

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Beberapa penelitian terkait deteksi nematoda, *object detection*, dan metode yang digunakan antara lain:

2.1.1 Deep Learning for Nematode Detection and Classification [2]

Penelitian dengan judul “*Deep Learning for Nematode Detection and Classification*” yang dilakukan oleh Jiejun Lu, Hongxiang Qiu, Weidong Xu dan Zeyu Zhao. Penelitian ini membahas tentang sebuah sistem pendeteksi nematoda kemudian nematoda yang terdeteksi diklasifikasikan menjadi nematoda parasit dan nematoda non-parasit lalu diberi box dan dilabeli sebagai *output* dari pemrosesan. Tantangan yang dihadapi dalam penelitian ini adalah adanya *bad illumination*, *noise*, *overlapping* nematoda, nematoda yang berbentuk aneh (tidak memanjang), dan salah pelabelan. Penelitian ini menggunakan RCNN dengan beberapa modifikasi dan membandingkannya. Dengan urutan hasil terbaik yaitu SA-R-CNN menempati tempat paling akurat, disusul dengan faster R-CNN, random forest, dan SVM. Penelitian ini juga menggunakan data augmentation yaitu dengan melakukan flip dan illumination adjusted sehingga dapat memperbanyak data sebanyak 11 kali.

Jurnal ini menjadi sumber acuan pertama yang penulis gunakan dalam penelitian, yaitu penelitian terkait dengan penelitian penulis tentang deteksi dan identifikasi nematoda dengan metode yang digunakannya berbasis CNN dan juga melakukan augmentasi pada dataset.

2.1.2 Nematode Identification Using Artificial Neural Networks [3]

Penelitian dengan judul “*Nematode Identification Using Artificial Neural Network*” ini dilakukan oleh Jason Uhlemann, Oisin Cawley, dan Thomais Kakouli-Duarte. Penelitian ini membahas tentang identifikasi nematoda menggunakan *deep learning*. Penulis penelitian ini mendesain CNN agar dapat digunakan untuk klasifikasi hasil foto mikroskop. Penulis menggunakan EPN atau entomopatogen nematoda atau yang berarti nematoda parasit bagi hama serangga, EPN ini dapat membuat serangga sakit dan dapat dijadikan sebagai bioinsektisida atau pengganti insektisida kimia yang dapat merusak lingkungan. Penulis menggunakan 3 jenis EPN yaitu *Heterorhabditis bacteriophora*, *Steinernema carpocapsae* dan *Steinernema feltiae*.

Peneliti ingin membentuk desain CNN baru, namun pada akhirnya penulis menggunakan arsitektur CNN yang sudah ada kemudian melakukan uji pada setiap model. Penulis menggunakan 13 arsitektur CNN sehingga memberikan hasil tes yaitu DenseNet169, DenseNet201 dan NASNetLarge tidak dapat melakukan training karena limitasi memori. NASNetMobile, VGG16, VGG1, dan MobileNetV2 mencapai validasi akurasi antara 30% sampai 55%. InceptionResNetV2, DenseNet121, Xception, ResNet50, InceptionV3, dan MobileNet memiliki hasil yang jauh lebih baik dibanding sebelumnya yaitu sekitar 90%. InceptionResNetV2 memiliki hasil terbaik namun terlalu besar dengan 572 layer. Maka penulis menggunakan Xception model yang memiliki akurasi hampir mirip dengan hanya memiliki 126 layer.

Jurnal ini berkontribusi sebagai penelitian terkait deteksi dan identifikasi nematoda dengan perbandingan arsitektur CNN yang juga digunakan oleh penulis dalam penelitian ini sehingga melalui jurnal ini, penulis mendapatkan informasi terkait arsitektur yang bisa digunakan.

2.1.3 An intelligent System for Detection of Nematodes in Digital Images [6]

Penelitian dengan judul “*An intelligent System for Detection of Nematodes in Digital Images*” ini dilakukan oleh Carlos A Silva, Kaiser M C Magalhaes dan Adriaio D Doria Neto. Penelitian ini berisi tentang deteksi nematoda untuk mengetahui keberadaan nematoda itu sendiri sehingga dapat mengendalikan nematoda, khususnya nematoda parasit yang dapat merusak tanaman. Namun dalam penelitian ini hanya melakukan deteksi murni terlepas dari spesies atau jenisnya. Penelitian ini akan terdiri dari kamera digital yang digabungkan dalam mikroskop kemudian dihubungkan ke komputer. Kemudian untuk pemrosesannya akan dilakukan *filterring* untuk peningkatan fitur, fase segmentasi, dan ekstraksi karakteristik untuk klasifikasi.

Penulis menggunakan *non-supervised segmentation method* berdasarkan *competitive neural network*. Penelitian ini mengusulkan penggunaan *radial basis function neural network* dan menggunakan fitur *shape* dan *texture* sebagai *input* untuk mengidentifikasi nematoda. Tahapan yang dilakukan pada penelitian ini adalah dimulai dari *image acquisition, pre-processing* yaitu untuk *improves image quality* dan meningkatkan keberhasilan dengan menggunakan Karhunen-Loeve Transform (KLT), melakukan segmentasi, *post-processing*, kemudian dilakukan klasifikasi dengan memberikan label kemudian memberikan hasil *output* dari proses ini.

Jurnal ini berkontribusi sebagai penelitian terkait deteksi dan identifikasi nematoda dengan menjelaskan pentingnya fase pre-processing bagi dataset untuk meningkatkan image quality sehingga mendapatkan hasil yang lebih baik.

2.1.4 Object Detection Techniques: A Comparison [7]

Penelitian atau jurnal dengan judul “*Object Detection Techiques: A Comparison*” ini dilakukan oleh Priyanka Malhotra dan Ekansh Garg. Penelitian ini berkontribusi untuk memberikan teknik terbaik dalam

melakukan objek deteksi. Pada penelitian ini, penulis membandingkan antara 3 pendekatan utama untuk mencapai deteksi objek yaitu R-CNN, Fast R-CNN dan YOLO. R-CNN melakukan klasifikasi dalam wilayah gambar. Teknik Fast R-CNN menghasilkan map fitur gambar dalam satu jejak. YOLO adalah algoritma yang beroperasi berdasarkan probabilitas objek dalam kotak dan kisi pembatas.

Hasil dari penelitian ini mendapatkan kesimpulan yaitu RCNN dan Fast RCNN lebih lambat dari YOLO tetapi dapat mendeteksi objek kecil. YOLO bagus dalam regresi daripada klasifikasi. YOLO mengalami kesulitan dalam mengklasifikasikan benda-benda kecil. Baik RCNN dan Fast RCNN gagal melakukan deteksi real time tetapi YOLO dapat melakukan klasifikasi real time dengan kecepatan yang baik. Pilihan untuk jenis algoritma klasifikasi objek yang digunakan tergantung pada jenis kumpulan data, jenis gambar, jumlah waktu pelatihan/pengujian dan aplikasi yang membutuhkan deteksi objek dan jenis objek. Jurnal ini berkontribusi sebagai penelitian terkait teknik yang digunakan untuk deteksi objek dengan memberikan ulasan antara R-CNN, Fast R-CNN, dan YOLO yang memberikan analisis bahwa hasil yang didapat lebih cepat menggunakan YOLO sehingga dapat digunakan secara realtime namun keluarga CNN dapat lebih baik dalam mendeteksi objek yang kecil.

Kesimpulan dari jurnal ini adalah perbandingan penggunaan R-CNN, Fast R-CNN, dan YOLO sesuai dengan kondisi penggunaan dan data yang digunakan. Kontribusi yang diberikan untuk penelitian ini adalah penggunaan keluarga R-CNN yang lebih cocok dengan kondisi penelitian penulis yaitu dapat mendeteksi objek yang kecil.

2.1.5 I-Nema: A Biological Image Dataset for Nematode Recognition [4]

Penelitian dengan judul "*I-Nema: A Biological Image Dataset for Nematode Recognition*" ini dilakukan oleh Xuequan Lu, Yihao Wang, Sheldon Fung, dan Xue Qing. Penelitian ini berisi dataset baru yang penulis kumpulkan karena terbatasnya dataset terkait dan dataset

tersebut diberikan secara publik oleh penulis. Selain menyediakan dataset, penulis juga melakukan *benchmark* dengan menyesuaikan dan melatih *state-of-the-art deep learning networks* di dataset penulis. Penulis juga membandingkan dan menganalisis *performance* nya.

Dalam pencarian dataset, penulis melakukan pencarian sample, kemudian dilakukan pendeteksian spesimen nya baru kemudian dilakukan pengambilan gambar setelah mengidentifikasi spesimen nya. Penulis membandingkan kinerja enam metode CNN ke dalam datasetnya. 6 metode itu adalah AlexNet, VGG16, VGG19, ResNet34, ResNet50, dan Resnet101. Dengan hasil akurasi terbesar ada pada ResNet101 dengan akurasi sebesar 79% pada kondisi gambar *flip* dan blur.

Jurnal ini berkontribusi sebagai penelitian terkait deteksi dan identifikasi nematoda yang membandingkan performa dari 6 metode CNN dengan hasil terbaik didapat oleh ResNet101 yang kemudian digunakan oleh penulis dalam penelitian ini.

2.1.6 Nematode Identification Techniques and Recent Advances [8]

Penelitian dengan judul “*Nematode Identification Techniques and Recent Advances*” ini dilakukan oleh Mesfin Bogale, Anil Baniya, dan Peter DiGennaro. Penelitian ini membahas identifikasi nematode berdasarkan berbagai aspek. Beberapa aspek diantaranya adalah analisis secara morfologi atau berdasarkan gambar, klasifikasi atau identifikasi berdasarkan DNA (*fingerprint, Microarrays dan Metode Berbasis Probe, metode sequence-based*), identifikasi berdasarkan protein (analisis *Isozyme*, analisis gel 2 dimensi, analisis *mass spectral*, analisis *serological*). Penulis juga membandingkan metode identifikasi yang paling seimbang digunakan, yaitu dengan membandingkan metode yang ada, terhadap *expertise, cost*, dan resolusi yang dihasilkan.

Jurnal ini berkontribusi sebagai penelitian terkait deteksi dan identifikasi nematoda yang menjelaskan bahwa nematoda dapat diidentifikasi berdasarkan banyak hal namun dalam hal penelitian

penulis, nematoda diidentifikasi berdasarkan karakteristik fisik yang terlihat saja.

2.2 Tinjauan Teori

Beberapa penjelasan dasar teori terkait penelitian ini diantaranya:

2.2.1 Object Detection

Computer vision merupakan salah satu cabang ilmu yang bertujuan untuk membuat keputusan untuk mengenali objek fisik nyata dan keadaan dari sebuah gambar atau citra (Shapiro & Stockman, 2001). Dalam artian sederhananya, *computer vision* adalah bagaimana komputer dapat melihat, memvisualisasikan, menganalisa citra digital baik dalam bentuk gambar ataupun video. Dengan kata lain, *computer vision* seperti peran mata manusia pada komputer dan juga otak manusia pada komputer.[9]

Kemampuan komputer ini dapat mendekati kemampuan manusia dalam menangkap informasi visual yaitu kemampuan:[10]

- *Object detection*: mengenali objek dan memberikan batasan
- *Recognition*: memberikan label pada objek
- *Interpreting motion*: menafsirkan gerak
- *Description, 3D interference*, Dan kemampuan lainnya.

Object detection merupakan suatu aspek yang terdapat pada *computer vision*. *Object detection* ini berfungsi untuk mendeteksi objek yang ada pada suatu gambar. Hal ini dapat diperlakukan sebagai pengenalan objek kelas dua, dimana satu kelas mewakili objek sedangkan satu kelas lagi mewakili non-objek.[10] Dalam hal penelitian ini, objek yang dideteksi adalah nematoda, sedangkan non-objek merupakan lingkungan sekitarnya

2.2.2 Nematoda

Nematoda adalah cacing tidak bersegmen, bilateral simetris, mempunyai saluran cerna, biasanya berbentuk silindris serta

panjangnya bervariasi dari beberapa milimeter hingga lebih dari 1 meter (Garcia, 1996). Nematoda dapat hidup di atas atau di dalam tanah. Nematoda yang hidup di atas tanah yaitu dapat hidup pada daun, dalam buah, pada batang, dan pada bagian tumbuhan lainnya.[11]

Nematoda dapat diklasifikasikan menjadi 2 jenis yaitu nematoda parasit dan nematoda non-parasit. Khususnya pada tumbuhan, nematoda kedua jenis nematoda ini bisa sangat mempengaruhi hasil dari tumbuhan itu sendiri. Nematoda parasit dapat dikatakan juga sebagai organisme pengganggu tanaman atau OPT yang dapat mengganggu kelangsungan hidup tanaman. Menurut sumber, nematoda parasit mengakibatkan hilangnya fungsi akar sehingga pengangkutan zat hara menjadi berkurang, dan ini akan menimbulkan kerusakan dengan gejala layu, terlihat menguning, dan hasil yang kurang baik[12]. Sedangkan nematoda non-parasit juga dapat mempengaruhi kelangsungan hidup tanaman yaitu dengan membantu memakan bakteri dan mengurai bahan organik lain, dan juga dapat memperbaiki struktur tanah sehingga tanah menjadi subur[13].

Ciri-ciri nematoda parasit dan nematoda non-parasit dapat dilihat pada penjelasan di bawah atau pada gambar 2.1:[12]

- nematoda parasit memiliki stilet yang berbentuk tabung berasal dari kutikula yang dapat dijulurkan dan mempunyai lubang. Ini berfungsi untuk menerobos dinding sel tumbuhan sehingga dapat menghisap isinya. Memiliki ukuran tubuh lebih kecil dibanding nematoda non-parasit.
- Sedangkan nematoda non-parasit memiliki mulut atau rongga seperti kerucut dengan lubang di bagian depan dan terhubung dengan esofagus pada bagian belakang ciri ini merupakan ciri pada nematoda pemakan bakteri. Sedangkan untuk nematoda karnivora memiliki ciri bergigi satu atau lebih. Memiliki ukuran tubuh lebih besar dari nematoda parasit.

Berikut tabel 2.1 yang berisi ciri-ciri nematoda menurut sumber [12], dan gambar 2.1 yang memberikan preview nematoda parasit dan non parasit.

Tabel 2. 1 Ciri-Ciri Nematoda Parasit dan Non-Parasit

Ciri-ciri	Nematoda	
	Parasit Tumbuhan	Non Parasit
Mulut	Mempunyai stilet untuk menerobos dinding sel tumbuhan dan menghisap isinya	Mempunyai rongga seperti kerucut dengan bagian depan terbuka dan bagian belakang langsung berhubungan dengan esofagus (nematoda pemakan bakteri) Mempunyai satu gigi atau lebih (nematoda karnivora)
Ukuran tubuh	Lebih kecil	Lebih besar dari parasit



Gambar 2. 1 Nematoda Parasit (kiri) dan Non Parasit (kanan)

2.2.3 Faster R-CNN

Deep learning adalah bagian dari *artificial intelligence* dan *machine learning* yang merupakan pengembangan *neural network*

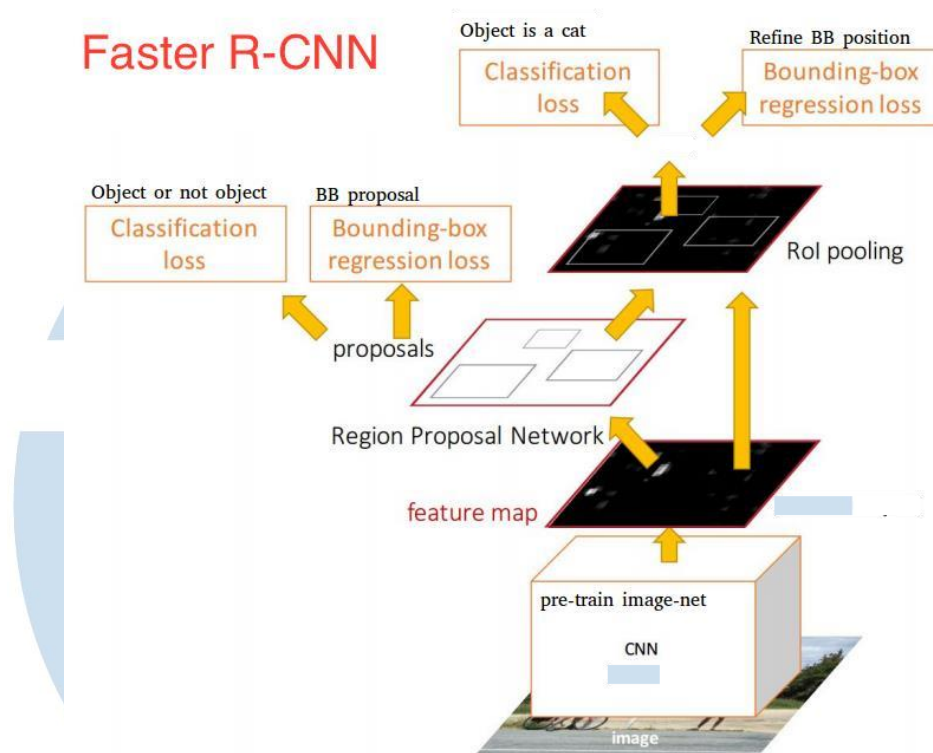
multiple layer untuk digunakan seperti pada *object detection*, dan lain-lain[14]. Berdasarkan sumber lain, *deep learning* adalah salah satu bidang *machine learning* yang memanfaatkan *layer* untuk melakukan pemrosesannya[10].

Berdasarkan definisi di atas, maka kesimpulan yang dapat diambil bahwa *deep learning* merupakan suatu *machine learning* yang memiliki karakteristik menggunakan *layer* dalam prosesnya. *Deep learning* ini menggunakan konsep hierarki sehingga komputer dapat mempelajari konsep yang kompleks melalui gabungan beberapa konsep yang sederhana[10].

Deep learning memiliki beberapa metode, salah satunya adalah metode yang berbasis convolutional neural network atau CNN. Metode CNN ini ada beberapa jenis pengembangan, beberapa diantaranya adalah R-CNN, fast R-CNN, dan pengembangan terbarunya yaitu Faster R-CNN.

R-CNN sendiri awalnya pada tahun 2015 dibuat sebagai metode pendeteksian objek yang mengkombinasikan algoritma Region Proposal Network (RPN) dan Convolutional Neural Network (CNN) (Girshick et al., 2014). Setelah itu dikembangkan lagi menjadi Fast R-CNN namun masih memiliki kekurangan, salah satunya adalah adanya bottleneck pada RPN sehingga tidak dapat menyamai kecepatan CNN. Kemudian sebagai jawaban dari permasalahan tersebut, dibuatlah perkembangan terbaru dari CNN ini yaitu Faster R-CNN yang merupakan solusi dari kelemahan Fast R-CNN dengan mempercepat proses RPN sehingga mengurangi terjadinya bottleneck.[15] ilustrasi faster R-CNN dapat dilihat pada gambar 2.2 di bawah ini.

U N I V E R S I T A S
M U L T I M E D I A
N U S A N T A R A



Gambar 2. 2 Ilustrasi Metode Faster R-CNN [16]

2.2.4 Dataset

Dataset atau dengan kata lain kumpulan data, seperti namanya, dataset akan berisi sekumpulan data yang banyak yang akan berfungsi sebagai data uji pada penelitian ataupun pengamatan beserta atributnya. Dataset dapat diambil dan dikumpulkan dari mana saja sesuai kebutuhan penelitian dan sesuai dengan penelitian yang dilakukan.

Dalam hal penelitian penulis kali ini, dataset yang digunakan adalah dataset baru yaitu dataset yang akan berisi kumpulan data atau objek yang akan terlihat seperti hasil mikroskop untuk dilakukan pendeteksian nematoda dan membedakan nematoda parasit dengan nematoda non-parasit, sehingga dapat menghasilkan sistem yang dapat membantu usaha pertanian dan perkebunan.

2.2.5 Data Augmentation

Data augmentation merupakan suatu proses pengolahan dataset yang biasanya berupa gambar dengan cara mengubah atau memodifikasi data yang sudah dikumpulkan atau yang sudah ada sedemikian rupa sehingga akan terdeteksi sebagai gambar yang berbeda oleh komputer[17]. *Data augmentation* ini berfungsi untuk memperbanyak dataset atau kumpulan data yang sudah ada dengan tidak menduplikasi data yang ada secara cuma-cuma melainkan melakukan beberapa perubahan berskala yang dapat diterapkan pada semua data gambar yang ada.

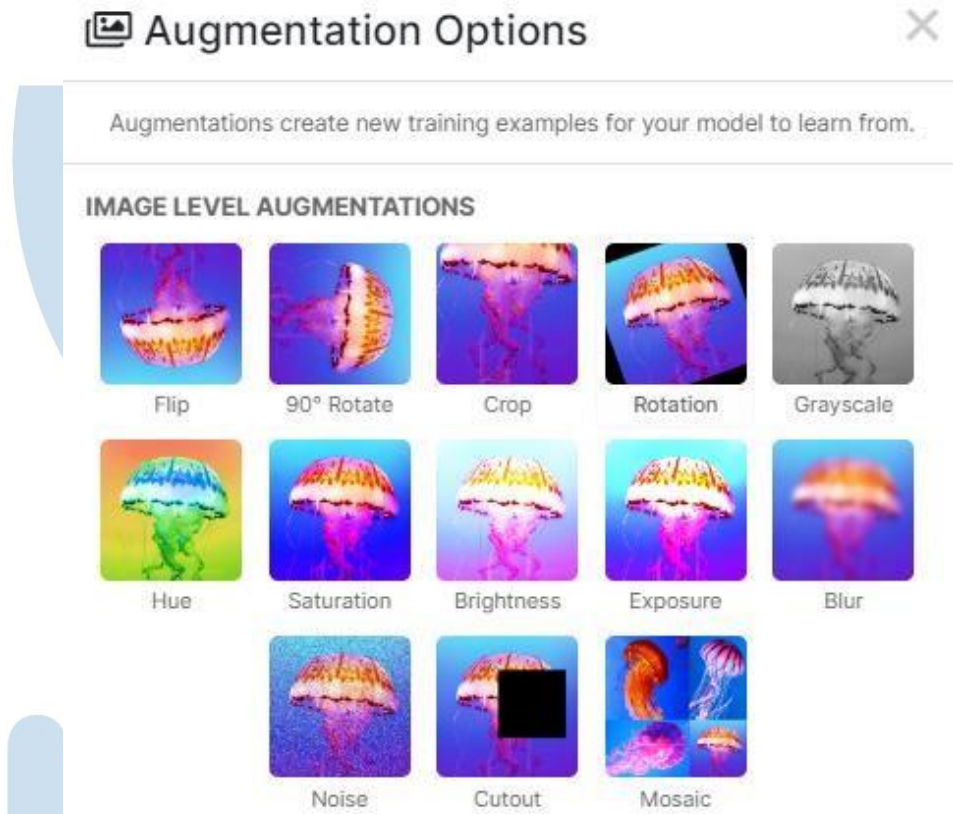
Data augmentation juga dapat memberikan hasil *training* yang lebih baik dengan banyaknya data untuk mencegah terjadinya *overfitting* atau terlalu terpaku dengan beberapa gambar yang sudah dipelajari[5]. *Data augmentation* biasanya dilakukan dengan operasi transformasi dan dapat digabungkan beberapa operasi sekaligus, antara lain:[5]

- *Rotasi*: melakukan rotasi dengan skala tertentu dari 0-180°
- *Zoom*: melakukan operasi memperbesar atau memperkecil gambar sesuai skala
- *Flip*: melakukan operasi membalik gambar
- *Shift*: melakukan penggeseran gambar yang sudah ada ke kanan atau kiri dengan skala tertentu
- *Shear*: melakukan transformasi geser secara acak

2.2.6 Roboflow

Roboflow merupakan sebuah platform yang tersedia di web yang memiliki banyak fungsi yang berhubungan dengan dataset. Dengan menggunakan roboflow ini dapat membagikan dataset sekaligus memproses dataset tersebut. Beberapa fitur yang digunakan pada penelitian ini diantaranya adalah melakukan annotate atau menandai objek yang akan di deteksi menggunakan bounding box, selain itu dapat

digunakan juga pre-processing pada dataset misalnya melakukan grayscale, dan juga augmentasi dengan menggunakan roboflow. Roboflow ini menyediakan beberapa jenis augmentasi konvensional seperti flip, rotate, brightness, exposure, shear dan lain-lain. Berikut beberapa augmentasi konvensional yang disediakan roboflow pada gambar 2.3.



Gambar 2. 3 Augmentasi yang Disediakan Roboflow [18]

2.2.7 Metrics Evaluasi

Metrik evaluasi yang digunakan adalah coco metrics dan confusion matrix.

Penulis menggunakan coco metrics untuk average precision (AP), mean average precision (mAP), dan average recall (AR). Hal ini dikarenakan perhitungan dari coco metrics yang sudah menyeluruh sehingga hasil dari presisi dan recall didapat dari rata-rata hasil dari IoU setiap 0,05 antara 0,5 sampai 0,95. Oleh karena perhitungan coco

metrics ini dihitung secara menyeluruh maka perhitungan AP pada coco metrics ini sama dengan mAP karena sudah dirata-rata pada semua threshold IoU, begitu pula untuk perhitungan AR sama dengan mAR jika menggunakan coco metrics.

Confusion matrix yang penulis dapatkan dari penelitian ini berupa matrix 3x3 dengan tambahan ground-truth sebagai kelas untuk misprediksi bounding box maupun klasifikasi, dimana hasil akan dihitung untuk memberikan hasil akurasi berupa persentase. Cara perhitungan confusion matrix ini adalah dengan menjumlahkan true positive (TP) dan true negative (TN) kemudian dibagi dengan total seluruhnya.

