

BAB V

KESIMPULAN DAN SARAN

5.1. Kesimpulan

Hasil penelitian ini mampu menjawab identifikasi masalah dengan kesimpulan sebagai berikut:

1. Performa naïve bayes berdasarkan confusion matrix memiliki performa nilai akurasi 56.9%, presisi 63.1%, recall 56.9%, dan f-1 score 51.5%. Sedangkan SVM memiliki nilai akurasi 51.7%, presisi 47.5%, recall 51.7%, dan f-1 score 49.4%. Berdasarkan waktu kerja model dalam mengelola data, naïve bayes memiliki waktu pengerjaan data latih 0.0091 detik, sedangkan SVM 0.0851 detik. Pada pengelolaan data uji, model naïve bayes memerlukan waktu 0.0017 detik dan SVM memerlukan waktu 0.0001 detik. Hasil AUC score pada naïve bayes adalah 0.6695 sedangkan SVM 0.6719.
2. Naïve bayes memiliki performa yang lebih unggul berdasarkan hasil confusion matrix dibandingkan SVM, dengan nilai akurasi, presisi, dan recall yang lebih tinggi, begitupun pada waktu pengelolaan data dimana naïve bayes lebih cepat. Meskipun hasil AUC score naïve bayes lebih kecil dibandingkan SVM, namun hasil distribusi yang dihasilkan tetap selaras dengan distribusi yang dihasilkan oleh model naïve bayes.
3. Berdasarkan hasil distribusi sentimen yang dihasilkan oleh pelabelan dengan metode lexicon maupun model klasifikasi naïve bayes dan SVM, ketiganya memiliki distribusi yang selaras dengan mayoritas kelas sentimen positif. Hal ini dapat diindikasikan bahwa meskipun terdapat perubahan kebijakan pada program Kampus Mengajar 7, mayoritas publik tetap merespons positif program tersebut.

5.2. Saran

Dalam melakukan penelitian selanjutnya dengan tujuan yang serupa, berdasarkan hasil penelitian ini terdapat beberapa saran yang dapat diterapkan yaitu:

1. Menggunakan data yang berasal dari lebih dari satu sumber, seperti menggunakan data yang berasal dari media sosial X (twitter) dan youtube. Tujuannya adalah untuk mendapatkan dataset dengan jumlah yang lebih banyak dan opini yang lebih beragam.
2. Menerapkan teknik *autolabeling* selain kamus lexicon, seperti misalnya Vader yang lebih tepat dalam menangkap konteks sentimen dalam setiap data. Teknik labeling yang berbeda juga dapat mempengaruhi performa dari model klasifikasi.
3. Membagi data dengan presentase selain 70% untuk data latih dan 30% untuk data uji. Pembagian data yang beragam dapat mempengaruhi model klasifikasi dalam menghasilkan nilai evaluasi.
4. Melakukan optimasi pada model klasifikasi dengan menyesuaikan parameter model yang disesuaikan dengan performa model yang didapatkan sebelum optimasi. Optimasi model dapat menjadi informasi baru performa maksimal yang dapat dicapai oleh model klasifikasi.
5. Melakukan analisis hasil evaluasi yang lebih mendalam, seperti mempertimbangkan *imbalance class*, *noise* dalam data, *generalization ability*, *interpretability*, efisiensi komputasi, serta teknik *feature engineering* dan *text representation* yang digunakan.