

## **BAB V**

### **PENUTUP**

#### **5.1 Kesimpulan**

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa kombinasi metode SMOTE-ENN dan algoritma XGBoost dengan optimasi bayesian berhasil diterapkan secara efektif untuk mengatasi masalah *imbalance class* pada deteksi penyakit gagal jantung sebagai berikut:

1. Penerapan teknik SMOTE-ENN terbukti mampu meningkatkan kinerja model XGBoost dalam menangani masalah ketidakseimbangan kelas. Hal ini ditunjukkan dari hasil evaluasi model *cross validation* tanpa SMOTE yang meskipun memiliki akurasi tinggi (90,82%), tetapi sangat bias terhadap kelas mayoritas dengan nilai Recall pada kelas positif hanya sebesar 09,17%. Setelah dilakukan penyeimbangan menggunakan SMOTE-ENN *Default*, nilai Recall meningkat signifikan menjadi 94,08%, diikuti dengan *F1-score* sebesar 92,91% yang menunjukkan keseimbangan performa model pada kedua kelas. Dengan demikian, SMOTE-ENN berperan penting dalam memperbaiki sensitivitas model terhadap kelas minoritas tanpa terlalu mengorbankan performa pada kelas mayoritas.
2. Dari perbandingan ketiga model, yaitu XGBoost tanpa SMOTE, XGBoost dengan SMOTE-ENN *Default*, dan XGBoost dengan SMOTE-ENN *Fine-Tuned Bayesian Optimization*, diperoleh hasil bahwa model paling optimal adalah XGBoost dengan SMOTE-ENN *Fine-Tuned BO*. Diperkuat dengan evaluasi model *cross validation*, model ini menghasilkan nilai *Recall* tertinggi 94,71% sekaligus mampu mendeteksi jumlah kasus positif lebih banyak pada data testing, yang sangat penting dalam konteks penelitian ini karena fokus utama adalah mendeteksi kelas minoritas (penderita gagal jantung). Meskipun nilai *accuracy* sedikit lebih rendah dibanding SMOTE-ENN *Default*, *trade-off* tersebut dapat diterima karena keberhasilan mendeteksi kasus positif jauh lebih krusial dibanding mempertahankan akurasi global. Dengan demikian, kombinasi XGBoost, SMOTE-ENN, dan optimasi Bayesian dapat dikatakan

sebagai solusi terbaik dalam menangani ketidakseimbangan data pada penelitian ini.

## 5.2 Saran

Berdasarkan temuan penelitian ini, saran yang dapat diberikan untuk pengembangan dan implementasi model di masa mendatang adalah:

1. Penyesuaian *Threshold* Klasifikasi

Melakukan optimasi nilai threshold untuk menyeimbangkan antara sensitivitas (*Recall*) dan spesifisitas (*Precision*), terutama untuk mengurangi risiko false negative yang dapat berakibat fatal pada pasien gagal jantung.

2. Penambahan Fitur Klinis

Memperkaya dataset dengan fitur klinis tambahan seperti hasil pemeriksaan laboratorium, data tekanan darah dinamis, atau riwayat rawat inap, agar model dapat menangkap pola yang lebih kompleks.

3. Uji Validasi pada Dataset Eksternal

Menguji model pada dataset gagal jantung dari sumber dan populasi berbeda untuk mengukur generalisasi model di luar data pelatihan.

4. Pengembangan Aplikasi Pendukung Keputusan Klinis

Mengintegrasikan model ini ke dalam sistem *Clinical Decision Support System* (CDSS) sehingga dapat digunakan langsung oleh tenaga medis untuk membantu pengambilan keputusan yang cepat dan berbasis data.

5. Eksperimen dengan Algoritma Lain

Mencoba algoritma alternatif seperti LightGBM, CatBoost, atau model deep learning berbasis tabular data untuk dibandingkan performanya dengan XGBoost