

Deteksi Pelanggaran pada Bahu Jalan Tol Menggunakan Algoritma Mask R-CNN

Rizka Rona Putri
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

rizkaronaputri@student.telkomuniversit
y.ac.id

Casi Setianingsih
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

setiacasie@telkomuniversity.ac.id

Randy Erfa Saputra
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

resaputra@telkomuniversity.ac.id

Abstrak—Bahu jalan tol merupakan jalur jalan tol kendaraan yang mengalami keadaan darurat. Namun masih banyak pengemudi yang melanggar penggunaan bahu jalan tol seperti berhenti terlalu lama pada bahu jalan tol dan mendahului kendaraan lain melalui bahu jalan tol. Makadari itu dibuat sistem yang dapat mendeteksi pelanggaran tersebut. Dengan memanfaatkan data CCTV pada jalan tol penelitian dapat dilakukan dengan mendeteksi kendaraan menggunakan algoritma *Mask R-CNN*. Algoritma tersebut dapat memprediksi sebuah object mask pada Region of Interest setiap pixel. Dataset dikumpulkan sebanyak 250 dataset kemudian data tersebut diberi label “Melanggar” dan “Tidak Melanggar”. Setiap object kendaraan pada gambar dilakukan wrapping menggunakan polygon untuk menentukan kendaraan yang melanggar dan tidak melanggar. Kemudian membentuk konfigurasi data training, data testing, dan data validation. Dataset tersebut dilatih dengan konfigurasi jumlah dataset yang berbeda dan *hyperparameter epoch, batch size, dan learning rate*. Setelah data dilatih didapatkan lah model terbaik dengan konfigurasi dataset 88% data *training*, 6% data *testing*, dan 6% data *validation* dengan *hyperparameter epoch 24, batch size 16, learning ratere*. Didapatkan hasil $mAP_{@.5:.95}$ sebesar 79,1%, $mAP_{@.5}$ sebesar 97,5%, *average precision* sebesar 97,5%, dan *average recall* sebesar 81,2%.

Kata kunci—Bahu jalan tol, Deteksi Object, Mask R-CNN.

I. PENDAHULUAN

Jalan tol merupakan jalanan jalur cepat yang umumnya dilalui oleh kendaraan seperti mobil, bus, dan truk, yang bertujuan untuk mempersingkat jarak perjalanan pengemudi kendaraan. Menurut Peraturan Pemerintah Nomor 15 Tahun 2005 Pasal 41 [1]. Pada jalan tol terdapat bahu jalan yang dipergunakan untuk pengemudi yang mengalami keadaan darurat saja, namun pengemudi yang tidak mengalami keadaan darurat tidak diperbolehkan untuk menggunakan bahu jalan.

Akan tetapi dalam mendeteksi pelanggaran tersebut membutuhkan CCTV yang dioperasikan oleh manusia yang harus selalu memantau pada setiap ruas jalan tol. Tentu saja hal tersebut memakan tenaga manusia yang banyak serta biaya yang tinggi untuk memantau ruas jalan tol selama 24 jam lamanya. Maka dari itu artificial intelligent diperlukan untuk mendeteksi pelanggaran tersebut untuk menggantikan tenaga manusia.

Pendekatan Deep Learning dapat digunakan untuk mendeteksi adanya pelanggaran penggunaan bahu jalan tol. Algoritma Mask R-CNN dapat melakukan segmentasi gambar untuk mendeteksi object. Dataset dikumpulkan melalui CCTV pada jalan tol, kemudian dataset diubah dalam format COCO dataset dan dilatih untuk mencari

hyperparameter yang tepat sehingga mendapatkan model terbaik untuk mendeteksi pelanggaran pada bahu jalan tol.

II. KAJIAN TEORI

A. Bahu Jalan Tol

Bahu jalan tol merupakan salah satu bagian penting yang ada pada jalan tol, fungsinya adalah untuk mobilisasi kendaraan saat kondisi darurat, di Indonesia peraturan mengenai kegunaan dari bahu jalan tol diatur menurut Peraturan Pemerintah Nomor 15 Tahun 2005 Pasal 41 yang terdiri dari 4 poin, yaitu: bahu jalan digunakan bagi arus lalu lintas pada keadaan darurat, diperuntukkan bagi kendaraan yang berhenti darurat, tidak digunakan untuk menarik/menderek/ mendorong kendaraan, dan tidak digunakan untuk keperluan menaikkan atau menurunkan penumpang dan/atau barang dan/atau hewan [1].

Visi komputer atau bisa dikatakan computer vision memiliki dua kata, yakni computer dan vision. Vision dapat diartikan sebagai penglihatan layaknya panca indra manusia. Visi komputer atau computer vision adalah sebuah bidang ilmu yang mempelajari dan menganalisis sebuah gambar pada komputer agar memperoleh hasil informasi sebagaimana seperti panca indra penglihatan pada manusia[2]. Penggunaan visi komputer ini di desain untuk membuat komputer dapat melihat dan mengenali sebuah objek[3].

B. Computer Vision

Computer Vision merupakan ilmu yang berkaitan dengan pencarian informasi mengenai sebuah gambar ataupun cuplikan video dengan menganalisis gambar ataupun cuplikan video tersebut. Computer Vision banyak sekali digunakan di berbagai bidang seperti pemrosesan dokumen, penginderaan jauh, radiologi, mikroskop, inspeksi industri, dan pengarah robot. Saat ini umumnya Computer vision menggabungkan kamera, komputasi berbasis edge atau cloud, perangkat lunak, dan Artificial Intelligence sehingga sistem dapat melihat dan mengidentifikasi objek. Computer Vision memiliki sistem yang dapat mengenali objek dan orang dengan cepat, menganalisis demografi khalayak, memeriksa hasil produksi, dan juga banyak hal yang lainnya yang dapat dilakukan oleh Computer Vision [2].

C. Object Detection

Object Detection merupakan sebuah ilmu yang berkaitan dengan pengidentifikasian objek di dunia nyata, contohnya seperti kendaraan, orang, hewan, jalan. Algoritma Object Detection menggunakan berbagai macam aplikasi

pemrosesan Citra Digital untuk menghasilkan bagian objek yang diinginkan. Salah satu program yang digunakan misalnya Open CV, Tensorflow serta algoritma Machine Learning maupun Deep Learning lainnya untuk mendeteksi objek yang diinginkan, biasanya masukan dapat berupa sebuah gambar, video rekaman atau video yang direkam secara langsung, dengan keluaran berupa hasil deteksi objek yang diinginkan [3].

D. Artificial Intelligence

Artificial Intelligence adalah sebuah solusi yang dibuat untuk membantu mesin menyelesaikan masalah yang kompleks pada sebuah mode yang mirip dengan manusia. Umumnya algoritma yang menyerupai karakteristik pemikiran kecerdasan manusia dan menerapkan algoritma kedalam sebuah komputer. Fleksibelnya pendekatan dari artificial intelligence memunculkan banyak artificial intelligence dengan pengembangan algoritma yang mampu meniru kecerdasan manusia sesuai kebutuhan penggunaannya [4].

Kemajuan artificial intelligence dipakai diberbagai aspek industri seperti permainan yang mampu mengalahkan pemain catur dunia. Pada bidang robotika banyak industry yang menggunakan artificial intelligence seperti pada pabrik perakitan. Robot menyerupai manusia yang mampu meniru gerakan dan perilaku manusia juga sudah banyak dikembangkan berkat artificial intelligence.


E. Machine Learning

Setiap aktifitas manusia dalam dunia digital meninggalkan banyak informasi seperti lokasi, pencarian hingga daftar belanja. Informasi tersebut dimuat dalam bentuk data yang dikumpulkan berkat teknologi basis data. Data tersebut dapat dianalisis untuk dipahami untuk model perilaku untuk membuat prediksi. Sebelum itu manusia harus menganalisa, menulis algoritma dan menerapkannya saat ini semua aktifitas tersebut dapat diperkenalkan pada sebuah mesin dan memungkinkan mesin tersebut dapat belajar sendiri dari data yang telah ada tanpa perlu diprogram secara eksplisit, hal tersebut merupakan definisi dari machine learning [5].

Dalam machine learning, komputer belajar dari contoh data yang berisi bagaimana menyelesaikan sebuah tugas. Dengan memberikan pengalaman dan tugas yang telah ditentukan ke sebuah mesin maka kinerja mesin akan meningkat. Misalnya mengklasifikasi email apakah email tersebut spam atau tidak, dengan pengalaman yang telah diberikan maka secara otomatis email baru yang sama dikalsifikasi untuk menentukan spam atau tidak [5].

F. Deep Learning

Deep learning adalah subarea dari machine learning yang mampu menyelesaikan masalah algoritma dengan lebih cepat. Dengan berkembangnya kemampuan komputasi menjadi alasan deep learning dapat berkembang yang membantu dalam pembuatan model deep neural network yang memiliki sejumlah besar hidden layer. Deep learning semakin banyak diterapkan dalam banyak bidang seperti pencitraan satelit, computer vision, sentimen analisis dari teks, suara, deteksi objek, prediksi dan lain lain. banyak yang telah dapat diselesaikan dengan deep learning daripada menggunakan metode machine learning biasa [6].




Gambar 1
Deep learning on artificial intelligence[7]

G. Convolutional Neural Network


Convolutional Neural Network merupakan salah satu dari banyak jaringan arsitektur Deep Learning yang saat ini banyak digunakan untuk mendeteksi sebuah objek, wajah manusia, dan pemandangan umum lainnya, tujuannya untuk mempermudah mengklasifikasi sebuah citra yang sudah ditandai dengan bantuan komputer [8].

Convolutional Neural Network merupakan salah satu pendekatan Deep Learning untuk memproses data yang mempunyai pola grid pattern, contohnya seperti sebuah citra yang terdiri dari kumpulan piksel yang dapat di baca oleh komputer dalam bentuk matriks, Convolutional Neural Network dirancang untuk secara otomatis dan adaptif mempelajari hierarki spasial dari sebuah features pada sebuah citra dari pattern tingkat rendah hingga pattern tingkat tinggi. Umumnya Convolutional Neural Network terdiri dari beberapa blok layer, Layer ini memiliki bermacam fungsi dasar seperti diantaranya Normalization, Convolution, Nonlinear, Pooling, dan terakhir Fully Connected Layer [9].



Gambar 2
Arsitektur Convolutional Neural Network [10]

H. Faster Region based Convolutional Neural Network (Faster R-CNN)




Gambar 3
Region Proposal Network (RPN) [11]

Faster Region based Convolutional Neural Network atau biasa disebut dengan Faster R-CNN, merupakan arsitektur yang menggunakan Convolution Neural Network (CNN) sebagai backbone utamanya. Faster R-CNN, terdiri dari dua modul. Modul pertama merupakan sebuah Region Proposed Network, dan modul kedua adalah detektor Fast R-CNN yang menggunakan region

proposed. Region Proposed Network (RPN) mengambil citra (dengan ukuran berapa pun) sebagai input dan output satu set object proposal persegi panjang. Region Proposed Network memetakan layer terakhir Convolutional Neural Network ke dimensi yang lebih rendah ke dalam feature map. Faster R-CNN di model kan dengan menggunakan Convolutional Neural Network [11].

I. Mask Region based Convolutional Neural Network (Mask R-CNN)

Mask Region based Convolutional Neural Network atau biasa disebut dengan Mask R-CNN, merupakan model Faster R-CNN yang ditambahkan cabang untuk memprediksi sebuah object mask pada Region of Interest (RoI). Cabang mask adalah fully Convolutional Network kecil yang ditambahkan kesetiap RoI untuk memprediksi segmentasi mask tiap piksel [12].




Gambar 4
Arsitektur Mask R-CNN [12].

Mask R-CNN mengadopsi dua tahap yang sama prosedur, dengan tahap pada faster R-CNN yang identik yaitu RPN. Di tahap kedua, paralel dengan memprediksi kelas dan kotak offset, Mask R-CNN juga mengeluarkan topeng biner untuk masing- masing RoI. Mask memiliki Km2 output dimensi untuk setiap ROI, yang mengkodekan K biner topeng resolusi $m \times m$, satu untuk masing-masing kelas K. Untuk ini kami menerapkan sigmoid per-piksel, dan mendefinisikan Lmask sebagai kerugian lintas-entropi biner rata-rata. Untuk RoI yang terkait dengan ground-truth class k, Lmask hanya terdefinisi pada k-th mask (output topeng lainnya tidak berkontribusi pada loss)[13].


J. Intersection over Union (IoU)

IoU merupakan metrik yang digunakan untuk mengevaluasi algoritma machine learning dengan memperkirakan seberapa baik mask yang diprediksi atau kecocokan kotak dengan data kebenaran dasar. Angka yang mengukur tingkat tumpang tindih antara dua kotak. Dalam kasus deteksi dan segmentasi objek, IoU mengevaluasi tumpang tindih wilayah *Ground Truth* dan prediksi [14].



Gambar 1
Intersection over Union [14].

Rasio Area of Overlap dengan gabungan area prediksi dan Ground Truth. nilai akan lebih kecil karena prediksi gagal memprediksi area di dalam Ground Truth. Jika luas kotak yang diprediksi lebih tinggi maka nilai akan lebih tinggi yang membuat IoU lebih rendah.




Gambar 6
hasil prediksi pada IoU [14].

Gambar 6 pada prediksi pertama menunjukkan True Positive karena threshold IoU adalah 0,5. apabila menetapkan threshold pada 0,97, itu menjadi False Positive. Demikian pula, prediksi kedua yang ditunjukkan adalah False Positive karena threshold-nya tetapi bisa menjadi True Positive jika ditetapkan threshold pada 0,20. Secara teoritis, prediksi ketiga juga bisa menjadi True Positive.

III. METODE

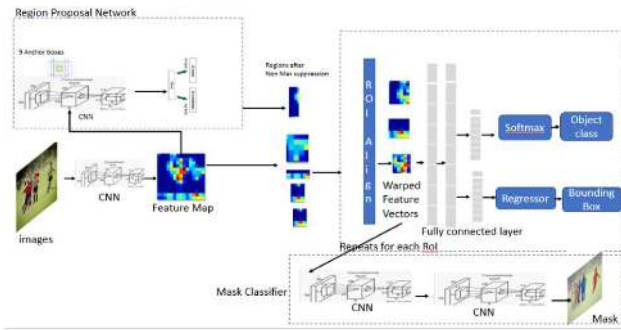
A. Desain sistem



Gambar 7
Diagram rancangan umum sistem

Deteksi pelanggaran pada bahu jalan tol menggunakan Mask R-CNN melalui data CCTV yang diproses pada komputer. Sebelum melakukan deteksi dataset dikumpulkan dengan cara mengambil gambar pada salah satu CCTV jalan tol. Gambar pada setiap dataset diberi label untuk menentukan object kendaraan yang melanggar dan tidak melanggar. Model terbaik dicari dengan cara melakukan pelatihan pada dataset dengan hyperparameter yang telah ditentukan. Mask R-CNN melalui model terbaik memproses gambar atau video CCTV untuk mendeteksi kendaraan yang melanggar dan tidak melanggar.

B. Arsitektur Mask R-CNN dalam Mendeteksi Pelanggaran



Gambar 8
Arsitektur Mask R-CNN dalam Mendeteksi Pelanggaran [11].

Gambar yang akan dideteksi dijalankan melalui CNN untuk menghasilkan peta fitur. Region Proposal Network (RPN) menggunakan CNN untuk menghasilkan beberapa Region of Interest (RoI) menggunakan pengklasifikasi biner ringan. Ini dilakukan dengan menggunakan 9 kotak jangkar di atas gambar. Pengklasifikasi mengembalikan skor objek/tanpa objek. Non Max suppression diterapkan pada Jangkar dengan skor objektivitas tinggi.

Jaringan RoI Align mengeluarkan beberapa kotak pembatas daripada satu kotak yang pasti dan melengkungkannya ke dalam dimensi yang tetap. Fitur Warped kemudian dimasukkan ke dalam lapisan yang terhubung sepenuhnya untuk membuat klasifikasi menggunakan softmax dan prediksi kotak batas lebih disempurnakan menggunakan model regresi. Fitur Warped juga dimasukkan ke dalam pengklasifikasi Mask, yang terdiri dari dua CNN untuk mengeluarkan mask biner untuk setiap RoI. Mask Classifier memungkinkan jaringan untuk menghasilkan Mask untuk setiap kelas yang dipisahkan antar kelas sehingga objek melanggar dan tidak melanggar dapat dideteksi.

C. Analisis Kebutuhan Dataset


Dataset yang digunakan pada penelitian ini sama dengan penelitian yang dilakukan sebelumnya oleh Maulana Heady Yusfian, Casi Setianingsih, dan Ratna Astuti yaitu pada ruas tol JORR-S KM 30+300 dengan ditambah data sebanyak 150 jadi total data sebanyak 250 dalam satu dataset. Dataset diambil dengan cara mengambil tangkapan layar pada CCTV jalan tol, kemudian disimpan dalam bentuk gambar. Gambar yang diambil merupakan gambar yang terdapat kendaraan dengan kondisi melanggar dan tidak melanggar. Dataset kemudian dibagi menjadi data train, data validation, dan data test.



Gambar 9
CCTV jalan tol

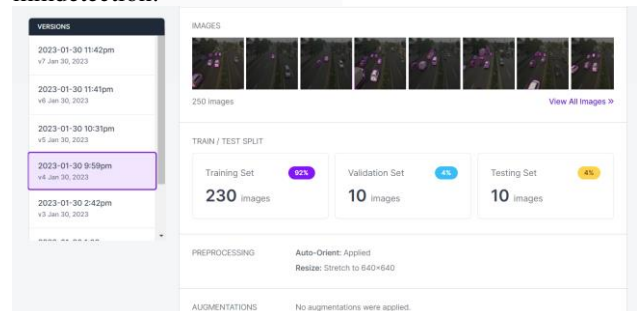
D. Menambahkan label pada dataset dengan Roboflow

Dataset yang telah dikumpulkan di upload dan dilabel menggunakan Roboflow, kemudian objek yang akan dideteksi ditandai menggunakan polygon tools. Label terbagi menjadi dua kelas yaitu “Melanggar” dan “Tidak Melanggar”. Dataset yang telah dilabel diambil kombinasi jumlah data train, test dan valid dataset di train untuk mendapat hasil terbaik dari setiap kombinasi dataset yang dibuat.



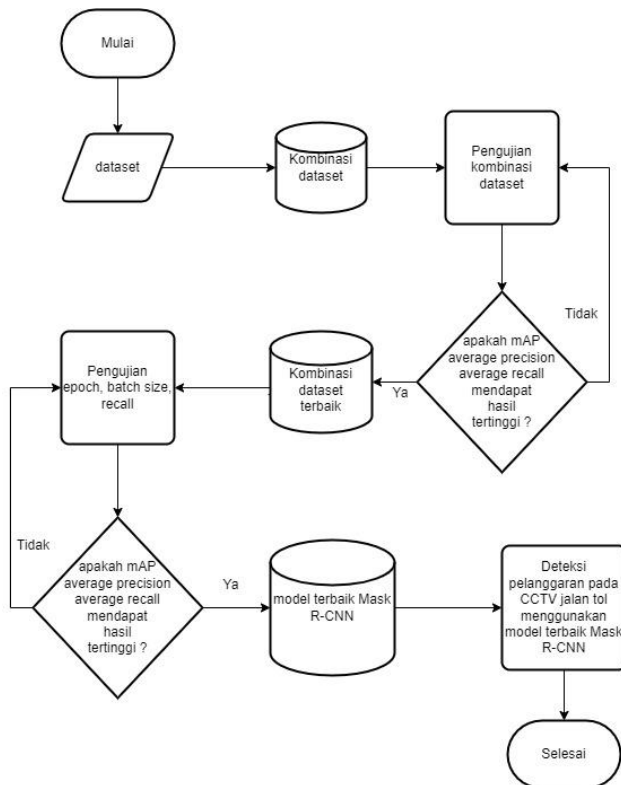
Gambar 10
Melabel dataset menggunakan roboflow

Dataset yang telah diberi label kemudian dataset dibagi menjadi beberapa versi sesuai dengan kombinasi dataset untuk dianotasi. Dataset yang diperlukan yaitu 80% data train, 10% data test, dan 10% data validation. kemudian versi berikutnya training dataset ditambah jumlahnya hingga menjadi versi yang terakhir yaitu 96% data train, 2% data test, dan 2% data validation. Kemudian dataset diubah dalam format COCO untuk diproses menggunakan tools mmdetection.




Gambar 11
Membuat kombinasi dataset menggunakan roboflow

E. Proses Pemodelan dan Deteksi Pelanggaran Mask R-CNN



Gambar 12
Flowchart pembuatan model terbaik

Dalam mencari model terbaik kombinasi dataset yang telah dibentuk dilakukan pelatihan. Setelah mendapat hasil terbaik dengan beberapa kombinasi dataset tersebut kemudian dilatih lagi dengan hyperparameter epoch, batch size, dan learning rate. Dataset yang dilatih pada setiap hyperparameter, dilihat parameter mAP, average precision, dan average recall untuk menentukan model terbaik. Setelah mendapatkan model terbaik Mask R-CNN salah satu gambar dicoba menggunakan model tersebut untuk melihat hasil dari algoritma Mask R-CNN dalam mendeteksi pelanggaran pada bahu kiri jalan tol. Kemudian model terbaik juga diuji coba pada video jalan tol. Berikut hasil dari mendeteksi pelanggaran pada bahu kiri jalan tol menggunakan model terbaik Mask R-CNN.



Gambar 13
Hasil deteksi pelanggaran

F. Analisis Performa Deteksi Mask R-CNN

Setelah proses training model telah dilakukan kemudian menganalisis performa dari Mask R-CNN dalam mendeteksi

pelanggaran. Analisis ini bertujuan agar model yang telah dikembangkan sesuai dengan yang telah diharapkan dengan melihat metrik validasi. Parameter yang akan menjadi acuan dalam menganalisis performa model adalah sebagai berikut:

1. mAP_@.5:95 dihitung dengan nilai rata-rata (mean) dari Average Precision (AP) dan pada IoU thresholds 0,5 sampai 0,95.
2. mAP_@.5 dihitung dengan nilai rata-rata (mean) dari Average Precision (AP) dan pada IoU thresholds 0,5.
3. Average Precision digunakan untuk menganalisa tingkat keakuratan dari prediksi yang dilakukan.
4. Average Recall adalah persentase kecenderungan sistem untuk menemukan True Positive pada keseluruhan prediksi yang dilakukan.

G. Analisis Kebutuhan Perangkat Lunak

Perangkat lunak yang dibutuhkan dalam mengembangkan sistem di antaranya adalah sebagai berikut:

1. Google Colaboratory, software eksekusi kode yang digunakan dalam membuat program Backpropagation Neural Network.
2. Roboflow, software yang digunakan untuk memberi label pada dataset dan merubah format dataset dalam bentuk COCO, serta memisahkan dataset menjadi data train, test, dan valid.
3. MMDetection, tools yang digunakan untuk melakukan train dan membuat model terbaik Mask R-CNN.

H. Analisis Kebutuhan Perangkat Lunak

Perangkat keras yang digunakan pada penelitian Tugas Akhir ini mempunyai spesifikasi dengan detail sebagai berikut:

1. Processor : Intel(R) Core(TM) i3-7020U CPU @ 2.30GHz (4 CPUs), ~2.3GHz.
2. RAM : 8 GB.
3. Sistem Operasi : Windows 10 Home Single Language 64-bit (10.0, Build 19044)(19041.vb_release.191206-1406).
4. GPU : Intel(R) HD Graphics 620 dan NVIDIA GeForce MX110, 4GB Display memory.

IV. HASIL DAN ANALISIS

A. Skenario Pengujian

Pada tahap pengujian dilakukan uji model dan mengevaluasi model hingga mendapat hasil terbaik dengan konfigurasi hyperparameter berbeda beda. Konfigurasi hyperparameter yang diuji yaitu kombinasi dataset, pengujian epoch, pengujian batch size, dan pengujian learning rate. Model terbaik merupakan model yang mempunyai mAP, average precision dan average recall yang tinggi.

B. Kombinasi Dataset

Dataset yang diuji berjumlah 250 dengan kombinasi dataset yang telah diatur sebagai berikut:


1. 80% data training, 10% data testing, 10% data validation.
2. 84% data training, 8% data testing, 8% data validation.
3. 88% data training, 6% data testing, 6% data validation.

4. 92% data training, 4% data testing, 4% data validation.
5. 96% data training, 2% data testing, 2% data validation.

Tabel 1
Hasil pengujian kombinasi dataset

	mAP_ _{@.5} :.95	mAP_ _{@.5}	Average Precision	Average Recall
80_10_10	73,6%	94,7%	94,7%	79,5%
84_8_8	76,9%	98%	98%	80,7%
88_6_6	81%	98%	98%	82,6%
92_4_4	76,8%	98%	98%	81,4%
96_2_2	75,2%	96,4%	96,4%	81,9%

Setelah dataset diuji didapat lah hasil terbaik dari beberapa kombinasi dataset yang telah dibuat. Dataset dengan kombinasi 88% data training, 6% data testing, 6% data validation menjadi dataset terbaik. Hasil dari dataset tersebut mendapatkan nilai mAP__{@.5}:95 sebesar 81%, mAP__{@.5} sebesar 98%, average precision sebesar 98%, dan average recall sebesar 82,6%. Dataset tersebut akan dipakai untuk pengujian berikutnya. Berikut adalah grafik hasil pengujian dataset berdasarkan tabel 1.



Gambar 14
Grafik pengujian konfigurasi dataset.

C. Pengujian Epoch

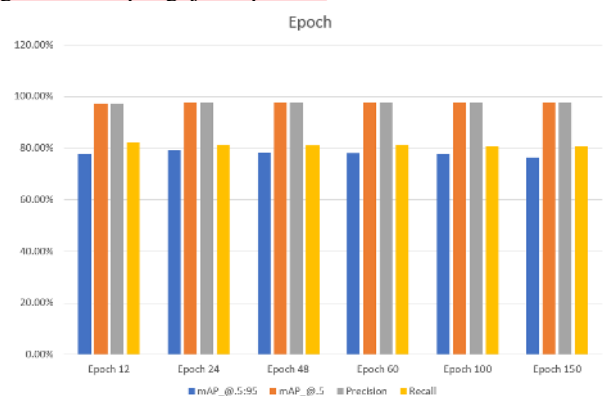
Pengujian hyperparameter epoch merupakan pelatihan disaat semua data digunakan sekaligus dan didefinisikan sebagai jumlah total iterasi dari semua data pelatihan dalam satu siklus untuk melatih model. Data diuji dengan jumlah epoch 12, 24, 48, 60, 100, 150. Dataset yang digunakan merupakan dataset dengan kombinasi 88% data training, 6% data testing, 6% data validation. Kemudian dataset diuji dengan epoch yang telah ditentukan, berikut hasil pengujiannya.

Tabel 2
Hasil pengujian epoch

	mAP_ _{@.5} :.95	mAP_ _{@.5}	Average Precision	Average Recall
Epoch 12	77,8%	97,3%	97,3%	82,1%
Epoch 24	79,1%	97,5%	97,5%	81,2%

h 24				
Epoch 24	78,2%	97,6%	97,6%	81%
Epoch 48	78,1%	97,6	97,6%	81,4%
Epoch 60	77,7%	97,5%	97,5%	80,7%
Epoch 100	76,4%	97,5%	97,5%	80,9%
Epoch 150				

Setelah dataset diuji dengan hyperparameter epoch yang telah ditentukan, didapat lah hasil terbaik dari beberapa kombinasi epoch. Dataset dengan epoch 24 menjadi hyperparameter epoch terbaik. Hasil dari pengujian epoch tersebut mendapatkan nilai mAP__{@.5}:95 sebesar 78,2%, mAP__{@.5} sebesar 97,6%, average precision sebesar 97,6%, dan average recall sebesar 81,2%. Dataset dengan epoch 24 akan dipakai untuk pengujian berikutnya. Berikut adalah grafik hasil pengujian epoch berdasarkan tabel 2.



Gambar 15
Grafik pengujian epoch

D. Pengujian Batch Size

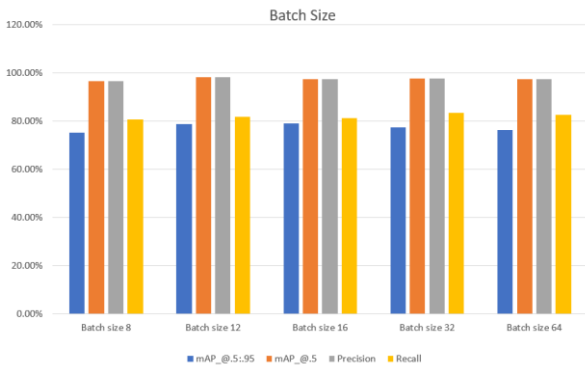
Pengujian hyperparameter batch size merupakan hyperparameter yang menentukan jumlah sampel yang diambil untuk mengerjakan model tertentu sebelum memperbarui parameter model internalnya. Batch dapat dianggap sebagai iterasi for-loop pada satu atau lebih sampel dan membuat prediksi. Prediksi ini kemudian dibandingkan dengan variabel output yang diharapkan pada akhir batch. error dihitung dengan cara membandingkan keduanya dan kemudian digunakan untuk memperbaiki mode. Data diuji dengan jumlah epoch 24 dengan kombinasi dataset 88% data training, 6% data testing, 6% data validation, berikut hasilnya.

Tabel 3
Hasil pengujian batch size

	mAP_ _{@.5} :.95	mAP_ _{@.5}	Average Precision	Average Recall
Batch size 8	75,4%	96,8%	96,8%	80,7%
Batch size 12	78,8%	98,3%	98,3%	82%

Batch size 16	79,1%	97,5%	97,5%	81,2%
Batch size 32	77,5%	97,8%	97,8%	83,4%
Batch size 64	76,4%	97,5%	97,5%	82,6%

Setelah dataset diuji dengan hyperparameter batch size yang telah ditentukan, didapat lah hasil terbaik dari beberapa kombinasi batch size. Dataset dengan batch size 16 menjadi hyperparameter batch size terbaik. Hasil dari pengujian batch size tersebut mendapatkan nilai mAP_@.5:95 sebesar 79,1%, mAP_@.5 sebesar 97,5%, average precision sebesar 97,5%, dan average recall sebesar 81,2%. Dataset dengan batch size 16 akan dipakai untuk pengujian berikutnya. Berikut adalah grafik hasil pengujian batch size berdasarkan tabel 3.



Gambar 16
Grafik pengujian batch size


E. Pengujian Learning Rate

Pengujian learning rate merupakan hyperparameter yang mengontrol seberapa banyak perubahan model sebagai respons terhadap perkiraan kesalahan setiap kali bobot model diperbarui. Data diuji dengan jumlah epoch 24 dengan kombinasi dataset 88% data training, 6% data testing, 6% data validation dan batch size 16, berikut hasilnya.

Tabel 4
Hasil pengujian learning rate

	mAP_@.5:9	mAP_@.	Average Precision	Average Recall
Lr 0.02	78,8%	98,3%	98,3%	82%
Lr 0.002	76,4%	97,5%	97,5%	82,6%
Lr 0.0002	67,5%	90,7%	91,1%	78,3%
Lr 0.00002	54,2%	70%	70,6%	71,4%

Setelah dataset diuji dengan hyperparameter learning rate yang telah ditentukan, didapat lah hasil terbaik dari beberapa kombinasi learning rate. Dataset dengan learning rate 0.02 menjadi hyperparameter learning rate terbaik. Hasil dari pengujian learning rate tersebut mendapatkan nilai mAP_@.5:95 sebesar 79,1%, mAP_@.5 sebesar 97,5%, average precision sebesar 97,5%, dan average recall sebesar 81,2%. Berikut adalah grafik hasil pengujian learning rate berdasarkan tabel 4.




Gambar 17
Grafik learning rate

F. Model Terbaik

Dari proses training yang telah dilakukan dapat disimpulkan konfigurasi dataset dan hyperparameter terbaik untuk mendapatkan model dengan performa terbaik adalah dengan mempartisi dataset dengan rasio 88:6:6, pada epoch = 24 batch size = 16 dan learning rate 0.02. Dari proses training yang telah dilakukan didapatkan score mAP_@50:95 sebesar 79,1%, mAP_@50 sebesar 97,5%, average precision sebesar 97,5%, dan average recall sebesar 81,2%. Kemudian akan diuji dengan gambar salah satu dataset pada jalan tol serta video CCTV pada jalan tol. Model juga diuji coba pada CCTV jalan tol dilokasi yang berbeda.

G. Inference pada Data Test

Inference merupakan uji coba data ke model terbaik yang telah didapatkan. Pada proses ini, dilakukan pengujian untuk mengetahui performa model. Proses ini dapat dilakukan dengan data test yang terdapat pada dataset yang diuji, Proses inference ini diperlukan untuk menguji performa model untuk mendeteksi objek pada dataset yang telah diuji sebelumnya. Berikut adalah hasil inference yang telah dilakukan pada gambar di data test.

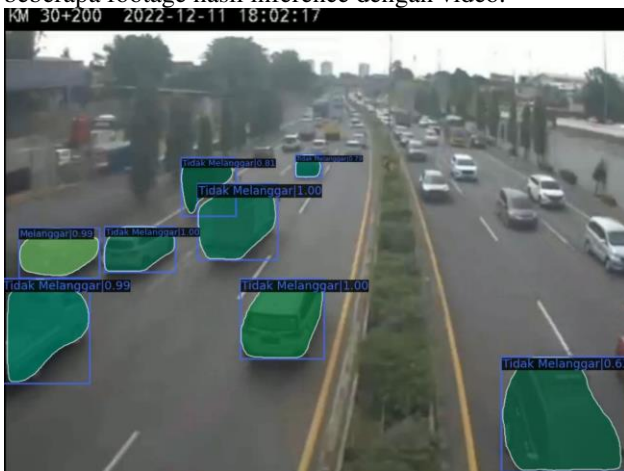


Gambar 18

Hasil deteksi gambar dengan model terbaik.

H. Inference Dengan Video

Video Inference dengan video diperlukan untuk menguji dan memastikan model dapat mendeteksi objek pelanggar pada video maupun pada CCTV secara langsung. Berikut beberapa footage hasil inference dengan video.



Gambar 19

Hasil deteksi video dengan model terbaik.

I. Inference Pada CCTV yang Berbeda

Inference video pada CCTV di lokasi jalan tol yang berbeda dapat dilakukan berikut hasilnya.



Gambar 20 Hasil deteksi video CCTV jalan tol berbeda dengan model terbaik.



Object kendaraan yang melanggar dan tidak melanggar dapat dideteksi. pada gambar diatas object kendaraan yang tidak melanggar sebanyak 9 dan melanggar sebanyak 1. Akan tetapi pada bagian kanan jalan, algoritma mendeteksi object kendaraan tidak melanggar sebanyak 3 yang seharusnya tidak perlu dideteksi.

V. KESIMPULAN DAN SARAN

A. Kesimpulan

Berdasarkan hasil dari penelitian Tugas Akhir Mask R-CNN dapat digunakan dalam mendeteksi pelanggaran pada jalan tol. Mask R-CNN dapat dikembangkan lebih lanjut untuk keperluan pendeteksian object.

1. Pengujian dataset sebanyak 250 yang telah dilakukan didapatkanlah model terbaik Mask R-CNN dengan kombinasi hyperparameter epoch 24, batch size 16, dan learning rate 0.02.
2. Dari model terbaik yang telah diuji didapatkan hasil mAP 79,1%, mAP 50 97,5%, average precision 97,5%, dan average recall 81,2%.

B. Saran

Berdasarkan hasil dari penelitian Tugas Akhir Mask R-CNN dapat digunakan dalam mendeteksi pelanggaran pada jalan tol. Mask R-CNN dapat dikembangkan lebih lanjut untuk keperluan pendeteksian object.

REFERENSI

- [1] K. P. dan R. Rakyat, "PERATURAN PEMERINTAH REPUBLIK INDONESIA NOMOR 15 TAHUN 2005." <https://bpjt.pu.go.id/peraturan/peraturan-pemerintah> (accessed Oct. 20, 2022).
- [2] A. Eslam and M. Solyman, "INTRODUCTION TO COMPUTER VISION," vol. 0100048051, no. February, 2019.
- [3] Y. Amit, P. Felzenszwalb, and R. Girshick, "Object Detection," *Comput. Vis.*, no. January 2020, pp. 875–883, 2021, doi: 10.1007/978-3-030-63416-2_660.
- [4] M. Litch and A. Karofsky, "Artificial Intelligence," *Philos. through Film*, pp. 102–129, 2020, doi: 10.4324/9780203772294-10.

- [5] R. Farhat, Y. Mourali, M. Jemni, and H. Ezzedine, "An overview of machine learning technologies and their use in e-learning," Proc. 2020 Int. Multi- Conference Organ. Knowl. Adv. Technol. OCTA 2020, pp. 8–11, 2020, doi: 10.1109/OCTA49274.2020.9151758.
- [6] M. Dixit, A. Tiwari, H. Pathak, and R. Astya, "An overview of deep learning architectures , libraries and its applications areas," 2018 Int. Conf. Adv. Comput. Commun. Control Netw., pp. 293–297, 2018, doi: 10.1109/ICACCCN.2018.8748442.
- [7] S. M. Piyush Madan, "An introduction to deep learning," Organizational Behavior. <https://developer.ibm.com/articles/an-introduction-to-deep-learning/>.
- [8] A. Upreti, "Convolutional Neural Network (CNN): A comprehensive overview," Int. J. Multidiscip. Res. Growth Eval., no. August, pp. 488–493, 2022, doi: 10.54660/anfo.2022.3.4.18.
- [9] R. Chauhan, K. K. Ghanshala, and R. C. Joshi, "Convolutional Neural Network (CNN) for Image Detection and Recognition," ICSCCC 2018 - 1st Int. Conf. Secur. Cyber Comput. Commun., no. December 2018, pp. 278–282, 2018, doi: 10.1109/ICSCCC.2018.8703316.
- [10] S. Saha, "A Comprehensive Guide to Convolutional Neural Networks," 2018. <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53> (accessed Feb. 02, 2023).
- [11] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," IEEE Trans. Pattern Anal. Mach. Intell., vol. 39, no. 6, pp. 1137–1149, 2017, doi: 10.1109/TPAMI.2016.2577031.
- [12] A. F. Gad, "Object Detection Using Mask R-CNN with TensorFlow | Paperspace Blog," vol. 3, no. 10, pp. 18–22, 2020, [Online]. Available: <https://blog.paperspace.com/mask-r-cnn-in-tensorflow-2-0/>.
- [13] P. Doll, R. Girshick, and F. Ai, "[FAIR] Mask R-CNN."
- [14] Kukil, "Intersection over Union (IoU) in Object Detection & Segmentation," Organizational Behavior. <https://learnopencv.com/intersection-over-union-iou-in-object-detection-and-segmentation/>.