

**PENERAPAN ALGORITMA EXTREME LEARNING MACHINE
(ELM) UNTUK MEMPREDIKSI PERILAKU KONSUMTIF
BERDASARKAN POLA TRANSAKSI E-COMMERCE**

SKRIPSI

DISUSUN OLEH

SITI MARDYATI RUKMANA

2209020115



UMSU

Unggul | Cerdas | Terpercaya

**PROGRAM STUDI TEKNOLOGI INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA**

MEDAN

2026

**PENERAPAN ALGORITMA EXTREME LEARNING MACHINE
(ELM) UNTUK MEMPREDIKSI PERILAKU KONSUMTIF
BERDASARKAN POLA TRANSAKSI E-COMMERCE**

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer
(S.Kom) dalam Program Studi Teknologi Informasi, pada Fakultas Ilmu Komputer
dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara**

SITI MARDYATI RUKMANA

2209020115

**PROGRAM STUDI TEKNOLOGI INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA**

MEDAN

2026

LEMBAR PENGESAHAN


Judul Skripsi : PENERAPAN ALGORITMA EXTREME LEARNING
MACHINE (ELM) UNTUK MEMPREDIKSI
PERILAKU KONSUMTIF BERDASARKAN POLA
TRANSASKI E-COMMERCE

Nama Mahasiswa : SITI MARDYATI RUKMANA


NPM : 2209020115

Program Studi : TEKNOLOGI INFORMASI

Menyetujui
Komisi Pembimbing


(Dr. Al-Khwarizmi, S.Kom., M.Kom.)
NIDN. 0127099201

Ketua Program Studi


(Fatma Sari Hutagalung, S.Kom, M.Kom.)
NIDN. 0117019301

Dekan



(Dr. Al-Khwarizmi, S.Kom., M.Kom.)
NIDN. 0127099201

PERNYATAAN ORISINALITAS

PENERAPAN ALGORITMA EXTREME LEARNING MACHINE (ELM) UNTUK MEMPREDIKSI PERILAKU KONSUMTIF BERDASARKAN POLA TRANSAKSI E-COMMERCE

SKRIPSI

Saya menyatakan bahwa karya tulis ini adalah hasil karya sendiri, kecuali beberapa kutipan dan ringkasan yang masing-masing disebutkan sumbernya.

Medan, 9 April 2026

Yang membuat pernyataan



Siti Mardyati Rukmana

NPM. 2209020115

**PERNYATAAN PERSETUJUAN PUBLIKASI
KARYA ILMIAH UNTUK KEPENTINGAN
AKADEMIS**

Sebagai sivitas akademika Universitas Muhammadiyah Sumatera Utara, saya bertanda tangan dibawah ini:

Nama : Siti Mardyati Rukmana
NPM : 2209020115
Program Studi : Teknologi Informasi
Karya Ilmiah : Skripsi

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Muhammadiyah Sumatera Utara Hak Bedas Royalti Non-Eksekutif (*Non-Exclusive Royalty free Right*) atas penelitian skripsi saya yang berjudul:

**PENERAPAN ALGORITMA EXTREME LEARNING MACHINE
(ELM) UNTUK MEMPREDIKSI PERILAKU KONSUMTIF
BERDASARKAN POLA TRANSAKSI E-COMMERCE**

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Non-Eksekutif ini, Universitas Muhammadiyah Sumatera Utara berhak menyimpan, mengalih media, memformat, mengelola dalam bentuk database, merawat dan mempublikasikan Skripsi saya ini tanpa meminta izin dari saya selama tetap mencantumkan nama saya sebagai penulis dan sebagai pemegang dan atau sebagai pemilik hak cipta.

Demikian pernyataan ini dibuat dengan sebenarnya.

Medan, 9 April 2026

Yang membuat pernyataan



Siti Mardyati Rukmana
NPM. 2209020115

RIWAYAT HIDUP

DATA PRIBADI

Nama Lengkap : SITI MARDYATI RUKMANA
Tempat dan Tanggal Lahir : Kp Lalang, 09 Februari 2005
Alamat Rumah : Dusun III A Kampung Lalang
Telepon/Faks/HP : 082275352030
E-mail : sitimardyati12@gmail.com
Instansi Tempat Kerja : -
Alamat Kantor : -

DATA PENDIDIKAN

SD : MIN Gunung Melayu TAMAT: 2016
SMP : MTS Negeri 1 Labura TAMAT: 2019
SMA : SMK Taruna Tekno Nusantara TAMAT: 2022

KATA PENGANTAR



Assalamualaikum Warahmatullahi Wabarakatuh

Alhamdulillah, penulis lantunkan kehadiran Allah SWT, yang telah memberikan rahmat dan karunia-Nya kepada penulis, sehingga penulis dapat menyelesaikan skripsi yang berjudul “ Penerapan Algoritma Extreme Learning Machine (ELM) Untuk Memprediksi Perilaku Konsumtif Berdasarkan Pola Transaksi E-commerce”. Shalawat dan salam kepada Nabi Muhammad SAW, yang telah membawa kita dari zaman kegelapan menuju zaman yang terang benderang seperti sekarang ini. Penyusunan skripsi ini bertujuan untuk memenuhi salah satu syarat guna mencapai gelar sarjana komputer di Universitas Muhammdiyah Sumatera Utara.

Dalam proses penyusunan skripsi ini, penulis menyadari bahwa penyelesaian skripsi ini tidak terlepas dari bantuan, bimbingan, dukungan, dan doa dari berbagai pihak. Oleh karena itu, pada kesempatan ini penulis ingin menyampaikan ucapan terima kasih yang sebesar-besarnya kepada:

1. Bapak Prof. Dr. Akrim, M.Pd., Rektor Universitas Muhammadiyah Sumatera Utara (UMSU)
2. Bapak Dr. Al-Khowarizmi, S.Kom., M.Kom. Dekan Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU. Sekaligus Dosen Pembimbing yang senantiasa telah membimbing dan mengarahkan penulis sehingga dapat menyelesaikan skripsi dengan sebaik-baiknya.

3. Ibu Dr. Firaahmi Rizky, M.Kom. Selaku Wakil Dekan I Fakultas Ilmu Komputer dan Teknologi Informasi Universitas Muhammadiyah Sumatra Utara.
4. Bapak Mhd. Basri, S.Si, M.Kom. Wakil Dekan III Program Studi Teknologi Informasi Fakultas Ilmu Komputer dan Teknologi Informasi.
5. Ibu Fatma Sari Hutagalung, S.Kom., M.Kom. Ketua Program Studi Teknologi Informasi.
6. Bapak Okvi Nugroho S.Kom., M.Kom. Sekretaris Program Studi Teknologi Informasi.
7. Seluruh dosen dan staf Fakultas Ilmu Komputer dan Teknologi Informasi yang telah dengan tulus memberikan ilmu pengetahuan, bimbingan, bantuan, serta pelayanan yang baik kepada penulis selama menempuh masa perkuliahan, sehingga penulis dapat belajar, berkembang, dan menyelesaikan pendidikan ini dengan baik.
8. Ucapan terima kasih ini penulis persembahkan kepada kedua orang tua tercinta, Bapak Misman dan Ibu Sri Mulyati yang selalu menjadi sumber kekuatan ,tempat bersandar dan berkeluh kesah. Terima kasih juga atas doa yang tak pernah putus , pengorbanan yang tak usai dalam setiap langkah penulis. Terima kasih juga selalu ada disisi penulis, hal ini menjadi penguat bagi penulis untuk segera menyelesaikan penulisan skripsi untuk mendapatkan gelar sarjana.
9. Ucapan terima kasih ini penulis persembahkan kepada abang kandung saya tercinta, Yusuf Hadi yang selalu memberikan dukungan dan semangat dalam penulisan skripsi.

10. Ucapan terima kasih ini penulis persembahkan kepada teman seperjuangan saya circle GALAXY , yang telah menjadi bagian cerita indah semasa perkuliahan. Terima kasih sudah menjadi tempat berkeluh kesah, tempat bercerita , tempat mengaduh segala permasalahan dan terima kasih juga selalu ada disisi penulis baik suka maupun duka . Terima kasih karena selalu menemani, mendukung, menghibur, dan berjalan bersama dalam setiap proses yang telah dilalui. Semoga persahabatan ini senantiasa terjaga, dan langkah kita semua selalu dimudahkan untuk meraih mimpi-mimpi terbaik di masa depan.
11. Terima kasih ini saya ucapkan kepada seluruh tim kkn mekar sawit atas dukungan, dan motivasi kepada penulis untuk segera menyelesaikan skripsi, semoga pertemanan kita senantiasa terjaga dan kita semua dimudahkan untuk meraih mimpi-mimpi terbaik dimasa yang akan datang.
12. Ucapan terima kasih yang tulus penulis sampaikan kepada teman-teman kelas C1 Para sahabat penulis dibangku perkuliahan yang selalu kebersamai dalam empat tahun ini yang memberikan banyak kenangan indah selama perkuliahan. Terima kasih atas kebersamaan, dukungan, dan bantuan yang diberikan, terutama saat penulis mengalami kebuntuan dalam menyelesaikan skripsi ini.
13. Penulis juga mengucapkan terima kasih kepada teman-teman lainnya yang tidak dapat disebutkan satu per satu, namun telah hadir dan memberikan dukungan, semangat, perhatian, serta bantuan kepada penulis, terutama pada masa-masa sulit dan titik terendah dalam proses penyusunan skripsi

ini. Kehadiran dan kebaikan kalian menjadi kekuatan tersendiri bagi penulis untuk tetap bertahan, bangkit, dan menyelesaikan skripsi ini hingga akhir.

14. Terakhir, ucapan terima kasih kepada diri sendiri atas perjuangan, kesabaran, dan ketekunan dalam menyelesaikan skripsi ini. Tidak sedikit rintangan, keraguan, kelelahan, bahkan air mata yang menyertai setiap proses penulisan skripsi ini. Namun penulis tetap berusaha dan bertahan hingga sampai ketahap ini. Semoga setiap perjalanan ini mejadi pengingat bagi penulis bahwa setiap perjuangan tidak akan pernah sia-sia dan akan selalu memberikan makna serta pembelajaran yang berharga dimasa depan.

**PENERAPAN ALGORITMA EXTREME LEARNING MACHINE
(ELM) UNTUK MEMPREDIKSI PERILAKU KONSUMTIF
BERDASARKAN POLA TRANSAKSI E-COMMERCE**

ABSTRAK

Perkembangan e-commerce mendorong perubahan pola belanja masyarakat dan berpotensi meningkatkan perilaku konsumtif. Penelitian ini bertujuan menerapkan algoritma Extreme Learning Machine (ELM) untuk memprediksi perilaku konsumtif berdasarkan pola transaksi e-commerce. Data yang digunakan merupakan data sekunder dari Kaggle sebanyak 1.000 transaksi dengan atribut Date, Gender, Age, Product Category, Quantity, Price per Unit, dan Total Amount. Dataset tidak memiliki label target bawaan sehingga label konsumtif dibentuk secara operasional menggunakan ambang persentil ke-75 pada Total Amount. Transaksi dengan Total Amount ≥ 900 dikategorikan sebagai konsumtif, sedangkan transaksi di bawah ambang tersebut dikategorikan sebagai tidak konsumtif. Tahapan penelitian meliputi preprocessing data, transformasi fitur, pembagian data latih dan data uji dengan rasio 80:20, implementasi model ELM, serta evaluasi menggunakan accuracy, precision, recall, dan F1-score. Hasil pengujian menunjukkan bahwa model ELM memperoleh accuracy 96,50%, precision 94,23%, recall 92,45%, dan F1-score 93,33%. Hasil ini menunjukkan bahwa ELM mampu mengklasifikasikan transaksi konsumtif dan tidak konsumtif secara baik berdasarkan fitur transaksi yang tersedia, dengan catatan bahwa definisi konsumtif dalam penelitian ini bersifat operasional berdasarkan nilai transaksi.

Kata kunci : E-commerce, Perilaku Konsumtif, Extreme Learning Machine, Klasifikasi, Machine Learning

**Application of the Extreme Learning Machine (ELM) Algorithm for
Predicting Consumptive Behavior Based on E-Commerce Transaction
Patterns**

ABSTRACT

The development of e-commerce has changed consumer shopping patterns and may increase consumptive behavior. This study aims to apply the Extreme Learning Machine (ELM) algorithm to predict consumptive behavior based on e-commerce transaction patterns. The dataset used in this research is secondary data obtained from Kaggle, consisting of 1,000 transactions with the attributes Date, Gender, Age, Product Category, Quantity, Price per Unit, and Total Amount. Since the dataset does not have a target label, the consumptive behavior label was operationally generated using the 75th percentile threshold of Total Amount. Transactions with Total Amount ≥ 900 were categorized as consumptive, while those below the threshold were categorized as non-consumptive. The research stages include data preprocessing, feature transformation, splitting training and testing data using an 80:20 ratio, ELM model implementation, and evaluation using accuracy, precision, recall, and F1-score. The testing results show that the ELM model achieved 96.50% accuracy, 94.23% precision, 92.45% recall, and 93.33% F1-score. These findings indicate that ELM can classify consumptive and non-consumptive transactions properly based on available transaction features, although the definition of consumptive behavior in this study is operationally based on transaction value.

Keywords: E-commerce, Consumptive Behavior, Extreme Learning Machine, Classification, Machine Learning

DAFTAR ISI

LEMBAR PENGESAHAN	ii
PERNYATAAN ORISINALITAS	iii
PERNYATAAN PERSETUJUAN PUBLIKASI	iv
RIWAYAT HIDUP	v
KATA PENGANTAR	vi
ABSTRAK.....	x
ABSTRACT.....	xi
DAFTAR ISI.....	xii
DAFTAR TABEL.....	xiv
DAFTAR GAMBAR.....	xv
BAB I.....	1
PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah	4
1.3 Batasan Masalah	4
1.4 Tujuan Penelitian	5
1.5 Manfaat Penelitian	5
BAB II.....	7
LANDASAN TEORI.....	7
2.1 E-Commerce dan Data Transaksi	7
2.2 Perilaku Konsumtif.....	8
2.3 Machine Learning Untuk Prediksi	8
2.4 Extreme Learning Machine (ELM).....	9
2.5 Python	12
2.6 Google Colab	12
2.7 Visual Studio Code	13
2.8 Penelitian Terdahulu	14
2.9 ANALISIS GAP	20
BAB III	22
METODOLOGI PENELITIAN.....	22
3.1 Jenis Penelitian.....	22
3.2 Analisis Alat Penelitian.....	22
3.2.1 Perangkat Keras (<i>Hardware</i>)	23
3.2.2 Perangkat Lunak (<i>Software</i>).....	23
3.3 Objek Penelitian dan Sumber Data	24
3.4 Alur Penelitian	26

3.5 Proses Pembuatan Model.....	27
3.5.1 Variabel Penelitian.....	27
3.5.2 Preprocessing Data.....	28
3.5.3 Pembagian Data Latih dan Data Uji.....	30
3.5.4 Implementasi Model <i>Extreme Learning Machine</i> (ELM).....	30
3.5.5 Evaluasi Kinerja model.....	31
3.6 Pemodelan dan Perancangan sistem	33
3.6.1 Use Case Diagram.....	33
3.6.2 Activity Diagram.....	34
3.6.3 Perancangan Antarmuka Interface	36
BAB IV	40
HASIL DAN PEMBAHASAN.....	40
4.1 Hasil Penelitian	40
4.1.1 Gambaran Umum Dataset.....	40
4.1.2 Hasil Preprocessing Data	42
4.1.3 Pembagian Data Latih dan Data Uji.....	42
4.1.4 Implementasi Model <i>Extreme Learning Machine</i> (ELM).....	44
4.1.5 Evaluasi Model pada Data Uji	44
4.1.6 Impementasi Antarmuka Pengguna	48
4.2 Pembahasan.....	52
4.2.1 Interpretasi Hasil Klasifikasi.....	52
4.2.2 Proses Pembentukan Label Konsumtif	53
4.2.3 Pengaruh Tahap Preprocessing terhadap Kinerja Model	54
4.2.4 Implementasi <i>Extreme Learning Machine</i> dalam Penelitian	55
4.2.5 Analisis Hasil pada Tiap Kelas	56
4.2.7 Kelebihan dan Keterbatasan Penelitian.....	58
4.2.8 Implikasi dan Pengembangan Lanjutan	59
4.3 Ringkasan Bab	60
BAB V	61
PENUTUP	61
5.1 Kesimpulan	61
5.2 Saran	62
DAFTAR PUSTAKA	64
Lampiran 1. SK Penetapan Dosen Pembimbing.....	67
Lampiran 2. Turnitin.....	69

DAFTAR TABEL

Tabel 2.1 Penelitian Tardahulu	14
Tabel 3.1 Tabel Spesifikasi Leptop.....	23
Tabel 3.2 Tabel Perangkat Lunak (software).....	23
Tabel 3.3 Tabel Dataset.....	25
Tabel 4.1 Ringkasan Kondisi Dataset	41
Tabel 4.2 Variabel yang Digunakan Dalam Pemodelan	41
Tabel 4.3 Distribusi Kelas Target Pada Data Uji.....	43
Tabel 4.4 Pembagian Data Latih dan Data Uji	43
Tabel 4.5 Hasil Evaluasi Model ELM.....	47

DAFTAR GAMBAR

Gambar 3.1 Diagram Alur Penelitian.....	26
Gambar 3.2 Flowchart Extreme Learning Machine(ELM).....	30
Gambar 3.3 Use Case Diagram.....	34
Gambar 3.4 Activity Diagram.....	35
Gambar 3.5 Rancangan Halaman Login.....	36
Gambar 3.6 Rancangan Halaman Dashboard.....	37
Gambar 3.7 Rancangan Prediksi Dataset.....	37
Gambar 3.8 Rancangan Prediksi 1Data.....	38
Gambar 3.9 Rancangan Riwayat Hasil Prediksi.....	39
Gambar 3.10 Rancangan Hasil Evaluasi Model.....	39
Gambar 4.1 Distribusi perilaku Konsumtif.....	36
Gambar 4.2 Confusion Matrix Model ELM.....	43
Gambar 4.3 Clasification Report Model.....	47
Gambar 4.4 Halaman Login.....	48
Gambar 4.5 Halaman Dashboard.....	49
Gambar 4.6 Halaman Prediksi Dataset.....	49
Gambar 4.7 Halaman Prediksi 1Data.....	50
Gambar 4.8 Halaman Riwayat Hasil Prediksi.....	51
Gambar 4.9 Halaman Hasil Evaluasi Model.....	51

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Era digitalisasi telah memunculkan beragam inovasi dalam bidang perdagangan yang mengubah pola interaksi perusahaan dengan konsumen dan mitra bisnisnya. Inovasi ini terwujud dalam sistem teknologi yang dikenal sebagai *e-commerce*. *E-commerce* telah mengubah secara fundamental cara perusahaan dan konsumen melakukan aktivitas perdagangan (Melisa et al., 2025). Digitalisasi membuat kebiasaan belanja semakin impulsif, sehingga banyak orang lebih suka memenuhi keinginan daripada kebutuhan pokok. Hal ini menciptakan pola belanja baru yang fokus pada jumlah belanja yang banyak. Meski ekonomi digital memberi banyak kemudahan, tantangan utamanya adalah menjaga keseimbangan agar teknologi tidak membuat masyarakat terjebak dalam budaya konsumtif yang tidak sehat. Perilaku konsumtif merupakan suatu perilaku yang tidak lagi didasarkan pada pertimbangan yang rasional, melainkan karna adanya keinginan yang sudah mencapai taraf tidak rasional lagi. Perilaku konsumtif melekat pada seseorang bila orang tersebut membeli sesuatu diluar nalar kebutuhan tetapi sudah karna faktor keinginan (Naning Fatmawatie, 2022).

Dalam penelitian ini, pola transaksi dijelaskan langsung melalui variabel-variabel yang ada, seperti waktu transaksi, jenis produk, jumlah barang yang dibeli, harga per item, serta total belanja pada setiap transaksi. Variabel-variabel ini kemudian digunakan sebagai fitur untuk membangun model yang bisa mengenali kecenderungan perilaku belanja konsumen berdasarkan riwayat transaksi yang tercatat dalam data *e-commerce*. Agar prediksi bisa dilakukan dengan baik pada

data transaksi yang banyak, diperlukan metode komputasi yang cepat, efisien, dan dapat diandalkan. Di tengah pertumbuhan pesat *e-commerce* yang menghasilkan data secara masif, kebutuhan akan metode prediksi yang mampu menangani skala besar semakin penting. Salah satu metode yang sering digunakan dan memiliki hasil prediksi yang baik di berbagai kasus adalah Extreme Learning Machine (ELM). Karena itu, dalam penelitian ini ELM dipilih sebagai pendekatan dalam membangun model prediksi perilaku belanja berdasarkan pola transaksi di *e-commerce*.

Extreme Learning Machine (ELM) merupakan suatu metode jaringan saraf yang inovatif yang didasarkan pada model dan data baru. Metode ini menggunakan algoritma Jaringan Saraf Maju Satu Lapisan Tersembunyi (SLFNs) untuk menghasilkan solusi tertutup dalam bentuk bobot output melalui metode Kuadrat Terkecil. ELM termasuk dalam kategori metode jaringan saraf feed-forward dengan satu lapisan tersembunyi, yang juga dikenal sebagai Single Hidden Layer Feed-Forward Neural Network. ELM memiliki keunggulan dibandingkan dengan metode jaringan saraf lainnya, seperti waktu komputasi yang lebih cepat dan output yang stabil dalam waktu nyata. (Warohma et al., 2023)

Penelitian terdahulu menurut (Devita Rizqi et al., 2025) melakukan penelitian berjudul “*Prediksi Tren Penggunaan Electronic Money (E-Money) di Indonesia menggunakan pendekatan Extreme Learning Machines*” yang dipublikasikan dalam *Emerging Statistics and Data Science Journal*. Penelitian ini menggunakan data sekunder nilai transaksi e-money bulanan di Indonesia periode 2021–2024 dan memodelkannya dengan algoritma *Extreme Learning Machine* (ELM). Hasilnya menunjukkan bahwa model ELM mampu memberikan proyeksi

tren transaksi e-money dengan pola pertumbuhan yang konsisten dan tingkat kesalahan yang relatif rendah, sehingga dinilai cukup efektif untuk peramalan data transaksi keuangan digital.

Penelitian lainnya (Dhanty et al., 2022) meneliti “*Analisis Pengaruh Kemudahan PayLater pada Aplikasi Shopee dan Promo Diskon Produk terhadap Perilaku Pembelian Impulsif (Studi pada Pengguna Shopee di DKI Jakarta)*” yang dimuat dalam Jurnal Manajemen dan Bisnis Jayakarta. Penelitian ini menggunakan pendekatan kuantitatif dengan kuesioner pada 150 pengguna Shopee di DKI Jakarta, dan dianalisis menggunakan regresi linier berganda. Hasil penelitian menunjukkan bahwa kemudahan PayLater dan promo diskon produk berpengaruh signifikan baik secara parsial maupun simultan terhadap perilaku pembelian impulsif pengguna Shopee, sehingga menegaskan bahwa fitur keuangan digital dan strategi promosi di e-commerce dapat mendorong perilaku konsumtif.

Penelitian terdahulu menunjukkan celah: ELM masih banyak digunakan untuk peramalan tren transaksi e-money (Devita dkk., 2025), sedangkan perilaku konsumtif e-commerce umumnya dikaji melalui kuesioner dan regresi (Dhanty dkk., 2022) sehingga belum berbasis data transaksi. Karena itu, penelitian ini bertujuan mengklasifikasikan perilaku konsumtif/tidak konsumtif pada transaksi e-commerce menggunakan ELM dengan pelabelan operasional berdasarkan indikator *Total amount*. Data yang digunakan merupakan data sekunder dari Kaggle, dan kinerja model dievaluasi menggunakan akurasi, *precision*, *recall*, dan *F1-score*.

1.2 Rumusan Masalah

Berdasarkan latar belakang masalah yang menunjukkan bahwa data transaksi e-commerce dapat mencerminkan kecenderungan perilaku belanja, penelitian ini difokuskan pada penetapan kategori konsumtif dan tidak konsumtif secara operasional dari pola transaksi, kemudian menerapkan algoritma Extreme Learning Machine (ELM) untuk memprediksi kecenderungan tersebut berdasarkan variabel transaksi yang tersedia. Selanjutnya, penelitian ini menilai seberapa baik model ELM dalam melakukan prediksi melalui evaluasi menggunakan akurasi, precision, recall, dan F1-score.

1.3 Batasan Masalah

Penelitian ini memiliki batasan permasalahan yang dibahas agar dapat menyelesaikan permasalahan utama. Berikut ini batasan masalah penelitian ini

1. Penelitian ini menggunakan data sekunder transaksi e-commerce yang diperoleh dari Kaggle, sehingga hasil penelitian dibatasi pada karakteristik dataset tersebut.
2. Penelitian ini menggunakan dataset transaksi e-commerce yang mencakup tiga kategori produk, yaitu Electronics, Clothing, dan Beauty, sehingga ruang lingkup penelitian dibatasi pada ketiga kategori tersebut.
3. Data yang digunakan tidak memuat identitas pelanggan (*Customer ID*), sehingga penentuan kategori konsumtif dan tidak konsumtif dilakukan berdasarkan informasi pada setiap transaksi, yang merepresentasikan perilaku belanja pada saat transaksi terjadi.
4. Dataset tidak menyediakan label perilaku konsumtif, sehingga label konsumtif (1) dan tidak konsumtif (0) ditetapkan secara operasional

berdasarkan indikator transaksi (misalnya nilai *Total Amount* dengan ambang tertentu).

5. Penelitian ini berfokus pada penerapan ELM dan tidak membahas optimasi lanjutan maupun perbandingan dengan algoritma klasifikasi lainnya.
6. Evaluasi kinerja model dilakukan menggunakan matrix akurasi, precision, recall dan F1 score.

1.4 Tujuan Penelitian

Adapun tujuan penelitian dari penelitian ini adalah sebagai berikut :

1. Menetapkan label konsumtif dan tidak konsumtif secara oprasional pada data transaksi *e-commerce* (Kaggle) berdasarkan indikator transaksi yang tersedia, seperti *total Amount* .
2. Menerapkan algoritma *Extreme Learning Machine* (ELM) untuk membangun model yang memprediksi konsumtif /tidak konsumtif berdasarkan variable yang tersedia.
3. Mengevaluasi kinerja model (ELM) dalam prediksi konsumtif/tidak konsumtif menggunakan metrik akurasi, precision, recall, dan F1 -score.

1.5 Manfaat Penelitian

Adapun manfaat penelitian dalam penelitian ini Adalah sebagai berikut:

1. Menambah referensi mengenai penerapan metode ELM pada kasus klasifikasi perilaku konsumtif berbasis data transaksi.
2. Memberikan gambaran tahapan penelitian data mining/machine learning mulai dari preprocessing, pelabelan (0/1), pemodelan ELM, hingga evaluasi kinerja menggunakan confusion matrix dan metrik (accuracy, precision, recall, F1-score).

3. Menjadi bahan perbandingan bagi penelitian sejenis yang menggunakan metode klasifikasi lain pada data transaksi e-commerce.

BAB II

LANDASAN TEORI

2.1 E-Commerce dan Data Transaksi

E-commerce adalah sistem pemasaran secara atau dengan media elektronik. Pada intinya, sistem ini memungkinkan transaksi produk dan jasa secara daring melalui berbagai jaringan komputer. Metode ini tidak sekadar mentransfer cara berbisnis konvensional ke ranah digital, melainkan menciptakan ekosistem perdagangan yang lebih fleksibel, efisien, dan tanpa batasan geografis. Keunggulan utama sistem pemasaran elektronik terletak pada kemampuannya untuk menghubungkan penjual dan pembeli dalam ruang digital yang sama, memfasilitasi pertukaran barang dan jasa dengan cara yang lebih cepat, transparan, dan mudah diakses (Melisa et al., 2025).

Transaksi penjualan menjadi salah satu sumber data utama karena mencatat informasi tentang barang atau layanan yang dibeli, jumlah dan harga transaksi, serta informasi waktu dan lokasi. Data ini membantu dalam memahami tren penjualan, preferensi produk, dan pola pembelian pelanggan. Selain itu, data pelanggan berisi informasi demografis, perilaku pembelian, dan preferensi yang berguna untuk segmentasi pelanggan dan personalisasi pengalaman belanja. Data produk mencakup atribut produk, harga, stok, dan performa penjualan, yang dapat digunakan untuk menganalisis performa produk, merencanakan strategi penetapan harga, dan rekomendasi produk. Terakhir, data interaksi pengguna, seperti aktivitas browsing, klik, dan interaksi media sosial, memberikan wawasan tentang minat dan perilaku pengguna yang mendalam (Apriana & Yuliansyah, 2024).

2.2 Perilaku Konsumtif

Perilaku konsumtif merupakan perilaku pada setiap individu yang memiliki rasa keinginan yang kuat untuk membeli barang maupun jasa yang hanya mementingkan kepuasan semata tanpa mempertimbangkan kebutuhan dan kegunaan dari barang tersebut, yang pada akhirnya hal tersebut dinilai menjadi berlebihan (Nurhasanah, 2023). Perilaku konsumtif merupakan kecenderungan seseorang untuk membelanjakan uang secara berlebihan untuk barang atau jasa, sering kali disebabkan oleh keinginan emosional, status sosial, atau kebutuhan untuk memenuhi ekspektasi (Juniar alya, 2023) dalam (Saputra & Naufal Wala, 2024). Perilaku ini biasanya dipengaruhi oleh elemen eksternal (seperti pengaruh sosial, iklan, dan tren) dan internal (seperti emosi dan kepribadian).

Perilaku konsumen, khususnya pembelian impulsif (*impulsive buying*), menjadi salah satu perhatian utama dalam dunia pemasaran karena dapat secara langsung meningkatkan volume penjualan. Pembelian impulsif terjadi secara spontan tanpa perencanaan matang, dan sering kali dipengaruhi oleh faktor emosional, seperti dorongan sesaat, daya tarik visual, serta strategi promosi yang menggugah. Hal ini diperkuat oleh (Feni, 2024) dalam (Rohmawati & Widiyanto, 2025) yang menyebutkan bahwa perilaku ini muncul akibat dorongan tertentu yang memengaruhi tindakan konsumen tanpa mempertimbangkan fungsi, tujuan, maupun konsekuensi dari pembelian tersebut. Bagi para pelaku usaha, fenomena *impulsive buying* menjadi peluang besar untuk meningkatkan omzet penjualan.

2.3 Machine Learning Untuk Prediksi

Dalam konteks data mining, machine learning digunakan untuk mengekstrak pola dari data sehingga dapat menghasilkan prediksi/klasifikasi secara otomatis.

Data mining dipahami sebagai proses pencarian informasi yang berguna dari penyimpanan data berukuran besar, termasuk untuk menemukan pola baru yang bermanfaat (Studi et al., 2025). Prediksi perilaku konsumtif dalam penelitian ini termasuk ke dalam klasifikasi biner, karena target keluaran hanya terdiri dari dua kelas (misalnya konsumtif dan tidak konsumtif). Klasifikasi sendiri merupakan pekerjaan untuk menempatkan suatu objek data ke dalam kelas tertentu dari sejumlah kelas yang sudah ditentukan, sehingga sesuai digunakan ketika keluaran model berbentuk kategori.

Secara umum, tahapan pemodelan *machine learning* untuk prediksi dilakukan melalui *preprocessing*, *training*, dan *testing*. *Preprocessing* data merupakan proses penting yang bertujuan untuk membersihkan, mengubah format, dan mempersiapkan data agar lebih mudah dan akurat (Agung et al., 2023). Pada praktik penelitian klasifikasi, *preprocessing* juga sering mencakup proses integrasi data, pelabelan (jika diperlukan), transformasi, dan pembersihan pada tahap awal sebelum pemodelan dilakukan. Setelah data siap, dataset umumnya dibagi menjadi data latih (training set) untuk melatih model dan data uji (testing set) untuk menguji performa model.

2.4 Extreme Learning Machine (ELM)

Extreme Learning Machine (ELM) merupakan jenis jaringan saraf tiruan feedforward dengan satu lapisan tersembunyi (SLFN) yang dirancang untuk mengenali pola dalam data secara efisien. Dalam ELM, bobot input dan bias pada lapisan tersembunyi diinisialisasi secara acak dan tidak diperbarui selama pelatihan, sementara bobot keluaran dihitung secara analitis melalui operasi invers sederhana. Hal ini membuat proses pelatihan lebih cepat karena tidak memerlukan

backpropagation. Arsitektur ELM terdiri dari tiga lapisan utama: lapisan input yang menerima data, lapisan tersembunyi yang menerapkan fungsi aktivasi pada kombinasi bobot dan bias, serta lapisan keluaran yang menghasilkan prediksi akhir berdasarkan bobot keluaran yang telah dihitung. (Dewi et al., 2025)

Berikut merupakan tahapan-tahapan yang dilakukan dalam proses Training dan Testing data :

1. Proses training

Menginisialisasi untuk input weight dan bias yang diambil secara random. Menghitung matriks output hidden layer dengan persamaan berikut.

$$H_{\text{init}} = X_{\text{train}} \cdot W^T + b \quad (2.1)$$

Keterangan :

H_{init} : Hasil output dari hidden layer.

X_{train} : Matriks data input dari data training.

W^T : Transpose dari matriks bobot input.

b : Vektor bias.

Perhitungan fungsi aktivasi dari output hidden layer.

$$H = \frac{1}{1 + \exp(-H_{\text{init}})} \quad (2.2)$$

Keterangan:

H : Hasil fungsi aktivasi.

H_{init} : Nilai output dari hidden layer.

Moore–Penrose Inverse

$$H^+ = (H^T \cdot H)^{-1} \cdot H^T \quad (2.3)$$

Keterangan

H^+ : Hasil dari Moore–Penrose inverse.

$(H^T \cdot H)^{-1}$: Invers dari perkalian matriks H^T dan H .

H^T : Transpose dari matriks H (hasil fungsi aktivasi).

Menghitung nilai matriks output weight menggunakan persamaan berikut

$$\beta = H^+ \cdot Y \quad (2.4)$$

Keterangan

β : Matriks output weight.

H^+ : Moore–Penrose inverse dari matriks H .

Y : Vektor target yang telah dinormalisasi.

2. Proses testing

Nilai weight dan bias menggunakan nilai yang sama dengan proses training.

Perhitungan matriks output hidden layer menggunakan persamaan berikut.

$$H_{init} = X_{testingq} \cdot W^T + b \quad (2.5)$$

Keterangan

H_{init} : Hasil output dari hidden layer.

$X_{testingq}$: Matriks data input dari data testing.

W^T : Transpose dari matriks bobot input.

b : Vektor bias.

Perhitungan nilai fungsi aktivasi dari H_{init} dilakukan dengan cara yang sama seperti tercantum dalam persamaan klasifikasi elm pada tahap pelatihan.

Perhitungan Prediksi (Output Layer)

$$\hat{y} = H \cdot \beta \quad (2.6)$$

Keterangan

\hat{y} : Hasil dari output layer.

H : Fungsi aktivasi data testing.

β : Matriks bobot output hasil training.

2.5 Python

Python adalah bahasa pemrograman tingkat tinggi yang populer untuk analisis data dan pemodelan. Dikembangkan pada tahun 1990 oleh Guido van Rossum, Python telah menjadi alat yang populer di berbagai bidang, termasuk ilmu data, pemrosesan bahasa alami, dan pemodelan epidemiologi. Python memiliki sintaks yang sederhana dan mudah dipahami, sehingga membuatnya cocok untuk pemula dan pengguna yang berpengalaman. (Salim et al., 2022)

Dalam praktiknya, Python sering digunakan karena memudahkan pengguna bekerja lebih cepat dan lebih mudah mengintegrasikan sistem. Selain itu, Python dikenal memiliki sintaks yang sederhana dan mudah dipahami, sehingga lebih gampang dipelajari dan digunakan dalam analisis data. Dalam penelitian berbasis data, Python sering digunakan karena memiliki berbagai pustaka yang mendukung bidang data science dan machine learning. Salah satu library yang sering digunakan adalah scikit-learn, yaitu perpustakaan untuk machine learning di Python yang menawarkan berbagai alat untuk membangun model dan menganalisis data.

2.6 Google Colab

Colaboratory, atau “Colab” merupakan produk dari Google Research. Colab memungkinkan siapa saja menulis dan mengeksekusi kode python arbitrer melalui browser, dan sangat cocok untuk machine learning, analisis data, serta pendidikan.

Secara lebih teknis, Colab merupakan layanan notebook Jupyter yang dihosting dan dapat digunakan tanpa penyiapan, serta menyediakan akses gratis ke resource komputasi termasuk GPU.(Irfon & Soen, 2022)

Google Colab sering dipilih karena kemudahannya. Dalam kegiatan pelatihan Python, Colab disebutkan sebagai "editor" untuk menulis kode Python tanpa perlu menginstal aplikasi di perangkat yang digunakan, sehingga lebih praktis untuk pembelajaran maupun praktik pemrograman. Bahkan, Colab bisa diakses lewat perangkat yang lebih sederhana, seperti hp, sehingga memudahkan peserta untuk terus berlatih menulis kode. Hal ini juga sesuai dengan penggunaan di pelatihan Python berbasis Colab yang mengutamakan penggunaan Google Drive sebagai media penyimpanan dan langsung memulai pemrograman Python melalui Colab.

Dalam pelaksanaan pembelajaran atau pelatihan, Colab sering digunakan karena praktis, pengguna dapat menulis baris kode Python tanpa perlu menginstal aplikasi di komputer, bahkan bisa digunakan melalui perangkat seperti smartphone. Ini mempermudah dan mempercepat proses pembelajaran pemrograman, terutama bagi pemula. Selain itu, Colab mendukung pembelajaran dengan praktek langsung karena notebook menyediakan kode dan langkah-langkah kerja yang bisa dijalankan segera, sehingga memudahkan proses bimbingan dan latihan

2.7 Visual Studio Code

Visual Studio Code (VS Code) merupakan editor kode sumber yang gratis, ringan, dan dapat diperluas, sehingga banyak digunakan dalam pengembangan perangkat lunak modern karena mendukung berbagai bahasa pemrograman, ekosistem ekstensi yang luas, IntelliSense, debugging, linting, refactoring, serta integrasi Git dalam satu lingkungan kerja. Popularitasnya juga tercermin dalam

Stack Overflow Developer Survey 2022, yang menunjukkan bahwa VS Code menjadi IDE paling disukai/digunakan lintas responden, dengan 74,48% dari 71.010 responden menyebutnya sebagai lingkungan pengembangan yang mereka gunakan secara luas . Dalam konteks pembelajaran, penelitian (Murani et al., 2025) menunjukkan bahwa VS Code membantu mahasiswa pemula meningkatkan pemahaman konseptual, keterampilan menulis dan men-debug kode, serta efisiensi pengelolaan proyek melalui fitur seperti IntelliSense, debugging terintegrasi, manajemen file, dan integrasi Git; meskipun demikian, penelitian tersebut juga menekankan perlunya pelatihan terstruktur karena sebagian pengguna baru masih mengalami kesulitan dalam konfigurasi ekstensi dan pemanfaatan fitur tingkat lanjut.

2.8 Penelitian Terdahulu

Berikut adalah tabel yang berisi penelitian terdahulu yang menjadi acuan dalam penelitian ini :

Tabel 2.1 Tabel Penelitian Terdahulu

NO	Judul dan peneliti	Pembahasan	Metode	Kelebihan atau Kekurangan
1	Prediksi Tren Penggunaan Electronic Money (E-Money) di Indonesia menggunakan pendekatan Extreme Learning Machines.(Devita Rizqi et al., 2025)	membahas peramalan (forecasting) nilai transaksi uang elektronik (e-money) di Indonesia untuk melihat tren pertumbuhan ke depan. Penulis memakai data transaksi e-money periode 2021–2024 dari Bank Indonesia dan menyajikan hasil proyeksi yang meningkat stabil setiap bulan.	Extreme Learning Machine (ELM)	Kelebihan: Cepat dan sederhana untuk dilatih: ELM tidak butuh iterasi panjang seperti pelatihan NN konvensional (karena bobot output dihitung analitis). Kekurangan: Sensitif pada bobot acak ELM: karena itu mereka perlu 20 kali

NO	Judul dan peneliti	Pembahasan	Metode	Kelebihan atau Kekurangan
				pengulangan dan ambil median ini indikasi hasil bisa berubah antar-run tanpa stabilisasi.
2	<i>Analisis Pengaruh Kemudahan PayLater pada Aplikasi Shopee dan Promo Diskon Produk terhadap</i>	Penelitian ini membahas pengaruh kemudahan transaksi Shopee PayLater dan promo diskon produk terhadap perilaku pembelian impulsif (impulse buying) pada pengguna Shopee di DKI Jakarta	Jenis penelitian: deskriptif dengan pendekatan kuantitatif.	Kelebihan: Metode kuantitatif + regresi linier berganda cocok untuk menguji pengaruh 2 variabel independen terhadap 1

NO	Judul dan peneliti	Pembahasan	Metode	Kelebihan atau Kekurangan
	<p><i>Perilaku Pembelian Impulsif (Studi pada Pengguna Shopee di DKI Jakarta)</i></p>			<p>variabel dependen secara parsial dan simultan. Kekurangan: Generalisasi terbatas: studi hanya pada DKI Jakarta dan pengguna Shopee (serta PayLater), jadi hasil belum tentu sama untuk wilayah/marketplace lain.</p>
3	<p>Peramalan Produksi Padi</p>	<p>Peramalan produksi padi di Kabupaten Bangkalan memakai data historis</p>	<p>Deteksi outlier Local Outlier Factor (LOF)</p>	<p>Kelebihan: ELM cepat, LOF</p>

NO	Judul dan peneliti	Pembahasan	Metode	Kelebihan atau Kekurangan
	Menggunkan Extreme Learning Machine (ELM) Dengan Deteksi Outlier.(Wanda et al., 2025)	(1997–2022), dengan tujuan meningkatkan akurasi prediksi	normalisasi pemodelan Extreme Learning Machine(ELM) evaluasi pakai MAPE (dibandingkan ELM vs ELM+LOF)	membantu mengurangi pengaruh data anomali; akurasi (MAPE) membaik. Kekurangan: Peningkatan MAPE uji kecil; variabel input terbatas; pembanding model lain masih minim.
4	Analisis Dampak Penggunaan	Jurnal ini menganalisis dampak/pengaruh penggunaan e-wallet	Pendekatan: kuantitatif,	Kelebihan: Topik sanga relevan, ada

NO	Judul dan peneliti	Pembahasan	Metode	Kelebihan atau Kekurangan
	E-Wallet terhadap Perilaku Konsumtif di Kalangan Mahasiswa	terhadap perilaku konsumtif mahasiswa misalnya karena kemudahan akses dan promo yang mendorong mahasiswa lebih sering berbelanja.	desain deskriptif.	data primer dan data sekunder, hasil deskriptif cukup jelas Kekurangan: Sampel kecil (52 responden)
5	Prediksi Harga Kelapa Sawit Menggunakan Metode Extreme Learning Machine.(Hariansyah et al., 2024)	prediksi harga kelapa sawit (di KUD Bangun Desa) karena harga yang naik-turun tiap bulan membuat pendapatan petani tidak stabil, sehingga perlu prediksi untuk membantu perencanaan.	Extreme Learning Machine (ELM)	Kelebihan: Metode ELM bisa diimplementasikan untuk prediksi dan penulis menyimpulkan ELM punya kemampuan

NO	Judul dan peneliti	Pembahasan	Metode	Kelebihan atau Kekurangan
				generalisasi yang baik pada proses training-testing. Kekurangan: Input masih terbatas pada pola time series rotasi sebelumnya

2.9 ANALISIS GAP

Berdasarkan penelitian terdahulu, masih ada beberapa celah. Pertama, penelitian tentang perilaku konsumtif/impulsif di *e-commerce* biasanya masih menggunakan survei/kuesioner, sehingga hasilnya bergantung pada jawaban responden dan cenderung subjektif. Kedua, metode *Extreme Learning Machine* (ELM) lebih sering digunakan untuk memprediksi tren/angka total (misalnya nilai transaksi, produksi, atau harga) dengan input yang terbatas, bukan untuk memprediksi perilaku konsumtif berdasarkan pola belanja pengguna. Ketiga, beberapa penelitian masih memakai evaluasi yang sederhana, padahal ELM bisa

menghasilkan output yang berbeda karena bobot awal yang acak sehingga perlu pengujian yang lebih kuat agar hasilnya stabil.

Karena itu, penelitian ini bertujuan mengisi celah tersebut dengan membangun model prediksi perilaku konsumtif berbasis pola transaksi e-commerce menggunakan ELM. Penelitian ini menggunakan data sekunder yang diambil dari Kaggle (bukan penyebaran kuesioner), dengan variabel tanggal transaksi (*Date*), jenis kelamin (*Gender*), usia (*Age*), kategori produk (*Product Category*), jumlah barang (*Quantity*), harga per unit (*Price per Unit*), dan total belanja (*Total Amount*). Variabel-variabel ini dapat digunakan untuk melihat pola belanja seperti seberapa sering transaksi, besarnya pengeluaran, dan kategori yang paling sering dibeli, sehingga prediksi yang dibuat lebih objektif dan bisa diuji kestabilannya untuk digunakan pada data baru.

BAB III

METODOLOGI PENELITIAN

3.1 Jenis Penelitian

Penelitian ini merupakan jenis penelitian kuantitatif yang menggunakan pendekatan eksperimen berbasis komputasi. Penelitian kuantitatif dipilih karena menggunakan data berupa angka dan kategori yang dapat diukur secara objektif, seperti tanggal transaksi, usia, jenis kelamin, kategori produk, jumlah pembelian, harga satuan, dan total belanja. Penelitian menggunakan pendekatan eksperimen komputasi karena dilakukan melalui beberapa tahap pemrosesan data dan pengujian model dengan algoritma *machine learning*, sehingga hasil yang diperoleh berasal dari proses pelatihan, pengujian, serta evaluasi kinerja model yang diukur secara teratur.

Dataset yang digunakan awalnya tidak memiliki label, baik konsumtif maupun tidak konsumtif. Oleh karena itu, penelitian ini melakukan penentuan label secara operasional berdasarkan indikator transaksi yang ada, seperti *Total Amount*. Setelah label terbentuk, penelitian dilanjutkan menggunakan supervised learning dengan tugas klasifikasi biner, yaitu memprediksi kelas konsumtif (1) dan tidak konsumtif (0) menggunakan algoritma *Extreme Learning Machine* (ELM). Evaluasi kemampuan model dilakukan menggunakan data uji dan mengukur dengan beberapa ukuran seperti akurasi, presisi, recall, serta skor F1.

3.2 Analisis Alat Penelitian

Pada proses analisa ini dipaparkan alat yang dibutuhkan, pada proses observasi ini terbagi menjadi dua bagian yaitu perangkat keras, (*hardware*) serta perangkat lunak (*software*), diantaranya :

3.2.1 Perangkat Keras (*Hardware*)

Perangkat keras yang digunakan pada penelitian ini yaitu :

1. Laptop

Menggunakan laptop asus dengan spesifikasi sebagai berikut:

Tabel 3.1 Tabel Spesifikasi Laptop

Komponen	Spesifikasi
Model sistem	Vivobook Go E1404FA
Prosesor	AMD Ryzen 5 7520U
Storage	512 GB
Sistem operasi	Windows 11
Dimensi	32.55 × 21.39 × 1.79 cm
Memori	16 GB

3.2.2 Perangkat Lunak (*Software*)

Perangkat lunak yang digunakan dalam penelitian ini yaitu:

Tabel 3.2 Tabel Perangkat lunak (Software)

Jenis perangkat lunak	Nama perangkat lunak
Sistem operasi	Windows 11
Lingkungan/platfrom pemrograman (cloud)	Google colaboratory(google colab)
Bahasa pemrograman	pyhton

3.3 Objek Penelitian dan Sumber Data

Objek pada penelitian ini adalah data transaksi e-commerce yang digunakan untuk memprediksi perilaku konsumtif. Data yang digunakan merupakan data sekunder yang diperoleh dari platform Kaggle dalam bentuk berkas CSV. Dataset tersebut berisi 1.000 baris data transaksi dengan atribut Date, Gender, Age, Product Category, Quantity, Price per Unit, dan Total Amount. Selain itu, terdapat kolom Unnamed: 0 yang hanya berfungsi sebagai indeks sehingga tidak digunakan dalam proses analisis.

Dataset yang digunakan dalam penelitian ini mencakup transaksi pembelian pada tiga kategori produk, yaitu Electronics, Clothing, dan Beauty. Ketiga kategori tersebut menjadi ruang lingkup penelitian dalam menganalisis perilaku konsumtif berdasarkan pola transaksi e-commerce.

Pengumpulan data dilakukan melalui beberapa tahapan, yaitu mengunduh dataset dari Kaggle, memeriksa struktur data, mengidentifikasi atribut yang relevan, serta menyimpan dataset dalam format CSV untuk selanjutnya diolah menggunakan Python. Data yang telah diperoleh kemudian diperiksa kualitasnya untuk memastikan bahwa data dapat digunakan pada tahap preprocessing, ekstraksi fitur, pelatihan model, dan evaluasi.

Pada dataset yang digunakan tidak tersedia variabel target bawaan. Oleh karena itu, penelitian ini membentuk label secara operasional untuk menghasilkan kelas biner, yaitu 1 (konsumtif) dan 0 (tidak konsumtif). Label ditentukan berdasarkan nilai Total Amount dengan menggunakan ambang persentil ke-75. Berdasarkan perhitungan pada dataset, nilai persentil ke-75 dari Total Amount adalah 900, sehingga transaksi dengan nilai Total Amount ≥ 900 dikategorikan sebagai

konsumtif (1), sedangkan transaksi dengan nilai Total Amount < 900 dikategorikan sebagai tidak konsumtif (0). Pendekatan ini digunakan untuk mengidentifikasi transaksi dengan nominal belanja yang relatif tinggi dibandingkan sebagian besar transaksi lainnya.

Berikut adalah tabel dataset yang menyajikan informasi struktur data yang digunakan dalam penelitian ini :

Tabel 3.3 Tabel Dataset

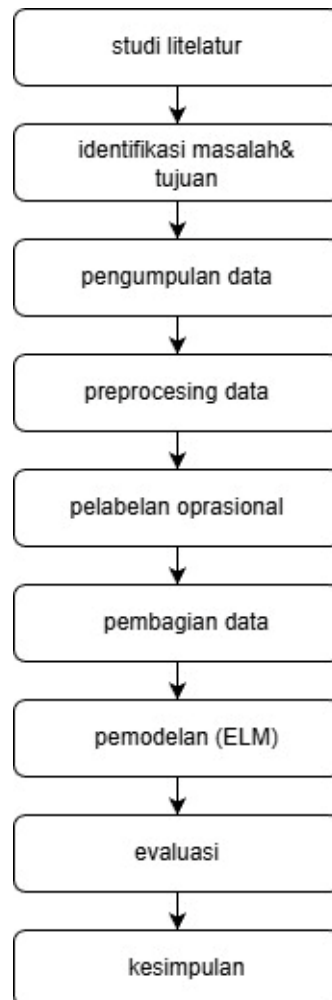
No	Date	Gender	Age	Product Category	Quantity	Price Per Unit	Total Amount
1	11/24/2023	Male	34	Beauty	3	50	150
2	2/27/2023	Female	26	Clothing	2	500	1000
3	1/13/2023	Male	50	Electronics	1	30	30
...
1000	4/12/2023	male		Electronics	4	30	120

Dataset yang digunakan pada penelitian ini tersimpan dalam berkas Sales Dataset.csv dan memiliki total 1.000 baris data dengan 8 atribut/kolom, yaitu Unnamed: 0, Date, Gender, Age, Product Category, Quantity, Price per Unit, dan Total Amount. Kolom Unnamed: 0 hanya berfungsi sebagai indeks/nomor baris sehingga tidak digunakan sebagai variabel penelitian. Pada dataset ini tidak tersedia variabel target bawaan, sehingga variabel target dibentuk secara operasional menjadi label perilaku konsumtif dengan dua kelas, yaitu 1 (konsumtif) dan 0 (tidak

konsumtif) berdasarkan indikator transaksi (misalnya Total Amount dan/atau Quantity) sesuai threshold yang ditetapkan dalam penelitian.

3.4 Alur Penelitian

Berikut adalah diagram alur penelitian yang menjelaskan tahapan penelitian dari awal hingga akhir.



Gambar 3.1 Diagram Alur Penelitian

Alur penelitian dimulai dari studi literatur terkait e-commerce, perilaku konsumtif, klasifikasi data, dan konsep ELM. Setelah itu dilakukan identifikasi masalah dan penentuan tujuan, yaitu membangun model yang mampu memprediksi perilaku konsumtif berdasarkan pola transaksi. Tahap berikutnya

adalah pengumpulan dataset transaksi e-commerce dari Kaggle sesuai variabel yang tersedia. Selanjutnya dilakukan preprocessing (pembersihan data, penanganan missing value, encoding variabel kategorikal, serta normalisasi/standarisasi bila diperlukan) dan pembentukan label operasional konsumtif/tidak konsumtif. Data kemudian dibagi menjadi latih dan uji, model ELM dilatih dan diuji, lalu hasilnya dievaluasi menggunakan confusion matrix dan metrik akurasi, precision, recall, serta F1-score sampai diperoleh kesimpulan penelitian.

3.5 Proses Pembuatan Model

Proses pembuatan model pada penelitian ini bertujuan untuk memprediksi perilaku konsumtif (0/1) berdasarkan pola transaksi e-commerce menggunakan Extreme Learning Machine (ELM). Data transaksi dipreprocessing (cleaning, missing value, encoding, normalisasi bila perlu), kemudian diberi label konsumtif/tidak konsumtif sesuai threshold. Data dibagi menjadi train-test, lalu model ELM dibangun dengan menentukan jumlah hidden neuron dan fungsi aktivasi, kemudian diuji dan dievaluasi menggunakan confusion matrix serta metrik accuracy, precision, recall, dan F1-score.

3.5.1 Variabel Penelitian

1. Variabel Bebas (Independen / X)
 - a. Date (tanggal transaksi)
 - b. Gender (jenis kelamin)
 - c. Age (usia)
 - d. Product category (kategori produk)
 - e. Quantity (jumlah barang)

- f. Price per unit (harga satuan)
- 2. Variabel Terikat (Dependen / Y)
 - a. Perilaku konsumtif (label biner)
 - 1. 1 = Konsumtif
 - 2. 0 = Tidak konsumtif

Label dibentuk berdasarkan nilai Total Amount dengan menggunakan ambang persentil ke-75. Transaksi dengan nilai Total Amount ≥ 900 dikategorikan sebagai konsumtif, sedangkan transaksi dengan nilai Total Amount < 900 dikategorikan sebagai tidak konsumtif. Karena Total Amount digunakan dalam pembentukan label, variabel tersebut tidak digunakan sebagai fitur input model agar tidak menimbulkan bias pada hasil klasifikasi.

3.5.2 Preprocessing Data

Preprocessing dilakukan untuk memastikan data transaksi e-commerce bersih, konsisten, dan siap dipakai pada pemodelan Extreme Learning Machine (ELM) untuk klasifikasi konsumtif (0/1). Langkah preprocessing yang disesuaikan dengan kondisi dataset :

1. Standarisasi nama kolom dan nilai kategorikal

Pada data set , header diawali dan diakhiri koma sehingga muncul kolom tanpa nama (Unnamed: 0 dan Unnamed: 8). Karena itu dilakukan:

- a. rapikan header kolom (trim/strip jika ada spasi) dan identifikasi kolom “Unnamed”
- b. rapikan nilai kategori pada Gender dan Product Category (strip whitespace, samakan penulisan)

2. Pembersihan data dan pemeriksaan missing value/duplikasi

Dataset diperiksa apakah ada nilai kosong (missing) dan data duplikat. Pada dataset ini tidak ditemukan missing value maupun duplikasi, namun pengecekan tetap dilakukan sebagai prosedur standar.

3. Penanganan nilai tidak wajar dan validasi konsistensi transaksi

Dilakukan pengecekan nilai tidak logis seperti $\text{Quantity} \leq 0$, $\text{Price per Unit} \leq 0$, atau $\text{Total Amount} \leq 0$. Selain itu dicek konsistensi transaksi:

$$\text{Total Amount} = \text{Quantity} \times \text{Price per Unit}.$$

Pada dataset ini nilai transaksi konsisten, sehingga tidak perlu koreksi.

4. Seleksi fitur (drop kolom yang tidak relevan).

a. Unnamed: 0 dihapus karena hanya indeks/nomor baris

b. Unnamed: 8 dihapus karena nama kolom tidak tersedia (tidak terdefinisi) dan tidak termasuk fitur utama penelitian

Setelah itu fitur yang dipakai sebagai X adalah: Date, Gender, Age, Product Category, Quantity, Price per Unit.

5. Transformasi kolom Date menjadi numerik.

Karena ELM membutuhkan input numerik, kolom Date dikonversi ke format tanggal (datetime), lalu diubah menjadi fitur numerik (misalnya bulan, hari, day-of-week atau format ordinal) agar bisa diproses model.

6. Encoding variabel kategorikal.

Kolom Gender dan Product Category (kategorikal) diubah menjadi numerik, umumnya menggunakan One-Hot Encoding agar representasi kategori tidak bias urutan angka.

7. Normalisasi/Standarisasi fitur numerik.

Skala fitur berbeda (misalnya Total Amount lebih besar dibanding Age).

Agar pelatihan ELM lebih stabil, fitur numerik seperti Age, Quantity, Price per Unit, Total Amount dilakukan normalisasi/standarisasi dalam pipeline.

3.5.3 Pembagian Data Latih dan Data Uji

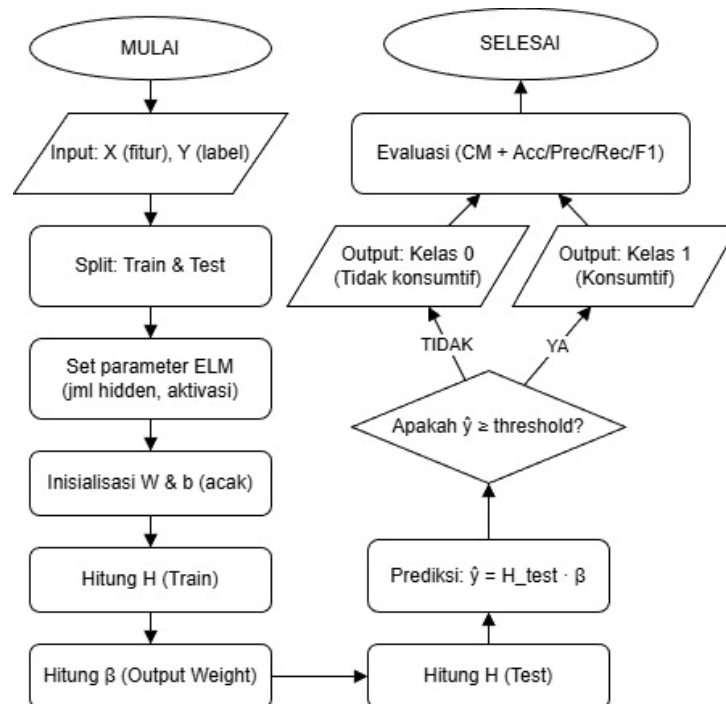
Dataset dibagi menjadi:

1. data latih (training) untuk melatih model
2. data uji (testing) untuk menguji kemampuan generalisasi model

Mengikuti praktik pada referensi, pembagian dapat menggunakan 80% training dan 20% testing, serta memakai splitting agar proporsi kelas pada train dan test tetap seimbang.

3.5.4 Implementasi Model *Extreme Learning Machine* (ELM)

Berikut adalah flowchart Extreme Learning Machine :



Gambar 3.2 Flowchart Extreme Learning Machine(ELM)

Flowchart penelitian ini menggambarkan tahapan proses pemodelan menggunakan Extreme Learning Machine (ELM) untuk mengklasifikasikan data ke dalam dua kelas (0/1). Proses dimulai dari input data berupa X (fitur) dan Y (label), kemudian dataset dibagi menjadi data latih (train) dan data uji (test) agar model dapat dilatih dan diuji secara objektif. Setelah itu ditetapkan parameter ELM seperti jumlah neuron pada hidden layer dan fungsi aktivasi yang digunakan. Tahap berikutnya adalah inisialisasi bobot (W) dan bias (b) secara acak, yang menjadi ciri khas ELM. Selanjutnya dihitung keluaran hidden layer untuk data latih sehingga terbentuk matriks H (train), lalu dari matriks tersebut dihitung bobot keluaran β (output weight) secara matematis untuk membentuk model. Setelah model terbentuk, dihitung H (test) untuk data uji dan dilakukan prediksi menggunakan persamaan $\hat{y} = H_{\text{test}} \cdot \beta$. Nilai keluaran \hat{y} kemudian dikonversi menjadi kelas berdasarkan aturan keputusan, yaitu jika $\hat{y} \geq \text{threshold}$ maka hasilnya kelas 1, sedangkan jika $\hat{y} < \text{threshold}$ maka hasilnya kelas 0. Terakhir, hasil prediksi dibandingkan dengan label sebenarnya dan dievaluasi menggunakan confusion matrix serta metrik akurasi, precision, recall, dan F1-score untuk mengetahui kinerja model, kemudian proses diakhiri.

3.5.5 Evaluasi Kinerja model

Tahap evaluasi sangat penting untuk mengetahui sejauh mana model dapat memprediksi dengan benar. Evaluasi dilakukan menggunakan confusion matrix, yang membandingkan hasil prediksi model dengan data yang sebenarnya. Metrik utama yang sering digunakan untuk evaluasi adalah akurasi, presisi, recall dan F1-Score.

1. Akurasi (Accuracy)

Akurasi mengukur seberapa banyak prediksi yang benar dibandingkan dengan total keseluruhan data. Ini dihitung dengan rumus :

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.1)$$

Diketahui :

- a. TP = True Positive (prediksi positif yang benar)
- b. TN = True Negative (prediksi negative yang benar)
- c. FP = False Positive (prediksi positif yang salah)
- d. FN = False Negative (prediksi negative yang salah)

2. Presisi (Precision)

Presisi menunjukkan seberapa akurat prediksi positif dari model. Artinya, dari semua data yang diprediksi sebagai positif, berapa persen yang benar-benar positif. Rumusnya:

$$Precision = \frac{TP}{TP + FP} \quad (3.2)$$

3. Recall

Recall mengukur seberapa baik model dalam menemukan semua data yang benar-benar positif. Rumusnya :

$$Recall = (TP)/(TP + FN) \quad (3.3)$$

4. F1-Score

Fokus utama dalam penelitian ini adalah pada metrik F1-score, karena F1-score memberikan penilaian yang seimbang antara presisi dan recall. Presisi mengukur berapa banyak prediksi positif yang benar, sedangkan

recall mengukur berapa banyak data positif yang berhasil teridentifikasi.

Rumus F1-score adalah :

$$F1 - Score = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (3.4)$$

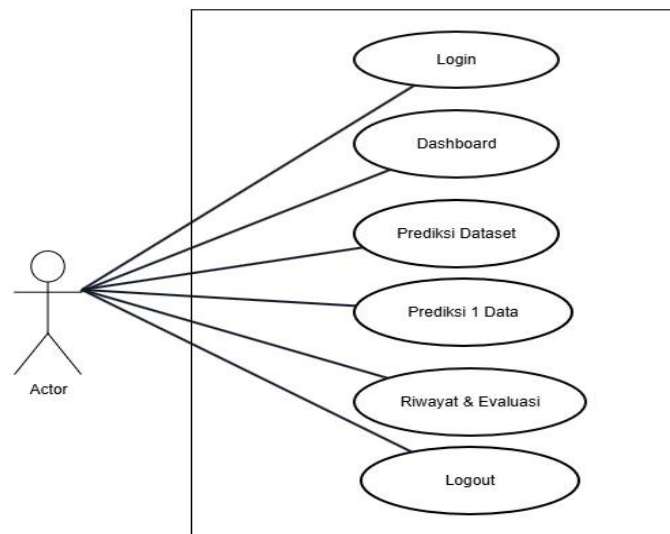
F1-score sangat berguna dalam kondisi data tidak seimbang, di mana akurasi bisa menyesatkan.

3.6 Pemodelan dan Perancangan sistem

Pemodelan dan perancangan sistem web pada penelitian ini bertujuan untuk mengimplementasikan model klasifikasi perilaku konsumtif berdasarkan pola transaksi e-commerce ke dalam aplikasi yang mudah digunakan oleh pengguna. Sistem dirancang menggunakan Python Streamlit karena mampu mendukung pembuatan antarmuka web secara cepat, sederhana, dan sesuai untuk kebutuhan prototipe penelitian. Sistem ini menyediakan beberapa fitur utama, yaitu login pengguna, prediksi dataset melalui unggah file CSV, prediksi satu data transaksi melalui input manual, tampilan hasil prediksi konsumtif atau tidak konsumtif, riwayat hasil prediksi, serta evaluasi model Extreme Learning Machine (ELM).

3.6.1 Use Case Diagram

Berikut adalah use case diagram yang menggambarkan aktivitas user dalam menggunakan sistem web prediksi perilaku konsumtif, mulai dari login, melakukan prediksi, melihat riwayat, melihat evaluasi model, hingga logout.



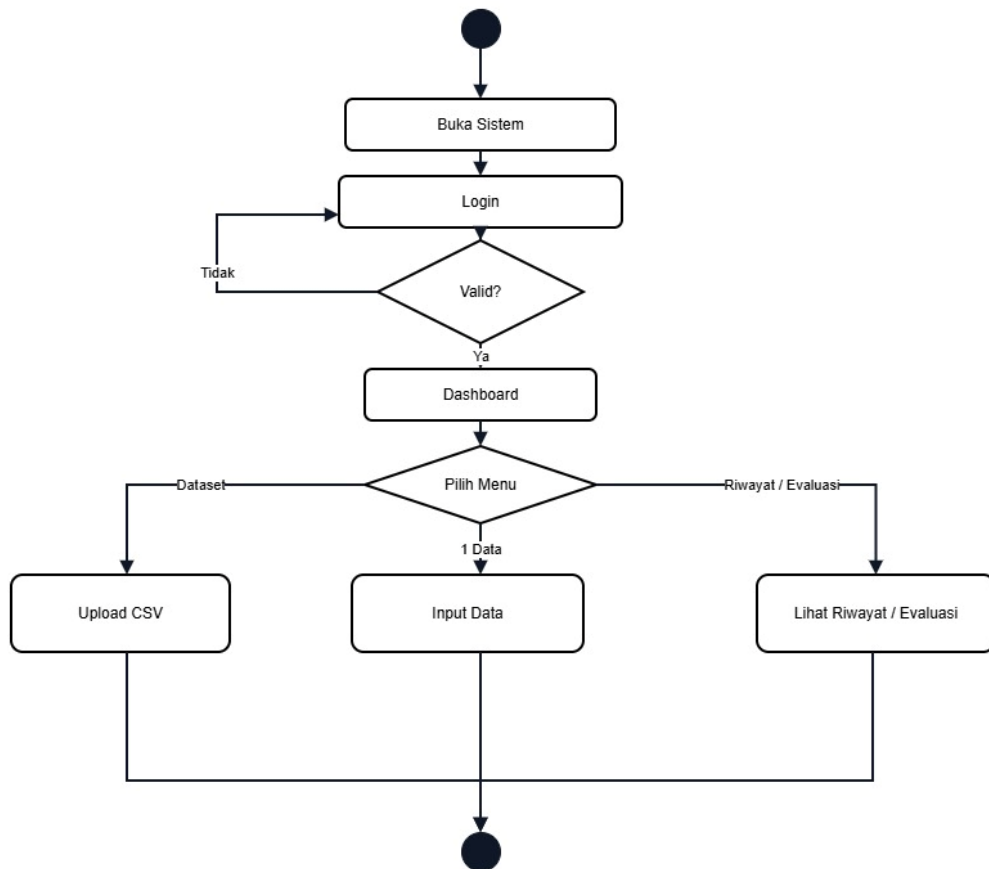
Gambar 3.3 Use Case Diagram

Use case diagram tersebut menggambarkan hubungan antara user dengan sistem web prediksi perilaku konsumtif. User berperan sebagai aktor utama yang dapat mengakses beberapa fitur dalam sistem, yaitu login, melihat dashboard, melakukan prediksi dataset, melakukan prediksi 1 data, melihat riwayat dan evaluasi, serta melakukan logout.

Pada fitur login, user masuk ke sistem menggunakan akun yang tersedia. Setelah berhasil login, user dapat melihat halaman dashboard sebagai halaman utama. User juga dapat melakukan prediksi dataset dengan mengunggah file CSV, atau melakukan prediksi 1 data dengan mengisi data transaksi secara manual. Hasil prediksi kemudian dapat dilihat pada menu riwayat dan evaluasi, sedangkan fitur logout digunakan untuk keluar dari sistem.

3.6.2 Activity Diagram

Berikut adalah activity diagram yang menggambarkan alur kerja sistem, mulai dari login, pemilihan menu, proses prediksi, hingga menampilkan hasil prediksi dan evaluasi model.



Gambar 3.4 Activity Diagram

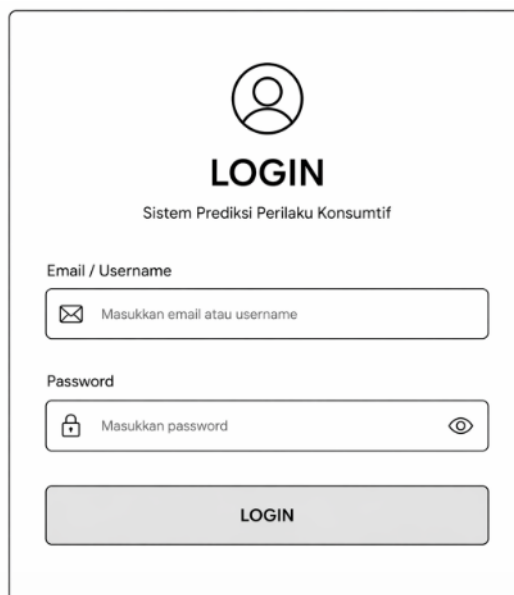
Activity diagram tersebut menggambarkan alur kerja sistem web prediksi perilaku konsumtif berdasarkan pola transaksi e-commerce. Proses dimulai ketika user membuka sistem dan melakukan login dengan memasukkan username serta password. Sistem kemudian melakukan validasi terhadap data login tersebut. Jika login tidak valid, user akan diarahkan kembali ke halaman login untuk mengisi data yang benar. Jika login valid, sistem akan menampilkan halaman dashboard sebagai halaman utama. Pada halaman dashboard, user dapat memilih menu yang tersedia, yaitu Dataset, 1 Data, dan Riwayat / Evaluasi. Menu Dataset digunakan untuk mengunggah file CSV agar dapat diproses oleh sistem, sedangkan menu 1 Data digunakan untuk memasukkan satu data transaksi secara manual. Menu Riwayat /

Evaluasi digunakan untuk melihat riwayat hasil prediksi dan hasil evaluasi model ELM. Setelah user memilih dan menjalankan salah satu menu, proses sistem akan selesai.

3.6.3 Perancangan Antarmuka Interface

Perancangan antarmuka (*User Interface*) pada penelitian ini dibuat untuk memudahkan pengguna dalam menjalankan proses klasifikasi perilaku konsumtif berdasarkan pola transaksi e-commerce menggunakan model Extreme Learning Machine (ELM). Antarmuka dirancang sederhana dan terstruktur dalam beberapa halaman utama, yaitu login, dashboard, prediksi dataset, prediksi 1 data, riwayat hasil, dan evaluasi model, sehingga pengguna dapat memahami alur sistem mulai dari memasukkan data transaksi, memproses prediksi, melihat hasil klasifikasi konsumtif atau tidak konsumtif, hingga melihat riwayat hasil dan evaluasi model.

- a. Halaman login digunakan sebagai halaman awal sebelum user masuk ke sistem. Pada halaman ini, user memasukkan email atau username dan password untuk mengakses fitur utama sistem.

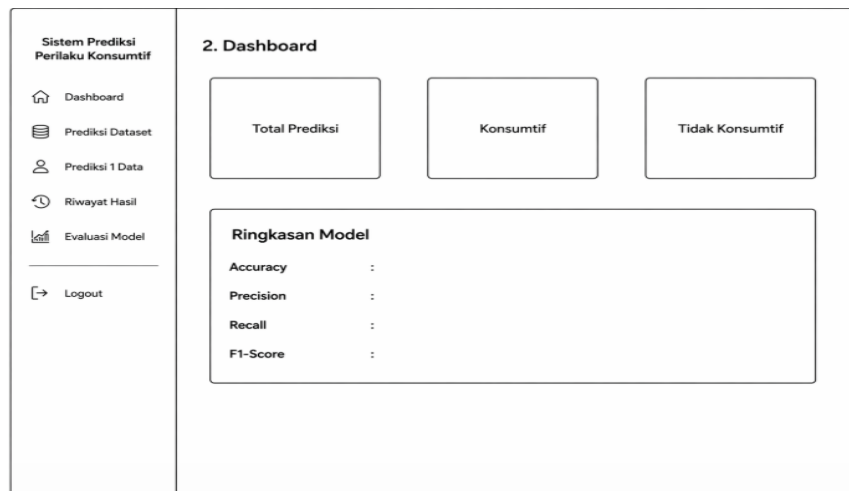


The image shows a login form with the following elements:

- A user icon at the top center.
- The word "LOGIN" in bold, uppercase letters.
- The subtitle "Sistem Prediksi Perilaku Konsumtif" below the title.
- A label "Email / Username" above a text input field containing the placeholder "Masukkan email atau username" and an envelope icon.
- A label "Password" above a text input field containing the placeholder "Masukkan password", a lock icon, and an eye icon for visibility toggle.
- A large, light gray button labeled "LOGIN" at the bottom.

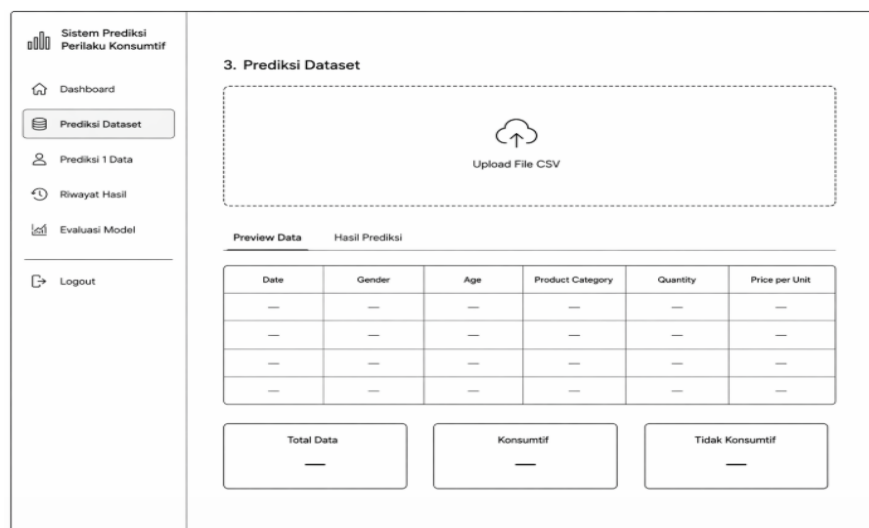
Gambar 3.5 Rancangan Halaman Login

- b. Halaman dashboard menampilkan ringkasan hasil prediksi, seperti total prediksi, jumlah konsumtif, dan jumlah tidak konsumtif. Selain itu, halaman ini juga menampilkan ringkasan evaluasi model ELM berupa accuracy, precision, recall, dan F1-score.



Gambar 3.6 Rancangan Halaman Dashboard

- c. Halaman prediksi dataset digunakan untuk mengunggah file CSV transaksi e-commerce. Sistem akan menampilkan preview data dan hasil prediksi dari dataset yang diunggah.



Gambar 3.7 Rancangan Prediksi Dataset

- d. Halaman prediksi 1 data digunakan untuk memasukkan satu data transaksi secara manual. Setelah data diinput, sistem akan menampilkan hasil klasifikasi berupa konsumtif atau tidak konsumtif.

Sistem Prediksi Perilaku Konsumtif

Dashboard

Prediksi Dataset

Prediksi 1 Data

Riwayat Hasil

Evaluasi Model

Logout

4. Prediksi 1 Data

Input Data

Date
dd/mm/yyyy

Gender
▼

Age

Product Category
▼

Quantity

Price per Unit

Proses Prediksi

Hasil Prediksi

Ringkasan Probabilitas

Kelas	Probabilitas
Konsumtif	-
Tidak Konsumtif	-

Hasil Prediksi

KONSUMTIF / TIDAK KONSUMTIF

Gambar 3.8 Rancangan prediksi 1 data

- e. Halaman riwayat hasil digunakan untuk menampilkan daftar hasil prediksi yang pernah dilakukan oleh user, baik dari prediksi dataset maupun prediksi satu data.

Sistem Prediksi Perilaku Konsumtif		5. Riwayat Hasil					
Dashboard		Tanggal	Jenis Input	Jumlah Data	Hasil	Konsumtif	Tidak Konsumtif
Prediksi Dataset							
Prediksi 1 Data							
Riwayat Hasil							
Evaluasi Model							
Logout							

Gambar 3.9 Rancangan Riwayat Hasil Prediksi

- f. Halaman evaluasi model menampilkan hasil evaluasi model ELM, seperti accuracy, precision, recall, F1-score, confusion matrix, dan distribusi kelas data uji.

Sistem Prediksi Perilaku Konsumtif		6. Evaluasi Model												
Dashboard		Accuracy	Precision	Recall	F1-Score									
Prediksi Dataset		-	-	-	-									
Prediksi 1 Data		Confusion Matrix												
Riwayat Hasil		<table border="1"> <thead> <tr> <th></th> <th>Konsumtif</th> <th>Tidak Konsumtif</th> </tr> </thead> <tbody> <tr> <th>Konsumtif</th> <td>-</td> <td>-</td> </tr> <tr> <th>Tidak Konsumtif</th> <td>-</td> <td>-</td> </tr> </tbody> </table>					Konsumtif	Tidak Konsumtif	Konsumtif	-	-	Tidak Konsumtif	-	-
	Konsumtif	Tidak Konsumtif												
Konsumtif	-	-												
Tidak Konsumtif	-	-												
Evaluasi Model		Distribusi Kelas Data Uji												
Logout		<table border="1"> <thead> <tr> <th>Kelas</th> <th>Jumlah</th> </tr> </thead> <tbody> <tr> <td>Konsumtif</td> <td>-</td> </tr> <tr> <td>Tidak Konsumtif</td> <td>-</td> </tr> </tbody> </table>				Kelas	Jumlah	Konsumtif	-	Tidak Konsumtif	-			
Kelas	Jumlah													
Konsumtif	-													
Tidak Konsumtif	-													

Gambar 3.10 Rancangan Hasil Evaluasi Model

BAB IV

HASIL DAN PEMBAHASAN

4.1 Hasil Penelitian

4.1.1 Gambaran Umum Dataset

Dataset yang digunakan pada penelitian ini adalah dataset transaksi e-commerce yang diperoleh dari Kaggle dalam format CSV. Sesuai rancangan penelitian pada proposal, dataset memuat 1.000 baris data transaksi dengan atribut Date, Gender, Age, Product Category, Quantity, Price per Unit, dan Total Amount. Penelitian ini berfokus pada tiga kategori produk, yaitu Electronics, Clothing, dan Beauty. Karena penelitian bertujuan untuk memprediksi perilaku konsumtif berdasarkan pola transaksi, maka data transaksi tersebut digunakan sebagai dasar untuk membangun model klasifikasi menggunakan algoritma Extreme Learning Machine (ELM).

Pada dataset ini tidak tersedia variabel target bawaan. Oleh karena itu, variabel target dibentuk secara operasional menjadi dua kelas, yaitu konsumtif (1) dan tidak konsumtif (0). Penetapan label dilakukan berdasarkan nilai Total Amount dengan ambang persentil ke-75, yaitu 900. Dengan demikian, transaksi dengan nilai Total Amount ≥ 900 dikategorikan sebagai konsumtif, sedangkan transaksi dengan nilai Total Amount < 900 dikategorikan sebagai tidak konsumtif. Pendekatan ini dipilih agar proses klasifikasi tetap objektif dan sesuai dengan indikator transaksi yang tersedia.

Sesuai skema pembagian data 80% : 20%, dataset dibagi menjadi data latihan sebanyak 800 data dan data uji sebanyak 200 data. Hasil pengujian pada data uji menunjukkan bahwa terdapat 147 data kelas tidak konsumtif dan 53 data kelas

konsumtif. Komposisi ini menunjukkan bahwa kelas tidak konsumtif lebih dominan dibandingkan kelas konsumtif, sehingga evaluasi model tidak hanya dilihat dari akurasi, tetapi juga dari precision, recall, dan F1-score.

Tabel 4.1 Ringkasan Kondisi Dataset

Komponen	Hasil
Jumlah baris data	1.000
Jumlah atribut awal	8 atribut
Fitur input model	6 fitur
Variabel target	Label perilaku konsumtif (0/1)
Sumber data	Kaggle
Kategori produk	Electronics, Clothing, Beauty
Threshold pelabelan	Total Amount \geq 900
Skema pembagian data	80% data latih dan 20% data uji

Tabel 4.2 Variabel yang Digunakan dalam Pemodelan

No	Variabel	Peran	Keterangan
1	Date	Fitur input	Tanggal transaksi yang diubah ke bentuk numerik
2	Gender	Fitur input	Jenis kelamin pelanggan, diubah melalui encoding
3	Age	Fitur input	Usia pelanggan
4	Product Category	Fitur input	Kategori produk: Electronics, Clothing, Beauty
5	Quantity	Fitur input	Jumlah barang yang dibeli
6	Price per Unit	Fitur input	Harga satuan barang
7	Total Amount	Dasar label	Digunakan untuk pembentukan label, tidak dipakai sebagai fitur input
8	Label konsumtif	Target	1 = konsumtif, 0 = tidak konsumtif

4.1.2 Hasil Preprocessing Data

Tahap preprocessing dilakukan untuk memastikan bahwa data transaksi e-commerce berada dalam kondisi bersih, konsisten, dan siap digunakan pada proses pemodelan ELM. Langkah pertama adalah merapikan nama kolom dan menghapus kolom yang tidak relevan, seperti kolom indeks. Setelah itu dilakukan pemeriksaan missing value dan duplikasi data. Berdasarkan hasil pemeriksaan, dataset tidak menunjukkan missing value maupun duplikasi yang mengganggu proses analisis.

Variabel kategorikal seperti Gender dan Product Category kemudian diubah ke bentuk numerik menggunakan encoding agar dapat diproses oleh model. Selain itu, kolom Date ditransformasikan menjadi fitur numerik karena ELM memerlukan input dalam bentuk angka. Fitur-fitur numerik yang digunakan pada model kemudian dinormalisasi atau distandarisasi agar perbedaan skala antarvariabel tidak memengaruhi proses pelatihan.

Dalam penelitian ini, variabel Total Amount tidak dimasukkan sebagai fitur input model karena variabel tersebut telah digunakan untuk membentuk label konsumtif dan tidak konsumtif. Jika tetap dimasukkan sebagai prediktor, maka hasil klasifikasi berpotensi bias. Dengan demikian, fitur akhir yang digunakan sebagai input model terdiri dari Date, Gender, Age, Product Category, Quantity, dan Price per Unit.

4.1.3 Pembagian Data Latih dan Data Uji

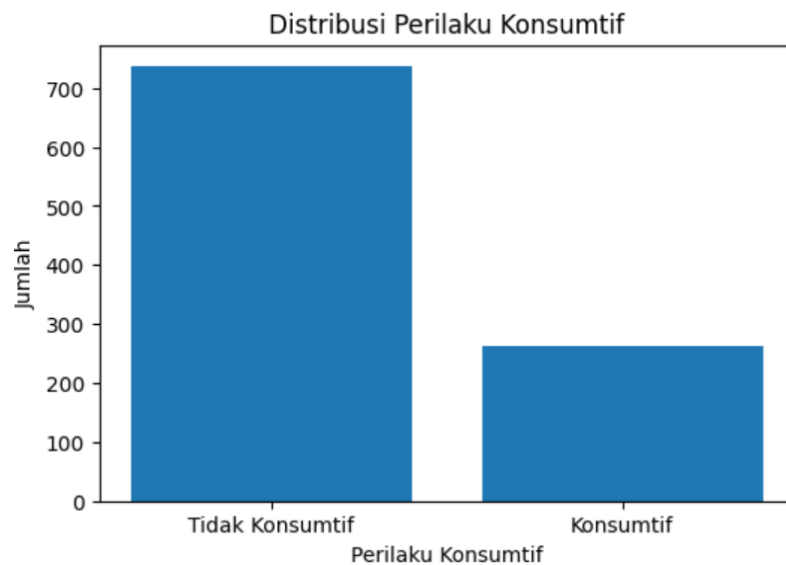
Sesuai rancangan penelitian pada Bab III, dataset dibagi menjadi dua bagian, yaitu data latih dan data uji. Data latih digunakan untuk melatih model ELM, sedangkan data uji digunakan untuk mengevaluasi kemampuan generalisasi

model. Pembagian data dilakukan dengan rasio 80% untuk data latih dan 20% untuk data uji.

Dari total 1.000 data transaksi, diperoleh 800 data latih dan 200 data uji. Komposisi pada data uji menunjukkan bahwa terdapat 147 data tidak konsumtif dan 53 data konsumtif. Oleh karena itu, metrik seperti precision, recall, dan F1-score digunakan untuk memberikan gambaran evaluasi yang lebih komprehensif.

Tabel 4.3 Distribusi Kelas Target pada Data Uji

Kelas	Jumlah	Persentase
Tidak konsumtif (0)	147	73,5%
Konsumtif (1)	53	26,5%
Total	200	100%



Gambar 4.1 Distribusi perilaku konsumtif

Tabel 4.4 Pembagian Data Latih dan Data Uji

Bagian Data	Jumlah Data	Persentase
Data latih	800	80%
Data uji	200	20%
Total	1.000	100%

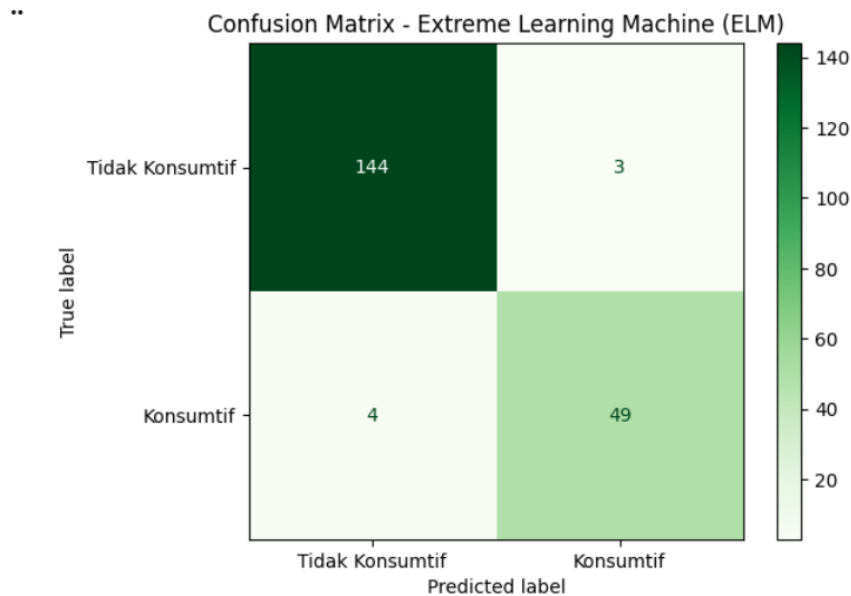
4.1.4 Implementasi Model Extreme Learning Machine (ELM)

Model klasifikasi pada penelitian ini dibangun menggunakan algoritma Extreme Learning Machine (ELM), yaitu jaringan saraf tiruan feedforward dengan satu hidden layer. Proses implementasi dimulai dari penyiapan data fitur (X) dan label (Y), kemudian dilanjutkan dengan pembagian data latih dan data uji. Setelah itu, model ELM dilatih menggunakan data latih dengan bobot input dan bias hidden layer yang diinisialisasi secara acak, sedangkan bobot output dihitung secara analitis menggunakan Moore-Penrose pseudoinverse.

Setelah proses pelatihan selesai, model digunakan untuk memprediksi kelas pada data uji. Hasil prediksi tersebut kemudian dibandingkan dengan label sebenarnya untuk memperoleh confusion matrix dan metrik evaluasi. Penggunaan ELM pada penelitian ini dipilih karena memiliki keunggulan dalam kecepatan komputasi serta mampu menghasilkan performa klasifikasi yang baik pada data dengan jumlah cukup besar.

4.1.5 Evaluasi Model pada Data Uji

Hasil evaluasi model ELM pada data uji ditunjukkan melalui confusion matrix. Berdasarkan hasil pengujian, model menghasilkan 144 prediksi benar untuk kelas tidak konsumtif dan 49 prediksi benar untuk kelas konsumtif. Di samping itu, terdapat 3 kesalahan prediksi ketika data tidak konsumtif diprediksi sebagai konsumtif, serta 4 kesalahan prediksi ketika data konsumtif diprediksi sebagai tidak konsumtif.



Gambar 4.2 Confusion Matrix Model ELM

Berdasarkan confusion matrix tersebut, diperoleh nilai True Negative (TN) = 144, False Positive (FP) = 3, False Negative (FN) = 4, dan True Positive (TP) = 49. Dari nilai-nilai tersebut, perhitungan manual metrik evaluasi dapat dijelaskan sebagai berikut.

1. Perhitungan Accuracy

Rumus accuracy adalah:

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}$$

Substitusi nilai ke dalam rumus:

$$\text{Accuracy} = \frac{49 + 144}{49 + 144 + 3 + 4}$$

$$\text{Accuracy} = \frac{193}{200}$$

$$\text{Accuracy} = 0,965$$

$$\text{Accuracy} = 96,5\%$$

Jadi, nilai accuracy yang diperoleh adalah 96,5%.

2. Perhitungan Precision

Rumus precision adalah:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}$$

Substitusi nilai ke dalam rumus:

$$\text{Precision} = \frac{49}{49 + 3}$$

$$\text{Precision} = \frac{49}{52}$$

$$\text{Precision} = 0,9423$$

$$\text{Precision} = 94,23\%$$

Jadi, nilai precision yang diperoleh adalah 94,23%

3. Perhitungan Recall

Rumus recall adalah:

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

Substitusi nilai ke dalam rumus:

$$\text{Recall} = \frac{49}{49 + 4}$$

$$\text{Recall} = \frac{49}{53}$$

$$\text{Recall} = 0,9245$$

$$\text{Recall} = 92,45\%$$

Jadi, nilai recall yang diperoleh adalah 92,45%.

4. Perhitungan F1-Score

Rumus F1-Score adalah:

$$\text{F1-Score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Substitusi nilai precision dan recall:

$$\text{F1-Score} = \frac{2 \times 0,9423 \times 0,9245}{0,9423 + 0,9245}$$

$$\text{F1-Score} = \frac{1,7424}{1,8668}$$

$$\text{F1-Score} = 0,9333$$

$$\text{F1-Score} = 93,33\%$$

Jadi, nilai F1-Score yang diperoleh adalah 93,33%.

Tabel 4.5 Hasil Evaluasi Model ELM

Metrik	Nilai
Accuracy	96,50%
Precision	94,23%
Recall	92,45%
F1-Score	93,33%

Classification Report:				
	precision	recall	f1-score	support
0	0.97	0.98	0.98	147
1	0.94	0.92	0.93	53
accuracy			0.96	200
macro avg	0.96	0.95	0.95	200
weighted avg	0.96	0.96	0.96	200

Gambar 4.3 Clasification report model

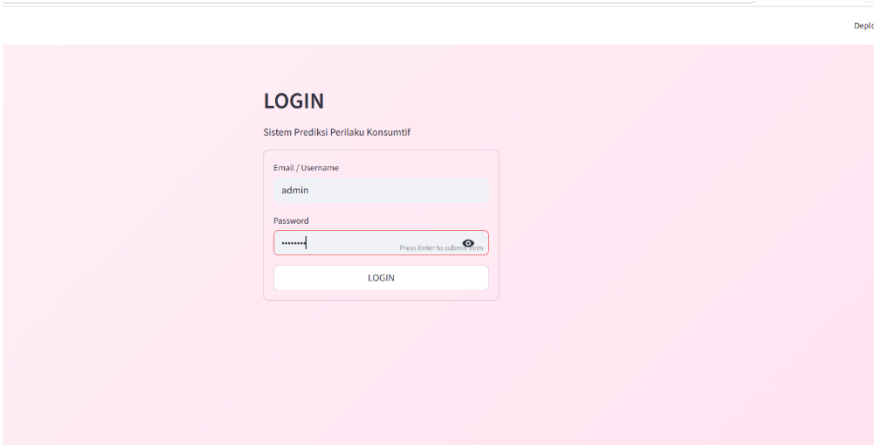
Berdasarkan hasil pengujian, model ELM mampu mengklasifikasikan 193 dari 200 data uji dengan benar. Jumlah prediksi yang salah hanya 7 data, yang terdiri atas 3 false positive dan 4 false negative. Hasil ini menunjukkan bahwa model

memiliki performa klasifikasi yang sangat baik dalam membedakan transaksi konsumtif dan tidak konsumtif.

4.1.6 Implementasi Antarmuka Pengguna

Implementasi antarmuka adalah tahap penerapan tampilan sistem agar dapat digunakan oleh pengguna dalam melakukan penelitian prediksi perilaku konsumtif. Sistem ini dikembangkan berbasis web menggunakan Streamlit dengan tampilan yang sederhana dan mudah digunakan. Antarmuka sistem terdiri dari beberapa halaman utama, yaitu login, dashboard, prediksi dataset, prediksi 1 data, riwayat hasil, dan evaluasi model. Berikut antarmuka pengguna yang dibuat:

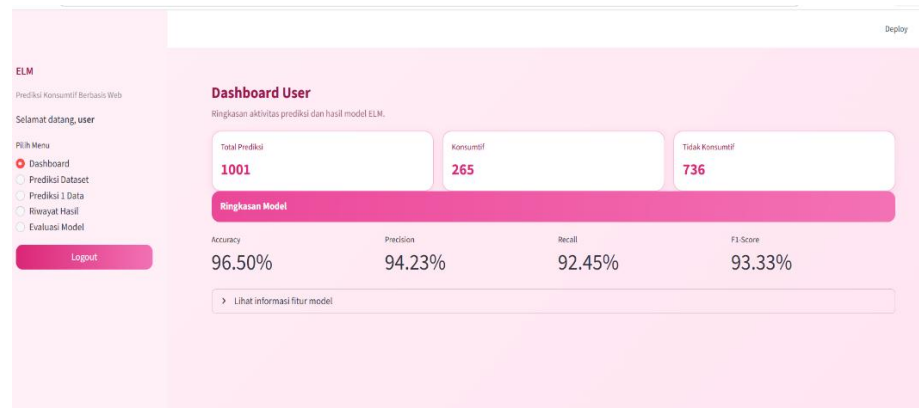
a. Halaman login



Gambar 4.4 Halaman login

Halaman login adalah halaman pertama yang digunakan oleh pengguna untuk mengakses sistem. Pada halaman ini, pengguna diminta untuk memasukkan alamat email atau nama pengguna beserta kata sandi. Jika data login yang dimasukkan benar, sistem akan mengarahkan pengguna ke halaman dashboard. Halaman ini bertindak sebagai penghalang akses agar fitur utama sistem hanya dapat digunakan oleh pengguna yang telah berhasil melakukan login.

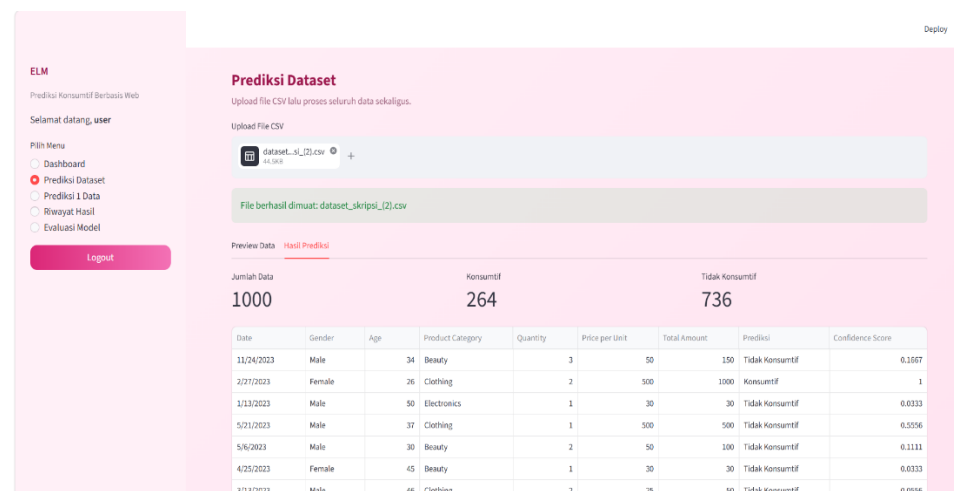
b. Halaman dashboard



Gambar 4.5 Halaman dashboard

Halaman dashboard merupakan halaman utama setelah pengguna berhasil login. Halaman ini menampilkan ringkasan hasil prediksi, yaitu total prediksi, jumlah data konsumtif, dan jumlah data tidak konsumtif. Selain itu, halaman dashboard juga menampilkan nilai evaluasi model ELM berupa accuracy, precision, recall, dan F1-score. Tampilan ini membantu pengguna melihat gambaran umum hasil prediksi dan performa model secara cepat.

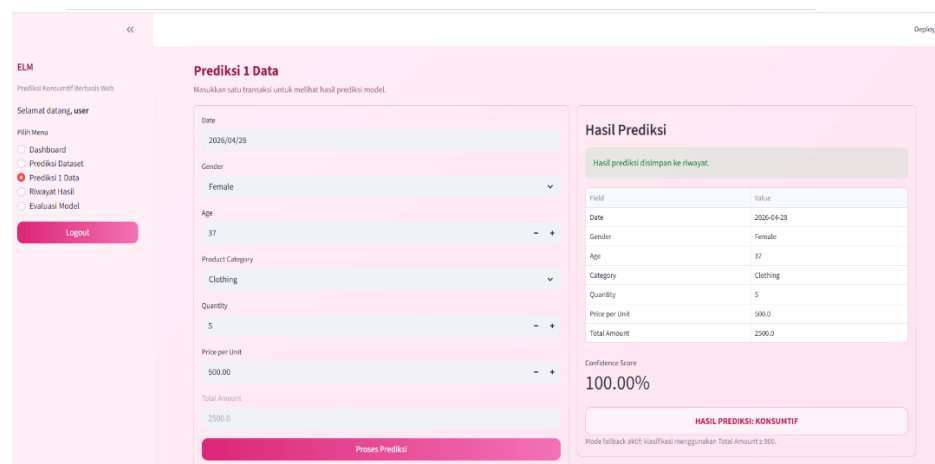
c. Halaman prediksi dataset



Gambar 4.6 Halaman prediksi dataset

Halaman prediksi dataset digunakan untuk melakukan prediksi terhadap data transaksi dalam jumlah banyak. Pengguna dapat mengunggah file CSV yang berisi data transaksi e-commerce, kemudian sistem menampilkan preview data sebelum dilakukan proses prediksi. Setelah data diproses, sistem menghasilkan klasifikasi konsumtif atau tidak konsumtif pada setiap data transaksi.

d. Halaman prediksi 1 data



ELM
Prediksi Konsumtif Berbasis Web

Selamat datang, user

Fitur Menu

- Dashboard
- Prediksi Dataset
- Prediksi 1 Data
- Riwayat Hasil
- Evaluasi Model

Logout

Prediksi 1 Data

Masukkan satu transaksi untuk melihat hasil prediksi model.

Date: 2026/04/28

Gender: Female

Age: 37

Product Category: Clothing

Quantity: 5

Price per unit: 500.00

Total Amount: 2500.0

Proses Prediksi

Hasil Prediksi

Hasil prediksi disimpan ke riwayat.

Field	Value
Date	2026-04-28
Gender	Female
Age	37
Category	Clothing
Quantity	5
Price per unit	500.0
Total Amount	2500.0

Confidence Score
100.00%

HASIL PREDIKSI: KONSUMTIF

Mode fallback aktif: klasifikasi menggunakan Total Amount > 900.

Gambar 4.7 Halaman prediksi 1 data

Halaman prediksi 1 data digunakan untuk melakukan prediksi terhadap satu data transaksi secara manual. Pengguna mengisi atribut transaksi, seperti Date, Gender, Age, Product Category, Quantity, dan Price per Unit. Setelah tombol proses prediksi ditekan, sistem akan menampilkan hasil klasifikasi berupa konsumtif atau tidak konsumtif.

e. Halaman Riwayat hasil

Tanggal	Jenis Input	Jumlah Data	Hasil	File	Konsumtif	Tidak Konsumtif
2026-04-28 09:23:35	1 Data		1 Konsumtif	-	1	0
2026-04-24 12:53:45	Dataset	3000	264 Konsumtif	dataset_ujiuji.csv	264	1736
2025-04-24 08:31:08	1 Data		1 Konsumtif	-	1	0

Gambar 4.8 Halaman riwayat hasil

Riwayat hasil digunakan untuk menampilkan daftar hasil prediksi yang pernah dilakukan oleh pengguna. Informasi yang ditampilkan meliputi tanggal prediksi, jenis input, jumlah data, hasil prediksi, serta jumlah data konsumtif dan tidak konsumtif. Halaman ini membantu pengguna melihat kembali hasil prediksi yang telah dilakukan sebelumnya.

f. Halaman hasil evaluasi model

Accuracy	Precision	Recall	F1-Score
96.50%	94.23%	92.45%	93.33%

Confusion Matrix

	Prediksi Konsumtif	Prediksi Tidak Konsumtif	
Konsumtif	49	4	
Tidak Konsumtif	3	144	

Distribusi Kelas Data Uji

Kelas	Jumlah
Tidak Konsumtif	147
Konsumtif	53

Gambar 4.9 Halaman hasil evaluasi model

Halaman evaluasi model digunakan untuk menampilkan hasil pengujian model Extreme Learning Machine (ELM). Pada halaman ini ditampilkan nilai accuracy, precision, recall, dan F1-score, serta confusion matrix dan distribusi kelas data uji. Nilai evaluasi tersebut diperoleh dari

proses pengujian model terhadap dataset, yaitu data uji yang telah dipisahkan dari dataset utama. Oleh karena itu, hasil evaluasi pada halaman ini bukan berasal dari prediksi 1 data, melainkan dari hasil pengujian model menggunakan data uji secara keseluruhan

4.2 Pembahasan

4.2.1 Interpretasi Hasil Klasifikasi

Nilai accuracy sebesar 96,50% menunjukkan bahwa model memiliki kemampuan klasifikasi yang sangat baik pada data uji. Dari total 200 data uji, sebanyak 193 transaksi berhasil diprediksi dengan benar, sedangkan hanya 7 transaksi yang mengalami kesalahan klasifikasi. Secara umum, hasil ini menandakan bahwa pola transaksi yang digunakan dalam penelitian sudah cukup representatif untuk membedakan transaksi yang cenderung konsumtif dan yang tidak konsumtif.

Namun demikian, akurasi tidak dapat dijadikan satu-satunya dasar penilaian karena distribusi kelas pada data uji tidak sepenuhnya seimbang, yaitu 147 data tidak konsumtif dan 53 data konsumtif. Pada kondisi seperti ini, model berpotensi terlihat baik hanya karena lebih sering mengikuti kelas mayoritas. Oleh sebab itu, evaluasi dilengkapi dengan precision, recall, dan F1-score agar interpretasi kinerja model menjadi lebih objektif dan komprehensif.

Nilai precision sebesar 94,23% menunjukkan bahwa ketika model memprediksi suatu transaksi sebagai konsumtif, maka sebagian besar prediksi tersebut benar. Sementara itu, nilai recall sebesar 92,45% memperlihatkan bahwa model mampu menemukan sebagian besar transaksi yang memang termasuk

konsumtif. Dengan kata lain, model tidak hanya akurat secara umum, tetapi juga cukup peka dalam mengenali kelas target penelitian.

Nilai F1-score sebesar 93,33% memperkuat kesimpulan bahwa model memiliki keseimbangan yang baik antara precision dan recall. Keseimbangan ini penting karena dalam konteks prediksi perilaku konsumtif, model diharapkan tidak hanya tepat saat memberi label konsumtif, tetapi juga tidak banyak melewatkan transaksi yang sebenarnya masuk kategori konsumtif. Dengan demikian, hasil pengujian menunjukkan bahwa ELM tidak hanya cepat secara komputasi, tetapi juga memberikan performa klasifikasi yang stabil pada dataset penelitian.

4.2.2 Proses Pembentukan Label Konsumtif

Salah satu bagian penting dalam penelitian ini adalah pembentukan label target karena dataset yang digunakan tidak memiliki label konsumtif dan tidak konsumtif secara bawaan. Berdasarkan kode program, label dibentuk dengan menggunakan nilai persentil ke-75 dari variabel `total_amount`. Transaksi dengan nilai belanja yang berada pada kelompok 25% teratas dikategorikan sebagai konsumtif, sedangkan sisanya dikategorikan sebagai tidak konsumtif.

Pendekatan ini relevan karena memberikan dasar klasifikasi yang objektif dan berbasis distribusi aktual data transaksi, bukan penilaian subjektif peneliti. Dalam konteks penelitian ini, transaksi dengan total belanja tinggi diasumsikan lebih dekat dengan karakteristik perilaku konsumtif dibandingkan mayoritas transaksi lainnya. Oleh sebab itu, penggunaan ambang P75 membantu membentuk target klasifikasi yang jelas dan terukur.

Meskipun demikian, label yang dihasilkan perlu dipahami sebagai label operasional. Artinya, model dalam penelitian ini memprediksi kecenderungan

konsumtif dari sudut pandang nominal transaksi, bukan dari aspek psikologis seperti dorongan emosional, impulsive buying, atau tekanan sosial. Penjelasan ini penting agar interpretasi hasil tetap sesuai dengan rancangan penelitian dan tidak melampaui batas data yang digunakan.

Dengan dasar pelabelan seperti ini, model dapat diarahkan untuk mengenali transaksi yang mengarah pada pola pengeluaran tinggi tanpa harus bergantung pada data kuesioner. Hal tersebut menjadi salah satu keunggulan penelitian ini karena klasifikasi dibangun dari perilaku pembelian yang benar-benar tercatat pada data transaksi e-commerce.

4.2.3 Pengaruh Tahap Preprocessing terhadap Kinerja Model

Tahap preprocessing pada penelitian ini memiliki peran besar terhadap keberhasilan model klasifikasi. Pembersihan nama kolom, penghapusan atribut yang tidak relevan, serta pemeriksaan missing value membantu menciptakan dataset yang lebih rapi dan konsisten. Data yang terorganisasi dengan baik akan mempermudah model dalam mempelajari pola-pola yang terkandung di dalamnya.

Transformasi pada variabel date menjadi month, day, dan dayofweek juga memberikan nilai tambah dalam pemodelan. Hal ini karena transaksi e-commerce tidak hanya dipengaruhi oleh besaran harga atau jumlah pembelian, tetapi juga dapat memiliki pola tertentu berdasarkan waktu. Dengan memecah tanggal menjadi komponen yang lebih spesifik, model diberi kesempatan untuk menangkap pola transaksi yang mungkin berkaitan dengan waktu tertentu.

Penggunaan One-Hot Encoding pada variabel kategorikal juga sangat tepat karena menghindari kesalahan interpretasi urutan kategori oleh model. Sementara itu, standardisasi pada fitur numerik membantu menjaga agar perbedaan skala

antarvariabel tidak terlalu memengaruhi proses pembelajaran. Semua fitur akhirnya memiliki kesempatan yang lebih seimbang untuk berkontribusi terhadap hasil prediksi.

Selain itu, variabel `total_amount` sengaja tidak dimasukkan sebagai fitur input karena sudah dipakai dalam pembentukan label. Keputusan ini penting untuk mencegah data leakage yang dapat membuat model tampak sangat akurat secara semu. Dengan preprocessing yang tepat, performa tinggi model menjadi lebih dapat dipertanggungjawabkan secara metodologis.

4.2.4 Implementasi Extreme Learning Machine dalam Penelitian

Implementasi model pada penelitian ini menunjukkan bahwa Extreme Learning Machine dapat diterapkan secara langsung pada data transaksi e-commerce. Pada kode program, ELM dibangun dengan satu hidden layer sebanyak 50 neuron dan menggunakan fungsi aktivasi sigmoid. Bobot input dan bias diinisialisasi secara acak, kemudian bobot output dihitung secara langsung menggunakan pseudoinverse.

Mekanisme tersebut menjadi ciri utama ELM dan membedakannya dari jaringan saraf tiruan konvensional yang membutuhkan proses iteratif melalui backpropagation. Karena bobot output dihitung secara analitis, proses pelatihan menjadi lebih sederhana dan lebih cepat. Hal ini menjadikan ELM sesuai digunakan pada penelitian dengan kebutuhan eksperimen komputasi yang efisien.

Penggunaan `random_state=42` pada kode juga menunjukkan bahwa eksperimen dibuat konsisten agar hasil yang diperoleh dapat direproduksi. Dengan demikian, implementasi ELM dalam penelitian ini tidak hanya tepat secara teori,

tetapi juga rapi secara teknis karena setiap tahap pemrosesan data dan pelatihan model dapat dijalankan kembali dengan alur yang sama.

Secara keseluruhan, implementasi ELM pada penelitian ini berhasil menunjukkan bahwa model dapat memanfaatkan kombinasi fitur transaksi untuk menghasilkan klasifikasi yang kuat. Keunggulan ELM pada kecepatan komputasi tetap dapat dipertahankan tanpa mengorbankan kualitas hasil prediksi.

4.2.5 Analisis Hasil pada Tiap Kelas

Berdasarkan matriks evaluasi dan laporan klasifikasi, performa model di kelas tidak konsumtif sedikit lebih baik dibandingkan kelas konsumtif. Dapat dilihat dari jumlah prediksi yang tepat pada kelas tidak konsumtif, yaitu 144 data, sedangkan pada kelas konsumtif, model berhasil memprediksi 49 data dengan benar. Perbedaan ini masih bisa dianggap normal karena data uji yang digunakan lebih banyak berasal dari kelas yang tidak konsumtif.

Meski begitu, prestasi model di kelas konsumtif masih bisa dikatakan sangat bagus. Dari 53 transaksi konsumtif yang ada dalam data uji, model hanya tidak berhasil mengenali 4 transaksi saja. Jumlah hasil positif palsu juga sangat sedikit, hanya 3 kasus, sehingga model tidak terlalu sering memperkirakan transaksi yang tidak konsumtif sebagai transaksi konsumtif.

Jika dilihat lebih dalam, kesalahan klasifikasi kemungkinan terjadi karena pendekatan penelitian yang memiliki karakteristik hampir mendekati ambang batas keputusan. Misalnya, ada transaksi di mana jumlah barang, harga per unit, atau kategori produknya menunjukkan pola pengeluaran yang tinggi, namun secara operasional masih sedikit di bawah batas `total_amount` 900. Situasi seperti ini sering terjadi dalam klasifikasi menggunakan batas kelas berbasis `threshold`.

Hasil di setiap kelas menunjukkan bahwa model tidak hanya mengikuti kelas yang jumlahnya paling banyak, tetapi juga masih bisa mengenali kelas konsumtif yang menjadi pusat perhatian penelitian. Sehingga, kinerja model bisa dikatakan baik bukan hanya dari tingkat akurasi secara keseluruhan, tetapi juga dari kemampuannya dalam membedakan dua kelas yang dituju.

4.2.6 Keterkaitan Hasil dengan Penelitian Terdahulu

Hasil penelitian ini sesuai dengan penelitian sebelumnya yang menunjukkan bahwa Extreme Learning Machine memiliki kemampuan memprediksi yang baik dan proses pembelihannya tergolong cepat. Dalam penelitian sebelumnya, ELM lebih sering digunakan untuk pekerjaan memprediksi angka atau kecenderungan, seperti mengirimkan dugaan transaksi e-money, hasil produksi, atau harga barang. Hasil penelitian ini menunjukkan bahwa ELM juga bisa digunakan dengan efektif untuk mengklasifikasikan data dalam dua kategori.

Perbedaan utama dari penelitian ini adalah pada jenis masalah yang berhasil diselesaikan. Penelitian sebelumnya lebih banyak menggunakan ELM untuk memprediksi, sedangkan penelitian ini menerapkan ELM untuk mengklasifikasikan perilaku konsumtif berdasarkan data transaksi di e-commerce. Dengan demikian, penelitian ini mengembangkan penggunaan ELM dari bidang memprediksi nilai ke analisis perilaku berdasarkan kelas.

Di sisi lain, penelitian sebelumnya tentang perilaku konsumtif biasanya lebih sering menggunakan cara survei atau kuesioner. Pendekatan itu penting agar kita bisa memahami hal-hal psikologis, tapi hasilnya tetap tergantung pada jawaban yang diberikan oleh responden. Penelitian ini melengkapi pendekatan sebelumnya

dengan menggunakan data transaksi nyata, sehingga klasifikasi dilakukan berdasarkan pola belanja yang benar-benar tercatat dalam sistem.

Dengan demikian, hasil penelitian ini mendukung analisis kesenjangan pada Bab II, yaitu masih ada ruang yang terbuka untuk menerapkan ELM dalam memprediksi perilaku konsumtif berdasarkan data transaksi e-commerce. Kontribusi utama penelitian ini adalah menegaskan bahwa menggunakan data sekunder dan machine learning bisa memberikan klasifikasi yang sangat baik serta memberikan perspektif yang lebih objektif.

4.2.7 Kelebihan dan Keterbatasan Penelitian

Penelitian ini memiliki beberapa kelebihan. Pertama, data yang digunakan adalah data transaksi nyata, sehingga proses analisis lebih jujur karena tidak tergantung pada pendapat responden. Kedua, algoritma ELM yang digunakan memiliki kelebihan dalam hal kecepatan pembelajaran dan mudahnya perhitungan, sehingga cocok diterapkan dalam penelitian klasifikasi dengan volume data yang cukup besar. Ketiga, pengevaluasian model tidak hanya melihat akurasi, tetapi juga presisi, recall, dan skor F1, sehingga hasil uji coba menjadi lebih menyeluruh. Selain itu, penelitian ini juga menunjukkan bahwa fitur transaksi yang sederhana bisa digunakan untuk membuat model klasifikasi yang kuat. Hal ini memberi manfaat secara metode dalam penelitian yang menggunakan data mining.

Di sisi lain, penelitian ini juga mengalami beberapa keterbatasan. Label konsumtif dibuat berdasarkan total jumlah transaksi, sehingga definisi konsumtif dalam penelitian ini lebih mencerminkan besarnya nominal yang dikeluarkan dibandingkan dengan makna konsumtif secara psikologis. Selain itu, data yang digunakan hanya berasal dari satu dataset Kaggle yang berisi 1.000 transaksi dan

tiga jenis produk. Keterbatasan lainnya adalah dataset tidak memiliki informasi identitas pelanggan, sehingga penelitian ini belum bisa menganalisis perilaku belanja secara berkelanjutan pada orang yang sama. Penelitian ini belum membandingkan ELM dengan algoritma klasifikasi lainnya dan belum memeriksa kinerja model pada berbagai situasi pelatihan yang berbeda. Oleh karena itu, penelitian lebih lanjut masih diperlukan agar model yang dihasilkan menjadi lebih kuat dan dapat diterapkan secara lebih luas.

4.2.8 Implikasi dan Pengembangan Lanjutan

Secara nyata, penelitian ini menunjukkan bahwa model prediksi yang menggunakan data transaksi bisa digunakan sebagai bantuan dalam menganalisis pola belanja di platform e-commerce. Informasi hasil klasifikasi bisa digunakan untuk membantu membagi transaksi, mengevaluasi pola belanja di kategori produk tertentu, serta memahami kecenderungan nilai belanja yang terdapat dalam data pelanggan. Bagi manajemen bisnis, hasil klasifikasi juga bisa membantu dalam memahami dampak dari strategi promosi yang diterapkan. Jika suatu kategori barang, jangka waktu, atau kombinasi jumlah beli dan harga per unit sering masuk ke kelas konsumsi yang tinggi, maka informasi tersebut bisa dipakai sebagai acuan dalam mengambil keputusan bisnis yang lebih berlandaskan data.

Di sisi lain, hasil penelitian ini juga bisa dilihat dari sudut pandang perlindungan konsumen. Prediksi terhadap kecenderungan transaksi konsumtif tidak selalu digunakan untuk mendorong pembelian yang lebih besar, tetapi juga bisa dimanfaatkan untuk memahami pola belanja berlebih. Sehingga hasil dari model tersebut dapat digunakan dengan lebih bertanggung jawab.

Agar penelitian bisa berkembang lebih lanjut, bisa dilakukan penambahan data dalam dataset, peningkatan variasi kategori produk, pengujian berulang dengan beberapa pengaturan random state, serta perbandingan metode ELM dengan algoritma klasifikasi lainnya. Pengembangan label yang lebih rumit juga bisa dipikirkan agar penjelasan tentang perilaku konsumtif menjadi lebih lengkap dan tidak hanya didasarkan pada jumlah uang yang dihabiskan.

4.3 Ringkasan Bab

Berdasarkan hasil pengolahan data dan uji coba model, dapat disimpulkan bahwa algoritma Extreme Learning Machine (ELM) memiliki kemampuan yang baik dalam melakukan klasifikasi pada data transaksi e-commerce. Model menghasilkan akurasi sebesar 96,50%, presisi 94,23%, recall 92,45%, dan skor F1 sebesar 93,33%. Hasil tersebut menunjukkan bahwa metode ELM bekerja dengan baik dalam memprediksi perilaku belanja seseorang berdasarkan pola pembelian di platform e-commerce.

Berdasarkan hasil klasifikasi, kategori elektronik adalah kategori produk yang paling besar memengaruhi pola belanja konsumen. Dari 342 data dalam kategori Elektronik, ada 91 data yang masuk ke dalam label 1 dan 251 data yang masuk ke dalam label 0. Ini menunjukkan bahwa kategori Elektronik memiliki jumlah data yang digunakan paling banyak dibandingkan kategori lainnya. Selain itu, kategori Elektronik juga memberikan kontribusi sekitar 34,47% dari seluruh data yang memiliki label 1, sehingga dapat disimpulkan bahwa kategori ini merupakan produk yang paling banyak mewakili perilaku belanja konsumen dalam penelitian ini.

BAB V

PENUTUP

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, maka dapat disimpulkan beberapa hal sebagai berikut:

1. Penelitian ini berhasil menerapkan algoritma Extreme Learning Machine (ELM) untuk memprediksi perilaku konsumtif berdasarkan pola transaksi e-commerce. Variabel input yang digunakan meliputi Date, Gender, Age, Product Category, Quantity, dan Price per Unit, sedangkan label target dibentuk secara operasional menjadi dua kelas, yaitu konsumtif (1) dan tidak konsumtif (0), berdasarkan ambang persentil ke-75 dari Total Amount, yaitu 900.

2. Model ELM yang dibangun menunjukkan performa yang sangat baik pada data uji. Berdasarkan confusion matrix, model menghasilkan True Negative (TN) = 144, False Positive (FP) = 3, False Negative (FN) = 4, dan True Positive (TP) = 49. Dari hasil tersebut diperoleh accuracy sebesar 96,50%, precision 94,23%, recall 92,45%, dan F1-score 93,33%. Nilai ini menunjukkan bahwa model mampu mengklasifikasikan transaksi konsumtif dan tidak konsumtif secara akurat dan seimbang.

3. Penelitian ini menunjukkan bahwa cara bertransaksi di e-commerce bisa menjadi acuan untuk memperkirakan bagaimana seseorang menghabiskan uang. Pendekatan ini menawarkan pilihan yang lebih terbuka dan jujur dibandingkan metode yang menggunakan kuesioner, karena mengandalkan data transaksi yang benar-benar terjadi. Meskipun demikian, makna konsumtif dalam penelitian ini tetap bersifat operasional, yaitu menggambarkan transaksi dengan nilai belanja yang cukup besar, bukan mencakup seluruh aspek psikologis dari perilaku konsumtif.

4. Secara substantif, kategori Electronics tercatat sebagai kategori dengan jumlah transaksi berlabel konsumtif terbanyak pada dataset penelitian. Temuan ini menunjukkan bahwa kategori produk dapat menjadi salah satu penanda penting dalam membaca kecenderungan perilaku belanja pada transaksi e-commerce.

5.2 Saran

Berdasarkan hasil penelitian dan keterbatasan yang ada, maka saran yang dapat diberikan adalah sebagai berikut:

1. Penelitian selanjutnya disarankan menggunakan dataset yang lebih besar, lebih beragam, dan berasal dari lebih dari satu sumber agar hasil penelitian memiliki tingkat generalisasi yang lebih baik.
2. Penelitian berikutnya dapat menambahkan identitas pelanggan atau riwayat transaksi berulang agar perilaku konsumtif dapat dianalisis secara lebih mendalam pada level individu, bukan hanya pada level transaksi tunggal.
3. Pembentukan label perilaku konsumtif dapat dikembangkan dengan menggabungkan beberapa indikator sekaligus, seperti frekuensi pembelian, jenis produk, pola waktu transaksi, atau metode pembayaran, sehingga definisi konsumtif menjadi lebih kaya dan tidak hanya bergantung pada nominal Total Amount.
4. Untuk memperoleh evaluasi yang lebih kuat, penelitian lanjutan disarankan membandingkan ELM dengan algoritma klasifikasi lain, seperti Support Vector Machine, Random Forest, atau Artificial Neural Network, serta melakukan pengulangan eksperimen atau cross-validation untuk menguji kestabilan model.
5. Jika dikembangkan untuk kebutuhan praktis, model prediksi seperti ini sebaiknya digunakan sebagai alat bantu analisis dan segmentasi perilaku belanja, bukan

sebagai satu-satunya dasar pengambilan keputusan, sehingga interpretasi hasil tetap mempertimbangkan konteks bisnis dan perilaku konsumen secara lebih luas.

DAFTAR PUSTAKA

- Agung, A., Daniswara, A., & Nuryana, I. K. D. (2023). *Data Preprocessing Pola Pada Penilaian Mahasiswa Program Profesi Guru*. 05, 97–100.
- Apriana, D., & Yuliansyah, C. (2024). Mengoptimalkan Penjualan Online Melalui Teknik Data Mining (Studi Kasus E-Commerce). *AL-MIKRAJ Jurnal Studi Islam Dan Humaniora (E-ISSN 2745-4584)*, 4(02), 514–527. <https://doi.org/10.37680/almikraj.v4i02.4774>
- Devita Rizqi, M., Mahmudah, U., & Dini Aulia, R. (2025). Prediksi Tren Penggunaan Electronic Money (E-Money) di Indonesia menggunakan pendekatan Extreme Learning Machines. *Emerging Statistics and Data Science Journal*, 3(3), 640–649. <https://doi.org/10.20885/esds.vol3.iss.3.art17>
- Dewi, A., Mukti, P., Ullinnuha, N., & Asyhar, A. H. (2025). *Implementasi Extreme Learning Machine dengan Seleksi Fitur Particle Swarm Optimization untuk Klasifikasi Sindrom Ovarium Polikistik*. 21(2), 131–142. <https://doi.org/10.24198/jmi.v21.n2.63988.131-142>
- Dhanty, W. R., Cahyati, A. V., & Alexandra, E. T. (2022). Analisis Pengaruh Kemudahan Paylater Pada Aplikasi Shopee Dan Promo Diskon Produk Terhadap Perilaku Pembelian Impulsif. *Jurnal Manajemen Dan Bisnis Jayakarta*, 04(01), 1–13.
- Hariansyah, J., Budianita, E., & Afrianty, I. (2024). *Prediksi Harga Kelapa Sawit Menggunakan Metode Extreme Learning Machine*. 5(2), 276–283. <https://doi.org/10.47065/josyc.v5i2.4858>
- Irfon, G., & Soen, E. (2022). *Implementasi Cloud Computing dengan Google Colaboratory Pada Aplikasi Pengolah Data Zoom Participants*. 6(1), 24–30.

- Melisa, O. :, Faisal, T., & Fasa, M. I. (2025). Transformasi Digital: Peran E-Commerce Dalam Pertumbuhan Ekonomi Digital Di Indonesia. *Jma (Jurnal Media Akademik)*, 3(4), 3031–5220.
- Murani, N. A., Wahyuni, S., Pratiwi, R. A., & Firdaus, T. (2025). Analisis Penggunaan Visual Studio Code Sebagai Editor Pemrograman Terbaik Untuk Pemula Pada Mahasiswa Informatika Universitas Nurul Huda. 2(2), 1–10.
- Naning Fatmawatie. (2022). E Commerce Dan Perilaku Konsumtif. In *IAIN Kediri Press*.
- Nurhasanah, E. (2023). Analisis Penggunaan E-Commerce Shopee terhadap Perilaku Konsumtif Mahasiswa (Studi Fenomenologi pada Mahasiswa Prodi Pendidikan Ekonomi Universitas Pamulang Angkatan 2022). *Pekobis : Jurnal Pendidikan, Ekonomi, Dan Bisnis*, 8(1), 47. <https://doi.org/10.32493/pekobis.v8i1.p47-59.30254>
- Rohmawati, A., & Widiyanto. (2025). Pengaruh Flash Sale, Cashback, dan Tagline “Gratis Ongkir” terhadap Perilaku Impulsive Buying pada Ibu Rumah Tangga Pengguna Shopee dengan Perceived Value sebagai Variabel Intervening. *Jurnal Ilmiah Sultan Agung, September*, 425–437.
- Salim, D., Wu, B., Salim, O. R., & Gunadi, R. B. (2022). *No Title*. 2, 120–133.
- Saputra, R., & Naufal Wala, G. (2024). Pengaruh Tekanan Sosial Terhadap Perilaku Konsumtif (Study Literature Review). *Jurnal Komunikasi Dan Ilmu Sosial*, 2(3), 111–122. <https://doi.org/10.38035/jkis.v2i3.1466>
- Studi, P., Informasi, S., Lamappapoleonro, U., Selatan-indonesia, S. S., Makassar, U. H., Selatan, S., Mining, D., Vektor, S., Desa, W., Kabupaten, K., Dengan, S., & Support, M. (2025). *Data Mining Klasifikasi Penduduk Miskin*

Menggunakan Metode Support Vektor Machine. 8(April).

Wanda, I. S., Mufarroha, F. A., Jauhari, A., & Anamisa, D. R. (2025). *Peramalan Produksi Padi Menggunakan Extreme Learning Machine (ELM) Dengan Deteksi Outlier. 4(1), 51–58.*

Warohma, M., Sains, F., Teknologi, D. A. N., Islam, U., Sultan, N., & Kasim, S. (2023). *Prediksi Jumlah Perceraian Menggunakan Metode Extreme Learning Machine (ELM) Tugas Akhir.*

Lampiran 1. SK Penetapan Dosen Pembimbing



UMSU

Unggul | Cerdas | Terpercaya
 Kita menegakkan keadilan agar kehidupan
 rakyat dan bangsa sejahtera

MAJELIS PENDIDIKAN TINGGI PENELITIAN & PENGEMBANGAN PIMPINAN PUSAT MUHAMMADIYAH
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI

UMSU Terakreditasi Unggul Berdasarkan Keputusan Badan Akreditasi Nasional Perguruan Tinggi No. 174/SK/DAN-PT/AK.Ppy/PT/2024

Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20238 Telp. (061) 6672400 - 66224567 Fax. (061) 6625474 - 6631003

<http://www.umsu.ac.id> BA@umsu.ac.id [umsumedan](https://www.instagram.com/umsumedan) [umsumedan](https://www.facebook.com/umsumedan) [umsumedan](https://www.youtube.com/umsumedan)

KEPUTUSAN DEKAN
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA
 Nomor : 264/KEP/IL.3.AU/UMSU-09/F/2026

Tentang :
PENGANGKATAN DOSEN PEMBIMBING SKRIPSI
PRODI TEKNOLOGI INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA



Dekan Fakultas Ilmu Komputer dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara, setelah

Menimbang : 1. Bahwa sehubungan dengan pelaksanaan Tugas Akhir Fakultas Ilmu Komputer dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara;
 2. Bahwa untuk memenuhi maksud tersebut perlu diterbitkan surat keputusan Dekan Fakultas Ilmu Komputer dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara.

Mengingat : 1. Undang-undang Republik Indonesia No. 12 Tahun 2012 tentang Pendidikan Tinggi;
 2. Peraturan Pemerintah Nomor 4 Tahun 2014 tentang Penyelenggaraan Pendidikan Tinggi dan Pengelolaan Perguruan Tinggi;
 3. Pedoman Perguruan Tinggi Muhammadiyah;
 4. Statuta Universitas Muhammadiyah Sumatera Utara
 5. Keputusan Rektor No. 1001/KEP/IL.3-AU/UMSU/D/2025 tanggal 25 Oktober 2025 tentang Dekan Fakultas Ilmu Komputer dan Teknologi Informasi UMSU Masa Jabatan 2025-2029
 6. Keputusan Rektor No. 624/KEP/IL.3.AU/UMSU/D/2025 tentang Prodi Fakultas Ilmu Komputer dan Teknologi Informasi UMSU Masa Jabatan 2025-2029

MEMUTUSKAN

Menetapkan :
KESATU : Menetapkan nama-nama dalam lampiran surat keputusan ini sebagai Dosen Pembimbing Prodi Teknologi Informasi Fakultas Ilmu Komputer dan Teknologi Informasi UMSU.
KEDUA : Keputusan ini berlaku sejak tanggal ditetapkan, dan akan ditinjau serta diperbaiki kembali jika terdapat kekeliruan di kemudian hari.

Ditetapkan di : Medan
 Pada tanggal : 05 Sya'ban 1447 H
 24 Januari 2026 M



Tembusan:

1. Yth. Wakil Dekan I & III UMSU di Medan,-
2. Ka. Prodi TI dan Sek. Prodi TI,-
3. Pertinggal.



Dipindai dengan CamScanner





UMSU
Unggul | Cerdas | Terpercaya

Unggul | Cerdas | Terpercaya

Unggul | Cerdas | Terpercaya

MAJELIS PENDIDIKAN TINGGI PENELITIAN & PENGEMILANGAN PIMPINAN PUSAT MUHAMMADIYAH
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI

UMSU Terakreditasi Unggul Berdasarkan Keputusan Badan Akreditasi Nasional Perguruan Tinggi No. 174/SK/BAN-PT/Ak.Ppy/PT/02024

Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20236 Telp. (061) 6622400 - 66224567 Fax. (061) 6625474 - 6631003

Website: www.umsu.ac.id Email: info@umsu.ac.id Instagram: [umsuamedan](https://www.instagram.com/umsuamedan) Facebook: [umsuamedan](https://www.facebook.com/umsuamedan) Twitter: [umsuamedan](https://twitter.com/umsuamedan)

Lampiran Dosen Pembimbing Prodi Teknologi Informasi
Nomor : 264/KEP/II.3.AU/UMSU-09/F/2026
Tanggal : 05 Sya'ban 1447 H / 24 Januari 2026 M

PENGANGKATAN DOSEN PEMBIMBING SKRIPSI
PRODI TEKNOLOGI INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA

NO	NAMA	NPM	JUDUL	DOSEN
1	Nadira Aulia Afriza	2209020182	Pendekatan Quasi-Eksperimental dan Klasifikasi Menggunakan Gradient Boosting dengan SHAP dalam Analisis Perubahan Nilai Sekolah Fenerina Program Makan Bergizi Gratis	Fatma Sari Hutagalung, S.Kom., M.Kom
2	M Wawan Subari	2209020298	Rancang Bangun Smart Game-Time Limiter Berbasis Internet of Things (IoT) untuk Pengendalian Durasi Bermain Game Online pada Anak di Lingkungan Rumah Tangga	Mhd. Basri, S.Si. M.Kom
3	Muhammad Aqil Fikri	2209020152	Sistem Monitoring dan Pengendalian Kualitas Udara Indoor pada Coffee Shop Berbasis Sensor Gas CO ₂ dan Asap Rokok Menggunakan IoT dengan Kendali Exhaust Fan Otomatis	Dr. Al-Khowarizmi, M.Kom.
4	Nabila Azura Putri	2209020070	Forecasting Tren Minat Jurusan Mahasiswa di UMSU Menggunakan Grey Forecasting Model Berbasis Android	Farid Akbar Siregar S.Kom., M.Kom.
5	Handika Alfazri	2209020169	Prototipe Sistem Penyortiran Paket Otomatis Berdasarkan Kecamatan Menggunakan Internet of Things	Yohanni Syahra, S.Si., M.Kom.
6	Siti Mardiyati Rukmana	2209020115	Penerapan Algoritma Extreme Learning Machine (ELM) untuk Memprediksi Perilaku Konsumtif Berdasarkan Pola Transaksi E-commerce	Dr. Al-Khowarizmi, M.Kom.
7	Muhammad Helmi Yazid	2209020266	Rancang Bangun Sistem Smart Seat Menggunakan Sensor Force Sensitive Resistor (FSR) dan ESP8266 untuk Pemantauan Pola Duduk Sehat Berbasis IoT.	Yohanni Syahra, S.Si., M.Kom.



Lampiran 2. Turnitin

Tidak Ada Judul

ORIGINALITY REPORT

28%	26%	12%	11%
SIMILARITY INDEX	INTERNET SOURCES	PUBLICATIONS	STUDENT PAPERS

PRIMARY SOURCES

1	journals.unpad.ac.id Internet Source	3%
2	repository.umsu.ac.id Internet Source	3%
3	jurnal.mediaakademik.com Internet Source	1%
4	repository.uin-suska.ac.id Internet Source	1%
5	ejournal.insuriponorogo.ac.id Internet Source	1%
6	repository.unissula.ac.id Internet Source	1%
7	repository.wicida.ac.id Internet Source	1%
8	repository.ulb.ac.id Internet Source	1%
9	openjournal.unpam.ac.id Internet Source	1%
10	repository.ub.ac.id Internet Source	1%
11	dinastires.org Internet Source	1%
12	informatika.umsida.ac.id	

	Internet Source	<1%
13	etheses.uin-malang.ac.id Internet Source	<1%
14	Submitted to Australian International Institute of Higher Education Student Paper	<1%
15	penerbitadm.pubmedia.id Internet Source	<1%
16	Submitted to Universitas Islam Indonesia Student Paper	<1%
17	journal.artei.or.id Internet Source	<1%
18	repositori.uin-alauddin.ac.id Internet Source	<1%
19	Submitted to Universitas Putera Batam Student Paper	<1%
20	repoi.jaipuria.ac.in Internet Source	<1%
21	ejurnal.stmik-budidarma.ac.id Internet Source	<1%
22	pt.scribd.com Internet Source	<1%
23	aiex.ai Internet Source	<1%
24	e-jurnal.pnl.ac.id Internet Source	<1%
25	journal.uii.ac.id Internet Source	<1%

26	repository.unpkediri.ac.id Internet Source	<1%
27	Submitted to Universitas Brawijaya Student Paper	<1%
28	Submitted to Telkom University Student Paper	<1%
29	hostjournals.com Internet Source	<1%
30	M. Theo Ari Bangsa, M. Badaruddin M. Badaruddin, Miko Septian, Hasby Al Munawar et al. "Perancangan Sistem Informasi Pengelolaan Arsip Buku Nikah di Kantor Urusan Agama Kecamatan Pelayangan Kota Jambi", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025 Publication	<1%
31	Riko Angga Bayu Kusuma -, Bambang Irawan -, Abdul Khamid -. "KLASIFIKASI PENYAKIT KULIT WAJAH MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK EFFICIENTNET-B3", Jurnal Informatika dan Teknik Elektro Terapan, 2026 Publication	<1%
32	Submitted to Universitas Muhammadiyah Palembang Student Paper	<1%
33	Submitted to UPN Veteran Yogyakarta Student Paper	<1%
34	archive.umsida.ac.id Internet Source	<1%

scholar.unand.ac.id

35	Internet Source	<1%
36	repository.its.ac.id Internet Source	<1%
37	www.repository.trisakti.ac.id Internet Source	<1%
38	Harditya Prayoga, De Rosal Ignatus Moses Setiadi, HENDY Kurniawan. "Application of Machine Learning and Deep Learning to Predict Financial Product Subscriptions Based on Customer Features", INOVTEK Polbeng - Seri Informatika, 2025 Publication	<1%
39	Kirk Ezra Rofran, Fergie Joanda Kaunang. "Analisis Sentimen Pengguna Instagram terhadap Kebijakan Nadiem Makarim yang Memperbolehkan Mahasiswa Lulus Tanpa Skripsi menggunakan Metode Analisis VADER dan Metode Klasifikasi Naïve Bayes", INTECOMS: Journal of Information Technology and Computer Science, 2024 Publication	<1%
40	e-journal.uajy.ac.id Internet Source	<1%
41	repository.upnjatim.ac.id Internet Source	<1%
42	sipora.polije.ac.id Internet Source	<1%
43	docplayer.info Internet Source	<1%
44	repo.darmajaya.ac.id	

	Internet Source	<1%
45	repositori.telkomuniversity.ac.id Internet Source	<1%
46	indo-intellectual.id Internet Source	<1%
47	Hidayat Hidayat, Musliadi KH, Indar Kusmanto, Munawirah Kadir, Kristian Kristian. "Klasifikasi Mahasiswa Calon Penerima Beasiswa KIP Menggunakan Algoritma Naive Bayes di Universitas Tomakaka Mamuju", JURNAL FASILKOM, 2025 Publication	<1%
48	Lely Kurniawati, Dadang Priyanto, Neny Sulistia Ningsih, Moch Syahrir, Ria Rismayati. "Comparison of Decision Tree-Based Methods in Lung Disease Detection", Jurnal Bumigora Information Technology (BITe), 2025 Publication	<1%
49	Submitted to Sriwijaya University Student Paper	<1%
50	Submitted to Sultan Agung Islamic University Student Paper	<1%
51	ejournal-binainsani.ac.id Internet Source	<1%
52	informasiinteraktif.janabadra.ac.id Internet Source	<1%
53	kc.umn.ac.id Internet Source	<1%
54	repository.stiki.ac.id Internet Source	<1%

55	Muhamad Rizki, Aditya Eka Danneswara, Yesa Dwi Aprilia, Muhammad Fatir Rizky Al Fajri, Yayan Hendrian, Shynde Limar Kinanti. "Prediksi Harga Saham Bank BRI dan Bank BCA dengan Menggunakan Model LSTM", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025 Publication	<1%
56	Submitted to Perpustakaan Student Paper	<1%
57	Submitted to Universitas Dinamika Student Paper	<1%
58	Submitted to University of Dundee Student Paper	<1%
59	senapan.upnjatim.ac.id Internet Source	<1%
60	Nindri Lia Desmita, Syahrani Lonang, Danang Tejo Kumoro. " COMPARATIVE ANALYSIS OF DECISION TREE AND RANDOM FOREST ALGORITHMS FOR PREDICTING DIABETES MELLITUS ", SainsTech Innovation Journal, 2025 Publication	<1%
61	doaj.org Internet Source	<1%
62	journal.irpi.or.id Internet Source	<1%
63	docobook.com Internet Source	<1%
64	eprints.uns.ac.id Internet Source	<1%

65	jurnal.polinela.ac.id Internet Source	<1 %
66	www.coursehero.com Internet Source	<1 %
67	yudisium.stmik-wp.ac.id Internet Source	<1 %
68	123dok.com Internet Source	<1 %
69	cdn.juris.id Internet Source	<1 %
70	eprints.walisongo.ac.id Internet Source	<1 %
71	id.123dok.com Internet Source	<1 %
72	repo.uinsatu.ac.id Internet Source	<1 %
73	www.jurnal.polgan.ac.id Internet Source	<1 %
74	Alidza Septia Wulansari, Nuril Lutvi Azizah, Irwan Alnarus Kaustar, Yunianita Rahmawati. "Smart Wast Management: Optimalisasi Pengolahan Sampah Rumah Tangga Berbasis Android", Jurnal Komunikasi Bisnis dan Teknologi Digital, 2025 Publication	<1 %
75	Egia Rosi Subhiyakto, Yani Parti Astuti, Nathaniel Alexander, Etika Kartikadarma. "Analisis Sentimen Menggunakan Metode Naïve Bayes Untuk Mengetahui Respon Masyarakat Terhadap Vaksinasi", Jurnal Ilmiah	<1 %

Intech : Information Technology Journal of
UMUS, 2022

Publication

-
- 76 Junaedi, Alexius Hendra Gunawan, Verri Kuswanto, Jonathan. "Tinjauan Support Vector Machine dalam Text-Mining untuk Analisis Sentimen di Sektor Pariwisata", bit-Tech, 2024 <1%
Publication
-
- 77 Muhamad Ali Zaenal Abidin. "Evaluasi Sentimen Ulasan Pengguna CGV Cinemas Indonesia Menggunakan Metode Naïve Bayes dan Support Vector Machine", Indonesian Journal on Software Engineering (IJSE), 2025 <1%
Publication
-
- 78 Muhammad Hanif, Garno, Asep Jamaludin. "ANALISIS SENTIMEN PENGGUNA APLIKASI QPON PADA ULASAN PLAY STORE MENGGUNAKAN SUPPORT VECTOR MACHINE (SVM)", PROSISKO: Jurnal Pengembangan Riset dan Observasi Sistem Komputer, 2026 <1%
Publication
-
- 79 Tata Arya Cahyaaty, Herlawati Herlawati, Andy Achmad Hendhar Setiawan. "Model Prediksi Kondisi Kesehatan dari Data Medical Check-Up Menggunakan K-Nearest Neighbors dan Decision Tree", Journal of Students' Research in Computer Science, 2025 <1%
Publication
-
- 80 Tisa Livia Zilka, Faisal Hidayat. "Analisis Kelayakan Finansial Usaha Ternak Itik Petelur Wijaya Farm di Nagari Jawi-Jawi Kecamatan <1%

Gunung Talang Kabupaten Solok Berdasarkan Perspektif Islam", ARZUSIN, 2026

Publication

81	Submitted to UIN Sultan Syarif Kasim Riau Student Paper	<1 %
82	digilib.uin-suka.ac.id Internet Source	<1 %
83	eprints.umpo.ac.id Internet Source	<1 %
84	journal.nurulfikri.ac.id Internet Source	<1 %
85	jurusan.tik.pnj.ac.id Internet Source	<1 %
86	mdpi-res.com Internet Source	<1 %
87	media.neliti.com Internet Source	<1 %
88	rama.unimal.ac.id Internet Source	<1 %
89	securityphresh.com Internet Source	<1 %
90	www.bantuanhukum.or.id Internet Source	<1 %
91	zebradoc.tips Internet Source	<1 %
92	Achmad Hakim Qoirul Haq, Harminto Mulyo, Adi Sucipto. "Optimasi Kinerja Algoritma K-Nearest Neighbor melalui Metode Random Forest untuk Klasifikasi Penyakit Ginjal", Jurnal	<1 %

JTIK (Jurnal Teknologi Informasi dan
Komunikasi), 2026

Publication

93 Amser Pangaribuan, Muhammad Rafi Al Latif, Alfian Panji Syahputra, Muhammad Fauzan, Fadli Azhima, Mohammad Naufal Fathur Rahman. "Analisa Perbandingan Metode Klasifikasi Data Mining untuk Menentukan Tingkat Kemiskinan", Jurnal Pengabdian Masyarakat dan Riset Pendidikan, 2026
Publication

<1 %

94 Baik Budi. "PENILAIAN KUALITAS UDARA DAN ANALISIS POLUSI BERBASIS ALGORITMA NAIVE BAYES DAN KLUSTERISASI DATA DENGAN K-MEANS", Jurnal Informatika dan Teknik Elektro Terapan, 2025
Publication

<1 %

95 doku.pub
Internet Source

<1 %

96 eprints.iain-surakarta.ac.id
Internet Source

<1 %

Exclude quotes Off

Exclude matches Off

Exclude bibliography Off
