

BAB V

PENUTUP

5.1 Kesimpulan

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan, dapat ditarik beberapa kesimpulan sebagai berikut.

1. Berdasarkan hasil pengujian, algoritma *Logistic Regression*, *Random Forest*, *LightGBM*, dan *CatBoost* dapat diterapkan dengan baik pada klasifikasi kelayakan pinjaman nasabah menggunakan *Loan Approval Prediction Dataset*. Seluruh model berhasil mempelajari pola data, namun tingkat performanya berbeda.
2. Berdasarkan perbandingan metrik evaluasi, model terbaik pada penelitian ini adalah *CatBoost* hasil *fine tuning*, dengan nilai *accuracy* 0,9977, *precision* 0,9962, *recall* 1,0000, *F1-score* 0,9981, dan *ROC-AUC* 1,0000 pada data uji. Model terbaik berikutnya adalah *Random Forest*, lalu *LightGBM*, sedangkan *Logistic Regression* menjadi model dengan performa terendah namun tetap berguna sebagai *baseline* yang stabil dan mudah diinterpretasikan.
3. *Fine tuning* memberikan dampak yang berbeda pada setiap algoritma. Pengaruh *tuning* paling jelas terlihat pada *Logistic Regression* dan *CatBoost*, sedangkan pada *Random Forest* peningkatannya kecil tetapi positif, dan pada *LightGBM* *tuning* tidak memberikan perbaikan performa test yang signifikan. Temuan ini menunjukkan bahwa optimasi *hyperparameter* harus dinilai berdasarkan hasil generalisasi, bukan hanya berdasarkan banyaknya kombinasi parameter yang diuji.
4. Rancangan eksperimen pada penelitian ini berhasil menekan potensi *data leakage* dan *overfitting*. Hal tersebut dibuktikan oleh penghapusan kolom identitas, pemisahan data sebelum fitting *preprocessing*, penggunaan data uji sebagai *hold-out set*, serta gap performa train-valid-test yang kecil pada

seluruh model hasil *tuning*.

5. Tingginya akurasi pada penelitian ini terutama dipengaruhi oleh karakter *dataset* yang sangat mudah dipisahkan. Variabel *cibil_score* menjadi fitur paling dominan pada seluruh model, disusul oleh *loan_term*, *rasio_pinjaman_pendapatan*, dan *rasio_agunan_pinjaman*. Dengan demikian, faktor skor kredit dan *rasio* finansial merupakan penentu utama kelayakan pinjaman pada *dataset* penelitian ini.

Pengujian ablasi membuktikan bahwa *rekayasa* fitur dan *cibil_score* keduanya berperan penting namun dengan cara yang berbeda. Ketiga variabel tambahan (*total_assets_value*, *rasio_pinjaman_pendapatan*, *rasio_agunan_pinjaman*) terbukti secara empiris menurunkan FP CatBoost dari 10 menjadi 2 dan mengeliminasi FN dari 2 menjadi 0, sehingga penggunaannya dapat dibenarkan baik secara konseptual (prinsip 5C Kredit) maupun secara empiris. Di sisi lain, *cibil_score* terbukti sebagai fitur yang tidak dapat digantikan: penghapusannya menyebabkan akurasi turun dari 0,9859 menjadi 0,6241 dan FP melonjak dari 2 menjadi 320 peningkatan 160 kali lipat.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, beberapa saran yang dapat diberikan adalah sebagai berikut.

1. Penelitian selanjutnya dapat menggunakan *dataset* perbankan nyata atau *dataset* yang lebih heterogen agar pengujian model lebih mendekati kondisi operasional sebenarnya.
2. Validasi model pada penelitian lanjutan disarankan menggunakan external validation atau time-based split agar kemampuan generalisasi terhadap perubahan waktu dapat diuji dengan lebih kuat.
3. Analisis berikutnya dapat menambahkan pendekatan cost-sensitive learning atau calibration analysis, karena pada domain kredit biaya kesalahan *false positive* dan *false negative* tidak memiliki dampak yang sama.

4. Penelitian lanjutan juga dapat memperdalam aspek interpretabilitas menggunakan teknik seperti SHAP, partial dependence, atau analisis aturan keputusan agar hasil model lebih mudah dipahami oleh pihak pengambil keputusan.
5. Perbandingan model dapat diperluas dengan menambahkan algoritma lain seperti XGBoost, stacking *ensemble*, atau pendekatan *deep learning* tabular, namun tetap harus mempertahankan kontrol yang ketat terhadap *data leakage* dan *overfitting*.

