

BAB V

PENUTUP

5.1 Kesimpulan

Penelitian ini berfokus pada penggunaan teknik syntetic minority oversampling (SMOTE) untuk mengatasi ketidakseimbangan distribusi kelas dalam dataset. Berdasarkan penelitian yang dilakukan, dapat diambil kesimpulan sebagai berikut :

1. **Peningkatan Akurasi algoritma Sebelum dan Setelah SMOTE**
 - Metode Decision Tree menunjukkan peningkatan akurasi yang signifikan setelah diterapkan teknik SMOTE, baik pada skenario cross-validation fold 10 (dari 71.2% menjadi 73.8%) maupun pada skenario 80% data training dan 20% data testing yang diulang sebanyak 50 kali (dari 71.2% menjadi 73.8%).
 - Pada metode KNN, penerapan SMOTE memberikan peningkatan yang lebih kecil dalam akurasi, baik pada skenario cross-validation fold 10 (dari 70.2% menjadi 70.4%) maupun pada skenario 80% data training dan 20% data testing yang diulang sebanyak 50 kali (dari 69.82% menjadi 69.87%).
2. **Performa Presisi Kelas Positif**
 - Presisi untuk kelas positif pada Decision Tree menunjukkan penurunan setelah penerapan SMOTE, baik pada skenario cross-validation fold 10 (dari 80.7% menjadi 70.9%) maupun pada skenario 80% data training dan 20% data testing yang diulang sebanyak 50 kali (dari 79.7% menjadi 71.3%).
 - Pada KNN, presisi untuk kelas positif juga mengalami penurunan setelah penerapan SMOTE, baik pada skenario cross-validation fold 10 (dari 78.1% menjadi 64.6%) maupun pada skenario 80% data training dan 20% data testing yang diulang sebanyak 50 kali (dari 77.8% menjadi 65.6%).
3. **Peningkatan Presisi, Recall dan F1-Score untuk Kelas Netral dan Negatif**

- Pada Decision Tree, presisi kelas netral meningkat dari 32.9% menjadi 66.3% (cross-validation fold 10) dan dari 32.5% menjadi 67.2% (80% data training dan 20% data testing). Presisi kelas negatif juga meningkat dari 58.3% menjadi 83.0% (cross-validation fold 10) dan dari 60.9% menjadi 82.8% (80% data training dan 20% data testing).
- Pada KNN, presisi kelas netral meningkat dari 39.6% menjadi 70.3% (cross-validation fold 10) dan dari 39.5% menjadi 70.0% (80% data training dan 20% data testing). Presisi kelas negatif meningkat dari 43.9% menjadi 76.5% (cross-validation fold 10) dan dari 41.2% menjadi 74.8% (80% data training dan 20% data testing).

5.2 Saran

1. Evaluasi Teknik Penyeimbangan Data Lainnya
 - Penelitian selanjutnya dapat mengeksplorasi teknik penyeimbangan data lainnya, seperti ADASYN atau Borderline-SMOTE, untuk melihat apakah ada peningkatan performa yang lebih signifikan.
2. Penggunaan Algoritma Klasifikasi Lain
 - Selain KNN dan Decision Tree, penelitian masa depan dapat mencoba algoritma lain seperti Random Forest, SVM, atau Neural Networks untuk melihat bagaimana teknik SMOTE mempengaruhi performa mereka.
3. Analisis Lebih Lanjut terhadap Metode Ensemble
 - Menerapkan metode ensemble learning, seperti bagging dan boosting, dapat memberikan wawasan tambahan tentang peningkatan performa klasifikasi pada dataset yang tidak seimbang.