



Optimasi Algoritma XGBoost Berbasis SMOTE untuk Mengidentifikasi Faktor Logistik Pemicu Pembatalan Pesanan *E-Commerce*

Arif Fitra Setyawan¹, Thomas Tri Wibowo², Intan Laily Muflikhah³, Muhammad Bhayu Bramantyo⁴

¹ Teknik Elektro, Politeknik Negeri Semarang, Indonesia

^{2,3,4} Teknik Elektro, Politeknik Negeri Semarang, Indonesia

Email author: ariffitra.setyawan@gmail.com¹, thomas.tri@polines.ac.id², intan.laily@polines.ac.id³, muhammad.bhayu@polines.ac.id⁴

Article Info

Article history:

Received June 23, 2026

Revised June 30, 2026

Accepted July 7, 2026

Available: July 13, 2026

Published: July 30, 2026

Keywords:

Data Leakage;
E-Commerce;
Order Cancellation;
SMOTE;
XGBoost

ABSTRACT

Unilateral order cancellation by consumers is a major operational challenge in the Indonesian e-commerce industry, directly impacting supply chain inefficiency and inflating logistics costs. Computational modeling to predict this risk often faces hurdles such as class imbalance and vulnerability to data leakage. This study proposes an optimization of the Extreme Gradient Boosting (XGBoost) algorithm integrated with the Synthetic Minority Over-sampling Technique (SMOTE) using a multi-scenario feature analysis approach. The dataset used comprises real transaction records from a major e-commerce platform. Experiments were designed in two scenarios: Scenario 1 included all transactional features, while Scenario 2 excluded the dominant financial feature (Total Pembayaran) to test the model's pure dependency on pre-finalization variables. The test results showed that Scenario 1 yielded a pseudo-accuracy of 99.50% due to data leakage. After reconstruction in Scenario 2, the SMOTE-based XGBoost model produced a stable real performance with an Accuracy Score of 83.96% and an Area Under ROC (AUC) of 86.98%. Through Feature Importance analysis, this study successfully revealed that pure logistics factors, specifically "Ongkos Kirim Dibayar oleh Pembeli" (Shipping Fee Paid by Buyer) with an absolute importance weight of 77.10%, serve as the primary predictor and driver behind consumer order cancellations. These findings provide tactical contributions for e-commerce decision-makers in formulating shipping cost strategies and mitigating early operational risks.

Corresponding Author:

Arif Fitra Setyawan,
Politeknik Negeri Semarang
Jl. Prof. Soedarto, Tembalang, Kec. Tembalang, Kota Semarang, Jawa Tengah 50275
Email: ariffitra.setyawan@gmail.com



1. PENDAHULUAN

Perkembangan teknologi digital dan ekosistem *e-commerce* di Indonesia telah mengubah lanskap perilaku belanja masyarakat secara masif. Namun, di balik pertumbuhan volume transaksi yang *eksponensial*, pelaku usaha dan penyedia platform dihadapkan pada tingginya angka pembatalan pesanan (*order cancellation*). Pembatalan transaksi secara sepihak oleh konsumen menimbulkan inefisiensi logistik, pembengkakan biaya operasional gudang, hingga hilangnya potensi pendapatan (*opportunity loss*). Untuk *platform* besar seperti Lazada dan Shopee, dinamika ulasan dan perilaku transaksional konsumen menjadi indikator vital dalam memprediksi tren pasar (Arif Fitra & Rozaq Isnaini, 2025). Oleh karena itu, kemampuan untuk memprediksi risiko pembatalan pesanan sebelum paket masuk ke fase pengiriman menjadi instrumen mitigasi risiko operasional yang sangat krusial dalam rantai pasok bisnis digital saat ini.

Dalam pemodelan komputasi berbasis data transaksi *e-commerce*, karakteristik data secara alamiah didominasi oleh ketidakseimbangan kelas (*class imbalance*), di mana jumlah pesanan berstatus "Selesai" jauh lebih banyak daripada pesanan berstatus "Batal". Karakteristik data yang tidak seimbang ini cenderung membuat algoritma klasifikasi standar mengalami bias ke kelas mayoritas, sehingga menurunkan sensitivitas prediksi kelas target (Achmad Fauzihan Bagus, Basuki, & Achmad, 2024) (Ping & Yiqiao Jia and Youlin, 2022). Untuk mengatasi kendala tersebut, metode *oversampling* seperti *Synthetic Minority Over-sampling Technique (SMOTE)* terbukti secara ilmiah mampu menyintesis sampel baru pada kelas minoritas tanpa memicu *overfitting* (Mehdi, Ali, & Hamid, 2025). Implementasi SMOTE secara konsisten terbukti menaikkan nilai F1-Score pada data tabular yang tidak seimbang di berbagai domain (Bayu Nur, Nadia Annisa, & Teguh, 2025).

Sebagai algoritma berbasis *ensemble learning*, *Extreme Gradient Boosting (XGBoost)* dikenal memiliki performa *superior*, kecepatan komputasi yang tinggi, serta kemampuan regulasi yang optimal dalam menangani data tabular kompleks (Fitri Permata & Rini, 2025). Keandalan XGBoost dalam mengelola data tidak seimbang juga dapat diperkuat melalui modifikasi istilah regularisasi (Ping & Yiqiao Jia and Youlin, 2022) serta optimasi hyperparameter (Ginanjari, Hardian, & Mukti, 2022). Guna meningkatkan stabilitasnya, riset mutakhir mulai memadukan XGBoost dengan variasi penyeimbangan data seperti SMOTE-Tomek Links (Yuliana, Robet, & Leony, 2026) *Borderline-SMOTE*, maupun *Adaptive Synthetic (ADASYN)* yang dioptimalkan menggunakan *framework Optuna* (Fastabyq Ad'ha Putra & Defri, 2026).

Meskipun kombinasi SMOTE dan XGBoost sering kali menghasilkan metrik performa yang mendekati sempurna, model klasifikasi pada data transaksi keuangan sangat rentan terjebak dalam fenomena data *leakage* (kebocoran data). Kebocoran data terjadi ketika fitur finansial pasca-transaksi seperti nominal akhir pembayaran yang otomatis berubah menjadi nol setelah dibatalkan sistem secara tidak sengaja dilibatkan dalam proses pelatihan model (*training*). Akibatnya, model terlihat memiliki akurasi yang sangat tinggi saat diuji, namun gagal total saat diimplementasikan pada data baru di waktu nyata (*real-time execution*).

Penelitian ini bertujuan untuk mengoptimalkan algoritma XGBoost berbasis SMOTE dengan menerapkan evaluasi kritis melalui pendekatan analisis fitur multi-skenario. Nilai kebaruan (*novelty*) dari penelitian ini terletak pada rekonstruksi fitur untuk mengeliminasi dampak bias data *leakage* finansial, sehingga dapat dilakukan pengungkapan pengetahuan murni (*knowledge discovery*). Melalui pemisahan skenario pengujian, penelitian ini tidak hanya berfokus pada perolehan akurasi tinggi yang jujur dan reliabel, melainkan juga mengidentifikasi faktor logistik murni yang menjadi pemicu utama keputusan konsumen dalam membatalkan pesanan di platform *e-commerce*.

2. METODE PENELITIAN

Penelitian ini dilaksanakan melalui alur eksperimental kuantitatif yang terstruktur secara sistematis. Tahapan penelitian dirancang secara kronologis yang meliputi pengumpulan data dari repositori publik, pra-pemrosesan data (*data preprocessing*), pembagian subset data menggunakan *Stratified Sampling*, penyeimbangan distribusi kelas menggunakan teknik SMOTE pada subset data

pelatihan, pembuatan model klasifikasi menggunakan algoritma XGBoost berbasis multi-skenario, hingga evaluasi performa model secara komparatif.

2.1. Pengumpulan Data dan Definisi Variabel

Dataset yang digunakan dalam penelitian ini diperoleh melalui repositori publik Kaggle, sebuah platform penyedia data terbuka (*open-source data repository*) internasional yang jamak digunakan dalam eksperimen pembelajaran mesin. Data transaksi riil yang diunduh berformat CSV bernama *all_months_clean.csv*. Variabel target (*ground truth*) ditentukan dari kolom Status Pesanan, yang kemudian ditransformasikan menjadi representasi biner melalui proses *label encoding*: nilai 1 merepresentasikan pesanan dengan status "Batal" (sebagai kelas minoritas) dan nilai 0 merepresentasikan pesanan dengan status "Selesai" (sebagai kelas mayoritas) (Arif Fitra & Rozaq Isnaini, 2025).

Fitur prediktor kuantitatif dan kualitatif yang diekstraksi dari dataset Kaggle ini meliputi dimensi kuantitas (*total_qty*), dimensi berat (*total_weight_gr*), dimensi diskon (*Total Diskon*), variabel finansial (*Total Pembayaran*), serta rangkaian variabel operasional logistik (*Perkiraan Ongkos Kirim*, *Ongkos Kirim Dibayar oleh Pembeli*, *Opsi Pengiriman*, *Metode Pembayaran*, dan variabel geografis (*Provinsi*). Penggunaan dataset transaksional dari platform terbuka ini ditujukan untuk menjamin transparansi eksperimen, reproduksibilitas model komputasi, serta objektivitas analisis variabel logistik yang memicu pembatalan belanja online.

2.2. Desain Fitur Multi-Skenario

Untuk mendeteksi sekaligus mengeliminasi dampak fenomena *data leakage* (kebocoran data) finansial yang kerap diabaikan pada riset-riset terdahulu, desain eksperimen dalam penelitian ini dibagi menjadi dua skenario fitur yang independen:

1. Skenario 1 (*Model Baseline*): Menggunakan seluruh dimensi fitur prediktor bawaan yang tersedia di dalam dataset asli Kaggle, yaitu: *total_qty*, *total_weight_gr*, *Total Diskon*, *Total Pembayaran*, *Perkiraan Ongkos Kirim*, *Ongkos Kirim Dibayar oleh Pembeli*, *Opsi Pengiriman*, *Metode Pembayaran*, dan *Provinsi*. Skenario ini berfungsi sebagai pembanding performa dasar.
2. Skenario 2 (*Model Optimasi Logistik*): Mengeklusi fitur finansial *Total Pembayaran* dari ruang dimensi data. Skenario ini murni hanya mengandalkan variabel perilaku logistik, kuantitas, geografis, dan diskon dasar untuk melatih model klasifikasi. Skenario ini menyimulasi sistem prediksi waktu nyata sebelum transaksi difinalisasi oleh sistem utama platform.

2.3. Pembagian Subset Data (*Data Splitting*)

Pada masing-masing skenario, dataset dibagi menjadi dua subset independen dengan proporsi 80% sebagai data pelatihan (*training data*) dan 20% sebagai data pengujian (*testing data*) menggunakan metode *Stratified Train-Test Split* dengan mengunci parameter acak *random_state= 42*. Pendekatan *stratified* ini sangat krusial digunakan untuk memastikan bahwa rasio perbandingan kelas target antara pesanan "Selesai" dan "Batal" pada data pelatihan maupun data pengujian tetap terjaga secara konsisten sesuai dengan proporsi distribusi data aslinya di dunia nyata, sehingga mencegah terjadinya bias pembagian data.

2.4. Penyeimbangan Kelas Menggunakan SMOTE

Karena data transaksi *e-commerce* memiliki karakteristik ketidakseimbangan kelas (*class imbalance*) yang masif di mana kelas pesanan "Batal" bersifat minoritas, maka diterapkan algoritma *Synthetic Minority Over-sampling Technique* (SMOTE) untuk menyeimbangkan distribusi data. Masalah ketidakseimbangan ulasan konsumen dan data transaksi pada platform *e-commerce* Indonesia terbukti dapat menurunkan keandalan generalisasi model jika tidak ditangani dengan teknik resampling yang tepat.

Secara matematis, SMOTE bekerja dengan cara mencari *kk*-tetangga terdekat (*k-nearest neighbors*) pada ruang fitur kelas minoritas, kemudian melakukan interpolasi linier untuk menciptakan sampel-sampel sampel baru menggunakan persamaan (1):

$$x_{new} = x_i + \lambda \times (x_{zi} - x_i) \quad (1)$$

Di mana x_i merupakan instans data dari kelas minoritas, x_{zi} merupakan salah satu tetangga terdekat yang dipilih secara acak, dan λ adalah bilangan acak berinterval $[0, 1]$. Pada penelitian ini, nilai parameter $k_{neighbors}$ ditetapkan sebesar 5. Langkah metodologis terpenting dalam penelitian ini adalah penerapan SMOTE dilakukan secara eksklusif hanya pada subset data pelatihan (*training data*). Data pengujian (*testing data*) sama sekali tidak dikenakan proses SMOTE untuk menjaga keaslian data uji dan mencegah bias optimasi semu pada hasil pengujian akurasi.

2.5. Pemodelan Berbasis Extreme Gradient Boosting (XGBoost)

Proses klasifikasi risiko pembatalan pesanan diimplementasikan menggunakan algoritma *Extreme Gradient Boosting* (XGBoost). XGBoost merupakan algoritma berbasis *ensemble learning* yang mengoptimalkan fungsi tujuan (*objective function*) dengan menggabungkan fungsi kerugian formal (*loss function*) dan suku regulasi guna mengendalikan kompleksitas model dan mencegah *overfitting*. Parameter operasional algoritma XGBoost diset secara seragam untuk kedua skenario, yaitu jumlah pohon keputusan ($n_{estimators}=100$), kedalaman maksimum pohon ($max_depth=6$), serta tingkat pembelajaran ($learning_rate=0.1$).

2.6. Evaluasi Performa Model

Kinerja model diuji secara komparatif menggunakan instrumen statistik standar untuk pengujian klasifikasi machine learning, meliputi:

- Confusion Matrix:** Untuk memetakan jumlah hasil prediksi benar dan salah (*True Positive, True Negative, False Positive, False Negative*).
- Accuracy Score:** Mengukur proporsi keseluruhan prediksi yang benar dari model.
- Precision & Recall:** Mengukur ketepatan model mendeteksi kelas target dan kemampuan model menjangkau seluruh data aktual kelas "Batal".
- F1-Score:** Nilai rata-rata harmonik antara *Precision* dan *Recall* untuk mengukur ketangguhan model pada kelas tidak seimbang.
- Area Under ROC Curve (AUC):** Mengukur kemampuan diskriminatif model dalam memisahkan kedua kelas status pesanan.


Langkah akhir dari metode penelitian ini adalah melakukan bedah *Feature Importance* berbasis arsitektur internal XGBoost untuk melakukan *knowledge discovery* mengenai variabel logistik murni yang menjadi pemicu paling dominan dari pembatalan transaksi *e-commerce*.

3. HASIL DAN ANALISIS

Eksperimen komputasi dijalankan secara terpisah menggunakan bahasa pemrograman Python untuk mengevaluasi dua skenario pemodelan klasifikasi XGBoost berbasis SMOTE. Analisis dilakukan secara berjenjang, dimulai dari pembuktian fenomena data leakage hingga penemuan pengetahuan terkait faktor logistik melalui visualisasi metrik performa formal.

3.1. Evaluasi Kinerja Eksperimen Skenario 1 (Baseline)

Pada Skenario 1, model XGBoost dilatih menggunakan seluruh fitur bawaan yang diekstraksi dari dataset Kaggle tanpa melakukan eliminasi variabel finansial pasca-transaksi. Evaluasi kinerja kuantitatif model pada skenario ini mencatat nilai *Accuracy Score* yang sangat tinggi yaitu sebesar 0,9950 (99,50%). Ketangguhan diskriminasi model juga terlihat sempurna dengan capaian skor Area Under ROC Curve (AUC) sebesar 0.9985. Penyebaran prediksi riil dari model baseline ini digambarkan secara mendetail melalui Confusion Matrix yang tersaji pada Gambar 1.

Gambar 1. Confusion Matrix Skenario 1 (*Baseline*)

Berdasarkan matriks evaluasi pada Gambar 1, nilai **Precision** untuk kelas "Batal" (1) mencapai 0,96 (96%), yang berarti dari seluruh pesanan yang diprediksi batal, hanya ada 21 pesanan yang meleset. Sementara itu, nilai **Recall** mencatat angka sempurna yaitu 1,00 (100%), menandakan model berhasil menjaring seluruh data aktual pesanan batal (566 sampel) tanpa ada yang terlewat menjadi *False Negative*. Nilai rata-rata harmonik atau *F1-Score* yang dihasilkan adalah sebesar 0,98.

Namun, melalui *Feature Importance* internal XGBoost, ditemukan bahwa tingginya akurasi ini bersifat semu (*pseudo-accuracy*). Fitur Total Pembayaran mendominasi nilai kepentingan fitur sebesar 0,9943 (99,43%). Secara fundamental, hal ini membuktikan terjadinya fenomena *data leakage* (kebocoran data). Di dalam sistem operasional *e-commerce* nyata, nilai pada kolom Total Pembayaran otomatis diubah oleh sistem menjadi nol *setelah* tindakan pembatalan terjadi. Akibatnya, model Skenario 1 tidak dapat diimplementasikan di dunia nyata karena variabel prediktor utamanya baru terbentuk setelah status target itu sendiri diputuskan oleh konsumen.

3.2. Evaluasi Kinerja Eksperimen Skenario 2 (Tanpa Total Pembayaran)


Untuk mengeliminasi bias kebocoran data finansial dan menguji dependensi murni model terhadap variabel pra-finalisasi transaksi, dilakukan rekonstruksi fitur pada Skenario 2 dengan mengeklusi kolom Total Pembayaran. Hasil pengujian komparatif metrik klasifikasi untuk Skenario 2 dirangkum secara komprehensif pada Tabel 1.

Tabel 1. Hasil pengujian Skenario 2

Kelas / Label	Precision	Recall	F1-Score	Support
Selesai (0)	0.94	0.87	0.90	3604
Batal (1)	0.44	0.66	0.53	566
Accuracy Score	0.84 (83.96%)			4170
Area Under ROC (AUC)	0.87 (86.98%)			4170

Sebagaimana dipaparkan pada Tabel 1, penghapusan fitur finansial yang bocor berdampak pada penurunan nilai *Accuracy Score* menjadi 0,8396 (83,96%). Nilai Precision untuk kelas minoritas ("Batal") mengalami penyesuaian menjadi 0,44, sedangkan nilai Recall berada pada angka 0,66. Meskipun terjadi penurunan metrik performa jika dibandingkan dengan Skenario 1, model Skenario 2 mencatat nilai *Area Under ROC Curve* (AUC) sebesar 0,8698 (86,98%) yang merepresentasikan performa klasifikasi yang masuk ke dalam kategori baik (Good Classification). Model ini dinilai jauh lebih jujur dan valid untuk diimplementasikan secara langsung pada sistem berjalan (*production environment*).

Rincian klasifikasi dari performa riil model XGBoost berbasis SMOTE tanpa fitur finansial ini disajikan melalui diagram peta *Confusion Matrix* pada Gambar 2.




Gambar 2. Confusion Matrix eksperimen 2

Merujuk pada Gambar 2, model Skenario 2 berhasil menebak dengan benar 374 pesanan batal dari total 566 data aktual (*True Positive*). Nilai *F1-Score* sebesar 0,53 mengonfirmasi bahwa penyeimbangan data latih menggunakan metode SMOTE sukses menjaga kemampuan generalisasi model dalam mengenali karakteristik perilaku pembatalan kelas minoritas, di tengah kepungan data pesanan selesai yang berjumlah 3.604 sampel data uji (*True Negative* = 3.127).

3.3. Analisis Faktor Logistik Pemicu Pembatalan (*Knowledge Discovery*)

Ketika fitur finansial dominan dihilangkan pada Skenario 2, algoritma XGBoost melakukan komputasi ulang untuk mencari korelasi tersembunyi dari sisa variabel yang tersedia. Berikut hasil pembobotan *Feature Importance* untuk Skenario 2.



Gambar 3. *Feature Importance* eksperimen 2

Hasil ekstraksi pembobotan *Feature Importance* murni untuk Skenario 2 disajikan secara urut pada Tabel 4.

Tabel 2. Hasil Pembobotan *Feature Importance* Skenario 2

Variabel Prediktor / Fitur	Nilai Kepentingan (<i>Feature Importance Weight</i>)
Ongkos Kirim Dibayar oleh Pembeli	0.771080
Opsi Pengiriman	0.086117
Metode Pembayaran	0.046704
Perkiraan Ongkos Kirim	0.044500
total_qty	0.016553
Provinsi	0.015537
total_weight_gr	0.012427
Total Diskon	0.007083
Ongkos Kirim Dibayar oleh Pembeli	0.771080

Berdasarkan data empiris pada Tabel 4, sektor logistik mengambil alih kendali prediksi secara mutlak, dipimpin oleh variabel "Ongkos Kirim Dibayar oleh Pembeli" dengan bobot kepentingan sebesar 77,10%.

Analisis ini menunjukkan bahwa sosiogeografis dan perilaku psikologis konsumen *e-commerce* di Indonesia sangat sensitif terhadap biaya pengiriman fisik barang belanjaan mereka. Ketika nominal akhir ongkos kirim yang dibebankan dirasa terlalu tinggi atau melebihi ekspektasi rasional konsumen, variabel ini langsung memicu stimulus psikologis instan bagi pembeli untuk membatalkan pesanan secara sepihak sebelum barang dikemas oleh penjual.

Faktor logistik pendukung lainnya seperti Opsi Pengiriman (8,61%) dan Metode Pembayaran (4,67%) turut memperkuat kecenderungan ini. Pola pembatalan pesanan terdeteksi kerap terjadi pada transaksi yang mengombinasikan pilihan kurir reguler dengan metode pembayaran *Cash on Delivery* (COD). Hal ini terjadi karena kombinasi tersebut sama sekali tidak menuntut komitmen finansial di awal dari sisi konsumen, sehingga mempermudah pembeli untuk melakukan pembatalan pesanan kapan saja tanpa adanya konsekuensi kerugian material langsung. Temuan ini membuktikan bahwa faktor operasional logistik, dan bukan nilai diskon produk, merupakan pemicu utama di balik tingginya risiko pembatalan transaksi pada industri belanja *online*.

4. KESIMPULAN

Berdasarkan serangkaian eksperimen klasifikasi risiko pembatalan pesanan menggunakan algoritma XGBoost berbasis SMOTE, penelitian ini berhasil membuktikan bahwa keterlibatan fitur finansial pasca transaksi seperti Total Pembayaran memicu fenomena *data leakage* (kebocoran data) yang menghasilkan akurasi semu (*pseudo-accuracy*) sebesar 99,50%. Setelah rekonstruksi fitur dilakukan dengan mengeklusi variabel finansial tersebut pada Skenario 2, model XGBoost mampu memberikan performa prediksi yang jujur, objektif, dan handal dengan capaian *Accuracy Score* sebesar 83,96% dan nilai *Area Under ROC Curve* (AUC) sebesar 86,98% yang dikategorikan sebagai performa klasifikasi baik (*Good Classification*). Penerapan metode penyeimbangan data SMOTE terbukti krusial dalam mempertahankan sensitivitas model pada data uji yang tidak seimbang, ditunjukkan dengan nilai *Recall* kelas target sebesar 0,66 dan nilai *F1-Score* sebesar 0,53.

Melalui pendekatan analisis kepentingan fitur (*Feature Importance*), berhasil mengungkap bahwa faktor operasional logistik merupakan pemicu paling dominan terhadap keputusan pembatalan pesanan oleh konsumen di platform *e-commerce*. Fitur Ongkos Kirim Dibayar oleh Pembeli mendominasi bobot kepentingan secara mutlak sebesar 77,10%, disusul oleh variabel Opsi Pengiriman sebesar 8,61% dan Metode Pembayaran sebesar 4,67%. Temuan empiris ini mengindikasikan bahwa perilaku transaksional konsumen belanja online di Indonesia sangat sensitif terhadap biaya pengiriman fisik barang, serta memiliki kecenderungan pembatalan yang tinggi pada metode pembayaran *Cash on*

Delivery (COD) yang dikombinasikan dengan kurir reguler karena tidak adanya komitmen finansial di awal transaksi. Model waktu nyata (*real-time model*) tanpa bias finansial ini dapat diintegrasikan secara valid oleh pengembang sistem platform *e-commerce* sebagai instrumen mitigasi risiko operasional logistik gudang sebelum pesanan masuk ke fase pengiriman massal.

UCAPAN TERIMA KASIH

Penulis menyampaikan rasa terima kasih dan apresiasi yang sebesar-besarnya kepada Program Studi Teknik Informatika, Jurusan Teknik Elektro serta institusi Politeknik Negeri Semarang (Polines) atas dukungan fasilitas, ekosistem akademik, dan atmosfer riset yang kondusif sehingga penelitian ini dapat diselesaikan dengan baik. Apresiasi yang mendalam juga penulis haturkan kepada Dewan Redaksi beserta tim penelaah Jurnal ELKOM (Jurnal Elektronika dan Komputer) atas kesempatan, ruang publikasi, serta rekomendasi peninjauan (*review*) ilmiah yang sangat berharga demi peningkatan kualitas manuskrip ini. Terakhir, ungkapan terima kasih yang tulus disampaikan kepada seluruh anggota Tim atas kolaborasi yang solid, diskusi teoretis yang konstruktif, serta bantuan teknis yang konsisten sejak tahap perancangan simulasi multi-skenario, penanganan kebocoran data (*data leakage*), hingga finalisasi draf artikel ini.

REFERENSI

- [1] S. Achmad Fauzihan Bagus, R. Basuki, and J. Achmad, "KLASIFIKASI INDEKS STANDAR PENCEMARAN UDARAN (ISPU) MENGGUNAKAN ALGORITMA XGBOOST DENGAN TEKNIK IMBALANCED DATA (SMOTE)," JITET (Jurnal Informatika dan Teknik Elektro Terapan), pp. 2190–2200, 2024.
- [2] S. Arif Fitra and N. Rozaq Isnaini, "OPTIMIZING GPT AND INDOBERT FOR SENTIMENT ANALYSIS AND CONSUMER TREND PREDICTION ON LAZADA PRODUCT REVIEWS," JIKO (Jurnal Informatika dan Komputer), pp. 113–120, 2025.
- [3] S. Bayu Nur, M. Nadia Annisa, and T. Teguh, "Analisis Sentimen Ulasan Pengguna Aplikasi Threads di Google Play Menggunakan Algoritma XGBoost Dengan Penguatan SMOTE," Jurnal Informatika dan Tekonologi Komputer, pp. 120–130, 2025.
- [4] S. Fastabyq Ad'ha Putra and K. Defri, "Application of ADASYN and Optuna in the XGBoost Algorithm for Stunting Detection," Journal of Applied Informatics and Computing (JAIC), vol. 10, pp. 1006–1014, 2026.
- [5] S. Fitri Permata and B. Rini, "Implementasi Extreme Gradient Boosting (XGBoost) untuk Klasifikasi Penggunaan Ulang Asisten AI," Jurnal Pustaka Data, vol. 5, pp. 303–310, 2025.
- [6] A. Ginanjar, O. Hardian, and S. Mukti, "Optimasi Algoritma XGBoost Classifier Menggunakan Hyperparameter Gridsearch dan Random Search Pada Klasifikasi Penyakit Diabetes," Informatics Journal (INFORMAL), vol. 7, pp. 193–198, 2022.
- [7] I. Mehdi, B. Ali, and R. A. Hamid, "Comprehensive Analysis of Random Forest and XGBoost Performance with SMOTE, ADASYN, and GNUS Under Varying Imbalance Levels," Technologies, pp. 1–40, 2025.
- [8] Z. Ping and Y. Jia and Youlin S., "Research and application of XGBoost in imbalanced data," International Journal of Distributed Sensor Networks, vol. 18, pp. 1–10, 2022.
- [9] Yuliana, Robet, and H. Leony, "Comparative Analysis of XGBoost, KNN, and SVM Algorithms for Heart Disease Prediction Using SMOTE-Tomek Balancing," Sinkron: Jurnal dan Penelitian Teknik Informatika, pp. 305–316, 2026.

NOMENKLATUR

- **X**: Matriks fitur/variabel prediktor berdimensi $n \times m$ sebelum pemrosesan.
- **y**: Vektor target biner berdimensi $n \times 1$ (0 untuk pesanan Selesai, 1 untuk pesanan Batal).

- ***X_{train}***: Subset matriks fitur yang dialokasikan khusus untuk proses pelatihan model (80% dari dataset).
- ***X_{test}***: Subset matriks fitur yang dialokasikan khusus untuk proses pengujian model (20% dari dataset).
- ***X_{resampled}***: Matriks fitur baru hasil sintesis data kelas minoritas menggunakan metode SMOTE.
- ***P***: Metrik kedekatan (Precision) dalam mengklasifikasikan kelas target secara tepat.
- ***R***: Metrik sensitivitas (Recall) dalam menjangkau keseluruhan sampel aktual kelas target.
- ***F1***: Skor rata-rata harmonik (F1-Score) yang menyeimbangkan nilai Precision dan Recall.
- ***AUC***: *Area Under the Receiver Operating Characteristic Curve* (Luas daerah di bawah kurva karakteristik operasi untuk mengukur performa diskriminasi model).
- ***COD***: *Cash on Delivery* (Sistem pembayaran tunai di tempat saat barang logistik tiba di tangan pembeli).
- ***ROC***: *Receiver Operating Characteristic* (Kurva yang memetakan hubungan tingkat sensitivitas dan spesifisitas model).
- ***SMOTE***: *Synthetic Minority Over-sampling Technique* (Algoritma berbasis k-nearest neighbors untuk mereplikasi sampel sintetis pada kelas minoritas yang mengalami ketidakseimbangan data).
- ***XGBoost***: *Extreme Gradient Boosting* (Algoritma *ensemble learning* berbasis *decision tree* dengan penguatan gradien tingkat lanjut).