

BAB V PENUTUP

5.1 Kesimpulan

Berdasarkan analisis dan pengujian yang telah dilakukan, terdapat beberapa kesimpulan yang dapat disampaikan dalam penelitian ini.

A. Deteksi Objek

- 1) Algoritma YOLOv8 berhasil diimplementasikan menggunakan parameter *default* YOLOv8-nano dan 21.175 dataset plat nomor kendaraan negara lain yang diperoleh dari *roboflow* dalam kondisi telah diaugmentasi dengan perbandingan 87% data latih, 8% data validasi, dan 4% data uji.
- 2) Kinerja model yang dilatih menggunakan YOLOv8-nano menunjukkan hasil mAP 0.984 pada tahap pelatihan, dan F1 score sebesar 0.85 dan kecepatan 46 FPS pada pengujian menggunakan dataset video.
- 3) Hasil pengujian berdasarkan jenis kendaraan, posisi kendaraan, posisi plat nomor, dan warna plat nomor, serta perspektif kamera ditemukan bahwa:
 - Deteksi plat nomor pada jenis kendaraan sepeda motor tidak berhasil dengan F1 score 0.0, sementara kendaraan dengan roda 4 atau lebih berhasil terdeteksi dengan F1 score 0.86.
 - Deteksi plat nomor dengan posisi kendaraan sebelah kanan menunjukkan hasil F1 Score 0.82, sementara posisi kendaraan sebelah kiri memiliki F1 Score 0.89.
 - Deteksi plat nomor dengan posisi plat nomor normal berhasil terdeteksi dengan F1 Score 0.88, namun posisi plat nomor Till Up dan Tilldown tidak berhasil terdeteksi dengan F1 Score 0.0.
 - Deteksi plat nomor pada Plat nomor dengan warna Hitam memiliki F1 score 0.78, Putih 1.00, Merah 1.00, dan Kuning 1.00.
 - Pada pengujian dengan perspektif kamera Pan Side menghasilkan F1 Score 0.85 dan Center 0.87.

B. Segmentasi Karakter

- 1) Metode segmentasi karakter pada citra plat nomor kendaraan dapat dilakukan menggunakan *grayscale*, *adaptive thresholding*, dan deteksi kontur.
- 2) Kinerja metode segmentasi karakter menggunakan *grayscale*, *adaptive thresholding*, dan deteksi kontur menghasilkan F1 score sebesar 0.48.
- 3) Hasil pengujian berdasarkan ukuran citra plat nomor, perspektif plat nomor, kondisi plat nomor, dan warna plat nomor, ditemukan bahwa:
 - Segmentasi karakter pada ukuran citra dengan lebar lebih dari 92px menghasilkan F1 Score sebesar 0.58, sementara pada ukuran citra dengan lebar kurang dari 92px menghasilkan F1 score sebesar 0.39.
 - Segmentasi karakter pada perspektif plat nomor sejajar atau lurus menghasilkan F1 score sebesar 0.46, sedangkan plat nomor dengan kondisi miring menghasilkan F1 score sebesar 0.49.
 - Segmentasi karakter pada kondisi plat nomor yang baik menghasilkan F1 score sebesar 0.52, kondisi plat nomor yang kurang baik menghasilkan F1 score sebesar 0.21, dan kondisi plat nomor yang tidak baik menghasilkan F1 score sebesar 0.17.
 - Segmentasi karakter pada plat nomor dengan warna hitam menghasilkan F1 score sebesar 0.40, plat nomor dengan warna putih menghasilkan F1 score sebesar 0.70, plat nomor dengan warna merah menghasilkan F1 score sebesar 0.37, dan plat nomor dengan warna kuning menghasilkan F1 score sebesar 0.50.

C. Klasifikasi Karakter

- 1) Algoritma CNN telah berhasil diimplementasikan menggunakan:
 - 7128 dataset yang dibuat sendiri dari font plat nomor Indonesia dan telah diaugmentasi dengan perbandingan data 50% data latih, 33% data validasi, dan 17% data uji.
 - Arsitektur CNN dirancang sendiri dengan komposisi 2 lapisan konvolusi, 2 lapisan Relu, dan 2 lapisan Max Pool pada tahap fitur learning. Hal ini

menghasilkan 16 channel dengan ukuran 32x32 sebagai output pada tahap fitur learning. Selanjutnya, pada tahap pembobotan atau klasifikasi, digunakan 1 hidden layer fully connected dengan lapisan linear dan 128 node, yang menghasilkan output sejumlah 36 kelas.

- Parameter pelatihan Adam Optimizer dengan Learning Rate sebesar 0.001 dan Loss Function berupa Cross Entropy. Proses pelatihan dilakukan pada perangkat CUDA dan berlangsung selama 50 epoch.
- 2) Kinerja model CNN yang telah dilatih menggunakan dataset, arsitektur, dan parameter pelatihan yang telah dijelaskan sebelumnya telah dievaluasi dengan melakukan 10 kali pelatihan. Hasil evaluasi pelatihan menunjukkan bahwa model ini mencapai rata-rata akurasi data pelatihan 1.00, data validasi 1.00, akurasi data uji sebesar 0.9931, dengan rata-rata standar deviasi dari hasil pelatihan adalah sebesar 0.2206. Namun ketika dilakukan pengujian menggunakan citra plat nomor hasil segmentasi karakter, dihasilkan F1 score sebesar 0.60.
- 3) Hasil pengujian menggunakan citra hasil segmentasi menunjukkan bahwa:
- Citra hasil segmentasi yang tidak memiliki *noise* mendapatkan akurasi sebesar 0.81, sedangkan citra dengan sebagian *noise* mendapatkan akurasi sebesar 0.66, dan citra dengan banyak *noise* mendapatkan hasil akurasi sebesar 0.21.
 - Citra hasil segmentasi yang sejajar atau lurus mendapatkan hasil akurasi sebesar 0.64, sedangkan citra yang tidak sejajar atau miring mendapatkan hasil akurasi sebesar 0.57.
 - Citra hasil segmentasi yang mudah terbaca manusia mencapai akurasi sebesar 0.66, citra yang sebagian terbaca manusia mencapai akurasi sebesar 0.59, sementara citra yang tidak terbaca manusia sama sekali mendapatkan hasil akurasi 0.0.

5.2 Saran

Dari kesimpulan diatas, berikut ini beberapa saran yang dapat dilakukan untuk pengembangan lebih lanjut.

- 1) Menerapkan pelatihan model YOLOv8 menggunakan dataset plat nomor kendaraan Indonesia, terutama untuk kendaraan roda dua yang belum berhasil terdeteksi. Dengan ini diharapkan model dapat belajar dari data yang lebih relevan dan mencerminkan kondisi sebenarnya dari plat nomor kendaraan yang ada di Indonesia.
- 2) Menerapkan pelatihan model YOLOv8 menggunakan hyperparameter tuning untuk mencari kombinasi yang lebih optimal daripada *default parameter* yang tersedia pada YOLOv8.
- 3) Menerapkan normalisasi citra sebelum melakukan segmentasi karakter, seperti meningkatkan kualitas citra, memperbaiki perspektif dan posisi citra plat nomor, dan melakukan *cropping* pada area nomor kendaraan agar hasil segmentasi lebih fokus terhadap karakter.
- 4) Menerapkan metode lain untuk segmentasi karakter yang lebih efektif dan tahan terhadap berbagai kondisi citra.
- 5) Menerapkan pelatihan model CNN dengan dataset validasi dari hasil *cropping* karakter pada plat nomor kendaraanya. Tujuannya agar pembaruan bobot dapat lebih merepresentasikan kondisi data yang sebenarnya.
- 6) Menerapkan nilai random seed pada pembobotan fully connected layer untuk mendapatkan stabilitas dan konsistensi dalam pelatihan model. Dengan menggunakan nilai random seed yang sama, proses pembobotan fully connected layer akan tetap konsisten setiap kali model dilatih, sehingga membantu memastikan bahwa model akan memberikan hasil yang stabil dan konsisten dalam setiap percobaan pelatihan.
- 7) Menerapkan hyperparameter tuning pada CNN seperti penggunaan dropout, dan optimizer lain (RMSprop, SGD, dan Adagrad). Tujuannya untuk mendapatkan variasi terbaik dari kinerja dan hasil model CNN.
- 8) Menerapkan pengenalan karakter menggunakan metode deteksi objek atau klasifikasi multi label.

Dengan melakukan evaluasi, pengembangan, dan penelitian lebih lanjut, diharapkan penelitian ini dapat memberikan kontribusi yang lebih baik dalam pengembangan deteksi objek dan pengenalan karakter pada plat nomor kendaraan.