

Analisis Perbandingan Random Forest dan XGBoost dalam Prediksi Pembatalan Pesanan Shopee Menggunakan Interpretasi SHAP

Comparison of Random Forest and XGBoost for Shopee Order Cancellation Prediction Using SHAP Interpretation

Muhammad Bayu Samudra, Mira Afrina*, Allsela Meiriza, Rizka Dhini Kurnia, Ardina Ariani

Fakultas Ilmu Komputer, Program Studi Sistem Informasi, Universitas Sriwijaya, Palembang, Indonesia

Email: ¹09031182328008@student.unsri.ac.id, ^{2,*}mira_afrina@unsri.ac.id, ³allsela@unsri.ac.id, ⁴rizkadhini@gmail.com, ⁵ardinaariani@unsri.ac.id

Email Penulis Korespondensi: mira_afrina@unsri.ac.id

Received: 09/08/2026, Revised: 18/08/2026, Accepted: 04/09/2026, Published: 08/09/2026

Abstrak—Pembatalan pesanan menjadi salah satu persoalan penting pada platform *e-commerce* karena dapat menyebabkan kehilangan pendapatan, bertambahnya biaya operasional, dan menurunnya efisiensi pengelolaan transaksi. Penelitian ini bertujuan membandingkan kemampuan *Random Forest* dan *Extreme Gradient Boosting* (XGBoost) dalam memprediksi pembatalan pesanan pelanggan Shopee serta menginterpretasikan faktor yang berkontribusi terhadap hasil prediksi menggunakan pendekatan *Explainable Artificial Intelligence* berbasis *SHapley Additive exPlanations* (SHAP). Dataset yang digunakan adalah *Shopee Consumer Behaviour Cancellation Order Analysis* yang diperoleh dari Kaggle. Tahapan penelitian mencakup *preprocessing* data, pembagian dataset dengan *Stratified Train-Test Split* menggunakan rasio 80:20, pelatihan kedua algoritma, evaluasi model menggunakan *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *Receiver Operating Characteristic–Area Under Curve* (ROC-AUC), serta interpretasi model menggunakan SHAP. Hasil pengujian menunjukkan bahwa *Random Forest* memberikan performa lebih unggul pada sebagian besar metrik evaluasi, sedangkan XGBoost memperoleh nilai ROC-AUC yang sedikit lebih tinggi. Analisis SHAP mengidentifikasi Total Diskon, Ongkos Kirim Dibayar oleh Pembeli, Perkiraan Ongkos Kirim, dan Estimasi Potongan Biaya Pengiriman sebagai variabel yang paling berkontribusi terhadap prediksi pembatalan pesanan. Temuan tersebut menunjukkan bahwa penggunaan algoritma prediksi yang disertai pendekatan *Explainable Artificial Intelligence* tidak hanya mendukung klasifikasi pembatalan pesanan, tetapi juga memberikan pemahaman mengenai faktor yang berperan dalam hasil prediksi sehingga dapat menjadi bahan pertimbangan dalam upaya mengurangi pembatalan pesanan pada platform *e-commerce*.

Kata Kunci: Pembatalan Pesanan; E-commerce; Random Forest; XGBoost; Explainable Artificial Intelligence

Abstract—Order cancellation is a significant issue for *e-commerce* platforms because it can result in revenue loss, increased operational costs, and reduced transaction management efficiency. This study aims to compare the performance of *Random Forest* and *Extreme Gradient Boosting* (XGBoost) in predicting customer order cancellations on Shopee and to interpret the factors contributing to the prediction outcomes using an *Explainable Artificial Intelligence* approach based on *SHapley Additive exPlanations* (SHAP). The study employed the *Shopee Consumer Behaviour Cancellation Order Analysis* dataset obtained from Kaggle. The research process consisted of data *preprocessing*, dataset partitioning using the *Stratified Train-Test Split* method with an 80:20 ratio, implementation of both algorithms, model evaluation using *Accuracy*, *Precision*, *Recall*, *F1-Score*, and *Receiver Operating Characteristic–Area Under Curve* (ROC-AUC), followed by model interpretation using SHAP. The evaluation results indicate that *Random Forest* achieved better performance across most evaluation metrics, while XGBoost obtained a slightly higher ROC-AUC value. SHAP analysis identified Total Discount, Buyer-Paid Shipping Cost, Estimated Shipping Cost, and Estimated Shipping Fee Deduction as the variables contributing most to order cancellation predictions. These findings indicate that combining predictive algorithms with an *Explainable Artificial Intelligence* approach not only supports the classification of order cancellations but also provides insights into the factors influencing prediction outcomes, which can serve as a consideration for reducing order cancellations on *e-commerce* platforms.

Keywords: Order Cancellation; E-commerce; Random Forest; XGBoost; Explainable Artificial Intelligence

1. PENDAHULUAN

Pesatnya adopsi platform *e-commerce* telah mengubah pola transaksi masyarakat sekaligus mendorong pertumbuhan ekonomi digital di Indonesia. Pemanfaatan teknologi digital dalam aktivitas perdagangan tidak hanya meningkatkan efisiensi proses transaksi, tetapi juga menghasilkan data dalam jumlah besar yang dapat dimanfaatkan sebagai dasar pengambilan keputusan berbasis data [1]. Besarnya aktivitas transaksi pada berbagai *marketplace*, termasuk Shopee, juga diikuti oleh permasalahan operasional berupa pembatalan pesanan (*order cancellation*). [2], [3]. Pembatalan pesanan dapat menyebabkan hilangnya potensi pendapatan, meningkatkan biaya operasional, serta mengganggu efektivitas pengelolaan persediaan dan layanan pelanggan [4]. Oleh karena itu, diperlukan pendekatan yang mampu mengenali transaksi yang berpotensi mengalami pembatalan berdasarkan pola historis sehingga langkah pencegahan dapat dilakukan secara lebih tepat.

Pemanfaatan *machine learning* dalam sektor *e-commerce* terus mengalami peningkatan karena kemampuannya dalam mengolah data transaksi berskala besar serta mengidentifikasi pola yang sulit dikenali melalui analisis konvensional. Berbagai aktivitas pelanggan, seperti proses pembelian, metode pembayaran, riwayat transaksi, hingga status penyelesaian pesanan, menghasilkan data yang dapat dimanfaatkan untuk membangun algoritma prediksi guna mendukung pengambilan keputusan berbasis data [5]. Dibandingkan dengan pendekatan statistik tradisional, *machine*

learning mampu mempelajari hubungan yang kompleks antarvariabel sehingga menghasilkan prediksi yang lebih adaptif terhadap karakteristik data transaksi [6]. Dalam permasalahan *e-commerce*, algoritma *ensemble learning* seperti *Random Forest* dan *XGBoost* banyak digunakan karena mampu menangani karakteristik data yang beragam serta memberikan performa klasifikasi yang kompetitif [7]. Penerapan kedua algoritma tersebut pada permasalahan prediksi pembatalan pesanan telah menghasilkan performa yang beragam, sehingga perbandingan algoritma menjadi penting untuk menentukan pendekatan yang lebih sesuai dengan karakteristik data yang digunakan [8].

Perkembangan *Artificial Intelligence* telah mengubah arah penelitian pada sektor *e-commerce*, yang semula lebih berorientasi pada otomatisasi proses bisnis menjadi pemanfaatan *predictive analytics* untuk mendukung pengambilan keputusan berbasis data secara lebih efektif. Berbagai algoritma *machine learning* telah diterapkan pada beragam kebutuhan, seperti sistem rekomendasi produk, analisis sentimen pelanggan, deteksi penipuan transaksi, prediksi perilaku konsumen, hingga prediksi status transaksi guna meningkatkan efisiensi operasional dan kualitas layanan [9]. Kondisi tersebut menunjukkan bahwa pemanfaatan *Artificial Intelligence* pada sektor *e-commerce* terus berkembang, tidak hanya untuk menghasilkan prediksi dengan tingkat akurasi yang tinggi, tetapi juga untuk mendukung proses pengambilan keputusan berbasis data [10]. Seiring meningkatnya kompleksitas penerapan algoritma *machine learning*, perhatian penelitian mulai bergeser dari sekadar peningkatan performa prediksi menuju pengembangan interpretasi hasil prediksi yang lebih mudah dipahami melalui pendekatan *Explainable Artificial Intelligence* (XAI). Pendekatan tersebut memungkinkan faktor-faktor yang memengaruhi keluaran prediksi dijelaskan secara lebih transparan sehingga mampu meningkatkan kepercayaan terhadap hasil yang dihasilkan algoritma [11]. Perkembangan tersebut kemudian menjadi landasan bagi berbagai penelitian yang mengevaluasi kemampuan algoritma *machine learning* dalam menyelesaikan berbagai persoalan prediksi pada sektor *e-commerce*, termasuk prediksi pembatalan pesanan.

Berbagai penelitian sebelumnya telah memanfaatkan algoritma *machine learning* untuk menangani permasalahan prediksi pada sektor *e-commerce*, baik yang berkaitan dengan pembatalan pesanan maupun perilaku pelanggan. Penerapan *Support Vector Machine* (SVM) untuk memprediksi pembatalan transaksi pada Shopee menghasilkan nilai *accuracy* sebesar 95,57%, *precision* 95,96%, *recall* 95,57%, dan *F1-score* 95,58%, dengan *Total Payment* dan *Estimated Shipping Fee Reduction* sebagai variabel yang paling berpengaruh terhadap pembatalan transaksi [12]. Penelitian lain yang membandingkan beberapa algoritma *machine learning* menunjukkan bahwa *Random Forest* memperoleh hasil terbaik dengan *accuracy* sebesar 86% dan *F1-score* sebesar 88% [4]. Hasil yang serupa dilaporkan pada penelitian mengenai pembatalan dan pengembalian pesanan, di mana *Random Forest* dan *XGBoost* memberikan performa terbaik dengan *accuracy* sebesar 80% dan *F1-score* sebesar 81% [7]. Selain itu, pendekatan *ensemble learning* yang mengombinasikan *Random Forest*, *XGBoost*, dan *LightGBM* mampu meningkatkan kemampuan prediksi pelanggan potensial pada sektor *e-commerce*, dengan nilai *precision* meningkat dari 89,5% menjadi 89,8% melalui pendekatan *soft voting* [13]. Penelitian lain yang mengombinasikan *Random Forest*, *XGBoost*, dan metode *SHapley Additive exPlanations* (SHAP) pada kasus *customer churn* menunjukkan bahwa *XGBoost* memperoleh *accuracy* sebesar 96%, *precision* sebesar 95%, *recall* sebesar 92%, dan *AUC* sebesar 0,999, sementara SHAP mampu mengidentifikasi variabel yang memberikan kontribusi terbesar terhadap hasil prediksi [14]. Hasil penelitian terdahulu tersebut menunjukkan bahwa *Random Forest* dan *XGBoost* telah memiliki kemampuan yang baik dalam berbagai permasalahan prediksi, sementara SHAP telah terbukti membantu menjelaskan kontribusi variabel pada permasalahan pelanggan. Namun, temuan tersebut masih berada pada konteks dan tujuan analisis yang berbeda, sehingga belum memberikan gambaran yang spesifik mengenai perbandingan kedua algoritma tersebut sekaligus interpretasi faktor pembatalan pada transaksi Shopee.

Perbandingan penelitian terdahulu menunjukkan bahwa kajian mengenai pembatalan pesanan telah banyak menilai kemampuan algoritma berdasarkan performa klasifikasinya [4], [7], [12], sedangkan aspek interpretasi terhadap alasan di balik hasil prediksi masih relatif terbatas. Penelitian yang menggunakan SHAP juga lebih banyak ditemukan pada konteks *customer churn* dan perilaku pelanggan [14], sementara penerapannya untuk menjelaskan prediksi pembatalan pesanan pada Shopee belum banyak dikaji. Dalam penelitian ini, dataset sekunder *Shopee Consumer Behaviour Cancellation Order Analysis* dari Kaggle digunakan karena menyediakan 4.238 data historis transaksi pelanggan Shopee pada periode Januari 2024 hingga November 2025 dengan atribut yang berkaitan langsung dengan karakteristik transaksi, termasuk informasi pembayaran, diskon, dan pengiriman. Karakteristik tersebut memungkinkan penelitian tidak hanya membandingkan kemampuan klasifikasi kedua algoritma, tetapi juga mengidentifikasi faktor transaksi yang berkontribusi terhadap pembatalan pesanan. Dengan demikian, kontribusi penelitian terletak pada penggabungan evaluasi komparatif *Random Forest* dan *XGBoost* dengan interpretasi berbasis SHAP pada konteks pembatalan pesanan Shopee, sehingga diperoleh informasi mengenai algoritma yang lebih sesuai sekaligus faktor transaksi yang dominan dalam hasil prediksi [15], [16].

Penelitian ini dilakukan untuk membandingkan performa algoritma *Random Forest* serta *XGBoost* dalam memprediksi pembatalan pesanan pada platform Shopee sehingga dapat ditentukan algoritma yang memberikan hasil terbaik. Setelah proses evaluasi selesai, algoritma dengan performa tertinggi selanjutnya dianalisis menggunakan metode *SHapley Additive exPlanations* (SHAP) guna menjelaskan kontribusi setiap variabel terhadap hasil prediksi. Pendekatan tersebut memungkinkan penelitian menghubungkan hasil perbandingan performa algoritma dengan faktor transaksi yang berkontribusi terhadap pembatalan pesanan. Melalui pendekatan tersebut, penelitian ini tidak hanya berorientasi pada peningkatan performa prediksi, tetapi juga pada penyediaan interpretasi yang lebih transparan sehingga faktor-faktor yang memengaruhi pembatalan pesanan dapat dipahami dengan lebih baik [17]. Hasil


penelitian diharapkan dapat memberikan informasi empiris mengenai algoritma yang sesuai dan faktor transaksi yang perlu diperhatikan dalam merancang strategi mitigasi pembatalan pesanan pada platform *e-commerce*.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini dilakukan melalui beberapa tahapan yang mencakup identifikasi masalah, studi literatur, pengumpulan data, *preprocessing*, pembagian data, penerapan algoritma *Random Forest* dan *XGBoost*, evaluasi performa, interpretasi menggunakan SHAP, serta analisis hasil. Rangkaian tahapan tersebut menggambarkan proses penelitian mulai dari penentuan permasalahan hingga diperolehnya hasil perbandingan algoritma dan faktor yang berkontribusi terhadap prediksi pembatalan pesanan. Alur penelitian disajikan pada Gambar 1.

Tahapan diawali dengan identifikasi permasalahan dan studi literatur untuk menentukan *research gap* serta pendekatan yang sesuai. Dataset selanjutnya dikumpulkan dan melalui proses *preprocessing* yang mencakup *data cleaning*, *feature selection*, *data encoding*, dan *feature engineering*. Data yang telah diproses kemudian dibagi menggunakan *Stratified Train-Test Split* dengan rasio 80:20. Kedua algoritma, yaitu *Random Forest* dan *XGBoost*, diterapkan pada data latih dan diuji menggunakan data uji berdasarkan metrik *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *ROC-AUC*. Algoritma dengan performa terbaik selanjutnya diinterpretasikan menggunakan SHAP untuk mengidentifikasi kontribusi variabel terhadap hasil prediksi, kemudian hasilnya dianalisis untuk memperoleh kesimpulan penelitian.



Gambar 1. Tahapan Penelitian

2.2 Dataset Penelitian

Penelitian ini menggunakan data sekunder yang diperoleh dari repositori publik Kaggle melalui *dataset* Shopee Consumer Behaviour Cancellation Order Analysis. Dataset terdiri atas 4.238 data historis transaksi pelanggan pada platform Shopee dengan periode pengamatan Januari 2024 hingga November 2025. Dataset tersebut digunakan karena memuat atribut transaksi yang berkaitan dengan karakteristik pembelian dan status pembatalan pesanan, sehingga dapat digunakan sebagai dasar penerapan algoritma *Random Forest* dan *XGBoost* untuk mengidentifikasi pola transaksi yang berpotensi mengalami pembatalan. Selain itu, ketersediaan sejumlah atribut transaksi memungkinkan dilakukan analisis lebih lanjut menggunakan metode *SHapley Additive exPlanations* (SHAP) untuk mengetahui kontribusi masing-masing variabel terhadap hasil prediksi.

Proses pengumpulan data dilakukan melalui studi dokumentasi dengan memanfaatkan *dataset* publik yang tersedia pada Kaggle. Penggunaan data publik mendukung keterlacakan sumber data dan memungkinkan proses penelitian dilakukan secara lebih transparan serta dapat direplikasi [18], [19]. Sebelum memasuki tahap pemodelan, data diseleksi dan diproses untuk memastikan atribut yang digunakan sesuai dengan kebutuhan penelitian. Rincian variabel yang dipertahankan setelah proses seleksi disajikan pada Tabel 1.

Tabel 1. Deskripsi Variabel Penelitian

No	Nama Variabel	Tipe Data	Keterangan
1	total_qty	Numerik	Jumlah produk dalam satu transaksi
2	total_weight_gr	Numerik	Total berat produk (gram)
3	Total Diskon	Numerik	Total nilai diskon yang diperoleh pelanggan
...	...	...	...
15	is cancelled	Target	Status transaksi (0 = Selesai, 1 = Batal)

2.3 Preprocessing Data

Proses *preprocessing* dilakukan untuk menyesuaikan dataset dengan kebutuhan analisis sebelum penerapan algoritma klasifikasi. Tahapan yang dilakukan meliputi *data cleaning*, *feature selection*, *data encoding*, dan *feature engineering*.

2.3.1 Data Cleaning

Kualitas dataset diverifikasi melalui tahap *data cleaning* sebelum memasuki proses analisis. Pemeriksaan dilakukan untuk memastikan tidak terdapat *missing values*, data duplikat (*duplicate data*), maupun ketidaksesuaian tipe data pada setiap atribut. Berdasarkan hasil verifikasi, dataset tidak menunjukkan adanya nilai yang hilang ataupun data yang terduplikasi sehingga seluruh data dapat dipertahankan untuk proses selanjutnya. Penyesuaian tipe data juga diterapkan pada atribut bertipe waktu sebagai persiapan dalam pembentukan fitur baru pada tahap *feature engineering*.

2.3.2 Feature Selection

Tahap *feature selection* bertujuan untuk memilih variabel yang relevan terhadap proses prediksi pembatalan pesanan sekaligus menghilangkan atribut yang tidak memberikan kontribusi terhadap pemodelan. Pada penelitian ini, atribut *order_id*, Status Pesanan, Total Pembayaran, dan *source_file* tidak digunakan karena berfungsi sebagai identitas transaksi, informasi yang berpotensi menyebabkan *data leakage*, maupun informasi administratif yang tidak memiliki hubungan langsung dengan proses prediksi. Hasil dari tahap ini adalah sekumpulan variabel yang dinilai relevan untuk digunakan pada proses klasifikasi.

2.3.3 Data Encoding

Tahap *data encoding* dilakukan dengan mengubah atribut kategorikal ke dalam bentuk numerik agar dapat digunakan sebagai masukan pada proses klasifikasi. Pada penelitian ini, metode *Label Encoding* diterapkan pada atribut *product_categories*, Opsi Pengiriman, Metode Pembayaran, Kota/Kabupaten, dan Provinsi. Pemilihan metode tersebut didasarkan pada kebutuhan untuk merepresentasikan setiap kategori dalam bentuk kode numerik dengan tetap mempertahankan jumlah atribut yang digunakan dalam pemodelan. Representasi numerik juga memudahkan proses pengolahan data oleh algoritma berbasis *decision tree* yang digunakan dalam penelitian, yaitu *Random Forest* dan *XGBoost*. Selain itu, penggunaan *Label Encoding* menghasilkan representasi data yang lebih ringkas dibandingkan metode *one-hot encoding*, sehingga tidak menambah sejumlah kolom baru untuk setiap kategori. Pendekatan pengkodean ini diterapkan secara konsisten pada data yang digunakan dalam proses pelatihan dan pengujian untuk menjaga kesesuaian representasi kategori.

2.3.4 Feature Engineering

Tahap *feature engineering* dilakukan untuk menghasilkan atribut baru yang mampu meningkatkan kemampuan algoritma dalam mengenali pola pembatalan pesanan. Pada penelitian ini, atribut Waktu Pesanan Dibuat diturunkan menjadi tiga variabel baru, yaitu Jam, Hari, dan Bulan, sehingga informasi waktu transaksi dapat direpresentasikan secara lebih spesifik. Selain itu, atribut *product_categories* dimanfaatkan untuk membentuk variabel *num_product_categories* yang menunjukkan jumlah kategori produk dalam setiap transaksi. Penambahan atribut tersebut bertujuan memperkaya informasi yang digunakan pada proses analisis sehingga diharapkan dapat meningkatkan kualitas hasil prediksi.

2.4 Proses Klasifikasi Algoritma Machine Learning

Proses klasifikasi dilakukan setelah seluruh tahapan *preprocessing* selesai sehingga dataset siap digunakan dalam pemodelan. Penelitian ini menerapkan dua algoritma *ensemble learning*, yaitu *Random Forest* dan *Extreme Gradient Boosting* (XGBoost), untuk memprediksi pembatalan pesanan pada platform Shopee. Dataset dibagi menggunakan metode *Stratified Train-Test Split* dengan rasio 80:20, yaitu 80% data digunakan sebagai data latih (*training data*) dan 20% sebagai data uji (*testing data*). Pembagian secara terstratifikasi bertujuan mempertahankan proporsi kelas pada data latih dan data uji sehingga kemampuan algoritma dapat dievaluasi secara lebih representatif menggunakan data yang tidak terlibat dalam proses pelatihan.

Random Forest merupakan algoritma *ensemble learning* yang menggabungkan sejumlah *decision tree* melalui teknik *bootstrap aggregating* (*bagging*). Prediksi akhir diperoleh berdasarkan mekanisme *majority voting*, sehingga kombinasi beberapa pohon keputusan dapat menghasilkan prediksi yang lebih stabil. Pendekatan tersebut memungkinkan *Random Forest* menangani hubungan nonlinier dan interaksi antarvariabel pada data transaksi [20].

Extreme Gradient Boosting (XGBoost) merupakan algoritma *ensemble learning* berbasis *gradient boosting* yang membangun *decision tree* secara bertahap dengan memanfaatkan kesalahan prediksi pada iterasi sebelumnya. Algoritma ini dilengkapi mekanisme *regularization* dan proses optimasi untuk meningkatkan kemampuan prediksi sekaligus mengendalikan risiko *overfitting*. XGBoost digunakan sebagai algoritma pembandingan karena penelitian terdahulu menunjukkan kemampuannya dalam menghasilkan performa klasifikasi yang baik pada data *e-commerce* [14].

Untuk menjaga keterulangan eksperimen, konfigurasi parameter yang digunakan pada masing-masing algoritma ditetapkan secara eksplisit. Algoritma *Random Forest* menggunakan 100 *decision tree* melalui parameter *n_estimators*=100 dan *random_state*=42, sedangkan parameter lainnya menggunakan nilai bawaan algoritma.

Algoritma XGBoost menggunakan $n_{\text{estimators}}=100$, $\text{learning_rate}=0,1$, $\text{max_depth}=6$, dan $\text{random_state}=42$, dengan $\text{eval_metric}=\text{logloss}$ sebagai metrik evaluasi selama proses pembelajaran. Konfigurasi tersebut diterapkan secara langsung pada proses pelatihan tanpa menggunakan metode pencarian *hyperparameter* tambahan.

2.5 Evaluasi Performa Algoritma

Kemampuan algoritma *Random Forest* dan XGBoost dalam memprediksi pembatalan pesanan dianalisis melalui proses evaluasi menggunakan data uji (*testing data*). Evaluasi dilakukan dengan memanfaatkan lima metrik, yaitu *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *Receiver Operating Characteristic–Area Under Curve (ROC-AUC)*, sehingga performa masing-masing algoritma dapat dinilai secara lebih komprehensif [21]. Pada penelitian ini, *Accuracy* digunakan sebagai salah satu indikator utama untuk mengukur proporsi prediksi yang sesuai dengan kondisi sebenarnya terhadap seluruh data yang dievaluasi. Persamaan perhitungan *Accuracy* disajikan pada Persamaan (1).

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

Perhitungan seluruh metrik evaluasi mengacu pada nilai yang diperoleh dari *Confusion Matrix*, yaitu matriks yang merangkum hasil klasifikasi berdasarkan empat komponen, yaitu *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*. Keempat komponen tersebut menjadi dasar dalam menentukan nilai *Accuracy*, *Precision*, *Recall*, *F1-Score*, serta *ROC-AUC*. Susunan *Confusion Matrix* yang digunakan pada penelitian ini ditunjukkan pada Tabel 2.

Tabel 2. Confusion Matrix

Aktual / Prediksi	Tipe Data	Keterangan
Batal (1)	True Positive (TP)	False Negative (FN)
Selesai (0)	False Positive (FP)	True Negative (TN)

2.6 Interpretasi Model Menggunakan SHAP

Interpretasi terhadap hasil prediksi pada penelitian ini dilakukan menggunakan metode *SHapley Additive exPlanations (SHAP)*, salah satu pendekatan dalam *Explainable Artificial Intelligence (XAI)* yang mampu menjelaskan kontribusi setiap variabel terhadap keluaran prediksi algoritma *machine learning*. Pemanfaatan SHAP tidak hanya bertujuan mengevaluasi hasil prediksi, tetapi juga mengungkap variabel-variabel yang memberikan pengaruh paling besar terhadap kemungkinan terjadinya pembatalan pesanan. Melalui pendekatan tersebut, faktor-faktor yang memengaruhi hasil prediksi dapat dipahami secara lebih jelas sehingga transparansi dan kepercayaan terhadap proses pengambilan keputusan algoritma dapat ditingkatkan [22], [23].

Pada penelitian ini, interpretasi SHAP disajikan melalui tiga jenis visualisasi, yaitu SHAP Summary Plot, SHAP Bar Plot, dan SHAP Dependence Plot. Ketiga visualisasi tersebut saling melengkapi dalam menjelaskan hasil prediksi, mulai dari distribusi dan tingkat kepentingan setiap variabel, arah pengaruh variabel terhadap hasil prediksi, hingga hubungan antara perubahan nilai suatu variabel dengan nilai SHAP yang dihasilkan. Ringkasan fungsi masing-masing visualisasi disajikan pada Tabel 3.

Tabel 3. Visualisasi SHAP yang Digunakan

Visualisasi SHAP	Tipe Data
SHAP Summary Plot	Menyajikan distribusi nilai SHAP seluruh variabel untuk menggambarkan arah pengaruh serta besarnya kontribusi masing-masing variabel terhadap hasil prediksi.
SHAP Bar Plot	Mengurutkan variabel berdasarkan nilai rata-rata absolut SHAP (<i>mean absolute SHAP value</i>) sehingga tingkat kepentingan setiap variabel dapat dibandingkan.
SHAP Dependence Plot	Menggambarkan hubungan antara perubahan nilai suatu variabel dengan nilai SHAP untuk menunjukkan bagaimana variabel tersebut memengaruhi hasil prediksi.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Preprocessing Data

Tahap *preprocessing* menghasilkan dataset yang siap digunakan dalam proses klasifikasi menggunakan algoritma *Random Forest* dan XGBoost. Rangkaian pengolahan meliputi *data cleaning*, *feature selection*, *data encoding*, dan *feature engineering* yang dilakukan untuk memastikan data memiliki struktur dan format yang sesuai sebelum proses pemodelan. Hasil pengolahan tersebut menjadi dasar bagi pembentukan algoritma karena setiap variabel yang digunakan telah melalui proses pemeriksaan, penyaringan, dan transformasi sesuai kebutuhan klasifikasi.

Ringkasan hasil *preprocessing* disajikan pada Tabel 4. Berdasarkan hasil pengolahan, dataset tidak memiliki *missing value* maupun data duplikat sehingga seluruh 4.238 data transaksi dapat dipertahankan untuk analisis. Tahap *feature selection* menghapus empat atribut yang tidak digunakan dalam pemodelan, sedangkan lima variabel kategorikal dikonversi menjadi bentuk numerik menggunakan *Label Encoding*. Selanjutnya, *feature engineering* menghasilkan tiga variabel tambahan sehingga diperoleh 14 variabel prediktor dan 1 variabel target (*is_cancelled*).

Dataset akhir kemudian dibagi menjadi 3.390 data latih (80%) dan 848 data uji (20%) menggunakan *Stratified Train-Test Split*. Pembagian tersebut mempertahankan proporsi kelas pada data latih dan data uji sehingga evaluasi kedua algoritma dilakukan pada data yang tetap merepresentasikan karakteristik kelas dalam dataset. Dengan kondisi tersebut, dataset akhir telah memenuhi struktur yang diperlukan untuk membandingkan kemampuan *Random Forest* dan XGBoost dalam memprediksi pembatalan pesanan.

Tabel 4. Hasil Akhir Preprocessing Data


Tahapan	Hasil
Jumlah data awal	4.238 data
Missing value	Tidak ada
Data duplikat	Tidak ada
Feature Selection	Menghapus 4 atribut (<i>order_id</i> , <i>Status Pesanan</i> , <i>Total Pembayaran</i> , dan <i>source_file</i>)
Data Encoding	5 variabel kategorikal dikonversi menjadi numerik menggunakan <i>Label Encoding</i>
Feature Engineering	Menambahkan variabel Jam, Hari, dan Bulan dari atribut Waktu Pesanan Dibuat
Jumlah variabel akhir	15 variabel (14 prediktor dan 1 target)
Data latih (<i>training</i>)	3.390 data (80%)
Data uji (<i>testing</i>)	848 data (20%)

3.2 Hasil Pengujian Algoritma

Pengujian dilakukan untuk mengevaluasi dan membandingkan kemampuan algoritma *Random Forest* serta XGBoost dalam memprediksi pembatalan pesanan menggunakan data uji (*testing data*). Proses evaluasi memanfaatkan pembagian dataset melalui metode *Stratified Train-Test Split* dengan rasio 80:20 sehingga proporsi kelas pada data latih dan data uji tetap terjaga. Kinerja masing-masing algoritma kemudian dianalisis menggunakan metrik *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *Receiver Operating Characteristic–Area Under Curve (ROC-AUC)*. Selain itu, *Confusion Matrix* digunakan untuk mengevaluasi kemampuan algoritma dalam mengklasifikasikan transaksi ke dalam kelas Selesai (0) dan Batal (1). Hasil pengujian masing-masing algoritma dijelaskan pada subbab berikut.

3.2.1 Random Forest

Pengujian menggunakan algoritma *Random Forest* dilakukan untuk mengetahui kemampuan algoritma dalam memprediksi status pembatalan pesanan berdasarkan data uji (*testing data*). Hasil klasifikasi yang diperoleh melalui *Confusion Matrix* ditampilkan pada Gambar 2. Berdasarkan hasil tersebut, algoritma berhasil mengklasifikasikan 669 data transaksi Selesai sebagai True Negative dan 153 data transaksi Batal sebagai True Positive. Selain itu, terdapat 26 data transaksi Selesai yang diprediksi sebagai Batal (False Positive), sedangkan tidak ditemukan data transaksi Batal yang diprediksi sebagai Selesai (False Negative). Hasil tersebut menunjukkan bahwa *Random Forest* mampu mengenali seluruh transaksi yang benar-benar mengalami pembatalan pada data uji. Tidak adanya *False Negative* menjadi temuan penting karena menunjukkan bahwa tidak terdapat transaksi Batal yang terlewat oleh algoritma, meskipun masih terdapat 26 transaksi Selesai yang dikategorikan sebagai Batal. Dalam konteks pengelolaan transaksi, kondisi tersebut menunjukkan bahwa algoritma lebih mampu mengidentifikasi transaksi yang berpotensi dibatalkan dengan konsekuensi adanya sejumlah prediksi positif yang tidak sesuai dengan kondisi sebenarnya.



Gambar 2. Confusion Matrix Random Forest

Evaluasi terhadap algoritma *Random Forest* selanjutnya dilakukan berdasarkan hasil *Confusion Matrix* menggunakan metrik *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *Receiver Operating Characteristic–Area Under Curve (ROC-AUC)*. Ringkasan nilai evaluasi ditampilkan pada Tabel 5. Berdasarkan hasil tersebut, *Random Forest* memperoleh nilai *Accuracy* sebesar 0,9693, *Precision* sebesar 0,8547, *Recall* sebesar 1,0000, *F1-Score* sebesar 0,9217, dan *ROC-AUC* sebesar 0,9736. Nilai *Accuracy* sebesar 0,9693 menunjukkan bahwa sebagian besar transaksi


pada data uji berhasil diklasifikasikan secara tepat. Sementara itu, nilai *Recall* sebesar 1,0000 memperlihatkan bahwa seluruh transaksi yang berstatus Batal berhasil dikenali oleh algoritma, sehingga tidak ditemukan *False Negative*. Kondisi tersebut menjadi keunggulan penting dalam konteks prediksi pembatalan karena transaksi yang berpotensi batal tidak terlewat dalam proses identifikasi. Nilai *Precision* sebesar 0,8547 menunjukkan bahwa tidak seluruh transaksi yang diprediksi Batal benar-benar berada pada kelas Batal, yang sesuai dengan ditemukannya 26 *False Positive* pada *Confusion Matrix*. Adapun nilai *F1-Score* sebesar 0,9217 menunjukkan keseimbangan yang baik antara kemampuan algoritma dalam menemukan transaksi Batal dan ketepatan prediksi pada kelas tersebut. Nilai *ROC-AUC* sebesar 0,9736 juga menunjukkan bahwa algoritma memiliki kemampuan yang sangat baik dalam membedakan transaksi Selesai dan Batal.

Tabel 5. Ringkasan Nilai Evaluasi Algoritma Random Forest

Indikator Evaluasi	Nilai
Accuracy	0.9693
Precision	0,8547
Recall	1,0000
F1-Score	0,9217
ROC-AUC	0,9736

3.2.2 XGBoost

Algoritma *XGBoost* diterapkan sebagai algoritma pembanding untuk mengevaluasi kemampuan pendekatan *gradient boosting* dalam memprediksi pembatalan pesanan pada platform Shopee. Proses pelatihan dan pengujian menggunakan pembagian data yang sama dengan algoritma *Random Forest*, sehingga hasil evaluasi kedua algoritma dapat dibandingkan secara objektif. Hasil klasifikasi berdasarkan *Confusion Matrix* ditampilkan pada Gambar 3. Berdasarkan hasil tersebut, algoritma berhasil mengklasifikasikan 669 data transaksi Selesai sebagai True Negative dan 151 data transaksi Batal sebagai True Positive. Selain itu, terdapat 26 data transaksi Selesai yang diprediksi sebagai Batal (False Positive) serta 2 data transaksi Batal yang diprediksi sebagai Selesai (False Negative). Hasil tersebut menunjukkan bahwa XGBoost mampu mengklasifikasikan sebagian besar transaksi secara tepat, meskipun masih terdapat dua transaksi Batal yang tidak berhasil dikenali oleh algoritma. Keberadaan *False Negative* tersebut menunjukkan bahwa sebagian kecil transaksi yang sebenarnya mengalami pembatalan masih dapat terlewat dalam proses prediksi.



Gambar 3. Confusion Matrix XGBoost

Kinerja algoritma XGBoost selanjutnya dievaluasi berdasarkan hasil *Confusion Matrix* menggunakan metrik *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *Receiver Operating Characteristic–Area Under Curve (ROC-AUC)*. Ringkasan hasil evaluasi ditampilkan pada Tabel 6. Berdasarkan hasil pengujian, XGBoost memperoleh nilai *Accuracy* sebesar 0,9670, *Precision* sebesar 0,8531, *Recall* sebesar 0,9869, *F1-Score* sebesar 0,9152, dan *ROC-AUC* sebesar 0,9775. Nilai *Accuracy* sebesar 0,9670 menunjukkan bahwa sebagian besar transaksi pada data uji berhasil diklasifikasikan dengan tepat. Nilai *Recall* sebesar 0,9869 menunjukkan bahwa hampir seluruh transaksi yang benar-benar berstatus Batal berhasil dikenali, meskipun masih terdapat dua *False Negative*. Sementara itu, *Precision* sebesar 0,8531 menunjukkan bahwa sebagian transaksi yang diprediksi Batal masih termasuk dalam kelas Selesai, yang tercermin dari adanya 26 *False Positive*. Nilai *F1-Score* sebesar 0,9152 menunjukkan keseimbangan yang baik antara kemampuan menemukan transaksi Batal dan ketepatan prediksi kelas tersebut. Meskipun *Accuracy*, *Precision*, *Recall*, dan *F1-Score* XGBoost sedikit lebih rendah dibandingkan *Random Forest*, nilai *ROC-AUC* sebesar 0,9775 justru lebih

tinggi. Hal ini menunjukkan bahwa XGBoost memiliki kemampuan diskriminasi kelas yang sangat baik meskipun pada metrik klasifikasi berbasis ambang yang digunakan dalam penelitian ini performanya sedikit berada di bawah *Random Forest*.

Tabel 6. Ringkasan Nilai Evaluasi Algoritma XGBoost

Indikator Evaluasi	Nilai
Accuracy	0,9670
Precision	0,8531
Recall	0,9869
F1-Score	0,9152
ROC-AUC	0,9775

3.3 Perbandingan Performa Algoritma

Setelah proses evaluasi terhadap masing-masing algoritma selesai dilakukan, langkah berikutnya adalah membandingkan performa *Random Forest* dan XGBoost berdasarkan seluruh metrik evaluasi yang digunakan. Perbandingan ini bertujuan menentukan algoritma dengan kinerja paling baik dalam memprediksi pembatalan pesanan pada platform Shopee. Ringkasan hasil perbandingan kedua algoritma disajikan pada Tabel 7.

Tabel 7. Perbandingan Hasil Evaluasi *Random Forest* dan XGBoost

Indikator Evaluasi	Random Forest	XGBoost
Accuracy	0.9693	0,9670
Precision	0,8547	0,8531
Recall	1,0000	0,9869
F1-Score	0,9217	0,9152
ROC-AUC	0,9736	0,9775

Berdasarkan perbandingan pada Tabel 7, kedua algoritma menunjukkan kemampuan klasifikasi yang tinggi dalam memprediksi pembatalan pesanan. *Random Forest* menghasilkan nilai lebih tinggi pada *Accuracy*, *Precision*, *Recall*, dan *F1-Score*, sedangkan XGBoost memiliki nilai *ROC-AUC* yang sedikit lebih tinggi. Perbedaan tersebut menunjukkan bahwa kedua algoritma memiliki kemampuan prediksi yang kompetitif, tetapi karakteristik keunggulannya berbeda. XGBoost mampu memberikan performa prediksi yang baik pada permasalahan pelanggan dalam lingkungan *e-commerce* melalui pemanfaatan karakteristik transaksi dan fitur temporal-spasial [24]. Nilai *Recall* sebesar 1,0000 pada *Random Forest* menunjukkan bahwa seluruh transaksi yang benar-benar berstatus Batal berhasil dikenali, sedangkan XGBoost masih menghasilkan dua *False Negative*. Dalam konteks prediksi pembatalan pesanan, kemampuan tersebut penting karena transaksi yang berpotensi batal dapat teridentifikasi tanpa adanya transaksi Batal yang terlewat pada data uji. Di sisi lain, nilai *ROC-AUC* XGBoost sebesar 0,9775 yang sedikit lebih tinggi daripada *Random Forest* sebesar 0,9736 menunjukkan kemampuan diskriminasi kelas yang sangat baik, tetapi keunggulan tersebut tidak diikuti oleh peningkatan pada metrik klasifikasi lainnya.


Dengan mempertimbangkan keseluruhan metrik, *Random Forest* ditetapkan sebagai algoritma dengan performa terbaik karena unggul pada empat dari lima indikator evaluasi dan memiliki *Recall* sempurna. Hasil tersebut menunjukkan bahwa *Random Forest* lebih sesuai dengan tujuan penelitian yang menekankan kemampuan mengenali transaksi yang mengalami pembatalan. Temuan ini juga sejalan dengan penelitian terdahulu yang menunjukkan performa *Random Forest* yang baik pada permasalahan prediksi pembatalan pesanan di sektor *e-commerce* [4], [7]. Berdasarkan hasil tersebut, *Random Forest* dipilih untuk tahap interpretasi menggunakan metode *SHapley Additive exPlanations* (SHAP) guna mengidentifikasi variabel yang paling berkontribusi terhadap hasil prediksi.

3.4 Interpretasi Model Menggunakan SHAP

Algoritma *Random Forest* yang memperoleh performa terbaik pada tahap evaluasi selanjutnya dianalisis menggunakan metode *SHapley Additive exPlanations* (SHAP) untuk menjelaskan alasan di balik hasil prediksi yang dihasilkan. Melalui pendekatan ini, besarnya kontribusi setiap variabel terhadap prediksi pembatalan pesanan dapat dianalisis sehingga proses pengambilan keputusan algoritma menjadi lebih mudah dipahami. Pendekatan SHAP juga telah digunakan untuk menganalisis tingkat kepentingan fitur pada model *Random Forest* dalam menjelaskan perilaku konsumen, termasuk melalui nilai rata-rata absolut SHAP untuk menentukan variabel yang paling berpengaruh [25]. Interpretasi dilakukan menggunakan tiga bentuk visualisasi, yaitu SHAP Summary Plot, SHAP Bar Plot, dan SHAP Dependence Plot. Ketiga visualisasi tersebut memberikan informasi yang saling melengkapi, mulai dari tingkat kepentingan variabel, arah pengaruh setiap variabel terhadap hasil prediksi, hingga hubungan antara perubahan nilai variabel dan kontribusinya terhadap prediksi yang dihasilkan.

Analisis diawali menggunakan SHAP Summary Plot untuk memperoleh gambaran distribusi kontribusi seluruh variabel terhadap prediksi. Visualisasi tersebut memungkinkan identifikasi variabel yang memiliki pengaruh relatif besar maupun kecil serta menunjukkan arah kontribusi masing-masing variabel terhadap kemungkinan pembatalan pesanan. Hasil visualisasi SHAP Summary Plot disajikan pada Gambar 4.

Visualisasi SHAP Summary Plot memperlihatkan kontribusi relatif setiap variabel terhadap hasil prediksi yang dihasilkan oleh algoritma *Random Forest*. Variabel diurutkan berdasarkan nilai rata-rata absolut SHAP (*mean absolute SHAP value*), sehingga posisi yang lebih tinggi menunjukkan kontribusi yang relatif lebih besar terhadap prediksi. Titik berwarna merah menunjukkan nilai variabel yang relatif tinggi, sedangkan titik berwarna biru menunjukkan nilai yang relatif rendah. Nilai SHAP positif menunjukkan kontribusi terhadap peningkatan prediksi pembatalan, sedangkan nilai SHAP negatif menunjukkan kontribusi yang mengarah pada penurunan prediksi pembatalan. Penggunaan SHAP Summary Plot juga memungkinkan tingkat kepentingan variabel dan arah kontribusinya terhadap keluaran model dianalisis secara bersamaan, sebagaimana diterapkan pada analisis perilaku pelanggan dalam konteks *e-commerce* [26].




Gambar 4. SHAP Summary Plot

Hasil visualisasi menunjukkan bahwa Total Diskon menjadi variabel dengan kontribusi terbesar, diikuti oleh Ongkos Kirim Dibayar oleh Pembeli, Perkiraan Ongkos Kirim, dan Estimasi Potongan Biaya Pengiriman. Dominannya variabel yang berkaitan dengan diskon dan biaya pengiriman menunjukkan bahwa aspek ekonomi transaksi menjadi informasi yang penting dalam membedakan transaksi Selesai dan Batal. Dalam konteks *e-commerce*, variasi diskon dan biaya pengiriman dapat berkaitan dengan pertimbangan pelanggan terhadap manfaat serta biaya yang harus dikeluarkan untuk menyelesaikan transaksi. Pada Total Diskon dan Ongkos Kirim Dibayar oleh Pembeli, nilai yang rendah cenderung memberikan kontribusi positif terhadap prediksi pembatalan, sedangkan nilai yang lebih tinggi cenderung memberikan kontribusi negatif. Pola tersebut mengindikasikan adanya keterkaitan antara komponen biaya transaksi dan perubahan hasil prediksi, meskipun nilai SHAP tidak menunjukkan hubungan sebab-akibat secara langsung.

Sementara itu, Hari, Jam, Provinsi, Opsi Pengiriman, dan *num_product_categories* memiliki sebaran nilai SHAP yang lebih terkonsentrasi di sekitar titik nol. Kondisi tersebut menunjukkan bahwa variabel-variabel tersebut memberikan kontribusi yang relatif lebih kecil dibandingkan variabel utama dalam prediksi. Dengan demikian, hasil SHAP menunjukkan bahwa *Random Forest* lebih banyak memanfaatkan informasi yang berkaitan dengan diskon dan biaya pengiriman ketika menghasilkan prediksi pembatalan pesanan. Temuan ini dapat menjadi pertimbangan bagi pengelola *e-commerce* untuk memperhatikan komponen biaya dan insentif transaksi dalam upaya memahami serta memitigasi pola pembatalan pesanan.


Interpretasi hasil tidak hanya dilakukan melalui *SHAP Summary Plot*, tetapi juga menggunakan *SHAP Bar Plot* untuk mengurutkan variabel berdasarkan besarnya nilai rata-rata absolut SHAP. Penyajian tersebut mempermudah proses analisis dalam menentukan variabel yang memberikan pengaruh paling dominan hingga yang kontribusinya relatif kecil terhadap prediksi pembatalan pesanan. Visualisasi *SHAP Bar Plot* dapat dilihat pada Gambar 5.

Visualisasi SHAP Bar Plot menunjukkan bahwa Total Diskon memiliki nilai rata-rata absolut SHAP tertinggi, diikuti oleh Ongkos Kirim Dibayar oleh Pembeli, Perkiraan Ongkos Kirim, dan Estimasi Potongan Biaya Pengiriman. Urutan tersebut memperkuat temuan pada SHAP Summary Plot bahwa variabel yang berkaitan dengan diskon dan biaya pengiriman merupakan komponen yang paling dominan dalam prediksi pembatalan pesanan. Dominasi variabel tersebut secara logis dapat dikaitkan dengan pertimbangan ekonomi dalam transaksi *e-commerce*, karena perubahan besaran diskon maupun biaya pengiriman dapat memengaruhi nilai transaksi yang dirasakan pelanggan dan biaya akhir yang harus dibayarkan. Dengan demikian, hasil ini menunjukkan bahwa aspek finansial transaksi menjadi informasi penting yang dimanfaatkan dalam membedakan pesanan yang berpotensi Batal dan Selesai.



Gambar 5. SHAP Bar Plot

Untuk memperoleh pemahaman yang lebih mendalam mengenai pengaruh masing-masing variabel, penelitian ini selanjutnya memanfaatkan SHAP Dependence Plot. Visualisasi tersebut menggambarkan hubungan antara perubahan nilai suatu variabel dengan nilai SHAP yang dihasilkan, sehingga pola peningkatan maupun penurunan kontribusi variabel terhadap peluang terjadinya pembatalan pesanan dapat diamati secara lebih jelas. Hasil visualisasi SHAP Dependence Plot disajikan pada Gambar 6.



Gambar 6. SHAP Dependence Plot

Visualisasi SHAP Dependence Plot memperlihatkan hubungan antara Perkiraan Ongkos Kirim dan nilai SHAP dengan interaksi Total Diskon yang direpresentasikan melalui gradasi warna. Hasil visualisasi menunjukkan bahwa peningkatan Perkiraan Ongkos Kirim cenderung diikuti penurunan nilai SHAP, sedangkan nilai Perkiraan Ongkos Kirim yang lebih rendah cenderung berkaitan dengan nilai SHAP positif dan kontribusi yang lebih besar terhadap prediksi pembatalan. Pola tersebut menunjukkan bahwa pengaruh biaya pengiriman terhadap hasil prediksi tidak berdiri sendiri, tetapi berkaitan dengan variasi Total Diskon pada transaksi. Dalam konteks *e-commerce*, interaksi tersebut secara logis dapat mencerminkan pertimbangan pelanggan terhadap keseimbangan antara manfaat potongan harga dan biaya pengiriman yang harus ditanggung. Dengan demikian, hasil ini menunjukkan bahwa kombinasi komponen biaya dan insentif transaksi menjadi informasi yang diperhatikan *Random Forest* dalam menentukan prediksi pembatalan, meskipun hubungan tersebut merupakan pola yang dipelajari dan tidak menunjukkan hubungan sebab-akibat secara langsung.

3.5 Pembahasan

Perbandingan hasil evaluasi menunjukkan bahwa algoritma *Random Forest* memberikan kinerja yang lebih baik dibandingkan XGBoost dalam memprediksi pembatalan pesanan pada platform Shopee. Keunggulan tersebut terlihat dari nilai *Accuracy*, *Precision*, *Recall*, dan *F1-Score* yang lebih tinggi, sedangkan XGBoost hanya unggul pada *ROC-AUC*. Nilai *Recall* *Random Forest* yang mencapai 1,0000 menunjukkan bahwa seluruh transaksi yang berstatus Batal pada data uji berhasil dikenali, sehingga karakteristik tersebut menjadi pertimbangan penting dalam pemilihan algoritma untuk permasalahan pembatalan pesanan. Performa tersebut menunjukkan bahwa pendekatan *bagging* pada *Random Forest*, yang menggabungkan sejumlah *decision tree*, mampu menghasilkan klasifikasi yang stabil pada karakteristik data transaksi yang digunakan. Meskipun XGBoost juga menghasilkan performa yang tinggi dan

memiliki kemampuan diskriminasi kelas yang sedikit lebih baik berdasarkan *ROC-AUC*, keunggulan *Random Forest* pada sebagian besar metrik membuat algoritma tersebut lebih sesuai dengan tujuan penelitian.

Hasil interpretasi SHAP menunjukkan bahwa Total Diskon, Ongkos Kirim Dibayar oleh Pembeli, Perkiraan Ongkos Kirim, dan Estimasi Potongan Biaya Pengiriman merupakan variabel yang paling berkontribusi terhadap prediksi pembatalan pesanan. Dominasi variabel tersebut menunjukkan bahwa informasi yang berkaitan dengan komponen biaya dan insentif transaksi lebih banyak dimanfaatkan dibandingkan beberapa karakteristik transaksi lainnya. Secara logis, kondisi tersebut dapat dikaitkan dengan pertimbangan ekonomi dalam transaksi *e-commerce*, karena perubahan nilai diskon dan biaya pengiriman dapat memengaruhi manfaat transaksi serta biaya akhir yang dipertimbangkan pelanggan. Temuan ini memberikan implikasi bahwa pengelola platform maupun penjual perlu memperhatikan struktur diskon dan biaya pengiriman ketika merancang strategi transaksi. Namun, kontribusi SHAP merupakan interpretasi terhadap keputusan dan tidak dapat digunakan untuk menyatakan hubungan sebab-akibat secara langsung antara variabel tersebut dan pembatalan pesanan.

Hasil penelitian ini memperkuat temuan sebelumnya yang menunjukkan bahwa *Random Forest* mampu memberikan performa yang baik dalam prediksi pembatalan pesanan pada sektor *e-commerce* [4], [7]. Sementara itu, penggunaan SHAP dalam penelitian terdahulu menunjukkan bahwa metode tersebut dapat membantu mengidentifikasi variabel yang berkontribusi terhadap hasil prediksi pada permasalahan pelanggan [14]. Perbedaan penelitian ini terletak pada penggabungan perbandingan *Random Forest* dan XGBoost dengan interpretasi SHAP dalam konteks prediksi pembatalan pesanan pada platform Shopee. Pendekatan tersebut memberikan hasil yang tidak hanya berfokus pada pemilihan algoritma dengan performa terbaik, tetapi juga menghasilkan informasi mengenai faktor transaksi yang paling berkontribusi terhadap prediksi pembatalan. Temuan ini dapat menjadi bahan pertimbangan bagi pengelola platform maupun penjual dalam mengevaluasi strategi diskon dan biaya pengiriman sebagai bagian dari upaya mengantisipasi potensi pembatalan pesanan.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa penerapan *machine learning* dapat membantu mengidentifikasi transaksi yang berpotensi mengalami pembatalan pada platform Shopee, dengan *Random Forest* menjadi algoritma yang paling sesuai berdasarkan hasil evaluasi keseluruhan. Interpretasi menggunakan SHAP menunjukkan bahwa Total Diskon, Ongkos Kirim Dibayar oleh Pembeli, Perkiraan Ongkos Kirim, dan Estimasi Potongan Biaya Pengiriman merupakan variabel yang paling dominan dalam pembentukan prediksi. Temuan tersebut memberikan implikasi praktis bagi pengelola platform maupun penjual untuk memperhatikan komponen diskon dan biaya pengiriman dalam mengevaluasi transaksi yang berpotensi mengalami pembatalan. Informasi tersebut dapat digunakan sebagai bahan pertimbangan dalam mengevaluasi strategi promosi, pemberian potongan harga, serta kebijakan biaya pengiriman agar upaya mitigasi pembatalan dapat dilakukan secara lebih tepat sasaran. Penggunaan SHAP juga memberikan interpretasi terhadap kontribusi masing-masing variabel sehingga hasil prediksi lebih mudah dipahami dan dapat mendukung pengambilan keputusan berbasis data. Penelitian ini masih terbatas pada penggunaan satu dataset publik dengan periode tertentu dan perbandingan dua algoritma *machine learning*. Penelitian selanjutnya dapat menggunakan dataset dari periode dan sumber yang lebih beragam untuk menguji konsistensi hasil pada karakteristik transaksi yang berbeda, menerapkan *hyperparameter tuning* secara sistematis untuk memperoleh konfigurasi model yang lebih optimal, serta membandingkan algoritma *machine learning* lainnya. Selain itu, metode XAI alternatif seperti LIME dapat digunakan sebagai pembanding untuk mengetahui konsistensi faktor yang berkontribusi terhadap prediksi pembatalan pesanan.

5. PERNYATAAN PENULIS

5.1 Kontribusi Penulis

Konseptualisasi: M.B.S., M.A., dan A.M.;

Metodologi: M.B.S., M.A., dan A.M.;

Perangkat Lunak: M.B.S.;

Validasi: M.B.S., M.A., dan A.M.;

Analisis Formal: M.B.S., M.A., dan A.M.;

Investigasi: M.B.S., M.A., dan A.M.;

Sumber Daya: M.B.S., M.A., dan A.M.;

Kurasi Data: M.B.S.;

Penulisan Draf Awal: M.B.S., M.A., dan A.M.;

Penulisan, Peninjauan, dan Penyuntingan: M.B.S., M.A., dan A.M., R.D.K., dan A.A.;

Visualisasi: M.B.S., M.A., dan A.M.;

Seluruh penulis telah membaca dan menyetujui versi manuskrip yang telah diterbitkan.

5.2 Ketersediaan Data

Data yang disajikan dalam penelitian ini tersedia berdasarkan permintaan kepada penulis pertama.

5.3 Pendanaan

Penelitian ini tidak menerima pendanaan eksternal.

5.4 Pernyataan Dewan Peninjau Institusional

Tidak Berlaku (*Not applicable*)

5.5 Pernyataan Persetujuan Berdasarkan Informasi

Tidak Berlaku (*Not applicable*)

5.6 Pernyataan Konflik Kepentingan

Para penulis menyatakan bahwa mereka tidak memiliki kepentingan keuangan yang bersaing atau hubungan pribadi yang diketahui yang dapat dianggap memengaruhi pekerjaan yang dilaporkan dalam artikel ini.

5.7 Penggunaan AI Generatif dan Teknologi Berbantuan AI dalam Proses Penulisan

Para penulis menggunakan AI Generatif untuk meningkatkan kejelasan penulisan dalam artikel ini. Para penulis telah meninjau dan menyunting konten yang dihasilkan dengan bantuan AI serta bertanggung jawab penuh atas versi akhir publikasi.

REFERENCES

- [1] R. Fandiyanto *et al.*, “Perkembangan E-Commerce Dari Masa Ke Masa: Sejarah, Tren, Dan Faktor-Faktor Yang Memengaruhi Kemajuan Transaksi Online Di Indonesia,” *Jurnal Mahasiswa Entrepreneurship (JME)*, vol. 4, no. 3, p. 448, 2025, doi: 10.36841/jme.v4i3.6574.
- [2] Z. Alamin, R. Missouri, S. Sutriawan, F. Fathir, and K. Khairunnas, “Perkembangan E-commerce: Analisis Dominasi Shopee sebagai Primadona Marketplace di Indonesia,” *J-ESA (Jurnal Ekonomi Syariah)*, vol. 6, no. 2, pp. 120–131, 2023, doi: 10.52266/jesa.v6i2.2484.
- [3] A. M. Hikmah, M. Mahmud, and T. A. Darodjat, “Modeling the Drivers of Online Purchase Decisions: An Empirical Study of Shopee Users in Indonesia,” *International Journal Of Accounting, Management, And Economics Research*, vol. 3, no. 1, pp. 77–95, Oct. 2025, doi: 10.56696/ijamer.v3i1.164.
- [4] K. ŞAHİNBAŞ, “Predicting Order Cancellations for E-Commerce Domain: A Proposed Model Based on Retailing Experience,” *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, vol. 11, no. 3, pp. 1493–1514, Sep. 2022, doi: 10.15869/itobiad.1127578.
- [5] I. Boukrouh and A. Azmani, “Explainable machine learning models applied to predicting customer churn for e-commerce,” *IAES International Journal of Artificial Intelligence*, vol. 14, no. 1, pp. 286–297, 2025, doi: 10.11591/ijai.v14.i1.pp286-297.
- [6] R. Alamsyah, “Using Random Forest and Support Vector Machine Algorithms to Predict Online Shopper Purchase Intention from E-Commerce Session Data,” *International Journal for Applied Information Management*, vol. 4, no. 2, pp. 84–96, Jun. 2024, doi: 10.47738/ijaim.v4i2.81.
- [7] Z. S. Sari, B. Taşkapi, G. Dağdaş, and M. F. Akay, “Development of Machine Learning-Based Sales Cancellation/Return Forecasting Models for the E-Commerce Industry,” in *International Conference on Advances in Electrical-Electronics Engineering and Computer Science Proceedings*, SETSCI, Nov. 2024, pp. 17–21. doi: 10.36287/setsci.19.5.022.
- [8] Angelin and S. A. Sanjaya, “Minimizing E-commerce Order Cancellation Cost Using Shap-based Explainable XGBoost,” in *2025 4th International Conference on Smart Cities, Automation & Intelligent Computing Systems (ICON-SONICS)*, IEEE, Oct. 2025, pp. 164–169. doi: 10.1109/ICON-SONICS67145.2025.11309270.
- [9] R. E. Bawack, S. F. Wamba, K. D. A. Carillo, and S. Akter, “Artificial intelligence in E-Commerce: a bibliometric study and literature review,” *Electronic Markets*, vol. 32, no. 1, pp. 297–338, Mar. 2022, doi: 10.1007/s12525-022-00537-z.
- [10] P. Chugh and V. Jain, “Artificial Intelligence (AI) Empowerment in E-Commerce: A Bibliometric Voyage,” *NMIMS Management Review*, vol. 32, no. 3, pp. 159–173, Sep. 2024, doi: 10.1177/09711023241303621.
- [11] J. A. Bastos and M. I. Bernardes, “Understanding Online Purchases with Explainable Machine Learning,” *Information*, vol. 15, no. 10, p. 587, Sep. 2024, doi: 10.3390/info15100587.
- [12] R. Maulidia and W. Yustanti, “Implementation of the Support Vector Machine (SVM) Algorithm in Predicting Transaction Cancellations at Shopee E-commerce,” *Journal of Emerging Information Systems and Business Intelligence (JEISBI)*, vol. 6, no. 1, Apr. 2025, doi: 10.26740/jeisbi.v6i1.64414.
- [13] F. N. F. Insani and Denny, “Optimizing E-Commerce in Indonesia: Ensemble Learning for Predicting Potential Buyers,” *Indonesian Journal of Computer Science*, vol. 13, no. 1, Feb. 2024, doi: 10.33022/ijcs.v13i1.3690.
- [14] D. Amanda Ardhani and K. D. Tania, “Knowledge Discovery on E-Commerce Customer Churn Using Interpretable Machine Learning: A Comparative Study of SHAP-Based Classifiers,” *Journal of Applied Informatics and Computing*, vol. 9, no. 5, pp. 2695–2702, Oct. 2025, doi: 10.30871/jaic.v9i5.10811.
- [15] Christoph Molnar, *Interpretable Machine Learning: A Guide for Making Black Box Models Explainable*, 3rd ed. Christoph Molnar, 2025. [Online]. Available: <https://christophm.github.io/interpretable-ml-book/>
- [16] G. Vilone and L. Longo, “Notions of explainability and evaluation approaches for explainable artificial intelligence,” *Information Fusion*, vol. 76, pp. 89–106, Dec. 2021, doi: 10.1016/j.inffus.2021.05.009.
- [17] J. Brasse, H. R. Broder, M. Förster, M. Klier, and I. Sigler, “Explainable artificial intelligence in information systems: A review of the status quo and future research directions,” *Electronic Markets*, vol. 33, no. 1, p. 26, Dec. 2023, doi: 10.1007/s12525-023-00644-5.



- [18] W. Priatna, Hindriyanto Dwi Purnomo, Ade Iriani, Irwan Sembiring, and Theophilus Wellem, “Optimizing Multilayer Perceptron with Cost-Sensitive Learning for Addressing Class Imbalance in Credit Card Fraud Detection,” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 8, no. 4, pp. 563–570, Aug. 2024, doi: 10.29207/resti.v8i4.5917.
- [19] N. Kiesler *et al.*, “Where’s the Data? Finding and Reusing Datasets in Computing Education,” in *Working Group Reports on 2023 ACM Conference on Global Computing Education*, New York, NY, USA: ACM, Sep. 2024, pp. 31–60. doi: 10.1145/3598579.3689378.
- [20] J. Hu and S. Szymczak, “A review on longitudinal data analysis with random forest,” *Brief. Bioinform.*, vol. 24, no. 2, Mar. 2023, doi: 10.1093/bib/bbad002.
- [21] J. H. Cabot and E. G. Ross, “Evaluating prediction model performance,” *Surgery*, vol. 174, no. 3, pp. 723–726, Sep. 2023, doi: 10.1016/j.surg.2023.05.023.
- [22] M. Li, H. Sun, Y. Huang, and H. Chen, “Shapley value: from cooperative game to explainable artificial intelligence,” *Autonomous Intelligent Systems*, vol. 4, no. 1, p. 2, Feb. 2024, doi: 10.1007/s43684-023-00060-8.
- [23] M. Asfi, B. Warsito, and A. Wibowo, “Enhancing Explainable AI: Leveraging SHAP for Transparent Decision-Making in Machine Learning,” in *2024 Ninth International Conference on Informatics and Computing (ICIC)*, IEEE, Oct. 2024, pp. 1–6. doi: 10.1109/ICIC64337.2024.10956244.
- [24] F. Le and J. Zhai, “Research on cross-border e-commerce customer churn prediction based on enhanced XGBoost algorithm with temporal-spatial features,” *Journal of Computational Methods in Sciences and Engineering*, vol. 25, no. 5, pp. 4407–4418, Sep. 2025, doi: 10.1177/14727978251337888.
- [25] Y. Chen, H. Liu, Z. Wen, and W. Lin, “How Explainable Machine Learning Enhances Intelligence in Explaining Consumer Purchase Behavior: A Random Forest Model with Anchoring Effects,” *Systems*, vol. 11, no. 6, p. 312, Jun. 2023, doi: 10.3390/systems11060312.
- [26] J. A. Bastos and M. I. Bernardes, “Understanding Online Purchases with Explainable Machine Learning,” *Information*, vol. 15, no. 10, p. 587, Sep. 2024, doi: 10.3390/info15100587.