اختصاصیت و سرعت پردازش ارزیابی شده‌اند. نتایج نشان می‌دهد که مدل یولو۵v با دقت بالاتر و زمان پردازش کمتر، بهترین عملکرد را در تشخیص انواع نقص‌های سطحی و ساختاری ارائه می‌دهد. این پژوهش تأکید می‌کند که انتخاب معماری مناسب شبکه عصبی عمیق می‌تواند تأثیر قابل توجهی بر بهبود دقت و کارایی فرآیند بازرسی بردهای مدار چاپی داشته باشد و جایگزینی مؤثر برای روش‌های سنتی باشد.

کلمات کلیدی: پردازش تصویر، برد مدار چاپی، تشخیص نقص، افزونگی داده، یادگیری عمیق

نوع مقاله: پژوهشی

دریافت: ۱۴۰۳/۰۷/۱۰

بازنگری: ۱۴۰۴/۰۳/۱۰

پذیرش: ۱۴۰۴/۰۴/۲۲

نام نویسنده‌ی مسئول: سمیرا مودّتی

نشانی نویسنده‌ی مسئول: ایران – بابلسر – دانشگاه مازندران – دانشکده‌ی مهندسی و فناوری

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

بردهای مدار چاپی یکی از اجزای اصلی و حیاتی در طراحی و تولید تجهیزات الکترونیکی مدرن به شمار می‌روند. با توجه به پیچیدگی روزافزون مدارها و افزایش تعداد و تنوع قطعات مورد استفاده در بردهای مدار چاپی، اطمینان از کیفیت ساخت و عملکرد صحیح آن‌ها امری ضروری است. نقص‌های مختلفی مانند خطاهای اتصال، آسیب‌های فیزیکی، نقص‌های لحیم‌کاری و نواقص سطحی می‌توانند عملکرد صحیح بردهای مدار چاپی (PCB)[1] را تحت تأثیر قرار دهند و به خرابی دستگاه‌های الکترونیکی منجر شوند. از این رو، نیاز به روش‌های سریع و دقیق برای بازرسی و تشخیص خودکار نقص‌های PCB در فرآیند تولید احساس می‌شود[۱]. در سال‌های اخیر، رویکردهای سنتی بازرسی که مبتنی‌بر روش‌های دستی و نوری بودند، با چالش‌های متعددی همچون زمان‌بر بودن، محدودیت دقت و هزینه‌های بالا مواجه شده‌اند. این محدودیت‌ها سبب شده است که رویکردهای مبتنی‌بر هوش مصنوعی و به ویژه یادگیری عمیق، به عنوان راه‌حل‌های نوین برای بهبود فرآیندهای بازرسی و تشخیص نقص‌های PCB مطرح شوند. یادگیری عمیق با بهره‌گیری از شبکه‌های عصبی پیچیده و توانایی بالا در استخراج ویژگی‌های پیچیده از تصاویر، پتانسیل بالایی در تشخیص خودکار و دقیق نقص‌های PCB دارد. روش‌های مبتنی‌بر یادگیری ماشین به عنوان یک جایگزین موثر برای بهبود فرآیندهای بازرسی و تشخیص نقص‌های PCB مطرح شده‌اند. این روش‌ها با بهره‌گیری از تکنیک‌های مختلف مانند طبقه‌بندی، خوشه‌بندی و رگرسیون، قابلیت شناسایی الگوهای پیچیده را دارند. با این حال، مدل‌های یادگیری عمیق به عنوان یکی از پیشرفته‌ترین روش‌های یادگیری ماشین، به دلیل توانایی بالا در استخراج ویژگی‌های پیچیده و یادگیری خودکار از داده‌های بزرگ، به‌ویژه در زمینه پردازش تصویر، نتایج بسیار بهتری ارائه داده‌اند[۲]. در این پژوهش، تمرکز بر روش‌های مبتنی‌بر مدل‌های یادگیری عمیق برای تشخیص نقص‌های PCB قرار دارد. شبکه‌های عصبی عمیق به دلیل ساختار لایه به لایه خود، قادر به استخراج ویژگی‌های پیچیده از تصاویر بردهای مدار چاپی هستند که این امر موجب افزایش دقت و کاهش خطاهای تشخیص می‌شود. در این مقاله، چندین مدل معروف یادگیری عمیق شامل مدل‌های Inception-v3[2]،VGG16، رزنت۱۸[3]، رزنت۵۰[4]، رزنت۱۰۱[5]، و مدل یولوv5[6] مورد بررسی قرار می‌گیرند. این مدل‌ها به دلیل معماری‌های منحصربه‌فرد و قابلیت‌های بالای خود در پردازش تصاویر، توانایی تشخیص خودکار نقص‌های PCB را بهبود بخشیده‌اند. یادگیری عمیق به عنوان یک ابزار تحول‌آفرین در حوزه‌های مختلف صنعتی از جمله صنعت الکترونیک، پتانسیل به‌کارگیری گسترده‌ای دارد. در این پژوهش، استفاده از این فناوری در زمینه تشخیص نقص‌های PCB بررسی شده و مزایای آن نسبت به روش‌های سنتی مورد ارزیابی قرار گرفته است. برد مدار چاپی به عنوان یک جزء مهم در محصولات الکترونیکی نقش بسیار مهمی در زندگی ایفا می‌کند. به دلیل محدودیت‌های فنی، نقص‌هایی در PCBها در فرآیند تولید اجتناب‌ناپذیر است. برای تضمین بازدهی بالا و کاهش هزینه‌های نیروی کار، در [۳] دو نوع شبکه تشخیص هدف SSD[7] و FPN[8] به منظور شناسایی و طبقه‌بندی نقص‌های PCB استفاده شده است. آزمایش‌ها نشان داده‌اند که این دو روش در مجموعه داده‌های مختلف با دقت بالایی عمل کرده‌اند. در [۴]، روشی برای تشخیص نقص در PCB با استفاده از شبکه‌های عصبی کانولوشنال کامل بهبود یافته ارائه شده است. این شبکه با معرفی ماژول کانولوشن منقبض شونده پیوسته[9]، میدان پذیرش را افزایش می‌دهد و مشکل افت اطلاعات در کانولوشن منقبض شونده معمولی را حل می‌کند. این شبکه با مدل MobileNet-v2 که لایه‌های کمتری دارد ساخته شده و با مدل‌های رزنت۵۰ و VGG16[10] مقایسه شده است. در [۵]، یک مدل یادگیری عمیق با استفاده از مجموعه داده ای شامل انواع مختلفی از نقص‌های PCB مانند ترک، قطعی، خراش و ... آموزش داده شد. این مدل در تشخیص تمام این نواقص نتایج امیدوارکننده‌ای را نشان داد. این پژوهش نشان می‌دهد که استفاده از مجموعه داده جامع برای جلوگیری از سوگیری در تحلیل ویدئو برای تشخیص نقص PCB بسیار موثر است. [۶]، روشی مبتنی‌بر یادگیری ماشین با استفاده از شبکه‌های عصبی کانولوشنال (CNN)[11] برای طبقه‌بندی مدارهای چاپی سالم و معیوب پیشنهاد می‌کند. این مدل با دقت ۹۲/۸٪ مدارهای چاپی سالم و معیوب را تفکیک می‌کند. در [۷]، یک شبکه عصبی عمیق جدید به منظور شناسایی نقص‌های بردهای مدار چاپی پیشنهاد شده است. این پژوهش، ابتدا از شبکه حرارتی هرم باقیمانده[12] (RFHNet) که شامل مدل عمیق رزنت۵۰ و مکانیزم ترمودینامیکی[13](TM) است، برای استخراج ویژگی‌های چند مقیاس و تعیین مکان نقص استفاده می‌کند. با توجه به دشواری‌های روش‌های بینایی ماشین سنتی در تعیین معیارهای قبولی و مردودی بر اساس نمونه‌های نقص کوچک، پیشنهاد در [۸] استفاده از یک روش پیشرفته مبتنی‌بر خودرمزگذار کانولوشنی[14] برای بازرسی PCB است. این پژوهش از مدل‌های یادگیری ماشین پیشرفته مانند شبکه‌های عصبی کانولوشنی برای شناسایی خودکار نقص‌ها در پایگاه داده بزرگی از تصاویر PCB استفاده می‌کند. یک چارچوب کامل یادگیری عمیق برای شناسایی و طبقه‌بندی سریع و دقیق نقص‌های تولیدی در بردهای مدار چاپی با استفاده از مدل تشخیص شیء تک‌مرحله‌ای در [۹] گزارش شده است. مدل پیشنهادی با روش‌های پیشرفته مختلف مقایسه شده است. در [۱۰]، الگوریتم یادگیری عمیق مبتنی‌بر روش یولو برای بازرسی کیفیت بردهای مدار چاپی پیشنهاد شده است. با توجه به دقت و کارایی بالای الگوریتم‌های یادگیری عمیق، استفاده از آن‌ها در زمینه‌های مختلف افزایش یافته است. در [۱۱]، مدل شناسایی نوع PCB سریع به نام LD-PCB[15] معرفی شده است که قابلیت شناسایی در زمان واقعی و افزایش دقت شناسایی را فراهم می‌آورد. همچنین، مدل شناسایی دیگری توسعه یافته که دقت شناسایی نقوص غیرمنظم را بهبود می‌بخشد. [۱۲]، به استفاده از تکنیک‌های یادگیری ماشین و

هوش مصنوعی پرداخته می‌پردازد. ویژگی‌های مرتبط با استفاده از شبکه‌های پیش‌آموزش‌دیده VGG16 و Inception استخراج شده و مجموعه داده DeepPCB با ۱۵۰۰ جفت تصویر معیوب و غیرمعیوب مورد استفاده قرار گرفته است. روش ارائه شده در [۱۳]، بر روی شناسایی نقص‌های PCB با استفاده از تکنیک‌های یادگیری عمیق تمرکز دارد. در این مقاله، ساختار مدل شناسایی اشیاء یولوv8 و تکنولوژی‌های کلیدی آن توضیح داده می‌شود و در نهایت، عملکرد برتر یولوv8 در شناسایی نقص‌های PCB از طریق آزمایش‌های مقایسه‌ای تأیید می‌شود. در [۱۴]، الگوریتمی برای نظارت خودکار و زمان‌واقعی کیفیت PCBها در سناریوهای مختلف پیشنهاد شده است. در این روش، پیچیدگی سطح PCBها و چگالی طرح‌ها با استفاده از یادگیری عمیق و الگوریتم‌های استخراج ویژگی تصویر تحلیل می‌شود.

در این پژوهش، مدل یادگیری عمیق شامل مدل‌های Inception-v3، VGG16، رزنت۱۸، رزنت۵۰، رزنت۱۰۱، و مدل یولوv5 مورد بررسی قرار می‌گیرند. این مدل‌ها به دلیل معماری‌های متفاوت و قابلیت‌های منحصربه‌فرد در استخراج ویژگی‌های تصاویر، توانایی‌های قابل توجهی در تشخیص نقص‌های سطحی و ساختاری بردهای مدار چاپی از خود نشان داده‌اند. هدف از این مقاله، مقایسه کارایی این مدل‌ها در تشخیص نقص‌های PCB و ارزیابی توانایی آن‌ها در بهبود دقت و سرعت فرآیند بازرسی است. نتایج این تحقیق می‌تواند به بهبود روش‌های بازرسی صنعتی و کاهش خطاهای تولید در حوزه الکترونیک کمک کند. یافته‌ها در این مقاله عبارتند از:

- مدل‌های مختلف یادگیری عمیق شامل Inception-v3، VGG16، رزنت۱۸، رزنت۵۰، رزنت۱۰۱، و یولوv5 بر روی مجموعه داده‌های تصاویر نقص‌های برد مدار چاپی مورد آموزش و ارزیابی قرار گرفتند. نتایج نشان داد که این مدل‌ها با دقت بالا قادر به تشخیص خودکار نقص‌های سطحی و ساختاری در بردهای مدار چاپی هستند. این قابلیت به دلیل قدرت بالای این مدل‌ها در استخراج ویژگی‌های پیچیده از تصاویر است.

- مدل Inception-v3 به دلیل بهره‌گیری از معماری چندمقیاسی، توانسته است با کاهش پیچیدگی محاسباتی، سرعت پردازش بالاتری نسبت به سایر مدل‌ها ارائه دهد. این ویژگی به خصوص برای کاربردهای صنعتی که نیاز به تشخیص سریع دارند، اهمیت دارد.

- مدل یولوv5 و VGG16 به دلیل معماری‌های خاص، علاوه بر دقت مناسب، توانایی بالایی در تشخیص سریع چندین نقص دارند. این دو مدل به دلیل قابلیت‌های خود در تحلیل تصاویر و کاهش زمان بازرسی، به عنوان گزینه‌های برتر در کاربرد صنعتی معرفی می‌شوند.

- مدل رزنت۱۰۱ به دلیل معماری عمیق‌تر و قابلیت استخراج ویژگی‌های پیچیده‌تر، در شناسایی نقص‌های جزئی‌تر دقت مناسبی نشان داده است. این نتایج بیانگر اهمیت انتخاب مدل مناسب و بکارگیری بلوک‌های مانده در این مدل با توجه به نوع نقص‌ها است.

- مدل‌های مبتنی‌بر یادگیری عمیق به طور مؤثری می‌توانند نقص‌های موجود در بردهای مدار چاپی را با دقت و سرعت بالا تشخیص دهند. مدل‌های رزنت۱۰۱ و یولوv5 به دلیل دقت و سرعت بالاتر در مقایسه با دیگر مدل‌ها، بهترین عملکرد را در این مقاله نشان دادند. این نتایج نشان‌دهنده پتانسیل بالای استفاده از شبکه‌های عصبی عمیق در فرآیندهای بازرسی خودکار و صنعتی است.

- با وجود موفقیت‌های به‌دست آمده، همچنان چالش‌هایی نظیر نیاز به حجم بالای داده‌ها برای آموزش مؤثر و نیاز به منابع محاسباتی قدرتمند برای اجرای مدل‌ها در زمان واقعی وجود دارد. این چالش‌ها، موانعی هستند که برای کاربرد گسترده‌تر این روش‌ها در مقیاس صنعتی باید مورد توجه قرار گیرند. جدول ۱، نمونه‌ای از پژوهش‌های اخیر که بر پایه مفاهیم یادگیری عمیق برای تشخیص عیوب بردهای مدار چاپی انجام شده‌اند، را به تصویر می‌کشد. این جدول یک مقایسه جامع از روش‌های پیشنهادی، اهداف تحقیقاتی، منابع داده‌ای، تعداد دسته‌های مورد استفاده برای طبقه‌بندی، و سال‌های انتشار هر پژوهش را ارائه می‌دهد.

در بخش دوم این مقاله، به تفصیل رویکرد پیشنهادی شامل پایگاه داده، مراحل پیش‌پردازش، تبدیل داده‌ها، و تنظیمات پارامترهای مربوط به معماری طراحی‌شده توضیح داده می‌شود. بخش سوم به نتایج تجربی و ارزیابی عملکرد اختصاص دارد. در این بخش، نتایج به‌دست‌آمده از روش پیشنهادی مورد بررسی قرار گرفته و در نهایت، بخش آخر به نتیجه‌گیری از این تحقیق می‌پردازد.

۲- تشخیص نقص بردهای مدار چاپی براساس مدل‌های عمیق

تشخیص نقص در بردهای مدار چاپی براساس مدل‌های یادگیری عمیق، یک روش نوین و پیشرفته برای بهبود فرآیندهای بازرسی و کنترل کیفیت در صنعت الکترونیک است[۳-۱]. نقص‌های PCB معمولاً شامل مشکلات لحیم‌کاری، ترک‌ها، شکستگی‌ها، اتصال کوتاه و دیگر نواقص سطحی و ساختاری می‌شود که باید به دقت شناسایی شوند یادگیری عمیق به عنوان یکی از شاخه‌های پیشرفته یادگیری ماشین، قادر است به طور خودکار ویژگی‌های پیچیده‌ای از تصاویر بردهای مدار چاپی را استخراج کرده و نقص‌ها را با دقت بالایی شناسایی کند.

جدول (۱): پژوهش‌های اخیر در زمینه تشخیص تومورهای مغزی براساس مدل‌های عمیق.

مرجع	وظیفه	کلاس‌ها	مجموعه دادگان	دسته‌بند	انتشار
[۳]	تشخیص	۶ کلاس (Hole، Mouse bite، Open، Short، Copper و Spur)	PCB Dataset/ DeepPCB Dataset	SSD [16]/ FPN[17]	۲۰۲۱
[۴]	تشخیص	۴ کلاس (Mouse bite، Open، Short، و Spur)	PCB defect dataset	MobileNet-V2	۲۰۲۲
[۵]	تشخیص/ دسته‌بندی	۱۰ کلاس (Breakout, Copper, Crack, Cut, Exessive conductor, missing Conductor, mouse bite, Pinhole, Spur, and Scratch.	PCB Defect Dataset	Mask RCNN[18]	۲۰۲۳
[۶]	دسته‌بندی	۲ کلاس (معیوب، و غیر معیوب)	PCB defect dataset	CNN	۲۰۲۱
[۷]	تشخیص	۶ کلاس (Hole، Mouse bite، Open، Short، Copper و Spur)	PCB-Master dataset/ DeepPCB-Master	AKPLNet[19]	۲۰۲۴
[۸]	تشخیص	۶ کلاس (No hole، Mouse bite، Open، Short، Copper، و Pinches)	تهیه شده به صورت دستی	CNN	۲۰۲۳
[۹]	دسته‌بندی	۶ کلاس (Hole، Mouse bite، Open، Short، Copper و Spur)	PKU-Market-PCB Repository	FRCNN[20] / یولو۵v	۲۰۲۲
[۱۰]	دسته‌بندی	۲ کلاس (معیوب، و غیر معیوب)	جمع‌آوری توسط AOI[21]	CNN/یولو	۲۰۲۰
[۱۱]	تشخیص	۳ کلاس (جایگذاری اشتباه[22]، جایگذاری از دست رفته[23]، و تشخیص المان[24])	تهیه شده به صورت دستی	LDCN[25]	۲۰۲۰
[۱۲]	تشخیص/ دسته‌بندی	۶ کلاس (Hole، Mouse bite، Open، Short، Copper و Spur)	DeepPCB dataset	VGG16/Inception/ CNN	۲۰۲۲
[۱۳]	دسته‌بندی	۶ کلاس (Hole، Mouse bite، Open، Short، Copper و Spur)	Open Lab of Peking University Repository	یولو۸v	۲۰۲۴
[۱۴]	تشخیص/ دسته‌بندی	دسته‌بندی المان‌های از دست‌رفته و جهت المان‌ها	YUV dataset	رزنت۵۰	۲۰۲۲
روش پیشنهادی	دسته‌بندی	۶ کلاس (Hole، Mouse bite، Open، Short، Copper و Spur)	PCB defect dataset	Inception-v3/ VGG16/رزنت۱۸/ رزنت۵۰/رزنت۱۰۱v۵/یولو	-

این مدل‌ها با استفاده از شبکه‌های عصبی قابلیت پردازش و تحلیل تصاویر با رزولوشن بالا را دارند. برخی از مدل‌های معروف که در تشخیص نقص‌های PCB استفاده می‌شوند.

۲-۱- مجموعه داده و پیش پردازش تصاویر

مجموعه داده‌های مختلفی در مقالات برای تشخیص نقص برد مدار چاپی مورد استفاده قرار می‌گیرد. در این مقاله از مجموعه داده PCB-Defects که یک مجموعه داده عمومی است بهره گرفته شده است. این مجموعه داده به منظور طبقه‌بندی نقص برد مدار چاپی در شش کلاس نقص در صنعت نیمه‌هادی مورد استفاده قرار می‌گیرد [۱۵]. عیوب برد مدار چاپی می‌تواند منجر به خرابی دستگاه‌های الکترونیکی شود و هزینه‌های هنگفتی را به بار آورد. این عیوب می‌توانند در مراحل مختلف تولید، از جمله طراحی، مونتاژ و تست، رخ دهند. انواع مختلفی از عیوب برد مدار چاپی وجود دارد که هر کدام می‌تواند منجر به مشکلات خاص خود شود. برخی از رایج‌ترین آن‌ها عبارتند از: ۱) نقص مس زائد[26]: مس در بردهای مدار چاپی به دلیل هادی بودن و قیمت مناسب استفاده می‌شود، اما مستعد نقص‌هایی مانند حفره‌ها، ترک‌ها و خوردگی است. این نقص‌ها می‌توانند منجر به مشکلاتی مانند اتصال کوتاه، افت ولتاژ و نویز الکتریکی شوند. ۲) نقص Mousebite: نقصی است که به دلیل عدم لحیم‌کاری کامل لبه‌های مسی به وجود و ممکن است ظریف و غیرقابل مشاهده باشد. این نقص می‌تواند به اتصال کوتاه، افت ولتاژ و نویز الکتریکی منجر شود. ۳) نقص مدار باز[27]: زمانی رخ می‌دهد که پیوستگی الکتریکی بین دو نقطه از بین می‌رود، که می‌تواند به دلایل مختلفی مانند لحیم‌کاری نامناسب یا آسیب مکانیکی ایجاد شود.

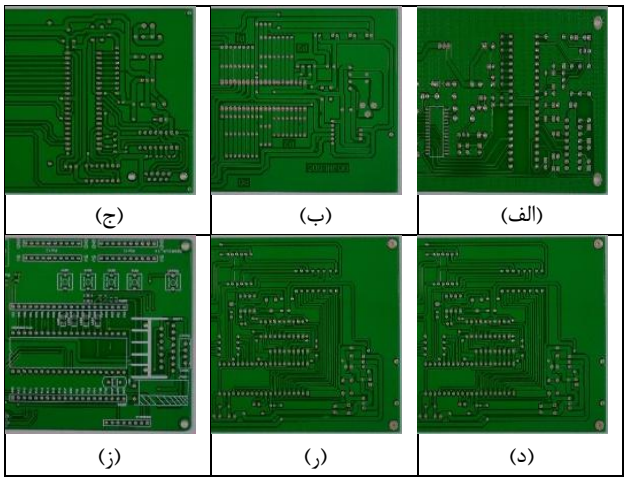

شکل (۱): تصاویر نقص‌های مختلف بردهای مدار چاپی، الف) حفره‌های مفقود، ب) نقص Mouse bite، ج) مدار باز، د) اتصال کوتاه، ر) مس زائد، و ز) نقص Spur

۴) نقص حفره‌های مفقود[۲۸]: حفره‌های ریز در سطح مسی PCB که به دلیل حباب‌های هوا یا ناخالصی‌ها ایجاد می‌شود. این نقص می‌تواند منجر به اتصال کوتاه، افت ولتاژ و نویز الکتریکی شده و تشخیص آن ممکن است دشوار باشد. ۵) نقص اتصال کوتاه[۲۹]: زمانی که دو نقطه هادی به طور ناخواسته به هم متصل می‌شوند. این نقص می‌تواند به دلیل لحیم‌کاری نامناسب یا آلودگی ایجاد شود و می‌تواند باعث گرم شدن بیش از حد، آسیب به اجزا و از دست دادن عملکرد شود. ۶) نقص Spur: لبه‌های تیز و برجسته‌ای که در سطح مسی PCB ایجاد می‌شود، ممکن است به دلیل حکاکی یا لحیم‌کاری نامناسب به وجود آید. این نقص می‌تواند به اتصال کوتاه، نویز الکتریکی و آسیب به اجزا منجر شود [۴-۶، ۱۲]. شکل ۱ نمونه‌ای از شش تصویر مربوط به هر یک از کلاس‌های نقص در برد مدار چاپی را نشان می‌دهد. علاوه بر این شش کلاس اصلی، ممکن است کلاس‌های فرعی دیگری نیز برای دسته‌بندی دقیق‌تر نقص‌ها استفاده شوند. ابعاد تصاویر مورد استفاده در این پژوهش ۲۲۴×۲۲۴ در نظر گرفته شده است. این اندازه به دلیل سازگاری با معماری مدل‌های عمیق انتخاب شده است. از نظر مشخصات تصویر، تصاویر باید دارای رزولوشن کافی برای شناسایی دقیق نقص‌ها باشند. تصاویر معمولاً به صورت با عمق رنگ ۲۴ بیت، ۸ بیت برای هر کانال رنگی، ذخیره می‌شوند تا اطلاعات رنگی دقیقی فراهم نمایند. سپس مقادیر پیکسل‌ها باید به دامنه [۱,۰] نرمال‌سازی شوند. برای بهبود عملکرد مدل. تنظیم روشنایی و کنتراست تصاویر نیز می‌تواند به بهبود دقت مدل در شناسایی نقص‌ها کمک کند و شامل تعدیل روشنایی، کنتراست و تعادل رنگ می‌شود.

۲-۲- افزونگی داده

افزونگی داده[۳۰] به مجموعه‌ای از تکنیک‌ها اطلاق می‌شود که برای افزایش تنوع داده‌های آموزشی به کار می‌روند. این روش‌ها به ویژه در پروژه‌های یادگیری عمیق اهمیت دارند، چرا که می‌توانند به بهبود دقت مدل‌ها و کاهش مشکلاتی مانند بیش برازش[۳۱] کمک کنند. در زمینه تشخیص نقص بردهای مدار چاپی، افزونگی داده نقش حیاتی در بهبود عملکرد مدل‌های یادگیری عمیق ایفا می‌کند [۱۷-۱۶]. به منظور تشخیص نقص‌های PCB، داده‌های آموزشی به طور معمول شامل تصاویری از انواع مختلف نقص‌ها است. با این حال، در بسیاری از موارد، داده‌های موجود ممکن است به اندازه کافی متنوع نباشند یا نقص‌های خاصی به طور نادر در داده‌ها وجود داشته باشند. اینجاست که افزونگی داده می‌تواند به کمک بیاید. با استفاده از تکنیک‌های افزونگی داده، می‌توان تعداد و تنوع تصاویر آموزشی را افزایش داد و به این ترتیب، مدل‌های یادگیری عمیق می‌توانند در برابر تغییرات و نقص‌های نادر بهتر آموزش ببینند.

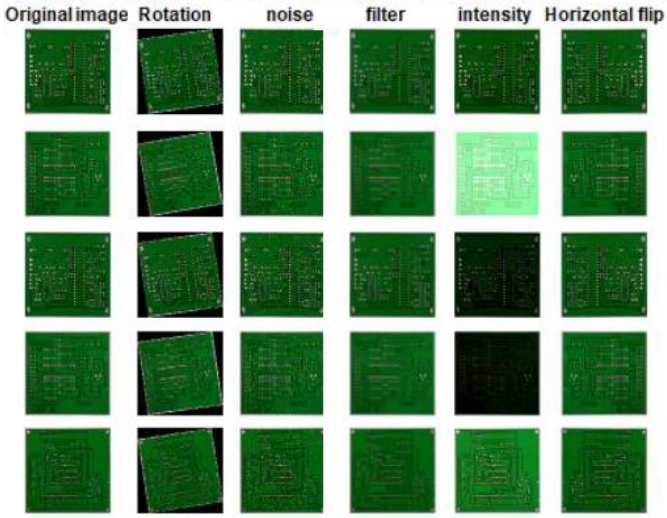

شکل (۲): نمونه‌هایی از تصاویر با افزونگی داده برای هر کلاس نقص بردهای مدار چاپی برای هر کلاس. ردیف اول) حفره‌های مفقود، ردیف دوم) نقص Mouse bite، ردیف سوم) مدار باز، ردیف چهارم) اتصال کوتاه، ردیف پنجم) مس زائد، و ردیف ششم) نقص Spur

جدول (۲): تعداد تصاویر هر کلاس قبل و بعد از اعمال تکنیک‌های افزونگی داده. نمایش تعداد تصاویر موجود در هر کلاس با استفاده از تکنیک‌های افزونگی داده به منظور افزایش تنوع داده‌ها و بهبود عملکرد مدل‌های یادگیری عمیق

کلاس‌ها	نام اختصاری	کل داده	بعد افزونگی	داده آموزش	داده آزمایش
حفره‌ها	Hole	۱۱۵	۶۹۰	۵۵۲	۱۳۸
Mouse bite	Mouse bite	۱۱۵	۶۹۰	۵۵۲	۱۳۸
مدار باز	Open	۱۱۶	۶۹۶	۵۵۷	۱۳۹
اتصال کوتاه	Short	۱۱۶	۶۹۶	۵۵۷	۱۳۹
مس زائد	Copper	۱۱۶	۶۹۶	۵۵۷	۱۳۹
Spur	Spur	۱۱۵	۶۹۰	۵۵۲	۱۳۸
کل		**۶۹۳**	**۴۱۵۸**	**۳۳۲۷**	**۸۳۱**

تکنیک‌های افزونگی داده شامل تغییرات مختلفی در تصاویر هستند، از جمله: چرخش، برش، تغییر مقیاس و ....[۱۸]. برخی از تصاویر مجموعه دادگان نامبرده افزونه شده از شش دسته ذکر شده در شکل ۲ نمایش داده شده است. در این بخش، تعداد تصاویر هر کلاس در مجموعه داده‌های آموزشی و تأثیر استفاده از تکنیک‌های افزونگی داده بر بهبود عملکرد مدل‌های یادگیری عمیق مورد بررسی قرار می‌گیرد. در جدول ۲، تعداد تصاویر موجود در هر کلاس قبل و بعد از اعمال تکنیک‌های افزونگی داده ارائه شده است. افزونگی داده شامل تکنیک‌هایی مانند چرخش، تغییر اندازه، جابجایی و تغییر روشنایی تصاویر است که به افزایش تنوع داده‌ها و کاهش خطر برازش بیش از حد مدل کمک می‌کند. با اعمال این تکنیک‌ها، تعداد تصاویر هر کلاس به طور قابل توجهی افزایش می‌یابد که این امر موجب بهبود قابلیت تعمیم مدل‌ها و افزایش دقت تشخیص نقص‌های PCB می‌شود. مقایسه

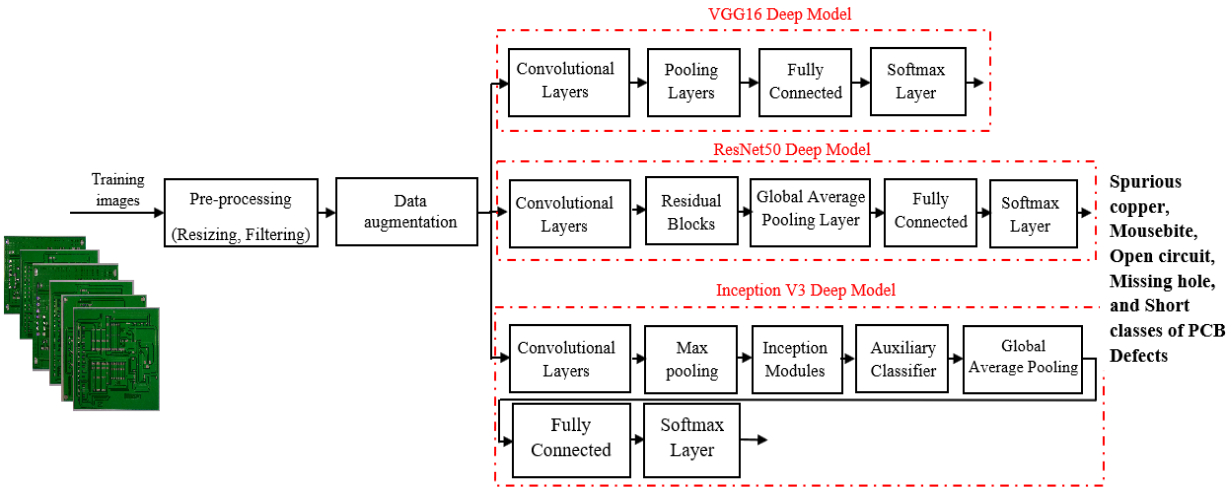

شکل (۳): بلوک دیاگرام روال تشخیص پیشنهادی نقص‌های برد مدار چاپی با استفاده از مدل‌های منتخب VGG16، رزنت ۱۰۱، و Inception-v3. این دیاگرام مراحل مختلف از ورود تصاویر PCB، پیش‌پردازش، استخراج ویژگی‌ها توسط این مدل‌های عمیق تا تشخیص نهایی نقص‌ها و ارائه خروجی را نمایش می‌دهد

تعداد تصاویر قبل و بعد از افزونگی داده به درک بهتر تأثیر این تکنیک‌ها بر عملکرد مدل‌ها کمک کرده و به ارزیابی کارایی این روش‌ها در بهبود نتایج شبیه‌سازی و آموزش مدل‌های یادگیری عمیق می‌پردازد. یادگیری انتقالی[۳۲] یکی از تکنیک‌های مهم در یادگیری عمیق است که به بهبود عملکرد مدل‌ها در مسائل جدید کمک می‌کند. در این تکنیک، به جای آموزش مدل از ابتدا با استفاده از داده‌های یک مسئله خاص، از مدل‌هایی که قبلاً بر روی مجموعه داده‌های بزرگ و عمومی مانند ImageNetآموزش دیده‌اند، استفاده می‌شود. ImageNet یک مجموعه داده عظیم شامل میلیون‌ها تصویر از دسته‌بندی‌های مختلف است که مدل‌ها از آن برای یادگیری ویژگی‌های عمومی تصاویر بهره می‌برند[۱۹-۲۰]. بلوک دیاگرام فرآیند پیشنهادی در شکل ۳ نشان داده شده است. این دیاگرام شامل چندین مرحله اصلی است. ابتدا، تصاویر بردهای مدار چاپی به عنوان ورودی به سیستم داده می‌شوند. این تصاویر می‌توانند از طریق دوربین‌های با وضوح بالا یا دیگر تجهیزات تصویربرداری تهیه شوند. در مرحله بعد، تصاویر ورودی برای بهبود کیفیت و حذف نویزها پردازش می‌شوند. این پردازش‌ها شامل تغییر اندازه، تنظیم روشنایی و کنتراست، و حذف بخش‌های غیرضروری است تا مدل بتواند ویژگی‌های مهم‌تر را بهتر شناسایی کند. سپس، مدل‌های یادگیری عمیق نامبرده که از پیش بر روی مجموعه داده‌های بزرگ مانند ImageNet آموزش دیده‌اند، برای استخراج ویژگی‌های پیچیده از تصاویر PCB به کار گرفته می‌شوند.

در مرحله تشخیص نقص‌ها، خروجی مدل‌های یادگیری عمیق شامل تشخیص نقص‌های سطحی و ساختاری برد مدار چاپی است. این نقص‌ها می‌توانند شامل مشکلاتی مانند شکستگی مدار، اتصالات نادرست و نقص‌های لحیم‌کاری باشند. درنهایت، نتیجه تشخیص نقص‌ها به صورت گزارش یا نمایش بصری در قالب نقشه‌های حرارتی یا تصاویر برجسته‌سازی شده به کاربر ارائه می‌شود. این مراحل به صورت هماهنگ با هم کار می‌کنند تا فرآیند تشخیص نقصهای PCB به صورت خودکار و با دقت بالا انجام شود.

۳- نتایج شبیه‌سازی

در این بخش به بررسی و تحلیل عملکرد مدل‌های یادگیری عمیق Inception-v3، VGG16، رزنت۱۸، رزنت۵۰، رزنت۱۰۱، و مدل یولو۵v به منظور تشخیص نقص‌های بردهای مدار چاپی پرداخته می‌شود. شبیه‌سازی‌های انجام شده شامل ارزیابی مدل‌ها بر روی مجموعه داده‌های متنوعی از تصاویر PCB است که برای تحلیل دقیق و مقایسه عملکرد مدل‌ها طراحی شده‌اند. این بخش به ارائه نتایج حاصل از آزمایش‌های مختلف، شامل دقت تشخیص، نرخ خطا، و زمان پردازش می‌پردازد و به بررسی تأثیر هر یک از مدل‌ها بر دقت و کارایی فرآیند تشخیص نقص‌ها می‌پردازد.

نتایج شبیه‌سازی به درک بهتر قابلیت‌های هر مدل در شناسایی نقص‌های مختلف PCB کمک نموده و به ارائه تحلیل‌های دقیق و جامع برای انتخاب مدل بهینه در کاربردهای صنعتی می‌پردازد.

۳-۱- جزئیات شبیه‌سازی

پیکربندی مدل‌های منتخب یادگیری عمیق مورد استفاده در این مقاله به تفصیل در جدول ۳ ارائه شده است. هر یک از این مدل‌ها دارای ساختار منحصر به فرد و لایه‌های خاص خود هستند که براساس معماری‌های مختلف طراحی شده‌اند. به طور خاص،یولو۵v به دلیل ساختار عمیق و با لایه‌های ویژگی، رزنت۱۰۱ به خاطر استفاده از لایه‌های باقیمانده[۳۳] برای بهبود عمق و یادگیری، و Inception-v3 به دلیل استفاده از ماژول‌های پیچیده و چندگانه برای استخراج ویژگی‌ها، هر کدام مزایای خاص خود را در تشخیص نقص‌های PCB ارائه می‌دهند. جدول ۴ به وضوح فراپارامترهای هر مدل از جمله تعداد لایه‌ها، ابعاد

فیلترها و سایر پارامترهای کلیدی را نشان می‌دهد، که به تحلیل دقیق‌تر عملکرد هر یک در شبیه‌سازی‌های مختلف کمک می‌کند. این جدول شامل جزئیات مربوط به تنظیمات کلیدی هر مدل از جمله ابعاد فیلترها، تعداد لایه‌ها، و سایر پارامترهای تنظیمی است که تأثیر زیادی بر عملکرد و کارایی مدل‌ها دارد. مدل VGG16 شامل تنظیم فراپارامترهایی مانند اندازه فیلترهای ۳×۳ و تعداد لایه‌های کانولوشن و تمام‌متصل است. رزنت ۱۰۱ دارای ۱۰۱ لایه با بلوک‌های مانده برای یادگیری ویژگی‌های پیچیده‌تر است. مدل Inception-v3 با استفاده از ماژول‌های Inception، کانولوشن‌های موازی، و کاهش ابعاد، ویژگی‌های چندگانه را استخراج می‌کند و برای ۱۵ دوره با بهینه‌ساز آدام و نرخ یادگیری 10^{-4} آموزش دیده است.

جدول (۳): پیکربندی مدل‌های عمیق مورد استفاده

Inception-v3	رزنت۱۰۱	یولو5v
Input Image: 224×224×3	Input Image: 224×224×3	Input Image: 224×224×3
(Conv2D/ReLU): 224×224×32	Conv1 (Conv2D/ReLU): 112×112×64	Conv: 112×112×32
(Conv2D/ReLU): 224×224×32	MaxPooling: 56×56×64	BottleneckCSP 1: 56×56×64
MaxPooling: 112×112×32	Residual Block1 : 56×56×256	BottleneckCSP 2: 28×28×128
(Conv2D/ReLU): 112×112×64	Residual Block2 : 28×28×512	BottleneckCSP 3: 14×14×256
MaxPooling: 56×56×64	Residual Block3 : 14×14×1024	BottleneckCSP 4: 7×7×512
Inception Module: 56×56×128	Residual Block4 (x3): 7×7×2048	SPPF: 7×7×512
(Mixed2): 28×28×256	Global Average Pooling: 2048	Upsample + Concat: 14×14×256
(Mixed3): 28×28×384	Fully connected: 1000	BottleneckCSP 5: 14×14×256
MaxPooling: 14×14×384		Upsample + Concat: 28×28×128
(Mixed4): 14×14×768		BottleneckCSP 6: 28×28×128
(Mixed5): 7×7×1280		Detect Head (3 heads):
Global Average Pooling: 1280		- 28×28×33
Fully connected: 1000		- 14×14×33

جدول(۴): فراپارامترهای کلیدی و جزئیات تنظیمات مهم مدل‌های یادگیری عمیق بکارگفته شده به منظور تحلیل و مقایسه در تشخیص نقص‌های بردهای مدار چاپی

	دوره	بهینه‌ساز	دسته	فعال‌ساز	یادگیری	لایه‌ها
Inception-v3	۱۵	آدام	۳۲	سیگموئید	10^{-4}	۳۱۵
VGG16	۱۵	آدام	۳۲	سیگموئید	10^{-4}	۱۶
رزنت۱۸	۲۰	آدام	۳۲	غیرخطی	10^{-3}	۱۸
رزنت۵۰	۲۵	آدام	۳۲	غیرخطی	10^{-3}	۵۰
رزنت۱۰۱	۱۵	آدام	۶۴	غیرخطی	10^{-4}	۱۰۱
یولو5v	۱۵	SGD[34]	۶۴	غیرخطی	10^{-3}	۱۰۰

مدل VGG16 نیز به مدت ۱۵ دوره با آدام و تابع فعال‌سازی سیگموئید آموزش داده شده و از ۱۶ لایه تشکیل شده است. مدل رزنت۱۸ با ۱۸ لایه و تابعReLU ، برای ۱۵ دوره آموزش دیده و نرخ یادگیری آن بین 10^{-3} است. رزنت۵۰ با ۵۰ لایه و نرخ یادگیری 10^{-4}، و رزنت۱۰۱ با ۱۰۱ لایه و نرخ یادگیری مشابه، به ترتیب برای ۱۵ دوره آموزش داده شده‌اند. مدل یولو5v با ۱۰۰ لایه و نرخ یادگیری 10^{-4}، برای ۱۵ دوره با بهینه‌ساز SGD و تابع Leaky ReLU آموزش دیده است. این مقاله از معیارهای مختلفی برای ارزیابی عملکرد مدل‌های یادگیری عمیق استفاده شده است، از جمله دقت[۳۵](Acc) ، ویژگی[۳۶] (Spe)، نرخ پیش‌بینی مثبت[۳۷](Ppr) ، حساسیت[۳۸] (Sen) یا یادآوری[۳۹] (R)و F-Measure [۲۱-۲۲]. دقت به عنوان یک معیار کلی، نشان‌دهنده نسبت پیش‌بینی‌های صحیح به کل پیش‌بینی‌ها است و به ارزیابی کلی عملکرد مدل می‌پردازد، اما در داده‌های نامتوازن ممکن است دقیق نباشد. ویژگی یا نرخ تشخیص درست منفی، به ارزیابی توانایی مدل در شناسایی صحیح نمونه‌های منفی کمک می‌کند و در مواردی که خطای مثبت کاذب اهمیت دارد، بسیار مهم است. نرخ پیش‌بینی مثبت نشان می‌دهد چه میزان از نمونه‌های پیش‌بینی شده به عنوان مثبت به طور واقعی مثبت هستند و برای مسائلی که کاهش خطای مثبت کاذب حیاتی است، به کار می‌رود. حساسیت یا یادآوری میزان توانایی مدل در شناسایی صحیح نمونه‌های مثبت را ارزیابی می‌کند و در مسائلی که شناسایی دقیق نمونه‌های مثبت اهمیت دارد، از اولویت بالایی برخوردار است. ترکیب این معیارها امکان ارزیابی جامع‌تری از عملکرد مدل‌های یادگیری عمیق را فراهم و به درک بهتر نقاط قوت و ضعف مدل‌ها در تشخیص و دسته‌بندی داده‌ها کمک می‌کند[۲۲]. معیارهای مورد استفاده در این مقاله برای مقایسه مدل‌های مختلف به صورت زیر تعریف شده‌اند[۲۴-۲۳]:

$$\text{Accuracy (Acc)}=(TP+TN)/(TP+TN+FP+FN) \quad (۱)$$

$$\text{Specificity (Spe)} =TN/(TN+FP) \quad (۲)$$

$$\text{Precision (Ppr)}= TP/(TP+F)P \quad (۳)$$

$$\text{Sensitivity (Sen)} = TP/(TP+FN) \quad (۴)$$

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

معیارهای به کار رفته در این مقاله برای مقایسه مدل‌های مختلف به صورت زیر تعریف شده‌اند. در این میان، TP[۴۰]، به عنوان تعداد نمونه‌های مربوط به کلاس نقص که به درستی تشخیص داده شده‌اند، تعریف می‌شود. TN[۴۱]، نشان‌دهنده تعداد نمونه‌هایی است که مدل به درستی آن‌ها را در کلاس دیگری دسته‌بندی کرده است. FP[۴۲]، تعداد تصاویری از کلاس داده را بیان می‌کند که به اشتباه به عنوان نقص تشخیص داده شده‌اند، در حالی که متعلق به کلاس دیگر بوده‌اند. در مقابل، FN[۴۳] به نمونه‌هایی اشاره دارد که به طور نادرست به عنوان کلاس مقابل طبقه‌بندی شده‌اند، در حالی که در واقع به کلاس دیگری تعلق دارند[۲۴-۲۳].

۳-۲- نتایج روش پیشنهادی مبتنی‌بر مدل عمیق

به منظور آموزش مدل‌های عمیق در این مقاله، از تکنیک اعتبارسنجی متقابل[۴۴] با ده بار تقسیم استفاده شده است. در این فرآیند، پایگاه داده به ده قسمت مساوی تقسیم می‌شود. در هر دور از ارزیابی، نه قسمت به عنوان داده‌های آموزشی انتخاب و به کار گرفته می‌شوند، در حالی که قسمت باقی‌مانده به منظور اعتبارسنجی و ارزیابی عملکرد مدل اختصاص داده می‌شود. این فرآیند به تکرار ده باره منجر می‌شود که در آن هر بخش از داده‌ها به نوبت به عنوان مجموعه تست و سایر بخش‌ها به عنوان داده‌های آموزشی مورد استفاده قرار می‌گیرند. چنین رویکردی موجب می‌شود که ارزیابی مدل‌ها به شکلی جامع و دقیق‌تر انجام گیرد و قابلیت تعمیم مدل به مجموعه‌های داده جدید بهبود یابد. در نتیجه، نتایج حاصل از این روش به شناسایی بهتر و کارایی بالاتر مدل در پردازش داده‌ها کمک شایانی خواهد کرد. نتایج معیارهای ارزیابی عملکرد مدل‌های یادگیری عمیق ذکرشده به منظور تشخیص نقص بردهای مدار چاپی در شکل ۴ برای هر کلاس نقص گزارش شده است. همچنین میانگین دقت کلی و هر کلاس برای هر مدل عمیق به منظور بررسی کارایی هر مدل در شکل ۵ بیان شده است.

شکل ۶ نمایشگر عملکرد سه مدل عمیق Inception-v3 [۱۲]، VGG16 [۱۲] و رزنت۱۰۱ در طبقه‌بندی نقص‌های برد مدار چاپی به تفکیک شش کلاس نقص ذکرشده است. این کلاس‌ها شامل نقص‌های Hole، Mouse bite، Open، Short، Copper و Spur است. هر ماتریس سردرگمی نشان‌دهنده‌ی دقت مدل‌ها در پیش‌بینی هر یک از این نقص‌ها بوده و میزان طبقه‌بندی صحیح و اشتباه در هر دسته را به تصویر می‌کشد. با تحلیل این ماتریس‌ها، می‌توان عملکرد هر مدل را از نظر دقت در تشخیص این نقص‌ها مقایسه و ارزیابی نمود. همچنین شکل ۷ به بررسی نمودار پیشرفت همگرایی و تلفات در طول فرآیند آموزش مدل‌های Inception-v3، رزنت۱۰۱، و یولو5v به منظور طبقه‌بندی نقص‌های برد مدار چاپی می‌پردازد.

این نمودارها کمک می‌کنند تا روند آموزش و بهینه‌سازی مدل‌ها مقایسه و تحلیل شوند. در ارزیابی نتایج مدل‌های مختلف برای تشخیص نقص‌های برد مدار چاپی، می‌توان مشاهده کرد که مدل رزنت۱۰۱ در مقایسه با سایر مدل‌های مبتنی‌بر رزنت دقت بهتری ارائه داده‌اند. مدل VGG16 با میانگین دقت ۹۲/۴۴٪، در تشخیص نقص‌های Hole و Open عملکرد متوسطی داشته است. این مدل همچنین در کلاس‌های دیگر مانند Mouse bite و Short نیز نتایج مطلوبی نشان داده است. مدل یولو5v نیز با میانگین دقت ۹۷/۷۵٪ عملکرد بسیار خوبی دارد و در تشخیص نقص‌های Short و Spur دقت بالایی از خود نشان داده و تقریباً نزدیک به دقت کامل عمل نموده است . مدل Inception-v3 اگرچه عملکرد قابل‌قبولی در برخی کلاس‌ها از جمله Open و Spur دارد، اما در تشخیص نقص‌هایی مانند Mouse bite و Hole نسبت به سایر مدل‌ها ضعیف‌تر عمل کرده است. مدل‌های رزنت۱۸ و رزنت۵۰ نیز با دقت‌های متوسط، نسبت به سایر مدل‌ها کمتر موفق بوده‌اند. به‌طور کلی، مدل‌های رزنت۱۸ و رزنت۵۰ در تشخیص نقص‌های خاص مانند Hole و Open دقت خوبی دارند، اما در مقایسه با رزنت۱۰۱ و یولو5v عملکرد ضعیف‌تری دارند. این بدان دلیل است که معماری‌های مبتنی‌بر رزنت، مانند رزنت۱۰۱، به‌دلیل عمق شبکه و قابلیت استخراج ویژگی‌های دقیق، در حوزه‌هایی نظیر تشخیص وسایل نقلیه و حذف سایه در تصاویر نیز عملکرد موفقی از خود نشان داده‌اند [۲۶-۲۵]. در رابطه با نمودار همگرایی مدل‌ها، روند همگرایی برای مدل‌های مختلف نشان‌دهنده کارایی و پایداری هر مدل در طی فرآیند آموزش است. مدل یولو5v همگرایی سریع‌تری نسبت به VGG16 داشته و نمودار کاهش تلفات آن‌ها به‌طور پیوسته کاهش یافته است، که این امر نشان‌دهنده بهینه‌سازی بهتر و یادگیری پایدارتر در این مدل‌ها است[۲۸-۲۷]. از سوی دیگر، مدل Inception-v3 اگرچه همگرایی مناسبی دارد، اما به دلیل افزایش تلفات در برخی مراحل، بهینه‌سازی کمتری نسبت به مدل‌های دیگر مانند یولو5v داشته است. در نمودارهای مربوط به مدل‌های رزنت۱۰۱، مشاهده می‌شود که فرآیند همگرایی اندکی نوسانات بیشتری داشته است اما نشان‌دهنده ثبات کافی در طی آموزش است. در جمع‌بندی کلی، مدل‌های عمیق در تشخیص نقص‌های برد مدار چاپی عملکرد بسیار کارآمدی از خود نشان داده‌اند.

(%) F-Measure	(%) Sen	(%) Ppr	(%) Spe	دقت (%)		
۸۴/۰۹	۷۴/۰۰	۹۷/۳۷	۹۹/۶۵	۷۴/۰۰	Hole	مدل Inception-v3 [۱۲]
۷۸/۱۵	۶۸/۷۰	۹۰/۶۰	۹۸/۲۶	۶۸/۷۰	Mouse bite	
۸۸/۱۶	۸۳/۵۱	۹۳/۳۷	۹۸/۵۷	۸۳/۵۰	Open	
۷۸/۲۷	۹۰/۳۷	۶۹/۰۴	۹۲/۸۲	۹۰/۳۶	Short	
۹۳/۰۱	۹۰/۴۸	۹۵/۶۸	۹/۳۰	۹۰/۴۸	Copper	
۷۴/۵۲	۸۹/۵۴	۶۳/۸۲	۹۰/۱۶	۸۹/۵۴	Spur	
۹۰/۰۴	۸۸/۷۳	۹۱/۳۹	۹۷/۸۳	۹۲/۵۳	Hole	مدل VGG16 [۱۲]
۹۲/۴۰	۹۰/۴۶	۹۴/۴۳	۹۲/۳۷	۸۷/۶۲	Mouse bite	
۹۳/۸۸	۹۲/۲۹	۹۵/۵۳	۹۶/۵۱	۹۴/۳۸	Open	
۹۳/۵۹	۹۱/۴۱	۹۵/۸۷	۹۵/۳۴	۹۶/۵۶	Short	
۹۱/۱۰	۸۹/۷۶	۹۲/۴۸	۹۶/۳۳	۸۶/۸۳	Copper	
۹۳/۹۷	۹۲/۶۳	۹۵/۳۵	۹۸/۵۴	۹۶/۷۴	Spur	
۹۲/۱۳	۹۰/۵۵	۹۳/۷۷	۹۱/۴۳	۸۲/۲۴	Hole	مدل رزنت۱۸
۹۳/۵۶	۹۲/۷۱	۹۴/۴۳	۸۳/۵۲	۶۸/۳۹	Mouse bite	
۹۰/۶۹	۸۹/۳۳	۹۲/۰۹	۸۸/۲۴	۸۹/۱۸	Open	
۸۶/۲۲	۸۳/۵۴	۸۹/۳۶	۹۱/۴۵	۸۱/۴۵	Short	
۹۳/۷۴	۹۱/۷۸	۹۵/۷۸	۸۹/۳۳	۷۱/۵۱	Copper	
۸۷/۶۹	۸۲/۶۰	۹۳/۴۴	۹۰/۴۵	۸۷/۵۵	Spur	
۹۲/۵۶	۹۰/۴۷	۹۴/۷۵	۹۴/۸۹	۹۵/۴۳	Hole	مدل رزنت۵۰
۸۹/۰۹	۹۲/۸۳	۸۵/۶۴	۷۷/۲۳	۸۵/۰۹	Mouse bite	
۹۰/۷۲	۸۹/۴۱	۹۲/۰۸	۸۷/۸۳	۹۴/۳۷	Open	
۹۵/۰۶	۹۳/۷۳	۹۶/۴۳	۹۱/۴۹	۹۳/۲۲	Short	
۹۳/۵۹	۹۲/۴۴	۹۴/۷۷	۹۰/۸۶	۹۰/۱۳	Copper	
۸۸/۶۳	۹۴/۵۶	۸۳/۴۱	۹۴/۶۰	۷۰/۲۱	Spur	
۹۶/۷۰	۹۷/۶۷	۹۵/۷۵	۹۹/۲۴	۹۷/۶۷	Hole	مدل رزنت۱۰۱
۸۱/۷۸	۷۷/۱۰	۸۷/۰۷	۹۷/۲۰	۷۷/۱۰	Mouse bite	
۹۴/۶۸	۹۶/۳۹	۹۳/۰۳	۹۸/۲۶	۹۶/۳۹	Open	
۸۲/۹۶	۹۸/۶۷	۷۱/۵۷	۹۳/۰۶	۹۸/۶۷	Short	
۹۷/۹۵	۹۷/۶۲	۹۸/۲۹	۹۹/۷۱	۹۷/۶۲	Copper	
۸۰/۶۴	۶۹/۸۵	۹۵/۳۸	۹۹/۳۴	۶۹/۸۵	Spur	
۹۷/۵۴	۹۹/۰۰	۹۶/۱۲	۹۹/۲۹	۹۹/۰۰	Hole	مدل یولو v5
۹۷/۵۷	۹۶/۹۵	۹۸/۲۰	۹۹/۵۶	۹۶/۹۵	Mouse bite	
۹۷/۸۱	۹۷/۹۴	۹۷/۶۹	۹۹/۴۴	۹۷/۹۴	Open	
۹۶/۳۵	۹۶/۳۵	۹۶/۳۵	۹۹/۳۵	۹۶/۳۴	Short	
۹۹/۳۲	۹۹/۶۶	۹۸/۹۹	۹۹/۸۲	۹۹/۶۶	Copper	
۹۷/۶۷	۹۶/۶۲	۹۸/۷۴	۹۹/۷۶	۹۶/۶۱	Spur	

شکل (۴): دقت کلی، ویژگی، نرخ پیش‌بینی مثبت، حساسیت، و F-Measure طبقه‌بندی‌کننده‌های نقص‌های بردهای مدار چاپی

	Hole	Mouse bite	Open	Short	Copper	Spur	میانگین دقت (٪)
مدل Inception-v3 [۱۲]	۷۴/۰۰	۶۸/۷۰	۸۳/۵۰	۹۰/۳۶	۹۰/۴۸	۸۹/۵۴	۸۲/۷۶
مدل VGG16 [۱۲]	۹۲/۵۳	۸۷/۶۲	۹۴/۳۸	۹۶/۵۶	۸۶/۸۳	۹۶/۷۴	۹۲/٤٤
مدل رزنت۱۸	۸۲/۲۴	۶۸/۳۹	۸۹/۱۸	۸۱/۴۵	۷۱/۵۱	۸۷/۵۵	۸۰/۰۵
مدل رزنت۵۰	۹۵/۴۳	۸۵/۰۹	۹۴/۳۷	۹۳/۲۲	۹۰/۱۳	۷۰/۲۱	۸۸/۰۷
مدل رزنت۱۰۱	۹۷/۶۷	۷۷/۱۰	۹۶/۳۹	۹۸/۶۷	۹۷/۶۲	۶۹/۸۵	۸۹/۵۵
مدل یولوv5	**۹۹/۰۰**	**۹۶/۹۵**	**۹۷/۹۴**	**۹۶/۳۴**	**۹۹/۶۶**	**۹۶/۶۱**	**۹۷/۷۵**

شکل (۵): درصد دقت طبقه‌بندی کننده نقص‌های بردهای مدارچاپی مبتنی‌بر مدل‌های یادگیری عمیق مختلف

	Hole	Mouse bite	Open	Short	Copper	Spur
Hole	۷۴/۰۰	۱/۰۰	۰/۳۳	۲۳/۰۰	۰	۱/۶۷
Mouse bite	۱/۲۷	۶۸/۷۰	۰/۷۶	۴/۸۳	۰/۲۵	۲۴/۱۷
Open	۰	۳/۶۱	۸۳/۵۰	۲/۸۳	۱/۸۰	۸/۲۵
Short	۰/۳۳	۱/۳۳	۴/۶۵	۹۰/۳۶	۰/۸۸	۲/۶۶
Copper	۰	۰	۱/۰۲	۰	۹۰/۴۸	۸/۵۰
Spur	۰	۲/۱۵	۰/۶۱	۷/۰۸	۰/۶۱	۸۹/۵۴

(الف)

	Hole	Mouse bite	Open	Short	Copper	Spur
Hole	۹۷/۶۷	۰/۶۷	۰	۱/۶۷	۰	۰
Mouse bite	۲/۲۹	۷۷/۱۰	۳/۳۱	۱۴/۵۰	۰	۲/۸۰
Open	۰	۰/۲۶	۹۶/۳۹	۳/۰۹	۰/۲۶	۰
Short	۱/۳۳	۰	۰	۹۸/۶۷	۰	۰
Copper	۰	۰	۲/۳۸	۰	۹۷/۶۲	۰
Spur	۰	۱۲/۹۲	۲/۴۶	۱۳/۵۴	۱/۲۳	۶۹/۸۵

(ب)

	Hole	Mouse bite	Open	Short	Copper	Spur
Hole	۹۹/۰۰	۰	۰	۱/۰۰	۰	۰
Mouse bite	۲/۲۹	۹۶/۹۵	۰/۷۶	۰	۰	۰
Open	۰	۰/۵۱	۹۷/۹۴	۱/۰۳	۰/۲۶	۰/۲۶
Short	۰/۶۶	۰/۳۳	۱/۹۹	۹۶/۳۴	۰	۰/۶۶
Copper	۰	۰	۰	۰	۹۹/۶۶	۰/۳۴
Spur	۰/۳۱	۰/۳۱	۰	۲/۱۵	۰/۶۲	۹۶/۶۱

(ج)

شکل (۶): ماتریس سردرگمی به منظور طبقه‌بندی نقص‌های برد مدار چاپی مبتنی‌بر الف) مدل عمیق Inception-v3، ب) مدل عمیق رزنت۱۰۱، و ج) مدل عمیق یولوv5

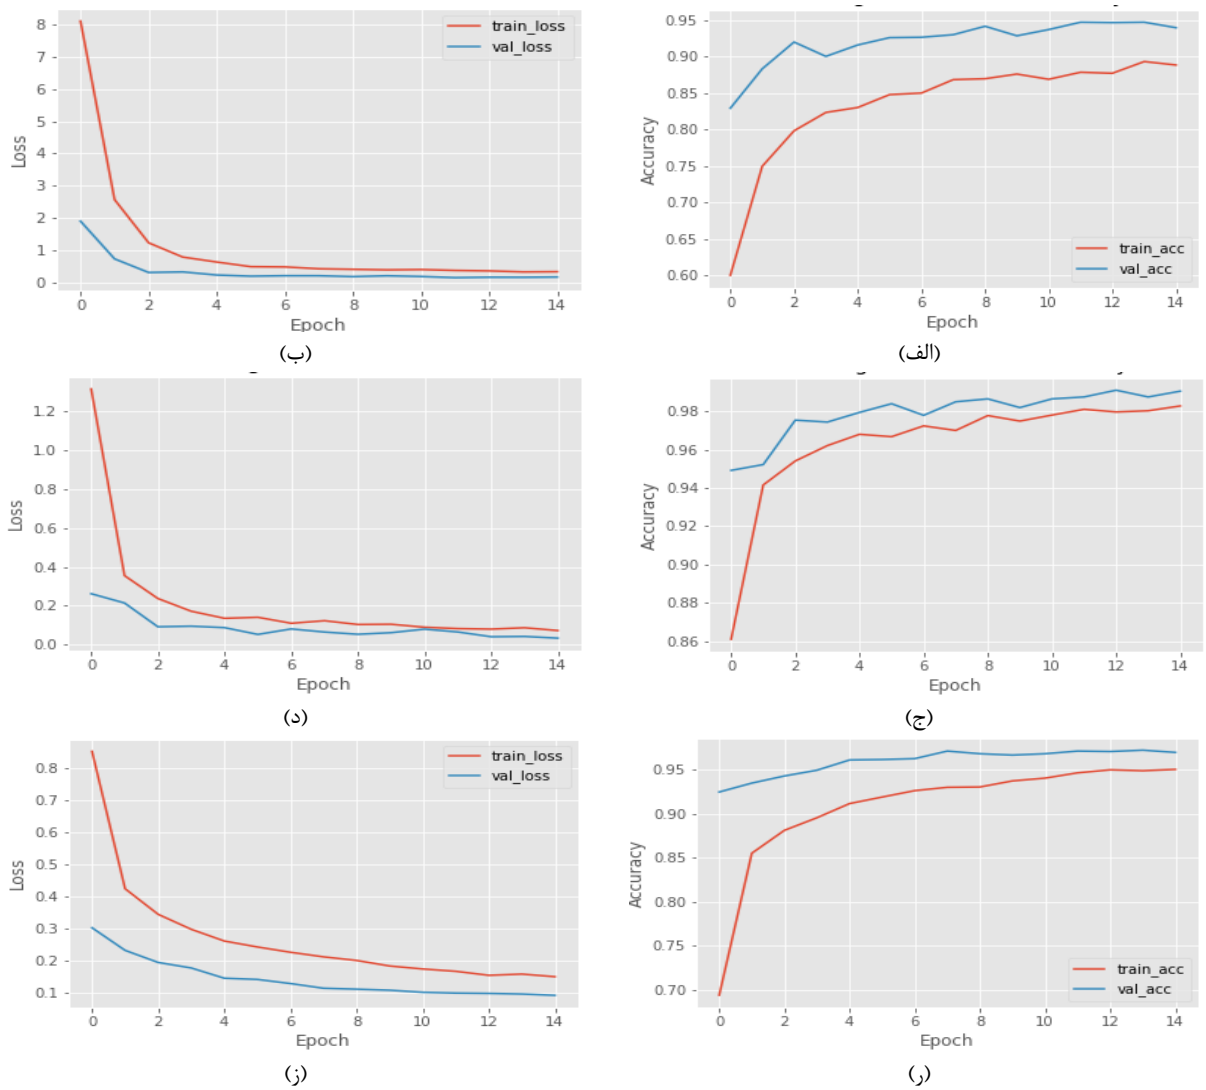

شکل (۷): نمودار پیشرفت همگرایی و تلفات در روال آموزش به منظور طبقه‌بندی نقص‌های برد مدار چاپی، الف) پیشرفت همگرایی مدل Inception-v3، ب) نمودار تلفات مدل Inception-v3، ج) پیشرفت همگرایی مدل رزنت۱۰۱، د) نمودار تلفات مدل رزنت۱۰۱، ر) پیشرفت همگرایی مدل یولو5v، ز) نمودار تلفات مدل یولو5v.

مدل رزنت۱۰۱ با دقت بالا و همگرایی سریع، عملکرد مناسبی را در میان سایر مدل‌ها داشته و توانسته نقص‌های مختلف را با دقت بالایی شناسایی نماید. یولو5v نیز با دقت بالا و قابلیت پردازش سریع، گزینه عالی برای کاربردهای بلادرنگ و شناسایی نقص‌های متنوع است. به‌طور کلی، مدل‌های عمیق برای تشخیص نقص بسیار کارآمد بوده اما مدل یولو5v با توجه به دقت و پایداری بالا، مناسب‌ترین گزینه در این زمینه به شمار می‌آید.

۴- نتیجه‌گیری

در این پژوهش، چندین مدل یادگیری عمیق شامل Inception-v3 ، VGG16، رزنت۱۸، رزنت۵۰، رزنت۱۰۱ و یولو5v برای تشخیص خودکار نقص‌های بردهای مدار چاپی مورد بررسی قرار گرفتند. نتایج تجربی نشان داد که این مدل‌ها به‌ویژه یولو5v و رزنت۱۰۱ در تشخیص سریع و دقیق نقص‌های سطحی و ساختاری عملکرد برتری از خود نشان دادند. معماری یولو5v به‌دلیل قابلیت تشخیص هم‌زمان چندین نقص با سرعت بالا، و معماری رزنت۱۰۱ به‌دلیل دقت بالای خود در شناسایی نقص‌های ظریف‌تر، از سایر مدل‌ها پیشی گرفتند. این نتایج نشان می‌دهند که استفاده از شبکه‌های عصبی عمیق می‌تواند به‌طور مؤثر کارایی سیستم‌های بازرسی خودکار در صنعت الکترونیک را ارتقاء دهد و انتخاب درست معماری نقش کلیدی در افزایش دقت و سرعت این سیستم‌ها ایفا می‌کند.

با توجه به نتایج حاصل از این پژوهش، مسیرهای متعددی برای بهبود سیستم‌های تشخیص نقص قابل پیشنهاد است. استفاده از تکنیک‌های پیشرفته بهینه‌سازی، روش‌های مؤثر افزایش داده، و ترکیب معماری‌های مختلف می‌تواند به بهبود دقت مدل‌ها منجر شود. همچنین، پیاده‌سازی این مدل‌ها روی سخت‌افزارهای نهفته و بهینه‌سازی آن‌ها برای استفاده در زمان واقعی، گامی مؤثر در جهت کاربرد صنعتی خواهد بود. توسعه

مدل‌هایی برای شناسایی نقص‌های پیچیده‌تر و بهره‌گیری از داده‌های واقعی و متنوع نیز می‌تواند عملکرد این سامانه‌ها را در شرایط عملیاتی بهبود بخشد.

مراجع

[1] G. Lakshmi, V. U. Sankar, and Y. S. Sankar, “A survey of PCB defect detection algorithms”, J. Electron. Test., vol. 39, pp. 541-554, 2023, doi: 10.1007/s10836-023-06091-6.

[2] Q. Ling and N. A. M. Isa, “Printed circuit board defect detection methods based on image processing, machine learning and deep learning: A survey”, IEEE Access, vol. 11, pp. 15921-15944, 2023, doi: 10.1109/ACCESS.2023.3245093.

[3] X. Wu, Y. Ge, Q. Zhang, and D. Zhang, “PCB defect detection using deep learning methods”, in IEEE 24th International Conference on Computer Supported Cooperative Work in Design (CSCWD), 2021, pp. 873-876, doi: 10.1109/CSCWD49262.2021.9437846.

[4] J. Zheng, X. Sun, H. Zhou, C. Tian, and H. Qiang, “Printed circuit boards defect detection method based on improved fully convolutional networks”, IEEE Access, vol. 10, pp. 109908-109918, 2022, doi: 10.1109/ACCESS.2022.3214306.

[5] Y. D. Austria and A. C. Fajardo, “Defect detection in printed circuit boards using convolutional neural networks”, in 2023 2nd International Conference on Edge Computing and Applications (ICECAA), 2023, pp. 1498-1504, doi: 10.1109/ICECAA58104.2023.10212195.

[6] V. Mankad, N. Bhanvadia, M. I. Patel, and R. Gajjar, “PCB classification using convolutional neural network”, in 2021 3rd International Conference on Advances in Computing, Communication Control and Networking (ICAC3N), 2021, pp. 986-990, doi: 10.1109/ICAC3N53548.2021.9725695.

[7] J. Yu, L. Zhao, Y. Wang, and Y. Ge, “Defect detection of printed circuit board based on adaptive key-points localization network”, Comput. Ind. Eng., vol. 193, p. 110258, 2024.

[8] G. J. Brindha, S. Athiban, J. Gurumoorthi, and P. Sanjaykrishna, “Printed circuit board defect detection using machine learning”, J. Electron Int. Res. J. Educ. Technol., pp. 76-82, 2023, doi: 10.1234/abcd.efghi.

[9] A. Bhattacharya and S. G. Cloutier, “End-to-end deep learning framework for printed circuit board manufacturing defect classification”, Sci. Rep., vol. 12, p. 12559, 2022, doi: 10.1038/s41598-022-16302-3.

[10] V. A. Adibhatla, H. C. Chih, C. C. Hsu, J. Cheng, M. F. Abbod, and J. S. Shieh, “Defect detection in printed circuit boards using you-only-look-once convolutional neural networks”, Electronics, vol. 9, no. 9, p. 1547, 2020, doi: 10.3390/electronics9091547.

[11] J. Shen, N. Liu, and H. Sun, “Defect detection of printed circuit board based on lightweight deep convolution network”, IET Image Process., vol. 14, pp. 3932-3940, 2020.

[12] M. A. Alghassab, “Defect detection in printed circuit boards with pre-trained feature extraction methodology with convolution neural networks”, Comput. Mater. Contin., vol. 70, no. 1, pp. 637-652, 2022, doi: 10.32604/cmc.2022.019527.

[13] Q. Yang and F. Yu, “Deep learning-based defect detection research on printed circuit boards”, Int. J. Adv. Netw. Monit. Control., vol. 9, no. 2, pp. 51-58, 2024, doi: 10.2478/ijanmc-2024-0015.

[14] V. T. Nguyen and H. A. Bui, “A real-time defect detection in printed circuit boards applying deep learning”, EUREKA: Phys. Eng., no. 2, pp. 143-153, 2022, doi: 10.21303/2461-4262.2022.002127.

[15] Kaggle, “PCB defects dataset”, [Online]. Available: https://www.kaggle.com/datasets/akhatova/pcb-defects.

[16] C. Wang, G. Huang, Z. Huang, and W. He, “Conditional TransGAN-based data augmentation for PCB electronic component inspection”, Comput. Intell. Neurosci., vol. 2023, p. 2024237, Jan. 2023, doi: 10.1155/2023/2024237.

[17] H. Kang and Y. Yang, “An enhanced detection method of PCB defect based on D-DenseNet (PCBDD-DDNet)”, Electronics, vol. 12, p. 4737, 2023, doi: 10.3390/electronics12234737.

[18] X. Yu and Y. He, “PCB defect detection based on GAN data generation with self-attentive mechanism”, in 2022 2nd International Conference on Frontiers of Electronics, Information and Computation Technologies (ICFEICT), Wuhan, China, 2022, pp. 55-60, doi: 10.1109/ICFEICT57213.2022.00018.

[19] B. Ghosh, M. K. Bhuyan, P. Sasmal, Y. Iwahori, and P. Gadde, “Defect classification of printed circuit boards based on transfer learning”, in Proc. 2018 IEEE Applied Signal Process. Conf. (ASPCON), Kolkata, India, 2018, pp. 245-248, doi: 10.1109/ASPCON.2018.8748670.

[20] X. Chen, Y. Wu, X. He, and W. Ming, “A comprehensive review of deep learning-based PCB defect detection”, IEEE Access, vol. 11, pp. 139017-139038, 2023, doi: 10.1109/ACCESS.2023.3339561.

[21] A. Legon, M. Deo, S. Albin, and M. Audette, “Detection and classification of PCB defects using deep learning methods”, in Proc. 2022 IEEE 31st Microelectron. Design Test Symp. (MDTS), Albany, NY, USA, 2022, pp. 1-6, doi: 10.1109/MDTS54894.2022.9826925.

[22] T. T. A. Pham, D. K. T. Thoi, H. Choi, and S. Park, “Defect detection in printed circuit boards using semi-supervised learning”, Sensors, vol. 23, no. 6, p. 3246, Mar. 2023, doi: 10.3390/s23063246.

[23] S. Szabó, I. J. Holb, V. É. Abriha-Molnár, G. Szatmári, S. K. Singh, and D. Abriha, “Classification Assessment Tool: A program to measure the uncertainty of classification models in terms of class-level metrics”, Applied Soft Computing, vol. 155, p. 111468, 2024, doi: 10.1016/j.asoc.2024.111468.

[24] M. Krzywicka and A. Wosiak, “Sensitivity of Standard Evaluation Metrics for Disease Classification and Progression Assessment Based on Whole-Body Imaging”, Procedia Computer Science, vol. 225, pp. 4314–4323, 2023, doi: 10.1016/j.procs.2023.10.428.

[25] Z. Dorrani, H. Farsi, and S. Mohamadzadeh, “Deep learning in vehicle detection using ResUNet-a architecture”, Jordan Journal of Electrical Engineering, vol. 8, no. 2, pp. 165–178, 2022.

[26] Z. Dorrani, H. Farsi, and S. Mohamadzadeh, “Shadow removal in vehicle detection using ResUNet-a”, Iranian Journal of Energy and Environment, vol. 14, no. 1, pp. 87–95, 2023.

[27] N. Aghayan Mashhady and A. Amirkhani, “Improving the Accuracy of Road Damage Detectors Using Traditional Augmentations and Object Bounding Box Augmentation”, Journal of Iranian Association of Electrical and Electronics Engineers, vol. 21, no. 3, pp. 139–154, 2024.

[28] N. Aghaei, G. Akbarizadeh, and A. Kosarian, “Using ShuffleNet to design a deep semantic segmentation model for oil spill detection in synthetic aperture radar images”, Journal of Iranian Association of Electrical and Electronics Engineers, vol. 19, no. 3, pp. 131–144, 2022.

زیرنویس‌ها

[1] Printed Circuit Board
[2] Visual Geometry Group 16
[3] Residual Network 18 (ResNet18)
[4] Residual Network 50 (ResNet50)
[5] Residual Network 101 (ResNet101)
[6] You Only Look Once (YOLO)
[7] Single Shot Multibox Detector
[8] Feature Pyramid Network
[9] Continuous Atrous Convolution Module
[10] Visual Geometry Group 16
[11] Convolutional Neural Network
[12] Residual Pyramid Heat Mapping Network
[13] Thermodynamic Mechanism
[14] Jump-Related Convolutional Autoencoder
[15] Lightweight PCB Type Detection Model
[16] Single Shot Multibox Detector
[17] Feature Pyramid Network
[18] Recurrent convolutional neural network
[19] Adaptive Key Point Localization Network
[20] Faster Region-Based Convolutional Neural Network
[21] Automatic Inspection Machine
[22] Wrong Insertion
[23] Missing Insertion
[24] Character Recognition
[25] Lightweight Deep Convolution Network
[26] Spurious Copper
[27] Open Circuit
[28] Missing Hole
[29] Short
[30] Data Augmentation
[31] Overfitting
[32] Transfer Learning
[33] Residual Layers
[34] Stochastic Gradient Descent
[35] Accuracy
[36] Specificity
[37] Positive Predictive Rate
[38] Sensitivity
[39] Recall
[40] True Positive
[41] True Negative
[42] False Positive
[43] False Negative
[44] K-Fold evaluation