



## Implementasi Deep Learning Berbasis Citra Digital untuk Deteksi Kerusakan Komponen Elektronik

Radus Batau

Program Studi Teknik Informatika, Universitas Indonesia Timur  
Jl. Rappocini Raya No. 174, Makassar, Sulawesi Selatan-Indonesia  
radus.khinza@gmail.com\*<sup>1</sup>

### Kata Kunci :

Deep Learning;  
Citra Digital;  
MobileNetV2;  
Kerusakan;  
Komponen  
Elektronik.

### ABSTRAK

Kerusakan komponen elektronik seperti retak, terbakar, dan korosi dapat menurunkan kinerja perangkat serta meningkatkan risiko kegagalan sistem. Proses identifikasi kerusakan secara manual masih bergantung pada ketelitian teknisi sehingga membutuhkan waktu lama dan rentan terhadap subjektivitas. Penelitian ini bertujuan mengimplementasikan model deep learning berbasis citra digital untuk mendeteksi kondisi komponen elektronik secara otomatis. Metode penelitian menggunakan pendekatan eksperimen komputasional melalui tahapan pengumpulan citra, anotasi kelas, pra-pemrosesan, augmentasi data, pelatihan model, evaluasi, dan implementasi prototipe. Dataset yang digunakan terdiri atas 1.200 citra komponen elektronik dengan empat kelas, yaitu normal, terbakar, retak, dan korosi. Model MobileNetV2 berbasis transfer learning digunakan sebagai arsitektur utama dengan ukuran input 224x224 piksel. Hasil pengujian menunjukkan model memperoleh akurasi 95,56%, precision 95,71%, recall 95,56%, dan F1-score 95,58%. Pengujian blackbox pada prototipe menunjukkan seluruh fungsi utama berjalan valid. Hasil ini menunjukkan bahwa deep learning berbasis citra digital dapat digunakan sebagai solusi awal untuk membantu deteksi kerusakan komponen elektronik secara cepat, konsisten, dan objektif.

### Keywords

Deep Learning;  
Digital Image;  
MobileNetV2;  
Damage;  
Electronic  
Components.

### ABSTRACT

Damage to electronic components such as cracks, burns, and corrosion can reduce device performance and increase the risk of system failure. Manual damage identification still depends on technician accuracy, which makes the process time-consuming and prone to subjectivity. This study aims to implement a digital image-based deep learning model to automatically detect the condition of electronic components. The research applies a computational experimental approach through image acquisition, class annotation, preprocessing, data augmentation, model training, evaluation, and prototype implementation. The dataset consists of 1,200 images of electronic components grouped into four classes: normal, burned, cracked, and corroded. A transfer learning-based MobileNetV2 model with an input size of 224x224 pixels was used as the main architecture. The experimental results show that the model achieved 95.56% accuracy, 95.71% precision, 95.56% recall, and 95.58% F1-score. Blackbox testing of the prototype indicated that all major functions operated properly. These results indicate that digital image-based deep learning can be used as an initial solution to support fast, consistent, and objective detection of electronic component damage.

---Jurnal JISTI @2026---

## PENDAHULUAN

Perkembangan industri elektronik dan layanan perbaikan perangkat digital menuntut proses inspeksi komponen yang lebih cepat, akurat, dan konsisten. Kerusakan fisik pada komponen elektronik seperti resistor, kapasitor, integrated circuit, transistor, konektor, serta papan rangkaian tercetak dapat



muncul dalam bentuk bekas terbakar, retakan mikro, korosi pada pin, perubahan warna, dan kerusakan permukaan. Pada praktik konvensional, identifikasi kerusakan masih banyak dilakukan secara visual oleh teknisi. Cara ini mudah diterapkan, tetapi kualitas hasilnya sangat bergantung pada pengalaman, pencahayaan, dan ketelitian pemeriksa.

Citra digital memberikan peluang untuk merepresentasikan kondisi visual komponen elektronik secara terukur. Melalui kamera digital atau mikroskop digital, karakteristik kerusakan dapat direkam dalam bentuk pola warna, tekstur, bentuk, dan tepi objek. Pada tahap awal, teknik pengolahan citra klasik seperti segmentasi warna, deteksi tepi, thresholding, dan ekstraksi fitur tekstur sering digunakan untuk mengenali perubahan permukaan. Namun, teknik tersebut kurang adaptif ketika citra memiliki variasi pencahayaan, sudut pengambilan gambar, kompleksitas latar belakang, dan ukuran cacat yang sangat kecil (Chen et al., 2021; Saberironaghi et al., 2023).

Deep learning, khususnya Convolutional Neural Network (CNN), menjadi pendekatan yang banyak digunakan dalam inspeksi visual karena mampu mengekstraksi fitur citra secara otomatis dari data pelatihan. Pada konteks inspeksi papan rangkaian tercetak, beberapa penelitian menunjukkan bahwa model deep learning mampu meningkatkan kemampuan deteksi cacat dibandingkan inspeksi manual maupun metode berbasis fitur konvensional. Bhattacharya dan Cloutier (2022) mengembangkan kerangka deep learning end-to-end untuk klasifikasi cacat manufaktur PCB, sedangkan Ling dan Isa (2023) menegaskan bahwa integrasi image processing, machine learning, dan deep learning semakin penting dalam inspeksi otomatis PCB.


Penelitian terbaru juga menunjukkan kecenderungan penggunaan model ringan dan transfer learning untuk kebutuhan inspeksi yang memerlukan kecepatan serta efisiensi komputasi. Park et al. (2023) menganalisis strategi pelatihan model deep learning untuk deteksi cacat PCB, sementara Kang dan Yang (2023), Xiao et al. (2024), serta Bai dan Xu (2025) mengusulkan variasi model deep learning untuk meningkatkan kemampuan deteksi cacat berukuran kecil. Di sisi lain, Ma et al. (2024) dan Ameri et al. (2024) menyatakan bahwa deteksi cacat industri masih menghadapi tantangan berupa variasi visual, ketidakseimbangan data, ukuran cacat kecil, dan kebutuhan generalisasi pada lingkungan nyata.

Dalam konteks penelitian nasional, penerapan machine learning pada masalah klasifikasi dan prediksi juga semakin berkembang. Penelitian Hermin dan Ismail (2026) memperlihatkan bahwa model machine learning dapat memberikan prediksi yang kuat ketika didukung seleksi fitur dan evaluasi yang sistematis. Wardana dan Ismail (2026) juga menekankan pentingnya model explainable machine learning untuk menghasilkan prediksi yang dapat dipahami pengguna. Hal ini relevan dengan pengembangan sistem deteksi kerusakan komponen elektronik karena hasil model tidak cukup hanya akurat, tetapi juga perlu disajikan dalam bentuk informasi yang mudah dipahami oleh teknisi.

Berdasarkan permasalahan tersebut, penelitian ini mengusulkan implementasi deep learning berbasis citra digital untuk mendeteksi kerusakan komponen elektronik. Kebaruan praktis penelitian ini terletak pada penyusunan alur eksperimen sederhana yang memadukan pra-pemrosesan citra, augmentasi data, transfer learning MobileNetV2, evaluasi performa berbasis metrik klasifikasi, serta implementasi prototipe sistem deteksi. Penelitian ini diharapkan dapat menjadi rujukan awal bagi pengembangan sistem inspeksi komponen elektronik yang lebih cepat, objektif, dan mudah diintegrasikan pada proses praktikum teknik digital maupun layanan perbaikan perangkat elektronik.

## METODE PENELITIAN

Penelitian ini menggunakan pendekatan eksperimen komputasional dengan tahapan pengembangan model deep learning berbasis citra digital. Proses penelitian disusun secara sistematis mulai dari identifikasi masalah hingga penarikan kesimpulan. Alur penelitian ditampilkan pada Gambar 1:



Gambar 1. Tahapan Penelitian

1) Identifikasi Masalah

Tahap ini dilakukan untuk mengidentifikasi kebutuhan deteksi kerusakan komponen elektronik berbasis citra digital. Permasalahan utama yang menjadi fokus adalah masih terbatasnya sistem otomatis yang dapat membedakan kondisi komponen normal, terbakar, retak, dan korosi secara konsisten.

2) Studi Literatur

Studi literatur dilakukan terhadap penelitian yang membahas deep learning, CNN, transfer learning, pengolahan citra digital, dan deteksi cacat pada produk industri maupun PCB. Literatur digunakan untuk menentukan model, skema evaluasi, serta jenis pra-pemrosesan yang sesuai.

3) Pengumpulan dan Anotasi Data


Data penelitian berupa citra komponen elektronik dikumpulkan menggunakan kamera digital dengan variasi sudut, pencahayaan, dan jarak pengambilan gambar. Citra kemudian diberi label ke dalam empat kelas, yaitu normal, terbakar, retak, dan korosi. Anotasi kelas dilakukan secara manual berdasarkan karakteristik visual kerusakan.

4) Pra-pemrosesan dan Augmentasi Citra

Pra-pemrosesan dilakukan melalui resize citra menjadi 224x224 piksel, normalisasi nilai piksel ke rentang 0-1, serta penyesuaian kontras untuk mengurangi pengaruh variasi pencahayaan. Augmentasi data dilakukan menggunakan rotasi, flipping, zoom, dan brightness adjustment agar model lebih adaptif terhadap variasi citra.

5) Pengembangan Model Deep Learning

Model utama yang digunakan adalah MobileNetV2 berbasis transfer learning karena arsitektur ini relatif ringan dan sesuai untuk klasifikasi citra. Lapisan dasar MobileNetV2 digunakan sebagai ekstraktor fitur, sedangkan lapisan klasifikasi ditambahkan berupa global average pooling, dense layer, dropout, dan softmax empat kelas. Arsitektur model ditampilkan pada Gambar 2.



Gambar 2. Arsitektur Model MobileNetV2 untuk Deteksi Kerusakan Komponen Elektronik

6) Pelatihan Model

Dataset dibagi menjadi data latih, validasi, dan uji dengan komposisi 70:15:15. Pelatihan dilakukan selama 20 epoch menggunakan optimizer Adam, batch size 32, learning rate 0,0001, dan



categorical cross-entropy sebagai fungsi loss. Strategi early stopping digunakan untuk mengurangi risiko overfitting.

7) Evaluasi Model

Evaluasi dilakukan menggunakan akurasi, precision, recall, F1-score, confusion matrix, dan waktu inferensi. Metrik tersebut digunakan untuk melihat kemampuan model dalam membedakan setiap jenis kerusakan serta efisiensi prediksi pada citra baru.


8) Implementasi Prototipe dan Pengujian Sistem

Model yang telah dilatih diintegrasikan ke dalam prototipe aplikasi deteksi berbasis web. Pengujian sistem dilakukan menggunakan blackbox testing untuk memastikan fungsi unggah citra, pra-pemrosesan, prediksi, penyimpanan riwayat, dan laporan hasil berjalan sesuai kebutuhan pengguna.

## HASIL DAN PEMBAHASAN

### 1. Deskripsi Dataset Citra Komponen Elektronik

Dataset penelitian terdiri atas 1.200 citra komponen elektronik yang dibagi ke dalam empat kelas. Kelas normal merepresentasikan komponen tanpa indikasi kerusakan fisik, sedangkan kelas terbakar menunjukkan bekas panas berlebih atau perubahan warna hitam kecokelatan. Kelas retak menunjukkan pecahan atau garis retakan pada permukaan komponen, dan kelas korosi menunjukkan oksidasi pada pin atau area logam. Contoh representasi visual kelas citra ditampilkan pada Gambar 3:



Gambar 3. Contoh Representasi Citra Komponen Elektronik

Tabel 1. Distribusi Dataset Penelitian

| No    | Kelas Citra | Jumlah Citra | Data Latih | Data Uji |
|-------|-------------|--------------|------------|----------|
| 1     | Normal      | 480          | 336        | 72       |
| 2     | Terbakar    | 240          | 168        | 36       |
| 3     | Retak       | 240          | 168        | 36       |
| 4     | Korosi      | 240          | 168        | 36       |
| Total |             | 1.200        | 840        | 180      |

### 2. Tahap Pra-pemrosesan Citra

Pra-pemrosesan dilakukan agar data citra memiliki ukuran, skala, dan kualitas input yang seragam. Tahap ini sangat penting karena citra komponen elektronik umumnya memiliki pantulan cahaya, bayangan, dan variasi sudut pengambilan gambar. Proses pra-pemrosesan yang digunakan pada penelitian ini ditampilkan pada Tabel 2.




Tabel 2. Tahapan Pra-pemrosesan Citra


| No | Tahapan     | Parameter                      | Tujuan                                |
|----|-------------|--------------------------------|---------------------------------------|
| 1  | Resize      | 224x224 piksel                 | Menyamakan dimensi input model        |
| 2  | Normalisasi | Nilai piksel 0-1               | Menstabilkan proses pelatihan         |
| 3  | Augmentasi  | Rotasi, zoom, flip, brightness | Menambah variasi data latih           |
| 4  | Split data  | 70:15:15                       | Membagi data latih, validasi, dan uji |

### 3. Pelatihan Model Deep Learning

Model MobileNetV2 dilatih menggunakan data citra yang telah diproses. Pada tahap awal, bobot pra-latih digunakan untuk mempercepat proses konvergensi. Lapisan klasifikasi akhir disesuaikan dengan empat kelas kerusakan. Grafik akurasi dan loss selama pelatihan ditampilkan pada Gambar 4 dan Gambar 5



Gambar 4. Grafik Akurasi Pelatihan dan Validasi



Gambar 5. Grafik Loss Pelatihan dan Validasi

### 4. Perbandingan Kinerja Model

Untuk melihat efektivitas arsitektur yang digunakan, penelitian ini membandingkan CNN sederhana, ResNet50, dan MobileNetV2. Hasil perbandingan menunjukkan bahwa MobileNetV2 memberikan keseimbangan terbaik antara akurasi dan waktu inferensi. Hasil perbandingan ditampilkan pada Tabel 3.



Tabel 3. Perbandingan Kinerja Model


| Model              | Accuracy      | Precision     | Recall        | F1-score      | Waktu Inferensi    |
|--------------------|---------------|---------------|---------------|---------------|--------------------|
| CNN Sederhana      | 88,89%        | 89,12%        | 88,89%        | 88,95%        | 52 ms/citra        |
| ResNet50           | 93,33%        | 93,61%        | 93,33%        | 93,40%        | 67 ms/citra        |
| <b>MobileNetV2</b> | <b>95,56%</b> | <b>95,71%</b> | <b>95,56%</b> | <b>95,58%</b> | <b>38 ms/citra</b> |

Sumber : Hasil Olahan data menggunakan python

Berdasarkan Tabel 3, MobileNetV2 memperoleh akurasi tertinggi sebesar 95,56% dengan waktu inferensi 38 ms per citra. Hasil ini menunjukkan bahwa transfer learning pada arsitektur ringan mampu menghasilkan performa yang kompetitif untuk kebutuhan klasifikasi kerusakan komponen elektronik. CNN sederhana memiliki performa lebih rendah karena ekstraksi fiturnya terbatas, sedangkan ResNet50 membutuhkan waktu inferensi lebih lama walaupun akurasinya cukup baik.

## 5. Confusion Matrix dan Analisis Kesalahan Klasifikasi

Confusion matrix digunakan untuk melihat sebaran prediksi benar dan salah pada setiap kelas. Hasil pengujian terhadap 180 citra data uji ditampilkan pada Gambar 6:



Gambar 6. Confusion Matrix Model MobileNetV2

Pada kelas normal, model berhasil mengklasifikasikan 70 dari 72 citra dengan benar. Kesalahan paling banyak terjadi pada kelas retak karena beberapa citra memiliki retakan halus yang menyerupai bayangan atau garis tepi komponen. Pada kelas korosi, sebagian kesalahan terjadi karena pola warna oksidasi tipis memiliki kemiripan dengan noda permukaan. Hasil ini menunjukkan bahwa kualitas pencahayaan dan resolusi citra sangat memengaruhi kemampuan model dalam mengenali kerusakan berukuran kecil.

Tabel 4. Classification Report Model MobileNetV2

| Kelas            | Precision     | Recall        | F1-score      | Support    |
|------------------|---------------|---------------|---------------|------------|
| Normal           | 95,89%        | 97,22%        | 96,55%        | 72         |
| Terbakar         | 100,00%       | 97,22%        | 98,59%        | 36         |
| Retak            | 94,29%        | 91,67%        | 92,96%        | 36         |
| Korosi           | 91,89%        | 94,44%        | 93,15%        | 36         |
| <b>Rata-rata</b> | <b>95,71%</b> | <b>95,56%</b> | <b>95,58%</b> | <b>180</b> |

Sumber : Hasil Olahan data menggunakan python

## 6. Implementasi Prototipe Sistem

Model hasil pelatihan diintegrasikan ke dalam prototipe sistem deteksi kerusakan komponen elektronik. Prototipe dirancang agar pengguna dapat mengunggah citra komponen, menjalankan proses prediksi, melihat hasil kelas kerusakan, memperoleh nilai confidence, dan menyimpan riwayat



pemeriksaan. Alur kerja prototipe terdiri atas halaman beranda, halaman unggah citra, proses prediksi, riwayat hasil, dan laporan.

Tabel 5. Hasil Pengujian Blackbox Prototipe

| No | Halaman yang Diuji | Langkah Pengujian                  | Respon Sistem Diharapkan                | Status |
|----|--------------------|------------------------------------|-----------------------------------------|--------|
| 1  | Halaman Masuk      | Input username dan password        | Sistem berhasil masuk ke aplikasi       | Valid  |
| 2  | Beranda            | Membuka menu utama                 | Menu utama dapat ditampilkan            | Valid  |
| 3  | Unggah Citra       | Memilih file citra komponen        | Citra berhasil diunggah                 | Valid  |
| 4  | Pra-pemrosesan     | Menjalankan resize dan normalisasi | Citra siap diproses model               | Valid  |
| 5  | Prediksi Model     | Menekan tombol deteksi             | Kelas kerusakan dan confidence muncul   | Valid  |
| 6  | Riwayat Hasil      | Membuka data hasil deteksi         | Riwayat tersimpan dan dapat ditampilkan | Valid  |
| 7  | Laporan            | Mencetak laporan hasil deteksi     | Laporan dapat diunduh                   | Valid  |

Hasil pengujian blackbox pada Tabel 5 menunjukkan bahwa seluruh fungsi utama prototipe berjalan sesuai dengan kebutuhan. Halaman unggah citra mampu menerima file gambar, proses pra-pemrosesan berjalan otomatis, dan hasil prediksi dapat ditampilkan dengan informasi kelas serta tingkat keyakinan model. Dengan demikian, prototipe dapat digunakan sebagai media awal untuk membantu proses identifikasi kerusakan komponen elektronik berbasis citra digital.

### SIMPULAN DAN SARAN

Penelitian ini berhasil mengimplementasikan deep learning berbasis citra digital untuk mendeteksi kerusakan komponen elektronik dengan empat kelas, yaitu normal, terbakar, retak, dan korosi. Tahapan penelitian meliputi pengumpulan citra, anotasi, pra-pemrosesan, augmentasi, pelatihan model, evaluasi, dan implementasi prototipe sistem. Model MobileNetV2 berbasis transfer learning menunjukkan performa terbaik dibandingkan CNN sederhana dan ResNet50 dengan nilai accuracy 95,56%, precision 95,71%, recall 95,56%, dan F1-score 95,58%. Hasil ini menunjukkan bahwa pendekatan deep learning dapat membantu proses inspeksi komponen elektronik secara lebih cepat, objektif, dan konsisten.

Pengembangan selanjutnya dapat dilakukan dengan memperluas dataset menggunakan citra nyata dari berbagai jenis komponen dan kondisi pencahayaan, menambahkan metode explainable AI untuk menampilkan area citra yang memengaruhi keputusan model, serta mengintegrasikan sistem dengan perangkat kamera digital atau mikroskop digital agar dapat digunakan secara langsung pada laboratorium teknik digital maupun layanan perbaikan perangkat elektronik.

### DAFTAR PUSTAKA

- Ameri, R., Hsu, C. C., & Band, S. S. (2024). A systematic review of deep learning approaches for surface defect detection in industrial applications. *Engineering Applications of Artificial Intelligence*, 130, 107717. <https://doi.org/10.1016/j.engappai.2023.107717>
- Bai, D., Li, G., Jiang, D., Yun, J., Tao, B., Jiang, G., Sun, Y., & Ju, Z. (2024). Surface defect detection methods for industrial products with imbalanced samples: A review of progress in the 2020s. *Engineering Applications of Artificial Intelligence*, 130, 107697. <https://doi.org/10.1016/j.engappai.2023.107697>
- Bai, L., & Xu, W. H. (2025). Improved printed circuit board defect detection scheme. *Scientific Reports*, 15, 2389. <https://doi.org/10.1038/s41598-025-85245-2>



- Bhattacharya, A., & Cloutier, S. G. (2022). End-to-end deep learning framework for printed circuit board manufacturing defect classification. *Scientific Reports*, 12, 12559. <https://doi.org/10.1038/s41598-022-16302-3>
- Chen, X., Wu, Y., He, X., & Wuyi, M. (2024). A comprehensive review of deep learning-based PCB defect detection. *IEEE Access*, 12, 1-1. <https://doi.org/10.1109/ACCESS.2023.3339561>
- Chen, Y., Ding, Y., Zhao, F., Zhang, E., Wu, Z., & Shao, L. (2021). Surface defect detection methods for industrial products: A review. *Applied Sciences*, 11(16), 7657. <https://doi.org/10.3390/app11167657>
- Elsharkawy, Z. F. (2025). Enhanced YOLOv11 framework for high precision defect detection in printed circuit boards. *Scientific Reports*, 15, 42550. <https://doi.org/10.1038/s41598-025-27415-w>
- Hermin, H., & Ismail, I. (2026). Prediksi produktivitas jagung berbasis explainable machine learning dan seleksi fitur adaptif. *Jurnal Ilmiah Sistem Informasi dan Teknik Informatika (JISTI)*, 9(1). <https://doi.org/10.57093/jisti.v9i1.398>
- Hosen, M. S., Shehab, M., & Elbeltagi, E. (2024). Advancing PCB quality control: Harnessing YOLOv8 deep learning for real-time fault detection. *Computers, Materials & Continua*, 81(1), 345-367. <https://doi.org/10.32604/cmc.2024.054439>
- Kang, H., & Yang, Y. (2023). An enhanced detection method of PCB defect based on D-DenseNet (PCBDD-DDNet). *Electronics*, 12(23), 4737. <https://doi.org/10.3390/electronics12234737>
- Ling, Q., & Mat Isa, N. A. (2023). Printed circuit board defect detection methods based on image processing, machine learning and deep learning: A survey. *IEEE Access*, 11, 1-1. <https://doi.org/10.1109/ACCESS.2023.3245093>
- Ma, Y., Yin, J., Huang, F., & Li, Q. (2024). Surface defect inspection of industrial products with object detection deep networks: A systematic review. *Artificial Intelligence Review*, 57, 333. <https://doi.org/10.1007/s10462-024-10956-3>
- Park, J. H., Kim, Y. S., Seo, H., & Cho, Y. J. (2023). Analysis of training deep learning models for PCB defect detection. *Sensors*, 23(5), 2766. <https://doi.org/10.3390/s23052766>
- Prunella, M., Scardigno, R., Buongiorno, D., Brunetti, A., & Longo, N. (2023). Deep learning for automatic vision-based recognition of industrial surface defects: A survey. *IEEE Access*, 11, 43370-43423. <https://doi.org/10.1109/ACCESS.2023.3271748>
- Saberironaghi, A., Ren, J., & El-Gindy, M. (2023). Defect detection methods for industrial products using deep learning techniques: A review. *Algorithms*, 16(2), 95. <https://doi.org/10.3390/a16020095>
- Wardana, M. A., & Ismail, I. (2026). Model explainable machine learning untuk prediksi kecukupan gizi menu MBG. *Jurnal Ilmiah Sistem Informasi dan Teknik Informatika (JISTI)*, 9(1). <https://doi.org/10.57093/jisti.v9i1.410>
- Xiao, G., Hou, S., & Zhou, H. (2024). PCB defect detection algorithm based on CDI-YOLO. *Scientific Reports*, 14, 7351. <https://doi.org/10.1038/s41598-024-57491-3>
- Yang, W., Huang, X., Zhang, F., & Li, H. (2023). PCB defect detection based on deep learning algorithm. *Processes*, 11(3), 775. <https://doi.org/10.3390/pr11030775>
- Zhang, X., Wang, J., Jiang, D., Li, Y., Wang, X., & Zhang, H. (2025). Defects detection in screen-printed circuits based on an enhanced YOLOv8n algorithm. *International Journal of Computational Intelligence Systems*, 18, 101. <https://doi.org/10.1007/s44196-025-00815-6>
- Sun, Z., Ma, R., & Lei, Q. (2026). Small PCB defect detection based on convolutional block attention mechanism and YOLOv8. *Applied Sciences*, 16(2), 1078. <https://doi.org/10.3390/app16021078>
- Wang, J., Xie, X., Liu, G., & Wu, L. (2025). A lightweight PCB defect detection algorithm based on improved YOLOv8-PCB. *Symmetry*, 17(2), 309. <https://doi.org/10.3390/sym17020309>