

Metode Deteksi Obyek Berbasis Computer Vision dan Deep Learning untuk Sistem Inspeksi Cacat pada Permukaan Printed Circuit Board (PCB)

1st Eko Bagus Nugroho
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

ekobagus@student.telkomuniversity.ac.id

2nd Fityanul Akhyar
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

fityanul@telkomuniversity.ac.id

3rd Ledy Novamizanti
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

ledyaldn@telkomuniversity.ac.id

Abstrak — Perkembangan Printed Circuit Board (PCB) telah mengalami kemajuan yang sangat pesat dalam beberapa dekade terakhir. PCB merupakan sebuah wadah yang digunakan untuk menyusun dan menghubungkan komponen elektronik dalam suatu perangkat. Kecacatan pada sebuah PCB merupakan hal yang tidak dapat terpisahkan pada saat proses produksi PCB. Dengan adanya PCB yang memiliki cacat akan mempengaruhi kinerja sistem menjadi buruk, untuk mengatasi masalah tersebut dibutuhkan sebuah sistem yang mampu mendeteksi cacat PCB dengan baik, efisien, dan tepat. Penelitian ini bertujuan untuk meningkatkan kinerja deteksi cacat pada PCB dengan menggunakan *framework* MMDetection, model ResNest-101 dan teknik Online Hard Example Mining (OHEM). Fungsi dari MMDetection adalah sebagai dasar detektor obyek, penerapan model ResNest-101 sebagai backbone dari jaringan konvolusi untuk ekstraksi fitur visual yang lebih kuat serta OHEM untuk meningkatkan fokus pada sampel yang sulit selama pelatihan model. Teknik OHEM dapat membantu memprioritaskan obyek yang sulit dikenali oleh model agar dapat dipelajari dengan baik sehingga obyek dapat dideteksi secara tepat. Hasil percobaan menunjukkan bahwa penggunaan kombinasi MMDetection, ResNest-101 dan OHEM berhasil meningkatkan performa deteksi cacat pada PCB dengan mendapatkan nilai Mean Average Precision (mAP) sebesar 99,3%. Sehingga diharapkan dari penelitian ini dapat membantu memperbaiki efisiensi proses inspeksi pada proses produksi PCB.

Kata kunci— PCB, MMDetection, Resnest-101, OHEM

I. PENDAHULUAN

Printed Circuit Board (PCB) pada dasarnya adalah papan yang secara mekanis mendukung dan menghubungkan komponen elektronik secara elektrik. Ini adalah blok bangunan dasar dari setiap desain elektronik dan telah berkembang menjadi komponen yang sangat canggih selama bertahun-tahun. PCB banyak digunakan di semua produk elektronik kecuali yang paling sederhana. Pada tahun 2018, laporan analisis pasar PCB satu sisi global memperkirakan bahwa pasar PCB akan mencapai \$79 miliar pada tahun 2024 [1]. Deteksi cacat pada PCB (Printed Circuit Board) merupakan proses penting dalam industri elektronik untuk memastikan kualitas dan keandalan perangkat elektronik yang diproduksi. PCB adalah platform utama yang digunakan untuk menyusun dan menghubungkan komponen-komponen

elektronik, sehingga identifikasi dini dan penghapusan cacat sangatlah krusial.

Cacat-cacat pada PCB dapat berasal dari berbagai faktor, seperti kesalahan desain, ketidakaturan jalur konduksi, sambungan yang tidak sempurna antar komponen atau jalur konduktif, serta adanya kerusakan fisik atau kontaminasi. Cacat tersebut dapat mengakibatkan masalah fungsionalitas perangkat elektronik hingga potensi kegagalan sistem secara keseluruhan. Untuk mendeteksi cacat pada PCB secara efektif, telah dikembangkan berbagai metode deteksi yang melibatkan teknologi diantaranya (*machine vision*), pemrosesan citra secara digital, dan algoritma pembelajaran mesin (*machine learning*). Tujuan dari metode ini untuk menganalisis gambar atau data visual dari permukaan PCB guna mengidentifikasi anomali atau pola-pola tertentu yang menunjukkan adanya cacat.

Pada penelitian ini menggunakan *Deep learning* yang merupakan cabang dari pembelajaran mesin (*machine learning*) yang berfokus pada pengembangan dan penerapan model jaringan saraf tiruan atau *artificial neural networks* yang sangat rinci atau kompleks. Tujuannya adalah untuk memberikan kemampuan kepada komputer untuk belajar secara otomatis melalui contoh-contoh data dengan tingkat representasi yang semakin abstrak.

Dalam *deep learning*, terdiri dari jaringan saraf tiruan seperti *multiple layer* atau lapisan *neuron-artificial nodes*. Setiap layer tersebut menerima masukan dari layer sebelumnya, yang telah melakukan operasi matematika tertentu, dan menghasilkan output pada layer selanjutnya. Dengan demikian, informasi diproses secara hierarkis melalui serangkaian lapisan hingga mencapai output akhir.

Penelitian ini mendapatkan dukungan dari sejumlah besar penelitian sebelumnya tentang cacat PCB. Penelitian yang dilakukan oleh Runwie Ding et al. pada tahun 2019 mengusulkan model TTD-Ned: Tiny Defect Detection Network untuk deteksi PCB. Studi tersebut menemukan nilai rata-rata ketepatan rata-rata (mAP) sebesar 98,9%, tetapi hubungan peta fitur pada berbagai tingkat dan manfaat informasi struktural pada tingkat deteksi kecacatan PCB masih rendah [11].


Dengan menggunakan algoritma ResNest-101 sebagai arsitektur metode deteksi objek, penelitian yang dilakukan oleh Muhammad Azka dkk. pada tahun 2022 menunjukkan

bahwa sistem dapat mendeteksi enam jenis cacat pada PCB. Penelitian ini menghasilkan nilai akurasi sebesar 99,2% untuk akurasi rata-rata (mAP) dan nilai akurasi rata-rata (AR) sebesar 99,5% [12].

Studi lain yang dilakukan oleh A. Srivastava dkk. pada tahun 2016. Dalam penelitian ini, algoritma OHEM yang sederhana namun sangat efektif disajikan untuk melatih detektor ConvNet berbasis wilayah. Dengan memilih OHEM ini, penelitian menjadi lebih efisien dan efektif. Penelitian OHEM ini menghasilkan hasil mAP yang canggih sebesar 78,9% pada PASCAL VOC 2007 dan 76,3% pada PASCAL VOC 2012 [13].

II. METODE

Penelitian ini bertujuan untuk menghasilkan suatu sistem yang dapat mendeteksi cacat pada permukaan PCB. Jenis cacat yang dapat dideteksi yaitu *missing hole*, *open circuit*, *short*, *spur*, *spurious copper*, dan *mouse bite*. Pendeteksian dilakukan dengan metode berikut ini.



GAMBAR 1.
Blok Diagram Sistem Deteksi Cacat Permukaan PCB

A. Citra PCB

Deteksi obyek untuk sistem inspeksi cacat pada PCB menggunakan dataset publik yang di rilis oleh Peking University [1]. Dataset memiliki enam *class* cacat permukaan PCB sebagai klasifikasi, yaitu *missing hole*, *open circuit*, *short*, *spur*, *spurious copper*, dan *mouse bite*. Terdapat 10.668 gambar yang dipotong menjadi sub-gambar 600 × 600, membentuk set pelatihan dan set pengujian kami masing-masing dengan 9920 dan 2508 gambar. Dataset menyediakan file anotasi *bounding box* dalam bentuk dokumen XML. Berikut ini merupakan penjelasan mengenai enam jenis cacat PCB yaitu:

1. Open Circuit

Pada Open Circuit ataupun sirkuit terbuka kerusakan seringkali terjadi dikarenakan pada saat mencetak atau pattern printing screen dengan menggunakan tinta dan rubber squeezenya kurang jelas.

2. Short

Cacat pada PCB berjenis short dapat terjadi dikarenakan pattern printing atau tercetaknya jalur – jalur yang berhimpitan, sehingga dapat mengakibatkan jalur yang konslet (short) dan akan mengganggu kinerja PCB

3. Mouse Bite

Cacat PCB Mouse Bite merupakan kondisi di mana terdapat lubang-lubang kecil atau goresan pada jalur tembaga PCB.

4. Spur

Spur adalah cacat dengan goresan atau cabang yang terlihat seperti garis sehingga dapat membuat cacat pada PCB dan PCB menjadi tidak terhubung. Spur dapat terjadi

dikarenakan pada saat proses desain tidak dioptimalkan dengan baik, panjang jejak, jalur, dan penempatan komponen dapat menyebabkan gelombang refleksi dan gangguan sinyal, yang berujung pada munculnya spur.

5. Missing Hole

Missing hole ataupun rangkaian yang tidak terlapsi oleh tinta dapat terjadi dikarenakan pada saat pattern printing atau mencetak, tinta tidak melapsi bagian dalam lubang rangkaian, sehingga menyebabkan suatu kecacatan dan Printed Circuit Board (PCB) ini apabila digunakan tidak akan bisa berfungsi.

6. Spurious Copper

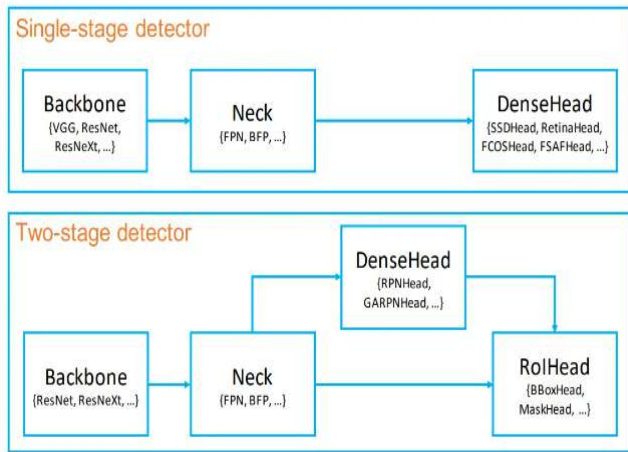
Spurious copper dapat terjadi karena kesalahan selama proses manufaktur atau proses produksi PCB. Spur terjadi dikarenakan terdapat sisa tembaga yang tidak diinginkan yang muncul pada jalur PCB atau area lainnya yang seharusnya sesuai dengan desain PCB.

B. MMDetection

MMDetection adalah *toolbox* untuk deteksi objek dari *OpenMMLab* yang berisi sekumpulan metode modul terkait deteksi objek. MMDetection merupakan *toolbox* yang terlengkap karena memiliki sekitar 200 model jaringan. MMDetection memiliki kemampuan tolok ukur untuk memudahkan dalam membuat struktur detektor baru pada kerangka dasar sehingga dapat membandingkan kinerja model. Fitur yang dimiliki MMDetection adalah sebagai berikut:

1. Menggunakan framework deteksi yang populer dan terbaru, seperti RetinaNet, Faster-RCNN, Mask-RCNN, dan sebagainya.
2. Menggunakan kumpulan data PASCAL VOC, Cityscapes, dan Coco.
3. Semua dasar bbox dan mask dijalankan pada GPU sehingga basis kode yang lain seperti Mask-RCNN-Benchmark, SimpleDet, dan Detectron2 memiliki training lebih cepat atau setara.
4. Framework pada MMDetection terdiri dari sistem deteksi objek yang berbeda dan dibuat dengan menggabungkan beberapa modul.

MMDetection terdapat arsitektur dengan 2 jenis detektor, yaitu single-stage detector dan two-stage detektor, yang dimana masing-masing detektor memiliki arsitektur tersendiri. Berikut komponen yang membentuk arsitektur keseluruhan pada Gambar 2.



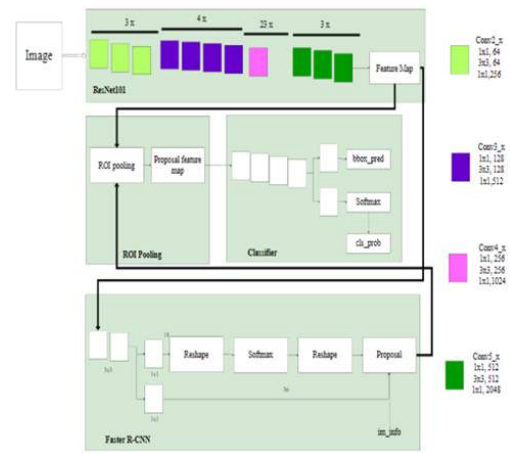
GAMBAR 2. Arsitektu MMDetection

Berdasarkan pada Gambar 2. menjelaskan tentang arsitektur dari Mmdetection sebagai berikut:

- Backbone:** seperti yang diketahui pada ResNet-50, komponen yang mengubah gambar menjadi peta fitur tanpa memiliki lapisan akhir yang sepenuhnya terhubung.
- Neck:** ruas yang menghubungkan backbone menuju head. Backbone melakukan penyesuaian atau konfigurasi ulang salah satunya adalah Fitur Pyramid Network (FPN).
- Dense Head (AnchorHead/AnchorFreeHead):** komponen AnchorHead dan AnchorFreeHead yang berfungsi di area padat peta fitur, seperti AnchorHead dan AnchorFreeHead. Contohnya seperti FCOSHead, RPNHead, dan RetinaHead.
- RoIExtractor:** penggunaan operator yang mirip dengan RoIPooling, yang menarik fitur RoIwise dari satu atau lebih peta fitur.
- RoIHead (BBoxHead/MaskHead):** bagian dari sistem yang menggunakan karakteristik RoI sebagai input dan menghasilkan prediksi tugas tertentu berbasis RoI, seperti klasifikasi dan regresi bonding box serta prediksi mask.

C. ResNest-101

Residual Network (ResNet) merupakan sebuah jaringan *bottom-up* yang digunakan untuk mengekstraksi fitur dari gambar masukan [2]. ResNet dibuat untuk dapat mengatasi degradasi problem dimana ketika layer network akan mengalami penurunan akurasi pada proses training [3]. Dasar dari arsitektur ResNet adalah *Convolutional Neural Network (CNN)* terdiri dari *convolutional layer*, *pooling layer*, dan *fully connected layer* serta penambahan skip connection pada setiap beberapa convolution layer. Arsitektur yang digunakan dapat dilihat pada Gambar 3. dibawah ini




GAMBAR 3. Arsitektur ResNest-101

Pada Gambar 3. saat menerima informasi masukkan gambar dengan ukuran khusus akan diolah dengan empat lapisan konvolusi dengan keterangan kernel masing-masing, total 101 lapisan konvolusi. Untuk menemukan objek pada gambar dapat menggunakan feature map, selain itu RoI diperoleh dari *Region Proposal Network (RPN)* yang menggunakan feature map sebagai input untuk memprediksi bounding box pada gambar. Selanjutnya kedua hasil dikumpulkan dan dikirim ke lapisan fully connected untuk mendapatkan prediksi kotak batas dan hasil klasifikasi untuk setiap kotak batas yang diprediksi. Dengan demikian, model secara keseluruhan dapat menemukan dan mngklasifikasi objek dari gambar.

D. Online Hard Example Mining

Online Hard Example Mining (OHEM) merupakan teknik bootstrap yang mengubah *Stochastic Gradient Descent (SGD)* ataupun penurunan gradien stokastik dari sampel dataset dengan cara yang tidak sama tergantung pada selesainya pengujian dataset. Metode ini memanfaatkan struktur deteksi masalah yang spesifik dimana kumpulan mini SDG tidak hanya terdiri dari satu atau dua gambar, tetapi ribuan gambar. OHEM dapat mentraining dataset yang sulit secara otomatis sehingga membuat proses training menjadi lebih efektif dan efisien. Selain itu, OHEM dapat menghilangkan beberapa heuristic dan hyperparameter yang umum digunakan [4]. Pada penelitian ini didapatkan hasil nilai *Average Precision (AP)* cacat PCB menggunakan model ResNest-101 pada bagian *short* adalah 97,7%. Sehingga penelitian ini menggunakan metode OHEM untuk meningkatkan nilai *Average Precision (AP)*.



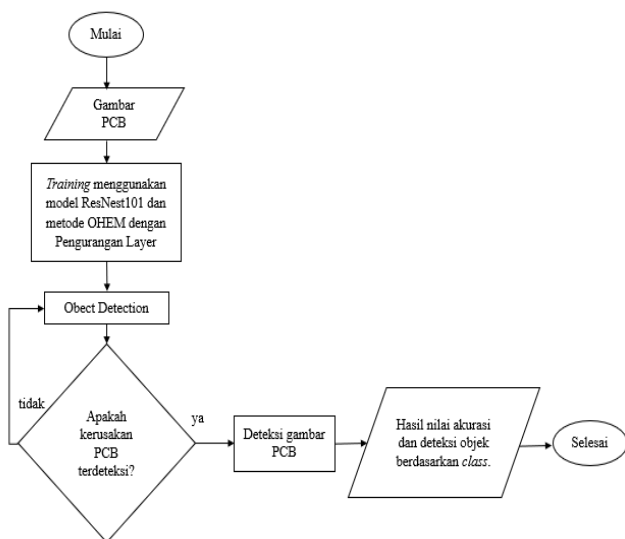
GAMBAR 4. Struktur OHEM

Pada Gambar 4. merupakan implementasi struktur OHEM dengan menggunakan dua salinan jaringan RoI. Algoritma diterapkan pada gambar untuk mengekstrak proposal wilayah terlebih dahulu. Kemudian penyatuan RoI

menggunakan semua RoI yang diekstraksi melalui pencarian selektif dan peta fitur yang diperoleh dan peta fitur sebanyak jumlah RoI dihasilkan. Pada kotak hijau menunjukkan semua RoI yang diurutkan berdasarkan nilai loss dan hanya dapat dibaca. Jaringan ini hanya meneruskan dan menghitung loss pada semua RoI input. Kemudian pada kotak merah merupakan modul pengambilan sampel hard RoI menggunakan OHEM untuk menunjukkan RoI yang dipilih.

E. Perancangan Sistem

Tahap berikutnya adalah perancangan sistem dengan menggunakan *deep learning* untuk menentukan deteksi cacat PCB yang diuji. Terdapat dua jenis algoritma yang digunakan, yaitu object detection dan classification. Berikut flowchart terkait algoritma deep learning yang digunakan dalam deteksi obyek untuk sistem inspeksi cacat pada permukaan printed circuit board (PCB) dapat dilihat Gambar 5. dibawah ini.

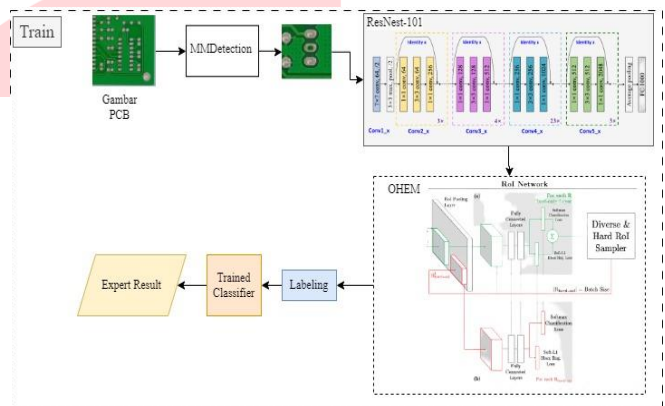


GAMBAR 5.
Flowchart Deep Learning

Deteksi obyek untuk sistem inspeksi cacat pada PCB menggunakan dataset publik yang di rilis oleh Peking University. Dataset memiliki enam class cacat permukaan PCB sebagai klasifikasi, yaitu missing hole, open circuit, short, spur, spurious copper, dan mouse bite. Terdapat 10.668 gambar yang dipotong menjadi sub-gambar 600 × 600, membentuk set pelatihan dan set pengujian kami masing-masing dengan 9920 dan 2508 gambar. Dataset menyediakan file anotasi bounding box dalam bentuk dokumen XML.

Pada training deteksi obyek menggunakan arsitektur Convolution Neural Network (CNN) sebagai backbone untuk mengekstraksi fitur dari suatu gambar. Sistem deteksi akan memproses untuk mengecek apakah PCB terdeteksi memiliki kerusakan atau tidak. Jika terdeteksi maka proses selanjutnya adalah mengklasifikasi kerusakan sesuai dengan class dan menghasilkan output deteksi sesuai dengan kerusakan PCB. Jika tidak ada kerusakan yang terdeteksi maka akan dikembalikan kepada proses training deteksi objek dan akan di proses kembali.

Algoritma yang digunakan dalam sistem deteksi PCB ini menggunakan pretrained model ResNest-101 dengan tujuan dapat meningkatkan akurasi serta efisiensi pada proses pelatihan dalam pengenalan gambar dan deteksi objek. Model ResNest-101 memiliki kelebihan dalam akurasi dan pertukaran latensi pada klasifikasi gambar. Model ResNest-101 termasuk dalam arsitektur CNN yang memiliki kedalaman tinggi sehingga memiliki performa yang baik, namun dapat mengakibatkan masalah vanishing gradient, dimana sebuah keadaan karena mengalami perkalian berkali-kali, hasil gradien yang dipelajari model tidak dapat mencapai lapisan pertama. Hal ini menyebabkan CNN tidak dapat mempelajari kesalahan yang telah dihitung. Sehingga pada pengujian ini ditambahkan metode Online Hard Example Mining (OHEM) untuk meningkatkan nilai akurasi.



GAMBAR 6.
Proses Train Model

F. Metrik Evaluasi

Untuk mengevaluasi output kinerja detektor secara kuantitatif dapat dihitung dengan menggunakan persamaan (1) dan (2) berikut ini.

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

$$Recall (\%) = \frac{TP}{TP + FN} \times 100 \quad (2)$$

Pada kedua persamaan tersebut terdapat TP, FP, dan FN. TP (*true positif*) merupakan jumlah cacat yang terdeteksi dengan benar, sementara FP (*false positif*) merupakan jumlah cacat yang tidak ada pada PCB, dan jumlah cacat yang tidak terdeteksi disebut dengan FN. Nilai *precision* menunjukkan rasio cacat yang ditemukan dan dideteksi dengan benar dari semua jenis cacat. Recall merupakan indikator sensitivitas dari detektor [6].

III. HASIL DAN PEMBAHASAN

Pada hasil sistem Metode Deteksi Obyek Berbasis Computer Vision Dan Deep Learning untuk Sistem Inspeksi Cacat Pada Permukaan Printed Circuit Board (PCB), mendapatkan hasil perbandingan kinerja lokalisasi kedalaman pembelajaran model arsitektur menggunakan nilai recall dan presisi yang digunakan sebagai matriks evaluasi. Presisi

adalah kecocokan antara data lokal yang diambil dan yang informasi dibutuhkan. Recall adalah matriks yang digunakan untuk mengukur seberapa baik sistem dalam recovering informasi. Presisi dan recall biasanya dinyatakan dalam persentase antara 1 - 100%. Sistem dapat dikatakan baik jika presisi dan recall mendapatkan hasil nilai yang tinggi.

A. Perbandingan pengujian


Pada bagian ini, dilakukan pengujian tanpa Online Hard Example Mining (OHEM) dan dengan ditambahkan OHEM. Pada Tabel dibawah ini menunjukkan hasil perbandingan nilai mAP antara ResNest, dengan ResNest yang ditambahkan metode OHEM. Pengujian menggunakan ResNest-101 pada epoch ke 20 mendapatkan nilai *mean average precision* sebesar 99,2% dan penelitian menggunakan ResNest+OHEM pada epoch 9 didapatkan nilai *mean average precision* sebesar 99,3%.

TABEL 1. Perbandingan Hasil Pengujian

Class	ResNest-101			ResNest-101+OHEM		
	20 epoch			9 epoch		
	mAP (%)	AP (%)	Recall	mAP (%)	AP (%)	Recall
Missing Hole	99,2	99,8	99,8	99,3	99,8	99,8
Mouse Bite		99,3	99,7		99,2	99,8
Open Circuit		99,5	99,8		99,6	99,8
Short		97,7	98,3		98,2	98,5
Spur		99,3	99,5		99,5	99,7
Spurious Copper		99,6	99,8		99,4	99,7


B. Deteksi Objek

Proses latih algoritma menggunakan Google Colab Pro. Hasil yang didapatkan seperti Gambar 7.




GAMBAR 7. Akurasi dari model ResNest-101+OHEM

Pada Gambar 7 adalah grafik akurasi dari deteksi PCB menggunakan model ResNest-101 ditambah dengan metode OHEM, yang mendapatkan hasil nilai akurasi 98,04%.



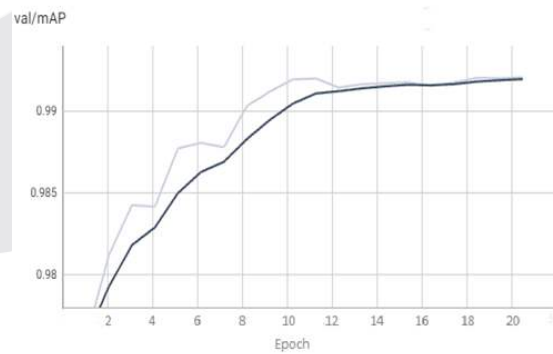
GAMBAR 8. Loss

Gambar 8. menunjukkan hasil Grafik loss pada training deteksi PCB menggunakan model ResNest-101 ditambah metode OHEM. Didapatkan hasil loss 0,1285, model yang digunakan merupakan hasil yang cukup baik karena mendapatkan nilai loss kecil.



GAMBAR 9. Grafik AP@50

Pada Gambar 9. merupakan grafik nilai AP pada deteksi PCB. Didapatkan hasil nilai AP menggunakan model ResNest-101 ditambah metode OHEM yaitu 99,3%.




GAMBAR 10. Grafik mAP

Gambar 10. merupakan grafik nilai mAP pada deteksi PCB, dimana hasil yang didapatkan adalah 99,27%. Hasil tersebut merupakan hasil yang cukup bagus dibandingkan dengan pengujian dengan model lainnya.

C. Hasil Pengujian Deteksi Gambar Cacat PCB

Setelah dilakukan pengujian dari sistem Deteksi Cacat PCB menggunakan metode ResNest 101 ditambahkan

dengan metode OHEM, didapatkan hasil pada Gambar 11. berikut dimana PCB yang dideteksi dapat mendeteksi dan menampilkan kerusakan pada PCB yang cukup akurat sesuai dengan masing-masing class pada cacat PCB.



GAMBAR 11.

Hasil Deteksi PCB kategori kerusakan (a) Missing Hole, (b) Mouse Bite, (c) Open Circuit, (d) Short, (e) Spur, (f) Spurious Copper

IV. KESIMPULAN

Penelitian ini menghasilkan sistem deteksi cacat pada permukaan PCB menggunakan model MMDetection dengan penambahan ResNest-101 dan OHEM. Nilai mAP tertinggi pada dataset PCB mencapai 99,2% tanpa menggunakan *Online Hard Example Mining* (OHEM), namun saat diberikan penambahan OHEM, nilai mAP mengalami peningkatan sebesar 99,3%. Oleh karena itu pada penelitian ini dipilih sistem deteksi cacat pada permukaan PCB menggunakan model MMDetection dengan penambahan ResNest-101 dan OHEM agar proses inspeksi cacat pada permukaan PCB menjadi lebih efektif dan efisien.

REFERENSI

- [1] Ixiaohuihuihui, "Tiny-Defect-Detection-for-PCB," pp. <https://github.com/Ixiaohuihuihui/Tiny-Defect-Detection-for-PCB>, 5 October 2021.
- [2] S. Yuliyanto, "Sistem Inspeksi Permukaan Baja Berbasis Deep Learning Menggunakan Metode Anchor-Free," *Juritek*, vol. 2, 2022.
- [3] Gunawan and I. Kadek, "Segmentasi Buah Apel Menggunakan Framework Yolact Arsitektur Resnet-101 segmentasi Buah Apel Menggunakan Framework Yolact Arsitektur Resnet-101," *Jurnal Ilmiah Teknologi dan Komputer*, vol. 1, no. 2, pp. 234-242, 2020.
- [4] Adzkia, M. Arland, and A. W. Setiawan, "Deteksi Pneumonia Menggunakan Citra Sinar-X Paru Berbasis Residual Network," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 9, no. 2, pp. 373-380, 2018.
- [5] W. Wiguna, Pengembangan User-Menu Pada Zuken CR_5000 Untuk Hole Check Pada Desain PCB, *Diss. Universitas Komputer Indonesia*, 2017.
- [6] F. Akhyar, L. Novamizanti & T. Riantiarni, "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, 2022.
- [7] R. Ding, L. Dai, G. Li, and H. Liu, "Tdd-Net: A Tiny Defect Detection Network For Printed Circuit Boards," *CAAI Transactions on Intelligence Technology*, no. 2, pp. 110-116, 2019.
- [8] Y. LeCun, Y. Bengio and G.Hinton, "Deep Learning Nature," Vols. 4, No.2 , pp. 110-116, 2019.
- [9] S. J. P. Kurniasari. Nur, "Deteksi Jalur yang Putus pada Rangkaian Listrik dalam PCB menggunakan Metode Convolutional Neural Network," *Jurnal Sistem Cerdas dan Rekayasa*, vol. 3, 2021.
- [10] Jay, "Kotak Alat MMDetection untuk Deteksi Objek," p. <https://hashdork.com/id/mmdetection/>, 22 September 2022.
- [11] R. Ding, L. Dai, G. Li, and H. Liu, "Tdd-Net: A Tiny Defect Detection Network For Printed Circuit Boards," *CAAI Transactions on Intelligence Technology*, no. 2, pp. 110-116, 2019.
- [12] F. Akhyar, L. Novamizanti, M. A. Imaddudin, I. H. Pratama, S. R. Firmansyach, M. C. Chang, and C. Y. Lin, "Observation of Attention Mechanism Baseline for PCB Surface Inspection System," *In 2022 IEEE Asia Pacific Conference on Wireless and Mobile (APWiMob)*, pp. 1-6, December 2022.
- [13] A. Shrivastava, A. Gupta, and R. Girshick, "Training Region-Based Object Detectors with Online Hard Example Mining," *Proceedings of the IEEE conference on Computer Vision and Pattern Recognition*, pp. 761-769, 2016.
- [14] N. D. Miranda, L. Novamizanti, and S. Rizal, "Convolutional Neural Network Pada Klasifikasi Sidik Jari Menggunakan Resnet-50," *J. Tek. Inform.*, vol. 1, no. 2, pp. 61-68, 2020.
- [15] P. D. Wananda, L. Novamizanti, R. D. Atmaja, "Sistem Deteksi Cacat Kayu dengan Metode Deteksi Tepi SUSAN dan Ekstraksi Ciri Statistik," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi & Elektronika*, Vol 6, No 1, 2018.
- [16] H. M. Lathifah, L. Novamizanti, and S. Rizal, "Fast and Accurate Fish Classification from Underwater Video using You only Look Once," *in IOP Conference Series: Materials Science and Engineering*, IOP Publishing Ltd, Dec. 2020.
- [17] F. Akhyar, L. Novamizanti, T. Putra, E. N. Furqon, M. C. Chang & C. Y. Lin, "Lightning YOLOv4 for a surface defect detection system for sawn lumber," *In 2022 IEEE 5th International Conference on Multimedia Information Processing and Retrieval (MIPR)*, pp. 184-189, 2022.

