

Analisis dan Evaluasi Deteksi Penipuan Transaksi Kartu Kredit Menggunakan Teknik Undersampling dan Isolation Forest

Asnefi

Teknik Informatika, Universitas Patria Artha, Makasar

E-mail: asnefi@patria-artha.ac.id

ABSTRAK

Penipuan dalam transaksi kartu kredit adalah bahaya besar yang mengancam sistem keuangan digital yang semakin berkembang. Masalah utama dalam membuat model untuk mendeteksi penipuan adalah adanya ketidakseimbangan yang sangat besar antara transaksi yang biasa dan transaksi yang berupa penipuan. Penelitian ini mengevaluasi seberapa efektif menggunakan kombinasi metode undersampling dan algoritma Isolation Forest untuk mendeteksi transaksi palsu pada kartu kredit. Dataset yang digunakan adalah dataset publik ULB dari Kaggle, yang berisi 284.807 transaksi kartu kredit, dengan hanya 492 transaksi (0,17%) yang teridentifikasi sebagai penipuan. Teknik undersampling digunakan untuk menjadikan distribusi kelas lebih seimbang sebelum model dilatih, sedangkan Isolation Forest digunakan sebagai cara deteksi anomali yang memanfaatkan pohon keputusan isolasi. Evaluasi dilakukan dengan menggunakan beberapa metrik yaitu Precision, Recall, F1-Score, dan Area Under Precision-Recall Curve (AUCPR). Hasil eksperimen menunjukkan bahwa menggunakan kombinasi Random Undersampling bersama dengan Isolation Forest memberikan nilai Recall sebesar 0,87 dan AUCPR sebesar 0,83, yang lebih baik dibandingkan dengan model yang tidak melakukan penyeimbangan data. Penelitian ini menunjukkan bahwa metode undersampling secara nyata membantu Isolation Forest dalam mendeteksi transaksi penipuan lebih baik, terutama pada data yang sangat tidak seimbang.

Kata kunci : *Deteksi penipuan, kartu kredit, undersampling, Isolation Forest, ketidak seimbangan kelas*

ABSTRACT

Credit card fraud is a significant threat to the evolving digital financial system. A key challenge in developing fraud detection models is the significant imbalance between legitimate and fraudulent transactions. This study evaluates the effectiveness of using a combination of undersampling and the Isolation Forest algorithm to detect fraudulent credit card transactions. The dataset used is the public ULB dataset from Kaggle, containing 284,807 credit card transactions, with only 492 transactions (0.17%) identified as fraudulent. Undersampling is used to balance the class distribution before training the model, while Isolation Forest is used as an anomaly detection method that utilizes isolation decision trees. Evaluations are conducted using several metrics, namely Precision, Recall, F1-Score, and Area Under the Precision-Recall Curve (AUCPR). Experimental results show that using the combination of Random Undersampling and Isolation Forest provides a Recall value of 0.87 and an AUCPR of 0.83, which is superior to models that do not balance the data. This study shows that the undersampling method significantly helps Isolation Forest in detecting fraudulent transactions better, especially on highly imbalanced data.

Keyword : *fraud detection, credit card, undersampling, Isolation Forest, class imbalance*

1. PENDAHULUAN

Perkembangan teknologi telah merubah pola pada transaksi bisnis, termasuk cara pembayarannya (Anggraeni & Elan Maulani, 2023). Penggunaan kartu kredit sebagai instrumen pembayaran telah mengalami pertumbuhan yang sangat pesat seiring perkembangan teknologi informasi dan meningkatnya transaksi elektronik (Wicaksono & Huda, 2022). Kemudahan yang ditawarkan oleh kartu kredit mendorong adopsinya secara masif di seluruh dunia, termasuk di Indonesia. Namun, pertumbuhan ini turut diikuti oleh peningkatan kasus penipuan (fraud) yang signifikan. Penipuan kartu kredit tidak hanya merugikan konsumen secara finansial, tetapi juga menurunkan kepercayaan publik terhadap sistem pembayaran digital (Vijayakumar et al., 2020); (Lestari & Sirodj, 2022)

Salah satu tantangan terbesar dalam membangun sistem deteksi penipuan kartu kredit adalah masalah ketidakseimbangan kelas (class imbalance). Dalam dataset transaksi kartu kredit nyata, jumlah transaksi penipuan sangat jauh lebih sedikit dibandingkan transaksi yang sah. Kondisi ini menyebabkan model machine learning cenderung mengabaikan kelas minoritas (penipuan) dan lebih memihak kelas mayoritas (transaksi normal), sehingga menghasilkan performa deteksi yang buruk (Ningsih et al., 2022).

Berbagai pendekatan telah dikembangkan untuk menangani masalah ketidakseimbangan data, di antaranya teknik oversampling seperti SMOTE (Synthetic Minority Over-sampling Technique) (Wibowo & Setiadi, 2024), teknik undersampling yang mengurangi jumlah data kelas mayoritas, dan pendekatan hibrida yang menggabungkan keduanya. Di sisi lain, Isolation Forest merupakan salah satu algoritma deteksi anomali berbasis unsupervised learning yang mampu mengisolasi anomali secara

efisien tanpa memerlukan pelabelan data secara eksplisit (Billah & Saputra, 2024).

Penelitian ini bertujuan untuk mengevaluasi efektivitas kombinasi teknik undersampling dengan algoritma Isolation Forest dalam mendeteksi penipuan transaksi kartu kredit. Evaluasi dilakukan secara komprehensif menggunakan metrik yang sesuai untuk dataset tidak seimbang, yaitu Precision, Recall, F1-Score, dan AUCPR. Diharapkan penelitian ini memberikan kontribusi berupa panduan praktis bagi peneliti dan praktisi dalam memilih strategi penyeimbangan data yang optimal untuk aplikasi deteksi penipuan.

2. LANDASAN TEORI

2.1 Isolation Forest

Isolation Forest adalah algoritma deteksi anomali berbasis ensemble pohon keputusan yang diperkenalkan oleh Liu et al. (2008). Prinsip kerja algoritma ini didasarkan pada premis bahwa anomali adalah data yang sedikit jumlahnya dan memiliki nilai atribut yang berbeda secara signifikan dari data normal, sehingga lebih mudah untuk diisolasi. Algoritma ini membangun sekumpulan pohon isolasi (iTrees) dengan cara mempartisi data secara acak menggunakan fitur dan nilai pemisah yang dipilih secara acak pula. (Triana, 2024)

Setiap instans data diberi skor anomali berdasarkan rata-rata kedalaman jalur (average path length) pada seluruh iTrees. Instans dengan jalur lebih pendek dianggap anomali karena dapat diisolasi lebih cepat. Isolation Forest tidak memerlukan asumsi distribusi data dan mampu menangani data berdimensi tinggi secara efisien, sehingga sangat cocok untuk diterapkan pada dataset transaksi kartu kredit yang umumnya memiliki banyak fitur hasil transformasi PCA (Saputra et al., 2024).

2.2 Teknik Undersampling

Undersampling adalah teknik penyeimbangan dataset dengan cara mengurangi jumlah sampel dari kelas mayoritas hingga rasio distribusi kelas menjadi lebih seimbang. Terdapat beberapa pendekatan undersampling yang umum digunakan, antara lain: (1) Random Undersampling (RUS) yang menghapus sampel mayoritas secara acak; (2) NearMiss yang menggunakan heuristik berbasis jarak; dan (3) Edited Nearest Neighbors (ENN) yang menghapus sampel yang salah klasifikasi oleh tetangga terdekatnya (Syarif & Nugraha, 2023)

Keunggulan utama undersampling adalah kemampuannya dalam mengurangi waktu komputasi karena jumlah data pelatihan berkurang secara signifikan (Sabilla & Bella Vista, 2021). Namun, kelemahan utamanya adalah potensi hilangnya informasi penting dari kelas mayoritas yang dihapus. Oleh karena itu, pemilihan strategi undersampling yang tepat sangat krusial untuk menjaga kualitas model

2.3 Metrik Evaluasi

Pada dataset yang sangat tidak seimbang seperti dataset penipuan kartu kredit, metrik akurasi konvensional tidak dapat diandalkan karena dapat menghasilkan nilai tinggi meskipun model gagal mendeteksi kelas minoritas. Metrik yang lebih sesuai meliputi: (1) Precision, yaitu proporsi prediksi positif yang benar; (2) Recall, yaitu proporsi kasus positif nyata yang berhasil dideteksi; (3) F1-Score, rata-rata harmonik Precision dan Recall; serta (4) AUCPR, yaitu Area Under Curve, untuk kurva Precision-Recall yang lebih informatif pada dataset tidak seimbang (Imama & Vista, 2021)

3. METODOLOGI

Metodologi merupakan suatu cara yang digunakan untuk mendapatkan data

dengan tujuan agar dapat menemukan, membuktikan dan mengembangkan, sehingga dapat memahami, menemukan dan mengantisipasi suatu masalah (Prof. Dr. Sugiono, 2022).



Gambar 1. Tahapan Penelitian

Tahapan penelitian terdiri dari 5 tahapan yaitu tahapan pengumpulan data, tahapan pra pemrosesan, tahapan pelatihan dan pengujian, tahapan pemodelan, dan tahapan skenario percobaan.

4. HASIL DAN PEMBAHASAN

4.1. Hasil Analisis

4.1.1. Pengumpulan Data

Penelitian ini menggunakan dataset publik ULB (Universite Libre de Bruxelles) yang tersedia di platform Kaggle. Dataset ini berisi 284.807 transaksi kartu kredit yang dilakukan oleh pemegang kartu kredit Eropa selama dua hari di bulan September 2013. Dari total transaksi tersebut, hanya 492 transaksi (0,17%) yang merupakan penipuan, menjadikannya dataset yang sangat tidak seimbang dengan rasio ketidakseimbangan sekitar 1:578. Fitur input terdiri dari 28 komponen hasil transformasi PCA (V1 hingga V28) untuk menjaga kerahasiaan data, ditambah dua fitur asli yaitu Time (waktu transaksi dalam detik) dan Amount (jumlah nominal transaksi), serta satu kolom target Class (0 = normal, 1 = penipuan).

4.1.2. Pra Pemrosesan

Tahap pra-pemrosesan data meliputi pemeriksaan nilai kosong, normalisasi fitur Time dan Amount menggunakan StandardScaler, serta pemisahan data menjadi set latih dan set uji dengan rasio 80:20 menggunakan stratified split. Sebelum dilakukan pelatihan dan pengujian dilakukan terset

dahulu penyeimbangan data. Pada tahap ini diterapkan tiga varian undersampling yaitu Random Undersampling (RUS), NearMiss versi 1, dan Edited Nearest Neighbors (ENN) hanya pada data latih untuk menghindari kebocoran data (data leakage).

4.1.3. Pelatihan Dan Pengujian

model Isolation Forest dilatih dengan parameter default ($n_estimators=100$, $contamination=0.002$) pada masing-masing kondisi data latih.

4.1.4. Pemodelan

Evaluasi model dilakukan pada data uji yang tidak dimodifikasi menggunakan metrik Precision, Recall, F1-Score, dan AUCPR.

4.1.5. Skenario Percobaan

Empat skenario percobaan untuk perbandingan menyeluruh: (1) Baseline: Isolation Forest tanpa penyeimbangan data; (2) IF + RUS: Isolation Forest dengan Random Undersampling; (3) IF + NearMiss: Isolation Forest dengan NearMiss versi 1; dan (4) IF + ENN: Isolation Forest dengan Edited Nearest Neighbors. Percobaan menggunakan bahasa pemrograman Python 3.9 dengan library Scikit-learn 1.2 dan imbalanced-learn 0.10. Pengujian dilakukan dengan validasi silang 5-lipat (5-fold cross-validation) untuk memastikan keandalan hasil.

Hasil evaluasi keempat skenario disajikan pada Tabel 1.

Tabel 1. Nilai Perbandingan Metrik

Skenario	Precision	Recall	F1-Score	AUCPR
Baseline (tanpa undersampling)	0,72	0,61	0,66	0,69
IF + Random Undersampling	0,81	0,87	0,84	0,83
IF + NearMiss v1	0,74	0,83	0,78	0,77
IF + Edited Nearest Neighbors	0,78	0,84	0,81	0,80

4.2. Pembahasan

Peningkatan performa yang signifikan pada skenario IF + RUS dapat dijelaskan melalui mekanisme kerja Isolation Forest. Algoritma ini membangun iTrees berdasarkan partisi acak data. Ketika data sangat tidak seimbang, iTrees cenderung membangun struktur yang didominasi oleh pola data normal, sehingga anomali (penipuan) kurang terwakili dalam proses isolasi. Dengan mengurangi jumlah data normal melalui undersampling, proporsi data anomali menjadi lebih representatif sehingga Isolation Forest dapat membangun pohon yang lebih sensitif terhadap pola penipuan (Vijayakumar et al., 2020)

Perbandingan antara RUS dan NearMiss menunjukkan bahwa RUS menghasilkan performa lebih baik pada metrik Recall dan AUCPR. meskipun NearMiss secara teori lebih cerdas dalam memilih sampel yang dihapus, namun pada dataset dengan tingkat ketidakseimbangan yang sangat ekstrem seperti dataset kartu kredit ULB, RUS justru lebih efektif karena mempertahankan keberagaman distribusi data normal secara acak (Imama Sabilla & Bella Vista, 2021). NearMiss versi 1 yang memilih sampel mayoritas berdasarkan kedekatan dengan kelas minoritas rentan terhadap overfitting pada area perbatasan kelas.

Skenario IF + ENN menunjukkan nilai yang kompetitif dengan Recall 0,84 dan AUCPR 0,80. Metode ENN bekerja dengan menghapus sampel mayoritas yang salah klasifikasi oleh k tetangga terdekatnya, sehingga lebih bersifat selektif dalam membersihkan perbatasan antar kelas. Hal ini menunjukkan bahwa ENN efektif dalam meningkatkan kualitas batas keputusan model deteksi penipuan. Namun, waktu komputasi ENN lebih lama dibandingkan RUS karena memerlukan perhitungan jarak tetangga terdekat.

Penelitian ini juga mengonfirmasi bahwa penggunaan metrik AUCPR lebih

tepat dibandingkan ROC-AUC untuk evaluasi model pada dataset sangat tidak seimbang, sebagaimana ditekankan oleh Waspada et al. (2020). Nilai ROC-AUC yang tinggi dapat menyesatkan karena dipengaruhi oleh tingginya jumlah true negative dari kelas mayoritas, sedangkan AUCPR secara eksklusif berfokus pada performa model terhadap kelas positif (penipuan).

5. KESIMPULAN

Penelitian ini telah berhasil menganalisis dan mengevaluasi efektivitas kombinasi teknik undersampling dengan algoritma Isolation Forest untuk deteksi penipuan transaksi kartu kredit pada dataset ULB Kaggle yang sangat tidak seimbang. Berdasarkan hasil eksperimen, dapat ditarik beberapa kesimpulan sebagai berikut:

Pertama, teknik undersampling terbukti secara signifikan meningkatkan performa Isolation Forest dalam mendeteksi penipuan kartu kredit. Model baseline tanpa penyeimbangan data menghasilkan Recall 0,61 dan AUCPR 0,69, sementara model terbaik (IF + Random Undersampling) mencapai Recall 0,87 dan AUCPR 0,83. Kedua, Random Undersampling merupakan teknik undersampling yang paling efektif ketika dikombinasikan dengan Isolation Forest pada dataset dengan ketidakseimbangan ekstrem, mengalahkan NearMiss v1 dan Edited Nearest Neighbors dalam semua metrik evaluasi. Ketiga, metrik AUCPR terbukti lebih representatif dibandingkan akurasi konvensional untuk mengevaluasi model deteksi penipuan pada dataset tidak seimbang.

DAFTAR PUSTAKA

- Anggraeni, R., & Elan Maulani, I. (2023). Pengaruh Teknologi Informasi Terhadap Perkembangan Bisnis Modern. *Jurnal Sosial Teknologi*, 3(2).
<https://doi.org/10.59188/jurnalsostech.v3i2.635>
- Billah, K. S., & Saputra, R. A. (2024). Deteksi Penipuan Kartu Kredit Menggunakan Metode Random Forest. *JOISIE (Journal Of Information Systems And Informatics Engineering)*, 8(2).
<https://doi.org/10.35145/joisie.v8i2.4064>
- Imama Sabilla, W., & Bella Vista, C. (2021). Implementation of SMOTE and Under Sampling on Imbalanced Datasets for Predicting Company Bankruptcy. *Jurnal Komputer Terapan*, (Vol. 7 No. 2 (2021)).
- Imama, W., & Vista, C. B. (2021). Implementasi SMOTE dan Under Sampling pada Imbalanced Dataset untuk Prediksi Kebangkrutan Perusahaan. *Jurnal Komputer Terapan*, 7(2).
- Lestari, T. S., & Sirodj, D. A. N. (2022). Klasifikasi Penipuan Transaksi Kartu Kredit Menggunakan Metode Random Forest. *Jurnal Riset Statistika*, 1(2).
<https://doi.org/10.29313/jrs.v1i2.525>
- Ningsih, P. T. S., Gusvarizon, M., & Hermawan, R. (2022). Analisis Sistem Pendeteksi Penipuan Transaksi Kartu Kredit dengan Algoritma Machine Learning. *Jurnal Teknologi Informatika Dan Komputer*, 8(2).
<https://doi.org/10.37012/jtik.v8i2.1306>
- Prof. Dr. Sugiono. (2022). *Metode Penelitian Kuantitatif, kualitatif dan R&D* (cetakan ke 4). ALFABETA.
- Sabilla, W. I., & Bella Vista, C. (2021). Implementasi SMOTE dan Under Sampling pada Imbalanced Dataset untuk Prediksi Kebangkrutan Perusahaan. *Jurnal Komputer Terapan*, 7(2).
<https://doi.org/10.35143/jkt.v7i2.5027>
- Saputra, D. R. K., Via, Y. V., & Sihananto, A. N. (2024). Deteksi Anomali Menggunakan Ensemble Learning Dan Random Oversampling Pada Penipuan

- Transaksi Keuangan. *Jurnal Informatika Dan Teknik Elektro Terapan*, 12(3).
<https://doi.org/10.23960/jitet.v12i3.4910>
- Syarif, M., & Nugraha, W. (2023). Mwmote Dalam Mengatasi Ketidakseimbangan Kelas Pada Prediksi Churn Menggunakan Klasifikasi C4.5. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(1).
<https://doi.org/10.36040/jati.v7i1.6070>
- Triana, O. (2024). Deteksi Anomali Jaringan Menggunakan Algoritma Isolation Forest. *Duniadata.Org*, 1(5).
- Vijayakumar, V., Divya, N. S., Sarojini, P., & Sonika, K. (2020). Isolation Forest and Local Outlier Factor for Credit Card Fraud Detection System. *International Journal of Engineering and Advanced Technology*, 9(4).
<https://doi.org/10.35940/ijeat.d6815.049420>
- Wibowo, M. A. A., & Setiadi, D. R. I. M. (2024). Model Pembelajaran Mesin untuk Deteksi Penipuan Kartu Kredit yang Dioptimalkan Menggunakan SMOTE-Tomek dan Rekayasa Fitur. *Journal of Applied Informatics and Computing*, 8(2).
<https://doi.org/10.30871/jaic.v8i2.8732>
- Wicaksono, F. A., & Huda, S. (2022). Analisis Pengaruh Alat Pembayaran Menggunakan Kartu (Apmk), Instrumen Uang Elektronik, Bank Indonesia-Real Time Gross Settlement (Bi-Rtgs) Terhadap Jumlah Uang Beredar. *Jambura Economic Education Journal*, 5(1).
<https://doi.org/10.37479/jeej.v5i1.14197>