

## ***Systematic Literature Review: Analisis Dan Prediksi Perilaku Konsumen E-Commerce Menggunakan Machine Learning***

Ayesa Aglystia Firdauzi<sup>1</sup>, Syifa Tania Annaztasya<sup>2</sup>, Febriana<sup>3</sup>

<sup>1,2,3</sup>Program Studi Teknologi Informasi, Fakultas Ilmu Komputer, Universitas Amikom Purwokerto, Jawa Tengah, Indonesia  
surel: [ayesaaglyst@gmail.com](mailto:ayesaaglyst@gmail.com), [syifaannaztasyaa@gmail.com](mailto:syifaannaztasyaa@gmail.com), [fbrn.178@gmail.com](mailto:fbrn.178@gmail.com)

### **Info Artikel**

#### ***Sejarah artikel:***

Diterima 12-11-2025

Revisi 24-11-2025

Diterima 02-12-2025

#### ***Kata kunci:***

*Machine Learning*

*Perilaku Konsumen*

*System Literature Review*

*Deep Learning*

*E-Commerce*

### **ABSTRAK**

Pertumbuhan eksponensial data *E-commerce* yang ditandai dengan volume, kecepatan, dan variasi yang tinggi menjadikan metode statistik tradisional tidak lagi memadai untuk memahami perilaku konsumen yang kompleks. Penelitian ini bertujuan untuk mengevaluasi efektivitas penerapan algoritma *Machine Learning* (ML) dalam memprediksi perilaku konsumen serta mengidentifikasi tren implementasi terkini sebagai solusi atas keterbatasan metode konvensional. Menggunakan pendekatan *Systematic Literature Review* (SLR) yang berpedoman pada protokol PRISMA 2020, penelitian ini melakukan pengumpulan data melalui empat basis data akademik utama, yaitu *ScienceDirect*, *IEEE Xplore*, *ACM*, dan *Semantic Scholar*. Sebanyak 273 artikel relevan yang diterbitkan antara tahun 2021 hingga 2026 dianalisis untuk mensintesis algoritma dominan dan metrik kinerjanya. Temuan utama menunjukkan adanya pergeseran paradigma dari model tunggal menuju arsitektur *Hybrid Deep Learning* dan metode *Ensemble* (seperti *XGBoost*) yang terbukti lebih unggul dalam menangani data multimodal dan tidak seimbang (*imbalanced*). Pendekatan ini secara konsisten melampaui metode statistik dalam hal akurasi prediksi, penurunan tingkat kesalahan, dan dampak bisnis nyata seperti peningkatan konversi. Studi ini menyimpulkan bahwa pengembangan masa depan perlu memprioritaskan *Explainable AI* (XAI) dan integrasi data multimodal untuk mendukung tren *live streaming commerce* serta meningkatkan transparansi keputusan bagi manajemen bisnis.

### ***Penulis yang sesuai:***

Febriana

Program Studi Teknologi Informasi Fakultas Ilmu Komputer Universitas Amikom Purwokerto

Email: [fbrn.178@gmail.com](mailto:fbrn.178@gmail.com)

## **1. PENDAHULUAN**

*E-commerce* memainkan peran penting dalam ekonomi digital modern, secara signifikan mengubah cara bisnis beroperasi dan konsumen terlibat dengan produk dan layanan. Sektor ini berhasil meningkatkan aksesibilitas pasar, efisiensi operasional, dan kenyamanan konsumen, sehingga mendorong pertumbuhan ekonomi. Terdapat banyak aspek yang menjadi kunci penting *E-commerce* dalam perekonomian saat ini, salah satunya adalah aspek perilaku konsumen. Sebagian besar konsumen sekarang lebih memilih belanja *online*, dengan lebih dari 55,8% melakukan pembelian mingguan, yang menunjukkan pergeseran signifikan perilaku konsumen ke saluran digital [1].



Pergeseran ini didukung oleh pesatnya transformasi digital dalam *E-commerce*, yang didorong oleh teknologi seperti kecerdasan buatan (AI), analitik data besar, dan komputasi awan, menghasilkan sejumlah besar data tentang aktivitas pengguna. Platform *E-commerce* terus mengumpulkan data dari berbagai interaksi pengguna, termasuk riwayat penelusuran, pola pembelian, dan data keranjang yang ditinggalkan [2]. Besarnya volume data ini secara signifikan mempengaruhi strategi bisnis dan pemahaman terhadap perilaku konsumen. Oleh karena itu, memahami perilaku konsumen menjadi sangat penting untuk keberhasilan perusahaan *E-commerce*, karena memungkinkan mereka untuk menyesuaikan strategi demi memenuhi kebutuhan pelanggan secara efektif.

Dengan memanfaatkan wawasan berbasis data, bisnis dapat meningkatkan keterlibatan pelanggan, mengoptimalkan upaya pemasaran, dan pada akhirnya mendorong penjualan. Pemanfaatan data ini terwujud dalam dua strategi utama. Pertama, analisis detail demografis dan tren pembelian memungkinkan segmentasi pelanggan yang efektif, yang mengarah ke strategi pemasaran yang dipersonalisasi untuk meningkatkan tingkat konversi [3]. Kedua, penerapan data besar membantu perusahaan *E-commerce* memprediksi perilaku konsumen, memungkinkan penyesuaian proaktif terhadap strategi pemasaran dan penjualan [4]. Namun, metode analisis tradisional kini semakin tidak memadai dalam menghadapi karakteristik “3V” dari data *E-commerce*: *volume* (jumlah), *velocity* (kecepatan), dan *variety* (variasi). Metode-metode ini secara spesifik kesulitan mengelola ukuran data yang sangat besar (volume), padahal algoritma canggih seperti metode *Bayesian* yang disempurnakan terbukti mampu mengelola volume data besar dengan lebih efektif dan mencapai akurasi tinggi dalam memprediksi perilaku pengguna (97,9%) dan tingkat konversi (83,2%) [5]. Dari segi *velocity*, teknologi AI memungkinkan analisis aliran data secara *real-time*, sehingga tren dapat teridentifikasi lebih cepat [6]. Sementara untuk aspek *variety*, penerapan model pembelajaran mesin dalam kerangka analisis berbasis cloud memberikan kemampuan untuk menangani berbagai format data yang berbeda [7]. Lebih jauh lagi, kelemahan mendasar dari metode statistik tradisional adalah ketergantungan mereka pada asumsi kaku dan model yang disederhanakan, seperti asumsi linier, yang seringkali gagal menangkap pola rumit dan non-linier yang melekat dalam data perilaku konsumen dunia nyata [8]. Selain itu, volume dan kompleksitas data konsumen, termasuk format terstruktur dan tidak terstruktur, seringkali melebihi kapasitas analitis metode konvensional [9]. Keterbatasan ini mendorong perusahaan *E-commerce* untuk menyadari pentingnya pendekatan canggih guna mengekstrak wawasan (*insights*) yang dapat ditindaklanjuti dan membuat prediksi yang akurat. Dalam konteks inilah *Machine Learning* (ML), sebagai sub-bidang Kecerdasan Buatan, hadir sebagai solusi. ML dirancang untuk mengatasi keterbatasan metode analisis tradisional dengan kemampuannya menangani kompleksitas, volume, dan variasi data besar secara efektif, sehingga mampu mengungkap pola dan wawasan yang rumit [10].

Penerapan ML telah menjadi bagian integral dari *E-commerce*, yang secara signifikan meningkatkan analisis perilaku konsumen melalui berbagai aplikasi. Area utamanya mencakup segmentasi pelanggan, di mana algoritma seperti clustering memfasilitasi identifikasi kelompok konsumen yang berbeda untuk pemasaran yang dipersonalisasi [11], [12], prediksi niat pembelian, di mana model seperti *Random Forest* menunjukkan akurasi tinggi dalam meramalkan perilaku pembelian [13], mesin rekomendasi, yang menggunakan ML untuk menganalisis preferensi guna memberikan saran produk yang relevan [12], dan prediksi churn, yang mengidentifikasi pelanggan yang berisiko tidak terlibat untuk strategi retensi proaktif [14].

Penelitian yang sedang berlangsung terus menegaskan peran penting ML, didorong oleh kebutuhan akan layanan yang dipersonalisasi. Berbagai studi menunjukkan bahwa algoritma yang umum digunakan seperti *Random Forest* (RF), *Support Vector Machines* (SVM), dan *Neural Networks* telah menunjukkan akurasi tinggi dalam memprediksi perilaku konsumen [15]. Model-model ini dilatih menggunakan beragam kumpulan data, termasuk informasi demografis, riwayat pembelian, dan interaksi online [11], yang memungkinkan bisnis mengidentifikasi pola untuk menyesuaikan upaya pemasaran [16]. Bahkan, berbagai studi perbandingan juga telah mengkonfirmasi keunggulan ini, menunjukkan bahwa model ML seperti SVM dan RF secara konsisten mengungguli model statistik tradisional (contohnya Regresi Logistik) dalam metrik akurasi seperti presisi dan ingatan [17], [18]. Meskipun demikian, penerapan *Machine Learning* dalam memahami perilaku konsumen *E-commerce* adalah bidang yang berkembang pesat, namun tinjauan sistematis yang komprehensif untuk mensintesis temuan-temuan ini masih belum ada [15]. Selain itu, integrasi teknik-teknik canggih ini menghadirkan berbagai tantangan yang perlu ditangani. Tantangan tersebut mencakup masalah privasi data konsumen dan kepatuhan terhadap regulasi, serta potensi bias



algoritmik yang dapat menyebabkan hasil yang tidak adil [19]. Ketergantungan pada algoritma yang kompleks juga dapat menyebabkan masalah teknis seperti overfitting dan kesulitan generalisasi model [14].

Oleh karena itu, penelitian ini bertujuan untuk melakukan sebuah *Systematic Literature Review* (SLR) untuk mengidentifikasi, mengevaluasi, dan mensintesis bukti-bukti penelitian yang ada mengenai penerapan *Machine Learning* untuk analisis dan prediksi perilaku konsumen di *E-commerce*.

## 2. METODE

Pendekatan *Systematic Literature Review* (SLR) yang dipandu oleh PRISMA 2020 berperan penting dalam memastikan proses sistesis penelitian berlangsung secara transparan, terstruktur, dan dapat direplikasi. Melalui tahapan identifikasi, penyaringan, kelayakan, dan inklusi, metode ini meningkatkan ketelitian analisis dan memperkuat validitas temuan. PRISMA 2020 juga menekankan pelaporan yang jelas untuk memudahkan reproduktifitas hasil penelitian [20], sementara penerapan SLR memungkinkan cakupan literatur yang komprehensif, sebagaimana ditunjukkan dalam berbagai studi yang meninjau penerapan AI di sektor industri maupun pendidikan [21], [22]. Pencarian literatur dilakukan melalui basis data akademik resmi, yaitu *ScienceDirect*, *IEEE Xplore*, *ACM Digital Library* dan *Semantic Scholar*. Sumber-sumber ini dipilih karena cakupan publikasi ilmiah berkualitas tinggi dan relevansinya dengan bidang teknologi informasi. Fokus pencarian dibatasi pada publikasi tahun 2021–2026 untuk menjamin relevansi dan kebaruan penelitian. Melalui penerapan protokol PRISMA dan penilaian yang cermat, temuan studi ini memberikan wawasan komprehensif tentang praktik terbaik dan kemajuan terkini di sektor *E-commerce*.

Berdasarkan prosedur seleksi, sebanyak 3.033 dokumen berhasil diidentifikasi pada tahap awal, yang terdiri dari 2.197 artikel dari *ScienceDirect*, 580 dari *ACM Digital Library*, 216 dari *IEEE Xplore*, dan 40 dari *Semantic Scholar*. Setelah menghapus 129 dokumen duplikat, sebanyak 2.904 artikel disaring berdasarkan judul dan abstrak. Proses penyaringan tersebut mengeksklusi 2.423 dokumen, sehingga menyisakan 481 artikel untuk tahap penilaian retrieval. Dari jumlah tersebut, sebanyak 208 artikel lengkap tidak dapat diakses atau ditemukan, yang kemudian menyisakan 273 artikel lengkap untuk dinilai kelayakannya. Setelah melalui penilaian kualitas dan relevansi yang mendalam terhadap kriteria inklusi dan eksklusi, seluruh 273 studi tersebut dinyatakan layak untuk dimasukkan ke dalam analisis akhir. Melalui penerapan protokol PRISMA dan penilaian yang cermat, temuan studi ini memberikan wawasan komprehensif tentang praktik terbaik dan kemajuan terkini penggunaan *Machine Learning* dalam menganalisis perilaku konsumen di sektor *E-commerce*.

Sejalan dengan kerangka metodologis tersebut, tinjauan ini secara spesifik berupaya menjawab tiga pertanyaan penelitian berikut:

**RQ1:** Algoritma *Machine Learning* apa yang paling sering digunakan dalam penelitian untuk analisis perilaku konsumen di *E-commerce*?

**RQ2:** Bagaimana efektivitas pendekatan *Machine Learning* dalam meningkatkan akurasi prediksi perilaku konsumen dibandingkan metode tradisional?

**RQ3:** Apa tantangan utama dan peluang riset masa depan dalam penerapan *Machine Learning* pada sektor *E-commerce*?

### 2.1. Proses Pencarian

Pencarian literatur dilakukan dengan memanfaatkan basis data akademik resmi, seperti *ScienceDirect*, *IEEE Xplore*, *ACM Digital Library* dan *Semantic Scholar*. Basis data tersebut dipilih karena menyediakan publikasi ilmiah berkualitas serta memiliki keterkaitan yang kuat dengan bidang teknologi informasi dan energi. Strategi pencarian menggunakan kombinasi kata kunci yang dipadukan dengan operator Boolean untuk memastikan hasil pencarian yang menyeluruh. Proses pencarian mengikuti tahapan berikut:

1. Kata kunci diidentifikasi berdasarkan topik utama dan istilah terkait (misalnya: *Machine Learning*, *E-commerce*, *Consumer Behavior*).
2. Kata kunci digabungkan dengan operator *Boolean* seperti *AND* dan *OR* untuk memperluas atau mempersempit cakupan pencarian.
3. Hasil pencarian awal disaring berdasarkan relevansi judul dan abstrak.
4. Proses seleksi lebih lanjut dilakukan untuk memastikan literatur sesuai dengan fokus penelitian.

Adapun kombinasi kata kunci (*search string*) yang digunakan adalah:



("Machine Learning" ) AND ("E-commerce" OR "Online Retail") AND ("Consumer Behavior" OR "Customer Prediction" OR "Purchase Intention")

## 2.2. Kriteria Inklusi dan Eksklusi

Literatur yang digunakan dalam tinjauan ini melalui kriteria inklusi dan eksklusi. Penerapan kriteria tersebut digunakan untuk memastikan hanya penelitian yang relevan yang dimasukkan

Tabel 1. Kriteria Inklusi dan Eksklusi

No	Inklusi	Eksklusi
1	Artikel diterbitkan antara 2021–2026	Artikel diterbitkan sebelum tahun 2021
2	Ditulis dalam bahasa Indonesia (minimal Sinta 3) atau bahasa Inggris, termasuk yang memiliki terjemahan valid	Artikel dalam bahasa lain tanpa terjemahan
3	Fokus pada <i>e-commerce</i> , belanja <i>online</i> , atau <i>online retail</i>	Fokus pada perilaku konsumen di konteks <i>offline</i> atau sektor lain (misal perbankan, pendidikan, kesehatan)
4	Menerapkan algoritma <i>machine learning</i> untuk menganalisis data <i>e-commerce</i>	Hanya membahas teori <i>machine learning</i> tanpa implementasi nyata
5	Bertujuan untuk memprediksi atau menganalisis perilaku konsumen (misalnya preferensi, niat beli, segmentasi pelanggan)	Menggunakan <i>machine learning</i> di <i>e-commerce</i> untuk tujuan lain seperti deteksi penipuan, keamanan, atau prediksi harga saham
6	Full paper dalam jurnal atau prosiding konferensi	Artikel berupa <i>review paper</i> , <i>short paper</i> , poster, atau abstrak tanpa isi lengkap

Berdasarkan Tabel 1, proses seleksi difokuskan pada artikel mutakhir yang diterbitkan dalam rentang waktu lima tahun terakhir (2021–2026). Kriteria ini menekankan pada studi empiris yang menerapkan algoritma Machine Learning untuk memprediksi perilaku konsumen secara spesifik di ranah *E-commerce*. Artikel tinjauan (*review*), abstrak, serta penelitian yang tidak menyediakan data implementasi nyata atau berada di luar konteks ritel online secara otomatis dieksklusi untuk menjaga fokus pembahasan.

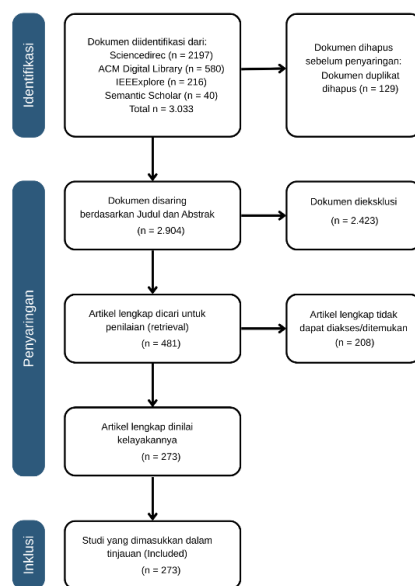
## 2.3. Pengumpulan dan Analisis Data

Proses pengumpulan data dalam penelitian ini terdiri dari beberapa langkah:

1. Artikel yang lolos tahap penyaringan awal (inklusi/eksklusi) dianalisis secara mendalam. Setiap artikel diekstraksi berdasarkan metode yang digunakan, aspek perilaku konsumen yang diteliti, metrik evaluasi, dan tantangan yang ditemukan.
2. Data dari setiap studi yang relevan disimpan dalam spreadsheet dengan atribut khusus (misalnya: tahun publikasi, sumber, algoritma ML, dan hasil akurasi).
3. Teknik analisis deskriptif digunakan untuk menemukan pola, tren, tantangan, dan solusi dalam penerapan ML di *E-commerce*. Indikator utama yang dianalisis meliputi frekuensi metode tertentu, kinerja model, dan tren tahunan publikasi.

## Diagram PRISMA untuk Proses Seleksi Literatur





Gambar 1. Proses sistematis yang digunakan dalam tinjauan literatur

### 3. HASIL DAN PEMBAHASAN

Hasil analisis terhadap 273 artikel terpilih menunjukkan beberapa tren kunci dalam penerapan *Machine Learning* (ML) dan *Deep Learning* (DL) untuk analisis perilaku konsumen di *E-commerce*. Tren ini mencakup pergeseran preferensi peneliti menuju arsitektur model hibrida (*Hybrid Architectures*), keunggulan kinerja metode *Ensemble* dibandingkan statistik tradisional dalam menangani data besar, serta peningkatan fokus pada pemrosesan data multimodal. Analisis memperlihatkan bahwa metode *Hybrid Deep Learning* (seperti kombinasi CNN-LSTM) dan algoritma berbasis gradient boosting (seperti *XGBoost* dan *LightGBM*) mendominasi lanskap penelitian saat ini, terutama untuk tugas prediksi yang melibatkan data urutan waktu (*sequential*) dan data tabular yang tidak seimbang.

Studi yang diulas melaporkan peningkatan performa yang signifikan. Penggunaan *Random Forest*, misalnya, terbukti meningkatkan nilai AUC secara drastis hingga 0,931 dibandingkan metode Regresi Logistik yang hanya mencapai 0,531 [23]. Selain itu, model *Transformer* (seperti BERT) dan pendekatannya pada kasus lintas domain (*cross-domain*) menunjukkan penurunan *Root Mean Square Error* (RMSE) hingga 64,28% pada sektor fashion dibandingkan algoritma baseline [24]. Dalam konteks data yang dinamis, integrasi model hibrida CNN-LSTM berhasil menurunkan tingkat kesalahan (*error rate*) sebesar 18,7% dalam memprediksi perilaku belanja harian [25], mendemonstrasikan superioritas DL dalam menangkap pola non-linear. Di sisi lain, metode klasik seperti *K-Means Clustering* masih tetap relevan dan sering digunakan dalam tahap awal segmentasi pelanggan (*customer profiling*) sebelum diterapkan model prediksi yang lebih kompleks.

#### 3.1. RQ 1: Algoritma *Machine Learning* apa yang paling sering digunakan dalam penelitian untuk analisis perilaku konsumen di *E-commerce*?

Hasil tinjauan sistematis menunjukkan pergeseran paradigma dari penggunaan algoritma tunggal (*single algorithm*) menuju Arsitektur Hibrida (*Hybrid Architectures*). Seperti terlihat pada Tabel 1, kategori *Hybrid Deep Learning* menempati posisi teratas. Hal ini mengindikasikan bahwa peneliti kini menyadari bahwa satu model saja (misalnya hanya CNN atau hanya LSTM) tidak cukup untuk menangkap kompleksitas perilaku konsumen modern yang bersifat multimodal.

Temuan menarik lainnya adalah tingginya penggunaan Gradient Boosting (*XGBoost/LightGBM*) dan *Random Forest* (posisi ke-2). Meskipun bukan Deep Learning, algoritma berbasis decision tree ini tetap menjadi favorit karena kemampuannya menangani data tabular yang tidak seimbang (*imbalanced*) dan memberikan feature importance yang lebih mudah diinterpretasikan dibandingkan neural networks yang kompleks.

Sementara itu, kemunculan Transformer (BERT/GPT) dan Graph Neural Networks (GNN) dalam jumlah signifikan menandai gelombang baru penelitian yang fokus pada pemahaman semantik teks ulasan dan relasi jejaring sosial yang rumit.

Tabel 2. Sintesis Frekuensi Penggunaan Algoritma

No	Kategori Algoritma	Metode	Jumlah Artikel	Tren & Temuan Utama
1	Deep Learning & Hybrid Models	CNN-LSTM, Hybrid Meta-heuristic + DL, End-to-End Models	40	Peneliti cenderung menggabungkan dua model (misal: CNN untuk fitur visual + LSTM untuk urutan waktu) guna meningkatkan akurasi.
2	Ensemble & Tree-Based Methods	XGBoost, LightGBM, Random Forest, Gradient Boosting	35	Sangat dominan untuk data terstruktur (tabular). XGBoost dan LightGBM menjadi standar industri untuk prediksi churn dan penjualan karena kecepatan dan akurasinya.
3	Transformer & LLMs	BERT, GPT, RoBERTa, SpanBERT	31	Mengalami lonjakan signifikan di 2024-2025, khusus untuk analisis sentimen ulasan (text mining) dan semantic retrieval.
4	Graph Neural Networks (GNN)	GNN, GCN, Hypergraph Learning	17	Tren yang sedang naik daun untuk memodelkan relasi kompleks antar user-item dan jejaring sosial dalam rekomendasi.
5	RNN & Variants	LSTM, BiLSTM, GRU	16	Masih menjadi pilihan utama untuk sequential data (riwayat klik/pembelian), seringkali dikombinasikan dengan mekanisme Attention.
6	Reinforcement Learning (RL)	Deep RL, Q-Learning	14	Digunakan spesifik untuk kasus dinamis seperti strategi harga (dynamic pricing) dan rekomendasi interaktif.
7	Clustering & Segmentation	K-means, HC-means, Clustering + RFM	13	Tetap relevan untuk segmentasi pelanggan (customer profiling), sering digunakan sebagai tahap awal sebelum prediksi.

### 3.2. RQ2: Bagaimana efektivitas pendekatan Machine Learning dalam meningkatkan akurasi prediksi perilaku konsumen dibandingkan metode tradisional?

Berdasarkan sintesis data dari literatur terpilih, efektivitas Machine Learning dapat dikategorikan ke dalam tiga dimensi peningkatan utama: (1) Peningkatan Akurasi & Penurunan Error, (2) Keunggulan dalam Data Kompleks (Multimodal/Imbalanced), dan (3) Dampak Bisnis (ROI & Kecepatan).

Tabel 3. Ringkasan Bukti Kuantitatif Efektivitas Machine Learning

No	Referensi	Metode ML (Usulan)	Metode Pemanding (Baseline)	Metrik Evaluasi	Hasil Kuantitatif & Temuan Utama
<b>Peningkatan Akurasi Prediksi (Accuracy &amp; AUC)</b>					
1	[23]	Random Forest (RF)	Logistic Regression (LR)	AUC	Peningkatan drastis: RF (0.931) vs LR (0.531). Menunjukkan LR gagal menangkap pola non-linear.
2	[26], [27]	LSTM (Deep Learning)	Logistic Regression	Accuracy	LSTM (99.7%) vs LR (94%) pada prediksi churn. Pada studi lain [26], LSTM mencapai 86.5% vs baseline.
3	[28]	XGBoost	SVM, RF, MLP, DT	Accuracy	Mencapai akurasi tertinggi 90.65% dan F1-Score 0.91, unggul dalam mendeteksi kelas positif.



4	[29]	<i>Voting Ensemble</i>	<i>XGBoost, CatBoost (Single)</i>	<i>AUC</i>	AUC 0.99; membuktikan bahwa menggabungkan beberapa model ( <i>ensemble</i> ) lebih baik daripada model tunggal terbaik.
5	[30]	<i>EEG-based DL</i>	<i>SVM &amp; Random Forest</i>	<i>Accuracy</i>	Mencapai 92.4% dalam memprediksi preferensi konsumen berbasis sinyal otak.
6	[31]	<i>BERT + Fuzzy Fusion</i>	<i>Survey &amp; Bayesian Network</i>	<i>Accuracy</i>	Mencapai akurasi segmentasi di atas 97%, jauh melampaui metode survei tradisional.

#### Penurunan Tingkat Kesalahan (RMSE/Error)

1	[32]	<i>Hierarchical Bayesian DL</i>	<i>DeepAR, Prophet</i>	<i>RMSE</i>	Error 22.8% lebih rendah dibanding metode <i>forecasting</i> standar industri saat ini.
2	[33]	<i>Hybrid GWO + CNN</i>	<i>CNN, LSTM, MLP, KNN</i>	<i>RMSE</i>	Error terendah (0.570) dan akurasi tertinggi (97.81%) dibanding model DL standar.
3	[25]	<i>Hybrid CNN-LSTM</i>	<i>SVM / Random Forest</i>	<i>RMSE</i>	Menurunkan nilai error sebesar 18.7% pada prediksi perilaku belanja harian.
4	[24]	<i>PEMF-CD (Transformer)</i>	<i>13 Baseline Algorithms</i>	<i>RMSE</i>	Peningkatan signifikan hingga 64.28% (Fashion) dan 24.72% (Musik) pada kasus <i>cross-domain</i> .
5	[34]	<i>SFOA-ELM</i>	<i>BPNN, GRNN</i>	<i>RMSE</i>	Error turun 9.45% - 11.89% dibanding Neural Network standar.

#### Kinerja pada Data Kompleks (Imbalanced, Multimodal, Cold-Start)

1	[35]	<i>LightGBM (Retrieval)</i>	<i>Deep Neural Network</i>	<i>MAP@K</i>	Kinerja 3x lebih tinggi secara konsisten. LightGBM lebih efektif menangani data tabular sparse dibanding DNN.
2	[36], [37]	<i>F-Ensemble / Hybrid DNN</i>	<i>Single Decision Tree</i>	<i>F1-Score</i>	Meningkat 13.39% (F-Ensemble) dan 15.8% (Hybrid DNN) pada data tidak seimbang ( <i>imbalanced</i> ).
3	[38]	<i>Multimodal DL</i>	<i>BERT4Rec (Text-only)</i>	<i>AUC-ROC</i>	Peningkatan 5.5%, membuktikan bahwa data gabungan (Teks+Gambar+Suara) lebih prediktif.
4	[39]	<i>Multimodal AI</i>	<i>Text-only model</i>	<i>Hit Rate</i>	Meningkatkan Hit Rate sebesar 21.3% pada kasus produk baru ( <i>cold-start</i> ).
5	[40]	<i>Sentiment-Aware DL</i>	<i>Collaborative Filtering</i>	<i>Recall</i>	Recall naik 12.4%; menurunkan error masalah <i>cold-start</i> hingga 15%.
6	[41]	<i>XGBoost-SHAP</i>	<i>PLS-SEM (Linear)</i>	<i>Pattern</i>	Berhasil mengungkap hubungan non-linear (pola kurva U terbalik) yang gagal ditangkap statistik linear.

#### Dampak Bisnis (ROI, Konversi, & Kecepatan)

1	[42]	<i>AI-Driven Framework</i>	<i>Traditional Methods</i>	<i>Sales</i>	Nilai keranjang belanja naik 38.7%; ROI promosi meningkat 35.5% - 57.6%.
2	[43]	<i>Naive Bayes + Spark</i>	<i>Standalone Naive Bayes</i>	<i>Speed</i>	Kecepatan pemrosesan data 4.5x lebih cepat pada skala Big Data, dengan akurasi stabil (~88%).



3	[44]	<i>Hierarchical RL</i>	<i>Single-step RL</i>	<i>CTR</i>	Meningkatkan <i>Click-Through Rate</i> (CTR) sebesar 12.5%.
---	------	------------------------	-----------------------	------------	---

### 3.3. RQ3: Apa tantangan utama dan peluang riset masa depan dalam penerapan *Machine Learning* pada sektor *E-commerce*?)

Tabel 4. Tantangan Utama dan Peluang Riset Masa Depan

No	Area Fokus	Tantangan Utama	Peluang Riset Masa Depan
1	Metodologi & Model	Model <i>deep learning</i> sering menghadapi dua tantangan utama, yaitu sifat <i>black-box</i> yang membuat hasil prediksi sulit dijelaskan sehingga dapat menurunkan kepercayaan manajerial, serta masalah <i>data sparsity</i> berupa <i>cold-start</i> pada pengguna atau produk baru yang belum memiliki riwayat interaksi, sehingga akurasi rekomendasi menjadi terbatas.	<i>Explainable AI</i> (XAI) berfokus pada pengembangan model yang transparan agar proses dan dasar pengambilan keputusan dapat dipahami oleh manusia, sementara <i>causal inference</i> dan transfer learning dimanfaatkan untuk mengidentifikasi hubungan sebab-akibat serta mentransfer pengetahuan antar domain guna mengatasi keterbatasan dan kelangkaan data.
2	Tipe Data & Pemrosesan	Kompleksitas multimodal muncul dari kesulitan menyinkronkan data teks, visual, dan audio secara <i>real-time</i> seperti pada <i>live streaming</i> , sementara <i>imbalanced data</i> menyebabkan bias prediksi karena ketimpangan jumlah data antara pembeli dan penjual.	<i>Advanced multimodal fusion</i> memungkinkan integrasi <i>Computer Vision</i> dan <i>Natural Language Processing</i> secara simultan untuk memahami berbagai jenis data, sementara <i>ensemble techniques</i> memanfaatkan penggabungan model atau resampling guna meningkatkan akurasi prediksi pada kondisi data yang tidak seimbang.
3	<i>Generative</i> (LLM)	LLM terkadang menghasilkan informasi tidak akurat atau kurang spesifik pada domain produk <i>niche</i> .	Pemanfaatan GPT-4 untuk pencarian semantik, pembuatan ulasan sintetis, dan <i>chatbot</i> yang humoris/humanis.
4	Aplikasi Bisnis & <i>Live Streaming</i>	Perubahan tren instan (hitungan detik) saat <i>flash sale</i> yang sulit diprediksi model statis.	Analisis sentimen <i>danmaku</i> , pengaruh <i>Virtual Streamer</i> (Avatar), dan strategi harga dinamis berbasis <i>Dynamic Hypergraphs</i> .
5	<i>Neuromarketing</i> & UX	Bias kognitif tersembunyi muncul karena data transaksi tidak mampu merekam emosi bawah sadar maupun beban kognitif pengguna, sementara antarmuka yang statis gagal beradaptasi ketika pengguna mengalami <i>information overload</i> , sehingga menurunkan kualitas pengalaman dan pengambilan keputusan.	<i>Bio-signal integration</i> memanfaatkan sinyal otak (EEG) dan <i>eye-tracking</i> untuk mendeteksi emosi pengguna yang autentik, sementara <i>dynamic interfaces</i> memungkinkan antarmuka beradaptasi secara otomatis—misalnya dengan menyederhanakan tampilan—berdasarkan tingkat beban kognitif pengguna secara <i>real-time</i> .
6	Etika & Regulasi	Kekhawatiran privasi data dan manipulasi keputusan belanja oleh algoritma.	Pengembangan kerangka kerja etis dan legalitas AI dalam pemasaran digital.

Tantangan mendasar dalam penerapan *Machine Learning* di *E-commerce* adalah sifat "*Black Box*" dari model *Deep Learning* yang menghambat adopsi manajerial, serta masalah *cold-start* akibat kelangkaan data (*Data Sparsity*). Literatur terkini [24], [32], [41] menyarankan pergeseran fokus riset menuju *Explainable AI* (XAI) dan *Causal Inference* untuk tidak hanya memprediksi "apa" yang dibeli konsumen, tetapi "mengapa". Selain itu, penggunaan *Transfer Learning* lintas domain menjadi solusi kunci untuk mengatasi masalah pengguna baru, sementara teknik *Ensemble Learning* diperlukan untuk menangani bias pada data yang tidak seimbang [36], [37].

Evolusi *E-commerce* menuju format interaktif (*Live Streaming*) menuntut kemampuan pemrosesan data multimodal (teks, audio, visual) secara simultan dan *real-time*. Riset masa depan perlu mengeksplorasi analisis sentimen pada komentar berjalan (*danmaku*) serta dampak penggunaan *Virtual Streamer* (*Avatar AI*) terhadap keputusan impulsif konsumen [38], [45], [46]. Di sisi lain, *Generative AI* (LLM) membuka peluang baru untuk



semantic search dan pembuatan data sintetis, meskipun tantangan terkait halusinasi model harus diatasi melalui validasi domain yang ketat [31], [47].

Temuan menarik dari data terbaru menyoroiti keterbatasan data transaksional dalam menangkap emosi bawah sadar pengguna. Peluang riset mutakhir terletak pada *Neuromarketing*, yaitu integrasi sinyal biologis (EEG/*Eye-tracking*) untuk menciptakan *Dynamic Interfaces* yang mampu beradaptasi secara otomatis saat pengguna mengalami beban kognitif berlebih (*cognitive overload*) [30], [48]. Terakhir, seiring makin canggihnya algoritma, isu Etika AI dan privasi menjadi krusial, mendorong perlunya riset mengenai *Corporate Digital Responsibility* (CDR) untuk memastikan algoritma tidak memanipulasi konsumen secara tidak etis [49], [50].

#### 4. KESIMPULAN

Berdasarkan hasil dan pembahasan, penelitian ini berhasil mengonfirmasi pernyataan pada bagian pendahuluan bahwa pendekatan *Machine Learning* (ML) merupakan solusi yang jauh lebih efektif dibandingkan metode statistik tradisional dalam menghadapi kompleksitas data *E-commerce* (*Volume, Velocity, Variety*). Sebagaimana diharapkan, hasil tinjauan sistematis membuktikan bahwa pergeseran dari metode konvensional ke algoritma canggih, khususnya arsitektur Hibrida (*Hybrid Deep Learning*) dan metode *Ensemble* (seperti *XGBoost* dan *Random Forest*), memiliki korelasi langsung dengan peningkatan performa analisis perilaku konsumen. Kesesuaian ini ditunjukkan melalui bukti empiris bahwa ML tidak hanya unggul dalam metrik teknis seperti akurasi dan penurunan *error* (RMSE), tetapi juga mampu menangani data yang tidak seimbang serta memberikan dampak bisnis nyata berupa peningkatan ROI dan tingkat konversi.

Sebagai prospek pengembangan hasil penelitian dan penerapan lanjutan, fokus masa depan tidak lagi sekadar pada peningkatan akurasi, melainkan pada aspek transparansi dan adaptabilitas model. Pengembangan selanjutnya sangat potensial diarahkan pada implementasi *Explainable AI* (XAI) untuk mengatasi kendala *black-box* sehingga keputusan algoritma dapat dipahami oleh manajemen bisnis. Selain itu, seiring dengan evolusi tren belanja interaktif, penerapan penelitian lanjutan perlu menyoasar analisis multimodal (teks, audio, visual) untuk ekosistem *Live Streaming Commerce*, serta eksplorasi ranah *Neuromarketing* yang mengintegrasikan sinyal biologis dan *Generative AI* untuk memahami preferensi bawah sadar konsumen secara real-time.

#### REFERENSI

- [1] O. Reshetnikova, V. Danylenko, dan M. Dorosh-Kizym, "Analysis Of Digital Consumer Behavior In The Conditions Of E-Commerce Development," *Economic scope*, no. 203, hlm. 223–229, Agu 2025, doi: 10.30838/EP.203.223-229.
- [2] R. M. Saad, M. Majdalawieh, M. AlARaj, dan H. J. Foxwell, "The Impact of Big Data Analytics on the E-Commerce Businesses," dalam *2023 Tenth International Conference on Social Networks Analysis, Management and Security (SNAMS)*, IEEE, Nov 2023, hlm. 1–8. doi: 10.1109/SNAMS60348.2023.10375428.
- [3] D. Anwar, Md. Faizanuddin, F. Rahman, dan R. Dayal, "Analyzing Consumer Behavior in E-Commerce: Insights from Data-Driven Approaches," *Management (Montevideo)*, vol. 3, hlm. 127, Mar 2025, doi: 10.62486/agma2025127.
- [4] F. P. Chamorro-Zapana, H. E. Chumpitaz-Caycho, E. N. Espinoza-Gamboa, M. A. Espinoza-Cruz, dan F. Cordova-Buiza, "Application Of Big Data For Analyzing Consumer Behavior In E-Commerce Companies," dalam *2023 IEEE 6th International Conference on Big Data and Artificial Intelligence (BD AI)*, IEEE, Jul 2023, hlm. 30–34. doi: 10.1109/BD AI59165.2023.10256889.
- [5] L. Wang, "Design of Intelligent Analysis Method for E-Commerce Data Based on Improved Bayesian Algorithm," dalam *2024 Third International Conference on Distributed Computing and Electrical Circuits and Electronics (ICDCECE)*, IEEE, Apr 2024, hlm. 1–4. doi: 10.1109/ICDCECE60827.2024.10548504.
- [6] I. Oktaviani, E. Purawanto, dan T. Triana, "Analysis of AI-Based Big Data for Strategic Decision-Making in E-Commerce," *Proceeding of International Conference on Science, Health, And Technology*, hlm. 266–278, Sep 2024, doi: 10.47701/icohetech.v5i1.4192.
- [7] J. Yeung, "Data Analytics Architectures for E-Commerce Platforms in Cloud," *International Journal for Applied Information Management*, vol. 1, no. 1, Apr 2021, doi: 10.47738/ijaim.v1i1.3.
- [8] J. Wu, Y. Yang, dan G. Zhang, "Leveraging Machine Learning for Predictive Analysis of Consumer Behavior in Marketing," dalam *2025 IEEE 8th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)*, IEEE, Agu 2025, hlm. 950–954. doi: 10.1109/IAEAC65194.2025.11165851.
- [9] H. H. Chang, A. Mukherjee, H. H. Chang, dan A. Mukherjee, "Machine Learning and Consumer Data." 2023. [Daring]. Tersedia pada: <https://arxiv.org/abs/2306.14118>
- [10] Z. Gao, "Artificial Intelligence Techniques For Complex Big Data Environments: Methods And Perspectives," *Advances in Engineering Innovation*, vol. 16, no. 7, hlm. 167–170, Jul 2025, doi: 10.54254/2977-3903/2025.25599.
- [11] J. Panduro-Ramirez, "Machine Learning-Based Customer Behavior Analysis for E-commerce Platforms," dalam *2024 International Conference on Advances in Computing, Communication and Applied Informatics (ACCAI)*, IEEE, Mei 2024, hlm. 1–5. doi: 10.1109/ACCAI61061.2024.10602204.



- [12] S. K, S. Palit, B. Pravallika, Manjunatha, R. Lenka, dan A. Singla, "Client Segmentation and Customization in E-Commerce: Applications of Machine Learning from a Management Perspective," dalam *2024 International Conference on Communication, Computer Sciences and Engineering (IC3SE)*, IEEE, Mei 2024, hlm. 1423–1427. doi: 10.1109/IC3SE62002.2024.10592939.
- [13] N. Hesvindrati, A. Aminuddin, J. Mahadhni, A. Pambudi, dan B. Sudaryatno, "Behavior-Based Purchase Intent Prediction in E-Commerce: A Machine Learning Approach," *International Journal of Current Science Research and Review*, vol. 08, no. 08, Agu 2025, doi: 10.47191/ijcsrr/V8-i8-03.
- [14] X. Zhang, F. Guo, T. Chen, L. Pan, G. Beliakov, dan J. Wu, "A Brief Survey of Machine Learning and Deep Learning Techniques for E-Commerce Research," *Journal of Theoretical and Applied Electronic Commerce Research*, vol. 18, no. 4, hlm. 2188–2216, Des 2023, doi: 10.3390/jtaer18040110.
- [15] P. Dahake, R. Mohare, dan N. Somani, "Exploring Machine Learning's Potential in Predicting Consumer Behavior for Captivating Marketing," Agu 2023, hlm. 1347–1352. doi: 10.1109/SmartTechCon57526.2023.10391558.
- [16] W. Huang, "Analysis Of Promotional Online Shopping Behavior Based On Machine Learning," *Highlights in Science, Engineering and Technology*, vol. 56, hlm. 65–72, Jul 2023, doi: 10.54097/hset.v56i.9817.
- [17] Navneet Kaur, "Price Prediction In E-Commerce Using Machine Learning Models: A Comparative Study," *ShodhKosh: Journal of Visual and Performing Arts*, vol. 4, no. 1, Jun 2023, doi: 10.29121/shodhkos.v4.i1.2023.5942.
- [18] R. Kasemrat dan T. Kraiwanit, "Benchmarking Machine Learning Models for Predictive Analytics in E-Commerce." 2024. doi: 10.2139/ssrn.4832967.
- [19] M. Joseph Nnaemeka Chukwunweike (MNSE, Dare Abiodun, Omeregie Bright, dan Rotimi Taiwo, "Enhancing Productiveness In E-Commerce Through Machine Learning: Challenges, Future Perspectives, And A Matlab-Based Approach," *World Journal of Advanced Research and Reviews*, vol. 23, no. 2, hlm. 2120–2132, Agu 2024, doi: 10.30574/wjarr.2024.23.2.2585.
- [20] M. A. Rahman, M. S. Hossain, A. A. Minto, dan S. Islam, "A Systematic Review of Intelligent Support Systems for Strategic Decision-Making Using Human–AI Interaction in Enterprise Platforms," *American Journal of Advanced Technology and Engineering Solutions*, vol. 1, no. 1, hlm. 506–543, Feb 2025, doi: 10.63125/a5yh1293.
- [21] S. Syafri dan J. Veri, "Pemanfaatan Artificial Intelligence dalam Dunia Industri: Analisis Literatur Menggunakan Metode SLR dan Teknik PRISMA," *Indo-MathEdu Intellectuals Journal*, vol. 6, no. 5, hlm. 7316–7322, Agu 2025, doi: 10.54373/imeij.v6i5.3887.
- [22] S.P.Neehalika Bavya, G.Suvarchala Reddy, dan G. Sheila, "Beyond Lectures: The Rise of Intelligent Assistants in Management Learning- a Systematic Literature Review," *International Research Journal on Advanced Engineering and Management (IRJAEM)*, vol. 3, no. 08, hlm. 2751–2756, Agu 2025, doi: 10.47392/IRJAEM.2025.0432.
- [23] Y. Zhang, Y. Wang, Y. Ji, dan X. Du, "A Machine Learning Approach to Examine Impacts of Customer Satisfaction on Financial Performance of Firms via Online Reviews," *Journal of Cases on Information Technology*, vol. 27, no. 1, 2025, doi: <https://doi.org/10.4018/JCIT.385600>.
- [24] S. Acharyya dan N. Pervin, "Enhancing cross-domain recommendations: Leveraging personality-based transfer learning with probabilistic matrix factorization," *Expert Systems with Applications*, vol. 263, hlm. 125667, Mar 2025, doi: 10.1016/j.eswa.2024.125667.
- [25] Y. Zhao dkk., "Conditional Potential User Mining framework via explainable surrogate models," *Expert Systems with Applications*, vol. 262, hlm. 125587, 2025, doi: <https://doi.org/10.1016/j.eswa.2024.125587>.
- [26] X. Zhou, F. Li, J. Hu, dan J. Liang, "A customer profiling method for personalized service in retail pharmacies," dalam *Proceedings of the 2025 6th International Conference on Computer Information and Big Data Applications*, dalam CIBDA '25. New York, NY, USA: Association for Computing Machinery, 2025, hlm. 1082–1086. doi: 10.1145/3746709.3746892.
- [27] M. Zaghoul, S. Barakat, dan A. Rezk, "Enhancing customer retention in Online Retail through churn prediction: A hybrid RFM, K-means, and deep neural network approach," *Expert Systems with Applications*, vol. 290, hlm. 128465, Sep 2025, doi: 10.1016/j.eswa.2025.128465.
- [28] Abdullah-All-Tanvir, I. A. Khandokar, A. K. M. M. Islam, S. Islam, dan S. Shatabda, "A gradient boosting classifier for purchase intention prediction of online shoppers," *Heliyon*, vol. 9, no. 4, hlm. e15163, 2023, doi: <https://doi.org/10.1016/j.heliyon.2023.e15163>.
- [29] R. B. Y. Syah dan M. Elveny, "An adaptive analytics framework for customer retention through integrative feature optimization and ensemble learning," *Decision Analytics Journal*, vol. 16, hlm. 100626, 2025, doi: <https://doi.org/10.1016/j.dajour.2025.100626>.
- [30] M. Ouzir, H. C. Lamrani, R. L. Bradley, dan I. E. Moudou, "Neuromarketing and decision-making: Classification of consumer preferences based on changes analysis in the EEG signal of brain regions," *Biomedical Signal Processing and Control*, vol. 87, hlm. 105469, 2024, doi: <https://doi.org/10.1016/j.bspc.2023.105469>.
- [31] M. Zhang, D. Wu, H. Xu, dan Z. Chao, "A Consumer Trust Assessment Model for Online Shopping Based on Fuzzy Fusion Decision-Making," *Journal of Organizational and End User Computing*, vol. 36, no. 1, 2024, doi: <https://doi.org/10.4018/JOEUC.349730>.
- [32] A. Jha, A. Bhatia, K. Tiwari, dan H. M. Pandey, "Hierarchical Bayesian Deep Learning for return on advertising spend prediction: A probabilistic approach to e-commerce advertising," *Engineering Applications of Artificial Intelligence*, vol. 164, hlm. 113200, Jan 2026, doi: 10.1016/j.engappai.2025.113200.
- [33] M. Dasoomi, A. Naderan, dan T. Allahviranloo, "A novel hybrid machine learning model for shopping trip estimation: A case study of Tehran, Iran," *Transportation Engineering*, vol. 14, hlm. 100218, 2023, doi: <https://doi.org/10.1016/j.treng.2023.100218>.
- [34] B. Li, M. Liao, J. Yuan, dan J. Zhang, "Green consumption behavior prediction based on fan-shaped search mechanism fruit fly algorithm optimized neural network," *Journal of Retailing and Consumer Services*, vol. 75, hlm. 103471, Nov 2023, doi: 10.1016/j.jretconser.2023.103471.



- [35] D.-N. Nguyen, V.-H. Nguyen, T. Trinh, T. Ho, dan H.-S. Le, "A personalized product recommendation model in e-commerce based on retrieval strategy," *Journal of Open Innovation: Technology, Market, and Complexity*, vol. 10, no. 2, hlm. 100303, 2024, doi: <https://doi.org/10.1016/j.joitmc.2024.100303>.
- [36] C. Du, "Construction of Consumption Data Optimization Model Based on XGBoost Algorithm," *Procedia Computer Science*, vol. 262, hlm. 278–286, 2025, doi: <https://doi.org/10.1016/j.procs.2025.05.054>.
- [37] W. Zhang dan F. Liu, "F-Ensemble: A Full Fusion Ensemble Model for Predicting E-commerce User Purchasing Behavior," dalam *Proceedings of the 2024 7th International Conference on Information Management and Management Science*, Beijing China: ACM, Agu 2024, hlm. 117–123. doi: 10.1145/3695652.3695715.
- [38] W. Zhong, "E Commerce Consumer Behavior Prediction Model Integrating Spatiotemporal Features and Multimodal Sentiment Recognition," dalam *Proceedings of the 2025 International Conference on Economic Management and Big Data Application*, Shenzhen China: ACM, Jul 2025, hlm. 502–506. doi: 10.1145/3770177.3770258.
- [39] Y. Qian, Y. Jiang, J. Shang, Y. Chai, dan Y. Liu, "Why some products compete and others don't: A competitive attribution model from customer perspective," *Decision Support Systems*, vol. 169, hlm. 113956, 2023, doi: <https://doi.org/10.1016/j.dss.2023.113956>.
- [40] T. Li, Y. Wu, Y. Liu, dan J. Li, "Deep Learning-Based Analysis of E-Commerce Enterprises:," *Journal of Organizational and End User Computing*, vol. 37, no. 1, 2025, doi: <https://doi.org/10.4018/JOEUC.379722>.
- [41] J. Gary, Z. Xixing, Y. M. Tang, G. Yang, dan A. C. Moreira, "Augmented Reality in Retail:," *Journal of Global Information Management*, vol. 33, no. 1, 2025, doi: <https://doi.org/10.4018/JGIM.394246>.
- [42] Y. Wang, "Enhancing Retail Promotional ROI Through AI-Driven Timing and Targeting: A Data Decision Framework for Multi-Category Retailers," dalam *Proceedings of the 2025 International Conference on Digital Economy and Information Systems*, Guangzhou China: ACM, Apr 2025, hlm. 296–302. doi: 10.1145/3745133.3745183.
- [43] L. Bi, "Design of personalised recommendation algorithm for e-commerce platform based on Naive Bayes model and Spark," dalam *Proceedings of the 2025 6th International Conference on Computer Information and Big Data Applications*, dalam CIBDA '25. New York, NY, USA: Association for Computing Machinery, 2025, hlm. 395–400. doi: 10.1145/3746709.3746774.
- [44] O. Katz, O. Barkan, dan N. Koenigstein, "Personalized Cadence Awareness for Next Basket Recommendation," *ACM Trans. Recomm. Syst.*, vol. 3, no. 1, Agu 2024, doi: 10.1145/3652863.
- [45] B. Xiang, X. Han, Q. Gu, F. Chao, X. Yang, dan X. Fu, "A Data-Driven Approach to Predict 'Freebie-Seeker' Behaviors in Digital Marketing," dalam *Proceedings of the 2025 2nd International Conference on Digital Economy, Blockchain and Artificial Intelligence*, dalam DEBAI '25. New York, NY, USA: Association for Computing Machinery, 2025, hlm. 299–307. doi: 10.1145/3762249.3762295.
- [46] D. Belanche, L. V. Casaló, dan M. Flavián, "Human versus virtual influences, a comparative study," *Journal of Business Research*, vol. 173, hlm. 114493, Feb 2024, doi: 10.1016/j.jbusres.2023.114493.
- [47] A. Kumar, A. Shankar, L. D. Hollebeek, A. Behl, dan W. M. Lim, "Generative artificial intelligence (GenAI) revolution: A deep dive into GenAI adoption," *Journal of Business Research*, vol. 189, hlm. 115160, Feb 2025, doi: 10.1016/j.jbusres.2024.115160.
- [48] Y. Yuan, "Analysis and Research of Retail Enterprise Customer Consumption Behavior Based on Support Vector Machine Algorithm," dalam *Proceedings of the 2025 International Conference on Economic Management and Big Data Application*, dalam ICEMBDA '25. New York, NY, USA: Association for Computing Machinery, 2025, hlm. 519–525. doi: 10.1145/3770177.3770262.
- [49] A. Kaponis dan M. Maragoudakis, "Data Analysis in Digital Marketing using Machine learning and Artificial Intelligence Techniques, Ethical and Legal Dimensions, State of the Art.," dalam *Proceedings of the 12th Hellenic Conference on Artificial Intelligence*, dalam SETN '22. New York, NY, USA: Association for Computing Machinery, 2022. doi: 10.1145/3549737.3549756.
- [50] A. Upadhyay, A. Dubey, P. Goenka, dan S. M. Kuriakose, "NMNet: Spatial-Temporal Transformer for EEG Signal Analysis in Neuromarketing," dalam *Proceedings of the 7th Joint International Conference on Data Science & Management of Data (11th ACM IKDD CODS and 29th COMAD)*, dalam CODS-COMAD '24. New York, NY, USA: Association for Computing Machinery, 2024, hlm. 474–478. doi: 10.1145/3632410.3632472.