

PENDAHULUAN

Moda transportasi kereta api memegang peranan penting dalam distribusi penumpang dan barang di Indonesia. Data dari Badan Pusat Statistik (BPS) menunjukkan bahwa penumpang kereta api dari Januari hingga Maret 2024 mencapai 98,8 juta orang, naik sebesar 14,78% dibanding periode waktu yang sama pada tahun 2023. Seiring dengan meningkatnya penumpang, frekuensi perjalanan kereta api juga mengalami peningkatan. Namun, peningkatan ini juga berdampak pada meningkatnya jumlah kecelakaan pada transportasi kereta api, khususnya di perlintasan sebidang. Dalam rentang waktu empat tahun, dari 2020 hingga Juni 2024, kecelakaan yang terjadi di perlintasan sebidang mencapai 1.353 kejadian. Hal ini menunjukkan bahwa kecelakaan di perlintasan sebidang membutuhkan perhatian khusus.

Sesuai dengan Peraturan Menteri Perhubungan Nomor 94 Tahun 2018 tentang Peningkatan Keselamatan Perlintasan Sebidang Antara Jalur Kereta Api Dengan Jalan, setiap JPL harus memiliki alat pendeteksi kereta api yang dapat mendeteksi kedatangan kereta api sebelum perlintasan dengan jarak paling jauh delapan kilometer [1]. Pendeteksi sarana kereta api terdiri dari dua jenis, yaitu *axle counter* dan *track circuit*.

Kemajuan teknologi kini telah mencapai pada penerapan *artificial intelligence* untuk

melakukan pekerjaan yang dapat dilakukan manusia [2]. Salah satu bidang AI yaitu *machine learning*. Sub kategori *machine learning* yang menggunakan jaringan saraf tiruan sesuai prinsip jaringan saraf otak manusia disebut dengan *deep learning* sehingga kategori ini dibagi menjadi klasifikasi citra, deteksi objek, pemrosesan bahasa alami, dan pengenalan suara [3].

Penulis mengembangkan suatu alat yang berfungsi untuk mendeteksi sarana menggunakan kecerdasan buatan atau *artificial intelligence* dengan teknis pengambilan video. Salah satu bentuk deteksi objek yang digunakan sekarang ini adalah metode YOLO. Metode ini bekerja menggunakan kamera dan dapat mendeteksi objek. *You Only Look Once* (YOLO) merupakan salah satu bagian dari *deep learning* yang dapat mendeteksi objek dengan cara pemecahan citra menjadi beberapa *grid* dan memberi kotak pembatas atau *bounding box* untuk mengindikasikan objek yang terdapat dalam sebuah citra [4]. Prinsip kerja YOLO adalah memberikan beberapa kotak pembatas dan nilai kepercayaan untuk menentukan objek. Sebelum itu model YOLO dilatih dengan menggunakan *dataset* berlabel dimana setiap citra memiliki kotak pembatas dan label kelas objek [5].

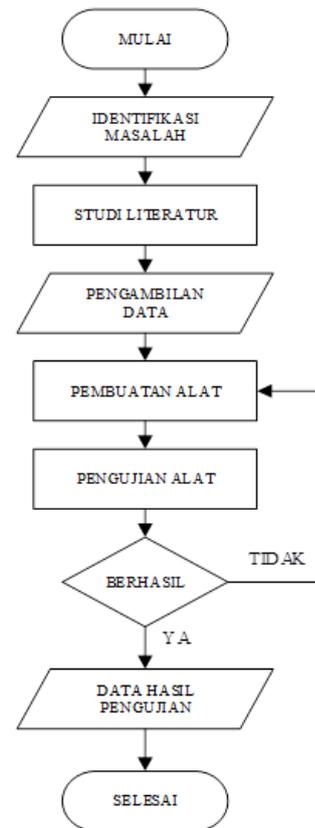
Dengan menggunakan kamera yang ditempatkan sebelum JPL, sistem deteksi berbasis YOLO dapat mengetahui keberadaan sarana. Kamera akan menangkap

video dari jalur kereta api, yang kemudian diproses oleh algoritma YOLO untuk mendeteksi berbagai jenis sarana seperti lokomotif, gerbong, dan kereta penumpang. *Output* dari alat ini berupa data visual berupa citra yang menampilkan hasil deteksi sarana [6].

METODE

2.1 Diagram Alir

Proses dimulai dengan identifikasi masalah yang terdapat pada JPL 03 yang berada di Klagenserut, Kecamatan Jiwan, Kabupaten Madiun, Provinsi Jawa Timur. Permasalahan pada JPL tersebut adalah tidak adanya alat *Early Warning System* (EWS) yang dapat mendeteksi kedatangan sarana kereta api. Setelah itu melakukan proses studi literatur tentang standar keamanan yang terdapat pada JPL dan studi literatur tentang deteksi objek menggunakan AI yang berasal dari jurnal maupun artikel. Kemudian proses penelitian dilanjutkan dengan pengambilan data berupa citra sarana yang dilakukan secara langsung. Setelah memiliki *dataset* yang cukup, maka akan dilanjutkan proses pembuatan alat dan pengujian alat. Tujuan melakukan pengujian alat untuk mengetahui apakah alat dapat mendeteksi sarana [7]. Apabila alat dapat mendeteksi sarana akan menghasilkan *output* data hasil pengujian berupa citra sarana. Tetapi jika alat tidak dapat mendeteksi sarana maka proses akan diulang pada pembuatan alat.



Gambar 1. Diagram alir penelitian
Sumber: Dokumen peneliti, 2024

2.2 Metode Pengumpulan Data

Penelitian ini membagi pengumpulan data berdasarkan menggunakan dua metode, yaitu data primer dan sekunder. Data primer didapatkan melalui metode seperti wawancara dengan *Petugas Negatif Cek* (PNC) dan survei di lapangan secara langsung. Sedangkan data sekunder diperoleh melalui sumber yang sudah ada seperti buku, jurnal, dan internet.

2.3 Metode Perancangan Alat

1. Perancangan *Hardware*

Pertama sensor kamera cctv mengambil *input* berupa citra dari

keberadaan sarana yang terdapat pada jalur kereta api. Pengambilan *input* menggunakan dua IP kamera IR bullet network. Kemudian kamera dihubungkan pada *switch* menggunakan kabel LAN. Kemudian *switch* dihubungkan pada laptop. Video dari cctv tersebut diolah pada laptop menggunakan algoritma YOLO. Pada alat ini menggunakan power yang berasal dari listrik PLN. Pendeteksian sarana menggunakan algoritma YOLO menghasilkan *output* berupa citra yang telah diberi kotak pembatas (*bounding boxes*) [8]. *Bounding box* dapat digunakan untuk memberi label yang berbeda pada setiap obyek citra berdasarkan label yang dimilikinya [9].



Gambar 2. Perancangan *hardware*
Sumber: Dokumen peneliti, 2024

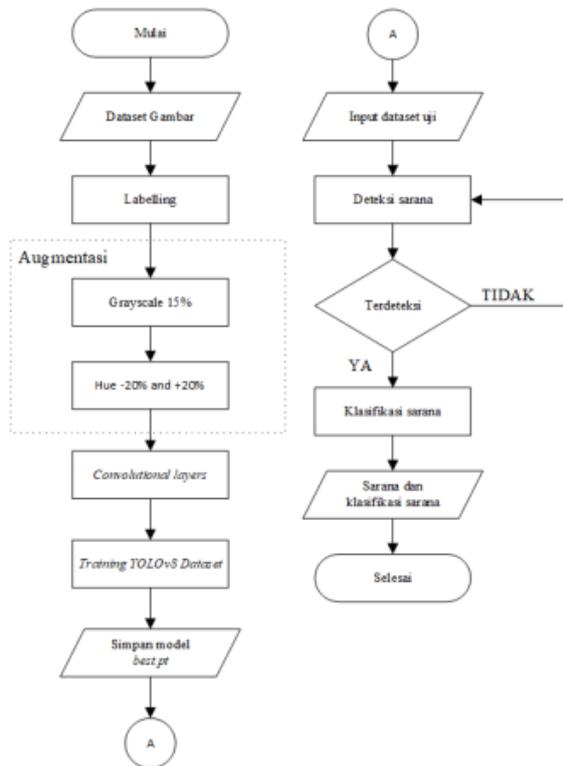
2. Perancangan *Software*

Flowchart dimulai dengan *input dataset* berupa citra sarana yang telah dikumpulkan secara langsung. Kemudian citra tersebut akan di-*upload* pada *platform*

roboflow untuk melakukan proses *labelling*. Setelah itu dilanjutkan proses *augmentasi*, yaitu perubahan citra menjadi *grayscale* sebanyak 15% dan ditambahkan *hue* antara -20% sampai 20%. Tujuan dilakukannya proses *augmentasi* adalah untuk menambah variasi *dataset* lebih beragam sehingga algoritma dapat mengenali berbagai macam citra. Kemudian dilakukan konvolusi pada layer untuk mengekstrak fitur dari citra seperti tepi, sudut, dan pola lain yang lebih kompleks. Tahap selanjutnya yaitu *training dataset* [10]. Hasil *dataset* dari *roboflow* yang telah di-*labelling* akan di-*ekspor* ke dalam *google colab* untuk proses *training data*. *Google colab* memiliki kapasitas penyimpanan besar dan *run time* yang cepat menggunakan *GPU* sehingga cocok untuk penyimpanan *dataset* [11]. Dilakukan pembagian *dataset* menjadi tiga, yaitu data *training*, data *test*, dan data validasi.

Data *training* berisi citra yang telah diberi label dan digunakan untuk melatih model. Data *test* berisi data yang belum pernah dilihat model dan digunakan untuk menguji kinerja model. Data validasi berisi data yang sama dengan data *test*, tetapi tanpa label dan digunakan untuk mengevaluasi kinerja akhir model setelah diuji. Tujuan pembagian *dataset* agar model memiliki kinerja yang baik dan mencegah terjadi *overfitting* pada data

baru yang belum pernah dilihat [12]. Proses *training* menggunakan beberapa jenis model dan jumlah *epoch* yang beragam. Setelah proses *training* selesai, maka akan menghasilkan model dalam file *best.pt*.



Gambar 3. Flowchart penelitian
Sumber: Dokumen peneliti, 2024

Hasil model pelatihan akan digunakan untuk deteksi sarana. Sebelum memulai percobaan pendeteksian, dilakukan pemanggilan terhadap model yang telah di-*training*. Jika alat dapat mendeteksi sarana, maka akan menghasilkan *output* berupa citra sarana yang diberi kotak pembatas (*bounding boxes*). Terakhir hasil dari semua pengujian akan disimpan dalam bentuk

citra.

2.4 Metode Pengolahan Data

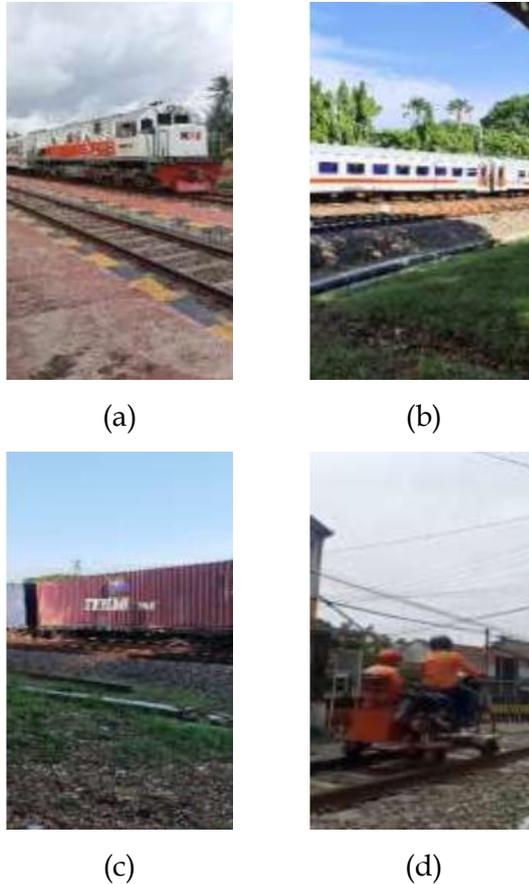
Data primer berupa citra sarana yang diambil secara langsung dari lapangan dijadikan sebagai dasar untuk melakukan pengenalan kepada sistem aplikasi pendeteksi penambat berbasis YOLOv8. Khususnya pada saat *preprocessing* data dan *training* data. Selain data primer, data sekunder berguna sebagai dasar perancangan dan analisis dalam penelitian ini.

1. Akuisisi Data

Akuisi data yaitu proses pengambilan gambar yang berasal dari berbagai sumber untuk mendapatkan citra digital [13], [14]. Citra digital yaitu bidang yang memiliki intensitas cahaya pada bidang dua dimensi dan mempunyai informasi lebih banyak dibanding teks [15]. Citra memiliki karakteristik yang sangat unik sehingga tidak dimiliki oleh jenis data yang lain karena kaya akan informasi yang terkandung dalam citra tersebut [16]. Semakin tinggi kualitas citra yang dihasilkan, semakin besar pula kapasitas yang dibutuhkan [17].

Dalam penelitian ini, akuisi data sarana perkeretaapian dilakukan dengan beberapa langkah yang sistematis. Proses akuisisi data berupa foto dan video yang diambil di DAOP 3 Cirebon secara langsung yang merupakan lokasi PKL penulis. Data yang masih berbentuk video akan diubah ke dalam bentuk citra menggunakan *platform roboflow*.

Data yang diambil merupakan citra dari lokomotif, kereta, gerbong, dan kendaraan pemeriksa jalur (kpi).



Gambar 4. Citra (a) lokomotif, (b) kereta, (c) gerbong, dan (d) kendaraan pemeriksa jalur (kpi)
Sumber: Dokumen peneliti, 2024

Akuisisi data dilakukan pada pagi hari, sore hari, dan malam hari. Hal itu bertujuan untuk mengetahui apakah model masih dapat bekerja dengan baik saat pencahayaan mulai berkurang. Akuisisi data ini menghasilkan 400 data citra yang terdiri dari masing-masing sarana berjumlah 100 citra.

2. Proses *preprocessing*

Proses *preprocessing* diawali dengan meng-*upload* data berupa video dan citra ke

dalam *platform roboflow*. Jika data berupa video, maka akan diubah menjadi beberapa citra. Tahap selanjutnya melakukan proses pembuatan kelas sesuai dengan jumlah kelas sarana. Pada penelitian ini kelas sarana dibedakan menjadi 4, yaitu lokomotif, kereta, gerbong, dan kpi. Kemudian, proses dilanjutkan dengan melakukan pelabelan pada citra yang didalamnya terdapat objek sarana. Pelabelan dilakukan satu per satu pada setiap citra. Jika telah selesai, simpan semua data yang telah diberi label. Kemudian dilakukan proses *generate* pada *dataset*.

Pembagian *dataset* ini bertujuan agar model dapat berlatih dengan baik dan mencegah terjadinya *overfitting* pada model. Setelah itu ukuran citra diubah menjadi 640x640 piksel. Kemudian dilakukan normalisasi dengan mengubah nilai piksel dari rentang 0-255 ke rentang 0-1 untuk memastikan model dapat memproses data secara lebih efisien dan stabil secara numerik. Proses augmentasi data juga diterapkan untuk meningkatkan keragaman dataset. Tahap ini sangat penting karena memastikan bahwa data *input* berkualitas tinggi dan sesuai dengan model YOLO sehingga efektif untuk mendeteksi sarana perkeretaapian dengan akurat.

3. *Training* dan Validasi

Import os digunakan untuk menyimpan *dataset* hasil *training* yang diletakkan pada *google drive*. Pada citra tersebut juga terdapat *install ultralytics* yang merupakan perusahaan

yang mengembangkan algoritma YOLOv8.

Setelah itu dilakukan pembuatan *folder* untuk menyimpan *dataset* yang diletakkan pada *drive*. Selain itu juga dilakukan *install roboflow* untuk memanggil *dataset* yang telah dilakukan *preprocessing* pada *roboflow*. Pada *dataset* ini dilakukan pelatihan beberapa kali dengan model yang berbeda untuk mendapatkan hasil akurasi yang terbaik. Selain itu pelatihan dilakukan dengan mengubah *epoch* agar hasil pelatihan beragam. Pada proses validasi ini akan menghasilkan sebuah model algoritma yang digunakan untuk pengujian.

2.5 Metode Pengujian Alat

1. Pengujian Akurasi Algoritma

Pengujian akurasi sarana bertujuan untuk mengevaluasi hasil pendeteksian sarana menggunakan algoritma YOLOv8. Pengujian dilakukan untuk mengetahui seberapa baik model dalam mendeteksi sarana perkeretaapian pengujian akurasi dihitung dengan menggunakan *confusion matrix*. Akurasi algoritma kemudian dihitung berdasarkan rumus yang mengacu pada nilai-nilai dalam *confusion matrix* yang meliputi *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*.

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots (2.1)$$

2. Pengujian Deteksi Sarana

Pengujian deteksi sarana bertujuan

untuk mengetahui hasil pendeteksian sarana menggunakan algoritma YOLOv8. Pengujian ini menggunakan kamera dan dilakukan pada saat sarana bergerak. Pengujian deteksi sarana ini bertujuan untuk mendeteksi sarana yang terdapat pada jalur dengan menggunakan algoritma YOLO v8. Pengujian ini berfungsi untuk menjamin dan memastikan kinerja alat dapat beroperasi dengan baik pada saat di lapangan.

HASIL DAN PEMBAHASAN

3.1 Hasil Pengujian Algoritma

Tingkat akurasi algoritma YOLOv8 dengan menggunakan *confusion matriks* yang diproses dari hasil *training* setiap model yang terdapat pada algoritma YOLOv8. Hasil tingkat akurasi dapat dicari menggunakan rumus (2.1).

a. YOLOv8n *epoch* 50

Hasil akurasi menggunakan model YOLOv8n dengan *epoch* 50. Dari citra tersebut dapat dihitung hasil akurasi lokomotif 99,25%, kereta 93,25%, gerbong 92,5%, dan kpj 99,25%.

b. YOLOv8n *epoch* 100

Hasil akurasi menggunakan model YOLOv8n dengan *epoch* 100. Dari citra tersebut dapat dihitung hasil akurasi lokomotif 96%, kereta 93,25%, gerbong 92,5%, dan kpj 99,25%.

c. YOLOv8s *epoch* 50

Hasil akurasi menggunakan model

YOLOv8s dengan *epoch* 50. Dari citra tersebut dapat dihitung hasil akurasi lokomotif 99,06%, kereta 94,94%, gerbong 91,57%, dan kpj 99,81%.

d. YOLOv8m *epoch* 50

Hasil akurasi menggunakan model YOLOv8m dengan *epoch* 50. Dari citra tersebut dapat dihitung hasil akurasi lokomotif 99,06%, kereta 94,19%, gerbong 92,32%, dan kpj 99,43%.

e. YOLOv8m *epoch* 100

Hasil akurasi menggunakan model YOLOv8m dengan *epoch* 100. Dari citra tersebut dapat dihitung hasil akurasi lokomotif 98,68%, kereta 93,44%, gerbong 92,5%, dan kpj 99,62%.

f. YOLOv8i *epoch* 50

Hasil akurasi menggunakan model YOLOv8i dengan *epoch* 50. Dari citra tersebut dapat dihitung hasil akurasi lokomotif 99,25%, kereta 93,82%, gerbong 92,5%, dan kpj 99,62%.

g. YOLOv8i *epoch* 100

Hasil akurasi menggunakan model YOLOv8i dengan *epoch* 100. Dari citra tersebut dapat dihitung hasil akurasi lokomotif 98,87%, kereta 93,44%, gerbong 92,5%, dan kpj 99,62%.

h. YOLOv8x *epoch* 50

Hasil akurasi menggunakan model YOLOv8x dengan *epoch* 50. Dari citra tersebut dapat dihitung hasil akurasi lokomotif 98,87%, kereta 94,38%, gerbong 92,32%, dan kpj 99,81%.

3.2 Hasil Pengujian Deteksi Sarana

Hasil pengujian deteksi sarana perkeretaapian dilakukan pada waktu pagi, sore, dan malam hari. Pengujian ini menggunakan model *training* YOLOv8s, dengan *learning rate* 0,001, *optimizer* SGD, dan *epoch* 50. Hasil data pengujian dilakukan dengan mengambil berupa citra dan video hasil deteksi setiap objek yang terdeteksi dalam jumlah *frame rate* suatu video pada kamera cctv.

3.2.1 Hasil Pengujian Deteksi Waktu Pagi Hari

Pengujian pertama dilakukan pada rangkaian kereta dengan durasi 18 detik menghasilkan akurasi sebesar 89%. Kemudian pengujian kedua dilakukan pada rangkaian gerbong pertama menghasilkan akurasi sebesar 52%. Pada kedua pengujian tersebut terdapat perbedaan akurasi yang cukup jauh dikarenakan untuk rangkaian gerbong pertama terjadi *underfitting*.

Tabel 1. Hasil deteksi sarana waktu pagi hari

No	Citra	Durasi	Hasil	
			Sistem	Aktual
1		18	212	236

2		15	78	150
---	---	----	----	-----

Sumber: Dokumen peneliti, 2024

3.2.2 Hasil Pengujian Deteksi Waktu Sore Hari

Pengujian deteksi dilakukan sebanyak dua kali dengan rangkaian kereta yang berbeda. Pengujian pertama dilakukan pada rangkaian kereta panoramic yang menghasilkan nilai akurasi sebanyak 85%. Sedangkan pengujian kedua menghasilkan nilai akurasi sebanyak 91%. Nilai akurasi pada pengujian sore hari cukup tinggi dikarenakan objek mendapatkan cahaya yang cukup dan cuaca yang terang.

Tabel 2. Hasil deteksi sarana waktu sore hari

No	Citra	Durasi (detik)	Hasil	
			Sistem	Aktual
1		9	124	145
2		25	284	312

Sumber: Dokumen peneliti, 2024

3.2.3 Hasil Pengujian Deteksi Waktu Malam Hari

Pengujian deteksi sarana dilakukan

sebanyak dua kali dengan tempat yang berbeda. Pengujian pertama dilakukan pada jalur sebelum JPL yang tidak terdapat pencahayaan sama sekali, sedangkan pengujian kedua dilakukan pada sebelah JPL yang terdapat pencahayaan. Hasil akurasi dari pengujian pertama adalah 33% dan pengujian kedua 44%. Hasil dari pengujian ini menunjukkan bahwa kurangnya pencahayaan dapat mempengaruhi hasil deteksi yang dilakukan.

Tabel 3. Hasil deteksi sarana waktu malam hari

No	Citra	Durasi (detik)	Hasil	
			Sistem	Aktual
1		10	3	9
2		30	42	94

Sumber: Dokumen peneliti, 2024

PENUTUP

Setelah melakukan pengujian dan analisis pada sistem, beberapa kesimpulan dapat ditarik sebagai berikut:

1. hasil akurasi model algoritma YOLOv8 menunjukkan bahwa model YOLOv8s dengan *learning rate* 0,001; *optimizer* SGD, dan *epoch* 50 memiliki akurasi yang paling baik yaitu akurasi lokomotif 99,25%,

- kereta 93,25%, gerbong 92,5% dan kpj 99,25%. Untuk akurasi model YOLOv8x dengan *epoch* 50 juga memiliki akurasi yang baik, tetapi pada proses pelatihan membutuhkan waktu yang lebih lama dan memori yang lebih besar. Kemudian hasil akurasi model YOLOv8n dengan *epoch* 100 memiliki akurasi yang paling rendah yaitu akurasi lokomotif 96%, kereta 93,25%, gerbong 92,5%, dan kpj 99,25%.
2. hasil akurasi deteksi sarana pada pagi hari didapatkan dari hasil pengujian sebanyak 3 kali. Pengujian pagi 1 menunjukkan bahwa algoritma YOLOv8 dapat mendeteksi sarana perkeretaapian dan menghasilkan akurasi yang paling baik yaitu sebesar 96,3% pada sarana lokomotif dan 88,1% pada sarana kereta.
 3. hasil akurasi deteksi sarana pada sore hari didapatkan dari hasil pengujian sebanyak 2 kali. Pengujian sore 2 menghasilkan akurasi yang paling bagus yaitu sarana lokomotif 99,2% dan kereta 92,7%. Hal tersebut membuktikan bahwa model algoritma dapat mendeteksi sarana pada waktu sore hari.
 4. hasil akurasi deteksi sarana pada malam hari didapatkan dari hasil pengujian sebanyak dua kali. Pada pengujian malam 2 dilakukan pada tempat dengan kondisi cahaya yang terbatas dan mendapatkan akurasi yang paling tinggi, yaitu 98,1% pada sarana lokomotif dan 65,8% pada sarana kereta.

5. hasil pengujian deteksi sarana menunjukkan bahwa algoritma YOLO dapat mendeteksi sarana perkeretaapian pada waktu pagi hari dan sore hari. Sedangkan untuk deteksi pada malam hari algoritma YOLO memiliki hasil akurasi yang rendah dikarenakan kurangnya pencahayaan.

DAFTAR PUSTAKA

- [1] Kementerian Perhubungan, "Peraturan Menteri Perhubungan Nomor 94 Tahun 2018 tentang Peningkatan Keselamatan Perlindungan Sebidang Antara Jalur Kereta Api Dengan Jalan", Peraturan Perundang-undangan, Jakarta, 2018.
- [2] B. Sasmito, B. H. Setiadji, and R. Isnanto, "Deteksi Kerusakan Jalan Menggunakan Pengolahan Citra Deep Learning di Kota Semarang", *TEKNIK*, vol.44, no.1, pp.7-14, 2023, <https://doi.org/10.14710/teknik.v44i1.51908>.
- [3] J. J. Hwang, Y. H. Jung, B. H. Cho, and M. S. Heo, "An Overview of Deep Learning in the Field of Dentistry", *Imaging Science in Dentistry*, vol.49, no.1, pp.1-7, 2019, <https://doi.org/10.5624/isd.2019.49.1.1>.
- [4] A. R. Wasril, M. S. Ghozali, and M. B. Mustafa, "Pembuatan Pendektesi Obyek Dengan Metode You Only Look Once (YOLO) Untuk Automated Teller Machine (ATM)", *Majalah Ilmiah UNIKOM*, vol.17, no.1, pp.69-76, 2019, <https://doi.org/10.34010/miu.v17i1.2240>.
- [5] A. Gallu, A. R. Himamunanto, and H. Budiati, "Pengenalan Emosi pada Citra Wajah Menggunakan Metode YOLO", *KESATRIA: Jurnal Penerapan Sistem Informasi (Komputer & Manajemen)*, vol.5,

- no.3, pp.1253-1261, 2024, <https://pkm.tunasbangsa.ac.id/index.php/kesatria/article/view/444>.
- [6] J. Pardede and H. Hardiansah, "Deteksi Objek Kereta Api menggunakan Metode Faster R-CNN dengan Arsitektur VGG 16", *MIND (Multimedia Artificial Intelligent Networking Database) Journal*, vol.7, no.1, pp.21-36, 2022, <https://doi.org/10.26760/mindjournal.v7i1.21-36>.
- [7] M. Fayyadh, U. Sunarya, and R. Nugraha, "Perancangan Sistem Otomatisasi Palang Pintu Kereta Api Berbasis Motion Detection", *e-Proceeding of Engineering*, vol.2, no.1, pp.291-297, 2015, <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/1681>.
- [8] H. J. Jeong, K. S. Park, and Y. G. Ha, "Image Preprocessing for Efficient Training of YOLO Deep Learning Networks", *2018 IEEE International Conference on Big Data and Smart Computing (BigComp)*, Shanghai, China, pp.635-637, 2018, <https://doi.org/10.1109/BigComp.2018.00113>.
- [9] T. Arifianto, "Segmentasi Aksara Pada Tulisan Aksara Jawa Menggunakan Adaptive Threshold", *SMATIKA: STIKI Informatika Jurnal*, vol.7, no.1, pp.1-5, 2017, <https://jurnal.stiki.ac.id/SMATIKA/article/view/20>.
- [10] G. Li, Z. Song, and Q. Fu, "A New Method of Image Detection for Small Datasets under the Framework of YOLO Network", *2018 IEEE 3rd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC 2018)*, Chongqing, China, pp.1031-1035, 2018, <https://doi.org/10.1109/IAEAC.2018.8577214>.
- [11] K. Mistry and A. Saluja, "An Introduction to OpenCV using Python with Ubuntu", *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, vol.1, no.2, pp.65-68, 2016, <https://ijsrcseit.com/home/issue/view/article.php?id=CSEIT16129>.
- [12] R. G. Fajri, I. Santoso, and Y. A. A. Soetrisno, "Perancangan Program Pendeteksi dan Pengklasifikasi Jenis Kendaraan Dengan Metode Convolutional Neural Network (CNN) Deep Learning", *Transient: Jurnal Ilmiah Teknik Elektro*, vol.9, no.1, pp.97-106, 2020, <https://doi.org/10.14710/transient.v9i1.97-106>.
- [13] T. Ismail, Supatman, and I. D. Rahayu, "Aplikasi Pengembangan Metode Seleksi Kualitas Kacang Kulit Oven Dengan Convolutional Neural Network (CNN)", *JITET (Jurnal Informatika dan Teknik Elektro Terapan)*, vol. 12, no.3, pp.2726-2734, 2024, <http://dx.doi.org/10.23960/jitet.v12i3.4874>.
- [14] B. Hartanto, B. W. Yudanto, and D. Nugroho, "Optimasi Deteksi Tepi Pada Citra Digital Melalui Tuning Hyperparameter Clahe dan Filter Bilateral: Studi Kasus Pada Gambar Kendaraan", *Biner : Jurnal Ilmiah Informatika dan Komputer*, vol.3, no.2, pp.134-141, 2024, <https://ojs.unsiq.ac.id/index.php/biner/article/view/7745>.
- [15] F. Fachrunnisa, A. Usman, and M. Khairani, "Implementasi Noise Removal dan Image Enhancement Pada Citra Digital Menggunakan Metode Adaptive Median Filter", *Jurnal Ilmu Komputer dan Sistem Informasi (JIRSI)*, vol.3, no.1, pp.11-20, 2024, <https://jurnal.unity-academy.sch.id/index.php/jirsi/article/view/95>.

- [16] R. C. S. Hariyono, K. Khoerunisa, N. M. Saraswati, R. N. Prasetyono, M. Z. Alfariki, "Deteksi Penyakit Bercak Coklat, Coklat Sempit Dan Hawar Melalui Spektrum Warna Citra Digital Daun Padi Menggunakan Metode Convolutional Neural Network", *ZONAsi: Jurnal Sistem Informasi*, vol.5, no.2, pp.334-346, 2023, <https://doi.org/10.31849/zn.v5i2.13245>.
- [17] P. A. R. Devi and H. Rosyid, "Pemaparan Materi Dasar Pengolahan Citra Digital untuk Upgrade Wawasan Siswa di SMK Dharma Wanita Gresik", *Jurnal Abdi Masyarakat Indonesia (JAMSI)*, vol.2, no.4, pp.1259-1264, 2022, <https://doi.org/10.54082/jamsi.4>