

BAB V

KESIMPULAN DAN SARAN

Bab ini menyajikan kesimpulan hasil penelitian dan saran untuk pengembangan selanjutnya. Kesimpulan mencakup pencapaian utama dari implementasi model klasifikasi jenis jalan menggunakan algoritma *Support Vector Machine* (SVM), *K-Nearest Neighbor* (KNN), dan *Gradient Boosting Decision Tree* (GBDT), serta evaluasi performa model berdasarkan *confusion matrix*. Selain itu, bagian saran memberikan rekomendasi untuk perbaikan dan pengembangan penelitian di masa depan, terutama terkait penambahan variasi jenis jalan dan penerapan sistem secara *real-time*.

5.1 Kesimpulan

Berdasarkan hasil penelitian dan analisis yang telah dilakukan, maka dapat disimpulkan sebagai berikut:

1. Pembangunan Model Prediksi Jenis Jalan

Model prediksi jenis jalan berhasil dibangun menggunakan tiga algoritma *supervised learning*, yaitu *Support Vector Machine* (SVM), *K-Nearest Neighbors* (KNN), dan *Gradient Boosting Decision Tree* (GBDT). Model-model ini dilatih menggunakan dataset yang berasal dari ekstraksi fitur tegangan dan arus motor DC kemudi. Proses pelatihan dilakukan dalam dua skenario yaitu menggunakan *dataset* dengan label jenis jalan saja dan dataset gabungan antara jenis jalan dan arah kemudi. Setiap model menunjukkan kemampuannya dalam mengenali pola dari data sensor untuk melakukan klasifikasi jenis jalan.

2. Evaluasi Model Prediksi Jenis Jalan

Evaluasi dilakukan menggunakan dua pendekatan utama, yaitu *train-test split* dan *K-Fold Cross Validation*, dengan mengandalkan *confusion matrix* (*precision*, *recall*, *f1-score*) sebagai metrik utama untuk mengukur performa model dalam klasifikasi. Hasil evaluasi dengan *train-test split* menunjukkan bahwa ketiga model mampu mencapai nilai *precision*, *recall*, dan *f1-score* yang sangat tinggi, bahkan sempurna (1.00) dalam banyak kategori. Hal ini mengindikasikan kemampuan model dalam mengenali pola pada data pelatihan dan uji awal. Namun, evaluasi ini

belum cukup merepresentasikan kemampuan generalisasi model. Evaluasi lanjutan dengan *K-Fold Cross Validation* menghasilkan rata-rata akurasi per *fold* yang lebih realistis dan menggambarkan stabilitas model terhadap variasi data. Hasil menunjukkan bahwa GBDT dan KNN memiliki performa yang lebih stabil dan tinggi dibandingkan SVM. Rata-rata akurasi GBDT mencapai 99,9% (*dataset 1*) dan 99,8% (*dataset 2*), sedangkan SVM hanya mencapai 70,6% pada *dataset 2* yang lebih kompleks. Selain itu, evaluasi dilakukan pada data validasi baru tanpa label target, untuk menguji model yang telah disimpan. *Confusion matrix* kembali digunakan untuk menilai hasil prediksi. Hasil menunjukkan bahwa KNN dan GBDT tetap mempertahankan nilai *precision*, *recall*, dan *f1-score* yang sempurna (1,00), sedangkan SVM mengalami penurunan performa signifikan di beberapa kelas, terutama pada dataset kompleks. Ini mengindikasikan bahwa KNN dan GBDT mampu menggeneralisasi lebih baik terhadap data nyata.

3. Analisis Kualitas Fitur dan Kompleksitas Data

Hasil analisis menunjukkan bahwa kualitas fitur dan kompleksitas data sangat memengaruhi performa model. Model GBDT dan KNN terbukti lebih mampu mengenali pola dari data sensor dan menghasilkan klasifikasi yang akurat, bahkan pada dataset dengan delapan kelas gabungan. Sebaliknya, model SVM mengalami kesulitan dalam membedakan beberapa kelas tertentu pada saat validasi, yang teridentifikasi melalui nilai *precision* dan *recall* yang tidak seimbang dalam *confusion matrix*. Oleh karena itu, *confusion matrix* berperan penting dalam mengidentifikasi kekuatan dan kelemahan masing-masing model terhadap tiap kelas target.

5.2 Saran

Berdasarkan hasil penelitian dan kesimpulan yang telah diperoleh, berikut adalah beberapa saran yang dapat dijadikan bahan pertimbangan untuk penelitian selanjutnya:

1. Penambahan variasi jenis jalan yang lebih beragam sangat disarankan. Saat ini model hanya dilatih untuk membedakan dua jenis jalan, yang masih belum mencerminkan kondisi jalan di dunia nyata secara

menyeluruh. Penambahan kelas seperti ini diharapkan dapat meningkatkan kemampuan model dalam menangani klasifikasi yang lebih kompleks dan realistis.

2. Perbanyak data pelatihan baik dari segi jumlah maupun kondisi pengambilan data dapat memperkuat generalisasi model. Disarankan untuk mengumpulkan data dari berbagai kondisi lingkungan seperti cuaca berbeda, jenis permukaan jalan yang bervariasi, serta pengaruh beban dan kecepatan kendaraan yang beragam.
3. Eksplorasi metode *machine learning* lainnya atau bisa dengan menggunakan *deep learning* dapat dijadikan alternatif untuk meningkatkan akurasi model dalam mengenali pola data sensor kendaraan.
4. Disarankan untuk melakukan implementasi model secara nyata, misalnya pada kendaraan. Implementasi ini bertujuan untuk menguji sejauh mana model dapat berfungsi dengan baik dalam kondisi *real-time* dan lingkungan dinamis, serta mengevaluasi kestabilan dan akurasi prediksi di luar lingkungan laboratorium.