BAB II
TINJAUAN PUSTAKA

2.1 Tinjauan Pustaka

2.1.1. Penerapan klasifikasi kerusakan PCB dengan representasi *bounding box*

Pendekatan klasifikasi kerusakan PCB berbasis *bounding box* merupakan metode yang paling umum digunakan dalam penelitian deteksi kecacatan PCB berbasis *computer vision* dan *deep learning*. Sejumlah penelitian terdahulu telah mengadopsi pendekatan ini untuk mendeteksi berbagai jenis kecacatan PCB. Weerakkody et al. [6] menggunakan *Faster* R-CNN dengan *backbone* ResNet-50 untuk mendeteksi dan mengklasifikasikan enam jenis cacat PCB, termasuk *mouse bite*, *open circuit*, *spur*, *spurious copper*, *short*, dan *missing hole*. Pada penelitian tersebut, setiap kecacatan direpresentasikan sebagai *bounding box* yang menjadi dasar proses klasifikasi, dan menghasilkan nilai *precision* dan *recall* yang cukup baik. Hal ini menunjukkan bahwa pendekatan berbasis *bounding box* mampu melakukan lokalisasi dan identifikasi cacat secara efektif pada citra PCB. Meskipun demikian, pendekatan berbasis *bounding box* memiliki keterbatasan dalam merepresentasikan karakteristik fisik jalur PCB secara detail. *Bounding box* hanya memberikan informasi spasial kasar mengenai lokasi cacat, tanpa menggambarkan bentuk geometris, ketebalan jalur, atau hubungan konektivitas antarjalur PCB. Akibatnya, beberapa jenis kecacatan yang memiliki perbedaan struktural halus, seperti *open circuit*, *spur*, dan *spurious copper*, berpotensi sulit dibedakan apabila hanya mengandalkan representasi *bounding box* semata.

Penelitian yang dilakukan oleh Lim et al. [13] mengembangkan model deteksi kecacatan PCB berbasis *deep learning* menggunakan arsitektur YOLOv5, di mana setiap jenis kecacatan direpresentasikan dalam bentuk *bounding box* sebagai keluaran utama sistem deteksi. Penelitian ini melakukan optimasi pada *feature pyramid network* dan fungsi *bounding box regression* untuk meningkatkan sensitivitas terhadap kecacatan berukuran kecil, serta mencapai performa deteksi

dan kecepatan inferensi yang tinggi untuk aplikasi *real-time* di lingkungan manufaktur. Namun demikian, pendekatan yang digunakan masih sepenuhnya bergantung pada representasi *bounding box* dan fitur visual global hasil ekstraksi jaringan, tanpa melibatkan analisis bentuk geometris maupun konektivitas jalur PCB yang secara fisik merepresentasikan karakteristik spesifik dari jenis kecacatan yang terjadi.

Berdasarkan uraian tersebut, dapat disimpulkan bahwa sebagian besar penelitian klasifikasi kerusakan PCB berbasis *computer vision* dan *deep learning* masih mengandalkan representasi *bounding box* sebagai keluaran utama dalam proses deteksi dan klasifikasi kecacatan. Pendekatan ini terbukti efektif untuk keperluan lokalisasi dan identifikasi awal cacat pada citra PCB. Namun, representasi *bounding box* yang bersifat spasial global belum mampu menggambarkan karakteristik fisik jalur PCB secara detail, seperti bentuk geometris dan hubungan konektivitas antarjalur, sehingga berpotensi membatasi ketelitian klasifikasi pada jenis kecacatan dengan perbedaan struktural yang halus.

2.1.2. Penerapan deteksi citra berbasis YOLO

Deteksi citra menggunakan YOLO, juga telah dilakukan pada penelitian-penelitian terdahulu untuk deteksi klasifikasi kerusakan. Penelitian oleh Zhijiang Xiong et al. [14] mengembangkan sistem deteksi cacat pada bare PCB menggunakan arsitektur YOLOv8, yang dirancang untuk meningkatkan kecepatan dan stabilitas deteksi visual pada proses inspeksi manufaktur. Model ini menunjukkan performa tinggi dengan akurasi rata-rata di atas 97% untuk lima jenis cacat umum, serta processing time yang lebih efisien dibandingkan generasi YOLO sebelumnya, sehingga secara praktis mendukung implementasi real-time pada lini produksi. Studi tersebut menegaskan keunggulan YOLOv8 dalam menyederhanakan *feature extraction* dan mengurangi kompleksitas inferensi tanpa mengorbankan presisi. Meskipun demikian, penelitian tersebut masih menitikberatkan pada optimalisasi arsitektur YOLOv8 untuk meningkatkan akurasi dan kecepatan deteksi berbasis *bounding box*, tanpa mengintegrasikan analisis struktur dan konektivitas jalur PCB yang secara fisik merepresentasikan jenis

kecacatan yang terjadi.

Penelitian oleh Adibhatla et al. [15] mengusulkan penerapan model YOLO untuk inspeksi kualitas pada PCB, dengan menggunakan arsitektur jaringan CNN yang terdiri atas 24 lapisan konvolusional dan dua lapisan penuh untuk melatih model deteksi cacat pada *dataset* besar sekitar 11.000 citra, dan berhasil mencapai akurasi deteksi cacat sebesar 98,79 % pada PCB yang diuji. Studi ini menegaskan bahwa pendekatan *deep learning*, khususnya *detector* satu-tahap seperti YOLO, mampu memberikan performa tinggi dan efisiensi pemrosesan yang baik untuk tugas inspeksi visual di lingkungan produksi yang luas. Namun demikian, fokus utama penelitian ini masih terbatas pada deteksi keberadaan cacat secara umum tanpa pengklasifikasian secara rinci terhadap jenis kecacatan yang terjadi pada jalur PCB.

Penelitian oleh Tang, Liu, dan Wang[16] mengembangkan pendekatan YOLO-SUMAS, sebuah modifikasi dari YOLOv8 yang mengintegrasikan st*rate*gi *multi-attention* dan optimasi struktur *neck* untuk meningkatkan proses ekstraksi fitur halus pada cacat berukuran kecil pada PCB. Model ini dilaporkan mampu meningkatkan *mean Average Precision (mAP)* secara signifikan dibandingkan YOLOv8 dasar, sekaligus mempertahankan kecepatan inferensi yang diperlukan untuk inspeksi produksi. Penulis juga menekankan bahwa mekanisme perhatian bertingkat membuat model lebih sensitif terhadap pola cacat tipis, seperti *mouse-bite* atau *spurious copper*, yang kerap sulit dibedakan oleh model deteksi satu-tahap. Namun demikian, pendekatan tersebut masih menempatkan model YOLO sebagai pengambil keputusan tunggal berbasis fitur visual, tanpa melibatkan validasi berbasis struktur jalur PCB yang secara fisik merepresentasikan jenis kecacatan yang terjadi.

Berdasarkan tinjauan terhadap penelitian-penelitian terdahulu, dapat disimpulkan bahwa pendekatan deteksi berbasis *deep learning* telah menunjukkan kinerja yang baik dalam meningkatkan akurasi dan efisiensi pemrosesan dibandingkan metode konvensional. Namun demikian, sebagian besar penelitian masih berfokus pada peningkatan kinerja deteksi berbasis *bounding box* dan metrik evaluasi visual, tanpa memanfaatkan karakteristik struktural dan konektivitas jalur

PCB sebagai dasar validasi dan klasifikasi kecacatan. Oleh karena itu, masih terdapat peluang penelitian untuk mengembangkan pendekatan inspeksi PCB yang tidak hanya mengandalkan informasi visual, tetapi juga mempertimbangkan aspek struktural jalur PCB guna meningkatkan keandalan dan ketepatan klasifikasi kecacatan.

2.1.3. Penerapan *Deep Learning* untuk Klasifikasi kerusakan PCB

Inspeksi kerusakan pada PCB menggunakan *machine learning*, telah dilakukan pada penelitian-penelitian terdahulu, dengan perkembangan yang signifikan. Penelitian dari Chen et al.[17] menggunakan model *deep learning* CNN, untuk mendeteksi kecacatan PCB, yang biasa dideteksi oleh mesin *Automatic Optical Inspection* (AOI). Penelitian tersebut berhasil melakukan deteksi kecacatan PCB, dengan persentase *precision* dan *recall* masing-masing sebesar 96.96% dan 94.96%. Penelitian ini membuktikan bahwa penggunaan *machine learning* menghasilkan lebih sedikit *missjudge* dibandingkan dengan mesin AOI. Namun demikian, penelitian hanya ini berfokus pada deteksi kecacatan yang sebelumnya teridentifikasi oleh mesin AOI, khususnya kecacatan yang berkaitan dengan keberadaan, posisi, orientasi, dan kualitas penyolderan komponen, yang meliputi *component missed, component flipped, component shifted, insufficient solder, component sideward, tombstoning, dan non-wetting*. Sehingga tidak memperhatikan klasifikasi kerusakan pada jalur PCB, yaitu *spur, spurious copper, short, mouse bite ,open circuit*, dan *missing hole*.

Penelitian oleh Weerakkody et al. [6] menggunakan *Faster* R-CNN dengan *backbone* ResNet-50 untuk mendeteksi dan mengklasifikasikan enam jenis cacat PCB, termasuk *mouse bites, open circuits, spurs*, dan *spurious copper*, serta *missing Holes* dan *shorts*. Penggunaan model *Faster* R-CNN ini menghasilkan persentase *precision* dan *recall* masing-masing sebesar 89% dan 87%. Penelitian ini membuktikan deteksi citra menggunakan *deep learning*, dapat menghasilkan klasifikasi dengan rerata akurasi sebesar 87%. Namun demikian, penelitian masih berfokus pada penggunaan deteksi berbasis *bounding box* sebagai representasi visual kecacatan, dan belum mengambil langkah untuk memanfaatkan karakteristik

struktural jalur PCB, seperti bentuk geometris dan hubungan konektivitas antarjalur, sebagai dasar tambahan dalam proses klasifikasi cacat.

Berdasarkan kajian terhadap penelitian-penelitian terdahulu, dapat disimpulkan bahwa penerapan metode *deep learning* telah menunjukkan kinerja yang unggul dalam deteksi dan klasifikasi kecacatan PCB dibandingkan dengan sistem AOI konvensional. Namun, sebagian penelitian masih berfokus pada kecacatan yang berkaitan dengan pemasangan dan penyolderan komponen, sementara penelitian yang menargetkan kecacatan pada jalur PCB masih terbatas dan umumnya mengandalkan pendekatan deteksi berbasis *bounding box* semata. Pendekatan tersebut belum sepenuhnya memanfaatkan karakteristik fisik jalur PCB, seperti struktur geometris dan hubungan konektivitas antarjalur, yang secara langsung merepresentasikan jenis kecacatan yang terjadi. Oleh karena itu, diperlukan pendekatan yang tidak hanya mengandalkan informasi visual, tetapi juga mempertimbangkan aspek struktural jalur PCB untuk meningkatkan akurasi dan keandalan klasifikasi kecacatan.

2.1.4. Penerapan analisis morfologi pada PCB

Analisis morfologi telah banyak digunakan dalam bidang pengolahan citra untuk mengekstraksi karakteristik bentuk objek berdasarkan struktur geometrisnya. Pada penelitian yang dilakukan oleh Han et al. [18], deteksi kerusakan PCB dilakukan menggunakan teknik pengolahan citra yang meliputi proses pra-pemrosesan, segmentasi, serta analisis bentuk objek untuk mengidentifikasi keberadaan cacat pada papan sirkuit. Pendekatan tersebut menunjukkan bahwa karakteristik morfologi suatu objek dapat dimanfaatkan untuk membedakan area normal dan area yang mengalami kerusakan, sehingga proses identifikasi tidak hanya bergantung pada nilai intensitas piksel, tetapi juga mempertimbangkan bentuk fisik objek yang diamati.

Penelitian lain yang dilakukan oleh Li et al.. [19] membandingkan beberapa metode segmentasi objek pada citra PCB untuk memperoleh representasi area kerusakan yang lebih akurat. Hasil penelitian menunjukkan bahwa kualitas segmentasi memiliki pengaruh yang signifikan terhadap kemampuan sistem dalam

memisahkan area cacat dari latar belakang. Melalui proses segmentasi, bentuk, ukuran, serta hubungan antar bagian objek dapat direpresentasikan dengan lebih jelas sehingga memungkinkan dilakukannya analisis lebih lanjut terhadap karakteristik struktur kerusakan yang muncul pada PCB.

Berdasarkan penelitian-penelitian tersebut, analisis morfologi dan segmentasi citra terbukti mampu mengekstraksi karakteristik geometris dari kerusakan PCB. Namun demikian, pemanfaatan karakteristik tersebut umumnya masih difokuskan pada proses deteksi atau klasifikasi kerusakan. Pendekatan yang digunakan belum banyak memanfaatkan informasi struktur hasil segmentasi sebagai sarana untuk mengevaluasi kesesuaian antara hasil klasifikasi dan karakteristik fisik kerusakan yang terdeteksi. Dengan demikian, karakteristik geometris yang diperoleh melalui proses segmentasi dan analisis morfologi masih memiliki potensi untuk dimanfaatkan lebih lanjut dalam mendukung interpretasi hasil klasifikasi kerusakan PCB.

2.1.5. Penerapan Analisis Morfologi untuk Interpretasi dan Validasi Hasil Klasifikasi

Zhang et al. [20] mengusulkan pendekatan *Morphological Image Analysis and Feature Extraction for Reasoning with AI-based Defect Detection and Classification Models* yang memanfaatkan karakteristik morfologi objek untuk melakukan proses penalaran (reasoning) terhadap hasil deteksi dan klasifikasi yang dihasilkan oleh model kecerdasan buatan. Dalam penelitian tersebut, berbagai karakteristik morfologi seperti luas area cacat, panjang, orientasi, bentuk, serta kompleksitas struktur objek diekstraksi dari hasil segmentasi citra. Karakteristik tersebut kemudian digunakan sebagai dasar untuk membangun mekanisme penalaran yang dapat menjelaskan hubungan antara fitur fisik objek dengan keputusan yang dihasilkan oleh model kecerdasan buatan.

Namun demikian, pendekatan yang dikemukakan oleh Zhang dkk. masih berfokus pada pemanfaatan karakteristik morfologi untuk mendukung proses interpretasi dan penalaran terhadap hasil prediksi model kecerdasan buatan secara umum. Pemanfaatan karakteristik morfologi sebagai mekanisme evaluasi

kesesuaian antara hasil klasifikasi dan struktur fisik kerusakan yang terdeteksi, khususnya pada domain kerusakan PCB, masih belum banyak dibahas. Oleh karena itu, diperlukan analisis morfologi yang dapat dimanfaatkan untuk mendukung interpretasi serta evaluasi hasil klasifikasi kerusakan PCB berdasarkan karakteristik geometris dan topologi yang dimiliki oleh masing-masing jenis kerusakan.

2.2 Celah Penelitian

Penelitian-penelitian sebelumnya telah menunjukkan bahwa penerapan *deep learning* mampu meningkatkan akurasi dan kecepatan dalam proses klasifikasi kerusakan PCB, dan YOLO menjadi salah satu model yang memiliki performa kompetitif. Namun, meskipun hasil tersebut menjanjikan, terdapat beberapa celah penelitian yang masih perlu diperhatikan dan ditangani. Berikut beberapa celah dari penelitian terdahulu:

1. **Keterbatasan pemanfaatan analisis morfologi sebagai mekanisme validasi terhadap hasil klasifikasi kerusakan berbasis *deep learning* pada PCB,** sebagian besar studi masih menggunakan analisis morfologi sebagai alat klasifikasi jenis kerusakan PCB, belum ada penelitian yang secara khusus menggunakan analisis morfologi sebagai mekanisme validasi terhadap hasil klasifikasi kerusakan PCB, terutama pada klasifikasi yang berbasis *deep learning*.
2. **Keterbatasan fokus penelitian pada jenis kecacatan jalur PCB**, di mana sebagian besar studi masih menitikberatkan pada kecacatan yang berkaitan dengan pemasangan dan penyolderan komponen, sehingga tidak bisa melakukan deteksi kecacatan jalur PCB. Sementara penelitian yang secara khusus mengkaji kecacatan pada jalur PCB, seperti *spur, spurious copper, mouse bite, open circuit, short,* dan *missing hole*, masih relatif terbatas.
3. **Pendekatan deteksi yang masih didominasi hanya oleh representasi berbasis *bounding box*** , sehingga proses klasifikasi kecacatan masih sangat bergantung pada kemiripan visual, tanpa secara eksplisit merepresentasikan karakteristik fisik jalur PCB.

4. **Belum terintegrasinya analisis struktural pada representasi *bounding box* dan konektivitas jalur PCB dalam proses klasifikasi**, di mana sebagian besar penelitian termasuk yang menggunakan modifikasi arsitektur YOLO—masih menjadikan model deteksi sebagai pengambil keputusan utama berbasis fitur visual, tanpa validasi lanjutan berdasarkan struktur geometris dan hubungan konektivitas antarjalur.

Berdasarkan celah tersebut, penelitian ini berfokus pada pengembangan pendekatan deteksi dan klasifikasi kecacatan jalur PCB yang mengombinasikan kemampuan deteksi berbasis YOLO dengan analisis struktural dan konektivitas jalur PCB, sehingga proses klasifikasi tidak hanya didasarkan pada karakteristik visual, tetapi juga mempertimbangkan representasi fisik dan fungsional jalur PCB untuk meningkatkan akurasi dan keandalan hasil inspeksi. Sebagai pembanding, Tabel 2.2.1 menunjukkan aspek-aspek pada penelitian terdahulu dan penelitian ini.

Tabel 2.2.1 Tabel Komparasi Penelitian Terdahulu

Penelitian	**Jenis Klasifikasi**	**Metode Deteksi**	**Mekanisme verifikasi klasifikasi**	**Pendekatan yang diusulkan**
Zhijiang Xiong[14]	Klasifikasi 6 jenis kerusakan jalur PCB	*Bounding box*	Langsung menggunakan *output* model	Memanfaatkan Peningkatan model YOLOv8
Chen et al[17]	Klasifikasi jenis kerusakan pada mesin AOI	*Bounding box*	Langsung menggunakan *output* model	Memanfaatkan peningkatan model YOLO
Han et al. [18]	Klasifikasi kerusakan jalur PCB berdasarkan karakteristik morfologi	Analisis morfologi dan pengolahan citra	Verifikasi berdasarkan bentuk geometris dan konektivitas objek hasil segmentasi	Pemanfaatan operasi morfologi untuk identifikasi dan klasifikasi cacat PCB
Li et al.. [19]	Segmentasi dan identifikasi area cacat PCB	Segmentasi objek berbasis pengolahan citra dan analisis morfologi	Evaluasi hasil segmentasi melalui karakteristik bentuk dan struktur objek	Perbandingan algoritma segmentasi untuk meningkatkan deteksi cacat PCB

Penelitian	**Jenis Klasifikasi**	**Metode Deteksi**	**Mekanisme verifikasi klasifikasi**	**Pendekatan yang diusulkan**
Zhang et al. [20]	Klasifikasi cacat berbasis AI dengan interpretasi fitur morfologi	Model AI yang dikombinasikan dengan ekstraksi fitur morfologi	Analisis morfologi sebagai mekanisme *reasoning* dan interpretasi hasil klasifikasi	Integrasi analisis morfologi dan ekstraksi fitur untuk meningkatkan kejelasan keputusan model AI
Adibhatla et al.[15]	Penggunaan YOLO untuk deteksi cacat PCB	*Bounding box*	Langsung menggunakan *output* model	Penggunaan dataset besar sebanyak 11000 gambar
Weerakkody et al[6]	Penggunaan *Faster R-CNN* untuk klasifikasi 6 jenis cacat PCB	*Bounding* box	Langsung menggunakan *output* model.	Penggunaan *Faster* R-CNN dengan *backbone* Resnet
Tang et al. [16]	Penggunaan YOLO-SUMAS untuk klasifikasi 6 jenis cacat jalur PCB	*Bounding box*	Langsung menggunakan *output* model	Penggunaan YOLO-SUMAS

Penelitian	**Jenis Klasifikasi**	**Metode Deteksi**	**Mekanisme verifikasi klasifikasi**	**Pendekatan yang diusulkan**
Lim et al. [13]	Penggunaan YOLOv5 yang ditingkatkan untuk klasifikasi 6 jenis cacat jalur PCB	*Bounding box*	Langsung menggunakan *output* model	Penggunaan *feature pyramid network* dan fungsi *bounding box regression*
Pana et al. [21]	Penggunaan analisis morfologi untuk melihat konektivitas jalur PCB	Analisis struktural dan konektivitas jalur PCB	Analisis morfologi untuk melihat konektivitas jalur PCB	Penggunaan analisis morfologi untuk melihat koneksi jalur PCB
Melnyk et al. [22]	Penggunaan analisis morfologi untuk melihat jaringan otak dan mengevaluasi *brain tissue*	Analisis jaringan otak dan evaluasi *brain tissue*	Analisis morfologi untuk melihat mengevaluasi struktur *brain tissue*	Penggunaan analisis morfologi untuk melihat jaringan otak yang kecil
Brahmantya.*	Klasifikasi 6 jenis Kerusakan visual jalur PCB	*Bounding box*, yang divalidasi analisis morfologi	Verifikasi berbasis analisis morfologi dan konektivitas jalur PCB	

Penelitian ini mengusulkan metode inspeksi cacat pada Printed Circuit Board (PCB) melalui klasifikasi enam jenis kerusakan visual jalur PCB. Pendekatan yang digunakan memanfaatkan deteksi bounding box awal yang kemudian divalidasi melalui analisis morfologi serta verifikasi berbasis konektivitas jalur PCB. Dengan mengintegrasikan teknik lokalisasi dari bounding box, segmentasi, dan validasi analisis morfologi, metode dalam penelitian ini mampu mengidentifikasi serta memverifikasi area kerusakan pada jalur PCB secara lebih akurat dan terstruktur.

2.3 Landasan Teori

2.3.1. *Supervised Learning*

Supervised learning merupakan suatu pendekatan dalam *machine learning* di mana model dilatih menggunakan data yang telah memiliki label atau target keluaran yang jelas[23]. Pada proses ini, sistem belajar memetakan hubungan antara *input* (misalnya citra, teks, atau fitur numerik) dan *output* (kelas atau nilai prediksi) sehingga mampu melakukan generalisasi terhadap data baru yang belum pernah dilihat sebelumnya. Selama pelatihan, algoritma berusaha meminimalkan kesalahan prediksi menggunakan fungsi *loss* sehingga model semakin akurat dalam memprediksi label yang benar. Metode ini banyak digunakan dalam tugas klasifikasi dan regresi, termasuk dalam klasifikasi kerusakan PCB, di mana citra diperkuat dengan label jenis cacat untuk melatih model pendeteksi. Géron [24] menjelaskan bahwa *supervised learning* bekerja dengan memperkaya model berdasarkan contoh berlabel sehingga mampu melakukan generalisasi.

2.3.2. Klasifikasi

Klasifikasi merupakan salah satu tugas utama dalam bidang machine learning yang bertujuan untuk mengelompokkan suatu data atau objek ke dalam kategori tertentu berdasarkan pola dan karakteristik yang dimilikinya. Dalam konteks visi komputer, klasifikasi biasanya digunakan untuk mengenali objek tertentu pada suatu citra dengan memberikan label yang sesuai [25]. Proses klasifikasi dilakukan dengan mempelajari pola dari data latih (training data),

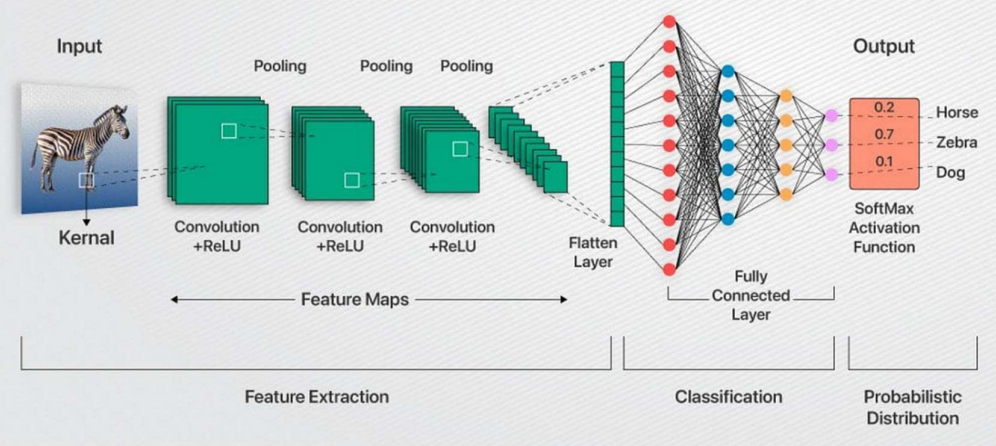
kemudian menerapkannya pada data baru untuk memprediksi kelas yang benar Model klasifikasi modern menggunakan algoritma pembelajaran mendalam (*deep learning*), terutama jaringan syaraf konvolusional (CNN), karena kemampuannya mengekstraksi fitur visual secara otomatis dan lebih *robust* dibandingkan metode tradisional berbasis handcrafted features.

Dalam sistem klasifikasi berbasis gambar, proses dimulai dengan feature extraction, yaitu tahap di mana model mengekstraksi pola seperti tepi, tekstur, bentuk, dan hubungan spasial. CNN melakukan hal ini melalui operasi konvolusi bertingkat, sehingga mampu membangun representasi visual dari fitur sederhana hingga fitur kompleks di lapisan yang lebih dalam[26]. Setelah fitur terbentuk, model melakukan classification menggunakan lapisan fully-connected untuk menentukan kelas akhir dengan menghitung probabilitas setiap label. Teknik seperti softmax sering digunakan untuk menghasilkan distribusi probabilitas yang memungkinkan model memilih kategori dengan nilai tertinggi .

2.3.3. *Convolutional Neural Network* (CNN)

CNN adalah salah satu jenis arsitektur *deep learning* yang dirancang untuk memproses data berbentuk *grid* [27], terutama citra digital. CNN bekerja melalui serangkaian lapisan konvolusi yang mengekstraksi fitur penting dari gambar, seperti tepi, tekstur, dan pola bentuk, menggunakan *kernel* yang bergerak secara lokal pada area citra. Setelah proses ekstraksi fitur, lapisan *pooling* digunakan untuk mereduksi dimensi dan meningkatkan ketahanan terhadap pergeseran objek pada gambar seperti pada ilustrasi pada Gambar 2.3.3.1**Error! Reference source not found.**. Lapisan *fully-connected* di bagian akhir jaringan digunakan untuk melakukan klasifikasi berdasarkan representasi fitur yang telah terbentuk. Dibandingkan metode pengolahan citra tradisional, CNN mampu melakukan ekstraksi fitur secara otomatis tanpa memerlukan perancangan fitur manual oleh manusia, sehingga menghasilkan performa klasifikasi yang lebih unggul dalam berbagai tugas pengenalan objek dan deteksi cacat permukaan. CNN telah terbukti efektif pada domain industri seperti inspeksi kualitas PCB karena kemampuannya mendeteksi pola cacat yang sangat kecil dan kompleks secara konsisten dan cepat

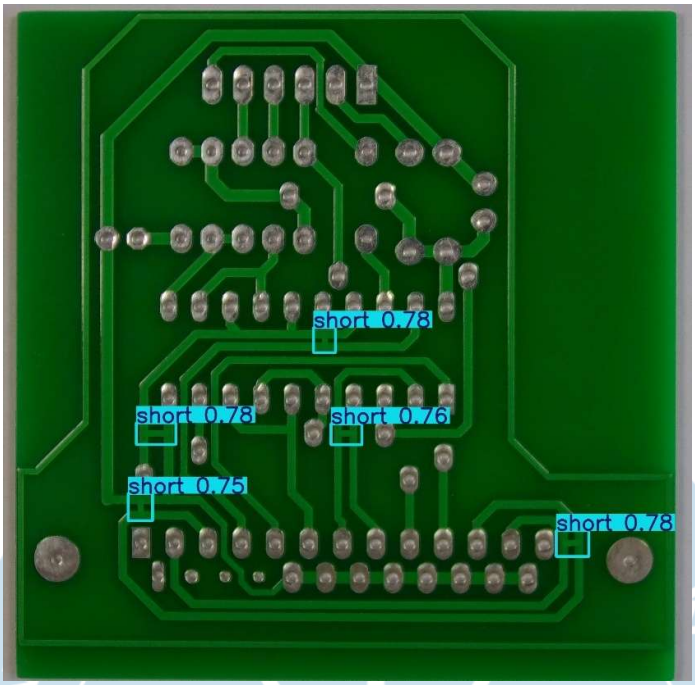
[28].



Gambar 2.3.3.1 Ilustrasi CNN – sumber: medium.com

2.3.4. *You Only Look Once* (YOLO)

YOLO adalah algoritma deteksi objek berbasis *deep learning* yang melakukan proses deteksi dan klasifikasi objek dalam satu tahap (*single-stage detector*), sehingga mampu menghasilkan prediksi secara *real-time*[29]. Tidak seperti metode dua tahap seperti R-CNN yang memisahkan region proposal dan klasifikasi, YOLO memetakan langsung citra *input* ke *bounding box* seperti pada Gambar 2.3.4.1**Error! Reference source not found.** dan probabilitas kelas dalam satu proses *forward propagation*. Citra dibagi ke dalam *grid*, dan setiap *grid* memprediksi koordinat *bounding box* serta skor kepercayaan untuk setiap kelas. Pendekatan ini memungkinkan YOLO mencapai kecepatan deteksi yang tinggi dengan akurasi yang kompetitif, menjadikannya efektif dalam aplikasi industri, termasuk inspeksi otomatis PCB, yang membutuhkan deteksi cacat secara cepat dan konsisten selama proses produksi. Versi-versi terbaru seperti YOLOv3 hingga YOLOv8 menunjukkan peningkatan dalam generalisasi, stabilitas pelatihan, dan efisiensi, sehingga meningkatkan performa pada deteksi objek berukuran kecil dan kompleks [30].



Gambar 2.3.4.1 Bounding Box

2.3.5. *Matriks Evaluasi*

Matriks evaluasi (*evaluation metrics*) digunakan untuk menilai kinerja model dalam tugas klasifikasi maupun deteksi objek. Dalam konteks deteksi cacat PCB, beberapa metrik yang sering digunakan yaitu *Precision*, *Recall*, dan *F1-Score*. *Precision* menunjukkan proporsi prediksi positif yang benar terhadap seluruh prediksi positif yang dihasilkan model, sebagaimana dirumuskan pada Persamaan 2.3.5.1 sehingga metrik ini penting untuk mengukur seberapa akurat model dalam mendeteksi cacat tanpa menghasilkan banyak *false positive*. Sementara itu, *Recall* mengukur kemampuan model dalam menemukan seluruh sampel cacat yang sebenarnya, sesuai dengan Persamaan 2.3.5.2, sehingga sangat relevan untuk meminimalkan *false negative*, terutama pada proses inspeksi kualitas produksi. *F1-Score* merupakan rata-rata harmonik dari *Precision* dan *Recall* yang dirumuskan pada Persamaan 2.3.5.3, dan digunakan ketika diperlukan keseimbangan antara kedua metrik tersebut. Selain itu, untuk tugas deteksi objek seperti pada model YOLO, metrik mAP digunakan untuk mengukur kinerja deteksi *bounding box* dan klasifikasi secara keseluruhan [31]. Nilai mAP mempertimbangkan *Intersection*

over Union (IoU), yaitu tingkat tumpang tindih antara *bounding box* hasil prediksi dengan *ground truth*. Penggunaan kombinasi metrik evaluasi yang tepat sangat penting untuk memastikan sistem inspeksi PCB mampu mendeteksi cacat secara andal, tanpa mengabaikan cacat kritis maupun menghasilkan *false alarm* yang berlebihan [32].

$$Precision = \frac{TP}{TP + FP}$$

Persamaan 2.3.5.1

$$RECALL = \frac{TP}{TP + FN}$$

Persamaan 2.3.5.2

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

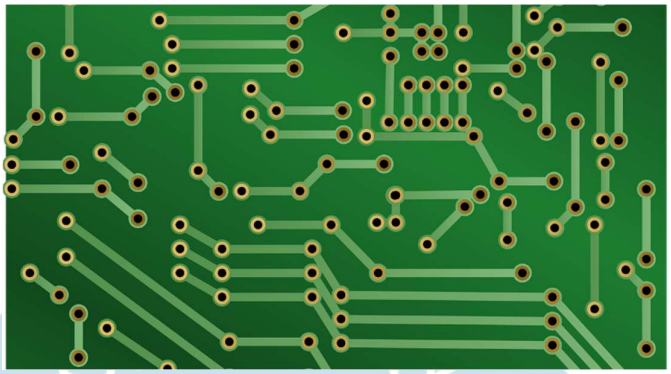
Persamaan 2.3.5.3

TP : ***True Positive***
FP : ***False Positive***
FN : ***False Negative***

2.3.6. PCB *(Printed Circuit Board)*

Printed Circuit Board (PCB) merupakan komponen dasar dalam perangkat elektronik modern yang berfungsi sebagai media untuk menghubungkan komponen elektronik melalui jalur konduktor berbahan tembaga yang dicetak pada papan isolator. PCB tidak hanya menyediakan dukungan mekanis, tetapi juga memastikan aliran sinyal dan distribusi daya berlangsung stabil dan terstruktur [33]. Gambar 2.3.6.1 menunjukkan contoh tampilan PCB, di mana jalur konduktor tembaga, lubang *via*, serta *pad* komponen tersusun membentuk jaringan konektivitas yang menghubungkan berbagai titik rangkaian secara terorganisasi. Struktur dasar PCB terdiri atas substrat seperti FR4 atau CEM-3, lapisan tembaga sebagai penghantar sinyal dan daya, solder *mask* sebagai pelindung jalur konduktor dari oksidasi dan hubung singkat, serta *silkscreen* yang digunakan untuk memberikan penanda

komponen. Kombinasi struktur tersebut memungkinkan PCB bekerja secara optimal dalam berbagai kondisi pengoperasian.



Gambar 2.3.6.1 Ilustrasi jalur PCB

Berdasarkan jumlah lapisan konduktor, PCB dibagi menjadi *single-layer*, *double-layer*, dan *multi-layer*. *Single-layer* dan *double-layer* digunakan untuk rangkaian sederhana, sedangkan multilayer—yang mampu memiliki empat hingga puluhan layer—umumnya digunakan pada perangkat berkinerja tinggi seperti motherboard, sistem telekomunikasi, dan perangkat medis karena mampu memberikan routing sinyal yang lebih efisien serta mengurangi interferensi elektromagnetik [34]. Dalam perangkat elektronik modern, PCB berperan penting dalam pengurangan noise, stabilisasi daya, serta memudahkan proses manufaktur dan perawatan.

Dalam proses produksi, PCB dapat mengalami berbagai bentuk kecacatan, seperti open circuit (jalur terputus), short circuit (hubungan singkat antarkomponen atau jalur), spurious copper (sisa tembaga tidak terkelupas sempurna), misaligned drill (ketidaktepatan lubang komponen), dan over/under-etching pada proses pengikisan tembaga. Kecacatan tersebut sangat berpengaruh terhadap performa perangkat, karena dapat menyebabkan ketidakstabilan rangkaian, hubungan pendek, panas berlebih, bahkan kegagalan komponen secara total. Oleh karena itu, proses inspeksi menjadi tahap kritis dalam memastikan kualitas PCB sebelum digunakan dalam produksi massal.

2.3.7. Semantic segmentation dan implementasinya pada U-Net

Semantic segmentation merupakan teknik pengolahan citra yang bertujuan untuk mengklasifikasikan setiap piksel pada suatu citra ke dalam kelas tertentu. Berbeda dengan klasifikasi citra yang menghasilkan satu label untuk keseluruhan gambar dan object detection yang menghasilkan lokasi objek dalam bentuk bounding box, semantic segmentation memberikan informasi yang lebih rinci dengan menentukan kelas setiap piksel pada citra. Dengan demikian, batas dan bentuk objek dapat direpresentasikan secara lebih akurat.

Pada semantic segmentation di Persamaan 2.3.7.1, setiap piksel x_i pada citra dipetakan ke dalam suatu kelas (c) yang telah ditentukan. Secara matematis, proses ini dapat dinyatakan sebagai:

$$f(x_i) = c_i$$

Persamaan 2.3.7.1

dengan:

$$(x_i) = piksel\ ke - (i)$$
$$(c_i) = kelas\ hasil\ klasifikasi\ piksel$$
$$(f) = fungis\ segmentasi$$

Hasil akhir semantic segmentation berupa peta segmentasi (segmentation map) yang memiliki ukuran sama dengan citra masukan, dimana setiap piksel memiliki label kelas tertentu.

Salah satu arsitektur *deep learning* yang banyak digunakan untuk semantic segmentation adalah U-Net yang diperkenalkan oleh Ronneberger dkk. pada tahun 2015. Arsitektur U-Net terdiri atas dua bagian utama yaitu encoder dan decoder. Bagian encoder bertugas mengekstraksi fitur dari citra masukan melalui operasi konvolusi dan downsampling, sedangkan decoder bertugas merekonstruksi fitur tersebut menjadi peta segmentasi dengan ukuran yang sama seperti citra masukan.

Proses ekstraksi fitur pada encoder dilakukan menggunakan operasi konvolusi yang secara matematis dituliskan pada Persamaan 2.3.7.2.

$$Y(i,j) = \sum_{M}\sum_{N} X(i-m, j-n)K(m,n)$$

Persamaan 2.3.7.2

dengan:

(X) = citra masukan

(K) = kernel konvolusi

(Y) = feature map hasil konvolusi

Keunggulan utama U-Net dibandingkan arsitektur encoder-decoder lainnya adalah penggunaan skip connection. Skip connection menghubungkan feature map pada encoder dengan feature map pada decoder yang memiliki ukuran spasial yang sama. Tujuannya adalah mempertahankan informasi lokasi objek yang mungkin hilang selama proses downsampling.

Pada lapisan keluaran, U-Net menghasilkan nilai probabilitas untuk setiap kelas pada setiap piksel. Probabilitas tersebut dihitung menggunakan fungsi Softmax pada Persamaan 2.3.7.3.

$$P(y_i) = \frac{e^{z_i}}{\sum_{j-1}^{c} e^{z_j}}$$

Persamaan 2.3.7.3

(z_i) = nilai keluaran neuron ke-(i),

(C) = jumlah kelas,

($P(y_i)$) = probabilitas piksel termasuk ke kelas (i).

Kelas akhir setiap piksel ditentukan menggunakan fungsi Argmax:

$$Class = \arg\max(P(y_i))$$

Pada penelitian ini, semantic segmentation digunakan untuk memisahkan area PCB menjadi beberapa kelas yang merepresentasikan karakteristik fisik jalur dan material pada papan sirkuit. Implementasi semantic segmentation dilakukan menggunakan arsitektur U-Net sehingga setiap piksel pada citra PCB dapat diklasifikasikan ke dalam kelas tertentu. Hasil segmentasi kemudian digunakan sebagai dasar untuk proses analisis morfologi dan *skeletonize* dalam rangka melakukan evaluasi terhadap karakteristik kerusakan PCB yang terdeteksi.

2.3.8. Operasi Morfologi

Operasi Morfologi merupakan salah satu cabang dari pengolahan citra yang berfokus pada analisis dan pemrosesan struktur geometris suatu objek dalam citra digital. Pendekatan ini didasarkan pada teori himpunan dan memanfaatkan elemen struktural (*structuring element*) untuk memodifikasi bentuk dan konektivitas objek pada citra biner maupun citra keabu-abuan [35]. Berbeda dengan metode berbasis statistik atau pembelajaran mesin, pemrosesan morfologi secara eksplisit mengeksplorasi karakteristik bentuk dan struktur objek, sehingga sangat sesuai untuk aplikasi inspeksi visual yang melibatkan pola geometris yang jelas, seperti jalur PCB.

Operasi dasar dalam *morphological image processing* meliputi *erosion* dan *dilation*. Operasi *erosion* digunakan untuk mengikis bagian tepi objek sehingga objek menjadi lebih kecil, yang berguna untuk menghilangkan *noise* kecil atau artefak yang tidak relevan. Sebaliknya, *dilation* berfungsi untuk memperluas area objek dengan menambahkan piksel pada batas objek, sehingga dapat digunakan untuk menutup celah kecil atau menyambungkan bagian jalur yang hampir terputus [36]. Kombinasi dari kedua operasi ini menghasilkan operasi lanjutan, yaitu *opening* (*erosion* diikuti *dilation*) dan *closing* (*dilation* diikuti *erosion*), yang umum digunakan untuk pembersihan citra biner dan perbaikan bentuk objek.

Dalam konteks inspeksi jalur PCB, operasi *opening* efektif digunakan untuk menghilangkan *noise* kecil yang bukan merupakan bagian dari jalur tembaga, sedangkan *closing* dapat membantu menutup celah sempit yang muncul akibat variasi pencahayaan atau ketidaksempurnaan segmentasi citra. Dengan demikian,

pemrosesan morfologi berperan penting dalam menghasilkan representasi jalur PCB yang lebih bersih dan konsisten sebelum dilakukan analisis lanjutan.

Selain operasi dasar tersebut, *skeletonization* atau *thinning* merupakan teknik morfologi yang digunakan untuk mereduksi objek menjadi representasi rangka satu piksel tanpa mengubah struktur topologinya [36]. *Skeleton* citra mempertahankan bentuk dan konektivitas jalur, sehingga sangat berguna untuk analisis struktur dan hubungan antarjalur pada PCB. Melalui *skeletonization*, jalur PCB dapat dimodelkan sebagai struktur graf yang terdiri dari simpul (*junction*), ujung (*endpoint*), dan cabang (*branch*), yang memungkinkan pendeteksian kecacatan seperti *open circuit*, *spur*, dan *short circuit* secara lebih representatif.

2.3.8.1.Skeletonization

Skeletonization merupakan teknik pengolahan citra yang digunakan untuk menyederhanakan bentuk suatu objek menjadi representasi garis tengah (medial axis) tanpa menghilangkan karakteristik topologi utama objek tersebut. Hasil dari proses skeletonization disebut sebagai skeleton, yaitu representasi objek dalam bentuk garis setebal satu piksel yang tetap mempertahankan struktur konektivitas, percabangan, dan bentuk dasar objek.

Pada citra biner, proses skeletonization dilakukan dengan menghilangkan piksel-piksel pada batas objek secara bertahap hingga diperoleh representasi garis tengah yang merepresentasikan bentuk objek asli. Berbeda dengan operasi erosi biasa yang dapat menghilangkan struktur objek secara signifikan, skeletonization berusaha mempertahankan informasi topologi seperti jumlah percabangan, hubungan antar segmen, dan titik ujung objek.

Secara matematis, skeleton suatu objek biner (A) dapat didefinisikan sebagai himpunan dalam Persamaan 2.3.8.1.

$$\big((A \ominus kB) - (A \ominus kB) \circ B\big)$$

Persamaan 2.3.8.1

dengan:

(S(A)) = skeleton objek,

(A) = objek biner,

(B) = elemen struktur (structuring element),

($\ominus$) = operasi erosi,

($\circ$) = operasi opening,

(K) = jumlah iterasi maksimum sebelum objek hilang.

Persamaan tersebut menunjukkan bahwa skeleton diperoleh melalui proses erosi bertahap yang dikombinasikan dengan operasi opening untuk mempertahankan bagian-bagian penting dari struktur objek.

Pada implementasi modern, proses skeletonization umumnya dilakukan menggunakan algoritma thinning seperti algoritma Zhang-Suen atau metode medial

axis transform. Metode tersebut bekerja dengan menghapus piksel batas secara iteratif sambil mempertahankan konektivitas objek hingga diperoleh representasi garis tengah dengan ketebalan satu piksel.

Skeletonization banyak digunakan pada analisis bentuk objek, pengenalan pola, ekstraksi fitur geometris, serta analisis struktur jaringan. Keunggulan utama skeletonization adalah kemampuannya mempertahankan karakteristik topologi objek meskipun ukuran area objek telah direduksi secara signifikan.

Dalam penelitian ini, skeletonization digunakan untuk mengubah hasil semantic segmentation PCB menjadi representasi jalur yang lebih sederhana. Hasil skeletonization memungkinkan analisis terhadap karakteristik topologi jalur PCB seperti konektivitas, percabangan, titik ujung, dan hubungan antar segmen jalur. Karakteristik tersebut digunakan untuk membantu identifikasi dan evaluasi jenis kerusakan PCB, seperti open circuit yang ditandai oleh terputusnya konektivitas jalur, short circuit yang ditandai oleh adanya hubungan yang tidak semestinya antar jalur, serta spur yang ditandai oleh munculnya percabangan konduktor yang tidak diinginkan.