

Analisis Perbandingan Teknik Balancing CTGAN dan ADASYN untuk Deteksi Transaksi Penipuan

Firman Zamzami Aziz¹, Muhammad Agus Priyanto², Afridho Nur Zaki³, Gilang Dely Mukti⁴, Akhmad Fauzan⁵, Adelia Najmi Raissa⁶

^{1,2,3,4,5}Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Amikom Purwokerto, Purwokerto, Indonesia

⁶Program Studi Informatika, Fakultas Teknik, Universitas Jenderal Soedirman, Purwokerto, Indonesia

surel: ¹firmanzamzamiaiziz@gmail.com, ²aguspriyanto.dev@gmail.com, ³elaidho25@gmail.com, ⁴gilangdelymukti@gmail.com, ⁵ozan6825@gmail.com, ⁶najmiraisaadelia@gmail.com

Info Artikel

Sejarah artikel:

Diterima 04-06-2025

Revisi 12-07-2025

Diterima 02-08-2025

Kata kunci:

Deteksi Penipuan
Data Imbalanced
ADASYN
CTGAN
Machine Learning

ABSTRAK

Ketidakseimbangan data menjadi tantangan utama dalam deteksi transaksi penipuan karena jumlah transaksi legal jauh lebih dominan. Penelitian ini membandingkan efektivitas metode ADASYN dan CTGAN dalam menyeimbangkan data dan meningkatkan performa model klasifikasi. Dataset berisi 6,3 juta transaksi dianalisis melalui preprocessing, seleksi fitur XGBoost, stratified sampling, balancing, dan modeling menggunakan Decision Tree, Random Forest, serta MLP Classifier. Hasil menunjukkan bahwa meskipun kedua metode meningkatkan distribusi kelas, performa metrik Precision dan F1-Score masih belum optimal. Diperlukan penerapan hyperparameter tuning serta eksplorasi metode balancing lain untuk hasil yang lebih baik.

Penulis yang sesuai:

Firman Zamzami Aziz

Program Studi Informatika Fakultas Ilmu Komputer Universitas Amikom Purwokerto

Email: firmanzamzamiaiziz@gmail.com

1. PENDAHULUAN

Kecurangan transaksi keuangan telah menjadi salah satu ancaman utama dalam era digitalisasi perbankan dan teknologi finansial global. Tren peningkatan kerugian akibat kecurangan transaksi keuangan di era digitalisasi perbankan dan teknologi finansial global menjadi perhatian serius. Laporan Nasdaq Verafin 2024 Global Financial Crime Report [1], menunjukkan kerugian global mencapai \$485.6 miliar pada tahun 2023, sementara Federal Trade Commission (FTC) mencatat lonjakan kerugian penipuan di Amerika Serikat hingga \$12.5 miliar pada tahun 2024, meningkat 24% dari tahun sebelumnya [2]. Di Indonesia, masalah ini juga signifikan; Otoritas Jasa Keuangan (OJK) melaporkan kerugian perbankan akibat kecurangan mencapai Rp 4,62 triliun pada tahun 2020 dengan peningkatan kasus eksternal yang signifikan [3]. Selain itu, sektor keuangan Indonesia juga menderita kerugian Rp 68 miliar akibat kebocoran data [4], menyoroti urgensi pengembangan sistem deteksi kecurangan yang lebih akurat.

Deteksi kecurangan transaksi keuangan menghadapi tantangan yang cukup kompleks yang membutuhkan pendekatan yang inovatif. Tantangan utama yang dihadapi adalah masalah ketidakseimbangan data (class imbalance) yang ekstrem dalam dataset transaksi keuangan. dataset kecurangan transaksi keuangan menunjukkan distribusi yang

sangat tidak seimbang, yang dimana transaksi legal mencapai 99.870% sementara transaksi ilegal hanya 0.129% [5]. Penelitian ini menggunakan dataset publik transaksi kartu kredit yang tersedia di platform Kaggle, yang secara nyata merepresentasikan permasalahan ketidakseimbangan kelas dalam deteksi transaksi penipuan. Ketidakseimbangan data yang ekstrem ini menyebabkan algoritma machine learning cenderung bias terhadap kelas mayoritas sehingga menghasilkan performa yang buruk dalam mendeteksi transaksi ilegal [6].

Dalam mengatasi masalah ketidakseimbangan data, berbagai metode telah dikembangkan. Salah satunya adalah ADASYN (Adaptive Synthetic Sampling), yang diperkenalkan oleh He et al. (2008). ADASYN adalah pendekatan adaptif yang membuat sampel sintetis kelas minoritas berdasarkan tingkat kesulitan pembelajarannya, dengan fokus pada area batas keputusan yang paling sulit dipelajari oleh model. Ini dilakukan dengan menghitung jumlah sampel sintetis yang perlu dibuat untuk setiap data minoritas berdasarkan distribusi kepadatan [7].

Di sisi lain, kemajuan dalam Generative Adversarial Networks (GANs) telah membawa CTGAN (Conditional Tabular GAN) sebagai solusi baru untuk data tabular yang tidak seimbang. CTGAN dirancang khusus untuk menghasilkan data sintetis berbentuk tabular, mampu menangani kombinasi kolom diskrit dan kontinu yang kompleks [8]. Keunggulan CTGAN terletak pada penggunaan conditional generator untuk merepresentasikan kategori langka, mode-specific normalization untuk menangkap pola distribusi lokal yang rumit, dan training-by-sampling agar model tidak hanya terfokus pada kelas mayoritas [9][10]. Penelitian menunjukkan bahwa CTGAN mampu menghasilkan peningkatan performa yang signifikan, bahkan melampaui metode tradisional seperti SMOTE dan ADASYN dalam hal presisi [11]. Meskipun demikian, masih ada celah dalam literatur terkait perbandingan komparatif mendalam antara ADASYN dan CTGAN, terutama dalam konteks deteksi kecurangan transaksi keuangan [12].

Berdasarkan analisis gap dari penelitian sebelumnya, penelitian ini bertujuan untuk melakukan perbandingan teknik balancing CTGAN dan ADASYN untuk mendeteksi penipuan melalui eksperimen dalam menangani data tidak seimbang. Penelitian ini dilakukan untuk mengidentifikasi algoritma yang terbaik untuk deteksi kecurangan pada transaksi keuangan.

2. METODE

Penelitian ini menggunakan metode kuantitatif dengan pendekatan eksperimen untuk menguji efektivitas CTGAN dan ADASYN dalam menangani data tidak seimbang pada kasus deteksi kecurangan transaksi keuangan. Pendekatan ini dipilih karena analisis kuantitatif memungkinkan pengukuran performa model secara objektif melalui metrik evaluasi seperti accuracy, precision, recall, dan F1-score.

2.1. Dataset

Data yang digunakan bersumber dari dataset public yang tersedia di internet dengan judul “fraudulent transaction” yang diperoleh dari Kaggle dan digunakan untuk mendeteksi transaksi penipuan. Dataset ini terdiri dari 6.362.620 data transaksi dengan 10 fitur.

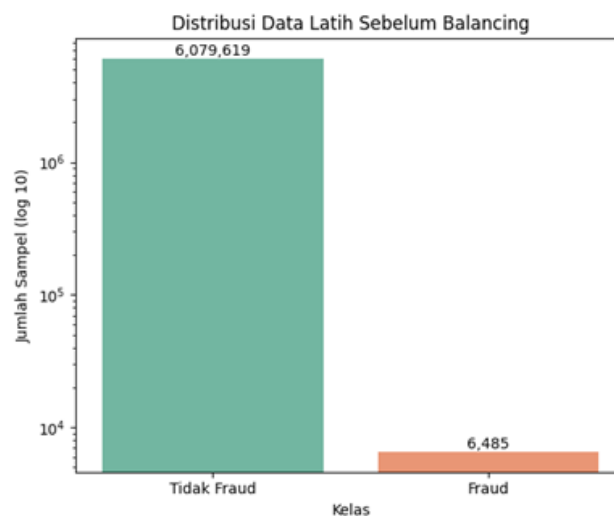
Tabel 1. 10 Fitur yang tersedia

hal	Fitur	Deskripsi
1	step	Unit waktu dalam dunia nyata, di mana 1 step merepresentasikan 1 jam. Total terdapat 744 step yang mencerminkan simulasi selama 30 hari.
2	type	Jenis transaksi yang terjadi, terdiri dari: CASH-IN, CASH-OUT, DEBIT, PAYMENT, dan TRANSFER.
3	amount	Jumlah nilai transaksi dalam mata uang lokal.
4	nameOrig	ID dari nasabah yang memulai transaksi.



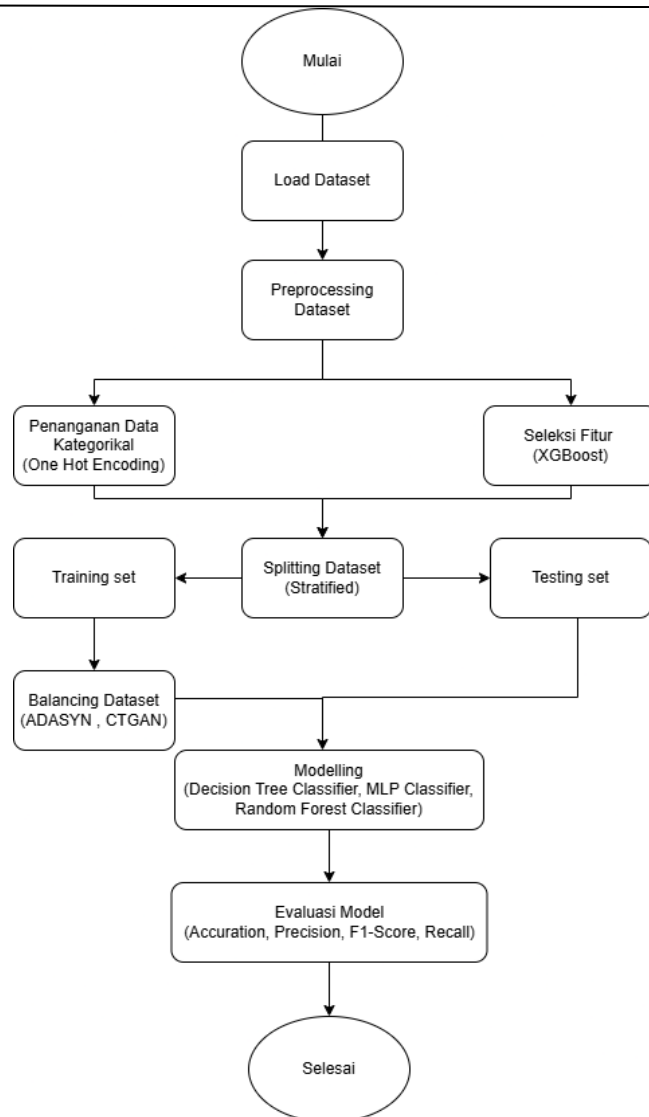
hal	Fitur	Deskripsi
1	step	Unit waktu dalam dunia nyata, di mana 1 step merepresentasikan 1 jam. Total terdapat 744 step yang mencerminkan simulasi selama 30 hari.
5	oldbalanceOrg	Saldo awal dari pengirim sebelum transaksi dilakukan.
6	newbalanceOrig	Saldo pengirim setelah transaksi dilakukan.
7	nameDest	ID dari nasabah penerima transaksi.
8	oldbalanceDest	Saldo awal penerima sebelum transaksi. Catatan: Tidak tersedia untuk nasabah yang namanya diawali dengan huruf M (Merchant).
9	IsFraud	Label yang menunjukkan apakah transaksi tersebut merupakan hasil dari aktivitas penipuan.
10	isFlaggedFraud	Label yang menunjukkan apakah transaksi tersebut dianggap sebagai upaya ilegal oleh sistem bisnis, seperti transfer di atas 200.000 dalam satu transaksi.

Tabel 1 menjelaskan deskripsi dari 10 fitur yang terdapat dalam dataset transaksi keuangan yang digunakan dalam penelitian ini.



Gambar 1. Visualisasi Dataset Sebelum Balancing

Dataset ini sangat tidak seimbang (imbalanced), di mana kelas positif (fraud) hanya mencakup sekitar 6485 dari total 6084104, atau sekitar 0.129%.



Gambar 2. Flowchart Uji Efektifitas CTGAN dan ADASYN

Dari bagan tersebut proses pertama diawali dengan Load Dataset dengan memuat dataset yang berisi data transaksi yang mencakup fitur numerik dan/atau kategorik, serta label klasifikasi antara transaksi normal dan penipuan. Dataset diperoleh dari sumber terbuka atau instansi terkait dan disimpan dalam format CSV atau sejenis. Kemudian langkah berikutnya diikuti dengan Preprocessing Dataset dengan cara Menangani Missing Value, Menangi Data Kategorikal, dan Seleksi Fitur.

2.2 Menangani Data Kategorikal

One-hot Encoding dengan Reduksi Dimensionalitas diterapkan, di mana untuk fitur dengan kardinalitas sangat tinggi (>100), kombinasi one-hot encoding dan Principal Component Analysis (PCA) memberikan solusi optimal. Pendekatan ini mengubah matriks sparse hasil dari one-hot encoding menjadi vektor laten yang berdimensi rendah serta mempertahankan struktur kategorikal. Penelitian di arXiv menunjukkan reduksi dimensionalitas hingga 80% dengan retain informasi sebesar 95% untuk dataset keuangan [13].

2.3 Seleksi Fitur

Penggunaan XGBoost (Extreme Gradient Boosting) dalam seleksi fitur pada klasifikasi penipuan transaksi kartu kredit dilakukan karena kemampuannya dalam mengidentifikasi fitur-fitur yang paling berpengaruh secara efisien dan akurat. XGBoost merupakan algoritma berbasis pohon keputusan yang menggunakan pendekatan

boosting, sehingga mampu menangkap hubungan non-linear dan kompleks antar fitur. Selain itu, algoritma ini dirancang untuk mengatasi overfitting, bekerja baik pada data yang tidak seimbang, serta memiliki toleransi tinggi terhadap noise. XGBoost juga mampu menangani fitur dengan berbagai skala tanpa memerlukan proses normalisasi, dan menyediakan skor kepentingan fitur yang dapat digunakan untuk menentukan fitur-fitur terbaik dalam proses klasifikasi.

2.4 Splitting Dataset

Stratified sampling merupakan teknik pembagian data yang mempertahankan proporsi kelas target dalam setiap subset data, baik pada data latih maupun data uji. Teknik ini sangat penting dalam kasus klasifikasi dengan distribusi kelas yang tidak seimbang, seperti pada deteksi transaksi penipuan, karena dapat memastikan bahwa perwakilan dari kelas minoritas tetap ada dalam masing-masing subset. Pembagian ini biasanya dilakukan dengan beberapa proporsi, seperti 60:40, 70:30, atau 80:20, dan pemilihan rasio terbaik disesuaikan dengan performa model dan kebutuhan validasi.

2.5 CTGAN

Conditional Tabular GAN (CTGAN) adalah varian dari Generative Adversarial Network (GAN) yang dirancang secara khusus untuk menangani data tabular, terutama yang mengandung kombinasi fitur numerik dan kategorikal. Berbeda dengan GAN konvensional yang umum digunakan untuk citra, CTGAN menggunakan pendekatan mode-specific normalization serta pemodelan distribusi kondisi yang memudahkan pembelajaran fitur-fitur tabular yang kompleks.

2.6 ADASYN

ADASYN adalah versi perbaikan dari Sintetis, Minoritas, Oversampling Technique (SMOTE), yang digunakan untuk menghindari overfitting yang terjadi ketika replika yang tepat dari instance minoritas ditambahkan ke dataset utama. Ide utama dari algoritma ADASYN adalah menggunakan distribusi densitas sebagai kriteria untuk secara otomatis menentukan jumlah sampel sintetis yang sesuai yang perlu dihasilkan untuk setiap contoh pada data minoritas.

2.7 Modeling

Sistem deteksi transaksi penipuan dikembangkan menggunakan tiga algoritma klasifikasi: Decision Tree Classifier, Multi-Layer Perceptron (MLP) Classifier, dan Random Forest Classifier. Pilihan ini bertujuan untuk membandingkan kinerja model berbasis pohon dengan model jaringan saraf tiruan dalam mengidentifikasi anomali transaksi.

Decision Tree adalah algoritma supervised learning yang membangun model prediksi dalam struktur pohon, mempartisi data secara rekursif berdasarkan aturan keputusan dari fitur data [14]. Setiap jalur dari akar ke daun merepresentasikan aturan klasifikasi, di mana daun adalah label kelas prediksi [15]. Keunggulannya terletak pada interpretasinya yang intuitif. Multi-Layer Perceptron (MLP) Classifier adalah arsitektur jaringan saraf tiruan feedforward dengan lapisan masukan, tersembunyi, dan keluaran. Pembelajaran terjadi melalui algoritma backpropagation untuk meminimalkan fungsi kerugian, memungkinkan model mempelajari pola kompleks dan melakukan klasifikasi. Adapun Random Forest adalah metode ensemble learning yang membangun banyak Decision Tree secara independen pada sub-sampel data menggunakan teknik bagging. Prediksi akhir ditentukan melalui majority voting dari semua pohon, yang secara efektif mengurangi overfitting dan meningkatkan akurasi serta robustness model.

2.9 Evaluasi

Model Decision Tree, MLP, dan Random Forest dibuat komparasi dengan menggunakan matrik evaluasi seperti Accuracy Precision Recall F1 score. Hasil evaluasi tersebut akan digunakan untuk memilih model yang paling optimal dan andal dalam mendeteksi transaksi penipuan.

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil dari seluruh tahapan eksperimen yang telah dilakukan, mulai dari preprocessing data, proses balancing menggunakan metode ADASYN dan CTGAN, hingga evaluasi performa model klasifikasi. Seluruh hasil dianalisis untuk mengukur efektivitas masing-masing metode dalam menangani ketidakseimbangan data pada deteksi transaksi penipuan.



3.1. Preprocessing

3.1.1. Penanganan data kategorikal

Tabel 2. Contoh data SEBELUM labeling dengan One Hot Encoding

	Step	Type	Amount	isFraud
0	1	PAYMENT	9839.64	0
1	1	PAYMENT	1864.28	0
2	1	TRANSFER	181.00	1
3	1	CASH_OUT	181.00	1
4	1	PAYMENT	11668.14	0


Tabel 3. Contoh data SETELAH labeling dengan One Hot Encoding

	Step	Amount	isFraud	type_CASH_IN	type_CASH_OUT	type_DEBIT	type_PAYM_ENT	type_TRAN_SFER
0	1	9839.64	0	False	False	False	True	False
1	1	1864.28	0	False	False	False	True	False
2	1	181.00	1	False	False	False	False	True
3	1	181.00	1	False	True	False	False	False
4	1	11668.14	0	False	False	False	True	False

Tabel 2 dan Tabel 3 menunjukkan penerapan One-Hot Encoding, sebuah tahap pra-pemrosesan data penting untuk machine learning. Tabel 1 menampilkan data awal, dengan kolom Type berisi nilai kategorikal seperti 'PAYMENT', 'TRANSFER', dan 'CASH_OUT'. Karena sebagian besar algoritma machine learning memerlukan input numerik, data non-numerik ini harus dikonversi.

Untuk itu, One-Hot Encoding diterapkan, seperti yang terlihat pada Tabel 2. Teknik ini mengubah kolom Type menjadi beberapa kolom biner baru, di mana setiap kolom mewakili satu kategori unik dari Type (misalnya, type_PAYMENT, type_TRANSFER, dll.). Nilai True (1) diberikan pada kolom yang sesuai dengan kategori asli, dan False (0) untuk kolom kategori lainnya. Sebagai contoh, baris ketiga dengan Type 'CASH_OUT' kini memiliki nilai True di kolom type_CASH_OUT dan False di kolom tipe lainnya.

3.1.2. Seleksi Fitur



Gambar 3. Visualisasi Seleksi Fitur dengan XGBoost.

Gambar 3 menunjukkan 8 fitur terpenting dari evaluasi model XGBoost, diurutkan berdasarkan "Skor Kepentingan". Fitur type_CASH_OUT adalah prediktor paling dominan. Selain itu, fitur terkait saldo akun seperti newbalanceOrig, newbalanceDest, dan oldbalanceOrg juga sangat krusial. Jenis transaksi lain seperti type_TRANSFER dan type_PAYMENT relevan, tetapi tidak sekuat type_CASH_OUT. Yang menarik, amount (jumlah transaksi) memiliki skor rendah, menunjukkan bahwa model lebih memprioritaskan informasi mengenai pihak yang bertransaksi dan perubahan kondisi akun mereka daripada nilai transaksinya. Di antara delapan fitur teratas ini, oldbalanceDest memiliki kontribusi paling kecil.

3.2. Splitting data stratified

Tabel 4. Hasil splitting metode stratified

Ratio Train	Ratio Test	Rata-rata f1 Score
90%	10%	0.8543
80%	20%	0.8526
70%	30%	0.8538
60%	40%	0.8565

Tabel 4 merupakan hasil akhir eksperimen pencarian rasio pembagian data menggunakan metode stratified split, diperoleh rata-rata nilai F1-Score untuk empat skenario rasio train/test yang berbeda. Hasilnya menunjukkan bahwa seluruh rasio menghasilkan performa yang relatif stabil dan tinggi, dengan perbedaan nilai F1-Score yang sangat kecil.

Secara keseluruhan, rasio 60:40 memberikan hasil paling optimal dalam hal akurasi klasifikasi berdasarkan metrik F1-Score, serta memiliki variabilitas yang rendah, sehingga dipilih sebagai rasio terbaik dalam pembagian data untuk tahap pelatihan model selanjutnya.

3.2. Modeling Tanpa Menggunakan Balancing


Pada tahap awal, dilakukan pelatihan model klasifikasi secara langsung tanpa menerapkan teknik balancing data. Penting untuk diketahui bahwa dataset yang digunakan memiliki ketidakseimbangan kelas (imbalanced), di mana jumlah sampel pada kelas mayoritas (non-fraud) jauh lebih besar dibandingkan kelas minoritas (fraud). Kondisi ini berisiko menyebabkan model cenderung mempelajari pola dari kelas mayoritas, sementara kelas minoritas yang sebenarnya menjadi fokus utama dalam deteksi penipuan, kurang terwakili dalam proses pembelajaran.

Tabel 5. Hasil modeling tanpa balancing

Algoritma	Accuracy	Precision	Recall	F1 Score
Decision Tree Classifier	99.970%	88.314%	88.314%	88.314%
MLP Classifier	99.36%	16.68%	99.45%	28.57%
Random Forest Classifier	98,46%	7,64%	98,78%	99,87%

Hasil evaluasi dari tiga algoritma yang diuji Decision Tree Classifier, MLP Classifier, dan Random Forest Classifier pada tabel 5 menunjukkan bahwa meskipun nilai akurasi secara keseluruhan cukup tinggi (hingga 99%), metrik penting lainnya seperti precision dan F1 Score mengalami penurunan signifikan, terutama pada model MLP dan Random Forest. Misalnya, MLP Classifier hanya memperoleh precision sebesar 16.68% dan F1 Score 28.57%, yang menandakan bahwa model menghasilkan banyak false positive dan tidak mampu menyeimbangkan antara kemampuan mendeteksi dan meminimalkan kesalahan klasifikasi.

3.3. Balancing Metode CTGAN



Gambar 4. Hasil Balancing Metode CTGAN

Setelah proses balancing menggunakan CTGAN, distribusi data latih berhasil diseimbangkan dengan sempurna. Sebelumnya terdapat ketimpangan signifikan antara kelas tidak fraud (0) dan fraud (1). Kini, setiap kelas memiliki 3.812.644 sampel, sehingga total data latih yang digunakan untuk pelatihan model berjumlah 7.625.288

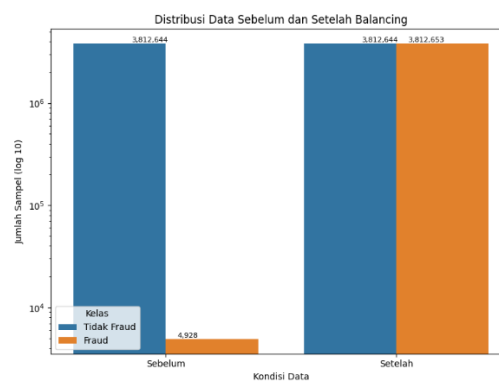
sampel. Dataset hasil balancing ini kemudian digunakan sebagai input untuk melatih tiga model klasifikasi yaitu, Decision Tree Classifier, MLP Classifier, Random Forest Classifier

Tabel 5. Hasil modeling dengan balancing CTGAN

Algoritma	Accuracy	Precision	Recall	F1 Score
Decision Tree Classifier	99.886%	53.609%	88.858%	66.873%
MLP Classifier	99.87%	49.59%	72.97%	59.05%
Random Forest Classifier	99.939%	75.930%	77.017%	76.470%

Berdasarkan Tabel 5, Random Forest Classifier menunjukkan performa terbaik pada data balancing CTGAN dan stratified sampling, dengan F1 Score 76.47% dan Precision 75.93%, yang berarti deteksi fraud seimbang dengan minimnya false positive. Decision Tree Classifier unggul dalam recall (88.86%) tetapi memiliki precision yang lebih rendah (53.61%). Di sisi lain, MLP Classifier memiliki akurasi tinggi namun precision dan recall terendah di antara ketiga model.

3.3. Balancing Metode ADASYN



Gambar 5. Hasil Balancing Metode ADASYN

Proses balancing data menggunakan ADASYN menghasilkan dataset latih yang seimbang dengan 3.812.644 sampel non-fraud dan 3.812.653 sampel fraud, sehingga total menjadi 7.625.297 sampel. Dataset yang seimbang ini kemudian digunakan untuk melatih tiga model klasifikasi: Decision Tree Classifier, MLP Classifier, dan Random Forest Classifier. Evaluasi performa model dilakukan berdasarkan Accuracy, Precision, Recall, dan F1 Score.

Tabel 6. Hasil modeling dengan balancing ADASYN

Algoritma	Accuracy	Precision	Recall	F1 Score
Decision Tree Classifier	99.933%	66.244%	98.691%	79.276%
MLP Classifier	99.474%	18.179%	87.884%	30.126%
Random Forest Classifier	99.905%	57.978%	96.012%	72.298%

Berdasarkan tabel 6, Decision Tree Classifier memberikan performa terbaik dengan Recall 98.69% dan F1 Score 79.28%, menjadikannya paling efektif dalam mendeteksi fraud. Random Forest Classifier juga kompetitif dengan F1 Score 72.30%. Sementara itu, MLP Classifier memiliki Recall tinggi namun Precision dan F1 Score rendah, menandakan banyak prediksi false positive sehingga kurang efektif setelah balancing dengan ADASYN.

3.4. Perbandingan dengan penelitian sebelumnya

Tabel 7. Hasil penelitian sebelumnya

Algoritma	Accuracy	Precision	Recall	F1 Score
Decision Tree Classifier	99.958%	99.945%	99.971%	99.958%
MLP Classifier	99.389%	99.390%	99.389%	99.389%
Random Forest Classifier	99.950%	99.950%	99.950%	99.950%



Hasil pada Tabel 7 menunjukkan bahwa penggunaan metode SMOTE dalam penelitian sebelumnya mampu menghasilkan metrik evaluasi yang sangat tinggi dan seimbang di semua aspek, termasuk Accuracy, Precision, Recall, dan F1 Score bahkan mendekati 100% pada hampir semua algoritma [5]. Di sisi lain, hasil eksperimen dalam penelitian ini dengan metode ADASYN maupun CTGAN menunjukkan kinerja yang lebih rendah, khususnya pada metrik Precision dan F1 Score.

4. KESIMPULAN

Berdasarkan hasil eksperimen yang telah dilakukan, dapat disimpulkan bahwa penerapan metode balancing ADASYN dan CTGAN dalam penelitian ini masih belum mampu menghasilkan performa model yang optimal. Meskipun kedua metode tersebut berhasil menyeimbangkan distribusi data latih dan memberikan peningkatan performa dibandingkan model tanpa balancing, nilai metrik evaluasi yang dicapai, khususnya Precision dan F1 Score, masih berada di bawah standar yang diharapkan dan belum mampu menyamai hasil penelitian sebelumnya yang menggunakan metode SMOTE. Metode SMOTE terbukti lebih konsisten menghasilkan metrik yang seimbang dan tinggi pada seluruh algoritma klasifikasi yang diuji. Hasil ini menunjukkan bahwa efektivitas metode balancing sangat bergantung pada karakteristik dataset, algoritma yang digunakan, serta parameter tuning yang diterapkan. Oleh karena itu, untuk penelitian selanjutnya disarankan dilakukan pengoptimalan parameter (hyperparameter tuning) baik pada metode balancing maupun algoritma klasifikasi.

REFERENSI

- [1] “Nasdaq Verafin 2024 Global Financial Crime Report | Nasdaq.” Accessed: Jun. 29, 2025. [Online]. Available: <https://www.nasdaq.com/global-financial-crime-report>
- [2] “New FTC Data Show a Big Jump in Reported Losses to Fraud to \$12.5 Billion in 2024 | Federal Trade Commission.” Accessed: Jun. 29, 2025. [Online]. Available: <https://www.ftc.gov/news-events/news/press-releases/2025/03/new-ftc-data-show-big-jump-reported-losses-fraud-125-billion-2024>
- [3] N. Intan, “OJK Ungkap Kerugian Perbankan Akibat Fraud Capai Rp 4,62 T | Republika Online,” Republika.co.id. Accessed: Jun. 29, 2025. [Online]. Available: <https://ekonomi.republika.co.id/berita/qzxirv457/ojk-ungkap-kerugian-perbankan-akibat-fraud-capai-rp-462-t>
- [4] F. – C. Services, “Menguak Kerugian Rp. 68 Miliar Akibat Kebocoran Data di Sektor Keuangan,” LinkedIn. Accessed: Jun. 29, 2025. [Online]. Available: <https://id.linkedin.com/pulse/menguak-kerugian-rp-68-miliar-akibat-kebocoran-data-di-sektor-8murc>
- [5] R. Y. R. Abdaljawad, T. Obaid, and S. S. Abu-Naser, “Fraudulent Financial Transactions Detection Using Machine Learning,” *2023 3rd Int. Conf. Emerg. Smart Technol. Appl. eSmarTA 2023*, vol. 6, no. 3, pp. 30–39, 2023, doi: 10.1109/eSmarTA59349.2023.10293697.
- [6] J. Zhao, “ADASYN (Adaptive Synthetic Sampling) for imbalance datasets - Online Technical Discussion Groups—Wolfram Community,” Wolfram Community. Accessed: Jun. 29, 2025. [Online]. Available: <https://community.wolfram.com/groups/-/m/t/1689390>
- [7] H. He, Y. Bai, E. A. Garcia, and S. Li, “ADASYN: Adaptive synthetic sampling approach for imbalanced learning,” *Proc. Int. Jt. Conf. Neural Networks*, no. 3, pp. 1322–1328, 2008, doi: 10.1109/IJCNN.2008.4633969.
- [8] L. Xu, M. Skoularidou, A. Cuesta-Infante, and K. Veeramachaneni, “Modeling tabular data using conditional GAN,” *Adv. Neural Inf. Process. Syst.*, vol. 32, no. NeurIPS, 2019.
- [9] A. E. Team, “CTGAN (Conditional Tabular Generative Adversarial Network) | ML and AI Wiki by AryaXAI,” AryaXAI. Accessed: Jun. 29, 2025. [Online]. Available: <https://www.aryaxai.com/wiki/ctgan-conditional-tabular-generative-adversarial-network>
- [10] M. E. Sánchez-Gutiérrez and P. P. González-Pérez, “Addressing the class imbalance in tabular datasets from a generative adversarial network approach in supervised machine learning,” *J. Algorithms Comput. Technol.*, vol. 17, 2023, doi: 10.1177/17483026231215186.
- [11] R. A. Nugraha, H. F. Pardede, and A. Subekti, “Oversampling based on generative adversarial networks to overcome imbalance data in predicting fraud insurance claim,” *Kuwait J. Sci.*, vol. 49, pp. 1–12, 2022, doi: 10.48129/kjs.splml.19119.
- [12] M. Ye-Bin, N. Hyeon-Woo, W. Choi, N. Kim, S. Kwak, and T.-H. Oh, “SYNAuG: Exploiting Synthetic Data for Data Imbalance Problems,” *Pattern Recognit. Lett.*, vol. 193, no. C, pp. 115–121, 2025, doi: 10.1016/j.patrec.2025.04.013.
- [13] Z. Liang, “Efficient Representations for High-Cardinality Categorical Variables in Machine Learning,” 2025, [Online]. Available: <http://arxiv.org/abs/2501.05646>
- [14] D. T. Larose and C. D. Larose, *Discovering Knowledge In Data An Introduction to Data Mining*. 2014. doi: <https://doi.org/10.1002/9781118874059>.
- [15] D. Gries and F. B. Schneider, *A Logical Approach to Discrete Math*. 1993. doi: 10.1007/978-1-4757-3837-7.

