

Detecção Automática de Defeitos de Superfície e Componentes em Placas de Circuito Impresso Usando Modelos de Aprendizado Profundo

Sílvia S. da Cruz, Samuel B. Mafra, Eduardo H. Teixeira .

Resumo— Este artigo propõe uma abordagem para verificação automática de defeitos em placas de circuito impresso (PCBs) usando os modelos de visão computacional Faster R-CNN, SSD, YOLOv5 e YOLOv8. Os modelos foram avaliados com base nas métricas Acurácia, Precisão, Recall e F1-Score. Os resultados mostram que o Faster R-CNN alcançou 91,94% de precisão, o SSD 93,35%, o YOLOv5 97,20% e o YOLOv8 97,90%. Dentre eles, o YOLOv8 se comportou sutilmente melhor na detecção de defeitos em PCBs, oferecendo uma solução robusta para a indústria eletrônica.

Palavras-Chave— PCBs Defeitos, YOLOv8, Detecção

Abstract— This paper proposes an approach for automatic defect verification in printed circuit boards (PCBs) using the Faster R-CNN, SSD, YOLOv5, and YOLOv8 computer vision models. The models were evaluated based on Accuracy, Precision, Recall, and F1-Score metrics. The results show that Faster R-CNN achieved 91.94% precision, SSD 93.35%, YOLOv5 97.20%, and YOLOv8 97.90%. Among them, YOLOv8 performed slightly better in defect detection in PCBs, offering a robust solution for the electronics industry.

Keywords— PCBs Defects, YOLOv8, Detection

I. INTRODUÇÃO

A Indústria 4.0 em conjunto com a Internet das Coisas (IoT) tem propiciado a criação das fábricas inteligentes através da conexão de máquinas, sistemas e produtos por meio de sensores e troca de dados. Esses ambientes inteligentes permitem um melhor monitoramento, análise e otimização em tempo real dos processos de produção. Como resultado é possível obter uma maior eficiência e controle de qualidade, além da possibilidade de fazer manutenção preditiva assim que os primeiros erros ou anomalias são identificados. Neste sentido, é possível obter um ambiente de manufatura mais confiável e responsivo [1], [2].

A indústria eletrônica contemporânea depende fortemente da precisão e confiabilidade das placas de circuito impresso (PCB) em seus produtos [3]. A qualidade dessas PCBs desempenha um papel crucial no adequado funcionamento dos dispositivos eletrônicos, sendo diretamente influenciada por cada

etapa do processo de produção. Com o constante avanço do design de PCB em direção a estruturas multicamadas, pastilhas e densificação, torna-se imperativo adotar métodos eficazes de detecção de defeitos na produção. Problemas em qualquer etapa do processo, desde o corte até a medição elétrica, podem resultar em falhas nos produtos finais, acarretando custos elevados. A detecção de defeitos em PCBs surge como uma solução eficaz, principalmente por meio de métodos de teste não destrutivos e sem contato [4].

Inicialmente, a realização de testes elétricos básicos, incluindo a detecção de defeitos, era fortemente dependente da inspeção manual, desempenhada por um número reduzido de trabalhadores altamente especializados. Essa prática demandava investimentos consideráveis das fábricas, quer fosse na contratação ou no treinamento desses profissionais. No entanto, mesmo os inspetores mais experientes eram suscetíveis a cometer erros durante o processo de inspeção. Com a diminuição no tamanho dos componentes e juntas de solda, e o aumento dos potenciais defeitos, a inspeção manual convencional tem se tornado cada vez mais obsoleta, incapaz de lidar eficazmente com as crescentes exigências da indústria eletrônica moderna [5].

Para resolver esses problemas, propôs-se o uso de técnicas de processamento de imagens, visando a redução da ocorrência de defeitos de fabricação. Alguns algoritmos foram desenvolvidos para detectar regiões defeituosas por meio de subtração de fundo, comparando imagens de placas sem defeitos com imagens de teste. Com a evolução da capacidade computacional dos dispositivos e o aprimoramento dos modelos de aprendizado de máquina, estudos recentes exploram o potencial de redes convolucionais profundas para aprimorar a precisão e eficiência desses sistemas. A detecção eficiente de defeitos em PCBs é crucial para garantir a qualidade e durabilidade desses dispositivos [4].

Neste artigo, apresentamos uma abordagem avançada para a verificação automática de defeitos em PCBs, comparando os modelos de visão computacional Faster R-CNN, SSD, YOLOv5, já utilizados em outros trabalhos, com o modelo YOLOv8. A automação desse processo não apenas acelera a inspeção, mas também contribui para a melhoria contínua da qualidade dos produtos eletrônicos. Dado que a literatura indica que a detecção de defeitos em PCBs pode ser dividida em duas categorias principais, detecção em placas nuas e detecção em PCBs com componentes já soldados [5].

Neste trabalho, foram treinados os quatro modelos para placas nuas e o melhor dos modelos treinados em um segundo

Sílvia S. da Cruz, Samuel B. Mafra, Eduardo H. Teixeira, Instituto Nacional de Telecomunicações (Inatel), Santa Rita do Sapucaí-MG; Este trabalho é parcialmente financiado pela RNP, com recursos do MCTIC, Grant No. 01245.020548/2021-07, no âmbito do projeto Brasil 6G do Centro de Referência em Radiocomunicações (CRR) do Instituto Nacional de Telecomunicações (Inatel), Brasil, o Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) (403827/2021-3), Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) (2021/06946-0), e pela Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) via Grant No. APQ-03162-24, RED-00194-23 and PPE-00124-23, Ciência por Elas project (APQ-04523-23)

dataset, composto de placas com componentes soldados a ela. Com isso, o objetivo do trabalho é explorar as capacidades de diferentes modelos, comparando sua eficiência na detecção de defeitos em diferentes contextos de PCBs. A automação desse processo não apenas acelera a inspeção, mas também contribui para a melhoria contínua da qualidade dos produtos eletrônicos.

Este artigo está organizado da seguinte forma: a Seção II revisa a literatura sobre modelos de aprendizado profundo e trabalhos relacionados; a Seção III descreve em detalhes a metodologia do sistema proposto; a Seção IV apresenta os resultados da validação experimental; e a Seção V conclui o artigo e sugere futuras direções de pesquisa.

II. FUNDAMENTAÇÃO TEÓRICA

A inspeção manual tradicional de PCBs é um processo demorado e propenso a erros humanos. Diante desse desafio, os métodos de visão computacional surgem como uma resposta crucial para automatizar a detecção de defeitos [6].

A. Modelos de Aprendizagem Profunda

A complexidade das PCBs modernas, onde os defeitos podem ser sutis e variados, apresenta um cenário desafiador para as abordagens convencionais. Nesse contexto, modelos de detecção como *region-based convolutional neural networks* (R-CNN), *single shot detector* (SSD) e *you only look once* (YOLO) têm desempenhado um papel fundamental na evolução desses métodos em relação aos tradicionais [7].

Os modelos baseados em regiões, como o Faster R-CNN, destacam-se pela capacidade de dividir a imagem em regiões e, posteriormente, classificar e localizar objetos dentro dessas regiões. Essa abordagem se revela eficaz para a detecção de defeitos em PCBs, permitindo uma análise mais detalhada de áreas específicas da placa. Contudo, a necessidade de processamento em várias etapas pode resultar em tempos computacionais mais longos [8].

Por outro lado, o SSD adota uma abordagem de detecção de objetos em uma única passagem pela rede neural. Isso permite uma execução mais eficiente ao realizar previsões simultâneas em diferentes escalas. A rapidez na detecção de defeitos em PCBs torna o SSD uma escolha vantajosa, especialmente onde a diversidade de tamanhos e formas dos defeitos demanda uma abordagem adaptável e eficiente [9].

O YOLO também adota uma abordagem de detecção em uma única passagem pela rede neural. No entanto, o YOLO se diferencia por sua arquitetura que divide a imagem em uma grade e, para cada célula, faz previsões de *bounding boxes* e probabilidades de classes simultaneamente. Isso resulta em tempos de inferência mais rápidos, tornando-o uma escolha valiosa para a detecção de defeitos em tempo real em ambientes industriais. Sua eficiência e rapidez são ideais para uso na inspeção de PCBs, onde a agilidade na detecção de defeitos é crucial para otimizar os processos de produção [9].

B. Trabalhos Relacionados

No panorama da detecção de defeitos em placas de circuito impresso, investigamos três estudos que adotam abordagens

distintas, cada uma utilizando arquiteturas consolidadas na detecção de objetos: R-CNN [10], SSD [11] e YOLO [12].

O primeiro estudo aborda a detecção de defeitos em PCBs por meio da aplicação do algoritmo Faster R-CNN [10]. Reconhecendo a vital importância da qualidade das PCBs para o desempenho eficaz de produtos eletrônicos, o documento destaca a escolha do Faster R-CNN devido à sua notável precisão. Para ampliar a eficiência do processo, o estudo propõe otimizações, integrando métodos como YOLOv3, YOLOv4 e técnicas de clusterização baseadas nessas arquiteturas [10].

O segundo estudo se aprofunda na aplicação de técnicas avançadas de visão computacional, especificamente utilizando o algoritmo SSD, para lidar com os desafios exclusivos da detecção de defeitos em PCBs [11]. Nesse estudo é introduzido um módulo de fusão de características e um mecanismo de atenção, visando superar as limitações do SSD na detecção de objetos pequenos devido à falta de informação semântica em características de baixo nível.

O terceiro estudo propõe uma abordagem baseada no YOLOv5, introduzindo módulos de detecção em várias escalas, mecanismos de atenção e ramos múltiplos para otimizar a detecção em diferentes contextos, incorporando uma camada de detecção rasa para alvos menores. Os autores desse trabalho utilizaram um conjunto de 552 imagens para treinamento, o mesmo utilizado no primeiro dataset nesse trabalho [12].

III. METODOLOGIA

Com base nos resultados promissores apontados no trabalho [12] e em outros estudos relevantes da literatura, como [13] e [14], que exploram modelos de detecção de objetos, optou-se por escolher as arquiteturas Faster R-CNN, SSD e YOLO para a condução dos experimentos. A partir dessa fundamentação, a metodologia adotada consistiu na exploração dos modelos sob condições semelhantes, visando analisar as métricas de desempenho obtidas por esses modelos de aprendizado profundo. A escolha do Faster R-CNN foi motivada por sua capacidade de análise detalhada de regiões específicas. O SSD foi escolhido por sua eficiência em detecção de objetos em uma única passagem. Os modelos YOLOv5 e YOLOv8 foram selecionados por serem também detectores de estágio único, bem como pelo seu amplo uso na literatura e por suas melhorias recentes [15].

A metodologia para a verificação automática de defeitos em PCBs utilizando esses modelos pode ser encontrada em outros trabalhos, como exemplificado por [12] e [14]. Neste contexto, os autores empregaram diferentes modelos para a detecção de diversos tipos de defeitos, tais como *Ausência de furo*, *Mordida*, *Circuito aberto*, *Curto circuito*, *Ramificação* e *Cobre indesejado*, uma vez que dentro de um mesmo cenário em que se deseja aplicar a visão computacional, geralmente podemos encontrar diferentes classes de objetos, ou de defeitos nesse caso [16]. A Figura 1 exemplifica um desses tipos de defeito, onde existe a falta do ponto de solda na placa.

Quanto ao treinamento dos modelos, as imagens das PCBs foram obtidas a partir de duas fontes distintas. Para a comparação entre o desempenho dos modelos no cenário de defeitos de superfície das placas, o *dataset* utilizado corresponde ao




Fig. 1. Imagem de treinamento do primeiro banco de dados [14].

mesmo conjunto apresentado em [14], com 552 fotos para treinamento e 138 para validação. Já no segundo *dataset*, focado em falhas relacionadas aos componentes, as imagens foram coletadas em uma empresa especializada na produção de placas de circuito impresso. Os autores realizaram uma cuidadosa rotulagem manual dessas imagens, conduzindo também técnicas de aumento de dados para expandir o *dataset* de treinamento, originalmente composto por 60 imagens sendo que após a sua expansão obteve-se um banco de 180 imagens. Um exemplo dessas imagens está representado pela Figura 2, onde as detecções em roxo representam a falta de capacitores, enquanto as demarcações em vermelho a falta de circuitos integrados.




Fig. 2. Imagem de treinamento do segundo banco de dados (Empresa Fênix).

Adicionalmente, o *dataset* foi dividido em conjuntos de treinamento e validação, com 80% destinados ao treinamento e 20% reservados para a validação dos modelos, proporcionando

uma Abordagem sólida e confiável para o treinamento efetivo dos modelos. As imagens foram submetidas aos modelos treinados para a detecção automática de defeitos.

Essa estratégia incorpora um plano sólido para aprimorar a precisão na detecção e classificação de defeitos em PCBs, considerando que os componentes devem estar previamente soldados na placa, cujo objetivo desse segundo sistema é encontrar os componentes faltantes. Para a criação desse segundo *dataset*, as classes de falhas escolhidas foram *Circuito integrado faltando*, *Capacitor faltando* e *Resistência faltando*, classes essas que representam os principais defeitos encontrados por essa empresa durante o processo de montagem dessas placas.

O objetivo é que o melhor modelo encontrado possa ser utilizado para compor uma estrutura de detecção real completa, tal como mostra a Figura 3, onde uma câmera é responsável por coletar as imagens das placas de circuito impresso em análise, enquanto um dispositivo computacional, como uma raspberry pi pode ser utilizado para o processamento das imagens e conseqüentemente para envio dos defeitos encontrados, como em um cenário de Internet das Coisas [17], [18].




Fig. 3. Concepção artística do instrumento proposto.

IV. AVALIAÇÃO E RESULTADOS

Para avaliar a eficácia da abordagem proposta, foram realizados experimentos usando dois conjuntos de imagens de PCBs. Para o primeiro teste, todos os modelos de aprendizagem profunda foram treinados por 2000 épocas, com tamanho do lote igual a 16 e tamanho de imagem de 640x640. Os resultados mostraram uma pequena diferença de desempenho entre os modelos, com o YOLOv8 apresentando um desempenho ligeiramente superior em relação aos demais, conforme mostrado na Tabela I. O desenvolvimento do modelo YOLOv8 ao longo do treinamento pode ser visualizado na Figura 4, onde é possível observar o decaimento das perdas em relação às imagens de treinamento, seguido pelo decaimento das perdas nas imagens de validação. As subfiguras com o termo *metrics* referem-se à evolução do desempenho do sistema ao longo do treinamento.

Para o segundo *dataset*, foi escolhido apenas a versão YOLOv8, pelo fato de ter tido maior destaque em relação aos demais modelos. O treinamento com a segunda base de dados pode ser visualizado por meio da Figura 5. Nesse caso, o modelo YOLOv8 atingiu 100% em todas as métricas, pois não obteve nenhum erro de classificação entre os componente que estavam faltando nas placas apresentadas.

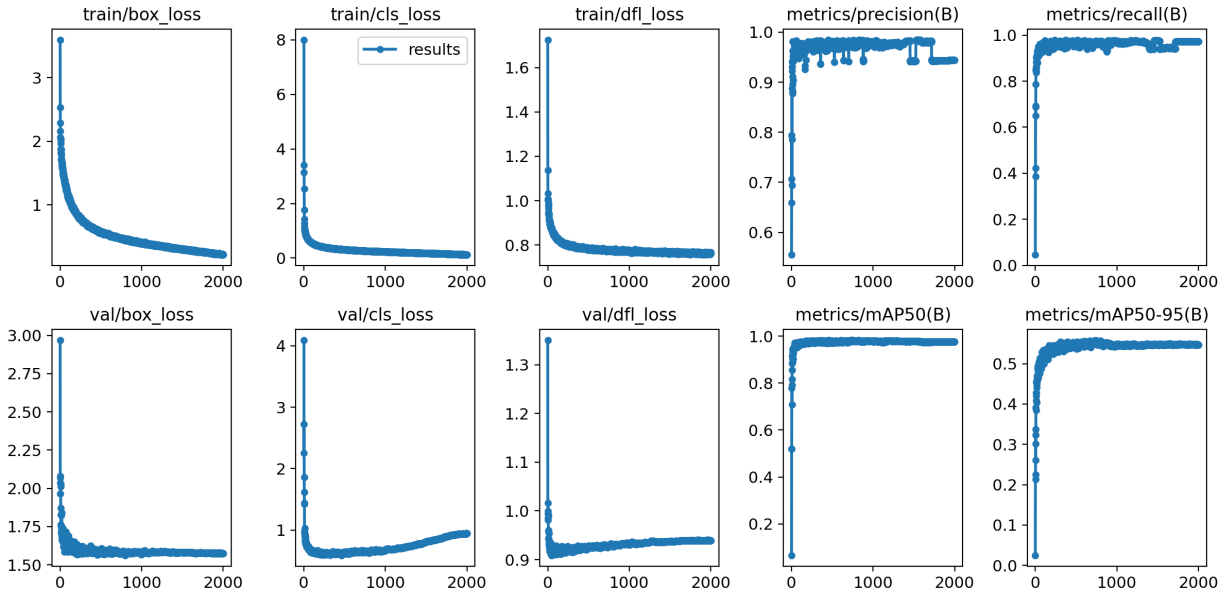


Fig. 4. Imagem de treinamento YOLOv8 (Dataset 1).

TABELA I
COMPARAÇÃO DE PERFORMACE DE DIFERENTES MODELOS DE
DETECÇÃO DE PCBs.

Modelos	Acurácia	Precisão	Recall	F1-Score
Yolov8	97,90%	98,95%	98,97%	98,95%
Yolov5	97,20%	98,62%	98,63%	98,63%
FasterRCNN	93,35%	96,68%	96,75%	96,7%
SSD	91,94%	95,98%	96,06%	96,01%

Como o *dataset* empregado para essa segunda análise era um pouco mais limitado em número e diversidade, é possível que a expansão desse *dataset* leve a um resultado mais próximo do encontrado para o *dataset* onde ocorreram alguns erros. Além disso, como as métricas são embasadas na etapa de classificação, erros podem ter acontecido na etapa da localização dos componentes faltantes, o que pode ser observado na validação em relação perdas por detecção de caixa delimitadora que não são zeradas completamente, como mostra a Figura 5.

V. DISCUSSÕES E CONCLUSÃO

A abordagem apresentada neste artigo demonstra o potencial dos modelos de aprendizado profundo na detecção automática de defeitos em PCBs. Os resultados indicam que o modelo YOLOv8 supera sutilmente os modelos YOLOv5, Faster R-CNN e SSD nas métricas de desempenho avaliadas. No entanto, ainda existem desafios a serem superados, como a necessidade de um conjunto de dados mais diversificado e otimizações contínuas do modelo.

Apesar dos resultados promissores, a pesquisa identificou alguns desafios como a capacidade do modelo de se adaptar e fornecer resultados precisos para diferentes tipos de dados e cenários. Durante os testes, o modelo demonstrou excelente desempenho com o *dataset* 2, mas há uma necessidade clara de validação com amostras mais variadas e numerosas para

garantir que o modelo possa generalizar eficientemente para novos dados. Com o aumento do número de amostras apresentadas, o sistema poderia cometer mais erros, assim como aconteceu no *dataset* 1 já utilizado nos outros trabalhos da literatura, alvo dos testes com todos os modelos.

A adoção bem-sucedida da verificação automática de defeitos em PCBs usando YOLOv8 pode ter um impacto significativo na indústria eletrônica. A automação desse processo reduz a necessidade de inspeção manual intensiva, resultando em uma produção mais eficiente e de maior qualidade. Além disso, a detecção precoce de defeitos contribui para a redução de custos associados a reparos pós-produção, aumentando assim a satisfação do cliente e a confiança na marca [19].

A implementação de técnicas adicionais de pré e pós-processamento e a exploração de novos contextos de aplicação, como a detecção em tempo real, são passos essenciais para consolidar essa tecnologia na indústria [18], [20]. Além disso, um protótipo como o da Figura 3 pode ser desenvolvido, comparando-se diferentes arquiteturas de processamento para o levantamento do tempo de inferência.

A principal contribuição desse trabalho reside na comparação entre vários modelos de detecção e na criação de uma nova base de dados com imagens de PCBs não nuas, visto que o número de trabalhos que consigam encontrar componentes faltantes ainda carece de maior pesquisa. Com isso, este estudo estabelece uma base sólida para futuras investigações e aplicações práticas no campo da inspeção automatizada de PCBs.

Futuros trabalhos devem considerar a integração de uma esteira automatizada com sensores para verificação e separação automática das placas com defeito. Esse sistema permitiria um fluxo contínuo de inspeção em tempo real, onde placas defeituosas seriam automaticamente separadas no final de linha de produção, aumentando a eficiência e reduzindo a necessidade de intervenção manual.

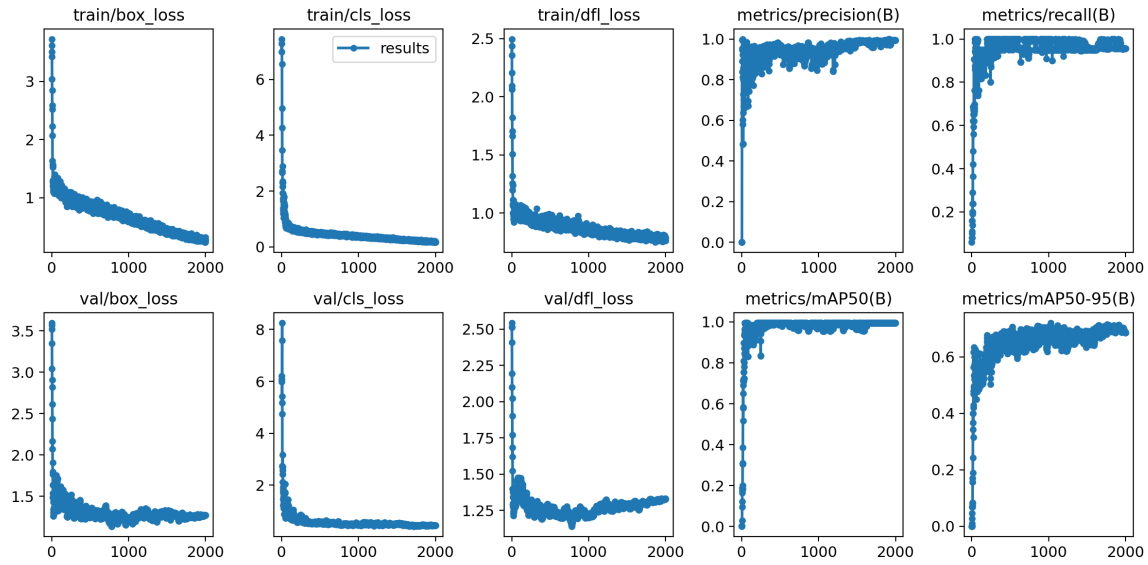


Fig. 5. Imagem de treinamento do YOLOv8 (Dataset 2).

Além disso, seria possível explorar outros modelos de detecção e a combinação de diferentes arquiteturas para melhorar a precisão. A utilização de técnicas de *ensemble* pode reduzir a probabilidade de falsos negativos, assegurando que placas com defeitos não cheguem ao cliente. Isso aumentaria a robustez e confiabilidade do sistema de inspeção, oferecendo uma camada extra de segurança ao processo de produção.

VI. AGRADECIMENTOS

Gostaríamos de agradecer a empresa do grupo Foxconn, Fênix Indústria Eletrônicos, pela disponibilização das placas eletrônica, imagens e demais contribuições nesse trabalho.

REFERÊNCIAS

- [1] I. H. Khan and M. Javaid, "Role of internet of things (iot) in adoption of industry 4.0," *Journal of Industrial Integration and Management*, vol. 7, no. 04, pp. 515–533, 2022.
- [2] M. Soori, B. Arezoo, and R. Dastres, "Internet of things for smart factories in industry 4.0, a review," *Internet of Things and Cyber-Physical Systems*, 2023.
- [3] J. A. B. Susa, E. Mariquina, M. L. Tria, C. M. Adolfo, and J. C. Castro, "Cap-eye-citor: A machine vision inference approach of capacitor detection for pcb automatic optical inspection," in *2020 IEEE 7th International Conference on Engineering Technologies and Applied Sciences (ICETAS)*, 2020, pp. 1–5.
- [4] W. Chen, Z. Huang, Q. Mu, and Y. Sun, "Pcb defect detection method based on transformer-yolo," *IEEE Access*, vol. 10, pp. 129 480–129 489, 2022.
- [5] 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. 15 921–15 944, 2023.
- [6] N. Aggarwal, M. Deshwal, and P. Samant, "A survey on automatic printed circuit board defect detection techniques," in *2022 2nd International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE)*, 2022, pp. 853–856.
- [7] E. Teixeira, B. Araujo, V. Costa, S. Mafra, and F. Figueiredo, "Literature review on ship localization, classification, and detection methods based on optical sensors and neural networks," *Sensors*, vol. 22, no. 18, 2022.
- [8] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C.-Y. Fu, and A. C. Berg, "Ssd: Single shot multibox detector," in *European Conference on Computer Vision (ECCV)*, 2016, pp. 21–37.
- [9] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You only look once: Unified, real-time object detection," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 779–788.
- [10] J. Niu, J. Huang, L. Cui, B. Zhang, and A. Zhu, "A pcb defect detection algorithm with improved faster r-cnn," 2022.
- [11] W. Shi, Z. Lu, W. Wu, and H. Liu, "Single-shot detector with enriched semantics for pcb tiny defect detection," *The Journal of Engineering*, 2020.
- [12] T. Yang, Y. Liu, C. Jin, K. Jiang, Q. Duan, C. Song, Q. Chen, X. Li, J. Ge, and R. Li, "Printed circuit board defect detection based on improved yolov5," in *2023 6th International Conference on Information and Computer Technologies (ICICT)*, 2023, pp. 72–77.
- [13] J. S. S. V. Mamidi, S. Sameer, and J. Bayana, "A light weight version of pcb defect detection system using yolo v4 tiny," in *2022 International Mobile and Embedded Technology Conference (MECON)*, 2022, pp. 441–445.
- [14] A. K. Lailesh, J. A. Richi, and N. Preethi, "A pre-trained yolo-v5 model and an image subtraction approach for printed circuit board defect detection," in *2023 International Conference on Intelligent and Innovative Technologies in Computing, Electrical and Electronics (IITCEE)*, 2023, pp. 140–145.
- [15] M. H. F. Afonso, E. H. Teixeira, M. R. Cruz., G. P. Aquino, and E. C. Vilas Boas, "Vehicle and plate detection for intelligent transport systems: Performance evaluation of models yolov5 and yolov8," in *2023 IEEE International Conference on Computing (ICOCO2023)*, 2023, pp. 328–333.
- [16] M. R. Cruz, F. A. P. de Figueiredo, S. Mafra, D. M. de Oliveira, and E. H. Teixeira, "Evaluating computer vision architectures for ship classification: A comparative study," in *XLI Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBrT2023)*, 2023.
- [17] J. G. A. Carvalho, A. A. Conceição, L. P. Ambrósio, F. F. Ramborger, E. H. Teixeira, G. P. Aquino, and E. C. V. Boas, "Smart lab: A non-invasive iot-centric approach for indoor environment automation," *Journal of Communication and Information Systems*, vol. 39, no. 1, pp. 82–96, May 2024.
- [18] E. H. Teixeira, S. B. Mafra, J. J. P. C. Rodrigues, W. A. A. N. da Silveira, and O. Diallo, "A review and construction of a real-time facial recognition system," in *Anais do Simpósio Brasileiro de Computação Ubíqua e Pervasiva (SBCUP)*, 2020, pp. 191–200.
- [19] A. Caliskan and G. Gurkan, "Design and realization of an automatic optical inspection system for pcb solder joints," in *2021 International Conference on INnovations in Intelligent SysTems and Applications (INISTA)*, 2021, pp. 1–6.
- [20] V. L. Costa, E. H. Teixeira, S. Mafra, and F. A. P. d. Figueiredo, "Pré-processamento de imagens de baixa resolução utilizando deep learning baseado em um autoencoder," in *Anais do XL Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBrT2022)*, 2022.