

Implementasi Algoritma CNN dan YOLO untuk Mendeteksi Jenis Kendaraan pada Jalan Raya

Fernandy Jupiter, Edi Surya Negara, Yesi Novaria Kunang, M. Izman Herdiansyah

Jurusan Teknik Informatika, Fakultas Magister Teknik Informatika

Universitas Bina Darma

Palembang, Indonesia

fernandy3jupiter@gmail.com, e.s.negara@binadarma.ac.id, yesinovariakunang@binadarma.ac.id,

m.herdiansyah@binadarma.ac.id

Abstract-This research integrates the capabilities of two primary algorithms for vehicle type detection on highways, namely Convolutional Neural Network (CNN) and You Only Look Once (YOLO). The objective of this study is to assess the effectiveness of these two algorithms in recognizing various types of vehicles, including motorcycles, cars, trucks, and buses, within a road context. The research methodology involves the collection of datasets containing vehicle images, model training using CNN and YOLO architectures, and performance evaluation based on precision, recall, and F1-score metrics. The research results show that a combined CNN and YOLO approach yields a relatively low level of accuracy in detecting vehicle types on the highway, as indicated by a precision value of 0.50, a recall value of 0.48, and an F1-score of 0.46 at epoch 50. However, during detection with each algorithm separately, high accuracy is achieved. This is demonstrated by the values during YOLO algorithm detection, with a precision parameter of 0.936, a recall value of 0.914, and an F1-score of 0.924. Similarly, in the case of the CNN algorithm, the precision value is 0.95, the recall value is 0.95, and the F1-score is 0.95. These findings hold promising applications in the development of intelligent traffic monitoring systems, traffic measurement, and the enhancement of road safety. This research makes a valuable contribution to the advancement of image processing technology and object detection in the realm of transportation

Keywords: CNN, YOLO, precision, recall, F1-score

Abstrak-Penelitian ini mengkombinasikan kinerja dua algoritma utama dalam deteksi jenis kendaraan pada jalan raya, yaitu Convolutional Neural Network (CNN) dan You Only Look Once (YOLO). Tujuan dari penelitian ini ialah untuk mengetahui seberapa jauh kedua algoritma tersebut dalam mengenali berbagai kendaraan misalnya motor, mobil, truck dan bus dalam konteks jalan raya. Metode penelitian mencakup pengumpulan dataset berisi gambar-gambar kendaraan, pelatihan model menggunakan arsitektur CNN dan YOLO, serta evaluasi kinerjanya berdasarkan parameter presisi, recall dan F1-score. Hasil penelitian menunjukkan bahwa pendekatan gabungan CNN dan YOLO menghasilkan tingkat akurasi yang kurang baik dalam mendeteksi jenis kendaraan pada jalan raya yang ditunjukkan dengan nilai presisi sebesar 0,50, nilai *recall* sebesar 0,48 dan nilai f1-score sebesar 0,46 pada *epoch* 50. Namun pada saat pendeteksian pada masing-masing algoritma menghasilkan tingkat akurasi yang baik, hal ini ditunjukkan dengan nilai pada saat pendeteksian pada algoritma YOLO yakni pada parameter presisi sebesar 0,936, nilai *recall* sebesar 0,914 dan nilai f1-score sebesar 0,924, kemudian pada algoritma CNN yang ditunjukkan pada nilai presisi sebesar 0,95, nilai *recall* sebesar 0,95 dan f1-score sebesar 0,95. Hasil ini memiliki potensi aplikasi dalam pengembangan sistem pemantauan lalu lintas cerdas, pengukuran lalu lintas, dan peningkatan keselamatan di jalan raya. Penelitian ini memberikan kontribusi positif dalam memajukan teknologi pemrosesan citra dan deteksi objek dalam konteks transportasi.

Kata Kunci: CNN, YOLO, presisi, recall, F1-score

1. Pendahuluan

Dalam era perkembangan teknologi informasi yang pesat, sistem pemantauan lalu lintas menjadi sangat penting dalam mengelola arus kendaraan di jalan raya dan mengoptimalkan efisiensi transportasi. Salah satu elemen utama dalam sistem pemantauan lalu lintas adalah kamera

monitoring pada jalan raya maupun pada jalan tol [1]. Kamera monitoring ini digunakan untuk mendeteksi kendaraan yang melewati jalan raya tertentu dan mengenali jenis kendaraan yang melalui jalan tersebut, sehingga memberikan data yang penting untuk tujuan

Vol.14 no.2 | Desember 2023

EXPLORE : ISSN: 2087-2062, Online ISSN: 2686-181X / DOI: <http://dx.doi.org/10.36448/jst.v14i2.3259>



This work is licensed under a [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/)

pemantauan, penegakan hukum, dan pengumpulan data statistik. Dalam penggunaan kamera pada jalan raya, pengenalan objek menjadi salah satu aspek kunci.

Dua algoritma yang paling populer dan berhasil dalam pengenalan objek adalah Convolutional Neural Network (CNN) dan You Only Look Once (YOLO)[2]. Algoritma CNN telah terbukti berhasil dalam berbagai tugas pengenalan objek, misalnya jenis mobil [3], bangunan [4] dan wajah manusia [5]. Algoritma ini menggunakan jaringan saraf yang terdiri dari lapisan konvolusi untuk mempelajari fitur-fitur yang relevan dari gambar dan melakukan deteksi objek dengan tingkat akurasi yang tinggi. Namun, kelemahan algoritma CNN terletak pada kecepatan deteksi [6]. Di sisi lain, algoritma YOLO menawarkan pendekatan yang berbeda dalam deteksi objek. YOLO menganggap deteksi objek sebagai masalah regresi langsung [7] sehingga menghasilkan kecepatan deteksi yang tinggi. Namun, akibat dari pendekatan ini, YOLO mungkin menghadapi tantangan dalam hal akurasi deteksi yang lebih rendah dibandingkan dengan CNN. Kombinasi kedua algoritma tersebut dapat memiliki dampak signifikan pada kinerja sistem pengenalan objek pada kamera jalan raya. Oleh karena itu perlu dilakukan implementasi pada kedua algoritma ini untuk mengetahui kinerjanya jika dikombinasikan.

Pada penelitian yang berjudul “Augmentasi Data Pengenalan Citra Mobil Menggunakan Pendekatan Random Crop, Rotate dan Mixup” menjelaskan bahwa dengan menggunakan algoritma CNN untuk meningkatkan deteksi model mobil yang akurat, digunakannya teknik untuk augmentasi data seperti random crop, rotasi dan mixup dapat meningkatkan kinerja model ResNet dalam hal akurasi. Namun penggunaan mixup juga dapat meningkatkan loss. Augmentasi dapat membantu model dalam menangkap lebih banyak fitur dan informasi untuk klasifikasi. Hasil akhir dalam penelitian ini adalah dengan perbandingan pelatihan dengan jumlah epoch masing-masing 14, metode non-mixup memiliki train loss sebesar 0,513145; valid loss 0,703171 dan akurasi 0,791234. Sedangkan metode mixup memiliki train loss 0,556042; valid loss 0,712334 dan akurasi 0,824154 [3].

Pada penelitian yang berjudul “Deep Learning dalam Mengidentifikasi Jenis Bangunan Heritage dengan Algoritma Convolutional Neural Network” menjelaskan bahwa penelitian yang menggunakan algoritma CNN (Convolutional neural Network) dan KNN (K- Nearest Neighbor) berfokus pada masalah yang disebabkan karena kurangnya pengetahuan masyarakat dalam mengenali jenis-jenis bangunan heritage serta kurangnya dokumentasi digital yang ada dan adanya masalah dalam mengidentifikasi bangunan heritage yang memiliki kemiripan antara bangunan satu dan lainnya, maka dengan metode deep learning. Penelitian ini juga menunjukkan bahwa kombinasi antara algoritma CNN dan KNN dapat digunakan untuk melakukan identifikasi bangunan heritage. Hal ini ditunjukkan dengan data hasil testing menghasilkan akurasi sebesar 98%. Dengan performa yang sangat bagus dari metode ini terutama

disebabkan oleh proses ekstraksi fitur menggunakan CNN kemudian diklasifikasikan oleh algoritma KNN [4].

Pada penelitian yang berjudul “Eksperimen Pengenalan Wajah Dengan Fitur Indoor Positioning System Menggunakan Algoritma CNN” menjelaskan bahwa pencatatan absensi secara manual menimbulkan berbagai masalah seperti kecurangan dengan cara titip absen. Pada proses pengenalan wajah mampu menghasilkan nilai yang baik namun hal ini tidak terjadi pada proses estimasi posisi. Hal ini ditunjukkan dengan hasil penelitian yang menampilkan confusion matrix dengan hasil akurasi pengujian maksimum sebesar 92,89%, nilai error akurasi 7,11% dan rata-rata akurasi sebesar 91,86% [5].

Pada penelitian yang berjudul “Objek Deteksi Makanan Khas Palembang Menggunakan Algoritma YOLO (You Look Only Once) menjelaskan bahwa dikarenakan kurangnya pemahaman mengenai berbagai kuliner khas Palembang. Tingkat akurasi model algoritma yang menggunakan YOLOv3 dapat dikatakan baik karena hasil rata-rata akurasi diatas 80%. Hal ini ditunjukkan dengan akurasi rata-rata sebesar 96% dan kecepatan deteksi sebesar 40,486 milidetik dalam mengidentifikasi 31 jenis makanan tradisional dari Palembang [8].

Pada penelitian yang berjudul “Pemanfaatan YOLO Untuk Pengenalan Kesegaran Buah Mangga” menjelaskan bahwa penggunaan algoritma YOLO dalam mengidentifikasi kesegaran dan kebusukan buah mangga masih memiliki keterbatasan dalam hal akurasi karena dibutuhkan lebih banyak lagi dataset dan variasi untuk meningkatkan performanya. Pada skenario pertama yang berisi mangga segar semua menghasilkan akurasi 80%, precision 82%, recall 87% dan F1-score 84%. Pada skenario kedua yang berisi mangga busuk semua didapatkan tingkat akurasi 76%, precision 76%, recall 87% dan F1-score 81%. Pada skenario ketiga yang berisi mangga segar dan busuk menghasilkan akurasi 73%, precision 66%, recall 81% dan F1-score 73% [9].

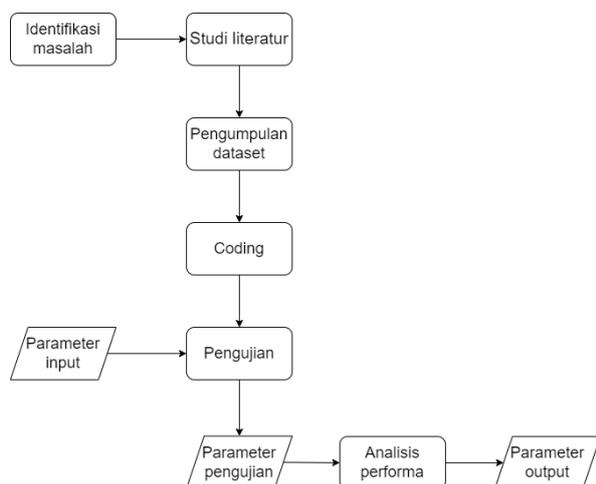
Pada penelitian yang berjudul “Pendeteksian Sel Darah Putih Dari Citra Preparat Dengan You Look Only Once” menjelaskan bahwa perlunya dibuat suatu sistem yang mempermudah deteksi citra preparat sel darah putih. Pada penelitian ini terdapat 2 skenario, yakni model preparat dengan pewarnaan (stained) dan tanpa pewarnaan (unstained). Pada skenario stained didapatkan hasil akurasi, precision, recall dan F1-score masing-masing sebesar 100%, sedangkan pada skenario unstained didapatkan hasil akurasi 76,5%, precision 100%, recall 55% dan F1-score 71,5% [7].

2. Metodologi

Metodologi dalam penelitian ini adalah dimulai dengan proses identifikasi masalah dan dilanjutkan dengan studi literatur terkait dengan permasalahan yang ada. Penelitian dimulai dengan mencari topik mengenai perkembangan mengenai algoritma machine learning. Ruang lingkup dikhususkan pada YOLO dan CNN karena algoritma ini sering diterapkan untuk berbagai macam masalah klasifikasi visual dan juga sering



digabungkan dengan algoritma lain agar lebih optimal dalam melakukan pelatihan model. Setelah itu dilanjutkan dengan proses pengumpulan dataset yang akan dilakukan proses *tagging* dan *cropping* sebagai data training. Kemudian proses selanjutnya adalah proses *coding* agar data yang sudah diproses sebagai data training dapat digunakan untuk kedua kombinasi algoritma yang akan dipakai. Langkah selanjutnya adalah melakukan pengujian dengan mengacu pada parameter yang telah ditentukan agar dapat dianalisis performa algoritma yang dikombinasikan.



Gambar 1. Flowchart Metodologi Penelitian

A. Data

Data yang digunakan pada penelitian ini berupa *dataset* gambar kendaraan yang dibedakan menjadi 4 jenis berupa motor, mobil, bus dan truck.

B. Pengumpulan Data

Pengumpulan data dilakukan melalui studi pustaka dan manual screen capturing. Pengumpulan data dilakukan agar data tersebut dapat diolah sebelum proses implementasi algoritma.

1. Studi pustaka

Pengumpulan data dilakukan dengan mencari berbagai literatur misalnya jurnal dan media internet.

2. Screen Capturing

Pengumpulan data dilakukan dengan cara melakukan *screen capture* dari situs *live streaming* CCTV jalan raya milik Dinas Perhubungan Kota Semarang pada situs <http://tiliksemar.semarangkota.go.id/dashboard>. Hal ini dilakukan agar data yang didapatkan mendekati keadaan pada jalan raya di negara Indonesia pada umumnya.

C. Pre-processing

Sebelum melakukan implementasi algoritma CNN dan YOLO, data yang sudah didapatkan akan melalui proses *tagging* (YOLO) dan *cropping* (CNN) agar data yang sudah dikumpulkan dapat disortir menurut kelasnya masing-masing lalu dapat digunakan untuk proses *training* pada masing-masing algoritma. Dataset ini terdiri dari 484 gambar dan terdapat 6482 *tagging* untuk *data training*

algoritma YOLO, dimana *tagging* tersebut terbagi dalam 4 *class* yakni motor (2050 *tag*), mobil (3650 *tag*), bus (365 *tag*) dan truck (417 *tag*). Untuk *data training* algoritma CNN, masing-masing *class* terdiri dari 100 gambar.

D. Algoritma

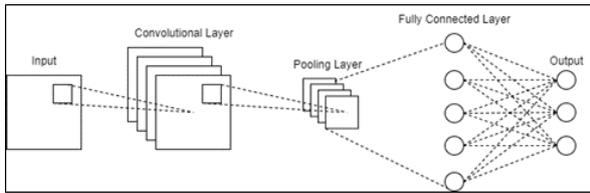
Sebuah sistem kerja komputer, yang melibatkan perangkat lunak, perangkat keras, dan manusia sebagai komponen-komponennya, adalah algoritma [10]. Ketidakterdapatnya salah satu dari ketiga elemen tersebut akan mengakibatkan komputer menjadi tidak berguna, fokus hanya pada perangkat lunak yang digunakan. Perangkat lunak sendiri terdiri dari serangkaian program dan aturan penulisan. Dalam proses merancang program atau menetapkan pedoman penulisan semacam itu, diperlukan pendekatan yang terstruktur dan logis untuk menyelesaikan masalah atau mencapai tujuan tertentu. Inilah tempat pentingnya peran algoritma. Algoritma adalah rangkaian langkah logis dan terstruktur yang digunakan untuk menyelesaikan masalah tertentu atau mencapai tujuan. Di dunia komputer, algoritma memainkan peran sentral dalam pengembangan perangkat lunak. Dalam kehidupan sehari-hari, pengaruh algoritma telah mempengaruhi berbagai aspek kehidupan kita [11].

1. CNN (Convolutional Neural Network)

Jaringan Saraf Konvolusi/Convolutional Neural Network (CNN) adalah jenis struktur jaringan saraf tiruan yang luas dipakai oleh domain pengenalan gambar, visi komputer, dan tugas terkait citra [3]. CNN dirancang untuk secara hierarkis mengenali pola dan fitur dalam data gambar dengan memanfaatkan operasi konvolusi, penggabungan, dan lapisan-lapisan non-linear. Arsitektur CNN terbagi menjadi dua bagian utama, yaitu Lapisan Ekstraksi Fitur dan Lapisan Terhubung Penuh (MLP)[12], [13]. Di dalam Lapisan Ekstraksi Fitur, terjadi "encoding" gambar menjadi representasi angka (Ekstraksi Fitur) yang terdiri dari Convolutional Layer dan Pooling Layer. Convolutional layer, sebagai lapisan pertama dan esensial dalam arsitektur CNN, melakukan konvolusi filter, biasanya berukuran 3x3, untuk mengekstrak fitur yang menonjol dari gambar input. Lapisan ini juga melibatkan parameter stride untuk mengatur pergeseran filter pada matriks serta teknik padding (zero padding) untuk mempertahankan ukuran asli gambar. Pada lapisan penggabungan (pooling layer), matriks dikurangi dengan mengambil bagian atau kelompok fitur yang dihasilkan dari lapisan konvolusi [14]. Fitur tersebut kemudian diproses untuk menghasilkan nilai yang mewakili kelompok atau bagian yang dipilih. Setelah pooling layer, terdapat lapisan terhubung penuh yang merupakan lapisan terakhir dalam arsitektur CNN. Lapisan ini bertanggung jawab untuk mengklasifikasikan input yang diterima. Fitur yang dihasilkan dari lapisan sebelumnya harus diubah bentuk (flatten) menjadi vektor agar dapat digunakan sebagai input bagi lapisan terhubung penuh sebelum menjalankan proses klasifikasi. Lalu fungsi aktivasi misalnya softmax atau sigmoid digunakan untuk



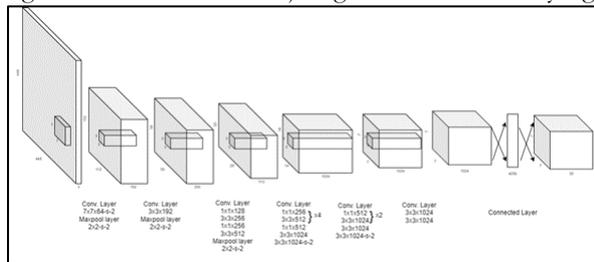
mengklasifikasikan berdasarkan nilai kategori paling tinggi [12].



Gambar 2. Arsitektur CNN

2. YOLO (You Look Only Once)

You Only Look Once (YOLO) adalah sebuah algoritma dan struktur jaringan saraf tiruan yang



Gambar 3. Arsitektur YOLO

3. Confusion Matrix

Salah satu cara pengukuran kinerja model klasifikasi yakni dengan cara mengevaluasi nilai precision dan recall. Dalam pengukuran kinerja model klasifikasi, terdapat beberapa istilah yang umum digunakan, yaitu "positive tuple" dan "negative tuple." Positive tuple merujuk pada tuple yang menjadi fokus pembahasan, sedangkan negative tuple mengacu pada tuple selain yang sedang dibahas. Terdapat pula istilah dasar dalam perhitungan nilai precision dan recall, seperti true positive (TP), true negative (TN), false positive (FP), dan false negative (FN) [1]. Istilah-istilah ini sering digabungkan dalam suatu matriks yang dikenal sebagai matriks kebingungan (confusion matrix), seperti yang ditunjukkan dalam gambar berikut.

		Predicted class		Total
		yes	no	
Actual class	yes	TP	FN	P
	no	FP	TN	N
Total		P'	N'	P + N

Confusion Matrix

Gambar 4. Confussion Matrix

True Positive (TP) adalah ketika model memberikan prediksi yang tepat untuk kelas positif pada data uji. True Negative (TN) adalah ketika model memberikan prediksi yang tepat untuk kelas negatif pada data uji. False Positive (FP) terjadi saat model memberikan prediksi yang salah

dirancang untuk melakukan deteksi objek secara real-time [15]. Proses deteksi objek berawal dengan pemilihan area objek yang ingin dideteksi dalam gambar (penandaan). YOLO menggunakan pendekatan dengan satu jaringan saraf (single neural network) pada gambar. Jaringan ini bertugas membagi gambar menjadi sejumlah wilayah (grid) dan melakukan prediksi pada masing-masing wilayah (bounding box) untuk mengklasifikasinya sebagai objek atau bukan. Arsitektur algoritma YOLO memanfaatkan Convolutional Neural Network [16] yang terdiri dari 24 lapisan konvolusi, diikuti oleh 2 lapisan terhubung penuh. Lapisan konvolusi berperan dalam mengekstraksi fitur dari gambar masukan, sementara lapisan terhubung penuh digunakan untuk memprediksi probabilitas keluaran dan koordinat objek.

dengan menganggap data uji sebagai kelas positif padahal seharusnya negatif. False Negative (FN) adalah ketika model memberikan prediksi yang salah dengan menganggap data uji sebagai kelas negatif padahal seharusnya positif..

4. Parameter Hasil Akhir

Pada penelitian ini digunakan 4 parameter hasil akhir dari pengujian yang dilakukan dari algoritma CNN dan YOLO, yakni tingkat precision, recall dan F-1 score. Tingkat presisi (precision), recall, dan F1 score adalah metrik evaluasi yang umum digunakan dalam bidang machine learning dan data mining untuk mengukur kinerja dari model klasifikasi atau sistem deteksi. Setiap metrik ini memberikan informasi yang berbeda tentang kemampuan model dalam melakukan prediksi yang benar.

1) Precision

Presisi mengukur seberapa baik model dalam mengidentifikasi kelas positif dengan benar dari semua hasil yang diprediksi sebagai kelas positif. Ini berfokus pada seberapa sedikit hasil positif palsu (false positive) yang dihasilkan oleh model. Nilai presisi dapat dihitung dengan persamaan:

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

2) Recall

Recall mengukur seberapa baik model dalam mengambil semua kasus positif yang benar dari keseluruhan data positif. Fokusnya adalah mengurangi jumlah positif palsu (false negative). Nilai recall dapat dihitung dengan persamaan:

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

3) F1-score



F1 score adalah rata-rata harmonik antara presisi dan recall. Metrik ini berguna ketika kita ingin mencari keseimbangan antara presisi dan recall, terutama ketika kelas positif dan negatif tidak seimbang (imbalanced class). F1 score mencapai nilai maksimum saat presisi dan recall memiliki nilai yang sama. Nilai F1-score dapat dihitung dengan persamaan:

$$F1 - s = 2 x \frac{Precision \times Recall}{Precision + Recall} x 100\%$$

3. Hasil dan Pembahasan

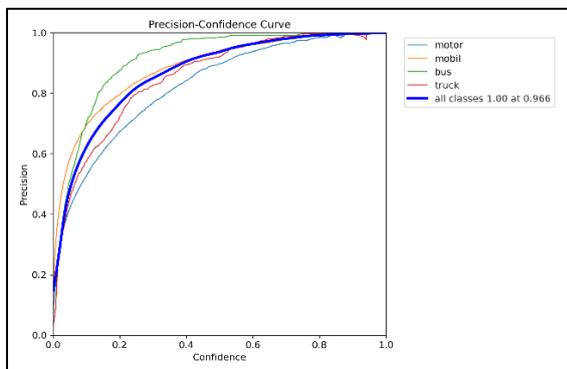
Dalam penelitian ini masing-masing algoritma dilakukan proses training secara terpisah, lalu dilakukan pengujian dengan sebuah video yang akan diproses lebih dahulu oleh algoritma YOLO untuk melakukan proses cropping berdasarkan jenis kendaraan yang terdeteksi. Setelah itu data yang telah diolah oleh algoritma YOLO akan dilakukan proses klasifikasi oleh algoritma CNN. Evaluasi dilakukan melalui pengujian terhadap kinerja dari proses pelatihan dan pengujian yang telah disusun. Hasil pencatatan akan dipisahkan berdasarkan kelas-kelas yang telah ditentukan, yaitu motor, mobil, bus, dan truk.

1) Training Algoritma YOLO

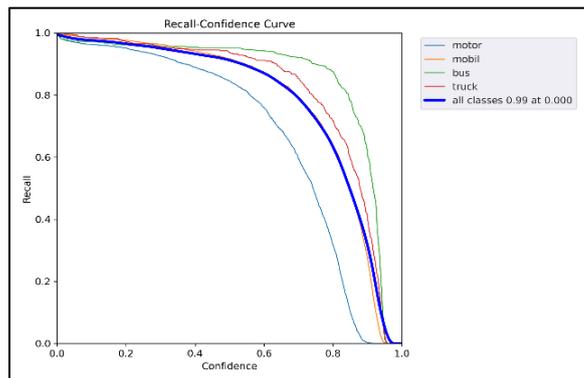
Training data pada algoritma YOLO terdiri dari 484 gambar yang terbagi menjadi 4 class. Pada class motor terdapat 2050 tag, class mobil terdapat 3650 tag, class bus 365 tag dan pada class truck terdapat 417 tag. Pengujian ini dilakukan hingga epoch 50 dapat dilihat pada Tabel 1. Hasil berupa precision dapat dilihat pada Gambar 5, hasil recall dapat dilihat pada Gambar 6 dan untuk F1-score dapat dilihat pada Gambar 7.

Tabel 1 Data Training YOLO

Epoch	Precision	Recall	F1-score
10	0,559	0,632	0,593
20	0,853	0,819	0,835
30	0,901	0,88	0,890
40	0,923	0,915	0,918
50	0,936	0,914	0,924

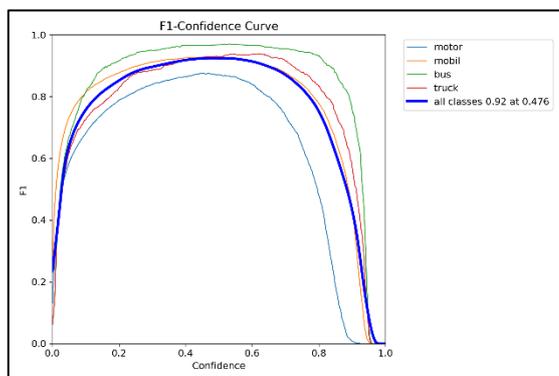


Gambar 5. Grafik Precision Hasil Training



YOLO

Gambar 6. Grafik Recall Hasil Training YOLO



Gambar 7. Grafik F1-score Hasil Training YOLO

Tabel 2 Summary Data Training YOLO

Class	Precision	Recall	F1-score
Motor	0,897	0,848	0,871
Mobil	0,94	0,918	0,928
Bus	0,985	0,951	0,967
Truck	0,92	0,94	0,929

Dari data hasil algoritma YOLO yang dibagi menjadi 5 tingkatan epoch mulai dari epoch 10, 20, 30, 40 dan 50 menunjukkan peningkatan yang signifikan pada setiap epoch yang ditunjukkan kenaikan pada setiap parameter yakni precision, recall dan f1-score yang dapat dilihat pada Tabel 1.

2) Training Algoritma CNN

Training pada algoritma CNN terdiri dari 400 gambar dalam bentuk cropping yang sudah dibagi kedalam 4 class, dimana class motor berisi 100 crop gambar, class mobil berisi 100 crop gambar, class bus berisi 100 crop gambar dan class truck juga berisi 100 crop gambar. Pengujian ini dilakukan hingga epoch 50 seperti pada algoritma YOLO yang hasilnya dapat dilihat pada Tabel 3. Hasil berupa

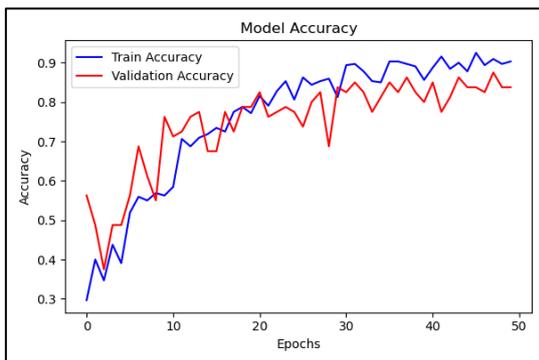


accuracy dapat dilihat pada Gambar 8 dan hasil berupa *loss* dapat dilihat pada Gambar 9.

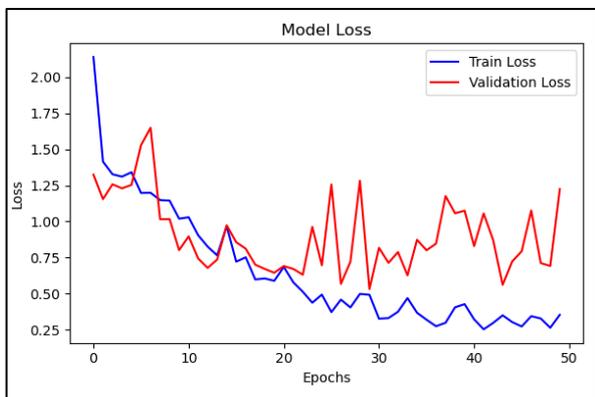
Tabel 3 Data Training CNN

Epoch	Precision	Recall	F1-score
10	0,82	0,82	0,82
20	0,88	0,87	0,87
30	0,90	0,90	0,90
40	0,96	0,95	0,96
50	0,95	0,95	0,95

Dari data hasil algoritma CNN yang terbagi menjadi 5 tingkat *epoch*, yakni *epoch* 10, 20, 30, 40 dan 50 menunjukkan sedikit peningkatan antar tingkat pada seluruh parameter yakni precision, recall dan f1-score.



Gambar 8. Grafik *Accuracy* Hasil Training CNN



Gambar 9. Grafik *Loss* Hasil Training CNN

Tabel 4 Summary Data Training CNN

Class	Precision	Recall	F1-score
Motor	0,897	0,848	0,871
Mobil	0,94	0,918	0,928
Bus	0,985	0,951	0,967
Truck	0,92	0,94	0,929

3) Cropping Data Uji

Data yang akan menjadi bahan uji pada penelitian ini adalah berupa file video berdurasi 35 detik yang menampilkan rekaman keadaan jalan raya yang

sedang dilalui banyak kendaraan. Video tersebut pertama kali akan melalui proses *cropping* yang dilakukan oleh algoritma YOLO berdasarkan data training yang telah didapatkan sebelumnya. Data hasil *cropping* akan dipisahkan berdasarkan *class* yang sudah ditentukan dalam proses training.



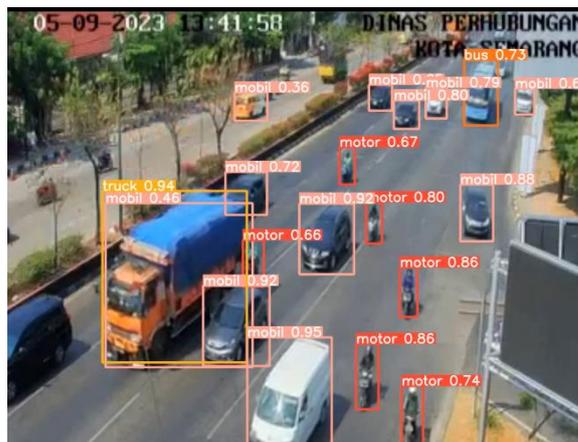
Gambar 10. Data video yang akan dilakukan proses *cropping* oleh algoritma YOLO

4) Proses Klasifikasi

Data yang telah melalui proses *cropping* oleh algoritma YOLO akan diklasifikasikan oleh algoritma CNN dengan menggunakan data training CNN (model training *epoch* 50) yang juga sudah didapatkan sebelumnya. Hasil pengolahannya dapat dilihat pada Tabel 4.

Tabel 5 Summary Data Testing YOLO + CNN

Class	Precision	Recall	F1-score
Motor	0,81	0,57	0,67
Mobil	0,82	0,73	0,77
Bus	0,08	0,36	0,13
Truck	0,29	0,28	0,28



Gambar 11. Hasil Testing YOLO + CNN



Dapat dilihat pada Tabel 5 dari hasil yang didapatkan setelah proses testing, bahwa *class* mobil mendapatkan nilai yang paling besar diantara *class* lain. Lalu diikuti oleh *class* motor, lalu *class* truck dan terakhir *class* bus pada masing-masing parameter.

Tabel 6 Data Testing YOLO + CNN

Epoch	Precision	Recall	F1-score
10	0,33	0,41	0,31
20	0,45	0,43	0,38
30	0,51	0,42	0,36
40	0,50	0,54	0,50
50	0,50	0,48	0,46

Pada Tabel 6 dapat dilihat bahwa hasil pengujian data testing dengan kombinasi algoritma YOLO dan CNN menunjukkan hasil yang kurang baik.

Hasil dari testing pada tabel tersebut terlihat meningkat dari *epoch* 10 ke *epoch* 20 pada parameter precision, recall dan f1-score. Pada *epoch* 30 terjadi peningkatan yang signifikan pada parameter precision namun pada parameter recall terjadi sedikit penurunan yang berimbas pada turunnya nilai f1-score. Kemudian beralih ke *epoch* 40 sedikit terjadi penurunan pada parameter precision namun terjadi peningkatan pada parameter recall dan f1-score. Dan pada *epoch* 50 tidak terjadi peningkatan pada parameter precision namun ada penurunan pada nilai recall dan f1-score.

4. Kesimpulan

Dari penelitian ini dapat disimpulkan bahwa baik algoritma YOLO dan CNN masing-masing memiliki performa yang baik dalam mendeteksi kendaraan berdasarkan *class* yang telah ditentukan. Hal ini ditunjukkan pada Tabel 1 dan Tabel 3 pada proses training masing-masing algoritma. Namun pada saat proses klasifikasi yang ditunjukkan pada Tabel 6 dengan cara kombinasi algoritma YOLO dan CNN menunjukkan hasil yang tidak sebaik pada saat training pada masing-masing algoritma yang digunakan. Hal ini juga terlihat pada Tabel 5 yang menunjukkan nilai pada masing-masing parameter berdasarkan tiap *class* tidak sebaik pada masing-masing algoritma YOLO dan CNN. Hal ini bisa terjadi karena perbedaan karakteristik pengenalan gambar antara algoritma YOLO dan CNN, dimana pada algoritma YOLO bisa mendeteksi objek yang terlihat walaupun tidak sepenuhnya terbuka (ada bagian yang tertutup objek lain) berdasarkan hasil *tagging* saat proses training. Sedangkan algoritma CNN dilatih berdasarkan *cropping* gambar objek secara penuh (terlihat seluruhnya). Hal yang juga mempengaruhi hasil penelitian ini adalah jumlah dataset pada masing-masing algoritma dan jenis *cropping* gambar yang menjadi data training pada algoritma CNN.

Saran untuk penelitian selanjutnya adalah dapat melakukan penelitian dengan jenis database yang berbeda, dalam artian data training dan data testing yang digunakan bisa dalam waktu yang berbeda, misalnya pada waktu

gelap/malam hari. Lalu dataset dan *class* yang digunakan dalam bentuk yang lebih bervariasi, misalnya perbedaan dalam jenis mobil berupa sedan, pickup dan SUV, lalu pada *class* truck bisa dibedakan berdasarkan bentuk dan fungsinya, misalnya truck engkel, dump truck, tronton dan trailer. Saran selanjutnya adalah dataset hasil *cropping* YOLO bisa diujicobakan untuk menjadi dataset training algoritma CNN, setelah dilakukan sortir terhadap kesalahan klasifikasi dari algoritma YOLO jika ada.

5. Daftar Pustaka

- [1] K. A. Shianto, K. Gunadi, dan E. Setyati, "Deteksi Jenis Mobil Menggunakan Metode YOLO Dan Faster R-CNN".
- [2] B. P. G. Pamungkas, B. Nugroho, dan F. Anggraeny, "Deteksi Dan Menghitung Manusia Menggunakan YOLO-CNN," vol. 02, no. 1, 2021.
- [3] J. Sanjaya dan M. Ayub, "Augmentasi Data Pengenalan Citra Mobil Menggunakan Pendekatan Random Crop, Rotate, dan Mixup," *J. Tek. Inform. Dan Sist. Inf.*, vol. 6, no. 2, Agu 2020, doi: 10.28932/jutisi.v6i2.2688.
- [4] S. Winiarti, M. Y. A. Saputro, dan S. Sunardi, "Deep Learning dalam Mengidentifikasi Jenis Bangunan Heritage dengan Algoritma Convolutional Neural Network," *J. MEDIA Inform. BUDIDARMA*, vol. 5, no. 3, hlm. 831, Jul 2021, doi: 10.30865/mib.v5i3.3058.
- [5] Y. Hartiwi, E. Rasywir, Y. Pratama, dan P. A. Jusia, "Eksperimen Pengenalan Wajah dengan fitur Indoor Positioning System menggunakan Algoritma CNN," *Paradig. - J. Komput. Dan Inform.*, vol. 22, no. 2, hlm. 109–116, Sep 2020, doi: 10.31294/p.v22i2.8906.
- [6] N. Y. S. Mendrofa, A. Mahfuzie, M. Faisal, A. Haidar, dan P. Rosyani, "Perbandingan Metode YOLO Dan FAST R-CNN Dalam Sistem Deteksi Pengenalan Kendaraan," vol. 1, no. 2, 2023.
- [7] F. Andrianson, Lina, dan A. Chris, "Pendeteksian Sel Darah Putih Dari Citra Preparat Dengan You Look Only Once," vol. 9, no. 1, 2021.
- [8] L. Rahma, H. Syaputra, A. H. Mirza, dan S. D. Purnamasari, "Objek Deteksi Makanan Khas Palembang Menggunakan Algoritma YOLO (You Only Look Once)," *J. Nas. Ilmu Komput.*, vol. 2, no. 3, hlm. 213–232, Nov 2021, doi: 10.47747/jurnalnik.v2i3.534.
- [9] M. S. Nuha dan R. Alexandro H., "Pemanfaatan YOLO untuk Pengenalan Kesegaran Buah Mangga," *Joutica*, vol. 7, no. 1, hlm. 513, Feb 2022, doi: 10.30736/jti.v7i1.747.
- [10] F. D. Wahyuningtyas, A. Arafat, A. Stiawan, dan D. Rolliawati, "Komparasi Algoritma Hierarchical, K-Means, dan DBSCAN pada Analisis Data Penjualan Melalui Facebook," *Explore J. Sist. Inf. Dan Telematika*, vol. 14, no. 1, hlm. 7, Jun 2023, doi: 10.36448/jsit.v14i1.2931.



- [11] A. M. Retta, A. Isroqmi, dan T. D. Nopriyanti, “Pengaruh Penerapan Algoritma Terhadap Pembelajaran Pemrograman Komputer,” *Indiktika J. Inov. Pendidik. Mat.*, vol. 2, no. 2, hlm. 126–135, Mei 2020, doi: 10.31851/indiktika.v2i2.4125.
- [12] R. M. Mailoa dan L. W. Santoso, “Deteksi Rompi dan Helm Keselamatan Menggunakan Metode YOLO dan CNN”.
- [13] R. A. Hamzah, C. Setianingsih, dan R. A. Nugrahaeni, “Deteksi Pelanggaran Parkir Pada Bahu Jalan Tol Dengan Intelligent Transportation System Menggunakan Algoritma Faster R-Cnn”.
- [14] S. Sakib, N. Ahmed, A. J. Kabir, dan H. Ahmed, “An Overview of Convolutional Neural Network: Its Architecture and Applications,” *Mathematics & Computer Science*, preprint, Feb 2019. doi: 10.20944/preprints201811.0546.v4.
- [15] F. Rachmawati dan D. Widhyaestoeti, “Deteksi Jumlah Kendaraan di Jalur SSA Kota Bogor Menggunakan Algoritma Deep Learning YOLO”.
- [16] D. S. Aulia, C. Setianingsih, dan M. Kallista, “Deteksi Tanda Kehidupan Pada Korban Bencana Alam Dengan Algoritma YOLO Dan Open Pose”.

