

BAB V

SIMPULAN DAN SARAN

5.1 Simpulan

Berdasarkan penelitian yang telah dilakukan untuk membandingkan performa model *Random Forest*, *Support Vector Machine* (SVM), dan *Logistic Regression* dalam memprediksi risiko gagal jantung pada pasien ICU, dapat ditarik beberapa kesimpulan utama.

Hasil evaluasi menunjukkan bahwa setiap model memiliki karakteristik performa yang unik. Model *Random Forest* mencapai tingkat akurasi (89,47%) dan ROC-AUC (0.9401) tertinggi, yang mengindikasikan kemampuannya yang unggul dalam melakukan klasifikasi secara keseluruhan. Namun, kelemahan signifikan model ini terletak pada nilai *recall* yang sangat rendah (33,33%). Di sisi lain, model SVM menunjukkan nilai *recall* tertinggi (66,67%), yang menjadikannya model paling andal dalam mengidentifikasi pasien yang benar-benar berisiko gagal jantung, meskipun dengan akurasi yang sedikit lebih rendah (81,58%). Sementara itu, model *Logistic Regression* menunjukkan performa yang moderat di antara keduanya.

Dengan mempertimbangkan konteks penerapan pada lingkungan klinis seperti ICU, di mana kegagalan mendeteksi kondisi kritis (*false negative*) memiliki risiko yang jauh lebih besar dibandingkan kesalahan identifikasi (*false positive*), maka model SVM dinilai sebagai yang paling efektif dan tepat. Kemampuan superior SVM dalam hal *recall* memastikan bahwa sistem prediksi dapat meminimalkan risiko terlewatnya pasien yang memerlukan perhatian medis, menjadikannya pilihan yang paling bertanggung jawab dan dapat diandalkan untuk implementasi nyata.

Penelitian ini juga berhasil mengidentifikasi variabel-variabel klinis yang paling berpengaruh dalam prediksi risiko gagal jantung. Berdasarkan analisis *feature importance*, lima faktor prediktor utama secara berurutan adalah detak jantung (*heart rate*), saturasi oksigen (*O2 saturation*), usia pasien (*anchor age*),

tekanan darah diastolik (*diastolic bp*), dan laju pernapasan (*respiratory*). Hal ini menegaskan bahwa parameter-parameter vital dasar pasien merupakan kunci utama dalam penilaian dan prediksi risiko gagal jantung di unit perawatan intensif.

5.2 Saran

Berdasarkan hasil dan kesimpulan yang diperoleh dari penelitian ini, terdapat beberapa saran yang dapat menjadi pertimbangan untuk pengembangan penelitian selanjutnya. Untuk menyempurnakan dan memperluas cakupan penelitian ini, disarankan beberapa hal berikut:

1. **Eksplorasi Model yang Lebih Lanjut:** Penelitian selanjutnya dapat mengeksplorasi penggunaan algoritma yang lebih kompleks seperti *Gradient Boosting Machines* (contohnya XGBoost dan LightGBM) atau model *deep learning* (misalnya, jaringan syaraf tiruan). Model-model ini berpotensi menangkap pola data yang lebih rumit sehingga dapat meningkatkan akurasi dan, yang lebih penting, nilai *recall* prediksi. Selain itu, melakukan *hyperparameter tuning* secara ekstensif pada model SVM juga dapat dipertimbangkan untuk menemukan kombinasi parameter optimal.
2. **Pengayaan Variabel dan Data:** Disarankan untuk menambah jumlah dan variasi data pasien guna meningkatkan kemampuan generalisasi model. Selain itu, dapat dilakukan *feature engineering* dengan menyertakan variabel klinis lain yang relevan, seperti riwayat penyakit penyerta (*comorbidities*), hasil elektrokardiogram (EKG), atau data biomarker spesifik lainnya yang tidak tercakup dalam penelitian ini.
3. **Penerapan Analisis Deret Waktu (*Time-Series*):** Penelitian ini menggunakan nilai rata-rata dari parameter vital. Untuk mendapatkan wawasan yang lebih dinamis, penelitian mendatang dapat menerapkan analisis deret waktu yang mampu menangkap tren dan fluktuasi kondisi pasien dari waktu ke waktu, yang mungkin merupakan prediktor risiko yang lebih kuat daripada nilai rata-rata tunggal.