

Implementasi jaringan syaraf tiruan sebagai pendeteksi kecacatan pada Printed Circuit Board (PCB)

Rayhan Gunawan, Sumantri Kurniawan R
Teknologi Rekayasa Elektronika
Politeknik Negeri Batam
Batam, Indonesia
email:rayhangunawan102@gmail.com

Sumantri Kurniawan R
Teknologi Rekayasa Elektronika
Politeknik Negeri Batam
Batam, Indonesia
email:sumantri@polibatam.ac.id

Abstract—Papan sirkuit cetak (*Printed Circuit Board/PCB*) merupakan komponen vital pada perangkat elektronik modern, namun proses manufakturnya rentan menimbulkan cacat seperti open circuit, short, spur, dan mouse bite. Keterbatasan metode inspeksi visual manual dalam hal konsistensi dan efisiensi mendorong kebutuhan akan sistem inspeksi otomatis yang andal. Penelitian ini menerapkan sistem deteksi cacat otomatis pada PCB menggunakan model berbasis arsitektur *Convolutional Neural Network (CNN)*, yaitu *You Only Look Once* versi 8 (*YOLOv8*). Dengan menggunakan dataset citra PCB yang telah dianotasi, model dilatih dengan teknik augmentasi data dan dievaluasi kinerjanya menggunakan metrik *Precision*, *Recall*, *F1-Score*, serta analisis visual. Hasil pengujian menunjukkan bahwa model yang dikembangkan mencapai kinerja yang baik dengan akurasi keseluruhan 99,5%, *Precision* 100%, *Recall* 99,2%, dan *F1-Score* 99,5%. Analisis lebih lanjut juga mengindikasikan kemampuan model untuk mendeteksi cacat berukuran kecil yang dominan di area tengah PCB. Hasil ini menunjukkan bahwa pendekatan yang diterapkan mampu memberikan deteksi yang cepat, akurat, dan konsisten, sehingga berpotensi besar untuk diimplementasikan pada sistem kontrol kualitas di industri manufaktur elektronik.

Keywords—Deteksi Cacat, *Printed Circuit Board (PCB)*, *Convolutional Neural Network (CNN)*, *You Only Look Once (YOLO)*.

I. PENDAHULUAN

Papan sirkuit cetak (PCB) merupakan komponen esensial dalam hampir seluruh perangkat elektronik modern, mulai dari sistem kendali industri hingga smartphone. Kompleksitas tinggi dalam produksi PCB sering kali mengakibatkan munculnya berbagai jenis cacat seperti jalur putus, solder berlebih, atau lubang yang tidak terbentuk dengan sempurna [1]. Proses inspeksi visual manual (*Manual Visual Inspection/MVI*) yang umumnya digunakan memiliki keterbatasan pada aspek konsistensi, ketelitian, dan efisiensi, terutama saat produksi dalam skala besar [2]. Oleh karena itu, pengembangan sistem inspeksi otomatis berbasis kecerdasan buatan menjadi kebutuhan mendesak dalam industri manufaktur elektronik. Agani dan Kusmanto (2016) menunjukkan bahwa deteksi otomatis menggunakan neural network seperti *Backpropagation* dan *Self-Organizing Map* memungkinkan akurasi hingga

96,7%, sehingga menjadi alternatif yang layak untuk inspeksi visual manual.

Salah satu pendekatan yang menjanjikan untuk mendeteksi cacat PCB secara otomatis adalah dengan memanfaatkan *deep learning*, khususnya algoritma deteksi objek seperti *YOLO (You Only Look Once)*. *YOLO* memiliki keunggulan dalam melakukan klasifikasi dan pelokalan objek secara bersamaan dalam waktu nyata. Penelitian oleh Muttaqin et al. menunjukkan bahwa penggunaan *YOLOv5* untuk mendeteksi enam jenis cacat pada PCB mampu mencapai akurasi sebesar 93,8%, *recall* sebesar 95,4%, dan nilai *mAP* sebesar 95,3% [3]. Hal ini membuktikan bahwa arsitektur *CNN* berbasis *YOLO* layak diimplementasikan untuk kebutuhan inspeksi visual yang kompleks.

Beberapa penelitian terdahulu juga menggabungkan metode *YOLO* dengan sistem kamera dan konveyor untuk mendeteksi cacat fisik seperti lubang drill dan jalur terputus. Prahasta, misalnya, mengembangkan sistem deteksi otomatis berbasis *YOLO* dan melaporkan tingkat akurasi deteksi mencapai 89% untuk beberapa kelas cacat [4]. Sistem inspeksi menggunakan kamera dengan hasil deteksi ditampilkan secara langsung pada antarmuka pengguna, meningkatkan efisiensi proses produksi.

Meskipun metode beberapa metode yang digunakan seperti *Adaptive Neuro-Fuzzy Inference System (ANFIS)* beberapa kelemahan dalam metode ini. Kemampuan untuk menangani data yang lebih kompleks dan kecepatan inferensi masih menjadi masalah. *Edge detector* yang memiliki kekurangan Sensitif terhadap noise, kurang efektif dalam mendeteksi pola kompleks atau fitur halus [5]. Walaupun Haar Cascade dengan kekurangannya Peka terhadap skala dan orientasi objek, kurang fleksibel dibandingkan metode *deep learning* dalam mendeteksi variasi objek yang luas [6]. Dengan volume dan kompleksitas PCB yang meningkat, kebutuhan akan sistem inspeksi yang lebih cepat, akurat, dan otomatis semakin meningkat.

Selain *YOLO*, beberapa studi turut mengeksplorasi arsitektur *CNN* lanjutan seperti *ResNet-101* dan menggunakan strategi pelatihan seperti *OHEM (Online Hard Example Mining)*. Penelitian oleh Azka et al.

menunjukkan bahwa pendekatan tersebut mampu meningkatkan nilai mAP menjadi lebih dari 99%, dengan *average recall* lebih dari 99,5% pada dataset PCB industri [7].

Berdasarkan tinjauan tersebut, penelitian ini mengusulkan penerapan jaringan saraf tiruan berbasis YOLO-CNN untuk mendeteksi cacat pada PCB secara otomatis. Dataset citra PCB dikumpulkan dari berbagai sumber dan kondisi pencahayaan untuk meningkatkan generalisasi model. Pada penelitian oleh Yuswardani et al., penggunaan YOLOv5m dalam mendeteksi enam kelas cacat PCB (open circuit, mouse bite, short circuit, spur) menghasilkan nilai mAP sebesar 95,3 %, presisi 98,13 %, dan recall 95,43 % [2].

Selain itu, studi oleh IJECE (2025) menunjukkan bahwa model *YOLOv8* mencapai nilai Precision 0,953, Recall 0,945, dan F1-score 0,949, yang menegaskan keandalan kecepatan dan akurasi sistem untuk aplikasi real-time pada inspeksi PCB [8]. Oleh karena itu, evaluasi dalam penelitian ini akan menggunakan metrik presisi, recall, F1-score, dan mAP, serta analisis visual berupa bounding box dan heatmap. Validasi sistem juga dilakukan melalui pengujian silang dataset (cross-dataset) serta pengukuran efisiensi waktu inference untuk memastikan implementasi model dapat diandalkan dalam lingkungan produksi nyata.

II. METODE

A. Printed Circuit Board(PCB)

Papan sirkuit cetak atau *Printed Circuit Board (PCB)* merupakan fondasi utama bagi hampir seluruh perangkat elektronik modern, berfungsi sebagai platform untuk menopang sekaligus menghubungkan komponen-komponen elektronik melalui jalur konduktif, bantalan, dan fitur lainnya yang terukir dari lembaran tembaga. Dalam proses manufakturnya, berbagai jenis cacat dapat muncul, seperti jalur putus (*open circuit*), lubang hilang (*missing hole*), gigitan tikus (*mouse bite*), hubung singkat (*short*), dan tembaga berlebih (*spur* atau *spurious copper*) [9]. Secara historis, inspeksi kualitas *PCB* mengandalkan Inspeksi Visual Manual (*MVI*) yang memiliki kelemahan inheren terkait subjektivitas, kelelahan operator, dan inefisiensi pada skala produksi besar, sehingga mendorong pengembangan sistem inspeksi optik otomatis (*Automated Optical Inspection - AOI*) berbasis visi komputer sebagai solusi yang lebih konsisten dan efisien.




Fig. 1. Jenis cacat dalam PCB.

Keterangan Fig. 1:

- Mouse bite
- Open circuit
- Short
- Spur

B. Jaringan Saraf Tiruan

Jaringan Saraf Tiruan adalah model komputasi yang terinspirasi dari jaringan saraf biologis, terdiri dari unit-unit pemrosesan sederhana yang disebut neuron. Setiap neuron menerima input, memprosesnya, dan meneruskan hasilnya ke neuron lain melalui koneksi dengan bobot (*weight*) yang dapat diatur. Salah satu arsitektur JST yang paling berpengaruh dalam bidang visi komputer adalah *Convolutional Neural Network (CNN)*. Arsitektur *CNN* dirancang secara khusus untuk memproses data berbentuk grid, seperti citra, dengan memanfaatkan lapisan-lapisan kunci: lapisan konvolusi untuk mengekstraksi fitur hierarkis (dari tepi sederhana hingga bentuk kompleks), lapisan pooling untuk mereduksi dimensi spasial dan menciptakan invarian terhadap translasi, serta lapisan terhubung penuh (*fully connected*) untuk melakukan klasifikasi akhir. Jaringan syaraf convolutional digunakan untuk secara otomatis mempelajari hirarki fitur yang kemudian dapat digunakan untuk klasifikasi, dibandingkan dengan membuat fitur secara manual [10]. Kemampuan *CNN* dalam mempelajari representasi fitur secara otomatis dari data citra membuatnya sangat superior untuk tugas-tugas seperti klasifikasi gambar dan deteksi objek.




Fig. 2. Arsitektur jaringan syaraf tiruan.

Arsitektur Convolutional Neural Network (*CNN*) secara umum terdiri atas tiga komponen utama, yaitu lapisan konvolusi (convolution layer), lapisan pooling, dan lapisan fully connected (*FC*) [11]. Proses dimulai dari gambar masukan yang diproses oleh beberapa lapisan konvolusi yang bertugas mengekstraksi fitur spasial dari citra dengan menggunakan filter atau kernel. Setelah itu, hasil konvolusi akan diteruskan ke lapisan pooling (seperti max pooling), yang berfungsi untuk mengurangi dimensi spasial serta kompleksitas komputasi, tanpa mengorbankan fitur penting dari gambar [12].

C. You Can Look Once (YOLO)

You Only Look Once (YOLO) adalah algoritma pendeteksi objek berbasis pembelajaran mendalam yang pertama kali dikembangkan oleh Joseph Redmon pada tahun 2016. Algoritma ini terkenal dengan pendekatannya yang efisien dan cepat dalam mendeteksi objek dalam gambar atau video secara real-time. Tidak seperti metode konvensional yang menggunakan dua tahap-yaitu, usulan

wilayah dan klasifikasi objek, *YOLO* menggunakan pendekatan deteksi satu tahap. Artinya, seluruh gambar diproses dalam satu jaringan saraf yang secara langsung memprediksi kotak pembatas dan kelas objek secara bersamaan. Gambar input dibagi menjadi beberapa grid, dan setiap sel grid ditugaskan untuk memprediksi keberadaan sebuah objek dengan nilai kepercayaan dan posisi bounding box. Karena efisiensinya, *YOLO* cocok untuk digunakan dalam aplikasi real-time seperti sistem pengawasan, kendaraan otonom, dan perangkat seluler.




Fig. 3. Struktur YOLOv8.

Algoritma YOLOv8 digunakan pada penelitian ini. Salah satu keunggulan utama YOLOv8 adalah penggabungan arsitektur backbone dan head yang lebih efisien, ditambah dengan penerapan teknik seperti Mosaic augmentation, anchor-free detection, dan penggunaan fungsi deteksi adaptif seperti CIoU dan DFL (Distribution Focal Loss). YOLO v8 juga berperan sebagai model yang kuat untuk mendeteksi objek bergerak. Nilai yang tinggi dan stabil untuk metrik seperti Average Precision (AP), mean Average Precision (mAP), dan Intersection over Union (IoU) menunjukkan bahwa model ini dapat mendeteksi dan melokalisasi secara akurat objek yang bergerak [13]. Arsitektur YOLOv8 terdiri dari tiga komponen utama: *backbone*, *neck*, dan *head*. Ciri khas utama arsitektur ini adalah penggunaan blok C2f (Concatenate-2-Feature), CBS (Conv-BatchNorm-SiLU), dan SPPF (Spatial Pyramid Pooling - Fast), yang dirancang untuk efisiensi dan peningkatan akurasi pada deteksi objek berskala kecil hingga besar [14].

D. Perbandingan Metode Deteksi Objek

Pemilihan arsitektur YOLO-CNN dalam penelitian ini diperkuat melalui analisis komparatif terhadap metode-metode alternatif. Pendekatan klasik seperti Haar Cascade Classifier, meskipun menawarkan kecepatan deteksi yang tinggi, memiliki kelemahan inheren pada fleksibilitasnya. Metode ini bergantung pada fitur-fitur Haar yang kaku (pola persegi sederhana) untuk mengidentifikasi objek, sehingga sangat sensitif terhadap variasi rotasi, skala, dan iluminasi. Dalam konteks PCB, di mana cacat seperti spur atau mouse bite memiliki bentuk yang tidak beraturan dan dapat muncul

dalam orientasi apa pun, ketergantungan pada fitur yang telah ditentukan secara manual ini akan menghasilkan tingkat deteksi yang rendah dan false negative yang tinggi.

Di sisi lain, metode hibrida seperti Adaptive Neuro-Fuzzy Inference System (ANFIS) menawarkan kemampuan untuk memodelkan ketidakpastian melalui integrasi logika fuzzy. Namun, penerapannya pada data citra berdimensi tinggi terbukti tidak efisien. ANFIS memerlukan proses rekayasa fitur manual (manual feature engineering) yang ekstensif, di mana seorang ahli harus terlebih dahulu mengekstraksi serangkaian atribut numerik (misalnya, area, perimeter, momen, atau metrik tekstur) dari citra cacat. Proses ini tidak hanya subjektif dan memakan waktu, tetapi juga sulit untuk diskalakan dan seringkali gagal menangkap nuansa visual yang kompleks..

Berbeda secara fundamental, YOLO-CNN adalah model pembelajaran end-to-end yang mengatasi keterbatasan tersebut dengan mempelajari fitur secara otomatis langsung dari data piksel mentah. Melalui lapisan-lapisan konvolusi, arsitektur ini mampu membangun hierarki fitur—mulai dari deteksi tepi dan warna sederhana di lapisan awal hingga pengenalan bentuk cacat yang kompleks dan abstrak di lapisan yang lebih dalam. Kemampuan belajar representasi secara mandiri ini menghilangkan bias manusia dari proses desain fitur dan memungkinkan model untuk menemukan pola-pola subtil yang mungkin terlewatkan oleh perancang manusia. Studi komparatif menyimpulkan bahwa "model deep learning seperti YOLO secara signifikan mengungguli metode tradisional... dalam hal akurasi deteksi... sambil tetap mempertahankan kecepatan yang memadai untuk aplikasi real-time" [12]. Oleh karena itu, YOLO-CNN menawarkan keseimbangan terbaik antara akurasi, kecepatan, dan robustitas, menjadikannya pendekatan yang paling unggul dan andal untuk aplikasi inspeksi cacat PCB di lingkungan industri.

E. Flowchart Sistem

Metodologi penelitian ini dirancang secara sistematis untuk mengimplementasikan dan mengevaluasi jaringan syaraf tiruan berbasis YOLOv8 dalam mendeteksi kecacatan pada *Printed Circuit Board (PCB)*, sebagaimana diilustrasikan pada diagram alir. Proses diawali dengan tahap pengumpulan data, di mana dataset citra PCB yang mengandung berbagai jenis kecacatan dikumpulkan. Selanjutnya, data mentah tersebut memasuki tahap pra-pemrosesan, yang merupakan langkah krusial di mana proses anotasi (pelabelan) dilakukan. Pada tahap ini, enam kelas cacat spesifik diberi label bounding box sesuai dengan kategorinya, yaitu: (1) *Mouse Bite*, (2) *Open Circuit*, (3) *Short*, (4) *Spur*.

Setelah *datasheet* siap, tahap inti yaitu pengembangan dan pelatihan model jaringan syaraf tiruan menggunakan arsitektur YOLOv8 dimulai. Model dilatih menggunakan dataset yang telah dianotasi hingga mencapai tingkat konvergensi yang optimal. Model yang telah terlatih kemudian memasuki fase evaluasi kuantitatif, di mana kinerjanya diukur menggunakan metrik standar seperti *Precision*, *Recall*, *F1-Score*, dan *mean Average Precision (mAP)* pada data uji yang terpisah. Hasil dari metrik tersebut kemudian dilanjutkan ke tahap pengujian dan analisis untuk menginterpretasi kekuatan dan kelemahan model secara statistik. Sebagai langkah terakhir, dilakukan evaluasi kualitatif dengan cara mengamati secara visual

hasil prediksi model pada citra uji untuk memastikan akurasi lokalisasi dan klasifikasi cacat secara praktis sebelum penelitian dianggap selesai.




Fig. 4. Flowchart sistem.

F. Metrik Evaluasi Model Deteksi Objek

Untuk mengevaluasi kinerja sistem deteksi secara kuantitatif, serangkaian metrik standar akan digunakan. Metrik ini didasarkan pada empat hasil prediksi: True Positive (TP), yaitu cacat yang terdeteksi dengan benar; False Positive (FP), yaitu deteksi keliru pada area non-cacat; True Negative (TN), yaitu area non-cacat yang benar tidak terdeteksi; dan False Negative (FN), yaitu cacat yang gagal terdeteksi. Precision mengukur akurasi dari prediksi positif yang dibuat, dihitung dengan rumus:

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (1)$$

Recall mengukur sejauh mana sistem mampu mendeteksi seluruh cacat yang benar-benar ada pada PCB. Nilai recall yang tinggi menunjukkan bahwa sistem jarang melewatkan cacat. Rumus Recall (juga dikenal sebagai Sensitivitas atau True Positive Rate) digunakan untuk mengukur kemampuan sebuah model dalam menemukan kembali semua sampel yang sebenarnya positif, dihitung dengan rumus:

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

F1-Score adalah metrik yang menggabungkan dua metrik lain—**Precision** dan **Recall**—untuk memberikan satu skor tunggal yang mengukur akurasi sebuah model. F1-Score sangat berguna ketika Anda ingin menyeimbangkan antara Precision dan Recall, terutama saat dataset tidak seimbang (jumlah satu kelas jauh lebih banyak dari kelas lainnya).

$$F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3)$$

III. HASIL DAN PEMBAHASAN

A. Evaluasi Kinerja Model Deteksi Cacat PCB

Untuk memastikan keandalan dan efektivitas model yang diusulkan, pengukuran yang komprehensif terhadap kapabilitasnya dalam mengidentifikasi dan mengklasifikasikan berbagai jenis cacat, seperti *spur*, *short*, *open circuit*, *mouse bite*, dan menjadi esensial. Pada Fig. 5, kinerja model deteksi cacat dievaluasi menggunakan matriks kebingungan yang dinormalisasi. Matriks ini secara visual merepresentasikan proporsi prediksi model terhadap kelas aktual untuk setiap kategori cacat, termasuk kelas "background".

Berdasarkan data confusion matrix, maka dapat diperoleh nilai akurasi dengan rumus akurasi multikelas sebagai berikut:

$$Accuracy = \frac{TP}{JUMLAH\ SAMPLE} \times 100\% = \frac{3,84}{4,85} = 0,79\% \quad (4)$$




Fig. 5. Klasifikasi model deteksi cacat PCB.

Pada sumbu horizontal (Predicted), terdapat kelas-kelas yang diprediksi oleh model, yaitu "background", "spur", "short", "open_circuit", dan "mouse bite". Sementara itu, sumbu vertikal (True) merepresentasikan kelas aktual dari objek yang dideteksi. Sel-sel pada matriks menunjukkan probabilitas model dalam mengklasifikasikan kelas aktual ke dalam kelas prediksi.

Sebagai contoh, nilai 0.95 pada baris "background" dan kolom "background" menunjukkan bahwa 95% dari objek yang sebenarnya adalah "background" berhasil diprediksi dengan benar oleh model. Demikian pula, nilai 0.96 untuk "spur" dan "short" menunjukkan kinerja yang kuat dalam mengklasifikasikan cacat tersebut. Namun, terdapat nilai 0.45 untuk "mouse_bite" yang diprediksi sebagai "mouse_bite", menunjukkan bahwa model memiliki kinerja yang lebih rendah dalam mengklasifikasikan cacat ini dibandingkan

kelas lain. Angka-angka di luar diagonal utama merepresentasikan kesalahan klasifikasi; misalnya, 0.01.




Fig. 6 Confusion Matrix Model

Matriks kebingungan mentah, seperti yang ditampilkan pada Fig.6, adalah alat evaluasi kinerja model deteksi cacat yang menyajikan jumlah absolut prediksi model terhadap kelas aktual ("background", "spur", "short", "open_circuit", "mouse_bite"). Diagonal utama matriks menunjukkan jumlah prediksi benar untuk setiap kelas; misalnya, model dengan akurasi tinggi berhasil mengklasifikasikan 125 sampel "background", 151 "spur" dengan tepat. Namun, elemen di luar diagonal utama menyorongkan jumlah kesalahan klasifikasi, seperti 10 "background" yang salah diklasifikasikan sebagai "short" yang salah diprediksi sebagai "open_circuit".

Pada Fig.6 juga menunjukkan kesulitan signifikan model "mouse_bite", dengan hanya 2 prediksi benar, sementara 266 sampel "mouse_bite" salah diklasifikasikan sebagai "open_circuit".

$$Precision = \frac{TP}{TP+FP} \times 100\% = \frac{125}{125+0} = 100\% \quad (5)$$

Dari perhitungan ini, kita bisa menyimpulkan bahwa untuk kelas ini, nilai TP (True Positive) = 125 dan FP (False Positive) = 0.

Hasil presisi 100% adalah hasil yang sempurna. Ini berarti setiap kali model memprediksi kelas ini, tebakannya selalu benar. Tidak ada kasus di mana model salah mengklasifikasikan kelas lain sebagai kelas ini. Ini menunjukkan model memiliki tingkat "salah alarm" yang nol untuk kelas ini.

$$Accuracy = \frac{TP}{JUMLAH\ SAMPLE} \times 100\% = \frac{608}{611} = 0,995\% \quad (6)$$

Akurasi mengukur performa model secara keseluruhan di semua kelas. Numerator (608) adalah jumlah semua prediksi yang benar (diagonal dari confusion matrix). Denominator (611) adalah total seluruh data. Ini berarti hanya ada 3 kesalahan (611 - 608) dari total 611 data.

Akurasi sebesar 99,5% menunjukkan bahwa model Anda sangat andal dan memiliki performa yang luar biasa secara umum.

$$Recall = \frac{TP}{TP+FN} = \frac{125}{126} \times 100\% = 0,992 \quad (7)$$

Hasil recall 99,2% juga sangat tinggi. Ini berarti model berhasil mengidentifikasi 99,2% dari semua sampel yang seharusnya masuk ke kelas ini. Model hanya "melewatkan" atau salah mengklasifikasikan 1 sampel saja.

$$F1\ Score = 2 \times \frac{1 \times 0,992}{1 + 0,992} = \frac{1,984}{1,992} = 0,995 \quad (8)$$

F1 Score sebesar 99,5% menunjukkan performa yang luar biasa dan sangat seimbang. Ini artinya, untuk kelas yang dianalisis, model Anda berhasil mencapai titik temu yang hampir sempurna antara dua hal: tidak salah tebak (Presisi tinggi), tidak ada yang terlewat (Recall tinggi).

Secara keseluruhan, hasil ini memperkuat kesimpulan sebelumnya bahwa model Anda memiliki kinerja yang sangat andal dan istimewa untuk kelas ini.

B. Karakteristik Geometris Bounding Box dan Lokasi Objek

Pada Fig. 7 menunjukkan visualisasi komprehensif dari ground truth labels yang digunakan, menampilkan distribusi lebar (width) dan tinggi (height) dari bounding box cacat yang dinormalisasi relatif terhadap dimensi citra. Pada histogram lebar dan tinggi, terlihat bahwa mayoritas bounding box memiliki lebar dan tinggi kurang dari 0.1 dari dimensi citra keseluruhan, mengindikasikan bahwa cacat yang dideteksi umumnya berukuran relatif kecil. Distribusi ini, yang menampilkan puncak di dekat nilai 0.0, menunjukkan prevalensi objek-objek kecil. Informasi ini esensial untuk konfigurasi anchor box dalam arsitektur deteksi objek berbasis anchor, memastikan anchor memiliki skala dan rasio aspek yang sesuai untuk mencakup sebagian besar objek dalam dataset.




Fig. 7. Karakteristik geometris bounding box.

Matriks pada Fig. 7 menampilkan posisi pusat bounding box (x-y coordinates), yang juga dinormalisasi dari 0 hingga 1. Titik-titik pada plot ini tersebar di seluruh area citra, namun dapat diamati konsentrasi yang lebih padat di area tengah dan sedikit ke arah bawah gambar, menunjukkan bahwa cacat cenderung lebih sering muncul di wilayah tersebut dibandingkan di tepi citra.

Analisis karakteristik geometris bounding box dan lokasi objek ini secara langsung menginformasikan

penyesuaian parameter model dan arsitektur jaringan saraf, berkontribusi pada peningkatan akurasi dan efisiensi model deteksi cacat yang dikembangkan.

C. Evaluasi Kinerja Model Deteksi Cacat: Analisis Kurva Precision, Recall, dan Precision-Recall

Fig.8 merepresentasikan kurva Recall (Sensitivity) sebagai fungsi dari ambang kepercayaan (confidence threshold) model. Kurva ini menggambarkan kemampuan model dalam mengidentifikasi semua instans positif yang relevan dalam dataset (True Positives), relatif terhadap jumlah total instans positif aktual (True Positives + False Negatives). Pada plot ini, sumbu X menunjukkan ambang kepercayaan (dari 0.0 hingga 1.0), sedangkan sumbu Y menunjukkan nilai Recall.

Bentuk kurva yang menurun secara bertahap seiring peningkatan ambang kepercayaan mengindikasikan bahwa ketika model dituntut untuk lebih yakin (confident) dalam prediksinya (ambang kepercayaan yang lebih tinggi), jumlah cacat yang berhasil ditemukan secara keseluruhan (recall) cenderung sedikit menurun. Hal ini wajar karena model akan mengabaikan deteksi yang memiliki skor kepercayaan rendah, yang mungkin saja merupakan True Positives pada ambang yang lebih rendah.




Fig. 8 Kurva Recall

Pada plot ini, sumbu X juga menunjukkan ambang kepercayaan (dari 0.0 hingga 1.0), dan sumbu Y menunjukkan nilai Precision. Bentuk kurva yang cenderung meningkat atau stabil pada nilai tinggi seiring peningkatan ambang kepercayaan menunjukkan bahwa ketika model lebih yakin dalam prediksinya, proporsi deteksi yang benar (precision) juga meningkat atau tetap tinggi.




Fig. 9 Hasil Uji Coba Model

Pengujian terhadap model deteksi objek YOLOv8 yang berbasis Arsitektur Jaringan Saraf Konvolusional (CNN) menunjukkan kapabilitas yang efektif dalam deteksi cacat multi-kelas pada Printed Circuit Board (PCB). Model ini berhasil mengidentifikasi dan melokalisasi beragam kategori cacat—termasuk open_circuit, short, spur, dan mouse_bite—dengan skor kepercayaan (confidence score) yang tinggi pada kasus-kasus yang jelas secara visual. Meskipun demikian, analisis mendalam mengungkap adanya variabilitas skor kepercayaan yang signifikan, serta deteksi terhadap cacat valid dengan skor yang sangat rendah (misalnya, 0.3).

Fenomena ini mengindikasikan tantangan kritis dalam penentuan ambang batas kepercayaan (confidence threshold) yang optimal, karena penetapan ambang batas yang terlalu tinggi akan mengakibatkan terjadinya false negative—kegagalan sistem untuk melaporkan cacat yang ada. Oleh karena itu, keandalan model untuk aplikasi kontrol kualitas sangat bergantung pada strategi mitigasi inkonsistensi skor dan kalibrasi ambang batas secara cermat untuk menyeimbangkan sensitivitas deteksi dengan tingkat alarm palsu.

IV. KESIMPULAN

Penelitian ini mengimplementasikan sistem deteksi kecacatan pada Papan Sirkuit Cetak (PCB) berbasis jaringan syaraf tiruan. Model yang dikembangkan dengan arsitektur Convolutional Neural Network (CNN) menunjukkan kapabilitas yang andal dalam mengidentifikasi dan melokalisasi beragam jenis cacat dari citra visual. Kinerja model telah dievaluasi dan dioptimalkan, menghasilkan metrik performa yang sangat tinggi. Sistem ini mencapai akurasi keseluruhan 99,5%, presisi 100%, recall 99,2%, dan F1-score 99,5%. Hasil ini membuktikan bahwa pendekatan yang digunakan efektif untuk tugas inspeksi PCB, termasuk dalam mendeteksi cacat berukuran kecil yang sering menjadi tantangan. Dengan kemampuan deteksi yang akurat dan konsisten, sistem ini berpotensi besar untuk mengurangi jumlah produk cacat yang lolos ke tahap akhir, sehingga dapat menekan biaya produksi dan meningkatkan efisiensi secara signifikan dibandingkan metode inspeksi manual yang subjektif. Implementasinya dapat memperkuat rantai produksi dan meminimalkan risiko kegagalan produk di tangan konsumen.

REFERENSI

- [1] T. S. Chi *et al.*, “Enhancing EfficientNet-YOLOv4 for Integrated Circuit Detection on Printed Circuit Board (PCB),” *IEEE Access*, vol. 12, pp. 25066–25078, Feb. 2024, doi: 10.1109/ACCESS.2024.3359639.
- [2] A. Zainul Muttaqin, I. Nawawi, and J. Pamungkas, “Implementasi Machine Learning Pada Deteksi Kecacatan Printed Circuit Board,” *Jurnal Vocational Teknik Elektronika dan Informatika*, vol. 12, no. 1, pp. 44–51, Mar. 2024, doi: 10.24036/voteteknika.v12i1.127224.
- [3] E. Bagus Nugroho, F. Akhyar, and L. Novamizanti, “Metode Deteksi Obyek Berbasis Computer Vision dan Deep Learning untuk Sistem Inspeksi Cacat pada Permukaan Printed Circuit Board (PCB),” in *e-Proceeding of Engineering*, Bandung, Apr. 2024, pp. 801–807.
- [4] A. Dwi Santoso, F. Budi Cahyono, B. Prahasta, I. Sutrisno, and A. Khumaidi, “Development of PCB Defect Detection System Using Image Processing With YOLO CNN Method,” *International Journal Of Artificial Intelligence Research*, vol. 6, no. 1, Jun. 2022, doi: 10.29099/ijair.v6i1.343.
- [5] M. Vechione and R. L. Cheu, “Comparative evaluation of adaptive fuzzy inference system and adaptive neuro-fuzzy inference system for mandatory lane changing decisions on freeways,” *Journal of Intelligent Transportation Systems: Technology, Planning, and Operations*, vol. 26, no. 6, pp. 746–760, Aug. 2022, doi: 10.1080/15472450.2021.1967153.
- [6] R. Y. Adhitya, A. Khumaidi, S. T. Sarena, S. Kautsar, B. Widiawan, and F. L. Afriansyah, “Applied Haar Cascade and Convolution Neural Network for Detecting Defects in the PCB Pathway,” in *CENIM 2020 - Proceeding: International Conference on Computer Engineering, Network, and Intelligent Multimedia* 2020, Institute of Electrical and Electronics Engineers Inc., Nov. 2020, pp. 408–411. doi: 10.1109/CENIM51130.2020.9297996.
- [7] F. AKHYAR, L. NOVAMIZANTI, and T. RIANIARNI, “Sistem Inspeksi Cacat pada Permukaan Kayu menggunakan Model Deteksi Obyek YOLOv5,” *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 10, no. 4, pp. 990–1005, Oct. 2022, doi: 10.26760/elkomika.v10i4.990.
- [8] J. Kustija, D. Fahrizal, M. Nasir, A. Adriansyah, and M. H. Muttaqin, “Object detection in printed circuit board quality control: comparing algorithms faster region-based convolutional neural networks and YOLOv8,” *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 15, no. 3, pp. 2796–2808, Jun. 2025, doi: 10.11591/ijece.v15i3.pp2796-2808.
- [9] J. Zheng, X. Sun, H. Zhou, C. Tian, and H. Qiang, “Printed Circuit Boards Defect Detection Method Based on Improved Fully Convolutional Networks,” *IEEE Access*, vol. 10, pp. 109908–109918, 2022, doi: 10.1109/ACCESS.2022.3214306.
- [10] M. Mustafa Taye, “Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions,” *Computation*, vol. 11, no. 3, pp. 1–23, Mar. 2023, doi: 10.3390/computation11030052.
- [11] A. Dhillon and G. K. Verma, “Convolutional neural network: a review of models, methodologies and applications to object detection,” *Progress in Artificial Intelligence*, vol. 9, no. 2, pp. 85–112, Jun. 2020, doi: 10.1007/s13748-019-00203-0.
- [12] A. Zafar *et al.*, “A Comparison of Pooling Methods for Convolutional Neural Networks,” *Applied Sciences (Switzerland)*, vol. 12, no. 17, Sep. 2022, doi: 10.3390/app12178643.
- [13] M. Safaldin, N. Zaghdien, and M. Mejdoub, “An Improved YOLOv8 to Detect Moving Objects,” *IEEE Access*, vol. 12, pp. 59782–59806, 2024, doi: 10.1109/ACCESS.2024.3393835.
- [14] M. A. Saleem, N. Senan, F. Wahid, M. Aamir, A. Samad, and M. Khan, “Comparative Analysis of Recent Architecture of Convolutional Neural Network,” *Math Probl Eng*, pp. 1–9, Mar. 2022, doi: 10.1155/2022/7313612.