

Model Deep Learning untuk Sistem Inspeksi Cacat Permukaan Printed Circuit Board (PCB)

1st Syifa'ul Erdianingtyas
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

syifaerd@student.telkomuniversity.ac.id

2nd Ledy Novamizanti
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

ledyaldn@telkomuniversity.ac.id

3rd Fityanul Akhyar
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

fityanul@telkomuniversity.ac.id

Abstrak — *Printed Circuit Board (PCB)* adalah papan dengan jalur sirkuit logam yang menghubungkan komponen elektronik satu sama lain. Seiring dengan perkembangan teknologi terutama pada bidang elektronik, produksi papan PCB selalu meningkat karena sering digunakan dalam kebutuhan barang elektronika dalam sehari-hari. Contohnya seperti televisi, lampu, dan lainnya. Pada desain papan PCB jika terdapat salah satu jalur yang tidak terhubung atau rusak, mengakibatkan perangkat elektronik tidak dapat berfungsi dengan baik. Untuk menghindari kerusakan tersebut pada rangkaian PCB, diperlukan sistem deteksi objek untuk memeriksa kerusakan pada desain papan PCB. Pada jurnal ini membahas tentang empat model pengenalan objek *detection* pembelajaran mendalam yang populer untuk menentukan mana yang paling efektif dalam hal mendeteksi kerusakan pada PCB. Keempat model pretrained tersebut adalah Carafe, Grid-CNN, Res2Nest, ResNest-101, dan ResNest-101 ditambah dengan metode OHEM. Hasil pengujian model menunjukkan bahwa model ResNeSt memperoleh nilai akurasi sistem inspeksi permukaan PCB paling unggul dengan presisi rata-rata (mAP) yaitu 99,2%. Pengujian model menjadi lebih baik ketika ditambahkan dengan metode Online Hard Example Mining (OHEM) dengan nilai rata-rata presisi (mAP) sebesar 99,3%. Hasil dari penelitian ini dapat meningkatkan efektivitas pendeteksian kerusakan pada permukaan PCB.

Kata kunci— PCB, deteksi cacat, deep learning, nilai akurasi.

I. PENDAHULUAN

Perkembangan teknologi pada masa kini dapat memudahkan penelitian dan riset yang kreatif dalam merancang sebuah sistem termasuk perangkat elektronik. Pada perangkat elektronik terdapat papan PCB sebagai komponen penting untuk menunjang kinerja sistem dan memberikan jalur penghubung antar komponen di dalam perangkat [1]. Jika pada desain papan PCB terdapat salah satu jalur yang tidak terhubung atau rusak, akan mengakibatkan perangkat elektronik tidak berfungsi dengan baik dan jalur *circuit* tidak akan terhubung. Tingkat keberhasilan kualitas hasil produksi perangkat elektronik terdapat pada identifikasi komponen keping PCB. Teknologi sekarang dalam produksi perangkat elektronik keping PCB saat ini masih dilakukan secara manual yang mengandalkan tenaga manusia untuk meneliti satu per satu cetakan komponen PCB apakah terdapat kerusakan komponen atau tidak [2].

Sistem inspeksi jalur PCB berfungsi sebagai pembandingan antara gambar PCB yang tidak ada kerusakan dan gambar PCB yang terdapat kerusakan komponen, dimana proses perbandingannya dilakukan pada sebuah program aplikasi [3]. Pada aplikasi ini menggunakan teknik *image processing* untuk mendeteksi kerusakan suatu objek pada *printed circuit board (PCB)* [4]. Ilmu yang berhubungan erat dengan penentuan kualitas produk, jenis dan kuantitas secara visual adalah *computer vision*. Pada ilmu *computer vision* membahas tentang klasifikasi objek dan deteksi objek pada gambar. Terdiri dari pengumpulan gambar, *training*, dan *deploy* [5]. Pelatihan model berarti mengenali sesuatu dan mengklasifikasikannya menurut kelasnya. *Convolutional Neural Network (CNN)* dengan arsitektur ResNet-101 adalah salah satu algoritma *deep learning* yang digunakan dalam penelitian [15]. Teknik yang digunakan pada *computer vision* merupakan metode dari pengolahan citra dan kecerdasan buatan sehingga memungkinkan komputer dapat melihat dan memahami objek melalui gambar atau video. Pengolahan citra dengan menggunakan komputer, akan menghasilkan kualitas yang lebih baik [6]. Proses pengolahan citra melibatkan serangkaian operasi seperti pengaturan tingkat kecerahan, kontras, deteksi tepi, peningkatan ketajaman, dan lainnya [16]. Tujuan utama pengolahan citra adalah agar citra yang mengalami gangguan mudah diinterpretasi oleh manusia maupun mesin. Metode pencocokan model merupakan ciri khas yang digunakan sebagai patokan pengembangan dari pengolahan citra digital sehingga sistem dapat mengidentifikasi cacat pada PCB [6]. Metode ini menggunakan metode pembelajaran mendalam yang inovatif menggunakan model ResNest-101 ditambah metode OHEM [18].

Tugas Akhir ini mengusulkan sebuah sistem deteksi objek kecacatan PCB sehingga dapat mempersingkat waktu dan meminimalisir biaya dalam proses produksi perangkat elektronik. Sistem deteksi objek cacat PCB ini menggunakan bantuan *webcamera* untuk mengambil gambar PCB yang akan dideteksi [17]. Dengan bantuan aplikasi *Graphical User Interface (GUI)* sebagai *interface* yang akan ditampilkan pada display, dan sistem akan memproses menggunakan model *pretrained* ResNest-101 dengan tambahan metode *Online Hard Example Mining (OHEM)* untuk mendeteksi kerusakan yang terdapat pada PCB. Hasil yang diharapkan adalah sistem dapat mendeteksi objek secara akurat sesuai

dengan *class* kerusakan PCB seperti *missing hole*, *open circuit*, *short*, *spur*, *spurious copper*, dan *mouse bite*. Diharapkan dengan adanya sistem deteksi ini akan memberikan manfaat dalam proses deteksi kerusakan PCB menjadi lebih efisien, akurat, meminimalisir biaya, dan sesuai dengan kebutuhan spesifik pada industri perangkat elektronik.

II. KAJIAN TEORI


A. Deep Learning

Deep learning merupakan subbidang dari machine learning yang terinspirasi dari otak manusia, memiliki struktur dinamakan *Artificial Neural Network*. Dalam penerapannya, deep learning bekerja berdasarkan arsitektur jaringan dan *prosedural optimal*. *Output* dari lapisan yang tersembunyi dapat dilihat menggunakan grafik untuk setiap neuron. Transformasi Non-Linier digunakan pada prosedur optimal untuk menghasilkan bobot optimal pada setiap lapisan agar mendapatkan nilai target yang dibutuhkan [7].

B. MMDetection

MMDetection adalah *toolbox* untuk deteksi objek dari OpenMMLab yang berisi sekumpulan metode modul terkait deteksi objek. Toolbox ini merupakan yang terlengkap karena memiliki sekitar 200 model jaringan. Kemampuan yang dimiliki MMDetection yaitu tolok ukur untuk memudahkan dalam membangun kerangka kerja detektor baru pada kerangka kerja sehingga dapat membandingkan kinerja model.

C. CARAFE



GAMBAR 1.
Fitur arsitektur jaringan piramida [8].

Fitur *up sampling* adalah operator utama dalam banyak hal arsitektur jaringan konvolusi modern yang dirancang untuk tugas seperti deteksi objek, segmentasi instance, dan penguraian adegan. CARAFE digunakan untuk sampel peta fitur [9]. CARAFE dapat memprediksi *reassembly kernel* dan memasang kembali fitur dalam wilayah terdekat yang telah ditentukan sebelumnya menggunakan konten yang mendasarinya informasi. CARAFE menggunakan adaptif dan optimal perakitan ulang kernel di lokasi yang berbeda, mencapai hasil yang lebih baik kinerja daripada *operator up sampling* tradisional seperti interpolasi atau dekonvolusi. CARAFE menguntungkan metode lanjutan pada tugas tingkat tinggi maupun tingkat rendah, seperti objek deteksi, segmentasi instan, segmentasi semantik, dan lukisan gambar, dengan parameter tambahan yang dapat diabaikan.

D. Grid R-CNN

Grid R-CNN mengadopsi mekanisme lokalisasi yang dipandu grid untuk deteksi objek yang akurat. Berbeda dari metode berbasis regresi tradisional, Grid R-CNN menangkap informasi spasial secara eksplisit dan menikmati properti sensitif posisi yang sepenuhnya konvolusional. Grid R-CNN dapat mengurangi dampak prediksi yang tidak akurat dari titik-titik tertentu [10].

E. Res2Nest

Struktur fusi multi-skala adalah yang esensial metode peningkatan algoritma untuk deteksi target kecil, sehingga meningkatkan kemampuan multi-skala backbone. Pada Res2Nest melakukan perbaikan lebih lanjut ke backbone ResNest yang ada. Meningkatkan kemampuan representasi multi-skala dari backbone dengan membangun koneksi seperti residu hierarkis dalam setiap blok radix tunggal pada model ResNest asli [11].

F. ResNest

Sebagian besar aplikasi *downstream*, termasuk deteksi objek dan segmentasi semantik, terus digunakan versi ResNet sebagai *backbone* jaringan. Meskipun model klasifikasi gambar baru-baru ini berkembang karena konstruksi yang sederhana dan modular. ResNest menawarkan blok SplitAttention langsung dan modular yang memfasilitasi perhatian di seluruh peta fitur kelompok [12]. Dengan menumpuk blok Split-Attention, ResNet membuat versi ResNet baru yang dikenal sebagai ResNeSt. Struktur ResNet secara keseluruhan dipertahankan oleh jaringan, memungkinkan penggunaan langsung dalam tugas berikutnya tanpa perlu diproses lebih lanjut. Ketika datang ke kompleksitas model yang serupa, model ResNeSt berperforma lebih baik daripada jaringan lain dan juga membantu tugas-tugas seperti deteksi objek, segmentasi instance, dan semantik segmentasi.

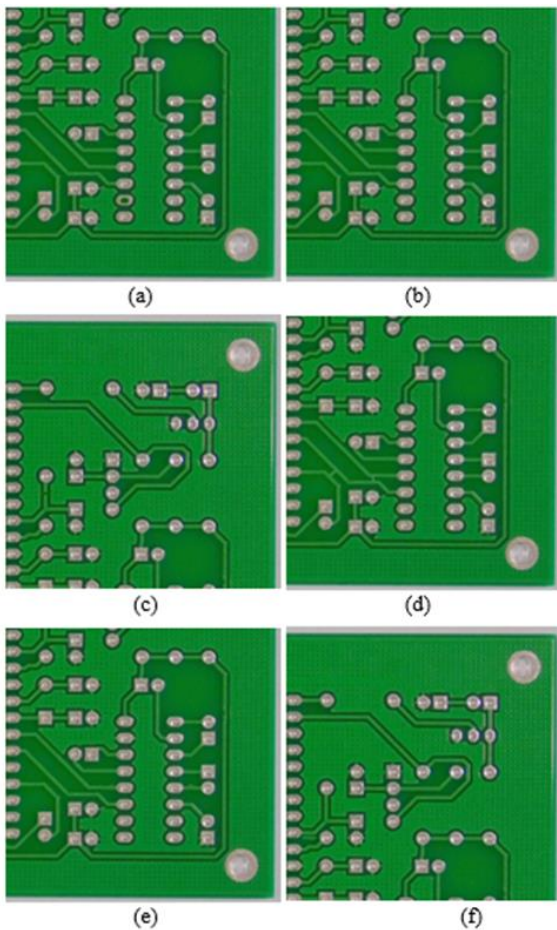
G. OHEM

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 [13].

III. METODE

A. Dataset

Dataset adalah kumpulan data yang disediakan untuk pengujian dan analisis pada sebuah sistem. Dataset yang diperlukan untuk deteksi objek adalah data yang mencakup gambar dan anotasi. Pada penelitian menggunakan dataset publik yang di rilis oleh Peking University [14]. PCB adalah bahan utama dalam perangkat elektronik yang menampung sejumlah besar elemen. Dataset dibagi menjadi enam kategori: *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 9.920 dan 2.508 gambar. Dataset menyediakan file anotasi bounding box dalam bentuk dokumen XML.

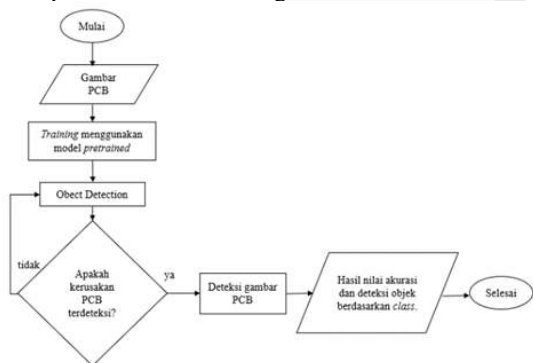


GAMBAR 2.

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

B. Diagram Alur pada Sistem Deep Learning

Salah satu pengujian pada sistem deteksi cacat PCB adalah perbandingan model. *Flowchart* yang digunakan pada sistem deteksi cacat PCB yaitu Deep Learning yang dijelaskan pada Gambar 3. sebagai berikut:



GAMBAR 3. *Flowchart* Deep Learning

Gambar 3. menjelaskan *flowchart* sistem pada deep learning. Diawali dengan pengambilan gambar dataset PCB. Selanjutnya pada bagian *training* menggunakan model *pretrained* seperti CARAFE [9], Grid CNN [10], Res2Nest [11], dan ResNest-101 [21] ditambah metode OHEM [22] yang dilakukan pengurangan jumlah layer menjadi 256 layer agar dapat diimplementasikan. Sehingga pada bagian *object detection* dapat mendeteksi gambar PCB yang mengalami

kerusakan sesuai dengan *class* cacat PCB, dan menghasilkan nilai akurasi sesuai model.

C. Spesifikasi Deep Learning

Pada penelitian ini mengusulkan sistem deteksi cacat pada PCB dengan menggunakan deep learning. Sistem ini dapat mempelajari data massif dengan menggunakan *back propagation* untuk mampu melakukan perubahan parameter internal, dimana parameter internal ini digunakan pada penelitian ini untuk menghitung representasi di setiap layer dari representasi layer sebelumnya.

TABEL 1.

Spesifikasi Deteksi Objek Deep Learning

Specification	Parameter
Learning Rate	0,0025
Epochs	10
Batch Size	16
Threshold	0,5
Train Data	70%
Validation Data	20%
Test Data	10%

Tabel 1. menunjukkan parameter model *pretrained* menggunakan *learning rate* 0.0025, 10 epochs, Batch Size 16, Threshold 0.5, dan perbandingan pada dataset train, val, test adalah 70:20:10. Dalam konteks deteksi objek, threshold 0.5 merupakan nilai ambang batas yang digunakan dalam metrik evaluasi deteksi objek seperti Mean Average Precision (mAP) atau Average Precision (AP). Metrik ini digunakan untuk mengevaluasi sejauh mana sistem deteksi objek berhasil dalam mengenali dan memposisikan objek dengan benar pada gambar.

D. Metrik Evaluasi

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

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

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

Pada kedua persamaan tersebut, ada TP, FP, dan FN. TP adalah jumlah cacat yang ditemukan dan dideteksi dengan benar, sementara FP adalah jumlah cacat yang tidak ada pada PCB, dan FN adalah jumlah cacat yang tidak ditemukan. Nilai ketepatan menunjukkan rasio cacat yang ditemukan dan dideteksi dengan benar dari masing-masing jenis cacat. Recall adalah bukti sensitivitas detektor.

IV. HASIL DAN PEMBAHASAN

Untuk membandingkan kinerja pembelajaran model arsitektur yang digunakan, nilai recall dan presisi digunakan sebagai matriks evaluasi. Presisi adalah kecocokan antara data lokal yang diambil dan yang dibutuhkan informasi. Recall adalah metrik yang digunakan untuk mengukur seberapa baik sistem sedang memulihkan informasi.

Selanjutnya dilakukan percobaan dengan menggunakan with Spesifikasi NVIDIA Tesla P100. Python 3.7.13, CUDA 11.2 dan cuDNN 8.2 digunakan dalam perangkat lunak.

TABEL 2.
Hasil Perbandingan Model

Model	Average Precision (AP) %	mean Average Precision (mAP) %
Grid R-CNN	98,3	98,3
Carafe	98,7	98,86
Res2Nest	98,7	98,67
ResNest 101	99,2	99,19
ResNest 101+ OHEM	99,3	99,26

Dataset PCB digunakan untuk melatih *Content-Aware ReAssembly of FEatures* (CARAFE). Seperti yang ditunjukkan pada Tabel 1, Grid CNN, Res2Nest, ResNest dan ResNest+OHEM. Hasil pengujian menggunakan model Carafe dengan hasil mAP 98,6%, Grid CNN dengan hasil 98,3%. Sedangkan model Res2Nest dengan hasil mAP 98,67% dan model ResNest-101 dengan nilai mAP yaitu 99,19%. ResNest-101 dengan nilai mAP 99,26%. Selain itu, Tabel 2, 3, 4, 5 dan 6 menunjukkan masing-masing hasil klasifikasi deteksi PCB model dalam tingkat *recall* dan *average precision* (AP). Tabel 7 menggambarkan sampel pengujian untuk setiap model dan kelas Short. Kami menemukan bahwa Grid R-CNN memiliki akurasi terendah dibandingkan dengan dua model lainnya. ResNest mencapai kestabilan akurasi, dan ditambah dengan metode OHEM mendapatkan hasil yang lebih bagus dibandingkan dengan metode lain. Akhirnya, berdasarkan pengujian pada penelitian ini, kami menyimpulkan bahwa ResNest mencapai kinerja terbaik. Jika ditambahkan dengan metode OHEM maka hasil yang didapatkan mencapai kinerja yang lebih baik lagi. Untuk Sistem inspeksi cacat permukaan PCB model ResNest-101 ditambah metode OHEM yang paling unggul di antara keempat model perhatian dasar.

A. Pengujian Terhadap Model CARAFE

Pada bagian ini, dataset PCB diproses training menggunakan model CARAFE. Tabel 3 merupakan hasil pengujian terhadap model CARAFE dengan hasil yang didapatkan adalah nilai recall dan Average Precision (AP).

TABEL 3.
Hasil Klasifikasi Deteksi Cacat PCB Menggunakan Carafe

Defect Types	Recall	Average Precision (AP)
Missing Hole	0.998	0.998
Mouse Bite	0.994	0.989
Open Circuit	0.996	0.993
Short	0.983	0.977
Spur	0.976	0.975
Spurious Copper	0.992	0.989

Berdasarkan Tabel 3, pengujian menggunakan model CARAFE yang dilakukan dengan dataset cacat PCB

didapatkan nilai Average Precision (AP) pada class Short yaitu 97,7%. Sehingga dapat disimpulkan menggunakan model CARAFE belum mencapai nilai akurasi yang diinginkan.

B. Pengujian Terhadap Model Grid-RCNN

Pada bagian ini, dataset PCB diproses training menggunakan model Grid-RCNN. Tabel 4 merupakan hasil pengujian terhadap model Grid-RCNN dengan hasil yang didapatkan adalah nilai recall dan Average Precision (AP).

TABEL 4.
Hasil Klasifikasi Deteksi Cacat PCB Menggunakan Grid RCNN

Defect Types	Recall	Average Precision (AP)
Missing Hole	0.996	0.994
Mouse Bite	0.991	0.986
Open Circuit	0.988	0.983
Short	0.983	0.975
Spur	0.988	0.976
Spurious Copper	0.992	0.985

Berdasarkan Tabel 4, pengujian menggunakan model Grid-RCNN yang dilakukan dengan dataset cacat PCB didapatkan nilai Average Precision (AP) pada class Short yaitu 97,5%. Sehingga dapat disimpulkan menggunakan model Grid-RCNN belum mencapai nilai akurasi yang diinginkan.

C. Pengujian Terhadap Model Res2Nest

Pada bagian ini, dataset PCB diproses training menggunakan model CARAFE. Tabel 3 merupakan hasil pengujian terhadap model CARAFE dengan hasil yang didapatkan adalah nilai recall dan Average Precision (AP).

TABEL 5.
Hasil Klasifikasi Deteksi Cacat PCB Menggunakan Res2Nest-101

Defect Types	Recall	Average Precision (AP)
Missing Hole	0.989	0.987
Mouse Bite	0.996	0.993
Open Circuit	0.997	0.995
Short	0.988	0.984
Spur	0.981	0.977
Spurious Copper	0.988	0.983

Berdasarkan Tabel 5, pengujian menggunakan model Res2Nest yang dilakukan dengan dataset cacat PCB didapatkan nilai Average Precision (AP) pada class Short yaitu 98,4%. Sehingga dapat disimpulkan menggunakan model Res2Nest belum mencapai nilai akurasi yang diinginkan.

D. Pengujian Terhadap Model ResNest-101

Pada bagian ini, dataset PCB di training menggunakan model ResNest-101. Tabel 6 merupakan hasil pengujian

terhadap model ResNest-101 dengan hasil yang didapatkan adalah nilai recall dan Average Precision (AP).

TABEL 6.
Hasil Klasifikasi Deteksi Cacat PCB Menggunakan ResNest-101

Defect Types	Recall	Average Precision (AP)
Missing Hole	0.998	0.998
Mouse Bite	0.997	0.993
Open Circuit	0.998	0.995
Short	0.983	0.977
Spur	0.995	0.993
Spurious Copper	0.998	0.996

Berdasarkan Tabel 6, pengujian menggunakan model ResNest-101 yang dilakukan dengan dataset cacat PCB didapatkan nilai *Average Precision (AP)* pada *class Short* yaitu 97,7%. Sehingga dapat disimpulkan menggunakan model ResNest-101 belum mencapai nilai akurasi yang diinginkan.

E. Pengujian Terhadap Model ResNest-101+OHEM

Pada bagian ini, dataset PCB di training menggunakan model ResNest-101 ditambah metode OHEM dengan pengurangan layer menjadi 256 layer. Tabel 6 merupakan hasil pengujian terhadap model CARAFE dengan hasil yang didapatkan adalah nilai recall dan Average Precision (AP).

TABEL 7.

Hasil Klasifikasi Deteksi Cacat PCB Menggunakan ResNest-101 + Metode OHEM


Defect Types	Recall	Average Precision (AP)
Missing Hole	0.998	0.998
Mouse Bite	0.998	0.992
Open Circuit	0.998	0.996
Short	0.985	0.982
Spur	0.997	0.995
Spurious Copper	0.997	0.994

Berdasarkan Tabel 7, pengujian menggunakan model ResNest-101 ditambah metode OHEM dan dilakukan penurunan layer menjadi 256 layer dilakukan dengan dataset cacat PCB didapatkan nilai Average Precision (AP) pada *class Short* yaitu 97,7%. Sehingga dapat disimpulkan menggunakan model ResNest-101 ditambah metode OHEM. dan dilakukan penurunan layer menjadi 256 layer mengalami kenaikan nilai akurasi dibandingkan dengan metode ResNest-101.

F. Hasil Deteksi Parameter Terbaik

Setelah dilakukan pengujian dari sistem deteksi cacat pada permukaan PCB didapatkan model yang memiliki performa yang bagus yaitu model ResNest-101 dengan metode OHEM yang dilakukan pengurangan jumlah layer menjadi 256 layer. Untuk citra cacat PCB memiliki kategori lebih kompleks yaitu enam class kategori cacat. Selanjutnya dilakukan perbandingan terhadap hasil deteksi pada cacat PCB yang tanpa model, dengan yang sudah ditambahkan dengan model pretrained. Model yang digunakan adalah CARAFE, Res2Nest, dan ResNest-101+OHEM. Tabel 8

menampilkan perbandingan hasil deteksi cacat PCB pada *class Short*. Nilai probabilitas atau akurasi yang didapatkan pada model Carafe yaitu 100%, model Res2Nest yaitu 96%, dan pada ResNest-101+OHEM yaitu 100%.




GAMBAR 4.

Hasil Pengujian pada Class Short. (a) Tanpa Model, (b) Carafe, (c) Res2Nest, dan (d) ResNest-101+OHEM.

Berdasarkan Tabel 8, pengujian menggunakan model CARAFE dan model ResNest-101 ditambah metode OHEM dan dilakukan penurunan layer menjadi 256 layer, mendapatkan nilai probabilitas atau akurasi dengan nilai yang unggul dibandingkan dengan model Res2Nest.

G. Grafik Perbandingan Model

Bagian ini menjelaskan tentang perbandingan model pretrained yaitu model Carafe, Grid-RCNN, Res2Net-101, ResNest101+OHEM dalam bentuk grafik.



GAMBAR 5.

Perbandingan Model

Pada Gambar 5. menjabarkan sumbu X merupakan hasil nilai mAP dan nilai AP pada pengujian model menggunakan model Carafe, Grid-RCNN, Res2Net-101, ResNest101+OHEM. Sumbu Y merupakan hasil nilai Model Carafe direpresentasikan oleh warna biru mendapatkan hasil nilai 98,68% dari 100%. Model Grid-RCNN direpresentasikan oleh warna orange mendapatkan hasil nilai 98,3% dari 100%. Model Res2Nest-101 direpresentasikan oleh warna abu-abu mendapatkan hasil nilai 98,67% dari 100%. Model ResNest-101+OHEM direpresentasikan oleh warna kuning mendapatkan hasil nilai 99,27% dari 100%. Parameter Average Precision (AP) menggunakan model Carafe, Grid-RCNN, Res2Net-101, ResNest101+OHEM. Model Carafe direpresentasikan oleh warna biru mendapatkan hasil nilai 98,7% dari 100%. Model Grid-RCNN direpresentasikan oleh warna orange mendapatkan hasil nilai 98,3% dari 100%. Model Res2Nest-101 direpresentasikan oleh warna abu-abu mendapatkan hasil

nilai 98,70% dari 100%. Model ResNest-101+OHEM direpresentasikan oleh warna kuning mendapatkan hasil nilai 99,3% dari 100%. Dari hasil perbandingan grafik didapatkan hasil bahwa menggunakan model ResNest101+OHEM merupakan model paling unggul dibandingkan dengan model-model lainnya.

V. KESIMPULAN

Penelitian ini untuk membandingkan model *pretrained* dalam deteksi objek pembelajaran mendalam kerusakan PCB. Sistem menggunakan model *pretrained* yang lebih baik dalam mendeteksi cacat PCB, dan didapatkan hasil pengujian nilai akurasi dengan arsitektur ResNest-101 ditambah metode OHEM dengan nilai akurasi 99,3% mengungguli model lain seperti Grid R-CNN, Carafe dan Res2Nest dengan akurasi masing-masing sebesar 98,30%, 98,86%, dan 98,67%. Kami berharap temuan ini akan berguna untuk masa depan penelitian, khususnya pada industri bidang elektronik terkait sistem inspeksi cacat permukaan PCB.

REFERENSI

- [1] I. W. Sukadana, and I. M. P. D. Yuda, "Prototyping Pcb Menggunakan Computer-Aided Design," *Tiers Information Technology Journal*, vol. 2, no. 2723-4533, 2021.
- [2] N. Agani, and T. H. Kusmanto, "Deteksi Label Komponen Pada Keping Pcb Menggunakan Backpropagation dan Self Organizing Map Neural Network," *Jurnal Telematika Mkom*, vol. 6, no. 1, pp.15-26, 2014..
- [3] I. Armawan, Y. Suprpto, and T. I. Suharto, "Rancangan Deteksi Jalur Printed Circuit Board Dengan Web Camera Logitech C525 Menggunakan Integrasi 2 Gambar Berbasis Raspberry Pi 4," *Prosiding SNITP (Seminar Nasional Inovasi Teknologi Penerbangan)*, vol. 4, 2020.
- [4] R. A. Juliano, E. Efrizon, H. Hendrick, L. Devy, S. Suryadi, and Y. Antonisfia, "Pembuatan Alat Inspeksi Visual Jalur Pcb Menggunakan Pengolahan Citra," *Elektron: Jurnal Ilmiah*, pp. 61-66, 2022
- [5] L. Liu, W. Ouyang, X. Wang, P. Fieguth, J. Chen, X. Liu, and M. Pietikainen, "Deep Learning For Generic Object Detection: A Survey," *International Journal of Computer Vision*, pp.261-318, 2019.
- [6] K. A. Nugroho, R. R. Isnanto, and A. Hidayatno, "Identifikasi Cacat Pada Keping Pcb Menggunakan Pencocokan Model (Template Matching)" *Diss. Jurusan Teknik Elektro Fakultas Teknik Undip*, 2011.
- [7] Gunawan and I. Kadek, "Segmentasi Buah Apel Menggunakan Framework Yolact Arsitektur Resnet-101segmentasi Buah Apel Menggunakan Framework Yolact Arsitektur Resnet-101," *Jurnal Ilmiah Teknologi dan Komputer*, vol. 1, no. 2, pp. 234-242, 2020.
- [8] Akhyar, Novamizanti, Ledy and Imaddudin. Muhammad Azka, "Observation Of Attention Mechanism Baseline For Pcb Surface Inspection System," *Asia Pacific Conference On Wireless And Mobile (Apwimob)*, 2022.
- [9] J. Wang, K. Chen, R. Xu, Z. Liu, C. C. Loy and A. D.Lin, "Carafe++: Unified Content-Aware Reassembly Of Features," *Ieee Trans Pattern Anal Mach Intell*, vol. 44, no.9, pp. 4674-4687, 2022
- [10] L. Xin, B. Li, Y. Yue, Q. Li, and J. Yan, "Grid r-cnn," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 7363-7372, 2019.
- [11] J. Cao, J. Zhang, and X. Jin, "A Traffic-Sign Detection Algorithm Based On Improved Sparse R-Cnn," *IEEE Access*, Vol. 9, pp. 122774-122788, 2021.
- [12] Z. Hang, C. Wu, Z. Zhang, Y. Zhu, H. Li, Z. Zhi, Y. Sun, T. Mueller, J. Manmatha, and M. Li, "Resnest: Split-Attention Networks" in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, pp. 2736-2746, 2022.
- [13] Adzka, 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.
- [14] Ixiaohuihuihui, "Tiny-Defect-Detection-For-Pcb," Pp. <https://github.com/Ixiaohuihuihui/Tiny-Defect-Detection-For-Pcb>, 5 October 2021.
- [15] 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.
- [16] 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
- [17] 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.
- [18] 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.

