

**STUDI KOMPARATIF ALGORITMA RANDOM FOREST
DAN XGBOOST UNTUK ANALISIS PERILAKU
KONSUMEN E-COMMERCE**

SKRIPSI

Diajukan untuk memenuhi salah satu syarat mencapai derajat Sarjana
Program Studi S1 Informatika



disusun oleh

AZZILA ISME KAREN

20.11.3312

Kepada

**FAKULTAS ILMU KOMPUTER
UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA**

2024

**STUDI KOMPARATIF ALGORITMA RANDOM FOREST
DAN XGBOOST UNTUK ANALISIS PERILAKU
KONSUMEN E-COMMERCE**

SKRIPSI

Diajukan untuk memenuhi salah satu syarat mencapai derajat Sarjana
Program Studi S1 Informatika



disusun oleh
AZZILA ISME KAREN
20.11.3312

Kepada

FAKULTAS ILMU KOMPUTER
UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA
2024

HALAMAN PERSETUJUAN

SKRIPSI

**STUDI KOMPARATIF ALGORITMA RANDOM FOREST
DAN XGBOOST UNTUK ANALISIS PERILAKU
KONSUMEN E-COMMERCE**

yang disusun dan diajukan oleh

AZZILA ISME KAREN

20.11.3312

telah disetujui oleh Dosen Pembimbing Skripsi
pada tanggal 20 Agustus 2024

Dosen Pembimbing,



Arif Akbarul Huda, S.Si., M.Eng.

NIK. 190302287

HALAMAN PENGESAHAN

SKRIPSI

STUDI KOMPARATIF ALGORITMA RANDOM FOREST
DAN XGBOOST UNTUK ANALISIS PERILAKU
KONSUMEN E-COMMERCE

yang disusun dan diajukan oleh

AZZILA ISME KAREN

20.11.3312

Telah dipertahankan di depan Dewan Pengaji
pada tanggal 20 Agustus 2024

Susunan Dewan Pengaji

Nama Pengaji

Ike Verawati, M.Kom
NIK. 190302237

Tanda Tangan





Bayu Setiaji, M.Kom
NIK. 190302216

Arif Akbarul Huda, S.Si, M.Eng
NIK. 190302287

Skripsi ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Sarjana Komputer
Tanggal 20 Agustus 2024

DEKAN FAKULTAS ILMU KOMPUTER



Hanif Al Fatta, S.Kom., M.Kom., Ph.D

NIK. 190302696

HALAMAN PERNYATAAN KEASLIAN SKRIPSI

Yang bertandatangan di bawah ini,

**Nama mahasiswa : Azzila Isme Karen
NIM : 20.11.3312**

Menyatakan bahwa Skripsi dengan judul berikut:

STUDI KOMPARATIF ALGORITMA RANDOM FOREST DAN XGBOOST UNTUK ANALISIS PERILAKU KONSUMEN E-COMMERCE

Dosen Pembimbing : Arif Akbarul Huda, S.Si., M.Eng

1. Karya tulis ini adalah benar-benar ASLI dan BELUM PERNAH diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya.
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian SAYA sendiri, tanpa bantuan pihak lain kecuali arahan dari Dosen Pembimbing.
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini.
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab SAYA, bukan tanggung jawab Universitas AMIKOM Yogyakarta.
5. Pernyataan ini SAYA buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka SAYA bersedia menerima SANKSI AKADEMIK dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi.

Yogyakarta, 20 Agustus 2024

Yang Menyatakan,



Azzila Isme Karen

HALAMAN PERSEMBAHAN

Dengan tulus, penuh penghargaan dan rasa syukur, halaman persembahan ini disusun sebagai ungkapan terima kasih atas dukungan, kontribusi dan dedikasinya atas perjalanan penulisan Skripsi yang berjudul “Studi Komparatif Algoritma *Random Forest* dan *XGBoost* untuk Analisis Perilaku Konsumen *E-commerce*”.

- 1 *Tuhan Yang Maha Esa*, terima kasih atas rahmat, karunia, dan kekuatan yang telah Engkau anugerahkan selama perjalanan ini.
- 2 *Rasulullah Sallallahu 'Alaihi Wasallam*, motivator dan panutan saya untuk selalu menjadi pengingat untuk memperbaiki diri.
- 3 Ayah dan Ibu tercinta yang tulus memberikan do'a, dukungan, dan dorongan yang tiada henti tercurahkan melalui keringat, usaha dan kekuatan hati yang setia menemani sehingga dapat mencapai titik ini.
- 4 Kepada Paguyuban Perbengkelan yang senantiasa memberikan pesan motivasi dan menerima apapun keadaan saya untuk selalu semangat menjalani hari-hari penuh warna ini.
- 5 Terima kasih kepada adik-adik saya yang selalu meluangkan waktu dengan memberikan berbagai dukungan dan menemani saya melepas penat dikala letih.
- 6 Kepada Bapak Arif Akbarul Huda, S.Si., M.Eng., yang telah memberikan bimbingan, arahan, dan berbagi pengetahuan baru.
- 7 Teman-teman yang telah memberikan semangatnya untuk menyelesaikan skripsi ini.

Dedikasi ini merupakan bentuk penghormatan dan terima kasih yang tulus kepada mereka yang telah berperan penting dalam perjalanan penelitian ini. Semoga setiap kata yang tercurah mampu mencerminkan rasa terima kasih yang mendalam.

KATA PENGANTAR

Segala puji terhadap *Allah Subhanallahu wa ta'ala* atas rahmat dan karunia-Nya sehingga penulis dapat menuntaskan skripsi bertajuk "STUDI KOMPARATIF ALGORITMA RANDOM FOREST DAN XGBOOST UNTUK ANALISIS PERILAKU KONSUMEN E-COMMERCE" dengan baik. Skripsi ini merupakan tugas akhir serta syarat untuk menyelesaikan studi Program Sarjana (S1) Fakultas Ilmu Komputer Prodi Informatika.

Melalui dukungan dan kontribusi dari berbagai pihak, penulis menuturkan terima kasih kepada:

1. Bapak Prof. Dr. M. Suyanto, M.M., Rektor Universitas Amikom Yogyakarta.
2. Ibu Windha Mega Pradnya D, M.Kom., Ketua Program Studi S1 Informatika.
3. Bapak Arif Akbarul Huda, S.Si., M.Eng., Dosen pembimbing yang telah memberikan arahan, saran dan berbagi pengetahuan baru.

Penulis menyadari bahwa masih terdapat keterbatasan dan kekurangan dalam penyusunan penelitian ini. Penulis mengharapkan kritik dan saran membangun guna membantu penyempurnaan skripsi ini. Semoga penelitian ini memberikan andil yang bermanfaat untuk memahami kinerja algoritma *Random Forest* dan *XGBoost* pada studi perilaku konsumen dalam perkembangan bidang *e-commerce*.

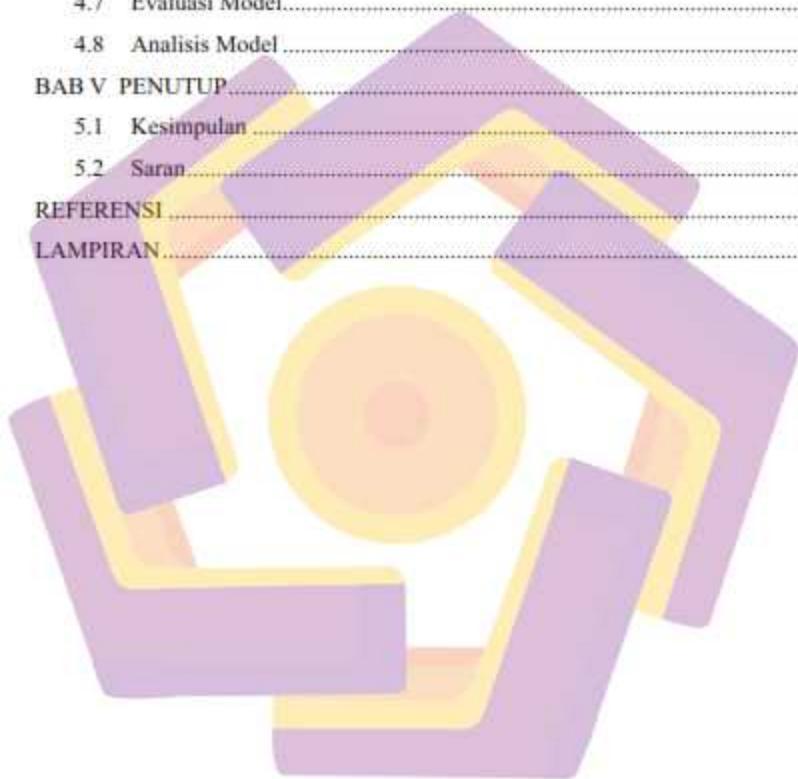
Yogyakarta, 20 Agustus 2024

Penulis

DAFTAR ISI

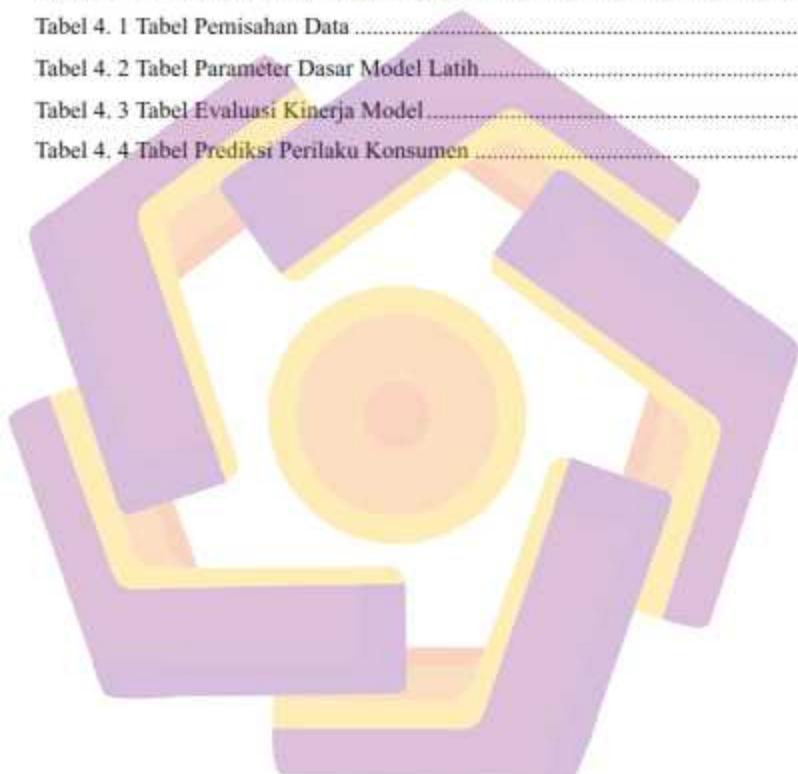
HALAMAN JUDUL.....	i
HALAMAN PERSETUJUAN.....	ii
HALAMAN PENGESAHAN.....	iii
HALAMAN PERNYATAAN KEASLIAN SKRIPSI.....	iv
HALAMAN PERSEMBAHAN.....	v
KATA PENGANTAR.....	vi
DAFTAR ISI.....	vii
DAFTAR TABEL.....	ix
DAFTAR GAMBAR.....	x
DAFTAR LAMBANG DAN SINGKATAN.....	xii
DAFTAR ISTILAH.....	xiii
INTISARI.....	xiv
<i>ABSTRACT.....</i>	xv
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	2
1.3 Batasan Masalah.....	2
1.4 Tujuan Penelitian.....	2
1.5 Manfaat Penelitian	2
1.6 Sistematika Penulisan.....	3
BAB II TINJAUAN PUSTAKA.....	4
2.1 Studi Literatur	4
2.2 Dasar Teori	11
BAB III METODE PENELITIAN.....	21
3.1 Objek Penelitian.....	21
3.2 Alur Penelitian	21
3.3 Alat dan Bahan.....	23
BAB IV HASIL DAN PEMBAHASAN.....	25
4.1 Persiapan Awal	25

4.2	<i>Pre-processing</i>	27
4.3	EDA	36
4.4	<i>Feature Selection</i>	37
4.5	Pemisahan Data	37
4.6	Pemodelan	39
4.7	Evaluasi Model	40
4.8	Analisis Model	45
BAB V PENUTUP		48
5.1	Kesimpulan	48
5.2	Saran	49
REFERENSI		50
LAMPIRAN		54



DAFTAR TABEL

Tabel 2. 1 Tabel Keaslian Penelitian	6
Tabel 2. 2 Tabel Penghitungan <i>Confusion Matrix</i>	16
Tabel 3. 1 Tabel Atribut <i>Dataset</i>	21
Tabel 3. 2 Tabel Deskripsi Variabel Penelitian.....	24
Tabel 4. 1 Tabel Pemisahan Data	39
Tabel 4. 2 Tabel Parameter Dasar Model Latih.....	39
Tabel 4. 3 Tabel Evaluasi Kinerja Model.....	46
Tabel 4. 4 Tabel Prediksi Perilaku Konsumen	47



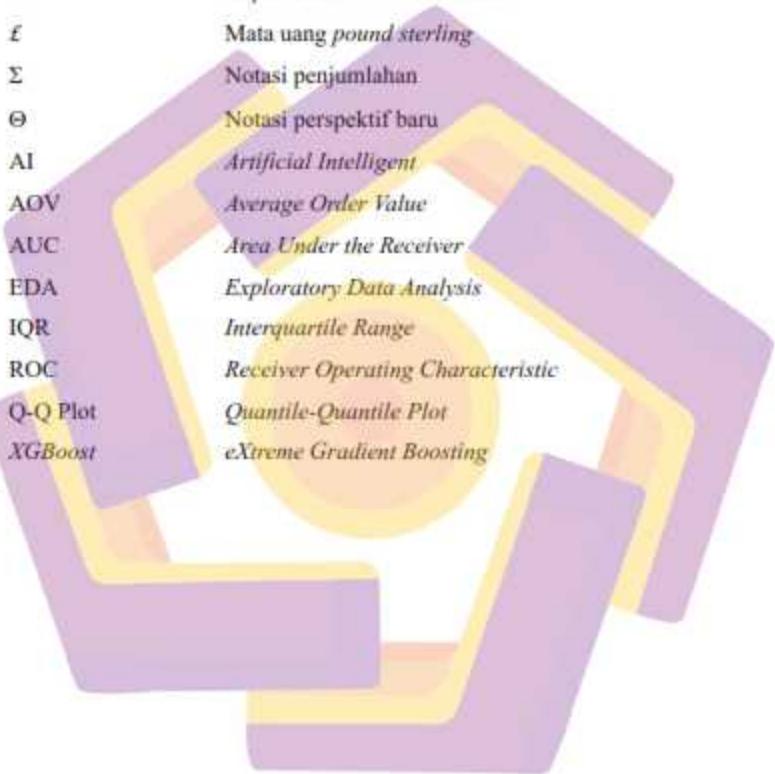
DAFTAR GAMBAR

Gambar 3. 1 Alur Penelitian.....	23
Gambar 3. 2 Bentuk <i>Dataset</i>	24
Gambar 4. 1 <i>Mount Dataset</i>	26
Gambar 4. 2 Membaca Dataset	26
Gambar 4. 3 Tampilan Dataset Ritel <i>Online</i>	26
Gambar 4. 4 Struktur Dataset Ritel <i>Online</i>	27
Gambar 4. 5 Riwayat Transaksi <i>Dataset Ritel Online</i>	27
Gambar 4. 6 Riwayat Pesanan Dibatalkan.....	28
Gambar 4. 7 Persentase Riwayat Pesanan.....	28
Gambar 4. 8 Indeks Karakter Unik	29
Gambar 4. 9 Penyaringan Data Entri	29
Gambar 4. 10 Pengecekan <i>Missing Values</i>	30
Gambar 4. 11 Persentase <i>Missing Values</i>	30
Gambar 4. 12 Menangani <i>Missing Values</i>	30
Gambar 4. 13 Menangani <i>Duplicated Entries</i>	31
Gambar 4. 14 Entri Duplikat yang Dihapus.....	31
Gambar 4. 15 Visualisasi <i>Outliers</i> menggunakan Q-Q Plot.....	31
Gambar 4. 16 Mengangani <i>Outliers</i> pada Fitur <i>Quantity</i>	32
Gambar 4. 17 Menangani <i>Outliers</i> pada Fitur <i>UnitPrice</i>	32
Gambar 4. 18 Hasil Menangani <i>Extreme Outliers</i>	33
Gambar 4. 19 Membuat Fitur Total Pembelian.....	33
Gambar 4. 20 Representasi Total Belanja Konsumen.....	34
Gambar 4. 21 Membuat <i>DataFrame</i> Baru	34
Gambar 4. 22 Tampilan <i>Dataset Ritel Online</i> Baru	35
Gambar 4. 23 Kriteria Fitur <i>CustomerLoyalty</i>	35
Gambar 4. 24 Membuat Fitur Loyalitas Pelanggan	36
Gambar 4. 25 10 Pelanggan Loyal Teratas	36
Gambar 4. 26 Hubungan Kuantitas dan Harga Satuan.....	37
Gambar 4. 27 Struktur Baru <i>Dataset</i>	37

Gambar 4. 28 <i>Feature Separation</i>	38
Gambar 4. 29 <i>Splitting Data</i>	38
Gambar 4. 30 Distribusi Data Asli	38
Gambar 4. 31 Menangani Data tidak Seimbang	39
Gambar 4. 32 Distribusi Data Terkini	39
Gambar 4. 33 <i>Random Forest Model</i>	39
Gambar 4. 34 <i>XGBoost Model</i>	40
Gambar 4. 35 <i>Random Forest Confusion Matrix</i>	41
Gambar 4. 36 <i>XGBoost Confusion Matrix</i>	43
Gambar 4. 37 Perbedaan Prediksi Model dengan Fitur Asli	47



DAFTAR LAMBANG DAN SINGKATAN



γ	Mengontrol kompleksitas model
λ	Regularisasi L2
Ω	Representasi keseluruhan fungsi regularisasi
ω	Representasi bobot individual
\pounds	Mata uang <i>pound sterling</i>
Σ	Notasi penjumlahan
Θ	Notasi perspektif baru
AI	<i>Artificial Intelligent</i>
AOV	<i>Average Order Value</i>
AUC	<i>Area Under the Receiver</i>
EDA	<i>Exploratory Data Analysis</i>
IQR	<i>Interquartile Range</i>
ROC	<i>Receiver Operating Characteristic</i>
Q-Q Plot	<i>Quantile-Quantile Plot</i>
XGBoost	<i>Extreme Gradient Boosting</i>

DAFTAR ISTILAH

Bias	Perbedaan antara nilai prediksi model dan nilai asli.
<i>Credit Card Default</i>	Peminjam yang gagal membayar minimum hutang kartu kredit dalam jangka waktu tertentu.
<i>DataFrame</i>	Struktur data dua dimensi yang terdiri dari baris dan kolom.
Dataset	Kumpulan data yang terstruktur untuk melatih, menguji, dan mengevaluasi model <i>machine learning</i> .
Interpretabilitas	Kemampuan model untuk memberikan penjelasan yang jelas dan dapat dimengerti atas prediksi atau keputusannya.
<i>Intervening</i>	Variabel yang mempengaruhi hubungan antara variabel independen dan variabel dependen.
<i>Meta-algorithmic</i>	Pendekatan tingkat tinggi dengan menggabungkan beberapa algoritma/model untuk mencapai solusi yang lebih kuat menggunakan sistem transparan dan adaptif.
<i>Overfitting</i>	Model terlalu baik untuk memprediksi data latih, namun kurang sensitif untuk memprediksi data baru.
<i>Recency</i>	Waktu terakhir kali suatu transaksi terjadi.
<i>Records</i>	Entri atau baris tunggal berisi informasi atau nilai tertentu yang terdiri dari beberapa bidang atau atribut.
<i>Robust</i>	Kemampuan model untuk mempertahankan akurasi dan stabilitas dalam menghadapi kondisi tidak ideal.
<i>Skew</i>	Ukuran asimetri dalam distribusi probabilitas.
Sparsitas	Kemampuan model mengidentifikasi dan fokus pada fitur penting dan mengabaikan fitur tidak relevan dalam dataset.
Spesifisitas	Proporsi contoh negatif yang diidentifikasi dengan benar.
Varians	Ukuran seberapa besar variasi prediksi model pada dataset yang sama.

INTISARI

Selama beberapa tahun terakhir, algoritma *Random Forest* dan algoritma *eXtreme Gradient Boosting (XGBoost)* populer untuk analisis perilaku konsumen. Namun, ditengah kepopulerannya, banyak perdebatan mana algoritma yang kompatibel untuk analisis perilaku konsumen di antara keduanya. Hal tersebut dibuktikan oleh beberapa penelitian yang menunjukkan bahwa *Random Forest* kompatibel untuk menangani distribusi data tidak seimbang, sedangkan *XGBoost* kompatibel untuk menangani data besar dan kompleks. Oleh sebab itu, penelitian ini akan membuktikan mana algoritma yang kompatibel dalam menangani *dataset* besar yang tidak seimbang dan kompleks untuk analisis perilaku konsumen *e-commerce* melalui perbandingan kinerja algoritma *Random Forest* dan *XGBoost*. Hasilnya, kedua algoritma tersebut mencapai nilai *accuracy* di atas 98%, dengan algoritma *Random Forest* sedikit lebih unggul (98.43%) dibandingkan algoritma *XGBoost* (98.40%). Begitu pula pada nilai *recall* algoritma *Random Forest* yang dapat mengungguli algoritma *XGBoost* (98.40% vs 98.00%). Sebaliknya, algoritma *XGBoost* lebih unggul daripada algoritma *Random Forest* pada nilai *precision* (97.23% vs 96.48%) dan nilai F1 (97.61% vs 97.43%). Adanya nilai AUC yang sangat tinggi (0.9992 untuk algoritma *Random Forest* dan 0.9993 untuk algoritma *XGBoost*) mengindikasikan bahwa kedua algoritma tersebut mampu membedakan kelas dengan hampir sempurna. Adapun hasil prediksi algoritma *XGBoost* yang sedikit lebih seimbang (253 loyal dan 583 tidak loyal) dibandingkan dengan algoritma *Random Forest* (256 loyal dan 580 tidak loyal) membuktikan bahwa algoritma *XGBoost* berkinerja lebih optimal untuk menangani dataset besar yang tidak seimbang dan kompleks. Berdasarkan hasil tersebut, penelitian ini dapat memberikan kontribusi pada pengembangan metode analisis perilaku konsumen pada industri *e-commerce* dan meningkatkan kemampuan algoritma *machine learning* untuk analisis perilaku konsumen *e-commerce*.

Kata kunci: Studi Komparatif, *Random Forest*, *XGBoost*, *E-Commerce*, Analisis Perilaku Konsumen

ABSTRACT

Over the past few years, Random Forest algorithm and eXtreme Gradient Boosting (XGBoost) algorithm are popular for consumer behavior analysis. However, amidst their popularity, there is a lot of debate on which algorithm is compatible for consumer behavior analysis between the two. This is evidenced by several studies that show that Random Forest is compatible for handling unbalanced data distribution, while XGBoost is compatible for handling large and complex data. Therefore, this study will prove which algorithm is compatible in handling large unbalanced and complex datasets for e-commerce consumer behavior analysis through a performance comparison of Random Forest and XGBoost algorithms. As a result, both algorithms achieved accuracy values above 98%, with the Random Forest algorithm slightly superior (98.43%) to the XGBoost algorithm (98.40%). Similarly, the recall value of the Random Forest algorithm can outperform the XGBoost algorithm (98.40% vs 98.00%). In contrast, the XGBoost algorithm is superior to the Random Forest algorithm in the precision value (97.23% vs 96.48%) and F1 value (97.61% vs 97.43%). The existence of very high AUC values (0.9992 for Random Forest algorithm and 0.9993 for XGBoost algorithm) indicates that both algorithms are able to distinguish classes almost perfectly. The slightly more balanced prediction results of the XGBoost algorithm (253 loyal and 583 non-loyal) compared to the Random Forest algorithm (256 loyal and 580 non-loyal) prove that the XGBoost algorithm performs more optimally for handling large unbalanced and complex datasets. Based on these results, this research can contribute to the development of consumer behavior analysis methods in the e-commerce industry and improve the ability of machine learning algorithms for e-commerce consumer behavior analysis.

Keywords: Comparative Study, Random Forest, XGBoost, E-Commerce, Consumer Behavior Analysis