

BAB V PENUTUP

5.1 Kesimpulan

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan, maka kesimpulan penelitian ini dapat dijabarkan sesuai dengan rumusan masalah sebagai berikut:

1. Dalam perbandingan langsung untuk analisis sentimen opini publik mengenai naturalisasi pemain sepak bola, model *Multinomial Naïve Bayes* (MNB) menunjukkan kinerja yang secara signifikan lebih unggul dan stabil dibandingkan model *AdaBoost*. Model MNB berhasil mencapai tingkat akurasi klasifikasi hingga 82%. Sebaliknya, penerapan model *AdaBoost* dengan base estimator MNB justru menghasilkan performa yang lebih rendah, dengan akurasi validasi silang hanya sebesar 65.29%.
2. Penerapan boosting dengan *AdaBoost* tidak efektif dalam meningkatkan performa klasifikasi pada dataset ini. Hasil penelitian menunjukkan bahwa untuk data teks dari Twitter yang memiliki karakteristik noise tinggi dan tidak terstruktur, model yang lebih kompleks seperti *AdaBoost* tidak selalu memberikan hasil yang lebih baik. Model MNB yang lebih sederhana terbukti lebih robust.
3. Kedua model, baik MNB maupun *AdaBoost*, mengalami kesulitan yang signifikan dalam mengklasifikasikan sentimen netral. Kegagalan ini disebabkan oleh ketidakseimbangan jumlah data pada kelas netral yang jauh lebih sedikit dibandingkan dengan kelas positif dan negatif, sehingga model tidak memiliki cukup contoh untuk dipelajari.

5.2 Saran

Berdasarkan kesimpulan yang telah diuraikan, terdapat beberapa saran yang dapat menjadi pertimbangan untuk penelitian selanjutnya agar dapat menghasilkan analisis yang lebih baik.

1. Penanganan Kelas Tidak Seimbang: Mengingat model gagal total dalam mengenali sentimen netral, penelitian selanjutnya sangat disarankan untuk menerapkan teknik penyeimbangan data. Metode seperti *Synthetic Minority Over-sampling Technique* (SMOTE) dapat digunakan untuk memperbanyak jumlah data pada kelas minoritas (netral) sehingga model dapat mempelajari polanya dengan lebih representatif.
2. Eksplorasi Algoritma *Ensemble* Lain: Meskipun *AdaBoost* tidak menunjukkan hasil yang memuaskan, bukan berarti semua metode *ensemble* akan gagal. Disarankan untuk mencoba algoritma *ensemble* lain seperti *Random Forest* atau *Gradient Boosting*, yang mungkin memiliki ketahanan lebih baik terhadap *noise* dan ketidakseimbangan data dibandingkan *AdaBoost*.
3. Prioritas pada Model *Baseline* yang Kuat: Temuan bahwa model MNB yang lebih sederhana mampu mengungguli *AdaBoost* yang lebih kompleks memberikan pelajaran penting. Untuk penelitian di masa depan dengan dataset yang memiliki karakteristik serupa (misalnya, teks media sosial), disarankan untuk memvalidasi secara cermat kinerja model *baseline* yang sederhana namun kuat sebelum beralih ke metode yang lebih kompleks.