

## **BAB V**

### **PENUTUP**

#### **5.1 Kesimpulan**

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan dapat ditarik kesimpulan sebagai berikut:

1. Teknik SMOTE-ENN terbukti sangat efektif dalam menangani masalah ketidakseimbangan kelas pada dataset deteksi diabetes BRFS 2015. Setelah penerapan SMOTE-ENN, distribusi kelas menjadi lebih seimbang, yang berdampak signifikan terhadap peningkatan kemampuan model dalam mendeteksi kasus diabetes, terutama untuk kelas minoritas (diabetes).
2. Dalam perbandingan kinerja keempat algoritma machine learning, Random Forest menunjukkan kinerja terbaik dengan accuracy 96%, precision 96%, recall 97%, F1-score 96%, dan AUC-ROC 0.99, diikuti oleh K-Nearest Neighbors (KNN), XGBoost, dan Logistic Regression, yang memiliki kinerja terendah dengan accuracy 85%.
3. Random Forest merupakan algoritma terbaik untuk deteksi penyakit diabetes dengan kelas yang tidak seimbang, karena unggul dalam hampir semua metrik evaluasi. Keunggulan utamanya terletak pada kemampuannya untuk menangani data yang kompleks, mengurangi overfitting melalui ensemble learning, serta memberikan keseimbangan yang baik antara precision dan recall, sehingga sangat cocok untuk aplikasi deteksi dini diabetes.
4. Implementasi sistem deteksi diabetes berbasis Flask yang menggunakan model Random Forest berhasil dikembangkan. Aplikasi ini memungkinkan pengguna untuk memasukkan data kesehatan pribadi melalui formulir interaktif dan memberikan prediksi risiko diabetes secara real-time dengan hasil klasifikasi "Beresiko Diabetes" atau "Kondisi Sehat/Normal". Aplikasi ini memiliki antarmuka yang user-friendly dan dapat diakses secara online, sehingga memudahkan masyarakat untuk melakukan skrining mandiri terhadap risiko diabetes.

## 5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa saran yang dapat dipertimbangkan untuk pengembangan penelitian lebih lanjut:

1. Eksplorasi Teknik Penanganan Ketidakseimbangan Kelas Lainnya: Penelitian selanjutnya dapat mengeksplorasi teknik-teknik lain untuk menangani ketidakseimbangan kelas seperti ADASYN (Adaptive Synthetic Sampling), Tomek Links, atau kombinasi teknik lainnya untuk dibandingkan dengan SMOTE-ENN. Selain itu, dapat juga dilakukan optimasi parameter SMOTE-ENN untuk mendapatkan hasil yang lebih optimal.
2. Implementasi Algoritma Deep Learning: Untuk meningkatkan akurasi dan kemampuan deteksi, penelitian selanjutnya dapat mengimplementasikan algoritma deep learning seperti Neural Networks, Convolutional Neural Networks (CNN), atau Long Short-Term Memory (LSTM) yang memiliki kemampuan lebih baik dalam menangkap pola-pola kompleks dalam data kesehatan. Perbandingan performa antara algoritma machine learning tradisional dan deep learning akan memberikan wawasan yang lebih komprehensif.
3. Penambahan Fitur Eksplanasi Model: Mengimplementasikan teknik explainable AI seperti SHAP (SHapley Additive exPlanations) atau LIME (Local Interpretable Model-agnostic Explanations) untuk menjelaskan hasil prediksi model kepada pengguna. Fitur ini akan meningkatkan kepercayaan pengguna terhadap sistem dengan memberikan pemahaman tentang faktor-faktor apa saja yang mempengaruhi hasil prediksi.