

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Penelitian ini menghasilkan model klasifikasi untuk mendeteksi aktivitas penipuan dalam transaksi *Ethereum*. Model dibangun melalui tahapan *pre-processing* data, pemisahan data latih dan uji, serta pelatihan dengan parameter *default* dan *hyperparameter* menggunakan validasi silang.

Dari segi waktu komputasi, setiap model menunjukkan perbedaan yang signifikan selama proses pelatihan. Berdasarkan hasil pengujian, model *GaussianNB* memiliki waktu pelatihan tercepat dengan hanya 0,006 detik, diikuti oleh *LightGBM* 0,0726 detik, *Extra Trees* 1,1283 detik, dan *Support Vector Machine* 1,3540 detik. Sementara itu, *CatBoost* membutuhkan waktu paling lama, yaitu 3,9060 detik. Namun, ketika dilakukan proses *hyperparameter tuning*, waktu komputasi meningkat drastis, terutama pada *CatBoost* yang memerlukan waktu hingga 206,1 detik.

Berdasarkan hasil evaluasi menggunakan *confusion matrix*, seluruh model menunjukkan performa yang cukup baik, terutama setelah dilakukan *tuning*. Model *LightGBM* menjadi salah satu model dengan kinerja paling konsisten, baik pada parameter *default* maupun setelah *tuning*, dengan skor *F1-Score* mencapai 98,59%. Sementara itu, *Gaussian Naïve Bayes* (GNB) menunjukkan peningkatan signifikan setelah *tuning*, dari *F1-score* 79,77% menjadi 89,22%. Hal ini menjelaskan bahwa proses *tuning* dan seleksi fitur dapat meningkatkan kemampuan model dalam mengklasifikasikan transaksi dengan lebih akurat, terutama pada model yang sebelumnya memiliki performa rendah.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, berikut disampaikan beberapa saran yang dapat dijadikan acuan untuk pengembangan lebih lanjut dalam upaya meningkatkan efektivitas dan ketahanan model klasifikasi dalam mendeteksi penipuan pada transaksi *Ethereum*:

1. Eksplorasi *hyperparameter* untuk *Gaussian Naive Bayes*: Meskipun *accuracy* GNB meningkat menjadi 94,92% setelah *hyperparameter tuning*,

precision masih di bawah 90% (82,63%). Menambahkan parameter seperti *var_smoothing* dengan rentang lebih luas atau mencoba pendekatan lain seperti *kernel density estimation* dapat membantu meningkatkan kemampuan model dalam menangani kelas minoritas pada data penipuan.

2. Integrasi ke Sistem Deteksi Penipuan *Ethereum Real-Time: LightGBM* menunjukkan performa terbaik dengan *accuracy* 99,39% pada data uji. Mengintegrasikan model ini ke dalam sistem deteksi penipuan berbasis *blockchain*, dengan pengujian pada transaksi langsung dan pemantauan performa, dapat memvalidasi efektivitasnya dalam lingkungan produksi *Ethereum*.
3. Pengujian pada *Dataset* yang Lebih Beragam: Dalam penelitian ini, *dataset* yang digunakan terdiri dari total 1.969 sampel pada data uji. Menguji model pada *dataset* yang lebih besar dan beragam, termasuk transaksi *Ethereum* dari berbagai periode waktu, dapat memastikan ketahanan model dalam menghadapi skenario dunia nyata.

