

BAB V PENUTUP

5.1 Kesimpulan

Dalam penelitian ini, kinerja model klasifikasi persetujuan kredit menunjukkan peningkatan yang signifikan setelah diterapkan penyeimbangan data menggunakan *SMOTE* dan *hyperparameter tuning*. Model *baseline* tanpa *SMOTE* masih memiliki keterbatasan dalam mengenali kelas minoritas, meskipun akurasi *Logistic Regression* dan *LightGBM* masing-masing telah mencapai 94,57% dan 94,33%. Penerapan *feature selection* tidak memberikan peningkatan performa yang berarti dan lebih berperan dalam menyederhanakan model. Peningkatan nyata terlihat pada tahap *SMOTE* dan *tuning*, dimana *Logistic Regression* mencapai akurasi 95,25% dan *LightGBM* meningkat hingga 97,04%. Performa terbaik diperoleh melalui *Soft Voting Ensemble (SMOTE + Tuning)* yang menggabungkan kedua model dan menghasilkan akurasi tertinggi sebesar 97,08% dengan *recall* 98,26% dan *F1-score* 97,11%, sehingga kombinasi penyeimbangan data, optimasi parameter, dan strategi ensemble terbukti paling efektif dalam meningkatkan kinerja klasifikasi persetujuan pinjaman.

Berdasarkan hasil yang diperoleh, dapat disimpulkan bahwa metode *Soft Voting Ensemble* efektif dalam meningkatkan stabilitas dan konsistensi prediksi dengan menggabungkan probabilitas keluaran dari *Logistic Regression* dan *LightGBM*. Pendekatan ini memanfaatkan keunggulan model linier dalam menjelaskan hubungan antarvariabel serta kemampuan model non-linier dalam menangkap pola kompleks, sehingga menghasilkan klasifikasi yang lebih seimbang dan representatif pada kedua kelas.

Penelitian ini juga menunjukkan bahwa penerapan metode *Soft Voting Ensemble*, yang menggabungkan prediksi dari *Logistic Regression* dan *LightGBM*, mampu meningkatkan akurasi model sebesar 0,04% dibandingkan penggunaan *LightGBM* secara individual meskipun telah melalui proses penyeimbangan data dan *hyperparameter tuning*. Temuan ini menegaskan bahwa strategi ensemble tidak hanya meningkatkan stabilitas dan konsistensi prediksi, tetapi juga memberikan

peningkatan performa tambahan, sehingga model yang dihasilkan memiliki kemampuan generalisasi yang baik dan layak digunakan sebagai sistem pendukung keputusan dalam proses persetujuan pinjaman.

5.2 Saran

Berdasarkan hasil dan temuan yang diperoleh dalam penelitian ini, masih terdapat beberapa peluang pengembangan yang dapat dilakukan untuk meningkatkan kualitas dan penerapan model klasifikasi persetujuan kredit di masa mendatang, antara lain sebagai berikut:

1. Penelitian selanjutnya disarankan untuk menguji algoritma klasifikasi lain, seperti XGBoost, CatBoost atau Random Forest guna dibandingkan dengan *Logistic Regression* dan *LightGBM*. Perbandingan ini dapat dilakukan berdasarkan metrik kinerja, stabilitas model, serta efisiensi komputasi, sehingga dapat diperoleh model yang paling optimal untuk kasus persetujuan kredit.
2. Penelitian ini menggunakan metode seleksi fitur berbasis statistik melalui *SelectKBest*. Pada penelitian selanjutnya, dapat dipertimbangkan penggunaan metode seleksi fitur yang lebih kompleks dan interpretatif, seperti *Recursive Feature Elimination* (RFE), teknik berbasis regularisasi, serta pendekatan interpretabilitas model seperti SHAP dan *Permutation Importance*. Pendekatan ini diharapkan mampu memberikan pemahaman yang lebih mendalam mengenai kontribusi masing-masing fitur terhadap persetujuan kredit.