



Klasifikasi Kerusakan Pin Komponen Pada Dioda *Bridge Rectifier* Menggunakan Metode *Faster R- CNN*

Laporan Tugas Akhir

**Oleh:
Salsabila Hanisaputri (4212201028)**

**Program Studi Teknik Mekatronika
Jurusan Teknik Elektro
Politeknik Negeri Batam
2026**

Pernyataan Keaslian Tugas Akhir

Saya yang bertandatangan dibawah ini menyatakan bahwa isi sebagian maupun keseluruhan Tugas Akhir saya yang berjudul: “Klasifikasi Kerusakan Pin Komponen Pada Dioda *Bridge Rectifier* Menggunakan Metode *Faster R-CNN*” adalah **hasil karya sendiri, diselesaikan tanpa menggunakan bahan-bahan yang tidak diizinkan**, dan **bukan merupakan karya pihak lain yang saya akui sebagai karya sendiri**. Semua referensi yang dikutip atau dirujuk telah ditulis secara lengkap pada daftar pustaka. Apabila ternyata pernyataan saya ini tidak benar, saya bersedia menerima sanksi sesuai peraturan yang berlaku.

Batam, 29 Desember 2025

A handwritten signature in black ink, appearing to read "Salsabila".

Salsabila Hanisaputri
NIM: 4212201028

Lembar Pengesahan

**Tugas Akhir disusun untuk memenuhi salah satu syarat memperoleh gelar
Sarjana Terapan Teknik (S.Tr.T)
di
Politeknik Negeri Batam**

**Oleh:
Salsabila Hanisaputri (4212201028)**

Tanggal Sidang: 20-01-2026

Disetujui oleh :



**1. Dr. Budi Sugandi, S.T., M.Eng.
NIK: 197303212021211005**

A handwritten signature in black ink, consisting of stylized cursive letters, representing Adlian Jefiza.

**1. Adlian Jefiza, S.Pd., M.T.
NIK: 199112022019031016**



**2. Daniel Sutopo Pamungkas, S.T., M.T., Ph.D.
NIK: 197511282012121002**

Klasifikasi Kerusakan Pin Komponen Pada Dioda *Bridge Rectifier* Menggunakan Metode *Faster R-CNN*

Abstrak

Deteksi kerusakan pada komponen elektronik, khususnya dioda bridge rectifier tipe KBJ208, merupakan hal krusial dalam penjaminan kualitas manufaktur. Namun, metode inspeksi kualitas manual yang umum digunakan masih memiliki kelemahan signifikan berupa subjektivitas dan kelelahan operator. Penelitian ini bertujuan untuk membangun prototipe sistem klasifikasi otomatis kerusakan pin komponen tersebut menggunakan metode *Faster Regional Convolutional Neural Network* (Faster R-CNN). Metodologi yang diterapkan meliputi akuisisi citra, *preprocessing* distorsi lensa, pelatihan model dengan arsitektur *backbone* ResNet-50 melalui pendekatan *transfer learning* dan *f*, serta pengembangan *user interface* untuk memvisualisasikan hasil deteksi. Sistem dirancang untuk mengklasifikasikan kondisi pin menjadi tiga kategori: normal, *bent*, dan *broken* pada sudut pandang tegak lurus. Hasil pengujian menunjukkan bahwa konfigurasi model terbaik mampu mencapai performa deteksi yang tinggi dengan nilai mAP (Pascal VOC) sebesar 99,36%. Pada pengujian integrasi *user interface*, alat berhasil mencapai akurasi klasifikasi sebesar 95%. Secara spesifik, sistem terbukti sangat andal dalam mendeteksi kerusakan fatal (*broken*) dengan nilai *recall* mencapai 99%, yang mengindikasikan efektivitas sistem dalam meminimalkan risiko lolosnya komponen rusak. Dapat disimpulkan bahwa metode *Faster R-CNN* terbukti efektif diterapkan pada sistem inspeksi otomatis untuk objek berskala kecil (*mikro*) dengan presisi tinggi guna mengatasi keterbatasan visual operator dalam mengidentifikasi detail kerusakan komponen elektronik.

Kata kunci: Klasifikasi Kerusakan, *Faster R-CNN*, *Deep Learning*, inspeksi pin.

Classification of Component Pin Damage in Rectifier Bridge Diode Using Faster R-CNN Method

Abstract

Defect detection in electronic components, specifically the KBJ208 type bridge rectifier diode, is crucial in manufacturing quality assurance. However, the commonly used manual inspection methods still possess significant weaknesses, such as subjectivity and operator fatigue. This research aims to develop a prototype of an automatic classification system for pin defects in said component using the Faster Regional Convolutional Neural Network (Faster R-CNN) method. The applied methodology includes image acquisition, lens distortion preprocessing, model training with a ResNet-50 backbone architecture using a transfer learning approach, and the development of a user interface to visualize detection results. The system is designed to classify pin conditions into three categories: normal, bent, and broken, from a perpendicular viewpoint. Test results demonstrate that the best model configuration achieved high detection performance with a mAP (Pascal VOC) value of 99.36%. In the user interface integration testing, the device achieved a classification accuracy of 95%. Specifically, the system proved to be highly reliable in detecting fatal defects (broken) with a recall value reaching 99%, indicating the system's effectiveness in minimizing the risk of defective components escaping detection. It can be concluded that the Faster R-CNN method is effectively applied in automatic inspection systems for small-scale (micro) objects with high precision, offering a solution to overcome operator visual limitations in identifying detailed defects in electronic components.

Keywords: Defect Classification, Faster R-CNN, Deep Learning, pin inspection.

Kata Pengantar

Puji syukur kehadiran Allah SWT atas segala limpahan rahmat, hidayah, dan karunia-Nya, sehingga penulis dapat menyelesaikan laporan Tugas Akhir ini. Laporan Tugas Akhir ini disusun sebagai salah satu syarat untuk menyelesaikan pendidikan Diploma IV pada Program Studi Teknik Mekatronika, Jurusan Teknik Elektro, di Politeknik Negeri Batam. Pada kesempatan ini penulis ingin mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Allah SWT yang telah memberikan kesehatan, kekuatan, dan kesabaran kepada penulis selama pengerjaan Tugas Akhir ini.
2. Ibu Murwati Handayani, S.Pd., dan Alm. Bapak Trisef Jonis Radianto Radiman selaku Orang Tua penulis. Serta Kakak Laras Hanisaputri dan Adik Dhia Nabilah Hanisaputri yang menjadi sumber doa, semangat terbesar, kasih sayang, serta dukungan moral dan material bagi penulis.
3. Bapak Ir. Bambang Hendrawan, S.T., M.S.M., selaku Direktur Politeknik Negeri Batam.
4. Bapak Ir. Indra Hardian Mulyadi, S.T., M.Eng., Ph.D., selaku Ketua Jurusan Teknik Elektro Politeknik Negeri Batam.
5. Bapak Diono, S.Tr.T., M.Sc., selaku Ketua Program Studi Teknik Mekatronika.
6. Bapak Adlian Jefiza, S.Pd., M.T., selaku Dosen Pembimbing yang telah meluangkan waktu dan pikiran di tengah kesibukan untuk memberikan bimbingan serta arahan selama penyusunan Tugas Akhir ini.
7. Bapak Dr. Budi Sugandi, S.T., M.Eng., selaku Dosen Penguji 1 yang telah memberikan evaluasi mendalam bagi penulis.
8. Bapak Daniel Sutopo Pamungkas, S.T., M.T., Ph.D., selaku Dosen Penguji 2 yang telah memberikan evaluasi mendalam bagi penulis.
9. Seluruh Dosen dan Staf Jurusan Teknik Elektro Polibatam yang telah memberikan ilmu dan bantuan selama masa perkuliahan Penulis.
10. Teman-teman penulis: Nabila, Sofya, Isfi, Difa, Surya, Fikri, Liz, dan Dimas Rizky serta seluruh teman-teman penulis yang tidak bisa disebutkan satu-persatu, terima kasih atas bantuan, diskusi, serta dukungan yang diberikan selama pengerjaan Tugas Akhir ini.

Penulis menyadari bahwa laporan ini masih memiliki kekurangan. Oleh karena itu, kritik dan saran yang membangun sangat diharapkan. Semoga laporan ini dapat memberikan manfaat bagi pembaca.

Batam, 29 Desember 2025

Salsabila Hanisaputri

Daftar Isi

Pernyataan Keaslian Tugas Akhir	i
Lembar Pengesahan	ii
Abstrak	iii
<i>Abstract</i>	iv
Kata Pengantar	v
Daftar Isi	vi
Daftar Gambar	ix
Daftar Tabel	xi
Bab 1. Pendahuluan	1
1.1. Latar Belakang.....	1
1.2. Rumusan Masalah	3
1.3. Tujuan	3
1.4. Manfaat	3
1.5. Batasan	3
Bab 2. Tinjauan Pustaka	5
2.1. Penelitian Terkait	5
2.2. Dioda <i>Bridge Rectifier</i>	7
2.2.1. Klasifikasi Kerusakan	8
2.3. <i>Convolutional Neural Network (CNN)</i>	9
2.4. <i>Preprocessing</i>	9
2.5. <i>Faster Regional Convolutional Neural Network</i>	10
2.5.1. Arsitektur <i>Faster R-CNN</i>	10
2.5.2. Parameter <i>Faster R-CNN</i>	12
2.6. <i>Feature Pyramid Network (FPN)</i>	13
2.7. <i>Transfer Learning</i>	13
2.8. <i>User Interface</i>	14
Bab 3. Metodologi Penelitian	15
3.1. Perancangan Penelitian	15
3.1.1. Studi Literatur	15

3.1.2. Persiapan Dataset	15
3.1.3. Perancangan Model <i>Faster R-CNN</i>	19
3.1.4. <i>Preprocessing</i> Dataset	20
3.1.5. <i>Training</i> Model <i>Faster R-CNN</i>	20
3.1.6. <i>Testing</i> Model <i>Faster R-CNN</i>	21
3.1.7. Evaluasi Model.....	21
3.1.8. Implementasi <i>User Interface</i>	22
3.1.9. Pengujian Sistem.....	23
3.2. Alat dan Bahan.....	23
3.3. Perancangan Pengujian.....	24
3.3.1. Pengujian Performa Model	24
3.3.2. Pengujian <i>User Interface</i>	26
Bab 4. Hasil dan Pembahasan	29
4.1. Hasil Pengolahan Dataset	29
4.1.1. Hasil Fabrikasi Tray.....	29
4.1.2. Hasil Pengumpulan Data Sampel	29
4.1.3. Hasil Pengambilan Citra Dataset	30
4.1.4. Pelabelan Dataset	31
4.1.5. Statistik <i>Dataset</i>	32
4.2. Tahapan <i>Preprocessing</i>	32
4.2.1. Normalisasi Statistik.....	33
4.2.2. Implementasi Augmentasi <i>On-Fly</i>	33
4.3. Visualisasi <i>Feature Map</i> dan Tahapan Deteksi.....	35
4.3.1. Hasil Visualisasi <i>Backbone Resnet50</i>	35
4.3.2. Hasil Visualisasi Fitur FPN (<i>Feature Map Analysis</i>)	36
4.3.3. Hasil Visualisasi Fitur RPN (<i>Region Proposal Network</i>).....	38
4.3.4. Hasil Visualisasi <i>Fast R-CNN Head</i>	38
4.4. Hasil Pengujian Performa.....	39
4.4.1. Perbandingan Performa	39

4.5. Analisa Model Terbaik	41
4.5.1. Analisa Grafik <i>Loss</i> dan <i>val mAP</i>	41
4.5.2. Analisis Pengaruh Hyperparameter.....	43
4.5.3. Evaluasi Model pada <i>Dataset Testing</i>	43
4.6. Hasil Pengujian Sistem <i>User Interface</i>	48
4.6.1. Perbandingan Hasil Pengujian.....	48
4.6.2. Evaluasi <i>Confusion Matrix</i> Pengujian <i>User Interface</i>	62
4.6.3. Evaluasi <i>Classification Report</i>	63
Bab 5. Kesimpulan dan Saran	67
5.1. Kesimpulan	67
5.2. Saran.....	67
Daftar Pustaka	69
Biodata	71
Lampiran.....	72

Daftar Gambar

Gambar 1. Komponen Dioda <i>Bridge Rectifier</i> KBJ208.....	8
Gambar 2. Arsitektur Umum CNN	9
Gambar 3. Arsitektur <i>Faster R-CNN</i>	11
Gambar 4. Blok Diagram Penelitian	15
Gambar 5. Realisasi Konfigurasi <i>Hardware</i> akuisisi citra.....	16
Gambar 6. Desain Mekanikal <i>Tray</i>	16
Gambar 7. Dimensi Desain Mekanikal	17
Gambar 8. <i>Datasheet</i> Dioda.....	17
Gambar 9. Rancangan <i>User Interface</i>	22
Gambar 10. <i>Flowchart</i> pengujian sistem <i>user interface</i>	26
Gambar 11. Hasil fabrikasi <i>custom tray</i>	29
Gambar 12. Pin <i>Bent</i>	29
Gambar 13. Pin <i>Broken</i>	30
Gambar 14. Pin Normal	30
Gambar 15. Citra asli.....	30
Gambar 16. Citra hasil <i>undistorted</i>	31
Gambar 17. Pelabelan Dataset dalam satu tray.....	31
Gambar 18. Struktur File Anotasi (XML).....	32
Gambar 19. Visualisasi Normalisasi	33
Gambar 20. Visualisasi Rotasi Acak.....	33
Gambar 21. Visualisasi Variasi Pencacayaan	34
Gambar 22. Visualisasi Blur.....	34
Gambar 23. Visualisasi <i>Random Crop</i>	35
Gambar 24. Visualisasi <i>Resnet50 Output Layer 1</i>	35
Gambar 25. Visualisasi <i>Resnet50 Output Layer 2</i>	36
Gambar 26. Visualisasi <i>Resnet50 Output Layer 3</i>	36
Gambar 27. Visualisasi <i>Resnet50 Output Layer 4</i>	36
Gambar 28. Visualisasi FPN Layer P5	37
Gambar 29. Visualisasi FPN Layer P4	37
Gambar 30. Visualisasi FPN Layer P3	37
Gambar 31. Visualisasi FPN Layer P2.....	38
Gambar 32. Visualisasi RPN	38
Gambar 33. Visualisasi Tahap akhir.....	39
Gambar 34. Grafik <i>Loss</i> Skenario F	42
Gambar 35. Grafik validasi mAP Skenario F.....	42
Gambar 36. Hasil <i>testing</i> mAP skenario F	43
Gambar 37. <i>Confusion Matrix dataset testing</i> skenario F.....	44
Gambar 38. <i>Classification report dataset testing</i> skenario F	45
Gambar 39. Metrik RPN.....	47

Gambar 40. Rata-rata *Loss* Komponen 47

Daftar Tabel

Tabel 1. Penelitian Terkait	5
Tabel 2. Matriks Kriteria.....	18
Tabel 3. Alat dan Bahan	24
Tabel 4. Skenario Pengujian.....	24
Tabel 5. Perbandingan Hasil Pengujian Skenario	25
Tabel 6. Perbandingan Hasil Pengujian	27
Tabel 7. <i>Confussion Matriks 3x3</i>	27
Tabel 8. Perhitungan Evaluasi Manual.....	28
Tabel 9. Distribusi Kelas	32
Tabel 10. Hasil Pembagian Dataset.....	32
Tabel 11. Perbandingan Peforma Skenario	40
Tabel 12. Hasil Pengujian <i>User Interface</i> 1.....	48
Tabel 13. Hasil Pengujian <i>User Interface</i> 2.....	49
Tabel 14. Hasil Pengujian <i>User Interface</i> 3.....	50
Tabel 15. Hasil Pengujian <i>User Interface</i> 4.....	51
Tabel 16. Hasil Pengujian <i>User Interface</i> 5.....	52
Tabel 17. Hasil Pengujian <i>User Interface</i> 6.....	53
Tabel 18. Hasil Pengujian <i>User Interface</i> 7.....	54
Tabel 19. Hasil Pengujian <i>User Interface</i> 8.....	55
Tabel 20. Hasil Pengujian <i>User Interface</i> 9.....	56
Tabel 21. Hasil Pengujian <i>User Interface</i> 10.....	57
Tabel 22. Hasil Pengujian <i>User Interface</i> 11.....	58
Tabel 23. Hasil Pengujian <i>User Interface</i> 12.....	59
Tabel 24. Hasil Pengujian <i>User Interface</i> 13.....	60
Tabel 25. Hasil Pengujian <i>User Interface</i> 14.....	61
Tabel 26. Hasil Pengujian <i>User Interface</i> 15.....	62
Tabel 27. <i>Confussion Matrix</i> Hasil Pengujian User Interface	63
Tabel 28. <i>Classification report</i> hasil pengujian <i>user interface</i>	64

Bab 1. Pendahuluan

1.1. Latar Belakang

Deteksi cacat memiliki peran krusial dalam menjamin kualitas produk, meningkatkan efisiensi proses produksi, serta menjadi elemen kunci dalam pengembangan manufaktur cerdas. Deteksi cacat merupakan proses identifikasi visual ketidaksempurnaan pada tampilan produk [1]. Cacat tersebut dapat memengaruhi performa, keselamatan, dan estetika produk secara keseluruhan. Dalam konteks transformasi menuju Industri 4.0, proses deteksi cacat juga menjadi pilar utama dalam mewujudkan sistem manufaktur cerdas berbasis data, sensor, dan kecerdasan buatan [2]. Meskipun teknologi *machine vision* dan *deep learning* telah berkembang signifikan, masih ditemukan lini produksi komponen elektronik khususnya di sektor industri kecil hingga menengah yang mengandalkan metode inspeksi visual manual. Hal ini diperkuat oleh hasil wawancara yang telah penulis lakukan dengan seorang narasumber yang berprofesi sebagai operator inspeksi manual komponen elektronik. Diperoleh kesimpulan bahwa proses deteksi cacat pada komponen elektronik yang dilakukan dengan pengamatan mata langsung terhadap *tray* berisi banyak komponen oleh operator manusia memiliki sejumlah kelemahan. Di antaranya adalah tingginya potensi kesalahan deteksi akibat penilaian yang bersifat subjektif, kelelahan mata pada operator, tekanan kerja yang tinggi, serta efisiensi yang rendah. Kondisi ini dapat berdampak serius, termasuk kemungkinan terjadinya penarikan produk akibat cacat yang tidak terdeteksi serta akumulasi tekanan kerja yang dapat berdampak negatif pada kesehatan fisik dan mental operator dalam jangka panjang. Narasumber juga menyatakan bahwa dengan adanya sistem deteksi otomatis sangat membantu mengurangi beban kerja operator.

Dalam konteks tersebut, penelitian ini memfokuskan pengembangan sistem klasifikasi otomatis untuk mendeteksi kerusakan pada pin komponen elektronika dioda *bridge rectifier* tipe KBJ208. Dioda *bridge rectifier* adalah komponen semikonduktor yang terdiri dari empat buah dioda yang disusun dalam konfigurasi jembatan [3]. Komponen ini berfungsi untuk mengubah tegangan bolak-balik (AC) menjadi tegangan searah (DC) [3]. Kerusakan pada pin komponen dioda dapat memberikan efek buruk terhadap performa listrik dan termalnya [4]. Pemilihan dioda *bridge rectifier* KBJ208 sebagai objek penelitian didasarkan pada penggunaannya yang masif dalam industri elektronika daya, yang umumnya dirakit menggunakan sistem otomatisasi (*auto-insertion*). Dalam konteks ini, integritas geometri pin menjadi parameter kritis. Kerusakan pada pin komponen sangat memengaruhi keberhasilan proses soldering dan keandalan koneksi listrik [5]. Untuk mengatasi permasalahan ini, sistem klasifikasi otomatis berbasis *machine vision* menjadi sangat relevan, dan salah satu pendekatan yang menjanjikan adalah penggunaan teknologi *deep learning*. Salah satu metode yang

dapat digunakan adalah *Faster Regional Convolutional Neural Network (Faster R-CNN)*, yang mampu mendeteksi dan mengklasifikasikan objek kecil dengan lebih akurat dengan konsep *two-stage detector*.

Dalam proposal tugas akhir ini, penulis merujuk pada beberapa penelitian sebelumnya sesuai dengan topik yang diambil, pertama adalah penelitian tugas akhir dengan judul “Penerapan Metode *Faster Regional Convolutional Neural Network (Faster R-CNN)* Untuk Klasifikasi Jenis Kerusakan Jalan”. Penelitian tersebut mengklasifikasikan 3 kelas jenis kerusakan jalan dan berhasil mencapai *accuracy* sebesar 95,73% pada 1.200 data uji [6]. Kedua, pada penelitian “*Convolutional Neural Network Dan Faster Region Convolutional Neural Network Untuk Klasifikasi Kualitas Biji Kopi Arabika*”. Penelitian tersebut mengenai klasifikasi kualitas biji kopi Arabika normal dan cacat, dengan membandingkan perbandingan kinerja antara *Faster R-CNN* dan *CNN VGG-16*, dengan hasil *Faster R-CNN* memperoleh hasil yang baik dengan *accuracy* rata-rata 93% dan *precision* 93% [7]. Ketiga, penelitian “*Defect Detection of Pantograph Slider Based on Improved Faster R-CNN*” mengenai deteksi dan klasifikasi 4 kelas jenis kondisi *pantograph slider* menggunakan metode *Faster R-CNN* dengan *accuracy* sebesar 97,63% [8].

Maka dari itu, penulis akhirnya mengusulkan penelitian menggunakan metode *Faster R-CNN* yang memfokuskan pada sistem klasifikasi kerusakan pin pada komponen dioda *bridge rectifier* tipe KBJ208 ke dalam tiga kelas yaitu normal, *bent*, dan *broken* sesuai dengan kategori ketidakterimaan visual berdasarkan standar *IPC-A-610 Revision H* [9]. Meskipun metode *Faster R-CNN* telah terbukti handal pada penelitian terdahulu, penerapannya pada inspeksi pin komponen elektronik memiliki tantangan tersendiri. Karakteristik pin dioda yang memiliki dimensi kecil, material logam yang sangat reflektif terhadap cahaya, serta kemiripan visual yang tinggi antar-kelas kerusakan menuntut konfigurasi sistem dan model deteksi yang lebih spesifik dibandingkan objek *makro* pada penelitian sebelumnya. Sistem dirancang dengan pendekatan *non-realtime* dan menggunakan metode *snapshot*, yaitu pengambilan citra statis dari *tray* berisi enam komponen dioda melalui kamera. Konfigurasi ini dipilih untuk memfasilitasi anotasi manual yang presisi, evaluasi model yang efektif, serta mengakomodasi keterbatasan komputasi dalam skenario penelitian skala awal. Implementasi sistem ini juga dilengkapi dengan *user interface* untuk menampilkan hasil klasifikasi secara terstruktur. Meskipun penelitian ini tidak langsung diterapkan di lingkungan industri nyata, sistem yang dikembangkan bertujuan untuk membuktikan kelayakan metode *Faster R-CNN* dalam konteks klasifikasi multiobjek kerusakan visual pada komponen elektronik, sebagai dasar untuk pengembangan sistem berskala lebih besar di masa depan.

1.2. Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan di atas, permasalahan yang dibahas dalam proposal tugas akhir ini dirumuskan sebagai berikut:

1. Bagaimana mengimplementasikan metode *Faster R-CNN* untuk sistem klasifikasi otomatis kerusakan pin komponen dioda *bridge rectifier* tipe KBJ208?
2. Bagaimana performa sistem yang dibangun dalam mengklasifikasikan kerusakan pin komponen dioda?

1.3. Tujuan

Berdasarkan rumusan masalah tersebut, didapat tujuan dari proposal tugas akhir ini, yaitu:

1. Mengimplementasikan metode *Faster R-CNN* pada sistem klasifikasi otomatis untuk mendeteksi kerusakan pin pada komponen dioda bridge rectifier tipe KBJ208.
2. Mengetahui dan menganalisis performa sistem yang dibangun dalam mengklasifikasikan kerusakan pin komponen dioda tersebut.

1.4. Manfaat

Manfaat yang dapat diperoleh dari proposal tugas akhir ini adalah sebagai berikut:

1. Menambah literatur dan wawasan keilmuan mengenai kinerja arsitektur *Faster R-CNN* dalam menangani tantangan deteksi objek kecil dengan karakteristik material reflektif pada komponen elektronika.
2. Menghadirkan solusi teknis untuk mengatasi keterbatasan inspeksi komponen kecil secara manual.

1.5. Batasan

Untuk membatasi ruang lingkup pembahasan permasalahan pada proposal tugas akhir ini maka ditentukan beberapa batasan sebagai berikut:

1. Sistem yang dirancang merupakan prototipe skala laboratorium yang dijalankan menggunakan Laptop, belum terintegrasi dengan sistem mekanik atau PLC skala industri.
2. Objek dikhususkan pada pin komponen elektronika Dioda *Bridge Rectifier* tipe KBJ208.
3. Kondisi pin diklasifikasikan ke dalam tiga kelas, yaitu *Normal*, *Bent*, dan *Broken*. Fokus utama sistem adalah mendeteksi deformasi lateral (sumbu X dan Y) yang terlihat dari sudut pandang atas.

4. Pengambilan data citra dilakukan terhadap enam komponen dioda pada *tray* yang diposisikan menggunakan *fixture* dari sudut pandang tegak lurus pada *mounting stand* statis.
5. Kondisi pencahayaan lingkungan dijaga konstan dengan 4ungga *diffused lighting*.
6. Sistem bekerja menggunakan metode pengambilan citra statis.

Bab 2. Tinjauan Pustaka

2.1. Penelitian Terkait

Tabel 1. Penelitian Terkait

No	Tahun	Penulis	Judul	Metode	Kelemahan
1	2020	Syifa Laili Hapsari Oktavian	Penerapan Metode <i>Faster Regional Convolutional Neural Network (Faster R-CNN)</i> untuk Klasifikasi Jenis Kerusakan Jalan	<i>Faster R- CNN</i>	Jumlah data <i>training</i> tergolong sedikit dan minim jenis variasi kerusakannya
2	2024	Gede Ardi Pratama, Eva Yulia Puspaningrum, Hendra Maulana	<i>Convolutional Neural Network</i> dan <i>Faster Region Convolutional Neural Network untuk</i> Klasifikasi Kualitas Biji Kopi Arabika	<i>CNN VGG- 16</i> dan <i>Faster R- CNN</i>	Model yang dilatih khusus untuk Arabika dari satu wilayah mungkin tidak bekerja baik untuk Arabika dari wilayah lain
3	2020	Xiaobo Chen, Huimin Zhang	<i>Rail Surface Defects Detection Based on Faster R-CNN</i>	<i>Faster R- CNN</i>	Objek rentan terpicu oleh <i>noise</i> visual seperti kilau dan noda sehingga kurang unggul terhadap cacat permukaan berukuran kecil

4	2019	Siyang Jiang, Xiukun Wei, Ziming Yang	<i>Defect Detection of Pantograph Slider Based on Improved Faster R-CNN</i>	<i>Faster R-CNN</i>	Dataset yang digunakan masih belum mencukupi meskipun telah dilakukan penambahan data. Diperlukan data yang lebih andal untuk verifikasi lebih lanjut.
5	2022	Xiangyang Xu, Mian Zhao, Peixin Shi, Ruiqi Ren, Xuhui He, Xiaojun Wei, Hao Yang	<i>Crack Detection and Comparison Study Based on Faster R-CNN and Mask R-CNN</i>	<i>Mask R-CNN</i> dan <i>Faster R-CNN</i>	Penelitian ini membutuhkan lebih banyak <i>dataset</i> untuk melatih retakan yang kompleks, dan dataset dalam percobaan ini memiliki lebih banyak retakan tunggal melintang dan lebih sedikit retakan yang kompleks
6	2024	Haiyang Zhanga, Xinjie Xiaob, Tingrui Sunb, Zhiwei Li	<i>Industrial Diode Approach To Surface Defect Detection Relying On Global Context Attention Mechanism And Dynamic Adjustment Head</i>	<i>YOLOv5</i>	Nilai <i>Maps</i> dari hasil penelitian ini adalah 64,7% dan masih terbilang rendah.

7	2018	Mingzhu Wang, Jack C. P. Cheng	<i>Development and Improvement of Deep Learning Based Automated Defect Detection for Sewer Pipe Inspection Using Faster R-CNN</i>	<i>Faster R-CNN</i>	Faktor bentuk, warna, dan intensitas objek memengaruhi <i>accuracy</i> deteksi model.
8	2018	Hai-Wei Lei, Bin Wang, He-He Wu, An-Hong Wang	<i>Defect Detection for Polymeric Polarizer Based on Faster R-CNN</i>	<i>Faster R-CNN</i>	Jumlah lapisan jaringan tidak sesuai dengan beberapa parameter jaringan.
9	2023	Peter Klco, Dusan Koniar, Libor Hargas, Katarina Pociskova Dimova, Marek Chnapko	<i>Quality Inspection of Specific Electronic Boards by Deep Neural Networks</i>	<i>YOLOv5n, YOLOv5s, YOLOv5m, YOLOv8n, YOLOv8s, Faster R-CNN</i>	Apabila gambar di <i>zoom</i> , fitur cacat pin menjadi buram dan hilang. Beberapa pin terlewatkan dalam hasil pengujian.
10	2025	Maurizio Calabrese, Leonardo Agnusdei, Gianmauro Fontana, Gabriele Papadia, Antonio Del Prete	<i>Application of Mask R-CNN and YOLOv8 Algorithms for Defect Detection in Printed Circuit Board Manufacturing</i>	<i>Mask R-CNN</i> dan <i>YOLOv8</i>	Masih memerlukan pengembangan lanjutan dalam hal optimalisasi model.

Berdasarkan tinjauan terhadap penelitian-penelitian terdahulu pada Tabel 1, penelitian ini menawarkan kebaruan dan kontribusi spesifik untuk mengatasi

keterbatasan dalam inspeksi komponen mikro elektronika menggunakan strategi *transfer learning* dan *fine tuning*.

2.2. Dioda *Bridge Rectifier*

Dioda adalah salah satu komponen elektronik yang berfungsi untuk mengalirkan arus listrik hanya dalam satu arah. Komponen ini memiliki peran penting dalam rangkaian elektronika, seperti mengubah arus bolak-balik (AC) menjadi arus searah (DC) dan menstabilkan arus DC agar tidak terpengaruh oleh perubahan beban dari sumber listrik [10]. Dioda umumnya dibuat dari bahan semikonduktor seperti silikon atau germanium yang banyak dimanfaatkan dalam berbagai perangkat serta rangkaian elektronik [4]. Penggunaannya meliputi adaptor daya, *charger*, lampu LED, hingga sirkuit proteksi untuk melindungi perangkat elektronik dari kerusakan [6]. Dioda *bridge rectifier* terdiri dari empat buah dioda yang terhubung dalam bentuk jembatan untuk konversi arus AC menjadi DC secara penuh [3].

Komponen dioda *bridge rectifier* yang digunakan sebagai objek penelitian ini adalah berjenis *single phase* dari merek *FCI Semiconductor* dengan kode KBJ208 dapat dilihat pada Gambar 1. Dioda jenis ini merupakan komponen terintegrasi yang sudah terdiri dari empat dioda di dalamnya, khusus digunakan untuk sumber listrik 1 fasa (*single-phase AC*). Komponen ini terdiri dari 4 pin komponen yang terdiri dari 2 pin *input* AC dan 2 pin *output* DC.



Gambar 1. Komponen Dioda *Bridge Rectifier* KBJ208


2.2.1. Klasifikasi Kerusakan

Dalam perspektif morfologis, terdapat empat jenis kerusakan umum pada produk industri yaitu *Gain Type Defect*, *Missing Type Defect*, *Distortion Type Defect*, dan *Substitution Type Defect* [1]. Kerusakan tipe *gain-type* mengacu pada keberadaan bagian atau elemen yang tidak diinginkan pada suatu produk, seperti kotoran, benda asing, dan sejenisnya [1]. Kerusakan tipe *missing* terjadi ketika suatu produk tidak memiliki material atau fitur yang seharusnya ada, yang dapat terlihat dalam bentuk lubang, goresan, retakan, atau komponen yang hilang [1]. Kerusakan tipe *distortion* merujuk pada perubahan bentuk atau ukuran produk yang tidak normal, misalnya melengkung, berkerut, atau mengalami deformasi [1].

Kerusakan tipe *substitution* terjadi ketika bagian dari produk digantikan oleh bahan yang salah atau tidak sesuai standar, yang dapat dikenali dari perbedaan warna, label yang salah, dan sejenisnya [1].

2.3. Convolutional Neural Network (CNN)

Deep learning adalah salah satu bidang *machine learning* yang berkembang cukup pesat dalam konteks pengenalan citra, didorong oleh kemajuan teknologi *Graphic Processing Unit* (GPU) [7]. *Convolutional Neural Network* (CNN) adalah salah satu metode *deep learning* yang dapat digunakan untuk melakukan tugas klasifikasi citra[12]. Konvolusi didefinisikan sebagai operasi linear khusus yang digunakan untuk mengekstraksi fitur, di mana sebuah kernel kecil digeser di atas *input* untuk menghasilkan *feature map*[11]. CNN terdiri dari tiga lapisan, yaitu lapisan konvolusi yang berfungsi seperti filter untuk mengekstrak fitur dari *input*, lapisan *pooling* untuk menurunkan sampel peta fitur dan mengurangi jumlah parameter, dan lapisan *fully connected* di mana setiap neuron terhubung sepenuhnya dengan lapisan sebelumnya. Lapisan *fully connected* menggabungkan semua input untuk membuat output berupa kategori klasifikasi[12].



Gambar 2. Arsitektur Umum CNN

2.4. Preprocessing


Preprocessing merupakan tahap awal dalam pengolahan citra digital yang bertujuan untuk menyiapkan data agar optimal untuk pelatihan model *deep learning*. Tahapan ini dilakukan sebelum citra diproses lebih lanjut oleh arsitektur jaringan, dengan tujuan meningkatkan kualitas visual citra untuk memudahkan proses ekstraksi fitur [13]. *Preprocessing* yang baik dapat meningkatkan performa model dalam mendeteksi dan mengklasifikasikan objek, terlebih ketika dikombinasikan dengan teknik augmentasi data [13]. Salah satu teknik penting dalam *preprocessing* adalah augmentasi data. Teknik ini menciptakan variasi buatan dari dataset asli dengan menerapkan transformasi seperti *rotasi*, *flipping*, *zooming*, *shifting*, dan perubahan *brightness* [14].

2.5. *Faster Regional Convolutional Neural Network*

Faster Regional Convolutional Neural Network (Faster R-CNN) adalah algoritma *deep neural network* yang diperkenalkan oleh Ren et al. sebagai pengembangan dari metode *Fast R-CNN* [6]. Pada algoritma *Fast R-CNN*, proses ekstraksi fitur dan pembuatan *region proposals* masih menggunakan teknik *selective search*. Namun, karena *selective search* berjalan terpisah dari CNN dan hanya bisa dijalankan di CPU membuat proses deteksi menjadi lambat. *Faster R-CNN* memperkenalkan *Region Proposal Network (RPN)* sebagai pengganti *selective search* [6].

2.5.1. *Arsitektur Faster R-CNN*

Arsitektur *Faster R-CNN* umumnya terdiri dari tiga bagian utama, yaitu CNN, RPN, dan modul deteksi *Fast R-CNN* [6]. CNN berperan dalam mengekstraksi fitur dari citra masukan sehingga menghasilkan *feature maps* yang merupakan representasi matematis yang menggambarkan karakteristik penting dari citra masukan seperti bentuk, tekstur, dan tepi objek. Representasi ini berbentuk tensor tiga dimensi (W, H, D) di mana W dan H menyatakan dimensi spasial (lebar dan tinggi), sementara D menunjukkan jumlah saluran (*depth*) yang merefleksikan banyaknya fitur yang telah diekstraksi [6]. *Feature maps* ini kemudian dimanfaatkan oleh RPN untuk mengidentifikasi area-area potensial yang kemungkinan besar mengandung objek, yang disebut sebagai *region proposal* [6]. Pada bagian *Fast R-CNN*, dilakukan proses *RoI pooling* terhadap *feature maps* dan *region proposal* yang telah diperoleh. *RoI pooling* ini bertujuan untuk menyesuaikan ukuran setiap proposal sehingga seragam dan dapat diproses oleh jaringan *fully connected* untuk klasifikasi dan regresi *bounding box* [6]. Dengan demikian, seluruh proses pada *Faster R-CNN* berjalan secara terintegrasi dan efisien dalam mendeteksi serta mengenali objek pada gambar. Desain umum arsitektur *Faster R-CNN* ditunjukkan pada Gambar 3.



Gambar 3. Arsitektur *Faster R-CNN*

Berdasarkan pada Gambar 3 diketahui bahwa tahapan utama pada arsitektur *Faster R-CNN* dapat dibagi menjadi tiga, yaitu:

1. Ekstraksi Fitur *ResNet-50*
Faster R-CNN membutuhkan *backbone* untuk memproses citra *input*. Pada penelitian ini menggunakan *ResNet-50* yang merupakan salah satu arsitektur CNN yang terdiri dari 50 lapisan, termasuk lapisan konvolusi serta *residual block* [6]. Keunggulan utama arsitektur ini terletak pada kemampuannya mengatasi permasalahan hilangnya gradien (*vanishing gradient*) melalui penggunaan *residual block*, yang memungkinkan aliran gradien tetap terjaga pada jaringan yang sangat dalam. Dalam konteks deteksi objek, *ResNet-50* sering dimanfaatkan sebagai *backbone* karena kemampuannya dalam mengekstraksi fitur secara efektif. *ResNet-50* digunakan karena terdapat sistem *bottleneck block* yang dapat mengurangi terjadinya *overfitting* pada *network*. Tahap ekstraksi fitur dilakukan pada blok *conv1_x*, *conv2_x*, *conv3_x*, dan *conv4_x* dengan *output* berupa *feature maps* [6].
2. *Sliding Windows* pada RPN
RPN merupakan algoritma yang digunakan dalam *Faster R-CNN* untuk menghasilkan *region proposals* atau calon area objek [6]. Pada tahap RPN dilakukan pergeseran *sliding windows* dengan kernel berukuran 3×3 dan *stride* 2 pada seluruh *feature maps* [6]. Hasil tahap RPN disimpan sebagai *proposal layer*, kemudian diproses pada *Fast R-CNN*.
3. *Fast R-CNN*

Pada metode *Fast R-CNN* diimplementasikan *rol pooling layer* untuk mengubah ukuran *input* yang berbeda-beda menjadi ukuran yang sama [6]. *Rol pooling layer* bertujuan untuk meningkatkan waktu pemrosesan pada *Faster R-CNN*. Setelah diperoleh output pada proses *average pooling*, kemudian *output* memasuki proses *fully connected layer* untuk menghubungkan seluruh *neuron* pada *layer* sebelumnya dan *layer* selanjutnya kemudian diperoleh *output* berupa klasifikasi kerusakan pin komponen dioda *bridge rectifier* dan *box regresi* [6].

2.5.2. Parameter *Faster R-CNN*

Faster R-CNN adalah arsitektur deteksi objek dua tahap yang menggabungkan RPN dengan *Fast R-CNN detector*. Keberhasilan model ini sangat bergantung pada konfigurasi parameter yang tepat. Beberapa parameter penting yang berpengaruh besar antara lain:

1. *Anchor Box*
Anchor box adalah kotak referensi dengan ukuran dan rasio yang berbeda yang digunakan oleh RPN untuk menghasilkan proposal kandidat objek [15]. *Anchor* menentukan kemampuan model dalam mengenali objek dari berbagai skala dan proporsi [15]. Untuk deteksi objek kecil seperti pin dioda, *anchor* berukuran kecil sangat dibutuhkan agar model mampu menangkap area kerusakan dengan lebih akurat.
2. *Learning Rate*
Learning rate adalah parameter yang menentukan seberapa besar perubahan bobot jaringan pada setiap iterasi pelatihan [15]. Nilai *learning rate* yang terlalu besar dapat membuat model tidak stabil, sedangkan nilai terlalu kecil akan membuat pelatihan menjadi sangat lambat [15].
3. *Epoch*
Epoch adalah jumlah putaran penuh seluruh dataset melalui model saat *training* [15]. Semakin banyak *epoch*, semakin lama model dilatih dan semakin besar kemungkinan model mampu mengenali pola, tetapi juga ada risiko *overfitting*.
4. *Batch Size*
Batch size menentukan jumlah sampel yang digunakan dalam satu iterasi pelatihan [15]. Batch kecil (2–8) memungkinkan pelatihan dengan memori terbatas, namun sering kali membutuhkan waktu lebih lama. Batch besar mempercepat pelatihan namun bisa kehilangan generalisasi.
5. *IoU (Intersection over Union) Threshold*
IoU digunakan untuk mengukur tumpang tindih antara *bounding box* prediksi dan *ground truth* [15]. *Threshold* ini menentukan apakah prediksi dianggap benar. Semakin tinggi nilai *threshold*, maka prediksi harus

sangat akurat. Pemilihan *threshold* yang tepat dapat meningkatkan sensitivitas deteksi, terutama pada objek kecil.

6. *Backbone Network*

Backbone network adalah komponen penting yang berfungsi sebagai jaringan ekstraksi fitur (*feature extractor*) [15]. Peran utama *backbone* adalah mengubah citra masukan menjadi representasi fitur dalam bentuk *feature maps* yang mengandung informasi spasial dan semantik yang dibutuhkan oleh RPN serta modul klasifikasi dan regresi.

7. *Non-Maximum Suppression (NMS) Threshold*

Non-Maximum Suppression (NMS) adalah teknik yang digunakan untuk menghapus deteksi duplikat pada objek yang sama dengan mengeliminasi *bounding box* yang memiliki tingkat tumpang tindih tinggi (IoU) [15]. Proses ini memastikan hanya satu deteksi dengan skor tertinggi yang dipertahankan. Pemilihan *threshold* yang terlalu rendah bisa menyebabkan kehilangan deteksi pada objek yang valid (*over-suppression*), sedangkan *threshold* yang terlalu tinggi bisa menyebabkan deteksi ganda (*duplicate detections*). Oleh karena itu, pengaturan *threshold NMS* yang tepat dapat meningkatkan *precision* deteksi serta mencegah prediksi yang berlebihan.

2.6. Feature Pyramid Network (FPN)

Feature Pyramid Network (FPN) adalah arsitektur jaringan yang dikembangkan untuk menangani tantangan mendasar dalam computer vision, yaitu mendeteksi objek pada berbagai skala dengan biaya komputasi yang efisien. Pada jaringan saraf konvolusional tradisional, lapisan terdalam memiliki informasi semantik yang kuat namun resolusinya rendah, sehingga kurang efektif untuk mendeteksi objek kecil. FPN mengatasi masalah ini dengan memanfaatkan bentuk piramida hierarkis dari *ConvNet* untuk membangun piramida fitur yang memiliki semantik kuat di semua level skala[16]. FPN sebagai fitur ekstraktor mengambil citra sebagai *input* dan menghasilkan *feature map* di berbagai level, dengan menggunakan konvolusi dan pembangunan piramida yang melibatkan *bottom-up pathway* dan *top-down pathway*[12]. FPN terbukti meningkatkan *Average Recall (AR)* pada objek kecil dibandingkan *baseline* RPN skala tunggal. Hal ini menjadikan FPN sangat relevan untuk diterapkan dalam inspeksi visual cacat mikroskopis pada komponen elektronik[16].

2.7. Transfer Learning

Dalam pengembangan model *Deep Learning*, ketersediaan data latih dalam jumlah besar seringkali menjadi kendala utama. Melatih dari awal membutuhkan dataset berskala masif untuk mencegah *overfitting* dan mencapai konvergensi yang baik. Untuk mengatasi keterbatasan jumlah sampel citra cacat pada

penelitian ini, diterapkan metode Transfer Learning. *Transfer Learning* didefinisikan sebagai metode untuk meningkatkan fungsi prediksi pada domain target dengan memanfaatkan pengetahuan yang telah dipelajari dari domain sumber dan tugas sumber[17].

Penelitian ini tidak membangun inisialisasi bobot secara acak, melainkan menggunakan model *backbone ResNet-50 pre-trained* pada dataset *ImageNet*. Dataset *ImageNet* merupakan standar *benchmark* global yang terdiri dari lebih dari 1,2 juta citra dengan 1.000 kategori kelas objek yang berbeda[18]. Penggunaan *pre-trained model* bertujuan untuk mentransfer kemampuan ekstraksi fitur generik yang telah dimiliki oleh model *ImageNet*. Fitur-fitur visual dasar seperti garis, sudut, kurva, dan tekstur yang telah dipelajari dari jutaan gambar tersebut dapat digunakan kembali untuk mengenali struktur fisik pada komponen dioda, sehingga mempercepat proses pelatihan dan meningkatkan akurasi deteksi meskipun menggunakan dataset yang terbatas.


Untuk mengadaptasi fitur generik dari *ImageNet* agar sesuai dengan karakteristik spesifik kerusakan pin dioda, diterapkan strategi *Fine-Tuning*. *Fine-Tuning* didefinisikan sebagai proses penyesuaian kembali parameter model yang telah dilatih dengan melatihnya menggunakan dataset baru yang lebih spesifik[fine tuning][19]. Transferabilitas fitur pada *Deep Neural Networks*, lapisan awal jaringan cenderung mempelajari fitur umum, sedangkan lapisan akhir mempelajari fitur yang sangat spesifik terhadap dataset aslinya[19].

2.8. User Interface

Sistem *user interface* dibangun menggunakan *framework* PyQt5 yang menyediakan *binding* bahasa Python untuk *toolkit* Qt. Pemilihan PyQt5 didasarkan pada kemampuannya untuk terhubung secara *seamless* dengan pustaka pengolahan citra dan *Deep Learning*. Sistem ini mengintegrasikan pustaka PyTorch sebagai mesin inferensi di latar belakang, di mana hasil prediksi dari model *Faster R-CNN* langsung dikirimkan kepada pengguna secara instan[20].

Bab 3. Metodologi Penelitian

3.1. Perancangan Penelitian



Gambar 4. Blok Diagram Penelitian

3.1.1. Studi Literatur

Pada tahap ini dilakukan pemahaman literatur dengan mengkaji berbagai sumber seperti jurnal internasional, buku referensi, serta penelitian terdahulu yang berkaitan dengan kerusakan objek, pengolahan citra digital, dan metode klasifikasi menggunakan *Faster R-CNN*. Studi literatur ini bertujuan untuk memperoleh pemahaman yang mendalam mengenai teori-teori yang relevan.

3.1.2. Persiapan Dataset

Pada tahap ini dilakukan pengumpulan dataset citra komponen dioda *bridge rectifier* KBJ208. Dalam satu pengambilan citra, terdapat satu *tray* yang memuat 6 *pcs* dioda. Target akuisisi data adalah sebanyak 150 citra *tray* dengan total objek pin teranotasi (*bounding box*) ditargetkan mencapai 3.600 sampel dengan distribusi kelas kerusakan yang merata.

3.1.2.1. Konfigurasi Modul Akuisisi

Untuk menciptakan kondisi pengambilan data yang statis dan terkontrol (*controlled environment*), digunakan alat bantu fiksasi berupa *custom tray* berbahan PLA (3D Printing) yang ditempatkan pada modul penyangga berbasis aluminium profile seri 2020 dengan jarak tetap antara camera dan *base* akrilik sebesar 8cm. Sistem ini dilengkapi dengan pencahayaan yang dikondisikan menggunakan teknik *diffused lighting* dengan intensitas cahaya 1240 lux seperti pada Gambar 5. Teknik ini diterapkan untuk meminimalkan bayangan dan pantulan cahaya pada permukaan logam dioda.




Gambar 5. Realisasi Konfigurasi Hardware akuisisi citra

3.1.2.2. Perancangan Tray

Adapun desain mekanikal *tray* dirancang menyesuaikan dimensi fisik Dioda Bridge Rectifier agar posisi objek tetap konsisten selama proses pengambilan data.

1) Desain Mekanikal


Desain 3D mekanikal dirancang menggunakan *solidwork* dengan hasil pada Gambar 6.



Gambar 6. Desain Mekanikal Tray

2) Dimensi

Satuan yang digunakan dalam rancangan desain pada Gambar 7 ini adalah millimeter.




Gambar 7. Dimensi Desain Mekanikal

3.1.2.3. Persiapan Sampel

Penerapan metode simulasi kerusakan (*controlled defect simulation*) dalam penelitian ini didasari oleh kelangkaan data cacat alami yang umum terjadi pada lini produksi dengan efisiensi tinggi, serta adanya kendala aksesibilitas fisik dan kebijakan kerahasiaan data industri yang membatasi pengambilan data primer di lapangan. Oleh karena itu, pendekatan rekayasa fisik pada sampel komponen dilakukan sebagai solusi guna menjamin ketersediaan dataset dalam kerangka penelitian.

Pendekatan ini mengintegrasikan spesifikasi teknis pabrikan (*Datasheet*) dan standar industri IPC-A-610 sebagai acuan. IPC-A-610 merupakan standar konsensus industri yang menetapkan kriteria penerimaan kualitas untuk perakitan elektronika.



Gambar 8. Datasheet Dioda

Dalam konteks komponen *Through-Hole* seperti Dioda KBJ208, definisi operasional untuk setiap kelas dalam penelitian ini ditetapkan sebagai berikut:

Tabel 2. Matriks Kriteria

Kelas	Datasheet	Standar IPC-A-610
Normal	- Jarak antar kaki presisi pada 5.1 mm (± 0.3 mm) - Dimensi panjang kaki memenuhi standar 13 mm	Kaki lurus dan sejajar memenuhi syarat untuk masuk ke lubang PCB
<i>Bent</i>	- Deviasi posisi lateral kaki melebihi toleransi > 0.3 mm dari titik tengah nominal 5.1 mm - Garis tepi (edge) pin terlihat melengkung atau membelok	<i>Defect - Component Mounting:</i> Deformasi bentuk pin yang berpotensi menyebabkan kegagalan pemasangan (<i>insertion failure</i>)
<i>Broken</i>	- Dimensi lebar kaki berkurang signifikan dari 1 mm atau panjang sisa kaki jauh di bawah 13 mm - Ujung pin terlihat tumpul, rata (<i>flat</i>), tidak beraturan (bekas patahan), dan kehilangan profil runcingnya	<i>Defect - Lead Damage:</i> Hilangnya integritas material atau panjang pin tidak mencukupi untuk proses penyolderan (<i>insufficient lead length</i>).

3.1.2.4. Preprocessing Citra

Pengambilan citra dilakukan dari satu sudut pandang tetap yaitu *top view* menggunakan kamera *USB* resolusi 4K dengan lensa tipe *fisheye* yang diposisikan secara tegak lurus terhadap komponen dioda. Penggunaan lensa *fisheye* pada tahap akuisisi menghasilkan distorsi radial (*barrel distortion*) yang signifikan, menyebabkan objek terlihat melengkung, terutama pada area tepi citra. Kondisi ini dapat menurunkan akurasi deteksi model yang mengandalkan fitur bentuk geometris. Untuk mengatasi hal tersebut, proses koreksi distorsi (*Lens Undistortion*) diterapkan untuk mengeliminasi efek *barrel distortion* pada citra dengan memetakan ulang koordinat piksel ke dalam bidang pandang yang datar dan lurus.

3.1.2.5. Anotasi Dataset

Proses anotasi bertujuan untuk memberikan informasi *ground truth* pada citra *dataset* agar model *Faster R-CNN* dapat mempelajari fitur visual dari setiap kelas. Anotasi dilakukan secara manual berupa meletakkan *bounding box* pada setiap pin dioda sesuai kelasnya menggunakan perangkat lunak *Roboflow* dengan

format *output* Pascal VOC (XML).

3.1.3. Perancangan Model *Faster R-CNN*

Arsitektur *Faster R-CNN* terdiri dari tiga komponen utama, yaitu *backbone ResNet-50*, RPN, dan modul deteksi *fast R-CNN*.

1) *Backbone ResNet-50*

Dalam penelitian ini digunakan *ResNet-50* yang telah dilatih sebelumnya (*pretrained*) pada dataset *ImageNet*. Penggunaan *pretrained ResNet-50* memungkinkan model untuk memanfaatkan pengetahuan awal terhadap pola visual umum seperti garis, bentuk dan tekstur sehingga proses pelatihan dapat lebih efisien dan akurat meskipun data terbatas. Penerapan model ini tidak dilakukan secara mentah, melainkan melalui proses *Fine-Tuning*. Layer konvolusi awal dibekukan untuk mempertahankan fitur universal, sementara tiga blok residual terakhir (*layer 2, 3, dan 4*) diatur sebagai *trainable* menggunakan dataset Dioda KBJ208. Hal ini memungkinkan model untuk memfokuskan kapasitas pembelajarannya pada fitur spesifik objek penelitian, seperti karakteristik pantulan logam pada kaki komponen dan pola kelengkungan geometri pada pin.

2) *Region Proposal Network (RPN)*

Sesuai dengan konfigurasi arsitektur, penelitian ini menetapkan lima tingkat skala anchor yaitu [8, 16, 32, 64, 128] piksel guna menyesuaikan variasi ukuran objek dari cacat *mikro*. Rasio aspek *anchor* diatur pada [0.5, 1.0, 2.0] untuk menyesuaikan geometri pin yang cenderung vertikal. Dalam proses penyaringan proposal, diterapkan nilai *threshold* IoU sebesar 0.7 pada tahapan *Non-Maximum Suppression* (NMS). Untuk menjaga efisiensi komputasi tanpa mengurangi akurasi, jumlah proposal dibatasi secara ketat, yaitu menyeleksi 2000 kandidat dengan skor tertinggi pada tahap awal (*pre-NMS*) menjadi 1000 proposal prioritas (*post-NMS*) untuk diteruskan ke tahap klasifikasi *Fast R-CNN*.

3) *Fast R-CNN*

Pada tahapan akhir, digunakan mekanisme *Multi-Scale Region of Interest (RoI) pooling* dengan ukuran output spasial 7×7 piksel. Mekanisme ini bertugas menyamakan dimensi fitur dari berbagai ukuran proposal yang dihasilkan RPN sebelum masuk ke tahap klasifikasi. Berbeda dengan RoI Pooling standar, *RoI Align* memberikan presisi lokalisasi yang lebih tinggi dengan menghindari kuantisasi koordinat, yang krusial untuk objek tipis seperti kaki komponen.

3.1.4. *Preprocessing Dataset*

Tahap preprocessing dataset dilakukan untuk mempersiapkan data sebelum dilatih menggunakan model *Faster R-CNN*. Langkah-langkah *preprocessing* yang dilakukan meliputi:

1) *Split Dataset*

Pada tahapan ini dataset total yang telah dianotasi dibagi menggunakan teknik *Stratified Random Sampling*, yang bertujuan untuk memastikan distribusi setiap kelas kerusakan tetap proporsional dan seimbang di dalam setiap sub-*folder*. Rasio pembagian dataset ditetapkan sebesar 80 (*train*) : 10 (*validation*) : 10 (*test*).

2) *Augmentasi*

Strategi augmentasi data diterapkan menggunakan pendekatan dinamis (*On-the-Fly*) berbasis pustaka *Albumentations*. Berbeda dengan metode statis, manipulasi citra dilakukan secara *real-time* di dalam memori sehingga menciptakan variasi visual yang berbeda pada setiap *epoch* tanpa membebani media penyimpanan fisik. Hal ini menciptakan variasi data yang nyaris tak terbatas sehingga model tidak pernah melihat pola *input* yang persis sama secara berulang. Augmentasi secara eksklusif diaplikasikan pada data *train* guna melatih ketahanan model terhadap variabilitas lingkungan, sementara data *validation* dan *test* dipertahankan dalam kondisi murni.

3) *Normalisasi*

Bertujuan untuk menyelaraskan format data *input* dengan persyaratan arsitektur *pre-trained* model *ResNet-50* serta memastikan integritas label geometris. Proses ini diterapkan secara seragam baik pada data *train*, data *validation*, dan data *testing*.

3.1.5. *Training Model Faster R-CNN*

Tahap *training* ini menetapkan strategi *hyperparameter* yang akan digunakan untuk melatih arsitektur *Faster R-CNN*. Pelatihan akan dilakukan dengan pendekatan *Fine-Tuning*, di mana hanya lapisan-lapisan akhir pada *backbone ResNet-50* yang dilatih ulang, sementara lapisan awal dibekukan untuk mempertahankan fitur visual universal dari *transfer learning*. Strategi parameter ini akan divariasikan dalam beberapa skenario eksperimen untuk menemukan konfigurasi optimal dalam mendeteksi dan mengklasifikasikan kerusakan pin dioda. Proses *training* bertujuan untuk mengoptimalkan parameter internal model berupa bobot dan bias agar dapat meminimalkan nilai *loss* dalam memprediksi fitur objek pada data *train*. Sementara itu, proses *validation* bertujuan untuk mengukur kemampuan generalisasi model dalam mengenali data baru yang belum pernah dilihat sebelumnya.

3.1.6. Testing Model Faster R-CNN

Setelah proses *training* selesai dan bobot model terbaik dari setiap skenario berhasil disimpan, model diuji secara independen menggunakan *dataset test*. Data ini belum pernah dilihat oleh model selama proses training, sehingga mampu memberikan evaluasi performa yang objektif. Pada tahap ini, model akan memprediksi lokasi *bounding box* dan label kelas pada citra uji. Hasil prediksi kemudian dibandingkan dengan *ground truth* untuk mengukur seberapa akurat model dalam mendeteksi dan mengklasifikasikan kerusakan pin dioda KBJ208.

3.1.7. Evaluasi Model

Evaluasi model dilakukan secara komprehensif mencakup kinerja *Region Proposal Network* (RPN), akurasi deteksi akhir, dan analisis kesalahan. Evaluasi dilakukan secara bertingkat menggunakan metrik-metrik berikut:

- 1) **RPN Recall**
Kinerja RPN dievaluasi untuk memastikan model mampu menemukan kandidat lokasi objek. Metrik yang digunakan adalah *RPN Recall (Average Recall)*. Metrik ini mengukur proporsi *Ground Truth* yang berhasil ter-cover oleh setidaknya satu *anchor box proposal* dengan nilai IoU ≥ 0.5 .
- 2) **Mean Average Precision (mAP)**
Sebagai standar utama evaluasi deteksi objek, penelitian ini menggunakan metrik mAP yang dihitung berdasarkan *rata-rata Average Precision (AP)* dari seluruh kelas. Perhitungan dilakukan menggunakan pustaka *TorchMetrics* dengan standar pelaporan PASCAL VOC. Nilai mAP dihitung pada ambang batas IoU tunggal sebesar 0,50. Metrik ini memberikan gambaran performa deteksi secara umum.
- 3) **Metrik Klasifikasi Per-Objek**
 - **Precision:** Tingkat keandalan prediksi model (meminimalkan *False Positive*).
 - **Recall:** Tingkat sensitivitas model dalam menemukan seluruh cacat (meminimalkan *False Negative*).
 - **F1-Score:** Rata-rata antara *Precision* dan *Recall* untuk melihat keseimbangan performa model.
- 4) **Confusion Matrix**
Confusion matrix untuk menganalisis secara visual kesalahan klasifikasi antar kelas, serta untuk mengidentifikasi kelas yang lebih sulit dikenali oleh model.
- 5) **Loss Function Analysis**
Evaluasi proses pembelajaran model dilakukan dengan memantau grafik *Loss Function* selama proses pelatihan dan validasi. Komponen tersebut adalah *train loss*, *validation loss*, *RPN Objectness Loss*, *RPN Box Regression Loss*, *Classifier Loss*, dan *Box Regression Loss*.

3.1.8. Implementasi *User Interface*

Rancangan *user interface* dibangun menggunakan pustaka **PyQt5** dan terintegrasi dengan modul klasifikasi *Faster R-CNN* yang memuat model terbaik.



Gambar 9. Rancangan *User Interface*

- 1) *Select Folder*
Berfungsi untuk memilih lokasi folder penyimpanan hasil deteksi yang telah diklasifikasi.
- 2) *Start*
Berfungsi untuk memulai sistem klasifikasi, tombol operasional akan dapat digunakan.
- 3) *Finish*
Berfungsi untuk mengakhiri sistem klasifikasi, tombol operasional tidak akan dapat digunakan.
- 4) *Statistik*
Tabel ini menampilkan akumulasi hasil klasifikasi dari citra terakhir yang diproses.
- 5) *Capture*
Berfungsi untuk melakukan akuisisi citra secara langsung dari perangkat kamera yang terhubung. Citra yang diambil kemudian ditampilkan secara otomatis pada area pratinjau, di mana citra hasil tangkapan digunakan sebagai data *input* untuk proses klasifikasi.
- 6) *Classify*
Berfungsi untuk menjalankan proses klasifikasi, sistem akan memuat model *Faster R-CNN* yang telah dilatih dan melakukan inferensi, dan menampilkan hasil klasifikasi dalam bentuk visual (*bounding box*) beserta jenis kelasnya.
- 7) *Save*

- Berfungsi untuk menyimpan gambar hasil klasifikasi ke folder tertentu.
- 8) *Reset*
 Berfungsi untuk menghapus citra yang diambil sebelumnya untuk mengambil citra baru selanjutnya.

3.1.9. Pengujian Sistem

Pada tahap ini dilakukan pengujian validasi sistem secara fungsional melalui *User Interface* yang telah dibangun. Pengujian ini bertujuan untuk mensimulasikan skenario penggunaan nyata di mana sistem menerima *input* citra baru yang belum pernah digunakan dalam proses *training* maupun pengujian *testing* sebelumnya. Dalam tahap ini, *output* visual pada layar monitor (hasil *bounding box* dan label kelas) dibandingkan secara manual dengan kondisi fisik aktual komponen oleh pengamat manusia. Metrik evaluasi yang digunakan untuk mengukur kinerja sistem klasifikasi adalah *Precision*, *Recall*, *Accuracy* dan *F1-Score*.

$$Precision = \frac{TP}{FP + TP} * 100\% \quad (2.1)$$

$$Recall = \frac{TP}{FN + TP} * 100\% \quad (2.2)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} * 100\% \quad (2.3)$$

$$F1 - Score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} * 100\% \quad (2.4)$$

Dengan keterangan:

- TP (*True Positive*): Kondisi di mana sistem mendeteksi kerusakan dan kondisi aktual komponen memang benar-benar rusak.
- TN (*True Negative*): Kondisi di mana sistem menyatakan normal dan kondisi aktual komponen memang benar-benar normal.
- FP (*False Positive*): Kondisi di mana sistem mendeteksi kerusakan padahal kondisi aktual komponen normal.
- FN (*False Negative*): Kondisi di mana sistem gagal mendeteksi kerusakan padahal kondisi aktual komponen rusak.

3.2. Alat dan Bahan

Pada penelitian diperlukan alat dan bahan dalam pengerjaannya. Berikut merupakan rincian pada alat dan bahan yang diperlukan pada Tabel 3.

Tabel 3. Alat dan Bahan

No	Alat/Bahan	Harga	Jumlah	Total	Keterangan
1	Kamera ELP-USB4K02AF-KL21	-	1	-	Milik Prodi
2	Laptop	-	1	-	Milik Pribadi
3	Dioda <i>Bridge Rectifier</i>	Rp2.000	112	Rp224.000	<i>FCI Semiconductor</i> KBJ208
4	<i>Custom Tray</i>	Rp45.000	1	-	Milik Pribadi
5	<i>Mounting Stand</i>	-	1	-	Milik Prodi
6	<i>Stand Lighting</i>	-	1	-	Milik Pribadi
Total				Rp224.000	Dana Pribadi

3.3. Perancangan Pengujian

Perancangan pengujian dilakukan melalui pengujian performa model yang dilakukan dalam 6 skenario pengujian dengan variasi parameter untuk memilih konfigurasi model terbaik. Dan dilakukan pengujian terhadap sistem *user interface* dengan menggunakan citra baru yang berasal dari luar *dataset* pelatihan.

3.3.1. Pengujian Performa Model

Untuk memperoleh konfigurasi terbaik dari model *Faster R-CNN* dalam mengklasifikasikan kerusakan pin dioda, dilakukan pengujian performa model dengan beberapa variasi parameter pelatihan. Setiap kombinasi parameter disusun ke dalam enam skenario berbeda sebagaimana ditunjukkan pada Tabel 4.

Tabel 4. Skenario Pengujian

Parameter	Skenario					
	A	B	C	D	E	F
<i>Epoch</i>	100	300	500	100	500	300
<i>Learning Rate</i>	0,001	0,0005	0,0001	0,0005	0,0001	0,001
<i>Batch Size</i>	1	2	4	1	4	2
<i>Optimizer</i>	SGD	SGD	SGD	Adam	Adam	Adam


Hasil pengujian ini digunakan untuk menentukan konfigurasi *hyperparameter* terbaik yang akan dijadikan sebagai final model melalui perbandingan *classification report*-nya.

Tabel 5. Perbandingan Hasil Pengujian Skenario

No	Skenario	Kelas	<i>mAP</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
1	A	Normal				
		<i>Bent</i>				
		<i>Broken</i>				
2	B	Normal				
		<i>Bent</i>				
		<i>Broken</i>				
3	C	Normal				
		<i>Bent</i>				
		<i>Broken</i>				
4	D	Normal				
		<i>Bent</i>				
		<i>Broken</i>				
5	E	Normal				
		<i>Bent</i>				
		<i>Broken</i>				
6	F	Normal				
		<i>Bent</i>				
		<i>Broken</i>				

3.3.2. Pengujian *User Interface*

Pengujian ini dilakukan dengan menggunakan 15 citra yang berasal dari luar dataset sebelumnya.



Gambar 10. Flowchart pengujian sistem *user interface*

- 1) Mulai
Proses dimulai ketika pengguna menjalankan aplikasi sistem klasifikasi.
- 2) *User Interface* dibuka
Setelah program dijalankan, *user interface* ditampilkan untuk memfasilitasi proses unggah citra dan visualisasi hasil klasifikasi.
- 3) Tombol '*Capture*' ditekan
Pengguna menekan tombol '*Capture*' untuk mengambil citra komponen dioda secara langsung dari kamera yang terhubung sebagai citra input yang akan diklasifikasi.
- 4) Gambar ditampilkan
Setelah citra diambil, gambar akan ditampilkan secara otomatis dalam *user interface*.
- 5) Tombol '*Classify*' ditekan
Pengguna kemudian menekan tombol '*Classify*' untuk memulai proses klasifikasi.
- 6) Menampilkan hasil klasifikasi visual
Hasil deteksi berupa *bounding box* dan label kelas akan ditampilkan secara visual pada citra tersebut.
- 7) Hasil klasifikasi diakumulasi dalam statistik
Selain tampilan visual, sistem juga akan menampilkan hasil klasifikasi dalam bentuk statistik jumlah objek berdasarkan kelas yang terdeteksi.

- 8) Apakah 15 citra sudah diuji?
Jika belum, proses dapat diulang mulai dari tahap menekan tombol 'Capture'.
- 9) Selesai
Jika jumlah citra telah mencapai 15, maka proses pengujian dinyatakan selesai.

Hasil prediksi dibandingkan dengan label kebenarannya dan ditulis dalam bentuk tabel yang memuat data label *actual* dan hasil prediksi pada tabel 6.

Tabel 6. Perbandingan Hasil Pengujian

No Gambar	No Pin	Label <i>Actual</i>	Hasil Prediksi
1	1		
	2		
	...		
	24		
2	1		
	2		
	...		
	24		
...	...		
15	1		
	2		
	...		
	24		

Kemudian dari hasil pengujian tersebut didapat hasil *confussion matrix* dan ditulis dalam tabel 7.

Tabel 7. Confussion Matriks 3x3

		Prediksi		
		Normal	<i>Bent</i>	<i>Broken</i>
Aktual	Normal			
	<i>Bent</i>			
	<i>Broken</i>			

Selanjutnya menghitung nilai evaluasi hasil pengujian dengan perhitungan manual dan ditulis pada tabel 8 kemudian menganalisa hasilnya.

Tabel 8. Perhitungan Evaluasi Manual

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Normal			
<i>Broken</i>			
<i>Bent</i>			
<i>Accuracy</i>			


Bab 4. Hasil dan Pembahasan

4.1. Hasil Pengolahan Dataset

Pada sub-bab ini dijelaskan hasil dari persiapan teknis untuk kebutuhan penyusunan *dataset*.

4.1.1. Hasil Fabrikasi Tray


Realisasi desain tray dari Bab 3 dilakukan melalui proses fabrikasi menggunakan 3D *printing* berbahan filamen PLA. Untuk menjamin stabilitas posisi objek, *tray* didesain dengan ketebalan 5 mm, di mana slot peletakan komponen memiliki kedalaman 4 mm. Spesifikasi ini memungkinkan dioda masuk sepenuhnya ke dalam slot sehingga mencegah pergeseran saat pengambilan gambar. Dari sisi visual, dipilih warna filamen Hitam *Matte* yang memberikan kontras maksimal terhadap pin dioda berbahan logam perak mengkilap.




Gambar 11. Hasil fabrikasi *custom tray*

4.1.2. Hasil Pengumpulan Data Sampel

Untuk memenuhi kebutuhan data pada kelas kerusakan, dilakukan modifikasi fisik secara manual pada pin komponen. Pin dibengkokkan dengan derajat yang bervariasi untuk membuat sampel kelas *Bent*, dan dipotong pada ukuran berbeda untuk menghasilkan sampel kelas *Broken*. Hal ini dilakukan agar model dapat mempelajari berbagai kemungkinan pola kerusakan yang mungkin terjadi di kondisi nyata.



Gambar 12. Pin *Bent*



Gambar 13. Pin Broken



Gambar 14. Pin Normal

4.1.3. Hasil Pengambilan Citra Dataset

Pengambilan citra dilakukan menggunakan kamera resolusi 4K dengan lensa *fisheye*. Untuk menjamin konsistensi kualitas data, diterapkan mekanisme penanda posisi pada sebagai acuan agar *tray* selalu berada tepat di tengah area pandang kamera. Selanjutnya, kamera melalui tahap koreksi distorsi (*undistortion*) dengan program sebelum digunakan dalam pengambilan citra *dataset*. Hal ini dilakukan untuk memastikan fitur geometri pin dipelajari dalam kondisi tegak lurus. Perbedaan karakteristik visual antara data mentah dan data hasil koreksi dapat dilihat pada Gambar 15 dan Gambar 16.



Gambar 15. Citra asli



Gambar 16. Citra hasil *undistorted*

Namun, karakteristik dataset ini memiliki distorsi piksel (*pixel stretching*) pada area sudut citra sebagai efek samping dari proses pelurusan digital lensa *fisheye*. Fenomena ini menyebabkan sedikit penurunan ketajaman pada objek yang berada di posisi pinggir ekstrem.

4.1.4. Pelabelan Dataset

Setelah proses akuisisi, dilakukan pelabelan pada pin komponen untuk memberikan informasi kepada model mengenai kelas dan lokasi objek yang akan dideteksi menggunakan *platform Roboflow*.



Gambar 17. Pelabelan Dataset dalam satu tray

Proses anotasi dilakukan menggunakan format Pascal VOC yang menghasilkan file berekstensi (.xml). Setiap file XML memuat informasi metadata citra seperti nama file, resolusi gambar, nama kelas (*class name*), dan koordinat *bounding box* (X_{min} , Y_{min} , X_{max} , Y_{max}).

```

▼ <annotation>
  <folder/>
  <filename>0010_jpg.rf.043098ba8786e5f6bf5b63f34d55efce.jpg</filename>
  <path>0010_jpg.rf.043098ba8786e5f6bf5b63f34d55efce.jpg</path>
  ▼ <source>
    <database>roboflow.com</database>
  </source>
  ▼ <size>
    <width>1280</width>
    <height>720</height>
    <depth>3</depth>
  </size>
  <segmented>0</segmented>
  ▼ <object>
    <name>normal</name>
    <pose>Unspecified</pose>
    <truncated>0</truncated>
    <difficult>0</difficult>
    <occluded>0</occluded>
    ▼ <bndbox>
      <xmin>977</xmin>
      <xmax>995</xmax>
      <ymin>174</ymin>
      <ymax>323</ymax>
    </bndbox>
  </object>

```

Gambar 18. Struktur File Anotasi (XML)

4.1.5. Statistik *Dataset*

Sebanyak **244 citra digital** dengan format (.JPG) dengan dimensi 1280x720 berhasil diakuisisi sebagai dataset utama. Distribusi total objek berdasarkan kelas kerusakan disajikan pada Tabel 9

Tabel 9. Distribusi Kelas

No	Kelas	Jumlah Objek (<i>Instances</i>)	Persentase (%)
1	Normal	2092	35,71%
2	<i>Bent</i>	1907	32,55%
3	<i>Broken</i>	1859	31,74%
Total		5858	100%

Dataset total dibagi ke dalam tiga jenis dataset *Training*, *Validation*, dan *Testing* dengan rasio pembagian **80:10:10**.

Tabel 10. Hasil Pembagian Dataset


No	Subset Data	Jumlah Citra	Jumlah Pin		
			Normal	Bent	Broken
1	<i>Training</i>	197	1722	1528	1480
2	<i>Validation</i>	22	204	158	166
3	<i>Testing</i>	25	166	221	213

4.2. Tahapan *Preprocessing*

Data citra melalui tahapan *preprocessing* untuk memastikan format *dataset* sesuai dengan arsitektur *ResNet-50*.

4.2.1. Normalisasi Statistik

Setiap citra *input* dinormalisasi menggunakan parameter statistik dataset *ImageNet*, yaitu *mean* [0.485, 0.456, 0.406] dan *standard deviation* [0.229, 0.224, 0.225]. Langkah ini krusial karena model menggunakan bobot *pretrained* yang dilatih pada distribusi warna tersebut. Normalisasi ini menyelaraskan histogram warna citra pin dioda dengan ekspektasi model, mempercepat konvergensi *loss* pada awal *training*.



Gambar 19. Visualisasi Normalisasi

4.2.2. Implementasi Augmentasi *On-Fly*

Augmentasi ini hanya diterapkan pada proses *training*. Berikut adalah rincian transformasi yang diterapkan beserta konfigurasi teknisnya:

- 1) Rotasi Acak [*A.Rotate(limit=1.8, p=0.5)*]

Batas rotasi $\pm 1.8^\circ$ dengan probabilitas muncul 50%. Rotasi dibatasi pada sudut yang sangat kecil, rotasi yang terlalu besar akan menyebabkan *Bounding Box* menjadi miring dan membesar secara signifikan. Tujuannya untuk mensimulasikan kondisi di mana posisi *tray* atau komponen tidak benar-benar lurus sempurna saat diletakkan di bawah kamera.




Gambar 20. Visualisasi Rotasi Acak

- 2) Variasi Pencapaian [*A.RandomBrightnessContrast(brightness_limit=0.15, contrast_limit=0.15, p=0.5)*]


Variasi kecerahan dan kontras hingga $\pm 15\%$ dengan probabilitas 50%. Pin dioda terbuat dari bahan logam yang memiliki sifat reflektif. Perubahan intensitas cahaya eksternal dapat mengubah tampilan kilauan pada batang

pin. Tujuannya untuk meningkatkan ketahanan model terhadap perubahan kondisi pencahayaan lingkungan.



Gambar 21. Visualisasi Variasi Pencahayaan

- 3) Pengaburan Citra [$A.Blur(blur_limit=(3, 5), p=0.15)$]
Menggunakan kernel blur ukuran 3x3 hingga 5x5 dengan probabilitas rendah 15%. Menerapkan filter *smoothing* ringan pada citra dengan tujuan mensimulasikan potensi ketidaksempurnaan fokus kamera atau getaran mikro pada *rig* kamera yang menyebabkan citra menjadi sedikit tidak tajam. Ini melatih model agar tidak terlalu bergantung pada tepi (*edge*) yang tajam sempurna.



Gambar 22. Visualisasi Blur

- 4) *Random Crop* [$A.RandomCrop(width=900, height=600, p=0.3)$]
Memotong citra secara acak menjadi ukuran 900x600 piksel dengan probabilitas 30%. Citra asli berukuran 1280x720 dipotong menjadi bagian yang lebih kecil. Karena *Random Crop* membuang sebagian informasi tepi model dipaksa untuk tidak menghapal posisi.



Gambar 23. Visualisasi *Random Crop*

5) *Bbox Params*


Memastikan bahwa jika proses *Random Crop* memotong sebagian besar tubuh pin (menyisakan $<10\%$), maka label kotak tersebut akan dihapus agar tidak membingungkan model dengan data sampah. Menjaga integritas data label agar selalu sinkron dengan transformasi geometri yang dilakukan pada citra.

4.3. Visualisasi *Feature Map* dan Tahapan Deteksi

Untuk memahami bagaimana model memproses citra *input* dan mengidentifikasi kerusakan pada dioda, dilakukan visualisasi pada *intermediate layers*.

4.3.1. Hasil Visualisasi *Backbone Resnet50*


Visualisasi lapisan awal pada Gambar 24 bertugas mengekstraksi fitur visual seperti garis, tepi, dan sudut. Fitur-fitur ini bersifat universal yang artinya garis lurus pada dataset *ImageNet* memiliki karakteristik matematis yang sama dengan garis lurus pada pin dioda. Membekukan lapisan ini mencegah model belajar ulang hal yang sudah dikuasainya.




Gambar 24. Visualisasi *Resnet50 Output Layer 1*

Visualisasi lapisan akhir pada Gambar 25, Gambar 26, dan Gambar 27 bertugas menyusun fitur menjadi representasi objek yang kompleks dan spesifik, seperti tekstur, pola retakan mikro, dan bentuk geometris bengkok. Dengan melatih ulang


lapisan ini, model dipaksa untuk mengabaikan fitur spesifik *ImageNet* dan menggantinya dengan fitur spesifik komponen elektronik.



Gambar 25. Visualisasi *Resnet50* Output Layer 2



Gambar 26. Visualisasi *Resnet50* Output Layer 3




Gambar 27. Visualisasi *Resnet50* Output Layer 4

4.3.2. Hasil Visualisasi Fitur FPN (*Feature Map Analysis*)

Untuk memvalidasi pemahaman model terhadap karakteristik visual objek, dilakukan analisis kualitatif dengan memvisualisasikan *feature maps* yang dihasilkan oleh modul FPN yang kemudian menjadi *input* bagi RPN. Visualisasi dilakukan dengan menampilkan tingkat aktivasi neuron pada empat layer keluaran FPN (P2, P3, P4, dan P5) terhadap sampel yang memuat kondisi cacat.


- 1) *Layer* P5 : Sematik dan Konteks Posisi

Layer ini memuat banyak akan informasi semantic namun kurang dalam detail spasial.




Gambar 28. Visualisasi FPN Layer P5

- 2) *Layer P4*: Geometri dan Bentuk Global
 Pada *layer* ini, detail tekstur mulai kabur dan digantikan oleh informasi bentuk secara utuh.




Gambar 29. Visualisasi FPN Layer P4

- 3) *Layer P3* : Tekstur Lokal dan Permukaan
 Berfungsi menghubungkan fitur garis menjadi fitur tekstur permukaan.



Gambar 30. Visualisasi FPN Layer P3

- 4) *Layer P2* : Deteksi Tepi dan Detail Mikro
 Menangkap informasi visual frekuensi tinggi seperti garis, sudut, dan tekstur halus.



Gambar 31. Visualisasi FPN Layer P2

4.3.3. Hasil Visualisasi Fitur RPN (*Region Proposal Network*)

Pada Gambar 32, menampilkan 50 proposal wilayah teratas (*Top-N Region Proposals*) yang dihasilkan oleh RPN sebelum masuk ke tahap klasifikasi final. Visualisasi ini memberikan informasi mengenai kemampuannya dalam melakukan lokalisasi awal objek pin dioda. Kotak berwarna *cyan* merepresentasikan kandidat area (ROI) yang diprediksi memiliki probabilitas tinggi memuat pin. Meskipun lokalisasi kasar berhasil, terlihat sejumlah proposal yang tidak akurat. Beberapa *bounding box* muncul di area kosong permukaan tray, hal ini mengindikasikan bahwa pada tahap RPN jaringan masih memiliki tingkat ketidakpastian dalam membedakan batas antara objek logam yang tipis dengan latar belakang tray yang gelap. Banyak proposal yang dihasilkan cenderung sedikit bergeser dari posisi sebenarnya. Hal ini wajar terjadi pada tahap RPN, karena tujuannya adalah memprioritaskan *recall* daripada presisi tinggi. Koreksi koordinat untuk mengatasi kotak yang longgar ini akan menjadi tugas utama dari *box regressor* pada tahap kedua setelah proses *RoI Align*.




Gambar 32. Visualisasi RPN

4.3.4. Hasil Visualisasi *Fast R-CNN Head*

Pada Gambar 33, menampilkan hasil akhir dari *Faster R-CNN*, yaitu *output* dari *Fast R-CNN Head* pada tahap 2. Berbeda dengan *output* RPN yang hanya berupa proposal lokasi kasar, hasil ini menunjukkan prediksi final yang mencakup label

kelas spesifik, *confidence score*, dan *bounding box* yang telah diregresi ulang. Sistem berhasil membedakan karakteristik kerusakan pin dengan sangat baik, selain itu jika dibandingkan dengan *output* RPN, pada Gambar 32 terlihat perbaikan *bounding box* yang drastis. Kotak prediksi kini membungkus objek pin secara pas dan mengikuti orientasi vertikal pin dengan presisi tinggi. Hal ini menunjukkan bahwa *box regressor* pada tahap kedua berhasil melakukan *fine-tuning* koordinat untuk meminimalkan selisih antara proposal awal dengan objek sebenarnya.



Gambar 33. Visualisasi Tahap akhir

4.4. Hasil Pengujian Performa

Sub-bab ini memaparkan evaluasi terhadap kinerja sistem deteksi cacat yang dilakukan menggunakan data *testing* yang sepenuhnya terpisah.

4.4.1. Perbandingan Performa

Secara keseluruhan, hasil eksperimen pada Tabel 11 menunjukkan bahwa arsitektur yang dikembangkan mampu bekerja dengan sangat baik, di mana keenam skenario secara konsisten menghasilkan nilai mAP di atas 98%. Namun demikian, terdapat variasi performa yang membedakan kualitas tiap model. Skenario F dan B teridentifikasi sebagai skenario dengan performa terbaik yang mencatatkan mAP di atas 99,3%, menunjukkan stabilitas klasifikasi yang paling optimal dibandingkan skenario lainnya. Sebaliknya, Skenario C menempati posisi terendah dengan mAP 98,23%, yang disebabkan oleh penurunan signifikan pada nilai *Recall* dan *F1-score* untuk kelas *Broken*, sebuah kelemahan yang berisiko tinggi dalam konteks inspeksi kualitas. Sementara itu, Skenario A, D, dan E, meskipun memiliki metrik individual yang cukup baik seperti presisi sempurna pada kelas *Broken* di Skenario E, namun masih belum mampu menandingi keseimbangan yang ditawarkan oleh Skenario F. Dengan demikian, analisis ini menetapkan Skenario F sebagai model terbaik yang tidak hanya unggul dalam akurasi rata-rata, tetapi juga memiliki keandalan deteksi yang merata pada seluruh kelas objek.

Keputusan ini didasarkan pada capaian performa deteksi tertinggi yaitu Skenario F berhasil mencapai nilai $mAP@0.50$ sebesar 99,36%. Nilai mAP ini merupakan yang tertinggi, mengindikasikan bahwa model memiliki kemampuan paling optimal dalam mengenali dan melokalisasi ketiga kelas kerusakan secara presisi. Hasil grafik *loss* Skenario F juga menjadi dasar pemilihan Skenario F sebagai scenario terbaik. Grafik Skenario F menunjukkan konvergensi yang ideal pada kurva *loss train* dan *validation* yang akhirnya saling berimpit pada fase akhir pelatihan. Hal ini membuktikan bahwa Skenario F memiliki stabilitas pembelajaran dan kemampuan generalisasi yang baik.

Tabel 11. Perbandingan Peforma Skenario

No	Skenario	Kelas	<i>mAP</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
1	A	Normal	99,09%	0,96	0,99	0,97
		<i>Bent</i>		0,98	0,96	0,97
		<i>Broken</i>		0,99	0,99	0,99
2	B	Normal	99,31%	0,97	0,98	0,98
		<i>Bent</i>		0,98	0,95	0,96
		<i>Broken</i>		0,95	0,97	0,96
3	C	Normal	98,23%	0,96	0,98	0,97
		<i>Bent</i>		0,96	0,92	0,94
		<i>Broken</i>		0,89	0,91	0,9
4	D	Normal	98,65%	0,95	0,97	0,96
		<i>Bent</i>		0,97	0,96	0,96
		<i>Broken</i>		0,99	0,97	0,98
5	E	Normal	98,48%	0,95	0,99	0,97
		<i>Bent</i>		0,98	0,96	0,97
		<i>Broken</i>		1	0,98	0,99
6	F	Normal	99,36%	0,93	0,98	0,95
		<i>Bent</i>		0,98	0,92	0,95
		<i>Broken</i>		0,97	0,99	0,95

4.5. Analisa Model Terbaik


Meskipun menggunakan metode yang sama, terdapat perbedaan hasil evaluasi yang signifikan antara penelitian ini dengan penelitian sebelumnya, seperti yang dilakukan oleh Oktavian pada deteksi kerusakan jalan dan Pratama pada klasifikasi biji kopi. Analisis mendalam menunjukkan bahwa keunggulan performa pada penelitian ini dipengaruhi oleh tiga faktor utama, yaitu kontrol lingkungan, karakteristik objek, dan strategi augmentasi. Faktor pertama adalah kompleksitas lingkungan pengambilan citra. Penelitian Oktavian dilakukan pada lingkungan *outdoor* yang memiliki variabilitas tinggi terhadap intensitas cahaya matahari dan *noise* latar belakang yang dinamis. Kondisi tersebut menyulitkan jaringan RPN dalam membedakan objek kerusakan dengan tekstur aspal. Sebaliknya, penelitian ini menerapkan lingkungan terkontrol yang menghasilkan kontras yang tinggi antara objek pin yang reflektif dengan latar belakang yang gelap, sehingga fitur tepi dapat diekstraksi dengan lebih tegas dan akurat oleh model. Faktor kedua berkaitan dengan karakteristik geometri objek. Objek deteksi pada penelitian Pratama yaitu biji kopi, merupakan objek dengan variasi bentuk dan ukuran yang sangat acak serta memiliki kemiripan fitur antar kelas yang tinggi. Berbeda dengan penelitian ini, di mana pin dioda merupakan komponen manufaktur dengan dimensi yang presisi dan bentuk geometris yang baku. Konsistensi bentuk visual pada pin dioda mempercepat proses konvergensi model dan meminimalisir ambiguitas klasifikasi, sehingga nilai *mean Average Precision* (mAP) yang dihasilkan jauh lebih tinggi.

Dari keseluruhan hasil skenario, konfigurasi Skenario F ditetapkan sebagai model final terbaik dengan performa mAP Pascal VOC sebesar 99,36%. Pada sub-bab ini, kinerja model terbaik dianalisis lebih mendalam sebagai berikut.

4.5.1. Analisa Grafik *Loss* dan *val mAP*


Pada gambar 34, menampilkan perubahan nilai *loss* selama proses *train* dan *validation* model yang berlangsung selama 300 *epoch*. Pada rentang *epoch* 0 hingga 30, terlihat penurunan *Training Loss* yang sangat tajam. Fenomena ini mengindikasikan efektivitas penggunaan *Transfer Learning* dengan bobot awal dari ImageNet. Kemudian kedua garis bergerak turun secara beriringan dan konsisten, jarak yang sempit ini menandakan bahwa model memiliki kemampuan generalisasi yang baik. Model tidak hanya mampu mengenali data yang dipelajarinya, tetapi juga mampu beradaptasi dengan data validasi yang belum pernah dilihat. Tidak adanya pola divergensi (garis oranye naik menjauhi garis biru) membuktikan bahwa strategi augmentasi berhasil mencegah terjadinya *overfitting*. Di mulai dari *epoch* ke-100 hingga 300, penurunan *loss* mulai melambat dan mencapai titik jenuh. Secara keseluruhan, pola grafik *loss* yang konvergen dan stabil mengonfirmasi bahwa proses pelatihan berjalan sehat. Meskipun tidak terdapat nilai ambang batas untuk *loss* yang dianggap ideal karena

sangat bergantung pada kompleksitas dataset, namun dalam berbagai literatur dan eksperimen menggunakan arsitektur *Faster R-CNN*, nilai *total loss* yang berada di bawah 0.5 sering dijadikan acuan tercapainya stabilitas model, sedangkan nilai di bawah 0.1 mengindikasikan performa *fitting* yang sangat ketat. Oleh karena itu, nilai *loss* yang semakin kecil atau mendekati nol mengindikasikan bahwa model semakin presisi dalam mempelajari fitur dan pola pada dataset.



Gambar 34. Grafik Loss Skenario F

Selanjutnya grafik validasi mAP pada Gambar 35, menunjukkan karakteristik kurva pembelajaran yang ideal. Model mencapai tingkat akurasi yang kompetitif (>80%) dalam waktu relatif singkat di *epoch* 100 dan mampu mempertahankan performa tersebut secara stabil hingga akhir pelatihan. Kondisi mendatar ini menandakan bahwa model telah mencapai titik konvergensi. Tidak adanya penurunan nilai secara drastis di fase akhir membuktikan bahwa model tidak mengalami *overfitting*.



Gambar 35. Grafik validasi mAP Skenario F

4.5.2. Analisis Pengaruh Hyperparameter

Berdasarkan perbandingan hasil, penggunaan *optimizer* Adam cenderung memberikan stabilitas dan performa yang lebih baik dibandingkan SGD. Mekanisme *adaptive learning rate* pada *optimizer* Adam mampu menyesuaikan besaran *update* bobot untuk setiap parameter. Karakteristik ini sangat efektif untuk menangani fitur yang jarang muncul, seperti fitur retakan halus pada kelas *Broken*. Selanjutnya, nilai *learning rate* yang cukup besar (0,001) memungkinkan model mempelajari fitur dengan cepat, sementara *Batch Size* kecil (2) memberikan sedikit *noise* pada gradien yang justru membantu model melakukan eksplorasi untuk menemukan solusi terbaik, terbukti dari capaian mAP 99,36% pada skenario F. Dapat dilihat pada skenario C yang memiliki performa terendah akibat kombinasi antara *Learning Rate* sangat kecil (0,0001) dan *Batch Size* besar (4) menggunakan SGD. Gradien yang dihasilkan terlalu rata-rata dan langkah pembelajarannya terlalu kecil, akibatnya model belajar sangat lambat.


Terakhir, durasi *epoch* berdampak pada presisi *bounding box* dan terbukti pada skenario E yang dilatih selama 500 *epoch* dengan *Learning Rate* rendah (0,0001). Durasi panjang dengan langkah kecil ini memungkinkan model untuk melakukan *fine-tuning* posisi kotak secara sangat presisi.

4.5.3. Evaluasi Model pada Dataset Testing

Evaluasi difokuskan untuk mengukur keandalan model terbaik skenario F dalam mengklasifikasikan kondisi pin pada data baru.

4.5.3.1. Mean Average Precision

Berdasarkan pengujian menggunakan standar metrik PASCAL VOC pada Gambar 36, model berhasil mencapai performa yang sangat tinggi mencapai nilai 99.36% dengan rincian nilai *Average Precision* (AP) yang tinggi dengan nilai tertinggi pada kelas *fracture*. Secara keseluruhan, tingginya nilai mAP ini mengindikasikan bahwa *confidence score* yang dihasilkan model sangat selaras dengan ketepatan posisi *bounding box*.



```
HASIL PENGUJIAN AKHIR (mAP)
Testing mAP : 99.36%


--- METRIK AVERAGE PRECISION (AP) per Kelas ---
| Kelas | AP |
|:-----|:-----|
| Normal | 99.58 |
| Bent | 98.67 |
| Broken | 99.82 |
```

Gambar 36. Hasil *testing* mAP skenario F

4.5.3.2. Confusion Matrix

Berdasarkan data *matrix* pada Gambar 37, model menunjukkan performa klasifikasi yang sangat dominan pada diagonal utama yang mengindikasikan tingginya jumlah prediksi benar. Untuk kelas *Broken*, model menunjukkan kinerja

yang hampir sempurna dengan berhasil mengenali 211 objek dari total aktual, di mana hanya terdapat 1 kesalahan prediksi yang terklasifikasi sebagai *Bent*. Tidak ditemukan adanya kasus *Broken* yang terdeteksi sebagai *Normal*, yang membuktikan bahwa model mampu memisahkan kondisi kerusakan fatal dengan sangat baik. Namun, analisis pada area *misclassification* mengungkapkan adanya kelemahan *minor* pada kelas *Bent*. Terdapat 12 objek aktual *Bent* yang terprediksi sebagai *Normal* yang merupakan kesalahan terbesar. Pin yang hanya mengalami pembengkokan sudut kecil atau pembengkokan yang sejajar dengan sumbu optik kamera sangat mirip dengan pin lurus, sehingga probabilitas kelas *Normal* menjadi lebih dominan saat proses *classification*. Adapun terdapat 6 objek *Bent* yang terdeteksi sebagai *Broken*. Kesalahan ini dikategorikan sebagai "toleransi aman", karena sistem tetap mendeteksi adanya cacat, meskipun jenis label cacatnya tertukar. Sementara itu, pada kelas *Normal*, kesalahan prediksi sangat minim, di mana hanya 3 objek normal yang salah terdeteksi sebagai *Bent*, sedangkan 164 objek lainnya berhasil diidentifikasi dengan tepat.



Gambar 37. Confusion Matrix dataset testing skenario F

4.5.3.3. Classification Report

Pada metrik per kelas di Gambar 38, kelas *Broken* mendapat performa terbaik dengan nilai *Recall* sebesar 0.97 dan F1-Score 0.98. Tingginya nilai *Recall* ini mengonfirmasi bahwa sistem memiliki sensitivitas yang sangat tinggi terhadap pin patah. Sebaliknya, kelas *Bent* menunjukkan karakteristik yang unik dengan nilai *Precision* terendah sebesar 0.92 dengan *Recall* sebesar 0.98. Hal ini membuktikan bahwa model sangat berhati-hati dalam kondisi *broken*, namun cenderung melewati beberapa kasus *bent* yang tidak terlalu signifikan. Terakhir, kelas *Normal* menunjukkan performa yang seimbang dengan *Recall* 0.96.

	precision	recall	f1-score	support
Normal	0.98	0.93	0.96	176
Bent	0.92	0.98	0.95	216
Broken	0.99	0.97	0.98	218
micro avg	0.96	0.96	0.96	610
macro avg	0.96	0.96	0.96	610
weighted avg	0.96	0.96	0.96	610

Gambar 38. Classification report dataset testing skenario F

Untuk membuktikan keabsahan perhitungan program atau memvalidasi perhitungan otomatis program, dilakukan perhitungan manual berdasarkan *confusion matrix* pada Gambar 37 sebagai berikut.

1) Normal

- *Precision*

$$Precision = \frac{TP}{FP + TP} * 100\%$$

$$Precision = \frac{164}{3 + 164} * 100\% = \mathbf{0.98}$$

- *Recall*

$$Recall = \frac{TP}{FN + TP} * 100\%$$

$$Recall = \frac{164}{12 + 164} * 100\% = \mathbf{0.93}$$

- *F1-Score*

$$F1 - Score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} * 100\%$$

$$F1 - Score = 2 \times \frac{(0.98 \times 0.93)}{(0.98 + 0.93)} * 100\%$$

$$F1 - Score = 2 \times \frac{0.91}{1.91} * 100\% = \mathbf{0.96}$$

2) Bent

- *Precision*

$$Precision = \frac{TP}{FP + TP} * 100\%$$

$$Precision = \frac{211}{18 + 211} * 100\% = \mathbf{0.92}$$

- *Recall*

$$Recall = \frac{TP}{FN + TP} * 100\%$$

$$Recall = \frac{211}{4 + 211} * 100\% = \mathbf{0.98}$$

- *F1-Score*

$$F1 - Score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} * 100\%$$

$$F1 - Score = 2 \times \frac{(0.92 \times 0.98)}{(0.92 + 0.98)} * 100\%$$

$$F1 - Score = 2 \times \frac{0.9}{1.9} * 100\% = \mathbf{0.95}$$

3) Bent

- *Precision*

$$Precision = \frac{TP}{FP + TP} * 100\%$$

$$Precision = \frac{211}{1 + 211} * 100\% = \mathbf{0.99}$$

- *Recall*

$$Recall = \frac{TP}{FN + TP} * 100\%$$

$$Recall = \frac{211}{6 + 211} * 100\% = \mathbf{0.97}$$

- *F1-Score*

$$F1 - Score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} * 100\%$$

$$F1 - Score = 2 \times \frac{(0.99 \times 0.97)}{(0.99 + 0.97)} * 100\%$$

$$F1 - Score = 2 \times \frac{0.96}{1.96} * 100\% = \mathbf{0.98}$$

4.5.3.4. Kinerja *Region Proposal Network*

Berdasarkan hasil metrik evaluasi RPN pada Gambar 39, model dikonfigurasi untuk menghasilkan rata-rata 1.000 proposal per gambar. Jumlah proposal ini dipilih untuk memberikan keseimbangan antara cakupan deteksi dan efisiensi

komputasi. Dari total 600 objek *Ground Truth* yang ada pada dataset, RPN mencatatkan nilai Recall sebesar 71.00% pada ambang batas IoU > 0.3. Nilai ini mengindikasikan bahwa pada tahap awal penyaringan, RPN berhasil mengisolasi 71% kandidat wilayah yang memiliki tumpang tindih signifikan dengan objek asli. Meskipun angka ini terlihat lebih rendah dibandingkan *Recall* pada hasil akhir, hal ini merupakan karakteristik wajar dari mekanisme *filtering* RPN yang memprioritaskan proposal dengan skor *objectness* tertinggi untuk diproses lebih lanjut.

```
=====
HASIL METRIK RPN (@ IoU > 0.3)
=====
RPN Recall: 71.00%
Rata-rata Proposals per Gambar: 1000.0
Total Objek Ground Truth: 600
```

Gambar 39. Metrik RPN

4.5.3.5. Rata-rata Komponen Loss

Berdasarkan hasil *training* pada Gambar 40, model mencapai titik konvergensi yang optimal, ditandai dengan rendahnya nilai pada keempat komponen utama *loss function*. Nilai *RPN Objectness Loss* tercatat sangat rendah di angka 0.0016. Hal ini mengindikasikan bahwa jaringan *region proposal* memiliki kemampuan yang hampir sempurna dalam membedakan antara pin dan latar belakang. Minimnya nilai ini berarti model sangat jarang menghasilkan proposal palsu di area kosong atau melewati keberadaan pin. Didukung oleh *RPN Box Regression Loss* sebesar 0.0079, yang menunjukkan bahwa kemampuan *anchor box* awal yang dihasilkan oleh RPN terbilang baik dalam mendeteksi pin sebelum masuk ke tahap klasifikasi akhir.

Pada tahap kedua, kemampuan model dalam mengenali detail spesifik objek terlihat dari *Classifier Loss* yang menyentuh angka 0.0730. Nilai ini merefleksikan tingginya *discriminative power* model dalam memisahkan fitur antar-kelas. Rendahnya *classifier loss* ini berhubungan dengan tingginya akurasi klasifikasi yang dihasilkan pada matriks pengujian. Artinya, model memiliki tingkat keyakinan yang tinggi saat memutuskan label suatu pin. Terakhir, komponen *Box Regression Loss* pada tahap akhir tercatat sebesar 0.1243. Meskipun nilai ini adalah yang tertinggi dibandingkan ketiga komponen lainnya, hal tersebut merupakan fenomena yang wajar dalam deteksi objek presisi tinggi. Nilai 0.1243 menunjukkan bahwa model terus berusaha melakukan penyesuaian koordinat hingga ke level piksel untuk memastikan *bounding box* benar-benar presisi.

RATA-RATA LOSS KOMPONEN (MEAN LOSSES)		PADA TESTING SET	
Classifier Loss	Box Reg Loss	RPN Objectness Loss	RPN Box Reg Loss
0.0730	0.1243	0.0016	0.0079

Gambar 40. Rata-rata Loss Komponen


4.6. Hasil Pengujian Sistem *User Interface*

Pengujian ini bertujuan untuk memvalidasi integrasi antara model dengan *user interface* berbasis *Python* yang telah dirancang.

4.6.1. Perbandingan Hasil Pengujian


Pengujian dilakukan menggunakan 15 citra yang di dalamnya terdapat total 360 pin yang terdeteksi. Evaluasi performa dilakukan berdasarkan hasil prediksi sistem dibandingkan dengan kondisi aktual komponen sebagai berikut.

Tabel 12. Hasil Pengujian *User Interface* 1

Gambar	No Pin	Label Actual	Hasil Prediksi
	1	Bent	Bent
	2	Normal	Normal
	3	Bent	Bent
	4	Bent	Bent
	5	Broken	Broken
	6	Bent	Bent
	7	Normal	Normal
	8	Bent	Normal
	9	Bent	Bent
	10	Normal	Normal
	11	Normal	Normal
	12	Bent	Bent
	13	Normal	Normal
	14	Normal	Normal
	15	Normal	Normal
	16	Normal	Normal
	17	Normal	Normal
	18	Normal	Normal
	19	Normal	Normal
	20	Normal	Normal
	21	Normal	Normal
	22	Normal	Normal
	23	Normal	Normal
	24	Normal	Normal


Pada tabel 12, terdapat kesalahan prediksi pada pin no 8 yang dikategorikan sebagai *False Negative*. Secara visual, pin tersebut memiliki tingkat

Tabel 14. Hasil Pengujian *User Interface* 3

Gambar	No Pin	Label <i>Actual</i>	Hasil Prediksi
	1	Bent	Bent
	2	Broken	Bent
	3	Broken	Broken
	4	Broken	Broken
	5	Normal	Normal
	6	Normal	Normal
	7	Broken	Broken
	8	Bent	Bent
	9	Normal	Normal
	10	Normal	Normal
	11	Normal	Normal
	12	Normal	Normal
	13	Broken	Broken
	14	Broken	Broken
	15	Broken	Broken
	16	Broken	Broken
	17	Normal	Normal
	18	Bent	Bent
	19	Bent	Bent
	20	Broken	Broken
	21	Broken	Broken
	22	Bent	Bent
	23	Bent	Bent
	24	Broken	Broken

Berdasarkan Tabel 14, hasil pengujian menunjukkan performa yang optimal. Seluruh label prediksi sesuai dengan label aktual. Pada kerusakan pin dioda yang patah total, nilai *confidence score*-nya berada di rentang 0.59 – 0.89 yang menunjukkan model ragu pada jenis kerusakan ini. Sedangkan untuk jenis kerusakan pin yang patah namun juga bengkok, model lebih yakin memprediksinya sebagai *Bent*.

Tabel 15. Hasil Pengujian *User Interface* 4

Gambar		No Pin	Label <i>Actual</i>	Hasil Prediksi
		1	Bent	Bent
		2	Bent	Bent
		3	Broken	Bent
		4	Bent	Bent
		5	Normal	Normal
		6	Normal	Normal
		7	Normal	Normal
		8	Normal	Normal
		9	Normal	Bent
		10	Broken	Broken
		11	Bent	Bent
		12	Broken	Broken
		13	Bent	Bent
		14	Bent	Bent
		15	Broken	Broken
		16	Bent	Bent
		17	Bent	Bent
		18	Bent	Bent
		19	Bent	Bent
		20	Bent	Normal
		21	Bent	Bent
		22	Bent	Bent
		23	Bent	Bent
		24	Bent	Bent

Hasil pengujian pada tabel 15 menunjukkan adanya tiga pola misklasifikasi utama yang disebabkan oleh ambiguitas fitur visual. Kasus *Broken* terprediksi *Bent* pada pin no 3 dengan *confidence score* 1.0 yang terjadi karena patahan pin membentuk sudut geometris yang menyerupai lengkungan bagi model. Selanjutnya kesalahan Normal terprediksi *Bent* pada pin no 9 dengan *confidence score* 0.56 yang berarti model juga ragu dalam mengklasifikasikan pin tersebut sebagai *Bent*. Hal tersebut dipicu oleh gangguan bayangan atau distorsi lensa di tepi citra yang menciptakan ilusi kelengkungan pada pin lurus. Sebaliknya, kasus *Bent* terprediksi Normal pada pin no 20 dengan *confidence score* 0.95 disebabkan oleh arah bengkokan yang lurus ke bawah, pin tersebut tidak menampilkan lengkungan visual melainkan hanya mengalami pemendekan objek namun tetap terlihat lurus, sehingga model mengklasifikasikannya sebagai Normal

Tabel 16. Hasil Pengujian *User Interface* 5

Gambar		No Pin	Label <i>Actual</i>	Hasil Prediksi
		1	Broken	Broken
		2	Bent	Bent
		3	Bent	Bent
		4	Broken	Broken
		5	Broken	Broken
		6	Broken	Broken
		7	Broken	Broken
		8	Broken	Broken
		9	Normal	Normal
		10	Normal	Normal
		11	Normal	Normal
		12	Normal	Normal
		13	Broken	Broken
		14	Broken	Broken
		15	Bent	Bent
		16	Broken	Broken
		17	Bent	Bent
		18	Broken	Broken
		19	Broken	Broken
		20	Broken	Broken
		21	Bent	Broken
		22	Bent	Bent
		23	Bent	Bent
		24	Bent	Normal

Hasil pengujian pada tabel 16 menunjukkan stabilitas yang baik dengan memprediksi benar pada 22 dari 24 pin. Namun, terdapat dua kesalahan klasifikasi pada kelas *actual* *Bent* yang masing-masing terdeteksi sebagai *Broken* pada pin 21 (0,54) dan *Normal* pada pin 24 (0,53). Kedua prediksi salah ini memiliki *confidence score* yang sangat rendah dan mendekati ambang batas (*threshold*), yang mengindikasikan tingginya ketidakpastian model terhadap fitur visual kedua pin tersebut. Pada kasus prediksi *Broken*, panjang pin terlihat lebih pendek yang menyerupai patahan, sedangkan pada prediksi *Normal*, deformasi yang ada terlalu halus sehingga model gagal membedakannya dari karakteristik pin normal.

Tabel 17. Hasil Pengujian *User Interface* 6

Gambar		No Pin	Label <i>Actual</i>	Hasil Prediksi
		1	Broken	Broken
		2	Broken	Broken
		3	Broken	Broken
		4	Broken	Broken
		5	Bent	Bent
		6	Normal	Normal
		7	Broken	Broken
		8	Broken	Broken
		9	Broken	Broken
		10	Broken	Bent
		11	Broken	Broken
		12	Bent	Bent
		13	Broken	Broken
		14	Bent	Bent
		15	Bent	Bent
		16	Bent	Bent
		17	Broken	Broken
		18	Broken	Broken
		19	Broken	Broken
		20	Broken	Broken
		21	Normal	Normal
		22	Normal	Normal
		23	Normal	Normal
		24	Bent	Bent

Pada tabel 17, hasil pengujian menampilkan bahwa model mencapai akurasi tinggi dengan 23 prediksi benar dari 24 sampel. Kesalahan tunggal teridentifikasi pada pin no 10 dengan *confidence score* 0.55, dimana kondisi aktual *Broken* terklasifikasi sebagai *Bent*. Analisis visual menunjukkan bahwa pin tersebut memiliki sisa patahan berujung tumpul namun mengalami deformasi lengkungan yang sangat ekstrem. Akibatnya, model memprioritaskan fitur lengkungan tersebut dan mengategorikannya sebagai *Bent*.

Tabel 18. Hasil Pengujian *User Interface* 7

Gambar		No Pin	Label <i>Actual</i>	Hasil Prediksi
		1	Broken	Broken
		2	Broken	Broken
		3	Broken	Broken
		4	Broken	Broken
		5	Broken	Broken
		6	Broken	Broken
		7	Broken	Broken
		8	Broken	Broken
		9	Normal	Normal
		10	Normal	Normal
		11	Normal	Normal
		12	Normal	Normal
		13	Broken	Broken
		14	Broken	Broken
		15	Broken	Bent
		16	Broken	Bent
		17	Bent	Bent
		18	Bent	Bent
		19	Bent	Bent
		20	Bent	Bent
		21	Bent	Bent
		22	Bent	Bent
		23	Bent	Bent
		24	Bent	Bent


Pada tabel 18, mayoritas prediksi sesuai dengan label aktual, namun terdapat dua kesalahan klasifikasi pada kelas *Broken* yang terdeteksi sebagai *Bent*. Tingginya *confidence score* pada kedua kesalahan tersebut (0,85 dan 0,87), yang mengindikasikan bahwa model memiliki keyakinan yang kuat namun keliru. Kesalahan ini disebabkan oleh orientasi pin yang mengalami rotasi, sehingga sisi patahan yang tumpul terlihat dari samping menyerupai siluet lengkungan. Akibat rotasi ini, fitur tajam yang menjadi ciri khas patahan tersembunyi.

Tabel 19. Hasil Pengujian *User Interface* 8

Gambar	No Pin	Label <i>Actual</i>	Hasil Prediksi
	1	Normal	Bent
	2	Normal	Normal
	3	Normal	Normal
	4	Normal	Normal
	5	Normal	Normal
	6	Normal	Normal
	7	Normal	Normal
	8	Normal	Normal
	9	Bent	Bent
	10	Bent	Bent
	11	Bent	Bent
	12	Bent	Bent
	13	Broken	Broken
	14	Broken	Broken
	15	Broken	Broken
	16	Broken	Broken
	17	Bent	Bent
	18	Bent	Bent
	19	Bent	Bent
	20	Bent	Bent
	21	Bent	Bent
	22	Normal	Normal
	23	Normal	Normal
	24	Normal	Normal


Pada tabel 19, teridentifikasi satu kasus *False Positive* pada pin no 1 dengan *confidence score* 0.91, di mana komponen dengan kondisi aktual Normal terklasifikasi sebagai *Bent*. Kesalahan ini terjadi secara spesifik pada pin yang terletak di posisi sudut ekstrem area pandang kamera. Hal ini merupakan dampak residual dari proses *lens undistortion*, pelurusan citra pada lensa *fisheye* menyebabkan efek peregangkan piksel dan interpolasi pada area tepi, yang secara visual memanipulasi geometri batang pin yang lurus menjadi tampak sedikit melengkung atau membesar.

Tabel 20. Hasil Pengujian *User Interface* 9

Gambar		No Pin	Label <i>Actual</i>	Hasil Prediksi
		1	Normal	Normal
		2	Normal	Normal
		3	Normal	Normal
		4	Normal	Normal
		5	Normal	Normal
		6	Normal	Normal
		7	Normal	Normal
		8	Normal	Normal
		9	Normal	Normal
		10	Normal	Normal
		11	Normal	Normal
		12	Normal	Normal
		13	Normal	Normal
		14	Normal	Normal
		15	Normal	Normal
		16	Normal	Normal
		17	Normal	Normal
		18	Normal	Normal
		19	Normal	Normal
		20	Normal	Normal
		21	Broken	Broken
		22	Broken	Broken
		23	Broken	Broken
		24	Broken	Broken


Pada tabel 20, seluruh pin berhasil diklasifikasikan sesuai dengan kondisi aktualnya (*True Positive*). Keberhasilan ini divalidasi oleh tingginya *confidence score* pada setiap kotak prediksi yang rata-rata berada di atas 0,90.

Tabel 21. Hasil Pengujian *User Interface* 10

Gambar		No Pin	Label <i>Actual</i>	Hasil Prediksi
		1	Broken	Bent
		2	Broken	Bent
		3	Broken	Broken
		4	Broken	Broken
		5	Bent	Bent
		6	Bent	Bent
		7	Broken	Broken
		8	Broken	Broken
		9	Bent	Bent
		10	Bent	Bent
		11	Bent	Bent
		12	Bent	Bent
		13	Normal	Normal
		14	Normal	Normal
		15	Normal	Normal
		16	Normal	Normal
		17	Bent	Bent
		18	Bent	Bent
		19	Bent	Bent
		20	Bent	Bent
		21	Broken	Broken
		22	Broken	Broken
		23	Broken	Broken
		24	Broken	Broken


Pada tabel 21, pin dengan kondisi *actual Broken* terprediksi oleh sebagai *Bent* pada pin no 1 dan 2 dengan *confidence score* mutlak sebesar 1. Tingginya tingkat keyakinan ini menunjukkan bahwa patahan yang terjadi pada pin memiliki ukuran yang cukup besar dengan potongan miring, sehingga sisa logam yang tertinggal membentuk geometri yang secara visual sangat menyerupai lengkungan. Bagi model yang mengekstraksi fitur berdasarkan pola tepi, karakteristik fisik ini memiliki kemiripan identik dengan fitur kelas *Bent* yang dipelajari selama *training*.

Tabel 22. Hasil Pengujian *User Interface* 11

Gambar		No Pin	Label <i>Actual</i>	Hasil Prediksi
		1	Bent	Bent
		2	Bent	Bent
		3	Bent	Bent
		4	Broken	Broken
		5	Normal	Normal
		6	Normal	Normal
		7	Normal	Normal
		8	Normal	Normal
		9	Broken	Broken
		10	Broken	Broken
		11	Broken	Broken
		12	Broken	Broken
		13	Bent	Bent
		14	Bent	Bent
		15	Bent	Bent
		16	Bent	Bent
		17	Broken	Broken
		18	Broken	Broken
		19	Broken	Broken
		20	Broken	Broken
		21	Bent	Bent
		22	Bent	Bent
		23	Bent	Bent
		24	Bent	Bent


Pada tabel 22, hasil menunjukkan performa yang sangat baik dengan semua pin terprediksi dengan benar. Keunggulan model terlihat signifikan khususnya pada kemampuan mendeteksi kategori *Broken* pada pin 9, 10, 11, dan 12 dengan karakteristik visual yang sulit. Model berhasil mengklasifikasikan pin dengan kondisi patahan yang sangat kecil dan memiliki ujung tumpul. Meskipun secara visual objek ini tidak memiliki fitur ketajaman yang mencolok dan memiliki kemiripan dimensi dengan pin normal, sistem mampu mengklasifikasikannya sebagai *Broken* dengan sangat tepat didukung oleh *confidence score* yang sangat meyakinkan, yakni di atas 0.95.

Tabel 23. Hasil Pengujian *User Interface* 12

Gambar		No Pin	Label <i>Actual</i>	Hasil Prediksi
		1	Bent	Bent
		2	Bent	Bent
		3	Bent	Bent
		4	Bent	Bent
		5	Normal	Normal
		6	Normal	Normal
		7	Normal	Normal
		8	Normal	Bent
		9	Broken	Broken
		10	Broken	Broken
		11	Broken	Broken
		12	Broken	Broken
		13	Bent	Bent
		14	Bent	Bent
		15	Bent	Bent
		16	Bent	Bent
		17	Normal	Normal
		18	Normal	Normal
		19	Normal	Normal
		20	Normal	Normal
		21	Broken	Bent
		22	Bent	Bent
		23	Bent	Bent
		24	Bent	Bent


Pada tabel 23, sebanyak 22 dari 24 pin berhasil terprediksi dengan benar. Pada pin 8, terdapat kasus *False Positive* di mana pin aktual Normal terdeteksi sebagai *Bent*. Namun, terlihat bahwa model memberikan *confidence score* yang relatif rendah, yaitu 0.74. Meskipun secara fisik masih masuk dalam toleransi kelas Normal, sensitivitas model merespons kemiringan tersebut sebagai potensi cacat *bent*. Selain itu pada pin 21 dengan *confidence score* 0,89 menunjukkan kesalahan klasifikasi kondisi aktual *Broken* terprediksi sebagai *Bent*. Kesalahan ini disebabkan oleh karakteristik patahan memanjang yang terjadi di sisi tepi pin. Garis patahan yang panjang tersebut menciptakan profil visual yang menyerupai bengkokan, sehingga model menginterpretasikannya sebagai lengkungan fisik.

Tabel 24. Hasil Pengujian *User Interface* 13

Gambar		No Pin	Label <i>Actual</i>	Hasil Prediksi
		1	Normal	Normal
		2	Normal	Normal
		3	Normal	Normal
		4	Normal	Normal
		5	Broken	Broken
		6	Broken	Broken
		7	Broken	Bent
		8	Broken	Broken
		9	Broken	Broken
		10	Broken	Broken
		11	Broken	Broken
		12	Broken	Bent
		13	Normal	Normal
		14	Normal	Normal
		15	Normal	Normal
		16	Normal	Normal
		17	Broken	Broken
		18	Broken	Broken
		19	Broken	Broken
		20	Broken	Broken
		21	Bent	Bent
		22	Bent	Bent
		23	Bent	Bent
		24	Bent	Bent

Pada tabel 24, model memberikan prediksi salah di mana kondisi aktual *Broken* terdeteksi sebagai *Bent* pada 2 pin. Pada pin no 7 dengan *confidence score* 0.99 menunjukkan bahwa tingginya skor ini dipicu oleh dominasi fitur deformasi pada sisa patahan. Meskipun ujung pin tumpul, sisa batang pin mengalami pembengkokan tajam ke kiri. Secara komputasi, model lebih memprioritaskan fitur geometri bengkokan tajam dibandingkan fitur tekstur ujung tumpul. Sementara itu pada pin no 12 dengan *confidence score* 0,98 memiliki patahan yang sangat runcing. Ujung yang melancip tajam ini menciptakan gradien visual yang menyerupai sebuah lekukan halus. Model mengidentifikasi pola runcing tersebut sebagai fitur *bent*.

Tabel 25. Hasil Pengujian *User Interface* 14

Gambar		No Pin	Label <i>Actual</i>	Hasil Prediksi
		1	Bent	Bent
		2	Bent	Bent
		3	Bent	Bent
		4	Bent	Bent
		5	Broken	Broken
		6	Broken	Broken
		7	Broken	Broken
		8	Broken	Broken
		9	Normal	Normal
		10	Normal	Normal
		11	Normal	Normal
		12	Normal	Normal
		13	Broken	Broken
		14	Broken	Broken
		15	Broken	Broken
		16	Broken	Broken
		17	Bent	Bent
		18	Bent	Bent
		19	Bent	Bent
		20	Bent	Bent
		21	Broken	Broken
		22	Broken	Broken
		23	Broken	Broken
		24	Broken	Broken

Pada tabel 25, seluruh pin berhasil diklasifikasikan dengan tepat sesuai dengan kondisi aktualnya, tanpa adanya kesalahan deteksi (*False Positive*) maupun objek yang terlewat (*False Negative*).

Tabel 26. Hasil Pengujian *User Interface* 15

Gambar		No Pin	Label <i>Actual</i>	Hasil Prediksi
		1	Bent	Bent
		2	Bent	Bent
		3	Bent	Bent
		4	Bent	Bent
		5	Bent	Bent
		6	Bent	Bent
		7	Bent	Bent
		8	Bent	Bent
		9	Broken	Broken
		10	Broken	Broken
		11	Broken	Broken
		12	Broken	Broken
		13	Broken	Broken
		14	Broken	Broken
		15	Broken	Broken
		16	Broken	Broken
		17	Broken	Broken
		18	Broken	Broken
		19	Broken	Broken
		20	Broken	Bent
		21	Normal	Normal
		22	Normal	Normal
		23	Normal	Normal
		24	Normal	Normal

Pada tabel 26, hampir seluruh pin berhasil terprediksi dengan benar sesuai kondisi aktualnya. Namun, pada pin no 20 terjadi *misclassification* dari kelas *Broken* menjadi *Bent*. Masalah ini diikuti dengan *confidence score* yang sangat tinggi, yakni 0.99. Analisis visual menunjukkan bahwa tingginya skor tersebut disebabkan oleh patahan panjang yang melancip dengan orientasi yang seolah-olah menekuk ke arah dalam. Sehingga model sangat yakin mengklasifikasikan fitur patahan tersebut sebagai fitur bengkok.

4.6.2. Evaluasi *Confusion Matrix* Pengujian *User Interface*

Berdasarkan tabel 27, model menunjukkan performa yang sangat baik dengan mendominasi prediksi pada diagonal utama. Namun, terdapat beberapa pola kesalahan, khususnya pada kelas *Broken* dan *Bent*. Masalah terbesar dalam

model ini terjadi pada 11 dari 128 sampel aktual *Broken* yang terprediksi sebagai *Bent*. Jika sisa patahan memiliki permukaan yang tidak rata atau sedikit miring, model mengekstraksi fitur sudut kemiringan daripada fitur panjang, sehingga diklasifikasikan sebagai *Bent*. Kesalahan ini dapat diterima dalam konteks industri, dalam hierarki kualitas menganggap barang patah sebagai bengkok atau sebaliknya lebih aman daripada meloslakannya sebagai barang normal.

Adapun 3 dari 110 sampel aktual Normal yang terprediksi sebagai *Bent*. Dalam *Computer Vision*, bayangan di sekitar pin normal dapat terdeteksi sebagai ketebalan tambahan atau distorsi bentuk. Hal ini membuat garis lurus pin terlihat melengkung bagi model. Secara visual pin tersebut lurus, namun mungkin memiliki deviasi mikroskopis yang bagi mata manusia dianggap normal, namun bagi model sudah melewati *threshold* fitur lurus, sehingga masuk ke kategori *Bent*. Lainnya, terdapat 3 dari 122 sampel aktual *Bent* yang terprediksi sebagai Normal. Pin tersebut hanya mengalami bengkok yang sangat tipis. Model gagal menangkap lengkungan tersebut karena fitur visualnya terlalu mendekati representasi pin Normal. Jika pin bengkok tepat ke arah depan atau belakang kamera, maka pada citra 2D pin tersebut akan tetap terlihat lurus dan hanya terlihat lebih pendek atau panjang. Ini adalah keterbatasan pengambilan citra dari satu sudut pandang (*monocular vision*). Dapat dilihat bahwa terdapat 0 kesalahan antara kelas Normal dan *Broken*. Hal ini menunjukkan bahwa model sangat baik dalam membedakan kondisi pin yang utuh sempurna dengan pin yang patah. Fitur pembeda utama seperti panjang piksel atau luas area objek berhasil dipelajari dengan sempurna oleh model, ini sangat krusial untuk mencegah barang patah lolos inspeksi.

Tabel 27. Confussion Matrix Hasil Pengujian User Interface

		Aktual		
		Normal	<i>Broken</i>	<i>Bent</i>
Prediksi	Normal	106	0	3
	<i>Broken</i>	0	117	1
	<i>Bent</i>	3	11	119

4.6.3. Evaluasi *Classification Report*

Berdasarkan hasil evaluasi menggunakan *Classification Report* pada tabel 28, menunjukkan performa generalisasi yang sangat baik dengan akurasi klasifikasi mencapai 95%. Secara spesifik, kelas Normal menunjukkan kinerja yang paling stabil dan seimbang, ditandai dengan nilai *Precision* sebesar 0.97 dan *Recall* 0.97. Tingginya kedua metrik ini mengindikasikan bahwa model memiliki kemampuan *robust* dalam membedakan pin kondisi baik dari pin yang cacat, sehingga meminimalkan risiko *false acceptance* (barang cacat terkirim ke konsumen)

maupun *false rejection* (barang bagus terbuang) yang sering menjadi isu utama dalam sistem *quality control*.

Pada kelas kerusakan, kelas *Broken* memiliki nilai *Precision* tertinggi sebesar 0.99, yang berarti prediksi model terhadap kondisi patah sangatlah akurat. Namun, nilai *Recall* pada kelas ini sedikit rendah di angka 0.91. Sebaliknya, kelas *Bent* justru memiliki karakteristik yang berkebalikan, yaitu nilai *Recall* yang sangat tinggi 0.96 namun dengan *Precision* yang paling rendah 0.89. Statistik ini menegaskan temuan pada *Confusion Matrix*, di mana terdapat kecenderungan model untuk mengklasifikasikan sampel *Broken* sebagai *Bent*. Fenomena ini kemungkinan besar disebabkan oleh ambiguitas fitur visual pada kasus patahan parsial.

Tabel 28. Classification report hasil pengujian user interface

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Normal	0.97	0.97	0.97
<i>Broken</i>	0.91	0.99	0.95
<i>Bent</i>	0.97	0.89	0.93
<i>Accuracy</i>	0.95		

Rincian perhitungan manual *classification report* pada Tabel 28 menggunakan rumus sebagai berikut.

1) Kelas Normal

- *Precision*

$$Precision = \frac{TP}{FP + TP} * 100\%$$

$$Precision = \frac{106}{3 + 106} * 100\% = \mathbf{0.97}$$

- *Recall*

$$Recall = \frac{TP}{FN + TP} * 100\%$$

$$Recall = \frac{106}{3 + 106} * 100\% = \mathbf{0.97}$$

- *F1-Score*

$$F1 - Score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} * 100\%$$

$$F1 - Score = 2 \times \frac{(0.97 \times 0.97)}{(0.97 + 0.97)} * 100\%$$

$$F1 - Score = 2 \times \frac{0.94}{1.94} * 100\% = \mathbf{0.97}$$

2) Kelas *Broken*

- *Precision*

$$Precision = \frac{TP}{FP + TP} * 100\%$$

$$Precision = \frac{117}{11 + 117} * 100\% = \mathbf{0.91}$$

- *Recall*

$$Recall = \frac{TP}{FN + TP} * 100\%$$

$$Recall = \frac{117}{1 + 117} * 100\% = \mathbf{0.99}$$

- *F1-Score*

$$F1 - Score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} * 100\%$$

$$F1 - Score = 2 \times \frac{(0.91 \times 0.99)}{(0.91 + 0.99)} * 100\%$$

$$F1 - Score = 2 \times \frac{0.90}{1.9} * 100\% = \mathbf{0.95}$$

3) Kelas *Bent*

- *Precision*

$$Precision = \frac{TP}{FP + TP} * 100\%$$

$$Precision = \frac{119}{4 + 119} * 100\% = \mathbf{0.97}$$

- *Recall*

$$Recall = \frac{TP}{FN + TP} * 100\%$$

$$Recall = \frac{119}{14 + 119} * 100\% = \mathbf{0.89}$$

- *F1-Score*

$$F1 - Score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} * 100\%$$

$$F1 - Score = 2 \times \frac{(0.97 \times 0.89)}{(0.97 + 0.89)} * 100\%$$

$$F1 - Score = 2 \times \frac{0.86}{1.86} * 100\% = \mathbf{0.93}$$

Bab 5. Kesimpulan dan Saran

5.1. Kesimpulan

Berdasarkan hasil perancangan, implementasi, dan analisis data pengujian yang telah dipaparkan pada bab-bab sebelumnya, dapat ditarik kesimpulan yang menjawab tujuan penelitian sebagai berikut:

1) **Implementasi Metode Faster R-CNN pada Prototipe Sistem**

Penelitian ini telah berhasil mengimplementasikan metode *Faster R-CNN* dengan arsitektur *backbone* ResNet-50 dan FPN ke dalam sebuah prototipe sistem deteksi untuk mengklasifikasikan kerusakan pin dioda KBJ208. Implementasi dilakukan dengan strategi *Transfer Learning* (skenario *Fine-Tuning*) yang terbukti optimal dalam mengadaptasi fitur kerusakan spesifik. Algoritma ini kemudian diintegrasikan ke dalam antarmuka pengguna berbasis PyQt5, sehingga menghasilkan alat bantu inspeksi visual yang mampu mendeteksi lokasi dan jenis kerusakan secara otomatis pada lingkungan kerja skala laboratorium.

2) **Analisis Performa Sistem**

Berdasarkan hasil evaluasi menggunakan *dataset testing* (total 608 objek) dan pengujian integrasi pada *User Interface* (total 360 objek), sistem menunjukkan performa klasifikasi sebagai berikut:

- Prioritas Keamanan, pengujian sistem GUI mencapai akurasi klasifikasi sebesar 95% dan sistem terbukti efektif dalam menangani kerusakan fatal (*Broken*) dengan nilai *Recall* mencapai 99%, yang mengindikasikan kemampuan sistem dalam meminimalisir risiko lolosnya komponen patah ke tahap selanjutnya.
- Presisi Deteksi Geometri, pada deteksi kerusakan bentuk (*Bent*), sistem mencatatkan nilai *Precision* sebesar 98%. Keterbatasan minor teridentifikasi pada area sudut ekstrem citra.
- Stabilitas dan Konvergensi Model, melalui pengujian skenario terbaik, model terbukti mencapai titik konvergensi yang stabil pada *epoch* ke-300 tanpa indikasi *overfitting*. Hal ini menghasilkan sistem inspeksi yang konsisten dalam membedakan variasi kerusakan fisik meskipun pada kondisi objek yang rapat di dalam *tray*.

5.2. Saran

Berdasarkan evaluasi terhadap manfaat penelitian dan kendala yang ditemukan selama proses pengembangan, berikut adalah saran untuk pengembangan penelitian selanjutnya:

1) **Pengembangan Aspek Visual dan Dataset**

Untuk meningkatkan literatur mengenai penanganan objek material reflektif, penelitian selanjutnya disarankan untuk:

- Penambahan Sudut Pandang Kamera (*Multi-View*)
Menambahkan kamera kedua dengan sudut pandang samping (*Side View*) yang bertujuan agar sistem dapat menangkap deformasi vertikal dan retakan di bagian bawah pin yang tidak terlihat dari sudut pandang tegak lurus.
- Validasi dengan sampel cacat alami
Untuk menguji ketahanan model secara penuh, disarankan untuk menguji sistem menggunakan sampel cacat alami yang dihasilkan langsung dari kesalahan mesin di lini produksi. Hal ini akan memverifikasi apakah model mampu mengenali pola kerusakan stokastik yang mungkin berbeda dari pola simulasi manual.

2) **Integrasi Sistem dan Optimasi Kinerja**

Sebagai langkah pengembangan menuju implementasi otomasi industri yang lebih komprehensif, terdapat beberapa poin strategis yang dapat diterapkan:

- Peningkatan Kapasitas Tray, disarankan untuk melakukan optimasi pada desain *tray* dengan menambah jumlah slot komponen guna meningkatkan jumlah inspeksi dalam satu kali siklus.
- Peningkatan Perangkat Pencitraan, peningkatan jumlah slot komponen tersebut harus didukung dengan penggunaan kamera beresolusi lebih tinggi dan kualitas lensa yang lebih baik untuk memastikan detail fitur pin tetap terjaga meskipun jumlah objek dalam satu *frame* meningkat.

Daftar Pustaka

- [1] Q. Wang, M. Wang, J. Sun, D. Chen, and P. Shi, "Review of Surface-defect Detection Methods for Industrial Products Based on Machine Vision," *IEEE Access*, 2025.
- [2] J. Qin, Y. Liu, and R. Grosvenor, "A Categorical Framework of Manufacturing for Industry 4.0 and beyond," *Procedia CIRP*, vol. 52, pp. 173–178, 2016.
- [3] U. A. Maduagwu and V. M. Srivastava, "Bridge rectifier with Cylindrical Surrounding Double-Gate MOSFET: A model for better efficiency," in *Proceedings of the 25th Conference on Domestic Use of Energy (DUE)*, 2017, pp. 109–113.
- [4] H. Zhang, X. Xiao, T. Sun, and Z. Li, "Industrial diode approach to surface defect detection relying on global context attention mechanism and dynamic adjustment head," *ResearchGate preprint*, 2024.
- [5] J. H. Lau, "State of the Art of Lead-Free Solder Joint Reliability," *Journal of Electronic Packaging*, vol. 143, no. 2, pp. 1–36, 2021.
- [6] S. L. H. Oktavian, "Penerapan metode Faster Regional-Convolutional Neural Network (Faster R-CNN) untuk klasifikasi jenis kerusakan jalan," Tugas Akhir, Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia, 2020.
- [7] G. A. Pratama, E. Y. Puspaningrum, and H. Maulana, "Convolutional Neural Network Dan Faster Region Convolutional Neural Network Untuk Klasifikasi Kualitas Biji Kopi Arabika," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 3, pp. 2776–2785, 2024.
- [8] S. Jiang, X. Wei, and Z. Yang, "Defect Detection of Pantograph Slider Based on Improved Faster R-CNN," in *Proceedings of the 31st Chinese Control and Decision Conference (CCDC)*, 2019, pp. 5278–5283.
- [9] IPC, *IPC-A-610G: Acceptability of Electronic Assemblies*, Bannockburn, IL, USA: IPC, 2017 .
- [10] Rizqi. F. Ahmad, Riyan. P. Yefta, and Endarko, "Karakteristik Dioda (E9)," *Jurnal Elektronika Dasar li*, vol. 1114100089, pp. 1–5, 2016.
- [11] A. C. Ian Goodfellow, Yoshua Bengio, "Deep Learning," *MIT Press*, vol. 521, no. 7553, p. 785, 2017, doi: 10.1016/B978-0-12-391420-0.09987-X.
- [12] M. Ichwan and R. Siti Syifa, "Klasifikasi citra bibit tanaman menggunakan convolutional neural network dan improved feature pyramid network," *Journal MIND Journal | ISSN*, vol. 8, no. 1, pp. 1–13, 2023, [Online]. Available: <https://doi.org/10.26760/mindjournal.v8i1.1-13>

- [13] C. Shorten and T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning," *J. Big Data*, 2019, doi: 10.1186/s40537-019-0197-0.
- [14] L. Perez and J. Wang, "The Effectiveness of Data Augmentation in Image Classification using Deep Learning," arXiv preprint arXiv:1712.04621, Dec. 2017.
- [15] S. Ren, K. He, and R. Girshick, "Faster R-CNN : Towards Real-Time Object Detection with Region Proposal Networks," pp. 1–9.
- [16] T.-Y. Lin, P. Dollár, R. Girshick, K. He, B. Hariharan, and S. Belongie, "Feature Pyramid Networks for Object Detection," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017, pp. 2117–2125.
- [17] S. Panigrahi, A. Nanda, and T. Swarnkar, "A Survey on Transfer Learning," *Smart Innovation, Systems and Technologies*, vol. 194, pp. 781–789, 2021, doi: 10.1007/978-981-15-5971-6_83.
- [18] R. Meng, Q. Cui, and C. Yuan, "A survey of image information hiding algorithms based on deep learning," *CMES - Computer Modeling in Engineering and Sciences*, vol. 117, no. 3, pp. 425–454, 2018, doi: 10.31614/cmcs.2018.04765.
- [19] J. Yosinski, J. Clune, Y. Bengio, and H. Lipson, "How transferable are features in deep neural networks?," *Adv. Neural Inf. Process. Syst.*, vol. 4, no. January, pp. 3320–3328, 2014.
- [20] A. Paszke *et al.*, "PyTorch: An imperative style, high-performance deep learning library," *Adv. Neural Inf. Process. Syst.*, vol. 32, no. NeurIPS, 2019.

Biodata





Nama : Salsabila Hanisaputri
TTL : Batam, 15 Juni 2005
Agama : Islam
Alamat : Perumahan Bumi Sakinah blok Mekah 1
no 20, Kel. Tembesi, Kec. Sagulung,
Kota Batam, Kepulauan Riau
Email : salsahanisa4888@gmail.com
Riwayat Pendidikan : SMK : SMK Negeri 1 Batam
SMP : SMP Negeri 43 Batam

Lampiran

Lampiran A. Dokumentasi Wawancara Narasumber
<https://drive.google.com/file/d/1W5rzZLvqFpN1AM6fxuNFECP3cabbAPL/view?usp=drivesdk>

Lampiran B. Grafik Train dan Val Loss Seluruh Skenario









Lampiran C. Logbook Bimbingan dan Pengajuan Sidang Tugas Akhir

FORMULIR LOGBOOK BIMBINGAN DAN PENGAJUAN SIDANG TUGAS AKHIR

Nama : Salsabila Hanisaputri
 NIM : 4212201028
 Pembimbing I : Adlian Jefiza, S.Pd., M.T.
 Judul : Klasifikasi Kerusakan Pin Komponen Pada Dioda Bridge Rectifier
 Menggunakan Metode *Faster R- CNN*

No	Hari/Tgl	Rincian Kegiatan	TTD Pembimbing I
1	Kamis, 23/10/2025	Pengambilan dataset menggunakan jig dan tray.	
2	Selasa, 28/10/2025	Pengerjaan sampai pada tahapan labelling dataset.	
3	Senin, 3/11/2025	Penyusunan arsitektur dan pelaksanaan training model	
4	Senin, 17/11/2025	Membahas hasil training Dimana hasilnya harus melebihi 3 penelitian terdahulu di pendahuluan latar belakang.	
5	Selasa, 25/11/2025	Membahas hasil training 6 skenario percobaan training termasuk nilai dan grafik, selanjutnya melakukan pengujian menggunakan hasil skenario terbaik.	
6	Jumat, 28/11/2025	Analisa hasil training terbaik	
7	Selasa, 2/12/2025	Melakukan demo gui	
8	Kamis, 4/12/2025	Melakukan pengambilan data pengujian	
9	Selasa, 16/12/2025	Melakukan demo alat secara real time	
10	Jumat, 19/2025	Penyusunan buku bab 4	

Berdasarkan hasil bimbingan yang telah dilaksanakan selama 3 bulan dan telah disetujui oleh dosen pembimbing, maka dengan ini saya mengajukan diri sebagai peserta Sidang Tugas Akhir.

Batam, 19 Desember 2025
 Peserta



NIM: 4212201028

**Hapus yang tidak perlu.
 Jumlah bimbingan minimal 10 kali. Dalam satu minggu maksimal bimbingan yang dihitung adalah 2 kali.*