

BAB V PENUTUP

5.1 Kesimpulan

Dengan mengacu pada keseluruhan proses serta hasil yang diperoleh dalam penelitian ini, maka kesimpulan yang dapat di ambil adalah sebagai berikut:

1. Penerapan model IndoBERT dalam analisis data kesehatan mental pada platform X (Twitter) menunjukkan bahwa pendekatan *fine-tuning* berbasis *transformer* mampu menghasilkan performa klasifikasi yang optimal. Tahapan penelitian yang dilakukan secara sistematis, mulai dari penyaringan data, pelabelan manual, *preprocessing* teks, hingga proses tokenisasi dan pembagian *dataset*, berkontribusi terhadap kualitas model yang dihasilkan. Hasil evaluasi akhir pada data uji memperlihatkan bahwa model terbaik memperoleh tingkat akurasi sebesar 88,10% dengan nilai *F1-score (macro)* sebesar 87,22%, yang mencerminkan keseimbangan kinerja antar kelas. Selain itu, distribusi nilai *precision* dan *recall* yang relatif proporsional menunjukkan kemampuan model dalam meminimalkan kesalahan, serta membuktikan bahwa IndoBERT memiliki kapasitas generalisasi yang baik dalam mengidentifikasi kecenderungan opini pada isu kesehatan mental di media sosial. Dengan demikian, model yang dikembangkan dinilai efektif untuk merepresentasikan pola ekspresi teks pengguna dalam konteks penelitian ini.
2. Eksperimen variasi *hyperparameter* menunjukkan bahwa pemilihan *learning rate* dan jenis *optimizer* memberikan pengaruh signifikan terhadap stabilitas pelatihan dan performa akhir model. Konfigurasi dengan *learning rate* 1e-05 dan *optimizer* Adam menghasilkan kombinasi metrik evaluasi yang paling konsisten dibandingkan variasi parameter lainnya, ditinjau dari nilai *validation loss*, akurasi, *precision*, *recall*, dan *F1-score*. *Learning rate* yang lebih kecil terbukti mampu menjaga kestabilan konvergensi selama proses pelatihan, sehingga model tidak mengalami fluktuasi performa yang berlebihan. Selain itu, penggunaan *optimizer* Adam memberikan keseimbangan yang lebih baik antara kecepatan pembaruan parameter dan

kemampuan generalisasi model. Ditinjau dari aspek efisiensi, pencatatan *time execution* menunjukkan bahwa penggunaan optimizer Adam lebih efisien secara komputasi dibandingkan AdamW. Meskipun efisiensi waktu maksimal dicapai pada konfigurasi *learning rate* $5e-05$ dengan Adam 77.6105 detik, konfigurasi *learning rate* $1e-05$ dengan Adam tetap menjadi pilihan paling optimal karena keunggulan akurasi yang dicapai sepadan dengan waktu eksekusi yang dibutuhkan 109.284 detik. Perbandingan antar konfigurasi juga menunjukkan adanya peningkatan akurasi. Oleh karena itu, optimasi *hyperparameter* serta analisis terhadap keseimbangan (*trade-off*) antara efisiensi waktu dan performa menjadi faktor krusial dalam memperoleh model klasifikasi teks yang akurat dan stabil, dan efisiensi sesuai dengan tujuan penelitian.

5.2 Saran

Berdasarkan hasil dan kesimpulan dari penelitian ini, peneliti memberikan beberapa saran yang diharapkan dapat diterapkan pada penelitian selanjutnya, yaitu:

1. Penelitian selanjutnya disarankan untuk memperluas *dataset* dengan jumlah dan rentang waktu yang lebih besar agar representasi data lebih komprehensif. Penambahan sumber data dari platform media sosial lain dapat meningkatkan validitas eksternal. Permasalahan *class imbalance* dapat diatasi melalui teknik *data augmentation* atau *resampling* guna mengoptimalkan performa pada kelas minoritas. Penerapan klasifikasi multikelas dengan menyertakan kembali kelas netral dapat memberikan metrik tambahan seperti AUC. Selain itu, analisis *confusion matrix* yang lebih mendalam dapat memperkaya interpretasi hasil, sehingga model memiliki generalisasi yang kuat terhadap dinamika opini di media sosial.
2. Secara metodologis, penelitian lanjutan dapat mengeksplorasi arsitektur *transformer* lain, termasuk model *multilingual* atau *large language model* yang disesuaikan untuk bahasa Indonesia. Metode optimasi *hyperparameter* seperti *Grid Search* atau *Random Search* dapat meningkatkan efisiensi dan presisi model. Eksperimen terhadap variasi *epoch*, *batch size*, dan teknik regularisasi juga perlu dianalisis untuk meminimalkan *overfitting*.

Pengujian pada skenario data *real-time* penting untuk menilai kesiapan implementasi praktis. Selain itu, integrasi analisis teks dengan *topic modeling* berpotensi memberikan wawasan yang lebih kontekstual, sehingga memperkaya kontribusi ilmiah dalam bidang analisis teks berbasis *deep learning*.

