

ABSTRAK

Pertumbuhan transaksi digital yang semakin pesat diikuti oleh meningkatnya risiko kecurangan yang sulit dideteksi secara konvensional, terutama pada data yang sangat tidak seimbang. Untuk mengatasi permasalahan tersebut, penelitian ini mengembangkan model deteksi fraud berbasis pendekatan hybrid dua tahap yang menggabungkan Autoencoder sebagai pendeteksi anomali tanpa label dan XGBoost sebagai model klasifikasi terawasi. Dataset yang digunakan adalah Credit Card Fraud Detection dari Kaggle (ULB Machine Learning Group), yang terdiri dari 284.807 transaksi dengan rasio fraud sebesar 0,17%. Tahapan penelitian mencakup pembagian data secara stratified sebelum preprocessing, normalisasi menggunakan StandardScaler yang hanya di-fit pada data latih, pelatihan Autoencoder secara eksklusif terhadap data non-fraud untuk menghasilkan skor rekonstruksi (AE_Score), serta integrasi skor tersebut sebagai fitur tambahan untuk XGBoost. Evaluasi dilakukan menggunakan metrik yang relevan untuk data imbalanced, yaitu precision, recall, F1-score, ROC-AUC, dan PR-AUC. Hasil penelitian menunjukkan bahwa model two-stage yang diusulkan mencapai precision 0,8971, recall 0,8243, F1-score 0,8592, ROC-AUC 0,9749, dan PR-AUC 0,8442 pada data uji. AE_Score menunjukkan kemampuan diskriminatif yang kuat, dengan rata-rata skor fraud (4,787) jauh lebih tinggi dibandingkan non-fraud (0,019). Temuan ini menunjukkan bahwa pendekatan hybrid Autoencoder-XGBoost efektif dalam memitigasi ketidakseimbangan data ekstrem dan dapat diterapkan sebagai sistem pendukung deteksi fraud berskala besar.

Kata kunci: deteksi fraud, *Autoencoder*, *XGBoost*, *anomaly detection*, *data imbalanced*

ABSTRACT

The rapid expansion of digital transactions has led to a rising risk of fraud that is difficult to detect using conventional methods, particularly when dealing with highly imbalanced datasets. To address this problem, this study proposes a two-stage hybrid fraud detection model that integrates an Autoencoder for unsupervised anomaly detection with XGBoost as a supervised classifier. The dataset used is the Credit Card Fraud Detection dataset from Kaggle (ULB Machine Learning Group), consisting of 284,807 transactions with a fraud ratio of 0.17%. The research pipeline includes stratified train-validation-test splitting prior to any preprocessing, StandardScaler normalization fitted exclusively on the training set, Autoencoder training on non-fraud data only to produce reconstruction error scores (AE_Score), and integration of AE_Score as an additional feature for XGBoost. Model performance was evaluated using metrics suitable for imbalanced classification, including precision, recall, F1-score, ROC-AUC, and PR-AUC. Results demonstrate that the proposed two-stage model achieved precision of 0.8971, recall of 0.8243, F1-score of 0.8592, ROC-AUC of 0.9749, and PR-AUC of 0.8442 on the test set. The AE_Score demonstrated strong discriminative power, with a fraud mean of 4.787 compared to 0.019 for non-fraud transactions. These findings confirm that the hybrid Autoencoder-XGBoost approach effectively handles extreme class imbalance and can serve as a reliable fraud detection component for large-scale platforms.

Keywords: fraud detection, Autoencoder, XGBoost, anomaly detection, imbalanced data