

BAB 5

SIMPULAN SARAN

5.1 Simpulan

Berdasarkan hasil penelitian dan evaluasi yang telah dilakukan terhadap model klasifikasi N-Stage Adenokarsinoma Paru, dapat ditarik beberapa simpulan sebagai berikut:

1. Penerapan teknik *Synthetic Minority Over-sampling Technique* (SMOTE) terbukti efektif dalam mengatasi ketidakseimbangan kelas pada dataset radiomik. Sebelum augmentasi dilakukan, model SVM dan TabNet menunjukkan kesulitan signifikan dalam mengidentifikasi kelas minoritas yang ditandai dengan kegagalan prediksi total pada sampel tersebut. Setelah pengaplikasian SMOTE, kemampuan model dalam mendeteksi kelas minoritas meningkat secara drastis. Hal ini divalidasi oleh kenaikan nilai *Recall* serta peningkatan stabilitas prediksi pada seluruh kategori kelas
2. Implementasi metode seleksi fitur memberikan dampak yang bervariasi terhadap setiap algoritma klasifikasi, namun secara keseluruhan terbukti mampu meningkatkan efisiensi dan performa model. Metode mRMR (Filter Method) merupakan pendekatan seleksi fitur yang paling efektif untuk algoritma XGBoost. Kombinasi tersebut menghasilkan performa tertinggi dalam penelitian ini dengan capaian akurasi sebesar 0,95 dan skor F1-Macro sebesar 0,96. Di sisi lain, L1-LASSO (Embedded Method) dan Boruta (Wrapper Method) menunjukkan sinergi yang optimal ketika dipadukan dengan algoritma SVM. Secara khusus, integrasi antara LASSO dan SMOTE mampu meningkatkan kinerja SVM secara signifikan hingga mencapai akurasi 0,89, yang dalam skenario tersebut melampaui performa algoritma XGBoost.
3. Berdasarkan hasil komparasi ketiga algoritma, XGBoost (Ensemble Learning) menunjukkan performa yang paling konsisten dan tangguh (robust) pada hampir seluruh skenario pengujian, baik dengan maupun tanpa penerapan SMOTE. Sementara itu, SVM menunjukkan potensi kompetitif dan mencapai hasil superior ketika didukung oleh penyeimbangan data serta seleksi fitur LASSO. Sebaliknya, TabNet (Deep Learning) secara konsisten

menghasilkan performa terendah dengan rata-rata akurasi di bawah 0,50. Hasil ini mengonfirmasi bahwa arsitektur deep learning yang kompleks cenderung sulit mencapai konvergensi optimal pada dataset dengan jumlah sampel terbatas

5.2 Saran

Berdasarkan keterbatasan yang ditemukan selama proses penelitian, terdapat beberapa saran yang dapat diajukan untuk pengembangan penelitian di masa mendatang:

1. Keterbatasan jumlah sampel yang mencakup 95 data dari 29 pasien diidentifikasi sebagai hambatan utama bagi konvergensi model TabNet, sehingga perluasan dataset melalui integrasi sumber data publik tambahan atau kolaborasi institusional diperlukan untuk memenuhi kebutuhan arsitektur deep learning yang lebih kompleks pada penelitian mendatang.
2. Eksplorasi terhadap arsitektur deep learning yang lebih ringan atau implementasi pendekatan transfer learning menggunakan model medis pralatih dapat dipertimbangkan sebagai alternatif untuk mengatasi kendala penggunaan TabNet pada data tabular radiomik yang memiliki skala sampel terbatas.
3. Pengembangan model dapat dioptimalkan melalui integrasi fitur radiomik citra CT Scan dengan data klinis tambahan seperti profil genomik atau hasil laboratorium darah dalam sebuah pendekatan multimodal guna menghasilkan akurasi diagnosis yang lebih komprehensif.
4. Uji validasi eksternal menggunakan dataset dari institusi atau populasi yang berbeda diperlukan untuk menjamin generalisasi dan keandalan model yang dilatih pada dataset TCGA-LUAD sebelum dipertimbangkan untuk implementasi dalam lingkungan klinis.