

BAB V

PENUTUP

5.1 KESIMPULAN

Penelitian ini dilakukan untuk membandingkan performa empat algoritma *machine learning*, yaitu *Logistic Regression*, *Random Forest*, *Gradient Boosting*, dan *K-Nearest Neighbor (KNN)* dalam melakukan prediksi terhadap risiko kanker tiroid. Evaluasi dilakukan baik sebelum maupun setelah penerapan kombinasi fitur *SMOTE*, *Recursive Feature Elimination (RFE)*, dan *Principal Component Analysis (PCA)*.

Berdasarkan hasil analisis dan evaluasi performa model, diperoleh beberapa kesimpulan penting sebagai berikut:

1. Algoritma dengan Performa Terbaik

Dari hasil analisis yang telah dilakukan, algoritma *Gradient Boosting* menunjukkan performa paling unggul dibandingkan algoritma lainnya. Hal ini ditunjukkan oleh nilai akurasi, sensitivitas, dan *F1-score* yang tinggi dan stabil. *Gradient Boosting* terbukti mampu memperbaiki kesalahan secara bertahap dari model sebelumnya sehingga menghasilkan prediksi yang lebih presisi.

2. Pengaruh Penambahan Fitur SMOTE, RFE, dan PCA

Penerapan fitur tambahan memberikan pengaruh berbeda pada masing-masing algoritma:

- a. *SMOTE* sangat membantu meningkatkan akurasi model pada data yang tidak seimbang, terutama untuk algoritma *KNN* dan *Logistic Regression*.

b. *RFE* berhasil meningkatkan efisiensi model dengan hanya menyisakan fitur-fitur yang relevan.

c. *PCA* membantu dalam reduksi dimensi, namun pada beberapa algoritma justru menyebabkan penurunan performa karena hilangnya informasi penting dari fitur asli.

3. Perubahan Performa Tiap Algoritma Setelah Penambahan Fitur

a. *Random Forest* mengalami peningkatan performa signifikan setelah ditambahkan *SMOTE* dan *RFE*, namun menurun saat digabungkan dengan *PCA* karena hilangnya kompleksitas struktur data.

b. *KNN* sempat meningkat performanya setelah menggunakan *SMOTE*, tetapi menurun drastis saat dikombinasikan dengan *PCA* karena algoritma ini sangat tergantung pada jarak antar titik data.

c. *Logistic Regression* cukup stabil dan cenderung meningkat performanya setelah penerapan *SMOTE* dan *RFE*, namun sedikit menurun saat ditambahkan *PCA*.

4. Kesimpulan Umum

Kombinasi fitur *SMOTE*, *RFE*, dan *PCA* tidak selalu memberikan hasil positif terhadap semua algoritma. Oleh karena itu, pemilihan teknik praproses data dan optimasi fitur perlu disesuaikan dengan karakteristik dari algoritma yang digunakan. Dalam konteks prediksi kanker tiroid, *Random Forest* menjadi model paling ideal karena konsisten memberikan performa terbaik baik tanpa maupun dengan penambahan fitur.

Berdasarkan hasil evaluasi, model *Random Forest* dan *Gradient Boosting* yang dikombinasikan dengan *SMOTE*, *PCA* dan *RFE* menunjukkan peningkatan performa yang signifikan dibandingkan sebelum preprocessing. Namun, *Random Forest* menghasilkan nilai recall

dan F1-score kelas Malignant yang lebih tinggi, sehingga lebih sesuai untuk prediksi kanker tiroid yang menekankan pada minimisasi kesalahan false negative. Model ini berpotensi membantu tenaga medis dalam proses skrining dini dan pengambilan keputusan klinis berbasis data. Penelitian selanjutnya disarankan untuk menguji model pada dataset kanker lainnya atau dengan teknik feature engineering yang lebih kompleks.

5.2 SARAN

Berdasarkan hasil penelitian yang telah dipaparkan, beberapa saran dapat diajukan untuk pengembangan di masa mendatang. Adapun saran dari penulis untuk penelitian selanjutnya adalah sebagai berikut

1. Teknik PCA memberikan dampak penurunan performa pada beberapa algoritma, penelitian selanjutnya disarankan untuk mengeksplorasi teknik reduksi dimensi lain seperti *Linear Discriminant Analysis* (LDA) atau metode nonlinear seperti *t-SNE* yang mungkin lebih mampu menjaga struktur data asli tanpa kehilangan informasi krusial. Selain itu, optimasi model dapat ditingkatkan melalui penerapan *hyperparameter tuning* yang lebih mendalam, misalnya dengan menggunakan metode *Bayesian Optimization* atau *Grid Search*, guna mencapai titik keseimbangan optimal antara akurasi dan efisiensi model.
2. Dari sisi dataset dan fitur, peneliti selanjutnya diharapkan dapat memperluas cakupan data dengan melibatkan dataset kanker dari berbagai institusi medis untuk menguji tingkat generalisasi model secara lebih luas. Penambahan teknik *feature engineering* yang lebih kompleks atau integrasi biomarker klinis baru juga berpotensi meningkatkan presisi prediksi. Terakhir, mengingat model Random Forest memiliki keunggulan dalam meminimalkan kesalahan *false negative* (nilai *recall* tinggi), model ini sangat potensial

untuk diimplementasikan ke dalam sistem pendukung keputusan klinis (*Clinical Decision Support System*). Namun, disarankan agar penelitian berikutnya juga menyertakan analisis interpretabilitas model menggunakan metode seperti SHAP atau LIME agar tenaga medis dapat memahami dasar pengambilan keputusan algoritma secara transparan dalam proses diagnosis.