



Analisis Prediksi Pembatalan Pesanan E-Commerce Menggunakan Algoritma Random Forest dan XGBoost untuk Mitigasi Kerugian Finansial

Ayla Zhafira¹, Fitri Yunita²

^{1,2}Program Studi Sistem Informasi, Fakultas Teknik dan Ilmu Komputer, Universitas Islam Indragiri
aylaazhafira@gmail.com, fitriyun@gmail.com

Abstrak

Pembatalan pesanan (*order cancellation*) memicu inefisiensi operasional dan kerugian biaya tertanam (*sunk cost*) logistik pada industri *e-commerce* di Indonesia. Penelitian ini mengintegrasikan analisis biaya (*cost analysis*) ke dalam sistem prediksi pembatalan berbasis *machine learning* untuk menjembatani performa teknis dengan dampak finansial industri. Analisis komparatif dilakukan menggunakan algoritma Random Forest dan XGBoost yang dikombinasikan dengan teknik SMOTE pada dataset berisi 20.848 transaksi. Hasil pengujian menunjukkan XGBoost lebih unggul dengan akurasi global 86,63% dan *recall* 37%, serta berhasil mendeteksi secara akurat 209 transaksi batal pada data uji. Melalui simulasi parameter biaya, XGBoost terbukti menyelamatkan anggaran operasional sebesar Rp6.036.879, memberikan efisiensi moneter lebih tinggi senilai Rp1.117.800 dibandingkan Random Forest. Analisis *feature importance* mengonfirmasi bahwa opsi pengiriman, perkiraan ongkos kirim, dan lokasi geografis merupakan tiga faktor kunci pemicu pembatalan. Penerapan model sebagai sistem peringatan dini yang terintegrasi dengan strategi mitigasi proaktif, seperti verifikasi multikanal dan pembayaran pra-bayar, menawarkan solusi aplikatif untuk menekan kebocoran finansial sekaligus menjaga profitabilitas platform.

Kata Kunci: Pembatalan Pesanan, E-Commerce, Random Forest, Xgboost, Kerugian Finansial.

1. Pendahuluan

Pertumbuhan pesat industri *e-commerce* di Indonesia telah mengubah lanskap perdagangan ritel secara fundamental. Berdasarkan laporan terbaru APJII, penetrasi internet nasional telah mencapai 80,66% pada tahun 2025 (Yonatan, 2025), yang berkontribusi pada nilai transaksi masif hingga Rp4.500 triliun per tahun menurut data Bank Indonesia (Andrianto, 2025). Namun, di balik pertumbuhan volume transaksi tersebut, industri ini masih dihadapkan pada risiko ketidakpastian dalam bentuk pembatalan pesanan (*order cancellation*) yang dapat terjadi sejak tahap pesanan masuk hingga proses pengiriman. Fenomena ini menimbulkan dampak finansial signifikan karena biaya pengambilan barang (*picking costs*) merupakan komponen tertinggi dalam pemenuhan pesanan, di mana aktivitas operasional mulai dari pengemasan hingga *reverse logistics* dapat menyerap hingga sepertiga dari total biaya operasional perusahaan (Rodríguez-García et al., 2023). Dampak ini diperparah oleh kerugian keuntungan (*profit losses*) yang memaksa platform menyesuaikan kembali struktur biaya guna menutupi inefisiensi akibat transaksi yang gagal (Najafi-Ghobadi et al., 2026). Selain itu, probabilitas pembatalan secara konsisten ditemukan bergantung pada waktu tunggu; semakin lama durasi tunggu dalam periode pemesanan awal, semakin tinggi pula risiko konsumen untuk membatalkan transaksi tersebut (Roosevelt et al., 2024).

Tantangan logistik kepulauan di Indonesia membuat kerugian akibat kegagalan transaksi ini menjadi jauh lebih substansial bagi pelaku pasar lokal. Biaya pengiriman antarkota yang bervariasi, mulai dari Rp7.500 untuk skala lokal hingga Rp23.000 untuk pengiriman antarpulau, berpotensi menjadi biaya tertanam (*sunk cost*) yang hilang seketika jika pembatalan terjadi setelah proses logistik dimulai (Aggarwal et al., 2023). Risiko operasional ini diperkuat oleh temuan bahwa karakteristik opsi pengiriman dan metode pembayaran berdampak signifikan terhadap tingginya angka pembatalan pesanan di berbagai platform *e-commerce* domestik (Jampur & Christmantara, 2025). Inefisiensi tersebut tidak hanya menyebabkan kerugian materi secara langsung, tetapi juga mengganggu manajemen stok akibat tertahannya barang selama proses transaksi berjalan, yang berujung pada hilangnya momentum penjualan kepada calon pembeli potensial. Terlepas dari besarnya dampak ekonomi tersebut, platform saat ini umumnya masih beroperasi secara reaktif dengan menangani pembatalan setelah peristiwa terjadi. Keterbatasan sistem konvensional dalam memahami pola perilaku konsumen yang kompleks menyebabkan manajemen kehilangan momentum intervensi proaktif, sehingga mekanisme peringatan dini berbasis kecerdasan buatan (AI) sebelum biaya operasional dikeluarkan sangat dibutuhkan untuk menghentikan pemborosan sumber daya ini.


Penerapan model prediksi untuk mengantisipasi pembatalan pesanan telah diuji melalui berbagai algoritma *machine learning*, salah satunya oleh (Sari et al., 2024) yang menemukan bahwa pendekatan *ensemble learning* seperti Random Forest dan XGBoost memberikan performa paling tangguh dibandingkan model MLP dan SVM.

Penelitian tersebut kemudian diperluas oleh (Sari et al., 2025) menjadi model multi-kelas melalui teknik seleksi fitur guna meningkatkan efisiensi pendeteksian pola transaksi yang kompleks. Keberhasilan literatur tersebut membuktikan ketangguhan Random Forest dan XGBoost melandasi alasan utama pemilihan kedua algoritma dalam penelitian ini. Karakteristik perilaku konsumen yang memengaruhi akurasi prediksi ini dikembangkan oleh (Şahinbaş, 2022), yang menemukan bahwa pemanfaatan variabel riwayat transaksi historis disertai *parameter tuning* mampu menghasilkan tingkat presisi model yang optimal. Temuan tersebut menegaskan bahwa pemahaman faktor dominan seperti jumlah pesanan sebelumnya sangat diperlukan sebagai dasar intervensi strategis pengelola *marketplace*. Urgensi interpretabilitas model dikembangkan lebih lanjut oleh (Tuba Irmak, 2025) menggunakan teknik pembobotan fitur seperti SHAP (*Shapley Additive Explanations*) untuk mengidentifikasi variabel sensitif pembatalan agar manajemen dapat merumuskan langkah intervensi tepat target. Relevansi studi ini mendasari penerapan metode *feature importance* dalam penelitian ini untuk mengurai faktor penentu pembatalan secara objektif. Sementara itu, karakteristik pasar domestik Indonesia dipotret secara spesifik oleh (Koten et al., 2026) menggunakan dataset transaksi lokal periode 2023-2025 dengan mengombinasikan Random Forest dan teknik SMOTE. Hasil riset mereka mengonfirmasi bahwa metode pembayaran seperti COD dan *Online Payment* merupakan pemicu utama pembatalan, yang menjadi acuan penting dalam aspek validasi geografis serta penanganan bias data. Rangkaian literatur terdahulu ini memberikan pemahaman komprehensif mengenai batas kemampuan teknis model klasifikasi saat ini.

Meskipun literatur terdahulu memberikan fondasi kuat dalam aspek klasifikasi, evaluasi yang terpaku pada optimasi metrik akurasi menyisakan jarak pemisah dengan kebutuhan praktis industri. Fokus riset yang dominan pada performa komputasi menyebabkan dampak ekonomi riil belum dipertimbangkan secara komprehensif. Implikasinya, model prediksi yang dihasilkan sulit diadopsi praktisi bisnis akibat tiadanya justifikasi nilai finansial serta belum dirumuskannya strategi mitigasi proaktif yang konkret. Kondisi tersebut semakin menantang dalam ekosistem domestik, mengingat kelangkaan studi komparatif yang menyertakan dimensi analisis ekonomi guna menekan risiko kebocoran anggaran logistik di Indonesia. Upaya menjembatani keterbatasan tersebut diwujudkan melalui pelaksanaan analisis komparatif menggunakan algoritma Random Forest dan XGBoost pada dataset “Indonesia E-Commerce Sales & Shipping 2023-2025” yang mencakup 20.848 data transaksi. Random Forest dipilih karena ketangguhannya mengelola data non-linear tanpa *overfitting* melalui pembobotan *feature importance* (Bhuria et al., 2025), sedangkan XGBoost diterapkan karena keunggulannya dalam optimasi *loss function* secara cepat dan adaptif (Rafi et al., 2024). Selain itu, teknik SMOTE diimplementasikan untuk mengatasi ketidakseimbangan kelas agar model mampu mengenali pola pembatalan pada kelas minoritas secara objektif dan akurat (Bhuria et al., 2025). Tujuan utama penelitian ini adalah menyelaraskan performa teknis *machine learning* dengan kebutuhan strategis industri *e-commerce* melalui integrasi analisis biaya. Melalui kuantifikasi kerugian operasional yang dapat dicegah secara riil serta perumusan strategi mitigasi proaktif, hasil pengujian diharapkan memberikan solusi praktis bagi pelaku usaha dalam menjaga stabilitas profitabilitas bisnis. Simulasi skenario intervensi konkret berdasarkan hasil prediksi model terbaik diarahkan agar sistem tidak sekadar menjadi alat evaluasi komputasi, melainkan bertransformasi menjadi instrumen pengambilan keputusan operasional (*early warning system*) yang siap diadopsi secara aplikatif oleh industri *e-commerce* di Indonesia.

2. Metode Penelitian

Penelitian ini bertujuan untuk mengomparasikan algoritma Random Forest dan XGBoost pada prediksi pembatalan pesanan (*order cancellation*) pelanggan *e-commerce* dengan evaluasi berbasis *cost analysis*. Untuk mencapai tujuan tersebut, seluruh tahapan penelitian dilaksanakan secara sistematis dan terstruktur, mulai dari pengolahan data, pembagian dataset, penanganan *class imbalance* menggunakan SMOTE, implementasi model, hingga analisis dampak finansial berdasarkan kerugian logistik akibat kegagalan deteksi dini. Alur penelitian tersebut diilustrasikan secara mendetail pada Gambar 1.



Gambar 1. Alur Penelitian Prediksi Pembatalan Pesanan E-Commerce

2.1. Pengumpulan dan Pra-pemrosesan Data

Penelitian ini memanfaatkan sumber data sekunder yang diperoleh melalui platform Kaggle dengan judul “Indonesia E-Commerce Sales & Shipping 2023-2025”. Dataset tersebut memuat 20.848 entri transaksi yang merepresentasikan aktivitas belanja daring di Indonesia, sehingga memberikan gambaran yang cukup luas mengenai perilaku konsumen. Informasi yang tersedia mencakup berbagai variabel mulai dari profil transaksi, metode pembayaran, hingga rincian logistik yang menjadi indikator penting dalam mendeteksi pola pembatalan pesanan. Rincian mengenai struktur dan fungsi dari setiap fitur dalam dataset tersebut disajikan pada Tabel 1, namun perlu dicatat bahwa beberapa fitur akan dieliminasi pada tahap seleksi fitur demi menjaga validitas model.

Tabel 1. Deskripsi Fitur Dataset

No	Nama Fitur	Jumlah Data	Tipe Data	Keterangan
1	order_id	20.848	object	ID unik untuk setiap transaksi
2	total_qty	20.848	int64	Jumlah produk dalam satu pesanan
3	total_weight_gr	20.848	int64	Total berat pesanan dalam satuan gram
4	Total Diskon	20.848	int64	Nilai potongan harga yang diberikan
5	Status Pesanan	20.848	object	Status transaksi (Target: Batal vs Selesai)
6	Opsi Pengiriman	20.848	object	Jenis layanan logistik yang dipilih
7	Metode Pembayaran	20.848	object	Metode pembayaran (COD, Saldo, Transfer)
8	Kota/Kabupaten	20.848	object	Lokasi geografis tingkat kota/kabupaten
9	Provinsi	20.848	object	Lokasi geografis tingkat provinsi
10	Total Pembayaran	20.848	int64	Nilai akhir transaksi setelah diskon
11	Perkiraan Ongkos Kirim	20.848	int64	Estimasi biaya pengiriman yang berlaku

Tahap ini dilakukan untuk mentransformasi data mentah menjadi bentuk yang lebih representatif bagi algoritma pembelajaran mesin. Langkah awal dimulai dengan seleksi fitur melalui penghapusan kolom identitas seperti `order_id` dan `source_file` karena atribut tersebut tidak memiliki nilai statistik yang mampu menjelaskan pola pembatalan transaksi. Selain itu, penelitian ini melakukan eliminasi terhadap variabel yang berpotensi menyebabkan kebocoran data (*data leakage*), seperti jumlah barang kembali, total pembayaran, dan biaya kirim yang dibayar pembeli. Hal ini dilakukan karena variabel tersebut merupakan data pasca-transaksi yang baru diketahui nilainya setelah pesanan berakhir, sehingga tidak relevan digunakan sebagai prediktor saat pesanan baru masuk.

Proses dilanjutkan dengan melakukan konversi pada variabel kategorikal seperti Opsi Pengiriman dan Metode Pembayaran melalui teknik *encoding* agar dapat diproses secara komputasi. Untuk menjamin keseimbangan kontribusi antar fitur, penelitian ini juga menerapkan standardisasi skala melalui *StandardScaler* pada atribut numerik yang tersisa, seperti berat barang, kuantitas produk, total diskon, dan estimasi ongkos pengiriman. Prosedur ini sangat krusial guna mencegah variabel dengan rentang nilai yang besar mendominasi hasil perhitungan bobot di dalam model, sehingga stabilitas performa algoritma dapat terjaga.

2.2. Pembagian Data dan Penanganan Class Imbalance

Setelah kualitas data dipastikan optimal, langkah berikutnya adalah membagi keseluruhan dataset ke dalam dua bagian utama dengan proporsi 80% sebagai data latih dan 20% sebagai data uji. Mengingat distribusi data memiliki ketimpangan antara jumlah pesanan yang selesai dan yang batal, penelitian ini mengimplementasikan teknik SMOTE (*Synthetic Minority Over-sampling Technique*) (Chawla et al., 2002). Prosedur ini bertujuan untuk menyamakan jumlah sampel pada kelas minoritas dengan menciptakan data sintetis berdasarkan karakteristik pesanan yang batal. Dengan diterapkannya penyeimbangan ini, model diharapkan mampu mengenali ciri-ciri transaksi berisiko tinggi tanpa terpengaruh oleh dominasi data pesanan yang berhasil.

2.3. Implementasi Model Random Forest dan XGBoost

Seluruh proses eksperimen pemodelan dilakukan secara komparatif antara algoritma Random Forest dan XGBoost menggunakan lingkungan Google Colab dengan bahasa pemrograman Python 3.12. Untuk mendukung manipulasi data dan penanganan ketidakseimbangan kelas (*class imbalance*), penelitian ini memanfaatkan pustaka Pandas, NumPy, serta teknik SMOTE dari pustaka Imbalanced-learn. Pengujian performa klasifikasi dijalankan secara objektif dengan mengonfigurasi model Random Forest via pustaka Scikit-Learn pada parameter $n_estimators=100$ dan $random_state=42$, sementara model XGBoost dieksekusi via pustaka XGBoost melalui pengaturan $eval_metric='logloss'$ serta $random_state=42$. Atribut dan parameter di luar konfigurasi khusus tersebut dibiarkan beroperasi menggunakan nilai standar (*default*) dari masing-masing pustaka guna menjamin validitas metrik evaluasi dalam mendeteksi risiko pembatalan pada sistem operasional *e-commerce*. Selanjutnya, seluruh hasil analisis disajikan secara visual melalui pustaka Matplotlib dan Seaborn untuk mempermudah interpretasi serta pemahaman terhadap setiap temuan yang diperoleh.

2.4. Evaluasi Model dan Analisis Dampak Finansial

Evaluasi eksperimen dilakukan melalui dua pendekatan terintegrasi, yaitu performa teknis model dan dampak finansial operasional. Penilaian teknis diukur berdasarkan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score* yang diturunkan langsung dari *Confusion Matrix*. Sementara itu, analisis dampak finansial difokuskan pada kuantifikasi Biaya Operasional yang Terselamatkan (*Avoided Cost*) dari transaksi yang berhasil terdeteksi batal (*True Positive*) sebelum memasuki tahap pemenuhan pesanan.

Penelitian ini mengadaptasi pendekatan analisis biaya yang diusulkan dalam studi tentang sistem inventori dengan pembatalan pesanan (Aggarwal et al., 2023), yang menggunakan metode discounted cash flow untuk mengukur dampak finansial akibat refund dan biaya operasional. Dengan mengacu pada kerangka tersebut, total biaya operasional yang dapat terselamatkan (*avoided cost*) dalam penelitian ini diformulasikan sebagai berikut:

$$\text{Total Biaya Terselamatkan} = \sum_{i=1}^{TP} (\text{Ongkos Kirim}_i + \text{Biaya Packaging}) \quad (1)$$

Pada formulasi di atas, *TP (True Positive)* mengacu pada jumlah pesanan yang benar-benar batal dan berhasil diidentifikasi oleh model pada data uji. Sementara itu, Ongkos Kirim_i adalah biaya pengiriman aktual dari setiap pesanan yang masuk dalam kelompok *TP* tersebut. Adapun *Biaya Packaging* ditetapkan sebesar Rp2.000 per pesanan sebagai representasi biaya pengemasan standar di platform *e-commerce*. Dengan formulasi ini, efisiensi finansial yang dihasilkan model dapat diukur secara objektif berdasarkan kontribusi langsung dari prediksi yang akurat terhadap penghematan biaya operasional.

3. Hasil dan Pembahasan


Penjabaran hasil dalam bagian ini mencakup seluruh siklus eksperimen, mulai dari transformasi data mentah hingga pengujian komparatif model *ensemble learning*. Fokus pembahasan diletakkan pada integrasi antara evaluasi teknis dan analisis biaya (*cost analysis*). Melalui pendekatan ini, efektivitas model dapat diukur berdasarkan kemampuannya dalam memberikan perlindungan finansial bagi perusahaan terhadap risiko *sunk cost* operasional akibat pesanan yang dibatalkan.

3.1. Analisis Pra-pemrosesan dan Distribusi Data

Tahapan ini merupakan fondasi krusial untuk menjamin bahwa dataset yang digunakan memiliki kualitas dan validitas yang tinggi sebelum memasuki fase pemodelan. Prosedur pengolahan data difokuskan pada penyesuaian format serta eliminasi atribut yang dapat mengganggu objektivitas prediksi. Langkah awal dalam pengolahan data adalah melakukan seleksi fitur yang ketat guna menghindari fenomena kebocoran data (*data leakage*). Penelitian ini secara sengaja mengeluarkan variabel seperti *total_returned_qty*, Total Pembayaran, dan Ongkos Kirim Dibayar oleh Pembeli dari daftar fitur prediktor. Hal ini dilakukan karena informasi tersebut merupakan data pasca-transaksi yang secara logis membocorkan hasil akhir pesanan, sehingga model tidak akan mampu memberikan prediksi yang jujur jika variabel tersebut tetap disertakan. Setelah seleksi fitur, variabel kategorikal yang tersisa

seperti Opsi Pengiriman, Metode Pembayaran, serta informasi geografis dikonversi menggunakan teknik *One-Hot Encoding*. Selanjutnya, dilakukan standarisasi fitur menggunakan *StandardScaler* pada variabel numerik seperti berat barang dan estimasi biaya pengiriman. Prosedur ini bertujuan untuk menyelaraskan skala distribusi data agar algoritma Random Forest dan XGBoost dapat memproses informasi secara stabil tanpa terpengaruh oleh perbedaan rentang nilai antarfitur.

Ketidakeimbangan proporsi data menjadi tantangan utama pada dataset ini, mengingat jumlah transaksi yang berstatus 'Selesai' memiliki frekuensi yang jauh melampaui transaksi 'Batal'. Fenomena disparitas ini jika tidak ditangani akan memicu bias pada performa model, di mana sistem cenderung memberikan preferensi prediksi pada kelompok mayoritas hanya untuk mengoptimalkan angka akurasi global. Akibatnya, kemampuan algoritma dalam mengidentifikasi pola-pola spesifik pada pesanan yang berisiko batal menjadi lemah, yang justru merupakan fokus kritikal dari sistem peringatan dini ini. Untuk menetralkan risiko bias tersebut, penelitian ini menerapkan strategi *oversampling* melalui metode *Synthetic Minority Over-sampling Technique* (SMOTE) pada fase pra-pelatihan. Teknik ini secara artifisial mereplikasi karakteristik data pada kelas minoritas sehingga diperoleh keseimbangan proporsi dengan total sampel mencapai 28.428 entri. Dengan ketersediaan data yang setara, model memiliki peluang yang lebih objektif untuk mendalami variabel-variabel pemicu pembatalan. Transformasi sebaran data dari kondisi awal yang sangat timpang hingga menjadi distribusi yang proporsional dapat ditinjau melalui visualisasi pada Gambar 2.



Gambar 2. Perbandingan Distribusi Kelas Sebelum dan Sesudah SMOTE

3.2. Evaluasi Performa Teknis Model

Setelah melewati fase penyeimbangan data, tahap selanjutnya adalah melakukan validasi terhadap kemampuan model dalam memproses data uji (*testing set*). Fokus utama pada bagian ini adalah mengevaluasi reliabilitas antara algoritma Random Forest dan XGBoost melalui serangkaian metrik standar guna menentukan arsitektur yang paling optimal dalam mendeteksi risiko pembatalan transaksi. Efektivitas dari masing-masing model diukur berdasarkan parameter *Accuracy*, *Precision*, *Recall*, dan *F1-Score* yang secara spesifik merujuk pada performa kelas pembatalan (*Class 1*). Hasil perbandingan teknis dari kedua model *ensemble learning* tersebut dapat ditinjau pada Tabel 2.

Tabel 2. Hasil Performa Model Klasifikasi

Model	Accuracy	Precision	Recall	F1-Score
Random Forest	84.56%	42%	33%	37%
XGBoost	86.63%	52%	37%	43%

Data pada Tabel 2 mengonfirmasi bahwa XGBoost memiliki dominasi performa dibandingkan Random Forest dengan capaian *Overall Accuracy* sebesar 86.63%. Secara arsitektural, XGBoost menunjukkan kemampuan yang lebih adaptif dalam memetakan karakteristik transaksi, yang didorong oleh mekanisme *gradient boosting* untuk meminimalisir *error* pada setiap iterasi pembelajaran.


Dalam evaluasi prediktif pembatalan pesanan ini, metrik *recall* memegang peranan yang paling kritikal dibandingkan akurasi global. Urgensi *recall* bersandar pada kebutuhan operasional platform untuk menjaring sebanyak mungkin transaksi yang berisiko batal sebelum memasuki tahap pemenuhan pesanan (*fulfillment*). Semakin tinggi nilai *recall*, semakin sedikit kasus pembatalan yang lolos dari sistem peringatan dini, sehingga perusahaan dapat meminimalkan akumulasi biaya tertanam (*sunk cost*) akibat proses pengemasan dan pengiriman yang sia-sia.

Meskipun memiliki urgensi yang tinggi, hasil pengujian menunjukkan nilai *recall* pada kelas pembatalan berada pada kisaran yang terbatas, yaitu 33% untuk Random Forest dan 37% untuk XGBoost. Rendahnya capaian ini merupakan konsekuensi logis dari karakteristik ketidakeimbangan kelas (*class imbalance*) yang sangat ekstrem pada ekosistem transaksi riil. Dari total 20.848 data transaksi, populasi didominasi oleh pesanan yang sukses atau

selesai, sedangkan kasus pembatalan hanya merepresentasikan sekitar 13% hingga 14% dari keseluruhan dataset. Pola minoritas ini juga tecermin pada data uji, di mana hanya terdapat 566 pesanan batal dari total 4.120 sampel yang diuji.

Kondisi ketimpangan struktural tersebut secara matematis memicu kecenderungan algoritma klasifikasi konvensional untuk menggeser batas keputusan (*decision boundary*) ke arah kelas mayoritas demi mengejar optimalisasi nilai akurasi global (Jing et al., 2026). Fenomena ini mendegradasi sensitivitas model dalam mengenali pola-pola spesifik pada kelompok minoritas tersebut. Upaya penyeimbangan data menggunakan teknik SMOTE pada data latih yang berhasil menyamakan proporsi kelas menjadi 50:50 dengan meningkatkan volume data dari belasan ribu menjadi 28.428 entri efektif dalam memandu model mengenali karakteristik pembatalan selama fase pelatihan. Namun, dampaknya tetap terbatas saat model dihadapkan pada data uji karena data uji sengaja dipertahankan dalam distribusi aslinya yang timpang demi menyajikan simulasi evaluasi yang realistis dan objektif sesuai kondisi operasional di lapangan (Chawla et al., 2002).

Untuk membedah distribusi klasifikasi tersebut secara lebih mendalam dan melihat representasi kuantitatif dari nilai persentase *recall* yang terbatas ini, dilakukan analisis terhadap matriks konfusi (*confusion matrix*). Evaluasi ini bertujuan mengukur volume riil dari deteksi akurat pada kelas minoritas (*True Positive*). Visualisasi matriks konfusi untuk kedua algoritma disajikan pada Gambar 3.



Gambar 3. Visualisasi Confusion Matrix Random Forest dan XGBoost

Berdasarkan visualisasi pada Gambar 3, terlihat perbedaan yang signifikan dalam kuantitas deteksi pembatalan secara riil di lapangan. Model XGBoost berhasil mengenali secara tepat 209 transaksi yang berisiko batal, mengungguli Random Forest yang hanya mampu mengidentifikasi 187 transaksi. Selisih deteksi sebanyak 22 transaksi ini menegaskan bahwa XGBoost memiliki tingkat presisi yang lebih solid dalam memisahkan sinyal pembatalan dari variansi data transaksi yang tidak relevan.


Meskipun persentase *recall* teknis terkesan moderat karena keterbatasan komputasi dalam menghadapi data yang timpang, visualisasi volume deteksi ini membuktikan bahwa model tidak kehilangan relevansi praktisnya. Justru melalui angka riil *True Positive* inilah nilai guna model ditransformasikan secara objektif. Keterbatasan angka metrik komputasi murni tersebut pada akhirnya berhasil dijembatani oleh penelitian ini dengan menghubungkan hasil deteksi riil secara langsung ke dalam kalkulasi dampak finansial operasional perusahaan, yang dijabarkan pada analisis biaya di bawah ini.

3.3. Analisis Biaya (Cost Analysis)

Implementasi model prediksi ini bertujuan untuk mentransformasi performa algoritma ke dalam nilai moneter guna mengukur dampak finansialnya terhadap profitabilitas platform. Melalui analisis biaya, efektivitas sistem dinilai berdasarkan kemampuannya dalam menekan pengeluaran sia-sia (*sunk cost*) melalui identifikasi dini terhadap transaksi yang berisiko tidak terselesaikan.

Berdasarkan pengujian pada dataset, kemampuan model dalam mengenali pesanan berisiko tinggi secara langsung berkontribusi pada efisiensi anggaran perusahaan. Meskipun nilai *recall* teknis model sebelumnya berada pada kisaran sepertiga dari total kasus akibat ketimpangan data uji, integrasi analisis finansial membuktikan bahwa algoritma XGBoost tetap mampu memberikan proteksi ekonomi yang signifikan. Keberhasilan instrumen ini dalam mendeteksi secara tepat 209 titik pembatalan pada kelompok *True Positive* mengonversi performa komputasi ke dalam bentuk penyelamatan biaya operasional sebesar Rp6.036.879. Kontribusi nyata ini diharapkan dapat memberikan gambaran yang lebih komprehensif mengenai utilitas bisnis model prediksi, melengkapi evaluasi metrik akurasi global yang telah ada. Sebagai perbandingan, arsitektur Random Forest mencatatkan angka efisiensi yang lebih rendah, di mana hanya 187 pesanan yang berhasil dicegah proses operasionalnya dengan total

nilai ekonomi sebesar Rp4.919.079. Distribusi keberhasilan penyelamatan anggaran logistik antara kedua model tersebut dipaparkan secara visual pada Gambar 4.



Gambar 4. Perbandingan Total Biaya Operasional yang Terselamatkan (Avoided Cost)

Grafik pada Gambar 4 mempertegas dominasi XGBoost dalam mengamankan margin keuntungan platform. Meskipun hanya terdapat selisih 22 pesanan yang berhasil dideteksi dibandingkan pesaingnya, nilai moneter yang dihasilkan menunjukkan bahwa peningkatan sensitivitas model pada kelas minoritas mampu memberikan perbedaan dampak finansial yang signifikan bagi ekosistem bisnis. Perbedaan kapabilitas dalam menekan angka kebocoran operasional antara XGBoost dan Random Forest menjadi parameter utama dalam penentuan model terbaik. Rangkuman mengenai nilai ekonomi yang berhasil dipulihkan oleh kedua algoritma disajikan pada Tabel 3.

Tabel 3. Perbandingan Dampak Finansial Model (Cost Analysis)


Indikator Finansial	Random Forest	XGBoost
Jumlah Deteksi Akurat (TP)	187 Transaksi	209 Transaksi
Total Anggaran Terselamatkan	Rp4.919.079	Rp6.036.879
Selisih Efisiensi Moneter		Rp1.117.800

Melalui data pada Tabel 3, terlihat jelas bahwa implementasi XGBoost mampu menekan pengeluaran logistik hingga Rp1.117.800 lebih banyak daripada Random Forest. Temuan ini menunjukkan bahwa dalam konteks distribusi barang, pemilihan algoritma yang lebih peka terhadap kelas pembatalan secara otomatis memberikan proteksi finansial yang lebih kuat terhadap pemborosan biaya kurir dan pengemasan.

Eksperimen ini membuktikan bahwa akurasi global yang tinggi tidak serta-merta menjamin penyelamatan biaya maksimal jika tidak dibarengi dengan presisi pada kelas yang berisiko. XGBoost, dengan penghematan yang menembus angka Rp6 juta, membuktikan reliabilitasnya dalam mengenali profil transaksi yang tidak produktif. Setiap kegagalan sistem dalam menangkap sinyal pembatalan berimplikasi pada biaya operasional yang terbuang percuma tanpa adanya *revenue* yang masuk. Dengan demikian, XGBoost divalidasi sebagai pilihan yang paling strategis untuk diimplementasikan guna menjaga kesehatan arus kas operasional platform.

3.4. Identifikasi Faktor Kunci (Feature Importance)

Analisis terhadap tingkat kepentingan fitur dilakukan untuk membedah variabel mana yang memberikan kontribusi paling signifikan dalam membentuk keputusan prediksi model. Tahapan ini krusial untuk memahami karakteristik transaksi yang memiliki risiko pembatalan tinggi, sehingga intervensi yang dilakukan perusahaan dapat lebih tepat sasaran. Urutan faktor dominan yang memengaruhi hasil prediksi model divisualisasikan pada Gambar 5.



Gambar 5. Faktor Dominan Penyebab Pembatalan Pesanan

Berdasarkan visualisasi pada Gambar 5, variabel Opsi Pengiriman menempati posisi puncak sebagai faktor yang paling berpengaruh dalam memprediksi pembatalan transaksi. Dominasi fitur ini mengindikasikan bahwa jenis layanan logistik yang dipilih oleh konsumen berkaitan erat dengan ekspektasi durasi waktu pemenuhan pesanan. Ketidaksesuaian antara kecepatan layanan pengiriman dengan urgensi kebutuhan pembeli di lapangan sering kali menjadi pemicu utama konsumen memutuskan untuk membatalkan pesanan sebelum barang diproses lebih lanjut oleh pihak *e-commerce*.

Hal tersebut diperkuat oleh variabel Perkiraan Ongkos Kirim yang muncul sebagai faktor penentu terpenting kedua, yang menegaskan bahwa aspek beban biaya logistik merupakan determinan ekonomi yang sangat sensitif bagi pelanggan di Indonesia. Biaya pengiriman yang tinggi atau dianggap tidak kompetitif dibandingkan dengan nilai barang secara linear meningkatkan probabilitas pembatalan. Oleh karena itu, pencapaian efisiensi finansial sebesar Rp6.036.879 yang telah dibahas sebelumnya sangat bergantung pada kemampuan model dalam mengidentifikasi dinamika variabel biaya kirim ini secara akurat.

Faktor dominan ketiga yang teridentifikasi adalah variabel Kota/Kabupaten, yang menunjukkan bahwa dimensi geografis memegang peranan krusial dalam pola transaksi digital domestik. Karakteristik wilayah Indonesia yang luas dengan infrastruktur logistik yang bervariasi menyebabkan adanya perbedaan tingkat risiko di tiap daerah, di mana wilayah dengan jangkauan pengiriman yang sulit cenderung memiliki probabilitas pembatalan lebih tinggi akibat durasi tunggu yang lama. Pengetahuan mendalam mengenai faktor-faktor penyebab ini memberikan landasan data yang objektif bagi manajemen dalam merumuskan langkah-langkah perlindungan aset perusahaan secara lebih presisi.

3.5. Rekomendasi Strategi Mitigasi Proaktif

Berdasarkan integrasi antara performa teknis model dan hasil analisis biaya, penelitian ini merumuskan serangkaian strategi mitigasi operasional yang terukur. Strategi ini dirancang untuk mentransformasi hasil prediksi menjadi tindakan nyata guna meminimalkan kerugian finansial pada ekosistem *e-commerce*.

Langkah pertama dilakukan melalui penguatan sistem peringatan dini (*Early Warning System*) dengan mengintegrasikan model prediksi secara langsung ke dalam alur pemrosesan pesanan sebagai penyaring otomatis sebelum tahap pemenuhan (*fulfillment*). Transaksi yang teridentifikasi memiliki probabilitas pembatalan tinggi tidak dibatalkan secara sepihak, melainkan masuk ke dalam antrean verifikasi khusus. Mekanisme ini memungkinkan tim operasional melakukan tindakan preventif sebelum sumber daya dialokasikan untuk pengemasan dan pengiriman. Dengan memvalidasi transaksi mencurigakan sejak awal, platform dapat mengamankan potensi penghematan biaya operasional sebesar Rp6.036.879 dari pengeluaran yang tidak produktif (*sunk cost*).

Langkah kedua diwujudkan melalui implementasi skenario intervensi berbasis profil risiko yang bersifat dinamis sesuai dengan tingkat risiko transaksi. Pada tingkat verifikasi multikanal untuk pesanan dengan risiko menengah, sistem dapat memicu pengiriman notifikasi konfirmasi ulang melalui saluran komunikasi instan untuk memastikan validitas pesanan serta menekan angka pembatalan akibat kesalahan *input* atau keraguan sesaat dari sisi pembeli. Sementara itu, pada skenario penyesuaian metode pembayaran untuk transaksi dengan profil risiko tinggi yang melibatkan kombinasi opsi pengiriman dan wilayah tujuan kritis, platform dapat mengarahkan pengguna untuk menggunakan metode pembayaran non-tunai (*pre-paid*). Strategi ini sangat efektif untuk memitigasi kegagalan

pembayaran di tempat (*Cash on Delivery*) yang selama ini menjadi kontributor utama terhadap kerugian logistik perusahaan.

Langkah terakhir difokuskan pada optimasi kebijakan logistik dan skema insentif mengingat biaya pengiriman adalah komponen pengeluaran terbesar. Perusahaan dapat memberikan insentif berupa potongan ongkos kirim atau *cashback* khusus bagi pelanggan pada transaksi yang diprediksi berisiko batal namun bersedia melakukan verifikasi tambahan. Pendekatan persuasif ini bertujuan untuk menjaga keseimbangan antara kepuasan pelanggan dan perlindungan margin keuntungan. Melalui penerapan strategi logistik yang adaptif ini, perusahaan dapat mengoptimalkan stabilitas profitabilitas jangka panjang dengan menyeimbangkan biaya retensi dan efisiensi operasional.

4. Kesimpulan

Penelitian ini berhasil mengintegrasikan pendekatan *machine learning* dan analisis dampak ekonomi (*cost analysis*) untuk memprediksi risiko pembatalan pesanan pada industri *e-commerce* di Indonesia. Hasil pengujian komparatif menunjukkan algoritma XGBoost lebih unggul dan adaptif dibandingkan Random Forest, dengan akurasi global 86,63% dan *recall* kelas minoritas 37%. Melalui analisis finansial operasional, akurasi deteksi XGBoost terbukti memberikan proteksi finansial signifikan dengan menyelamatkan biaya operasional sebesar Rp6.036.879 dari potensi pengeluaran sia-sia (*sunk cost*). Analisis *feature importance* menunjukkan bahwa opsi pengiriman, perkiraan ongkos kirim, dan lokasi geografis merupakan tiga faktor paling dominan yang memicu pembatalan transaksi. Implementasi model sebagai sistem peringatan dini (*early warning system*) yang dikombinasikan dengan strategi mitigasi proaktif, seperti verifikasi multikanal dan pengkondisian metode pembayaran pra-bayar, siap diadopsi secara praktis oleh industri untuk meminimalkan inefisiensi logistik serta menjaga stabilitas profitabilitas jangka panjang. Penelitian ini memiliki keterbatasan pada rendahnya nilai *recall* (37%), yang berarti model belum optimal dalam menjaring seluruh potensi pembatalan akibat ketidakseimbangan kelas (*class imbalance*) pada data uji riil. Penelitian selanjutnya disarankan untuk mengeksplorasi teknik penanganan ketidakseimbangan data yang lebih maju, seperti SMOTE-Tomek, eksperimen berbasis algoritma *Deep Learning*, serta perluasan durasi pengambilan data multi-bulan guna meningkatkan sensitivitas deteksi model.

Reference

- Aggarwal, K. K., Ahmed, S., & Malik, F. (2023). Optimal Pricing and Advertisement Policy for an Advance Order Booking Inventory System with Order Cancellation under Inflationary Condition. *International Journal of Mathematical, Engineering and Management Sciences*, 8(5), 869–895. <https://doi.org/https://doi.org/10.33889/IJMEMS.2023.8.5.050>
- Andrianto, R. (2025). *Bos BI Ungkap Transaksi Digital RI di E-Commerce Tembus Rp4.500 T*. CNBC Indonesia. <https://www.cnbcindonesia.com/market/20251030093858-17-680593/bos-bi-ungkap-transaksi-digital-ri-di-e-commerce-tembus-rp4500-t>
- Bhuria, R., Gupta, S., Kaur, U., Bharany, S., Rehman, A. U., Hussien, S., Tejani, G. G., & Jangir, P. (2025). Ensemble - based customer churn prediction in banking : a voting classifier approach for improved client retention using demographic and behavioral data. *Discover Sustainability*, 6(28), 1–28.
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE : Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research*, 16, 321–357. <https://doi.org/https://doi.org/10.1613/jair.953>
- Jampur, F. X. A. P., & Christmantara, V. (2025). Analisis Dampak Metode Pembayaran dan Opsi Pengiriman terhadap Cancel Order Pada merchant Toko Mainan Edukasi Anak di Shopee. *Jurnal Sistem Informasi (E-Journal)*, 17(1), 70–81. <https://doi.org/https://doi.org/10.18495/jsi.v17i1.233>
- Jing, H., Zhang, H., & Wang, N. (2026). Deep Neural Mapping Unilateral Relaxed Support Vector Machines for Imbalanced Data. *Discover Computing*, 29(255), 1–21. <https://doi.org/https://doi.org/10.1007/s10791-026-10148-3>
- Koten, F., Sudiarso, I. W., Trisnawati, N. K., Pera, M. M. P., & Ndinin, M. A. (2026). Prediksi Pembatalan Pesanan E-commerce Indonesia Menggunakan Random Forest dan SMOTE. *Jurnal Manajemen Akuntansi Dan Ilmu Ekonomi*, 3(1), 8–14. <https://doi.org/https://doi.org/10.70585/jumali.v3i1.192>
- Najafi-Ghobadi, Somayeh, Kalantary, R., & Mina. (2026). Optimizing Pricing in an Online Marketplace: The Role of Buy-Now, Pay-Later Option and Return Policies. *Journal of Retailing and Consumer Services*, 88. <https://doi.org/https://doi.org/10.1016/j.jretconser.2025.104493>
- Rafi, M., Faiz, M., Varshitha, K., Varsha, T. S., Lahari, K., Haque, M. A., Pagadala, P. K., & Dutta, S. R. (2024). *Customer Churn Prediction employing Ensemble Learning*.
- Rodríguez-García, M., Bas, A. O., Prado-Prado, J. C., & Lyons, A. (2023). Fulfillment Cost Analysis in Online Grocery Retailing: Store-Based vs. Warehouse-Based Strategies. *International Journal of Production Management and Engineering*, 11(2), 127–145. <https://doi.org/https://doi.org/10.4995/ijpme.2023.18442>
- Roosevelt, M. W., Simarmata, J., Nofrisel, & Pahala, Y. (2024). Logistics Transformation in Indonesia for the E-commerce Market Industry. *Malaysian Journal of Industrial Technology (MJIT)*, 8(3), 69–81.
- Şahinbaş, K. (2022). Predicting Order Cancellations for E-Commerce Domain: A Proposed Model Based on Retailing Experience. *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 11(3), 1493–1514. <https://doi.org/https://doi.org/10.15869/itobiad.1127578>
- Sari, Z. S., Taşkapı, B., Dağdaş, G., & Akay, M. F. (2024). Development of Machine Learning-Based Sales Cancellation/Return Forecasting Models for the E-Commerce Industry. *International Conference on Advances in Electrical- Electronics Engineering and Computer Science*, 17–21. <https://doi.org/https://doi.org/10.36287/setsci.19.4.022>
- Sari, Z. S., Yurdagül, H. H., Taşkapı, B., Dağdaş, G., & Akay, M. F. (2025). Multi-Class Machine Learning Models for Predicting Order Cancellations and Returns in E-Commerce. *2025 9th International Symposium on Innovative Approaches in Smart Technologies (ISAS)*. <https://doi.org/10.1109/ISAS66241.2025.11101817>

DOI: <https://doi.org/10.69693/ijmst.v4i2.12964>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

- Tuba Irmak. (2025). Analysis of Order Cancellation Rates and Feature Weighting with Machine Learning: An E-Commerce Case Study. *Intelligent and Fuzzy Systems (INFUS 2025)*, 1531, 763–770. https://doi.org/https://doi.org/10.1007/978-3-031-98304-7_82
- Yonatan, A. Z. (2025). *Tingkat Penetrasi Internet Indonesia Tembus 80% pada 2025*. GoodStats. <https://goodstats.id/article/tingkat-penetrasi-internet-indonesia-tembus-80-pada-2025-rape>d