

BAB V

PENUTUP

5.1. Kesimpulan

Berdasarkan hasil pembahasan yang telah dilakukan. Diperoleh beberapa kesimpulan diantaranya:

1. Pada semua rasio data 60:20:20, 70:15:15, 80:10:10, model *DistilBERT* pada percobaan 1 menunjukkan perbaikan pada *loss* dan akurasi baik pada data pelatihan maupun data validasi seiring dengan bertambahnya *epoch*.
2. Berdasarkan hasil evaluasi menggunakan *confusion matrix*, maka dapat disimpulkan bahwa hasil akurasi terbesar dicapai oleh skenario 3 (rasio 80:10:10) pada percobaan kedua. Akurasi yang diberikan pada model terbaik adalah 88%, dan dengan penggunaan *hyperparameter* (*batch size* 16, *learning rate* $2e-5$, dan *epoch* 10) dimana akurasi ini sudah sangat baik untuk suatu model *Natural Language Processing* (NLP).
3. Dari hasil percobaan analisis sentimen pada ulasan Aplikasi Digital Korlantas Polri dengan rasio 60:20:20, 70:15:15, dan 80:10:10, ditemukan bahwa rasio 80:10:10 memberikan hasil terbaik secara konsisten. Pada percobaan pertama, rasio ini menunjukkan akurasi tertinggi untuk label negatif 0.93 dan positif 0.86. Percobaan kedua juga menunjukkan performa tinggi dengan akurasi 0.91 untuk label negatif dan 0.88 untuk label positif. Meskipun rasio 70:15:15 memberikan akurasi terbaik untuk label netral 0.79 pada kedua percobaan, namun rasio 80:10:10 tetap lebih optimal secara keseluruhan dalam mendeteksi sentimen negatif dan positif.
4. Peningkatan rasio data latih memberikan dampak positif pada kinerja model, menunjukkan bahwa model dapat belajar lebih baik dengan jika menggunakan data latih yang lebih besar

5.2. Saran

1. Pada penelitian selanjutnya dapat dilakukannya peningkatan pada penanganan kelas netral dengan menambah atau memperbaiki fitur yang digunakan serta menggunakan metode penanganan kelas yang tidak

seimbang (seperti *oversampling* atau *undersampling*) dapat membantu meningkatkan kinerja model .

2. Pada hasil performa model menunjukkan bahwa peningkatan rasio data latih memberikan dampak positif pada kinerja model. Oleh karena itu, pada penelitian selanjutnya dapat mengumpulkan lebih banyak data latih, terutama untuk kelas Netral, bisa membantu model belajar lebih baik dan meningkatkan akurasi klasifikasi.
3. Pada penelitian selanjutnya dapat mencoba bereksperimen dengan arsitektur model yang berbeda, seperti penggunaan model deep learning yang lebih kompleks, dapat memberikan peningkatan kinerja yang signifikan, terutama dalam menangani kelas Netral yang lebih sulit.
4. Pada penelitian selanjutnya dapat mencoba menyesuaikan *hyperparameter* seperti *learning rate*, *batch size*, atau jumlah *epoch* untuk menemukan konfigurasi yang optimal dan mencegah *overfitting*.