

BAB V

PENUTUP

5.1 Kesimpulan

Dari hasil penelitian analisis sentimen pada topik gaji DPR, diperoleh beberapa poin kesimpulan berikut:

1. Distribusi Sentimen Publik

Berdasarkan hasil klasifikasi dan visualisasi pada isu Gaji DPR (dengan kata kunci “Gaji DPR” dan “Tunjangan DPR”), sentimen publik didominasi oleh sentimen negatif sebesar 89,47% (1.155 data), diikuti sentimen positif sebesar 6,20% (80 data), dan sentimen netral sebesar 4,34% (56 data). Dari tampilan Word Cloud dapat diketahui bahwa kosakata yang paling sering muncul pada kategori sentimen positif adalah “gaji”, “tunjang”, dan “DPR”, pada sentimen negatif “gaji”, “tunjang”, “DPR”, dan “kerja”, sedangkan pada sentimen netral didominasi oleh kata “DPR”, “tunjang”, dan “serba seribu”. Temuan ini mengindikasikan bahwa diskursus publik tetap terfokus pada isu utama gaji dan tunjangan DPR, meskipun polaritas sentimen yang muncul berbeda pada tiap kategori.

2. Perbandingan Kinerja Model *Klasifikasi*

Berdasarkan evaluasi kinerja model pada data uji, metode *Naïve Bayes* tanpa *SMOTE* menghasilkan akurasi sebesar 90% (0,90), namun performa antar kelas tidak seimbang. Model ini menunjukkan kinerja sangat baik pada kelas negatif dengan *precision* 89%, *recall* 100%, dan *F1-score* 94%, tetapi lemah dalam mendeteksi kelas positif (*precision* 0%, *recall* 0%, *F1-score* 0%) serta kelas netral dengan *recall* yang sangat rendah (17%). Nilai *macro average F1-score* yang hanya mencapai 41% mengindikasikan adanya bias terhadap kelas mayoritas.

Setelah diterapkan *SMOTE*, performa *Naïve Bayes* mengalami penurunan akurasi menjadi 77% (0,77), namun distribusi prediksi antar kelas menjadi

lebih seimbang. Pada kelas positif, *Naïve Bayes* dengan *SMOTE* memperoleh *precision* 19%, *recall* 50%, dan *F1-score* 28%, menunjukkan peningkatan kemampuan dalam mendeteksi sentimen positif dibandingkan tanpa *SMOTE*. Kategori negatif masih memperlihatkan hasil yang cukup baik dengan nilai *precision* sebesar 92%, *recall* 83%, dan *F1-score* 87%. Sebaliknya, kelas netral menunjukkan kinerja yang rendah dengan *precision* 19%, *recall* 17%, serta *F1-score* 18%. Nilai *macro average F1-score* meningkat menjadi 44%, yang menandakan perbaikan keseimbangan klasifikasi meskipun akurasi keseluruhan menurun.

Di sisi lain, metode SVM memberikan kinerja paling unggul secara umum dengan nilai akurasi mencapai 90% (0,90). Model SVM sangat unggul dalam mengklasifikasikan sentimen negatif dengan *recall* mencapai 100%, *precision* 90–91%, dan *F1-score* 95%. Namun, performa pada kelas minoritas masih terbatas, di mana sentimen positif memiliki *precision* tinggi (100%) tetapi *recall* rendah (17%) sehingga *F1-score* hanya 29%, sedangkan kelas netral mencatat *precision* 67%, *recall* 12%, dan *F1-score* 18%. Hasil tersebut menunjukkan bahwa SVM lebih selektif dalam menentukan kelas positif dan netral, tetapi memiliki kemampuan tinggi dalam mendeteksi sentimen negatif pada data.

5.2 Saran

Berdasarkan hasil yang diperoleh dalam penelitian ini, beberapa rekomendasi pengembangan dapat diajukan sebagai berikut:

1. Selain metode *Naive bayes* dan metode *Support Vector Machine*, penelitian selanjutnya diharapkan dapat menjelajahi model klasifikasi lainnya yang mungkin lebih sesuai dengan data yang digunakan. Misalnya, bisa mencoba *Decision Trees*, *Random Forest*, *K-Nearest Neighbor*, atau model klasifikasi lainnya yang tersedia.
2. Dalam penelitian ini, pembagian data latih dan data uji menggunakan rasio 80:20. Untuk penelitian selanjutnya, dapat dicoba variasi skema pembagian lain, seperti 90:10, 70:30, 60:40, maupun 50:50 guna melihat

pengaruhnya terhadap kinerja model.

3. Disarankan melakukan pengembangan pada tahap praproses dan pemodelan, misalnya penyesuaian parameter TF-IDF, seleksi fitur, atau penanganan ketidakseimbangan kelas. Upaya ini terutama penting untuk meningkatkan kinerja pada kelas yang masih menantang untuk diprediksi, khususnya kelas netral (terutama pada metode SVM) agar performa antar kelas menjadi lebih merata.