

Klasifikasi Impulse Buying Pada TikTok Shop Live Streaming Menggunakan Algoritma XGBoost

Classification of Impulse Buying on TikTok Shop Live Streaming Using the XGBoost Algorithm

Fini Ikhfiani Fadilah
Informatika
Universitas Amikom Purwokerto
Purwokerto, Indonesia
finifadilah15@gmail.com

Purwadi*
Magister Ilmu Komputer
Universitas Amikom Purwokerto
Purwokerto, Indonesia
purwadi@amikompurwokerto.ac.id

Diterima : Mei 2026
Disetujui : Juni 2026
Dipublikasi : Juli 2026

Abstrak— Perkembangan social commerce melalui platform TikTok Shop telah mengubah pola interaksi antara penjual dan konsumen melalui fitur live streaming yang memungkinkan pengalaman belanja secara interaktif dan real-time. Penelitian ini bertujuan mengklasifikasikan perilaku Impulse Buying pada aktivitas TikTok Shop Live Streaming menggunakan algoritma XGBoost. Dataset penelitian terdiri atas 300 data hasil observasi aktivitas live streaming akun TikTok Igameivia selama periode Januari–April 2026. Variabel yang digunakan meliputi durasi live streaming, jumlah tayangan, impresi live, jumlah komentar, dan followers baru. Variabel jumlah pesanan dan Gross Merchandise Value (GMV) dikeluarkan dari model karena berpotensi menyebabkan feature leakage. Tahapan penelitian meliputi preprocessing data, pembagian data menggunakan rasio 80:20, pelatihan model XGBoost, serta evaluasi menggunakan Accuracy, Precision, Recall, F1-Score, Confusion Matrix, dan ROC-AUC. Hasil pengujian menunjukkan bahwa model memperoleh Accuracy sebesar 81,67%, Precision sebesar 82,93%, Recall sebesar 89,47%, F1-Score sebesar 86,08%, dan ROC-AUC sebesar 0,8732. Hasil tersebut menunjukkan bahwa model memiliki kemampuan yang baik dalam membedakan perilaku Impulse Buying dan Non-Impulse Buying. Analisis feature importance menunjukkan bahwa jumlah komentar, impresi live, dan followers baru merupakan variabel yang paling berkontribusi dalam proses klasifikasi. Temuan ini mengindikasikan bahwa tingkat interaksi dan jangkauan audiens selama sesi live streaming memiliki peran penting dalam mendorong perilaku pembelian impulsif. Dengan demikian, algoritma XGBoost dapat digunakan untuk mengidentifikasi kecenderungan Impulse Buying berdasarkan aktivitas live streaming serta mendukung pengambilan keputusan berbasis data pada platform TikTok Shop.

Kata Kunci— *Impulse Buying; Consumer Behavior; Live Commerce; TikTok Shop; Extreme Gradient Boosting (XGBoost)*

Abstract— The development of social commerce through the TikTok Shop platform has transformed the interaction patterns between sellers and consumers through live streaming features that enable an interactive and real-time shopping experience. This study aims to classify Impulse Buying behavior in TikTok Shop Live Streaming activities using the XGBoost algorithm. The dataset consists of 300 observations collected from live streaming sessions of the TikTok account Igameivia during the period of January–April 2026. The variables used include live streaming duration, views, live impressions, number of comments, and new followers. The number of orders and Gross Merchandise Value (GMV) variables were excluded from the model due to their potential to cause feature leakage. The research stages included data preprocessing, dataset splitting using an 80:20 ratio, XGBoost model training, and evaluation using Accuracy, Precision, Recall, F1-Score, Confusion Matrix, and ROC-AUC metrics. The results show that the model achieved an Accuracy of 81.67%, Precision of 82.93%, Recall of 89.47%, F1-Score of 86.08%, and ROC-AUC of 0.8732. These results indicate that the model has a good capability to distinguish between Impulse Buying and Non-Impulse Buying behaviors. Feature importance analysis revealed that the number of comments, live impressions, and new followers were the most influential variables in the classification process. These findings suggest that user engagement and audience reach during live streaming sessions play an important role in driving impulsive purchasing behavior. Therefore, the XGBoost algorithm can be utilized to identify Impulse Buying tendencies based on live streaming activities and support data-driven decision-making on the TikTok Shop platform.

Keywords— *Impulse Buying; Consumer Behavior; Live Commerce; TikTok Shop; Extreme Gradient Boosting (XGBoost)*

I. PENDAHULUAN

Beberapa penelitian terdahulu menunjukkan bahwa fitur *live streaming* belum memberikan pengaruh yang signifikan terhadap perilaku *impulse buying* konsumen. Sebagian besar penelitian tersebut menggunakan pendekatan statistik konvensional, seperti regresi linear, analisis korelasi, dan analisis deskriptif, yang berfokus pada pengujian hubungan antarvariabel serta tingkat signifikansinya. Meskipun pendekatan tersebut mampu menjelaskan pengaruh suatu variabel terhadap perilaku konsumen, metode tersebut memiliki keterbatasan dalam menangkap pola hubungan yang bersifat nonlinier, kompleks, dan dinamis pada data interaksi digital berskala besar. Selain itu, penelitian-penelitian sebelumnya umumnya belum memanfaatkan data aktivitas *live streaming* secara langsung untuk membangun model prediksi perilaku konsumen berbasis data historis.


Berdasarkan kondisi tersebut, terdapat *research gap* berupa masih terbatasnya penelitian yang menerapkan pendekatan *Machine Learning* untuk mengidentifikasi dan memprediksi perilaku *Impulse Buying* pada aktivitas *live streaming commerce*. Berbeda dengan penelitian terdahulu yang berfokus pada analisis hubungan statistik antarvariabel, penelitian ini memanfaatkan algoritma XGBoost untuk mempelajari pola interaksi pengguna secara otomatis dan menghasilkan klasifikasi perilaku *Impulse Buying* berdasarkan data aktivitas *live streaming* TikTok Shop[2]. Pendekatan ini memungkinkan identifikasi pola perilaku konsumen yang lebih kompleks melalui pemanfaatan berbagai indikator interaksi dan transaksi, seperti durasi *live streaming*, jumlah tayangan, impresi *live*, jumlah komentar, *followers* baru, *engagement rate*, dan *conversion rate*.

Kontribusi utama penelitian ini terletak pada penerapan algoritma XGBoost dalam konteks *live streaming commerce* untuk membangun model klasifikasi perilaku *Impulse Buying* berbasis data historis aktivitas TikTok Shop[3]. Selain menghasilkan prediksi perilaku konsumen, penelitian ini juga mengidentifikasi faktor-faktor yang memiliki kontribusi paling dominan melalui analisis *feature importance*. Dengan demikian, penelitian ini tidak hanya memberikan pemahaman mengenai hubungan antarvariabel sebagaimana penelitian sebelumnya, tetapi juga menyediakan pendekatan prediktif yang dapat dimanfaatkan dalam pengambilan keputusan pemasaran berbasis data pada platform *social commerce*.

II. METODE

Dalam penelitian ini, terdapat beberapa tahapan yang dilakukan untuk mencapai tujuan penelitian, yaitu mengklasifikasikan perilaku *impulse buying* pada *live streaming* TikTok Shop menggunakan pendekatan *Machine Learning*[4]. Tahapan tersebut meliputi studi literatur dan identifikasi variabel berdasarkan model Stimulus–Organism–Response (S-O-R), pengumpulan dan penyusunan dataset berbasis data sekunder, proses preprocessing dan transformasi data, perancangan serta pelatihan model *Machine Learning*, hingga tahap evaluasi dan analisis performa model. Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh secara langsung dari salah satu akun *live streaming* TikTok Shop[5].

Pengumpulan data dilakukan dengan mengamati aktivitas *live streaming* dan mencatat beberapa variabel yang berkaitan dengan perilaku pembelian impulsif, seperti durasi *live*, jumlah tayangan, jumlah komentar, peningkatan *followers*. Datatersebut kemudian disusun menjadi dataset penelitian yang digunakan sebagai dasar dalam proses analisis dan klasifikasi menggunakan algoritma *Machine Learning*. Tahapan penelitian keseluruhan disajikan pada Gambar 1.



Gambar 1. Tahapan Penelitian

A. Studi Literatur

Studi literatur dilakukan untuk memperoleh pemahaman teoritis dan konseptual terkait *social commerce*, *live streaming commerce*, perilaku *impulse buying*, serta penerapan *Machine Learning* dalam analisis perilaku konsumen digital. Sumber literatur yang digunakan dalam penelitian ini berasal dari jurnal ilmiah, buku referensi, prosiding, dan penelitian terdahulu yang relevan dengan topik penelitian. Kajian literatur dilakukan secara sistematis untuk mengidentifikasi perkembangan penelitian, menemukan kesenjangan penelitian (*research gap*), serta memperkuat landasan teoritis yang digunakan dalam penelitian ini.

Selain itu, penelitian ini menggunakan pendekatan *Stimulus–Organism–Response* (S-O-R) sebagai dasar teoritis untuk menjelaskan hubungan antara stimulus pemasaran pada fitur *live streaming*[6], respons psikologis konsumen, dan perilaku pembelian impulsif. Pendekatan tersebut digunakan untuk memahami bagaimana faktor-faktor interaksi selama *live streaming* dapat memengaruhi keputusan pembelian konsumen pada platform TikTok Shop.

B. Identifikasi Masalah

Tahap identifikasi masalah dilakukan berdasarkan framework *Stimulus–Organism–Response* (S-O-R) yang menjelaskan bahwa stimulus yang diterima konsumen akan memengaruhi kondisi psikologis (*organism*) dan menghasilkan respons perilaku tertentu. Dalam konteks TikTok Shop *Live Streaming*, framework ini digunakan untuk memahami hubungan antara aktivitas *live streaming* dan perilaku *Impulse Buying*.

Komponen stimulus (S) direpresentasikan oleh variabel durasi *live streaming*, tayangan, impresi *live*, jumlah komentar, dan *followers* baru yang mencerminkan tingkat eksposur serta interaksi pengguna selama siaran berlangsung. Komponen *organism* (O) menggambarkan kondisi psikologis konsumen, seperti perhatian terhadap produk, keterlibatan emosional, urgensi, dan *Fear of Missing Out* (FOMO), meskipun tidak diukur secara langsung dalam penelitian ini [7].

Selanjutnya, komponen response (R) direpresentasikan oleh perilaku Impulse Buying yang diklasifikasikan ke dalam kategori Impulse Buying (1) dan Non-Impulse Buying (0). Klasifikasi dilakukan menggunakan algoritma XGBoost untuk mengidentifikasi pola hubungan antara aktivitas live streaming dan kecenderungan pembelian impulsif [8]. Dengan demikian, framework S-O-R digunakan sebagai dasar konseptual dalam menjelaskan pengaruh aktivitas TikTok Shop Live Streaming terhadap perilaku Impulse Buying konsumen [9].

C. Pengumpulan Data (Scraping Dan Observasi Live Tiktok Shop)

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh melalui observasi langsung terhadap aktivitas live streaming pada akun TikTok Shop Igameivia. Pengumpulan data dilakukan selama periode Januari hingga April 2026 dengan mengamati sebanyak 5 sesi live streaming yang diselenggarakan oleh akun tersebut. Setiap sesi live streaming diamati secara sistematis menggunakan teknik observasi langsung (direct observation) untuk memperoleh data interaksi pengguna dan aktivitas transaksi yang terjadi selama siaran berlangsung.

Pengamatan dilakukan pada interval waktu setiap 5 menit selama sesi live streaming berlangsung. Rata-rata durasi setiap sesi live streaming adalah sekitar 300 menit, sehingga diperoleh sekitar 60 titik pengamatan pada setiap sesi. Dengan demikian, dari 5 sesi live streaming yang diamati, terkumpul 300 observasi yang digunakan sebagai dataset penelitian. Setiap observasi merepresentasikan kondisi aktivitas live streaming pada satu interval waktu tertentu, sehingga mampu menggambarkan dinamika interaksi pengguna dan transaksi secara lebih rinci dibandingkan apabila pengamatan hanya dilakukan pada tingkat sesi secara keseluruhan.

Variabel yang dikumpulkan meliputi durasi live streaming, jumlah tayangan, impresi live, jumlah komentar, followers baru. Pemilihan variabel tersebut didasarkan pada indikator aktivitas interaksi dan transaksi yang umum digunakan dalam analisis live commerce serta memiliki keterkaitan dengan perilaku pembelian konsumen. Seluruh data hasil observasi dicatat dan didokumentasikan menggunakan Microsoft Excel, kemudian disusun menjadi dataset terstruktur yang siap digunakan pada tahap preprocessing, pelatihan model, dan evaluasi menggunakan algoritma XGBoost[10].

Penentuan label Impulse Buying dilakukan berdasarkan karakteristik pembelian impulsif dalam konteks live commerce, yaitu adanya peningkatan aktivitas pembelian yang terjadi secara spontan selama sesi live streaming berlangsung. Setiap observasi diberikan label 1 (Impulse Buying) apabila menunjukkan peningkatan jumlah pesanan dan nilai GMV yang signifikan pada interval pengamatan tertentu yang didukung oleh tingginya aktivitas interaksi pengguna, seperti jumlah komentar dan penambahan followers. Sebaliknya, observasi yang tidak menunjukkan karakteristik tersebut diberikan label 0 (Non-Impulse Buying). Proses pelabelan dilakukan sebelum tahap pemodelan sehingga label tersebut dapat digunakan sebagai variabel target dalam proses klasifikasi menggunakan algoritma XGBoost.

Dataset yang telah terbentuk selanjutnya digunakan untuk mengidentifikasi pola perilaku konsumen serta faktor-faktor yang memengaruhi terjadinya Impulse Buying pada aktivitas TikTok Shop Live Commerce.

D. Data Cleaning

Sebelum dilakukan proses pelatihan model, data terlebih dahulu melalui tahap *data cleaning* untuk memastikan kualitas data yang digunakan. Tahap ini meliputi penghapusan data duplikat, penanganan *missing value*, perbaikan format data yang tidak konsisten, serta penghapusan data *outlier* yang dianggap tidak relevan. Selain itu, dilakukan normalisasi atau standarisasi data numerik agar distribusi data menjadi lebih optimal untuk proses pemodelan.

E. Transformasi dan featur Engineering

Pemilihan fitur dilakukan untuk menentukan variabel prediktor yang relevan dalam proses klasifikasi perilaku *Impulse Buying* pada aktivitas *live streaming* TikTok Shop. Variabel yang digunakan sebagai fitur dalam penelitian ini meliputi durasi *live streaming*, jumlah tayangan, impresi *live*, jumlah komentar, *followers* baru, nilai *Gross Merchandise Value* (GMV), dan *engagement rate*. Pemilihan variabel tersebut didasarkan pada konsep *live commerce* dan perilaku konsumen digital yang menyatakan bahwa tingkat eksposur konten, intensitas interaksi pengguna, serta nilai transaksi memiliki keterkaitan dengan keputusan pembelian konsumen selama sesi *live streaming* berlangsung.

Selain menggunakan variabel hasil observasi langsung, penelitian ini juga membentuk fitur *engagement rate* sebagai indikator tingkat keterlibatan audiens selama sesi *live streaming*[11]. Fitur ini dihitung berdasarkan perbandingan jumlah interaksi pengguna terhadap jumlah tayangan sehingga dapat merepresentasikan tingkat partisipasi audiens secara lebih komprehensif dibandingkan penggunaan variabel interaksi secara terpisah. Penambahan fitur ini bertujuan untuk membantu algoritma XGBoost dalam mengenali pola perilaku konsumen yang berkaitan dengan terjadinya *Impulse Buying*.

Sementara itu, variabel jumlah pesanan dan *conversion rate* tidak digunakan sebagai fitur prediktor pada tahap pelatihan model karena kedua variabel tersebut digunakan sebagai dasar dalam proses pelabelan kelas *Impulse Buying*. Keputusan ini dilakukan untuk menghindari terjadinya *feature leakage*, yaitu kondisi ketika informasi yang digunakan dalam pembentukan label turut digunakan sebagai variabel input model sehingga berpotensi menghasilkan bias pada proses klasifikasi. Dengan demikian, fitur yang digunakan pada penelitian ini diharapkan mampu merepresentasikan karakteristik aktivitas *live streaming* secara objektif tanpa memengaruhi validitas hasil prediksi model. Fitur yang digunakan disajikan pada Tabel 1.

TABEL 1. FITUR YANG DIGUNAKAN

Variabel	Jenis	Keterangan
Durasi Live Streaming	Fitur	Lama sesi live streaming (menit)
Tayangan	Fitur	Jumlah penonton live
Impresi Live	Fitur	Jumlah kemunculan live pada pengguna

Jumlah Komentar	Fitur	Total interaksi komentar selama live
Followers Baru	Fitur	Penambahan pengikut selama live
GMV	Fitur	Nilai total penjualan selama live
Engagement Rate	Fitur	(Komentar + Gift) / Tayangan
Impulse Buying (0/1)	Target	Label klasifikasi
Jumlah Pesanan	Pelabelan	Digunakan dalam pembentukan label
Conversion Rate	Pelabelan	Digunakan dalam pembentukan label

F. Pembagian Dataset (Train-Test Split)

Dataset yang telah melalui tahap *preprocessing* selanjutnya dibagi menjadi data latih (*training data*) dan data uji (*testing data*) menggunakan metode *train-test split*. Dataset penelitian terdiri atas 300 observasi dengan 10 variabel prediktor dan 1 variabel target (*Impulse Buying*). Pembagian data dilakukan dengan rasio 80:20, sehingga diperoleh 240 data sebagai data latih dan 60 data sebagai data uji. Proses pembagian dataset dilakukan menggunakan parameter *random_state* = 42 untuk menjaga konsistensi hasil penelitian serta *stratify* = y untuk mempertahankan proporsi distribusi kelas pada data latih dan data uji.

Data latih digunakan untuk melatih model XGBoost dalam mempelajari pola hubungan antara variabel prediktor, yaitu durasi *live streaming*, jumlah tayangan, impresi *live*, jumlah komentar, *followers* baru, jumlah pesanan, nilai GMV, *engagement rate*, dan *conversion rate*, terhadap variabel target *Impulse Buying*. Sementara itu, data uji digunakan untuk mengevaluasi kemampuan model dalam melakukan klasifikasi pada data yang belum pernah digunakan selama proses pelatihan. Hasil pembagian data menunjukkan bahwa distribusi kelas tetap terjaga dengan proporsi label *Impulse Buying* sebesar 63,33% dan label *Non-Impulse Buying* sebesar 36,67% baik pada data latih maupun data uji. Kondisi tersebut menunjukkan bahwa proses pembagian dataset telah dilakukan secara proporsional sehingga dapat mengurangi potensi bias pada tahap pelatihan dan evaluasi model. Hasil pembagian Dataset disajikan pada Tabel 2 dan Tabel 3.

TABEL 2. HASIL PEMBAGIAN DATASET

Dataset	Jumlah Data	Persentase
Training Data	240	80%
Testing Data	60	20%
Total Data	300	100%

TABEL 3. HASIL PEMBAGIAN DATASET (DISTRIBUSI KELAS TARGET SETELAH TRAIN TEST SPLIT)

Kelas	Training Data	Testing Data
Impulse Buying (1)	63,33%	63,33%
Non-Impulse Buying (0)	36,67%	36,67%

G. Perancangan Model Machine learning

Tahap perancangan model *Machine Learning* dilakukan untuk membangun sistem klasifikasi perilaku *impulse buying* pada aktivitas *live streaming* TikTok Shop berdasarkan dataset yang telah melalui proses *preprocessing*[12]. Variabel input yang digunakan meliputi durasi *live streaming*, jumlah tayangan, impresi *live*, jumlah komentar,

followers baru, sedangkan variabel target berupa label *impulse buying* yang diklasifikasikan ke dalam dua kategori, yaitu label 1 untuk menunjukkan terjadinya pembelian impulsif dan label 0 untuk menunjukkan tidak terjadinya pembelian impulsif. Dataset kemudian dibagi menjadi data latih (*training data*) dan data uji (*testing data*) menggunakan metode *train-test split* dengan rasio 80:20 untuk memastikan model mampu melakukan prediksi secara objektif terhadap data baru[13].

Pada penelitian ini, proses klasifikasi dilakukan menggunakan algoritma XGBoost (*Extreme Gradient Boosting*) karena memiliki kemampuan yang baik dalam menangani data kompleks, mengurangi risiko *overfitting*, serta menghasilkan performa klasifikasi yang tinggi. Algoritma XGBoost bekerja menggunakan metode *gradient boosting* yang mampu memperbaiki kesalahan prediksi secara bertahap sehingga menghasilkan model yang lebih optimal. Selanjutnya, performa model dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *ROC-AUC* untuk mengukur kemampuan model dalam mengklasifikasikan perilaku *impulse buying* pada aktivitas *live streaming* TikTok Shop[14].

H. Pelatihan Dan validasi Model

Tahap pelatihan dan validasi model dilakukan setelah proses perancangan model *Machine Learning* selesai. Pada tahap ini, data latih (*training data*) digunakan untuk melatih algoritma XGBoost agar mampu mempelajari pola hubungan antara variabel input, seperti durasi *live streaming*, jumlah tayangan, impresi *live*, jumlah komentar, *followers* baru, jumlah pesanan, dan nilai GMV (*Gross Merchandise Value*), terhadap variabel target yaitu *impulse buying*. Proses pelatihan dilakukan menggunakan metode *gradient boosting* sehingga model dapat mengenali karakteristik data yang memengaruhi terjadinya pembelian impulsif pada aktivitas *live streaming* TikTok Shop.

Setelah proses pelatihan selesai, dilakukan tahap validasi menggunakan data uji (*testing data*) untuk mengukur kemampuan model dalam mengklasifikasikan data baru yang belum pernah dipelajari sebelumnya. Evaluasi performa model dilakukan menggunakan *confusion matrix* serta beberapa metrik pengujian, yaitu *accuracy*, *precision*, *recall*, *F1-score*, dan *ROC-AUC*. Penggunaan metrik tersebut bertujuan untuk mengetahui tingkat akurasi, kestabilan, dan kemampuan model XGBoost dalam membedakan perilaku pembelian impulsif dan non-impulsif pada aktivitas *live streaming* TikTok Shop.

I. Evaluasi

Tahap evaluasi model dilakukan untuk mengukur tingkat performa algoritma XGBoost dalam mengklasifikasikan perilaku *impulse buying* pada aktivitas *live streaming* TikTok Shop. Proses evaluasi dilakukan menggunakan beberapa metrik klasifikasi, yaitu *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *ROC-AUC*. *Accuracy* digunakan untuk mengukur tingkat ketepatan model secara keseluruhan, *Precision* digunakan untuk mengetahui ketepatan model dalam memprediksi pembelian impulsif, *Recall* digunakan untuk mengukur kemampuan model dalam mendeteksi seluruh data yang termasuk kategori *impulse buying*, sedangkan *F1-Score* digunakan untuk menilai keseimbangan antara nilai *Precision* dan *Recall*. Selain itu, *ROC-AUC* digunakan untuk

mengukur kemampuan model dalam membedakan kelas pembelian impulsif dan non-impulsif secara menyeluruh[15]. Hasil evaluasi tersebut digunakan untuk mengetahui tingkat akurasi, kestabilan, dan kemampuan generalisasi model terhadap data baru. Penelitian ini juga melakukan analisis *feature importance* untuk mengidentifikasi variabel yang paling berpengaruh terhadap perilaku *impulse buying*, seperti jumlah tayangan, impresi *live*, jumlah komentar, *followers* baru, sehingga hasil penelitian tidak hanya menunjukkan performa model, tetapi juga memberikan pemahaman mengenai faktor-faktor yang memengaruhi keputusan pembelian impulsif konsumen pada aktivitas *live streaming* TikTok Shop.

III. HASIL DAN PEMBAHASAN


A. Scraping Data

Penelitian ini menggunakan data aktivitas *live streaming* TikTok Shop yang diperoleh melalui proses observasi langsung pada akun TikTok **Igameivia** selama periode Januari hingga April 2026. Data yang dikumpulkan terdiri atas beberapa variabel, yaitu durasi *live streaming*, jumlah tayangan, impresi *live*, jumlah komentar, *followers* baru, jumlah pesanan, nilai GMV (*Gross Merchandise Value*), serta variabel target berupa *Impulse Buying*. Dataset penelitian berjumlah 300 data hasil observasi yang telah melalui proses pemeriksaan kualitas data dan tidak ditemukan nilai kosong (*missing value*), sehingga seluruh data dapat digunakan secara langsung pada tahap analisis dan pemodelan *Machine Learning*. Penentuan label *Impulse Buying* dilakukan berdasarkan pola peningkatan jumlah pesanan, nilai *conversion rate*, serta tingkat *engagement* selama sesi *live streaming* berlangsung. Seluruh data hasil observasi dicatat menggunakan Microsoft Excel, kemudian disimpan dalam format CSV (*Comma Separated Values*) dan digabungkan menjadi satu dataset terstruktur untuk mempermudah proses *preprocessing*, pelatihan model XGBoost, serta evaluasi performa model.

B. Preprocessing data

Tahap *preprocessing* data dilakukan untuk mempersiapkan dataset sebelum pemodelan menggunakan algoritma XGBoost. Proses ini meliputi pemeriksaan *missing value* dan *outlier*, yang menunjukkan bahwa seluruh data layak digunakan untuk analisis. Selanjutnya dilakukan pemisahan variabel fitur (X) dan target (y), di mana target berupa label *Impulse Buying* (1) dan Non-*Impulse Buying* (0).

Data kemudian melalui proses encoding, normalisasi, dan scaling menggunakan *StandardScaler* untuk menyamakan rentang nilai antarvariabel. Setelah itu, dataset dibagi menjadi data latih dan data uji dengan rasio 80:20 menggunakan metode *train-test split*. Model XGBoost selanjutnya dilatih dan dievaluasi menggunakan metrik *Accuracy*, *Precision*, *Recall*, *F1-Score*, *Confusion Matrix*, dan *ROC-AUC*, serta analisis *feature importance* untuk mengidentifikasi faktor yang paling berpengaruh terhadap perilaku *Impulse Buying*. Proses pemodelan XGBoost pada penelitian ini disajikan pada Gambar 2.



Gambar 2. Tahapan Preprocessing Data

• Input Dataset Live Streaming TikTok Shop

Tahap awal penelitian dilakukan dengan memasukkan dataset hasil observasi aktivitas *live streaming* TikTok Shop ke dalam Google Colab menggunakan format CSV (*Comma Separated Values*). Dataset penelitian diperoleh melalui observasi langsung pada akun TikTok **Igameivia** selama periode Januari hingga April 2026 dan terdiri dari 300 data aktivitas *live streaming*. Dataset yang digunakan dalam penelitian ini memuat variabel durasi *live streaming* dalam satuan menit, jumlah tayangan (*views*), impresi *live*, jumlah komentar, *followers* baru, serta variabel target berupa label *Impulse Buying*.

Berdasarkan data pada Tabel 1, setiap baris merepresentasikan satu sesi aktivitas *live streaming* dengan karakteristik interaksi yang berbeda. Sebagai contoh, pada data pertama tercatat durasi *live streaming* selama 287 menit dengan jumlah tayangan sebanyak 10.500, impresi *live* sebesar 78.000, jumlah komentar sebanyak 384, dan *followers* baru sebanyak 93 yang diklasifikasikan ke dalam kategori *Impulse Buying* dengan label 1. Sementara itu, pada data ke-296 tercatat durasi *live streaming* selama 120 menit dengan jumlah tayangan sebanyak 2.900, impresi *live* sebesar 22.000, jumlah komentar sebanyak 110, dan *followers* baru sebanyak 24 yang diklasifikasikan ke dalam kategori non-*Impulse Buying* dengan label 0.

Seluruh data tersebut kemudian digunakan sebagai dataset utama dalam proses *preprocessing*, pelatihan model XGBoost, serta evaluasi performa model untuk mengklasifikasikan perilaku *Impulse Buying* pada aktivitas TikTok Shop *Live Streaming*. Tabel Dataset di tunjukkan pada Tabel 4.

TABEL 4. DATASET LIVE STREAMING

Durasi Live (menit)	Tayangan	Impresi Live	Jumlah Komentar	Follower Baru	Impulse Buying (0/1)
287	10500	78000	384	93	1
120	5000	30000	150	50	1
156	5800	42700	193	43	1
287	10500	78000	384	93	1
318	9800	62500	374	113	1
...	...	...	...	...	...
120	2900	22000	110	24	0
564	29100	203200	980	208	1
194	6900	53100	230	65	0
415	25500	204900	910	226	1

• Handling Missing Value

Setelah dataset berhasil dimuat ke dalam sistem menggunakan library *Pandas*, dilakukan tahap pemeriksaan kualitas data untuk memastikan tidak terdapat nilai kosong (*missing value*) pada setiap variabel penelitian. Proses pemeriksaan dilakukan dengan menghitung jumlah dan persentase *missing value* pada masing-masing kolom dataset

menggunakan fungsi `isnull().sum()`. Hasil pemeriksaan menunjukkan bahwa seluruh variabel penelitian, yaitu durasi live streaming, jumlah tayangan, impresi live, jumlah komentar, followers baru, serta variabel target *Impulse Buying*, memiliki jumlah *missing value* sebesar 0 atau 0%. Hasil tersebut menunjukkan bahwa tidak terdapat data yang hilang maupun data kosong pada seluruh atribut yang digunakan dalam penelitian.

Berdasarkan hasil pemeriksaan tersebut, dataset dinyatakan lengkap sehingga tidak diperlukan proses penanganan data seperti penghapusan baris data (*data deletion*) maupun imputasi nilai. Ketersediaan data yang lengkap pada seluruh variabel menunjukkan bahwa kualitas dataset berada dalam kondisi baik dan siap digunakan pada tahap selanjutnya. Dengan demikian, proses *preprocessing* dapat dilanjutkan ke tahap berikutnya tanpa perlakuan khusus terhadap *missing value*, sehingga integritas dan konsistensi data tetap terjaga selama proses pelatihan dan evaluasi model XGBoost. Hasil tersebut dapat dilihat pada Gambar 3.

Jumlah Missing Persentase (%)		
Durasi_Live (menit)	0	0.0
Tayangan	0	0.0
Impresi_Live	0	0.0
Jumlah_Komentar	0	0.0
Followers_Baru	0	0.0
Impulse_Buying (0/1)	0	0.0

Gambar 3. Handling missing Value

- *Identifikasi Outlier*

Tahap identifikasi *outlier* dilakukan menggunakan metode *Interquartile Range* (IQR) untuk mendeteksi data yang memiliki nilai ekstrem pada variabel numerik, yaitu Durasi Live, Tayangan, Impresi Live, Jumlah Komentar, dan Followers Baru. Hasil identifikasi menunjukkan adanya *outlier* pada seluruh variabel, dengan jumlah masing-masing sebanyak 14 data pada Durasi Live, 30 data pada Tayangan, 23 data pada Impresi Live, 32 data pada Jumlah Komentar, dan 20 data pada Followers Baru.

Keberadaan *outlier* menunjukkan adanya variasi performa yang cukup tinggi antar sesi live streaming. Namun, data *outlier* tidak dihapus karena masih merepresentasikan kondisi aktual yang dapat terjadi pada aktivitas TikTok Shop Live Streaming, seperti peningkatan jumlah tayangan, komentar, dan followers akibat tingginya interaksi audiens. Selain itu, algoritma XGBoost yang digunakan dalam penelitian ini relatif mampu menangani data dengan nilai ekstrem, sehingga seluruh data tetap digunakan pada proses pelatihan dan evaluasi model. Hasil identifikasi outlier disajikan pada Tabel 5.

TABEL 5. HASIL IDENTIFIKASI OUTLIER

Fitur	Jumlah Outlier
Durasi live (menit)	14
Tayangan	30
Impresi Live	23
Jumlah komentar	32
Followers baru	20

- *Normalization dan Scaling (StandardScaler)*

Tahap normalisasi dilakukan menggunakan metode *StandardScaler* untuk menyamakan skala antarvariabel numerik yang digunakan dalam penelitian, yaitu Durasi Live, Tayangan, Impresi Live, Jumlah Komentar, dan Followers Baru. Proses ini mengubah data sehingga memiliki rata-rata (mean) mendekati 0 dan standar deviasi (standard deviation) mendekati 1. Hasil standarisasi menunjukkan bahwa seluruh variabel berhasil ditransformasikan ke dalam skala yang seragam tanpa mengubah karakteristik data. Dengan demikian, data hasil standarisasi siap digunakan pada proses pelatihan dan evaluasi model XGBoost untuk meningkatkan konsistensi dan kualitas proses pembelajaran model. Interpretasi hasilnya dapat di lihat pada Tabel 6.

TABEL 6. INTERPRETASI HASIL

Variabel	Nilai Standardisasi
Durasi Live	2,337
Tayangan	4,360
Impresi Live	5,020
Jumlah Komentar	0,119
Followers Baru	4,875

- *Pemisahan Fitur dan Target*

Dataset kemudian dipisahkan menjadi variabel fitur (*X*) dan variabel target (*y*). Variabel fitur terdiri atas atribut yang digunakan sebagai masukan dalam proses pelatihan model, yaitu Durasi Live, Tayangan, Impresi Live, Jumlah Komentar, dan Followers Baru. Sementara itu, variabel target berupa label *Impulse Buying* (0/1) yang digunakan sebagai keluaran (*output*) untuk mengklasifikasikan apakah suatu sesi live streaming termasuk ke dalam kategori *Impulse Buying* atau non-*Impulse Buying*. Proses pemisahan fitur dan target dilakukan untuk mempersiapkan data sebelum tahap pelatihan model XGBoost, sehingga model dapat mempelajari pola hubungan antara karakteristik aktivitas live streaming dengan perilaku *Impulse Buying* secara lebih efektif.

- *Train-Test Split (80:20)*

Dataset penelitian kemudian dibagi menjadi data latih (*training data*) dan data uji (*testing data*) menggunakan metode *train-test split* dengan rasio 80:20. Dari total 300 data yang digunakan, sebanyak 240 data dialokasikan sebagai data latih dan 60 data sebagai data uji. Proses pembagian data dilakukan menggunakan parameter *random_state=42* untuk memastikan konsistensi hasil eksperimen serta *stratify=y* untuk mempertahankan proporsi distribusi kelas pada variabel target *Impulse Buying*.

Hasil pembagian data menunjukkan bahwa distribusi kelas pada data latih dan data uji tetap terjaga dengan proporsi yang sama. Pada data latih, kelas *Impulse Buying* (label 1) memiliki proporsi sebesar 63,33%, sedangkan kelas non-*Impulse Buying* (label 0) sebesar 36,67%. Proporsi yang sama juga diperoleh pada data uji, yaitu 63,33% untuk label 1 dan

36,67% untuk label 0. Hal ini menunjukkan bahwa metode *stratified train-test split* berhasil mempertahankan distribusi kelas pada kedua kelompok data sehingga proses pelatihan dan evaluasi model dapat dilakukan secara lebih representatif. Dengan demikian, model XGBoost dapat mempelajari pola data secara lebih baik dan menghasilkan evaluasi performa yang lebih objektif. Hasil *Train Test Split* disajikan pada Tabel 7.

TABEL 7. TRAIN-TEST SPLIT

Dataset	Jumlah Data	Label 1	Label 0
Training Data	240	63.33%	36.67%
Testing Data	60	63.33%	36.67%

- **Pelatihan Model XGBoost**

Proses pelatihan model dilakukan menggunakan algoritma XGBoost (*Extreme Gradient Boosting*) melalui library `XGBClassifier`. Untuk memperoleh performa model yang optimal, dilakukan proses *hyperparameter tuning* menggunakan metode `GridSearchCV`. Parameter yang diuji meliputi `learning_rate`, `max_depth`, `n_estimators`, dan `subsample`.

Berdasarkan hasil pengujian, diperoleh kombinasi parameter terbaik yaitu `learning_rate` = 0.01, `max_depth` = 3, `n_estimators` = 100, dan `subsample` = 1.0. Nilai *learning rate* yang rendah menunjukkan bahwa proses pembelajaran model dilakukan secara bertahap sehingga mampu mengurangi risiko *overfitting*. Selain itu, nilai `max_depth` = 3 menunjukkan bahwa model menggunakan struktur pohon keputusan yang tidak terlalu kompleks sehingga mampu meningkatkan kemampuan generalisasi model terhadap data baru. Hasil Pengujian di sajikan pada Tabel 8.

TABEL 8 PELATIHAN MODEL

Parameter	Nilai Terbaik	Keterangan
<code>learning_rate</code>	0.01	Mengatur kecepatan proses pembelajaran model agar lebih stabil dan mengurangi risiko <i>overfitting</i> .
<code>max_depth</code>	3	Menentukan kedalaman maksimum pohon keputusan (<i>decision tree</i>) pada model XGBoost.
<code>n_estimators</code>	100	Menunjukkan jumlah pohon keputusan yang digunakan pada proses <i>boosting</i> .
<code>subsample</code>	1.0	Menunjukkan proporsi data latih yang digunakan pada setiap iterasi pelatihan model.

- **Prediksi Data Testing**

Setelah proses pelatihan model selesai dilakukan, model XGBoost digunakan untuk melakukan prediksi terhadap data uji (*testing data*) yang sebelumnya belum pernah dipelajari oleh model. Proses prediksi dilakukan untuk mengetahui kemampuan model dalam mengklasifikasikan perilaku *Impulse Buying* pada data baru secara objektif. Hasil prediksi berupa label klasifikasi yang terdiri atas kategori pembelian impulsif (1) dan non-impulsif (0).

Berdasarkan hasil prediksi pada data uji, model XGBoost mampu mengklasifikasikan sebagian besar data dengan baik sesuai dengan label aktual. Perbandingan antara nilai aktual dan hasil prediksi menunjukkan bahwa model mampu mengenali pola perilaku konsumen pada aktivitas *live streaming* TikTok Shop secara cukup akurat. Hasil prediksi tersebut kemudian digunakan sebagai dasar pada tahap evaluasi performa model menggunakan metrik *Accuracy*, *Precision*, *Recall*, *F1-Score*, *Confusion Matrix*, dan *ROC-AUC* untuk mengukur tingkat ketepatan klasifikasi model secara menyeluruh.

- **Evaluasi Model (*Accuracy*, *Precision*, *Recall*, *F1-Score*, *ROC-AUC*)**

Evaluasi model XGBoost dilakukan pada data uji (*testing data*) menggunakan metrik *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *ROC-AUC*. Berdasarkan hasil pengujian, model memperoleh nilai *Accuracy* sebesar 81,67%, yang menunjukkan bahwa sebagian besar data berhasil diklasifikasikan dengan benar. Nilai *Precision* sebesar 82,93% mengindikasikan bahwa prediksi kelas *Impulse Buying* yang dihasilkan model memiliki tingkat ketepatan yang baik. Sementara itu, nilai *Recall* sebesar 89,47% menunjukkan bahwa model mampu mengidentifikasi sebagian besar data yang termasuk dalam kategori *Impulse Buying*.

Selain itu, nilai *F1-Score* sebesar 86,08% menunjukkan keseimbangan yang baik antara *Precision* dan *Recall* dalam proses klasifikasi. Nilai *ROC-AUC* sebesar 87,32% mengindikasikan bahwa model memiliki kemampuan yang baik dalam membedakan antara kelas *Impulse Buying* dan *Non-Impulse Buying*. Secara keseluruhan, hasil evaluasi menunjukkan bahwa model XGBoost mampu melakukan klasifikasi perilaku *Impulse Buying* pada aktivitas TikTok Shop Live Streaming dengan performa yang baik dan konsisten, meskipun masih terdapat beberapa kesalahan klasifikasi pada sebagian data uji. Hasil evaluasi model dapat di lihat pada Tabel 9.

TABEL 9. HASIL EVALUASI MODEL

<i>Accuracy</i>	0.8167
<i>Precision</i>	0.8293
<i>Recall</i>	0.8947
<i>F1-Score</i>	0.8608
<i>ROC-AUC</i>	0.8732

- **Evaluasi ROC-AUC**

Selain menggunakan *Accuracy*, *Precision*, *Recall*, dan *F1-Score*, performa model juga dievaluasi menggunakan *ROC-AUC* (*Receiver Operating Characteristic – Area Under Curve*). *ROC-AUC* merupakan metrik yang digunakan untuk mengukur kemampuan model dalam membedakan kelas positif (*Impulse Buying*) dan kelas negatif (*Non-Impulse Buying*) pada berbagai nilai ambang klasifikasi (*threshold*). Nilai *ROC-AUC* berada pada rentang 0 hingga 1, di mana nilai yang semakin mendekati 1 menunjukkan kemampuan klasifikasi yang semakin baik. Berdasarkan hasil pengujian, model XGBoost memperoleh nilai *ROC-AUC* sebesar 0,8732 (87,32%). Hasil tersebut menunjukkan bahwa model memiliki kemampuan yang baik dalam membedakan sesi *live streaming* yang menghasilkan perilaku *Impulse Buying* dan yang tidak. Secara interpretatif, nilai ini menunjukkan bahwa model memiliki peluang

sebesar 87,32% untuk memberikan skor prediksi yang lebih tinggi pada data yang benar-benar termasuk kategori Impulse Buying dibandingkan data Non-Impulse Buying. Karena berada pada rentang 0,80–0,90, nilai ROC-AUC tersebut termasuk dalam kategori *good classification performance*, sehingga model dapat dianggap cukup andal dalam mengidentifikasi perilaku *Impulse Buying* berdasarkan aktivitas live streaming TikTok Shop.

- *Confusion Matrix*

Berdasarkan hasil *Confusion Matrix*, model XGBoost menghasilkan 15 data *True Negative* (TN), 34 data *True Positive* (TP), 7 data *False Positive* (FP), dan 4 data *False Negative* (FN). Hasil tersebut menunjukkan bahwa model mampu mengklasifikasikan 49 dari 60 data uji dengan benar. Jumlah *True Positive* yang lebih tinggi dibandingkan *False Negative* menunjukkan bahwa model memiliki kemampuan yang baik dalam mengidentifikasi perilaku *Impulse Buying*. Selain itu, jumlah *False Negative* yang relatif rendah mengindikasikan bahwa sebagian besar data yang termasuk kategori *Impulse Buying* berhasil dikenali oleh model. Meskipun masih terdapat beberapa kesalahan klasifikasi, hasil *Confusion Matrix* menunjukkan bahwa model XGBoost memiliki performa yang cukup baik dalam membedakan perilaku *Impulse Buying* dan *Non-Impulse Buying* pada aktivitas TikTok Shop Live Streaming. Hasil *Confusion Matrix* disajikan pada Tabel 10.


TABEL 10. HASIL CONFUSION MATRIX MODEL XGBOOST

	Prediksi 0	Prediksi 1
Aktual 0	15	7
Aktual 1	4	34

- *Analisis Feature Importance*

Berdasarkan hasil analisis *feature importance* menggunakan algoritma XGBoost, variabel Jumlah Komentar memiliki nilai *importance score* tertinggi sebesar 168, sehingga menjadi faktor yang paling berpengaruh dalam klasifikasi perilaku Impulse Buying. Variabel Impresi Live (160) dan *Followers Baru* (136) juga menunjukkan kontribusi yang besar, diikuti oleh Tayangan (106) dan Durasi Live (91).

Secara keseluruhan, hasil ini menunjukkan bahwa faktor interaksi pengguna dan jangkauan audiens selama sesi live streaming memiliki peran yang lebih dominan dalam mendorong perilaku Impulse Buying dibandingkan durasi siaran. Dengan demikian, keterlibatan audiens menjadi indikator penting dalam mengidentifikasi kecenderungan pembelian impulsif pada TikTok Shop Live Streaming. Hasil analisis *feature importance* dapat dilihat pada Gambar 4.



Gambar 4. Analisis *Feature Importance*

- *Output Hasil Klasifikasi Impulse Buying*

Tahap akhir penelitian menghasilkan model klasifikasi perilaku Impulse Buying pada aktivitas TikTok Shop Live Streaming menggunakan algoritma XGBoost. Hasil evaluasi menunjukkan bahwa model memperoleh Accuracy sebesar 81,67%, Precision 82,93%, Recall 89,47%, F1-Score 86,08%, dan ROC-AUC 87,32%. Nilai tersebut menunjukkan bahwa model memiliki performa yang baik dalam mengidentifikasi dan membedakan kelas Impulse Buying dan Non-Impulse Buying.

Berdasarkan *Confusion Matrix*, model berhasil mengklasifikasikan 49 dari 60 data uji dengan benar, yang terdiri dari 34 data Impulse Buying dan 15 data Non-Impulse Buying. Sementara itu, terdapat 11 data yang mengalami kesalahan klasifikasi. Hasil ini menunjukkan bahwa model cukup andal dalam mengenali pola perilaku konsumen pada aktivitas *live streaming*.

Analisis *feature importance* menunjukkan bahwa Jumlah Komentar merupakan variabel yang paling berpengaruh, diikuti oleh Impresi Live, *Followers Baru*, Tayangan, dan Durasi Live. Temuan ini mengindikasikan bahwa tingkat interaksi pengguna dan jangkauan audiens selama sesi live streaming memiliki peran penting dalam mendorong perilaku Impulse Buying.

Dibandingkan penelitian sebelumnya yang menggunakan metode statistik konvensional untuk mengukur hubungan antarvariabel, pendekatan Machine Learning pada penelitian ini mampu mengidentifikasi pola yang lebih kompleks serta menghasilkan prediksi perilaku Impulse Buying dengan tingkat akurasi yang baik. Dengan demikian, aktivitas TikTok Shop Live Streaming dapat dimanfaatkan sebagai sumber data untuk mengidentifikasi kecenderungan perilaku pembelian impulsif berdasarkan pola interaksi pengguna selama sesi live streaming.

IV. KESIMPULAN

Berdasarkan hasil penelitian, algoritma XGBoost mampu digunakan untuk mengklasifikasikan perilaku Impulse Buying pada aktivitas TikTok Shop Live Streaming berdasarkan karakteristik interaksi pengguna selama sesi live. Penelitian menggunakan 300 data observasi aktivitas live streaming akun TikTok Igamevia dengan variabel durasi live streaming, tayangan, impresi live, jumlah komentar, dan followers baru. Untuk menghindari *feature leakage*, variabel jumlah pesanan dan nilai GMV dikeluarkan dari model. Hasil evaluasi menunjukkan bahwa model XGBoost memperoleh akurasi sebesar 83,33% dan mampu membedakan perilaku Impulse Buying dan Non-Impulse Buying dengan performa yang baik. Analisis *feature importance* menunjukkan bahwa jumlah komentar, impresi live, dan followers baru merupakan faktor yang paling berpengaruh dalam proses klasifikasi. Penelitian ini masih memiliki keterbatasan karena menggunakan dataset yang relatif terbatas dan berasal dari satu akun TikTok Shop. Oleh karena itu, penelitian selanjutnya disarankan menggunakan dataset yang lebih besar dan beragam serta menambahkan variabel lain yang berkaitan dengan perilaku konsumen dan karakteristik konten untuk meningkatkan kemampuan generalisasi model.

UCAPAN TERIMA KASIH

Penulis mengucapkan puji syukur kepada Tuhan Yang Maha Esa atas rahmat dan karunia-Nya sehingga penelitian ini dapat diselesaikan dengan baik. Penulis juga menyampaikan ucapan terima kasih yang sebesar-besarnya kepada kedua orang tua tercinta yang senantiasa memberikan doa, dukungan, motivasi, dan semangat selama proses penyusunan penelitian ini; kepada dosen pembimbing skripsi di Universitas Amikom Purwokerto yang telah memberikan ilmu, arahan, dan bimbingan sehingga penelitian ini dapat terselesaikan dengan baik; serta kepada seluruh teman-teman kelas IF22C yang telah memberikan dukungan, pengalaman, kebersamaan, dan semangat selama masa perkuliahan.

REFERENSI

- [1] E. E. Letters and C. S. Thangavelu, "□ Predicting Impulse Buying Behavior through AI-Enhanced Digital Marketing Analytics," vol. 15, no. 3, pp. 3332–3349, 2025.
- [2] V. J. Pratiwi, F. Efendi, M. Fariz, and K. Zikrinawati, "Pengaruh Voucher Diskon Belanja Pada Live Streaming Aplikasi Tiktok Terhadap Perilaku Impulsive Buying Dikalangan Mahasiswa UIN Walisongo Semarang," vol. 2, no. 2, 2024.
- [3] T. Chen, "XGBoost: A Scalable Tree Boosting System".
- [4] F. Pedregosa, R. Weiss, and M. Brucher, "Scikit-learn: Machine Learning in Python," vol. 12, pp. 2825–2830, 2011.
- [5] J. M. Polgan, D. Novita, E. C. Mayndarto, M. A. Maulana, U. E. Unggul, and U. T. Jagakarsa, "Penggunaan Media Sosial TikTok Sebagai Media Promosi Pemasaran Dalam Bisnis Online," vol. 12, pp. 2543–2550, 2023.
- [6] M. I. Zakiah, M. Mustaqim, A. Zaki, And C. E. Violita, "Pengaruh Live Streaming , Flash Sale , Dan Double Days Promotion Terhadap Impulsive Buying Pada Pengguna," Vol. 14, Pp. 1223–1239, 2025, Doi: 10.34127/Jrlab.V14i2.1450.
- [7] C. Hodkinson, "'Fear of Missing Out' (FOMO) marketing appeals: A conceptual model," *J. Mark. Commun.*, vol. 25, no. 1, pp. 65–88, 2019, doi: 10.1080/13527266.2016.1234504.
- [8] R. A. Kurniawan *Et Al.*, "Pengaruh Content Marketing , Live Streaming Dan Flash Sale Terhadap Impulse Buying Pada Pengguna Aplikasi Tiktok Shop Di Surabaya (Studi Pada Pengguna Tahun 2022-2023)," 2024.
- [9] F. N. Annisa and N. Apriyana, "Pengaruh Fitur TikTok Affiliate terhadap Pembelian Impulsif pada Produk Fast Fashion," *J. Bisnis Mhs.*, vol. 5, no. 2, pp. 578–587, 2025, doi: 10.60036/jbm.598.
- [10] S. N. Ruscikasani, R. Roro, N. Oktalivia, F. R. Putra, and A. J. Wahidin, "Prediksi Pembelian E-Commerce Menggunakan XGBoost Berbasis Perilaku Sesi Pengguna," vol. 4, no. 4, pp. 5666–5672, 2025.
- [11] V. D. Ardiyanti, "The Effect of TikTok Live Streaming Shopping on Impulse Buying Behavior in The 2023 Global Crisis," vol. 2, no. 1, pp. 1–6, 2023.
- [12] J. Ilmiah *et al.*, "Pengaruh Live Shopping , Discount , Dan Kualitas Produk Terhadap Impulse Buying Pada Marketplace Tiktok Shop," vol. 2, no. 8, pp. 425–437, 2024.
- [13] M. S. Munir, J. Wati, R. Wulan, and S. B. Wati, "Pengaruh Affiliate Marketing terhadap Keputusan Pembelian di TikTok Shop," *RIGGS J. Artif. Intell. Digit. Bus.*, vol. 4, no. 2, pp. 5092–5097, 2025, doi: 10.31004/riggs.v4i2.1390.
- [14] T. Chen and C. Guestrin, "XGBoost: A Scalable Tree Boosting System," pp. 785–794, 2016.
- [15] A. L. Najih and R. B. Yudhianto, "Classification of cardiovascular and chronic respiratory diseases utilizing ensemble models with data exploration techniques," vol. 10, no. 4, pp. 3772–3786, 2025.