

BAB V PENUTUP

5.1 Kesimpulan

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan dalam analisis sentimen masyarakat terhadap layanan KRL Jogja–Solo menggunakan algoritma *Multinomial Naïve Bayes*, maka diperoleh beberapa kesimpulan sebagai berikut:

1. Berdasarkan hasil analisis distribusi sentimen masyarakat terhadap layanan KRL Jogja–Solo dari media sosial *Twitter* dan *TikTok*, ditemukan bahwa sentimen netral mendominasi ulasan pengguna, menunjukkan kecenderungan masyarakat untuk tidak secara eksplisit mengungkapkan pendapat positif maupun negatif. Ketimpangan distribusi ini berdampak pada proses pemodelan, sehingga diperlukan penerapan teknik SMOTE pada data latih guna menyeimbangkan jumlah data antar kelas sentimen. Temuan ini mengindikasikan bahwa persepsi masyarakat terhadap layanan KRL Jogja–Solo sebagian besar bersifat netral, dengan opini positif dan negatif yang lebih sedikit jumlahnya.
2. Performa algoritma *Multinomial Naïve Bayes* dalam mengklasifikasikan sentimen terhadap layanan KRL Jogja–Solo menunjukkan hasil yang cukup baik. Model yang dilatih dengan fitur hasil ekstraksi TF-IDF serta data latih yang telah diseimbangkan dengan SMOTE mampu mencapai akurasi sebesar 76,21%. Dari hasil evaluasi, model memiliki kemampuan terbaik dalam mengklasifikasikan sentimen netral dengan *f1-score* sebesar 0,85, sedangkan untuk sentimen positif dan negatif masing-masing memperoleh *f1-score* sebesar 0,49 dan 0,45. Nilai *macro average f1-score* sebesar 0,60 menandakan bahwa kinerja model antar kelas masih belum merata. Namun demikian, berdasarkan *confusion matrix*, model menunjukkan sensitivitas yang cukup baik dalam mendeteksi sentimen negatif tanpa kesalahan klasifikasi ekstrem, sehingga dapat disimpulkan bahwa algoritma *Naïve Bayes* masih relevan untuk digunakan dalam tugas

klasifikasi sentimen dengan pendekatan yang sederhana dan efisien.

5.2 Saran

Untuk penelitian selanjutnya, disarankan agar proses pelabelan sentimen tidak hanya mengandalkan pendekatan berbasis kamus, tetapi juga mempertimbangkan metode *supervised learning* atau pendekatan *hybrid* agar hasil *labeling* menjadi lebih akurat dan representatif terhadap konteks data. Selain itu, eksplorasi model algoritma lain seperti *Support Vector Machine* (SVM), *Random Forest*, atau *K-Nearest Neighbor* (KNN) dapat dijadikan pembanding terhadap performa model *Naïve Bayes*. Beberapa studi menunjukkan bahwa algoritma SVM memiliki kemampuan klasifikasi yang lebih kuat, terutama pada data teks yang kompleks dan tidak seimbang, sehingga berpotensi memberikan akurasi dan F1-score yang lebih tinggi.

Selanjutnya, pemanfaatan representasi fitur berbasis *word embedding* seperti *Word2Vec*, *GloVe*, atau bahkan *contextual embeddings* seperti *BERT* dapat meningkatkan kualitas input model dengan menangkap makna semantik kata-kata secara lebih mendalam. Di sisi evaluasi, penambahan metrik seperti ROC-AUC akan sangat berguna untuk menilai kemampuan model dalam membedakan antar kelas, terutama jika data memiliki ketidakseimbangan. Terakhir, penting untuk melakukan analisis kesalahan (*error analysis*) secara menyeluruh guna mengidentifikasi jenis kesalahan klasifikasi yang sering terjadi. Informasi ini dapat dimanfaatkan untuk menyempurnakan tahap *preprocessing*, strategi penyeimbangan data, maupun *tuning* parameter model, sehingga hasil klasifikasi di masa mendatang dapat lebih optimal dan sesuai dengan tujuan analisis sentimen.