KLASIFIKASI *FAST-MOVING* DAN *SLOW-MOVING* TERHADAP DATA TRANSAKSI PENJUALAN MENGGUNAKAN ALGORITMA XGBOOST PADA PT RODES CHEMINDO

SKRIPSI

DISUSUN OLEH

FELISIA AQUERAH

NPM. 2209010033

PROGRAM STUDI SISTEM INFORMASI

FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI

UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA

MEDAN

2026

KLASIFIKASI *FAST-MOVING* DAN *SLOW-MOVING* TERHADAP DATA TRANSAKSI PENJUALAN MENGGUNAKAN ALGORITMA XGBOOST PADA PT RODES CHEMINDO

SKRIPSI

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

FELISIA AQUERAH
NPM. 2209010033

PROGRAM STUDI SISTEM INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA
MEDAN
2026

LEMBAR PENGESAHAN

Judul Skripsi	:	KLASIFIKASI *FAST-MOVING* DAN *SLOW-MOVING* TERHADAP DATA TRANSAKSI PENJUALAN MENGGUNAKAN ALGORITMA XGBOOST PADA PT RODES CHEMINDO
Nama Mahasiswa	:	FELISIA AQUERAH
NPM	:	2209010033
Program Studi	:	SISTEM INFORMASI

Menyetujui
Komisi Pembimbing

(Mahardika Abdi Prawira, S.Kom., M.Kom)
NIDN. 0117088902

Ketua Program Studi

(Mahardika Abdi Prawira, S.Kom., M.Kom)
NIDN. 0117088902

Dekan

(Assoc. Prof Dr. Al-Khowarizmi, S.Kom., M.Kom.)
NIDN. 0127099201

PERNYATAAN ORISINALITAS

KLASIFIKASI *FAST-MOVING* DAN *SLOW-MOVING* TERHADAP DATA TRANSAKSI PENJUALAN MENGGUNAKAN ALGORITMA XGBOOST PADA PT RODES CHEMINDO

SKRIPSI

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

Medan, September 2026

Yang membuat pernyataan



Felisia Aquerah

NPM. 2209010033

PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

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

Nama	: Felisia Aquerah
NPM	: 2209010033
Program Studi	: Sistem 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:

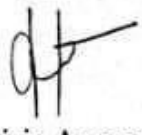
KLASIFIKASI *FAST-MOVING* DAN *SLOW-MOVING* TERHADAP DATA TRANSAKSI PENJUALAN MENGGUNAKAN ALGORITMA XGBOOST PADA PT RODES CHEMINDO

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, September 2026

Yang membuat pernyataan



Felisia Aquerah

NPM. 2209010033

RIWAYAT HIDUP

DATA PRIBADI

Nama Lengkap	: Felisia Aquerah
Tempat dan Tanggal Lahir	: Medan, 24 April 2005
Alamat Rumah	: Jl. Bunga Cempaka VI PSR III
Telepon/Faks/HP	082268135248
E-mail	: fellisaq1@gmail.com
Instansi Tempat Kerja	: -
Alamat Kantor	: -

DATA PENDIDIKAN

SD	: MIN Tanjung Sari Medan	TAMAT: 2016
SMP	: SMP Swasta Muhammadiyah -3 Medan	TAMAT: 2019
SMA	: SMK Swasta Telkom Sandhy Putra Medan	TAMAT: 2022

KATA PENGANTAR



Puji dan syukur penulis panjatkan ke hadirat Tuhan Yang Maha Esa atas segala rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi ini dengan baik. Skripsi ini disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer pada Program Studi Sistem Informasi, Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara.

Penulis tentunya berterima kasih kepada berbagai pihak dalam dukungan serta doa dalam penyelesaian skripsi. Penulis juga mengucapkan terima kasih kepada:

1. Bapak Prof. Dr. Akrim, M.Pd., Rektor Universitas Muhammadiyah Sumatera Utara (UMSU).
2. Bapak Assoc. Prof. Dr. Al-Khowarizmi, S.Kom., M.Kom., Dekan Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
3. Ibu Dr. Firahmi Rizky, S.Kom., M.Kom., selaku Wakil Dekan I Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
4. Bapak Mhd. Basri, S.Si, M.Kom., selaku Wakil Dekan III Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
5. Bapak Mahardika Abdi Prawira, S.Kom., M.Kom., selaku Ketua Program Studi Sistem Informasi sekaligus Dosen Pembimbing yang dengan penuh kesabaran telah membimbing penulis. Terima kasih atas arahan, kritik, dan ilmu yang diberikan, yang tidak hanya membantu penulis dalam menyelesaikan skripsi ini, tetapi juga memahami proses belajar itu sendiri.
6. Bapak Mulkan Azhari, S.Kom, M.Kom., selaku Sekretaris Program Studi Sistem Informasi Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
7. Dengan penuh cinta, skripsi ini penulis persembahkan kepada kedua orang tua tercinta, Ibu Erlini Damanik dan Ayah Nasip Priyanto. Terima kasih atas doa yang tidak pernah terputus, atas kepercayaan yang tidak pernah hilang, dan atas segala pengorbanan yang sering kali tidak terucap. Dalam setiap

langkah penulis, selalu ada doa kalian yang menguatkan. Skripsi ini mungkin tidak sebanding dengan semua yang telah kalian berikan, namun semoga dapat menjadi salah satu alasan untuk tersenyum dan merasa bangga. Penulis juga mengucapkan terima kasih kepada abang tersayang, Pandu Ananta, yang selalu hadir dengan dukungan, perhatian, dan semangat di setiap kondisi yang penulis hadapi.

8. Kepada seluruh pihak di PT Rodes yang telah memberikan izin, dukungan, serta membantu penulis dalam memperoleh data yang dibutuhkan dalam penelitian ini sehingga proses penyusunan skripsi dapat berjalan dengan baik.
9. Kepada teman seperjuangan penulis selama masa perkuliahan, Siti Rahma Wati (NPM: 2209010038), terima kasih atas kebersamaan, dukungan, serta cerita yang telah kita lalui bersama. Perjalanan ini tentu tidak mudah, tetapi kehadiranmu menjadi salah satu bagian penting yang membuat setiap proses terasa lebih ringan untuk dijalani.
10. Kepada teman-teman di luar lingkungan kampus yang tidak dapat disebutkan satu per satu, terima kasih atas kebersamaan, tawa, serta waktu yang telah dilalui bersama. Momen-momen sederhana yang kita lalui menjadi pengingat bahwa di tengah segala kesibukan dan tekanan, selalu ada alasan untuk kembali tersenyum
11. Dan terakhir, untuk diri penulis sendiri. Terima kasih karena telah bertahan sejauh ini. Terima kasih karena tidak menyerah meskipun sering merasa lelah, tidak berhenti meskipun sempat ragu, dan tetap melangkah meskipun jalannya tidak selalu jelas. Perjalanan ini tidak mudah, tetapi hari ini menjadi bukti bahwa semua usaha, sekecil apa pun, tidak pernah sia-sia.

KLASIFIKASI *FAST-MOVING* DAN *SLOW-MOVING* TERHADAP DATA TRANSAKSI PENJUALAN MENGGUNAKAN ALGORITMA XGBOOST PADA PT RODES CHEMINDO

ABSTRAK

Salah satu komponen kunci dalam mendukung operasional perusahaan adalah manajemen persediaan, terutama dalam menentukan ketersediaan dan pergerakan produk. PT Rodes Chemindo masih mengidentifikasi barang-barang yang cepat laku dan lambat laku secara manual menggunakan *Microsoft Excel*. Prosedur ini tidak memanfaatkan sepenuhnya data transaksi perusahaan yang sangat besar, relatif memakan waktu, dan rentan terhadap kesalahan manusia. Metode *Extreme Gradient Boosting* (XGBoost) akan digunakan dalam penelitian ini untuk menganalisis dan mengkategorikan barang berdasarkan pergerakannya ke dalam kategori "Barang yang Cepat Terjual" dan "Barang yang Lambat Terjual". Selain itu, sistem berbasis web akan dikembangkan untuk mengotomatiskan proses klasifikasi ini. Kumpulan data ini terdiri dari 17.973 transaksi penjualan PT Rodes Chemindo yang tercatat antara Januari dan Desember 2025. Sebanyak 413 item berbeda diidentifikasi sebagai objek klasifikasi dengan menggunakan jumlah penjualan total (total_qty) dan frekuensi transaksi sebagai fitur utama setelah prapemrosesan data, agregasi, dan rekayasa fitur. Rasio Perputaran (*Turnover Ratio*/TOR) digunakan untuk menentukan kategori Barang yang Cepat Terjual dan Barang yang Lambat Terjual. Selanjutnya, dataset tersebut dibagi menjadi 330 set pelatihan dan 83 set uji dengan rasio 80:20 dan *random_state* = 42. Teknik XGBoost, dengan laju pembelajaran sebesar 0,1, kedalaman pohon maksimum 5, dan 100 estimator, digunakan untuk membangun model klasifikasi. *Confusion Matrix*, *Accuracy*, *Precision*, *Recall*, dan *F1-Score* digunakan untuk mengevaluasi kinerja model. Model XGBoost mencapai nilai *Accuracy*, *Precision*, *Recall*, dan *F1-Score* sebesar 1,00 atau 100%, berdasarkan hasil evaluasi terhadap 83 titik data uji. Hal ini berarti seluruh data uji diklasifikasikan dengan benar sesuai dengan label yang telah ditentukan sebelumnya dalam dataset penelitian. Model tersebut kemudian diintegrasikan ke dalam sistem berbasis web yang mendukung pengunggahan data, pemrosesan, klasifikasi, serta penyajian hasil melalui tabel dan visualisasi menggunakan *Flask* dan MySQL. Untuk meningkatkan pengambilan keputusan dalam manajemen persediaan PT Rodes Chemindo, algoritma XGBoost dapat diimplementasikan dalam sistem berbasis web guna mengotomatiskan klasifikasi produk dan menghasilkan data yang lebih terorganisir.

Kata Kunci: *Fast-Moving*; *Slow-Moving*; Data Transaksi Penjualan; XGBoost; Klasifikasi.

CLASSIFICATION OF FAST-MOVING AND SLOW-MOVING ITEMS BASED ON SALES TRANSACTION DATA USING THE XGBOOST ALGORITHM AT PT RODES CHEMINDO

ABSTRACT

One of the key components in supporting a company's operations is inventory management, particularly in determining product availability and movement. PT Rodes Chemindo still identifies fast-moving and slow-moving items manually using Microsoft Excel. This procedure does not fully utilize the company's vast transaction data, is relatively time-consuming, and is prone to human error. The Extreme Gradient Boosting (XGBoost) method will be used in this project to analyze and categorize items based on their movement into the "Fast-Moving Items" and "Slow-Moving Items" categories. Additionally, a web-based system will be developed to automate this classification process. This dataset consists of 17,973 sales transactions from PT Rodes Chemindo recorded between January and December 2025. A total of 413 distinct items were identified as classification objects using total sales quantity (total_qty) and transaction frequency as the primary features following data preprocessing, aggregation, and feature engineering. The Turnover Ratio (TOR) was used to determine the categories of Fast-Moving Items and Slow-Moving Items. Subsequently, the dataset was split into 330 training sets and 83 test sets with an 80:20 ratio and random_state = 42. The XGBoost technique, with a learning rate of 0.1, a maximum tree depth of 5, and 100 estimators, was used to build the classification model. The confusion matrix, accuracy, precision, recall, and F1-score were used to evaluate the model's performance. The XGBoost model achieved Accuracy, Precision, Recall, and F1-Score values of 1.00 or 100%, based on the evaluation results of the 83 test data points. This means that all test data were correctly classified according to the labels previously defined in the research dataset. The model was then integrated into a web-based system that supports data upload, processing, classification, and the presentation of results through tables and visualizations using Flask and MySQL. To improve decision-making in PT Rodes Chemindo's inventory management, the XGBoost algorithm can be implemented in a web-based system to automate product classification and generate more organized data.

Keywords: Fast-Moving; Slow-Moving; Sales Transaction Data; XGBoost; Classification.

DAFTAR ISI

HALAMAN SAMPUL ..... **i**
LEMBAR PENGESAHAN ..... **iii**
PERNYATAAN ORISINALITAS ..... **iv**
PERNYATAAN PERSETUJUAN PUBLIKASI ..... **v**
RIWAYAT HIDUP ..... **vi**
KATA PENGANTAR ..... **vii**
ABSTRAK ..... **ix**
ABSTRACT ..... **x**
DAFTAR ISI ..... **xi**
DAFTAR TABEL ..... **xiv**
DAFTAR GAMBAR ..... **xvi**
BAB I PENDAHULUAN **1**
1.1. Latar Belakang Masalah 1
1.2. Rumusan Masalah 6
1.3. Batasan Masalah 7
1.4. Tujuan Penelitian 8
1.5. Manfaat Penelitian 8
BAB II LANDASAN TEORI **10**
2.1. Manajemen Persediaan 10
2.1.1. Manajemen Persediaan 10
2.1.2. Tujuan dan Fungsi Manajemen Persediaan 11
2.1.3. Jenis Persediaan dan Klasifikasinya 13
2.1.4. Model dan Metode Pengendalian Persediaan 13
2.1.5. Peran Sistem Informasi dalam Manajemen Persediaan 14
2.2. Fast-Moving dan Slow-Moving Item 15
2.2.1. Definisi Fast-Moving Item 15
2.2.2. Definisi Slow-Moving Item 16
2.2.3. Faktor Penyebab Perubahan Kecepatan Pergerakan Barang 16
2.2.4. Dampak Fast-Moving & Slow-Moving pada Operasional Perusahaan ... 17
2.2.5. Indikator Penilaian Fast / Slow Moving 19
2.3. Data Mining 21

2.3.1. Data Mining 21
2.3.2. Knowledge Discovery in Database (KDD) 23
2.4. Classification (Klasifikasi) 24
2.5. Unified Modeling Language (UML) 25
2.6. Penelitian Terdahulu 32
BAB III ANALISA DAN PERANCANGAN SISTEM 39
3.1. Jenis dan Pendekatan Penelitian 39
3.2. Analisis Permasalahan dan Metode Analisis 41
3.3. Teknik Pengumpulan Data 45
3.4. Algoritma Extreme Gradient Boosting (XGBoost) 47
3.4.1. Pengertian Algoritma XGBoost 47
3.4.2. Mekanisme Dasar Boosting 48
3.4.3. Struktur Model dalam XGBoost (Decision Trees & Boosting Iteration) 48
3.4.4. Rumus XGBoost 49
3.4.5. Langkah–Langkah Perhitungan XGBoost 51
3.4.6. Contoh Perhitungan Sederhana XGBoost 52
3.4.7. Parameter Penting XGBoost 55
3.4.8. Kelebihan XGBoost dibanding Model Lain 56
3.4.9. Kelemahan XGBoost 57
3.5. Perancangan Sistem 58
3.5.1. Flowchart Sistem 58
3.5.2. Struktur Data 59
3.5.3. Use Case Diagram 62
3.5.4. Activity Diagram 64
3.5.5. Sequence Diagram 66
3.5.6. Class Diagram 68
BAB IV IMPLEMENTASI DAN PENGUJIAN SISTEM 73
4.1. Kebutuhan Sistem 73
4.2. Implementasi Sistem 76
4.2.1. Gambaran dan Arsitektur Sistem 77
4.2.2. Implementasi dan Pembagian Dataset 81
4.2.3. Implementasi Klasifikasi XGBoost 85

4.2.4. Implementasi Antar Muka.....88
4.3. Pengujian Sistem dan Performa Model.....102
4.4. Analisis Kinerja Model, Data Penjualan, dan Implikasi Strategis.....114
4.5. Validasi Sistem, Kelebihan, dan Kekurangan Aplikasi.....121
BAB V PENUTUP.....125
5.1. Kesimpulan.....125
5.2. Saran.....126
DAFTAR PUSTAKA.....128
DAFTAR LAMPIRAN.....135

DAFTAR TABEL

Tabel 2.1 Simbol-simbol Use Case Diagram 26
Tabel 2.2 Simbol-simbol Activity Diagram 28
Tabel 2.3 Simbol-simbol Sequence Diagram 29
Tabel 2.4 Simbol-simbol Class Diagram 31
Tabel 2.5 Penelitian Terdahulu 33
Tabel 3.1 Rumus XGBoost 50
Tabel 3.2 Contoh Perhitungan Sederhana XGBoost 52
Tabel 3.3 Tabel Produk 61
Tabel 3.4 Tabel Transaksi 61
Tabel 3.5 Tabel Hasil_Klasifikasi 62
Tabel 3.6 Peran Aktor 63
Tabel 3.7 Definisi Use Case Sistem 63
Tabel 4.1 Struktur Atribut Dataset Transaksi Penjualan 82
Tabel 4.2 Ringkasan Dataset Utama Periode 2025 84
Tabel 4.3 Hasil Pengujian Fungsional (Blackbox Testing) Sistem 103
Tabel 4.4 Pemetaan Confusion Matrix Data Uji Aktual 111
Tabel 4.5 Hasil Evaluasi Akhir Performa Model XGBoost 112
Tabel 4.6 Data Penjualan AQUAPROOF PUTIH @4KG 116
Tabel 4.7 Data Penjualan BASILIUM @500ML 116
Tabel 4.8 Data Penjualan INTRA WHITE 12C75 117
Tabel 4.9 Data Penjualan MAT 300 JUSHI 1040 @30KG 117
Tabel 4.10 Data Penjualan POLYTANK CAHAYA @200L 117
Tabel 4.11 Data Penjualan SELANG HITPRO 1/2" @20M 118

Tabel 4.12 Data Penjualan SEPATU LYONS 118

Tabel 4.13 Data Penjualan SILICONE EMULSION 320 HV 119

Tabel 4.14 Data Penjualan TRANSPARENT 1/4" 100M.....119

Tabel 4.15 Data Penjualan YELLOW METERAN 5MM 119

DAFTAR GAMBAR

Gambar 3.1 Flowchart Sistem 59
Gambar 3.2 Relasi Antar Tabel (ERD) 60
Gambar 3.3 Use Case Diagram Sistem 63
Gambar 3.4 Activty Diagram 65
Gambar 3.5 Sequence Diagram 67
Gambar 3.6 Class Diagram 68
Gambar 4.1 Halaman Login 90
Gambar 4.2 Tampilan Dashboard 91
Gambar 4.3 Tampilan Unggah Data Transaksi 93
Gambar 4.4 Tampilan Tambah Manual Data Transaksi 94
Gambar 4.5 Tampilan Pemilihan Range Klasifikasi 95
Gambar 4.6 Tampilan Header Dan Statistik 96
Gambar 4.7 Tampilan Tabel Rincian Hasil Klasifikasi Stok 97
Gambar 4.8 Tampilan Matriks Penjualan Bulanan 1 98
Gambar 4.9 Tampilan Matriks Penjualan Bulanan 2 99
Gambar 4.10 Tampilan Hasil Ekspor Excel 100
Gambar 4.11 Tampilan Hasil Ekspor PDF 101
Gambar 4.12 Baris Kode Implementasi Kelas Model XGBoost 115

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Persediaan merupakan salah satu faktor terpenting dalam operasional bisnis karena berkaitan erat dengan ketersediaan produk, efisiensi pembayaran, dan kelancaran proses distribusi. Sebagaimana dijelaskan oleh (Suriyani et al., 2020) dalam penelitian mereka yang berjudul *"Analisis Perencanaan dan Pengawasan Persediaan Barang Dagang pada CV. Sumber Indoraya"* pengelolaan persediaan melibatkan proses perencanaan, pengawasan, dan pengendalian jumlah barang agar kegiatan produksi dan distribusi berjalan secara efisien dan efektif tanpa menimbulkan pemborosan sumber daya. Dalam konteks perusahaan yang mendistribusikan produk kimia, seperti PT Rodes Chemindo, pengelolaan persediaan memiliki pendekatan strategis karena setiap produk memiliki tingkat penjualan yang berbeda-beda, mulai dari yang bergerak cepat (*Fast-Moving*) hingga yang bergerak lambat (*Slow-Moving*). Pengelolaan yang tepat membantu perusahaan menghindari penumpukan atau kekurangan stok yang dapat menghambat proses distribusi.

Secara umum, pengelompokan produk berdasarkan tingkat pergerakan stok dikenal sebagai *Fast*, *Slow*, dan *Non-Moving* (FSN). (Rodjimin et al., 2023) menjelaskan bahwa metode FSN mengklasifikasikan produk berdasarkan frekuensi perputaran selama periode berjalan dengan menggunakan indikator *Turn Over Ratio* (TOR). Nilai TOR yang tinggi menunjukkan bahwa produk tersebut bergerak cepat, sedangkan nilai TOR yang rendah menunjukkan bahwa produk tersebut

bergerak lambat atau tidak bergerak sama sekali. Menurut penelitian (Habibi & Ulkhaq, 2025) penerapan metode FSN membantu bisnis mengoptimalkan proses pembelian barang guna meminimalkan biaya penyimpanan. Berdasarkan relevansi kebutuhan bisnis, penelitian ini berfokus pada dua kategori utama, yaitu *Fast-Moving* dan *Slow-Moving*, karena keduanya memiliki dampak terbesar terhadap stok dan pengambilan keputusan di PT Rodes Chemindo.

Kumpulan data transaksi penjualan yang diperoleh dari PT Rodes Chemindo mencakup seluruh periode dari tahun 2024 hingga 2026, dengan total 46.025 transaksi. Seluruh kumpulan data multi-tahun tersebut digunakan dalam implementasi sistem informasi guna meningkatkan fungsionalitas visualisasi grafis dan rekap matriks penjualan bulanan pada dasbor, sehingga manajemen dapat mengelola tren penjualan makro secara dinamis. Namun, untuk memenuhi persyaratan pemodelan *machine learning*, penelitian ini berfokus pada analisis yang hanya menggunakan data transaksi dari Januari hingga Desember 2025, dengan total sekitar 17.973 data. Periode satu tahun ini dipilih agar penjualan produk yang dipelajari dari model menjadi lebih stabil, konsisten, dan tidak terpengaruh oleh tren yang berfluktuasi antar tahun. Dengan jumlah data yang begitu besar, penggunaan *spreadsheet* untuk pengelolaan data tidaklah efisien. Pengolahan manual memerlukan perhitungan berdasarkan rumus (berbasis aturan), yang bersifat rumit dan harus diulang setiap kali dilakukan pengumpulan data. Hal ini juga membutuhkan waktu komputasi yang lama, serta kewaspadaan terhadap kesalahan manusia. Sebagaimana terlihat dari rata-rata jumlah transaksi bisnis, frekuensi aktivitas penjualan bisnis menunjukkan bahwa ketergantungan pada

metode *spreadsheet* manual akan menjadi tantangan operasional yang serius seiring dengan terus meningkatnya volume data transaksi dari waktu ke waktu.

Untuk meningkatkan akurasi dan efisiensi dalam proses klasifikasi produk, diperlukan pendekatan berbasis pembelajaran mesin yang mampu melakukan klasifikasi secara otomatis dan tepat. *Extreme Gradient Boosting* (XGBoost) adalah salah satu algoritma yang digunakan dalam pembelajaran terawasi. Menurut (Massaro et al., 2021) XGBoost merupakan algoritma *ensemble* yang didasarkan pada teknik *decision tree boosting* yang memiliki keunggulan dalam hal akurasi, kecepatan, dan efisiensi komputasi, terutama saat digunakan untuk mengklasifikasikan data dalam jumlah besar. Berdasarkan temuan (Kurniawansyah et al., 2025) algoritma *Extreme Gradient Boosting* (XGBoost) dapat meningkatkan akurasi klasifikasi melalui mekanisme *boosting* pohon yang terstruktur dan optimal.

Beberapa penelitian mendukung kemampuan XGBoost dalam meningkatkan akurasi prediksi. Efektivitas XGBoost ditunjukkan dalam penelitian (Wang, 2023) pada artikel berjudul *"Sales Forecast of Retail Commodity on the Basis of LightGBM and XGBoost"*, yang menunjukkan bahwa penggunaan XGBoost dapat mengurangi *Mean Absolute Error* hingga 29% jika dibandingkan dengan metode konvensional. Hasil ini sejalan dengan penelitian (Astrani & Rahayuda, 2025) berjudul *"Analisis Perbandingan XGBoost dan LightGBM dalam Prediksi Penjualan Ritel Walmart Store Sales"*, yang menemukan bahwa algoritma *Gradient Boosting Decision Tree* dapat meningkatkan akurasi hingga 92% jika dibandingkan dengan *K-Nearest Neighbors* (KNN). Teknik *boosting* ini juga dievaluasi oleh (Arai et al., 2023) melalui sebuah studi berjudul *"Churn Customer Estimation Method Based on LightGBM for Improving Sales"*, yang menunjukkan

bahwa algoritma *boosting* seperti XGBoost dan LightGBM memiliki kinerja yang lebih baik daripada metode tradisional dalam menganalisis perilaku pelanggan dan data penjualan. Faktor-faktor ini menunjukkan bahwa model *boosting* dapat memberikan hasil klasifikasi yang lebih stabil dan akurat dalam konteks pengumpulan data berskala besar. Saat ini, PT Rodes Chemindo masih menggunakan *spreadsheet* seperti *Microsoft Excel* untuk entri data secara manual. Meskipun *Excel* berguna untuk entri data dasar, terdapat perbedaan dalam proses entri data yang dapat diamati karena proses klasifikasi masih dilakukan melalui penggunaan rumus tertentu (berbasis aturan). Situasi ini menyebabkan fleksibilitas dalam pemrosesan data menjadi lebih sulit ketika volume data meningkat, serta berpotensi menimbulkan kesulitan dalam menafsirkan data penjualan.

Baik *Excel* maupun algoritma XGBoost sama-sama menggunakan data transaksional sebagai landasan analisis. Namun, perbedaan di antara keduanya bergantung pada cara data tersebut dianalisis. *Excel* berfungsi sebagai alat entri data manual sehingga pengguna dapat melakukan analisis dengan cara yang sederhana. Selain itu, XGBoost adalah algoritma pembelajaran mesin yang dapat secara otomatis mempelajari data historis melalui analisis model. Melalui proses pembelajaran model berdasarkan fitur agregat seperti jumlah total yang terjual (total_qty) dan frekuensi transaksi produk, XGBoost dapat mengidentifikasi hubungan kompleks antar variabel dalam dataset, sehingga menghasilkan klasifikasi produk yang lebih akurat dibandingkan dengan metode manual. Oleh karena itu, penggunaan algoritma XGBoost memungkinkan analisis data diselesaikan lebih cepat dan menghasilkan hasil yang lebih akurat daripada menggunakan *spreadsheet*. Selain itu, penggunaan algoritma XGBoost

memungkinkan pengklasifikasian data secara otomatis, sehingga lebih fleksibel dibandingkan dengan menggunakan *spreadsheet* untuk entri data secara manual.

Mengingat volume transaksi yang terus meningkat dan kompleksitas penjualan yang semakin tinggi dari waktu ke waktu, perusahaan harus menerapkan teknik analisis yang lebih fleksibel dan berbasis data. Penggunaan metode manual tidak hanya mempercepat proses analisis, tetapi juga berpotensi menghasilkan klasifikasi yang kurang akurat karena tidak mampu memanfaatkan pola data historis secara optimal.

Selain menggunakan algoritma XGBoost, penelitian ini juga mengembangkan sistem klasifikasi berbasis web. Tujuan dari integrasi sistem berbasis web ini adalah untuk memudahkan para manajer PT Rodes Chemindo dalam mengoperasikan model pembelajaran mesin tanpa harus memahami kode program yang rumit. Melalui sistem ini, pengguna dapat memasukkan data transaksi dengan dua cara; Baik dengan mengimpor dataset dalam format *Comma Separated Values* (.CSV) maupun dengan memasukkan data secara manual menggunakan rumus-rumus yang tersedia di sistem. Data tersebut kemudian diproses menggunakan teknik prapemrosesan, seperti analisis data duplikat dan data kosong, ekstraksi dan agregasi fitur, serta klasifikasi menggunakan algoritma XGBoost untuk menentukan kategori produk *Fast-Moving* dan *Slow-Moving*. Data yang dikumpulkan secara manual akan dimasukkan ke dalam basis data agar dapat digunakan dalam proses analisis. Selanjutnya, sistem berbasis web ini menampilkan visualisasi hasil klasifikasi dalam bentuk tabel dan grafik distribusi produk, serta *spreadsheet* dalam format *Excel* (.xlsx) dan PDF. Berkat sistem ini, proses analisis yang sebelumnya dilakukan secara manual kini dapat diselesaikan dengan lebih

cepat, sistematis, dan terstruktur, sehingga menghasilkan informasi yang dapat mendukung pengambilan keputusan operasional dan kegiatan bisnis.

Berdasarkan penelitian yang disebutkan di atas, algoritma XGBoost terbukti cocok untuk mengklasifikasikan produk *Fast-Moving* dan *Slow-Moving* berdasarkan data transaksi penjualan di PT Rodes Chemindo. Diharapkan sistem klasifikasi berbasis *machine learning* ini dapat meningkatkan akurasi analisis data, mempermudah proses pengumpulan data, serta membantu perusahaan dalam mengambil keputusan yang lebih efektif terkait persediaan.

Namun, penelitian sebelumnya umumnya hanya berfokus pada analisis klasifikasi tanpa mengintegrasikan sistem berbasis web secara langsung. Oleh karena itu, penelitian ini tidak hanya menggunakan algoritma XGBoost untuk klasifikasi, tetapi juga mengembangkan sistem berbasis web untuk mengotomatisasi proses analisis.

Berdasarkan penelitian yang disebutkan di atas, peneliti tertarik melakukan penelitian dengan judul: “Klasifikasi *Fast-Moving* dan *Slow-Moving* terhadap Data Transaksi Penjualan Menggunakan Algoritma XGBoost pada PT Rodes Chemindo”.

1.2. Rumusan Masalah

Berdasarkan uraian mengenai latar belakang masalah, rumusan masalah dalam penelitian ini dapat diringkas sebagai berikut:

1. Bagaimana data penjualan produk dari PT Rodes Chemindo dapat dianalisis untuk mengidentifikasi kategori *Fast-Moving* dan *Slow-Moving* secara lebih akurat?

2. Bagaimana algoritma *Extreme Gradient Boosting* (XGBoost) digunakan dalam proses klasifikasi produk berdasarkan data transaksi penjualan di PT Rodes Chemindo?
3. Bagaimana cara mengembangkan perangkat lunak berbasis web yang dapat secara otomatis mengklasifikasikan produk ke dalam kategori *Fast-Moving* dan *Slow-Moving* menggunakan algoritma XGBoost?

1.3. Batasan Masalah

Agar penelitian ini memiliki fokus yang jelas dan tidak meluas (tidak ambigu). Batasan masalah yang dibahas adalah sebagai berikut:

1. Penelitian ini hanya berfokus pada klasifikasi produk berdasarkan volume penjualan (*Fast-Moving* dan *Slow-Moving*) di PT Rodes Chemindo.
2. Data yang digunakan adalah riwayat transaksi penjualan PT Rodes Chemindo. Data transaksi tahun 2025 digunakan sebagai dataset utama untuk analisis, evaluasi, dan klasifikasi produk menggunakan algoritma XGBoost, sedangkan data transaksi tahun 2024–2026 digunakan untuk meningkatkan fungsionalitas visualisasi grafik tren makro pada dasbor sistem.
3. Metode yang digunakan dalam klasifikasi adalah algoritma XGBoost, yang termasuk kei dalam pendekatan *supervised learning*.
4. Perangkat lunak ini dikembangkan sebagai aplikasi web menggunakan bahasa pemrograman *Python* dengan kerangka kerja *Flask*, alat analisis data (*Pandas*, *NumPy*, *Scikit-Learn*), serta alat *front-end* termasuk *HTML5*, *CSS* (*Bootstrap*), dan *JavaScript*. Pengelolaan data menggunakan MySQL sebagai sistem manajemen basis data.

1.4. Tujuan Penelitian

Berdasarkan batasan masalah yang telah dibahas sebelumnya, tujuan penelitian ini adalah:

1. Menganalisis data penjualan produk PT Rodes Chemindo untuk mengidentifikasi kategori produk yang laris (*Fast-Moving*) dan produk yang kurang laris (*Slow-Moving*).
2. Menggunakan algoritma *Extreme Gradient Boosting* (XGBoost) untuk mengklasifikasikan produk berdasarkan data transaksi.
3. Membuat perangkat lunak berbasis web untuk mengklasifikasikan produk secara otomatis ke dalam kategori *Fast-Moving* dan *Slow-Moving* guna meningkatkan pengambilan keputusan dalam pengelolaan stok.

1.5. Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan beberapa manfaat, antara lain sebagai berikut bagi perusahaan, peneliti, dan perguruan tinggi:

1. Bagi PT Rodes Chemindo

   Diharapkan penelitian ini dapat membantu perusahaan mengklasifikasikan produk secara otomatis dan akurat berdasarkan data transaksi. Aplikasi yang dikembangkan menggunakan algoritma XGBoost dapat digunakan untuk mengidentifikasi produk yang laku terjual atau lambat terjual, sehingga meningkatkan efektivitas strategi distribusi dan penjualan, efisiensi pengelolaan stok, serta pengambilan keputusan pengadaan barang.

2. Bagi Peneliti

   Penelitian ini memberikan kesempatan kepada mahasiswa untuk menerapkan konsep *data mining* dan *machine learning* dalam konteks industri nyata.

Melalui penerapan algoritma XGBoost, peneliti dapat memperoleh wawasan mengenai teknik klasifikasi data, analisis penjualan, dan pengembangan aplikasi berbasis web yang berfokus pada efisiensi bisnis.

3. Bagi Universitas

   Penelitian ini diharapkan dapat berkontribusi pada pengembangan pengetahuan di bidang sistem dan teknologi informasi, khususnya dalam penerapan pembelajaran mesin untuk klasifikasi data penjualan. Hasil penelitian ini juga diharapkan dapat menjadi acuan bagi penelitian selanjutnya yang berkaitan dengan klasifikasi produk, analisis penjualan, serta penerapan algoritma pembelajaran *ensemble* dalam sistem informasi bisnis dan industri.

BAB II

LANDASAN TEORI

2.1. Manajemen Persediaan

2.1.1. Manajemen Persediaan

Manajemen persediaan merupakan komponen penting dalam manajemen operasional yang berfokus pada perencanaan, pengendalian, dan pengawasan terkait stok barang agar proses produksi dan distribusi dapat berjalan secara efisien dan terpadu. Menurut penelitian (Zahra et al., 2025) yang diterbitkan dalam Jurnal Ilmiah Ekonomi dan Manajemen, manajemen persediaan sangat penting dalam meningkatkan kinerja operasional bisnis melalui penerapan strategis kegiatan pengaturan, pengendalian, dan pengelolaan stok barang sehingga operasi dapat berjalan lebih efektif dan efisien. Berdasarkan studi ini, praktik manajemen persediaan yang efektif membantu perusahaan merencanakan operasinya, mengoptimalkan tingkat persediaan, dan meminimalkan risiko kekurangan atau kelebihan barang, yang semuanya berdampak pada kinerja operasional secara keseluruhan.

Manajemen persediaan adalah proses pembelian barang dan bahan baku dengan tujuan memastikan ketersediaan produk dalam jumlah yang memadai, pada waktu yang tepat, dan dengan biaya yang efisien. Dalam proses bisnis, persediaan berperan penting dalam kelancaran operasional baik bagi bisnis manufaktur maupun perdagangan. Oleh karena itu, pengelolaan persediaan tidak hanya berkaitan dengan pencatatan stok di gudang, tetapi juga mencakup perencanaan,

pengendalian, dan evaluasi agar kebutuhan konsumen dapat terpenuhi tanpa menimbulkan biaya yang berlebihan.

Menurut Rahman (Rahman & Nursyamsiah, 2023), manajemen persediaan merupakan faktor penting yang memengaruhi kinerja operasional perusahaan ritel di Indonesia. Tanpa pengelolaan yang baik, perusahaan akan menghadapi tantangan seperti kelebihan stok, yang meningkatkan biaya pembelian, dan kekurangan stok, yang menurunkan kepuasan pelanggan. Oleh karena itu, manajemen persediaan yang efektif memerlukan pendekatan sistematis dalam hal perencanaan, dukungan kebijakan, dan pencatatan.

Efektivitas sistem manajemen persediaan dipengaruhi oleh sejumlah faktor, termasuk permintaan konsumen, waktu tunggu, biaya penyimpanan, dan sistem informasi yang digunakan. Menurut (Munyaka & Yadavalli, 2022) keberhasilan pengelolaan persediaan sangat dipengaruhi oleh kemampuan organisasi dalam memanfaatkan teknologi informasi untuk meningkatkan proses pengambilan keputusan dan meningkatkan akurasi data stok. Dengan pengendalian yang tepat, perusahaan dapat memitigasi dampak negatif dari ketidakseimbangan antara pembelian dan pesanan, mengurangi biaya logistik, serta meningkatkan penjualan. Dengan demikian, manajemen persediaan tidak hanya berfungsi untuk memastikan ketersediaan barang, tetapi juga berperan sebagai alat penting untuk meningkatkan efisiensi operasional dan kelangsungan bisnis.

2.1.2. Tujuan dan Fungsi Manajemen Persediaan

Tujuan utamanya adalah memaksimalkan jumlah barang dagangan agar dapat memenuhi permintaan pelanggan dengan biaya operasional yang efisien. Menurut (Munyaka & Yadavalli, 2022) dalam *"Inventory Management Concepts*

and Implementations: A Systematic Review" manajemen persediaan yang efektif berkontribusi pada peningkatan produktivitas dan efisiensi organisasi. Kedua peneliti yang disebutkan di atas menyoroti pentingnya kebijakan persediaan yang dapat mengurangi waktu tunggu, pola permintaan, dan kapasitas penyimpanan. Sebaliknya, (Singh, 2022) mengklasifikasikan persediaan menjadi tiga kategori utama dalam bukunya *"Concepts of Inventory and Related Technical Terminologies: A Literature Review"* kategori-kategori tersebut meliputi bahan baku, barang dalam proses, dan barang jadi. Setiap kategori memerlukan metode pengendalian yang berbeda. Klasifikasi ini membantu bisnis menetapkan prioritas untuk pengadaan dan penyimpanan berdasarkan karakteristik dan tingkat pergerakan barang.

Tujuan utama manajemen persediaan adalah mencapai keseimbangan terbaik antara ketersediaan barang dan biaya yang terkait dengan pembelian serta penjualannya. Pengelolaan yang tepat memungkinkan perusahaan untuk secara konsisten memenuhi permintaan pelanggan, mengurangi risiko kehabisan stok, dan meningkatkan efisiensi rantai pasokan. Selain itu, manajemen persediaan juga memainkan peran penting dalam mencegah pembelian barang yang berpotensi menimbulkan masalah atau kedaluwarsa, serta mencegah biaya pembelian melalui pemesanan yang terjadwal dengan kualitas yang baik.

Menurut (Rahman & Nursyamsiah, 2023), fungsi manajemen persediaan tidak hanya terbatas pada penentuan jumlah barang; Fungsi ini juga mencakup permintaan, pengambilan keputusan pembelian, dan pengendalian stok secara berkala. Fungsi ini memastikan bahwa perusahaan memiliki informasi yang akurat mengenai tingkat konsumsi barang, pola permintaan, dan kebutuhan pengadaan di

masa mendatang. Perusahaan dapat meningkatkan produktivitas dan kualitas layanan bagi pelanggan melalui operasi yang efektif.

2.1.3. Jenis Persediaan dan Klasifikasinya

Persediaan dapat diklasifikasikan menjadi beberapa jenis, antara lain bahan baku, barang dalam proses, barang jadi, barang dagangan, suku cadang, dan perlengkapan pendukung. Setiap jenis memiliki karakteristik yang berbeda, sehingga diperlukan strategi pengelolaan yang sesuai. Fokus utama perusahaan distribusi, seperti PT Rodes Chemindo, adalah pada barang yang berkaitan dengan dagangan dan penjualan operasional. Persediaan juga dapat diklasifikasikan berdasarkan nilainya atau pergerakannya, selain berdasarkan jenisnya sesuai fungsinya. Salah satu metode yang populer dan sering digunakan adalah metode ABC, yang mengelompokkan produk berdasarkan kontribusi penjualan atau penggunaannya. Menurut (Saputra et al., 2025) klasifikasi ini memudahkan perusahaan dalam menentukan prioritas pengendalian, di mana item dalam kategori A (nilai tinggi) harus diberi bobot lebih besar daripada item dalam kategori B atau C. Selain itu, terdapat tiga kategori berdasarkan kecepatan pergerakan; *Fast-Moving*, *Slow-Moving*, dan *Non-Moving*. Klasifikasi ini sangat penting untuk analisis permintaan dan strategi pemesanan ulang.

2.1.4. Model dan Metode Pengendalian Persediaan

Tujuan dari pengendalian persediaan adalah untuk memaksimalkan tingkat persediaan dalam batas tertentu dengan memanfaatkan berbagai teknik perhitungan. Model-model dasar yang paling uimuim digunakan adalah *Just-In-Time* (JIT), *Safety Stock*, *Reorder Point* (ROP), dan *Economic Order Quantity* (EOQ). Berdasarkan biaya pemesanan dan penyimpanan, EOQ membantu perusahaan menentukan

jumlah pemesanan yang paling ekonomis. Menurut (Patappari & Muhlisa, 2023) penerapan EOQ di banyak usaha kecil dan menengah di Indonesia dapat secara signifikan mengurangi biaya layanan. *Reorder Point* (ROP) digunakan untuk menentukan kapan perusahaan harus melakukan pembelian ulang berdasarkan *lead time* dan rata-rata penggunaan. Perusahaan menggunakan konsep persediaan pengaman sebagai cadangan untuk mengatasi ketidakpastian permintaan. Dalam situasi tertentu, strategi JIT dapat digunakan untuk mengurangi persediaan dan meningkatkan efisiensi, namun hal ini memerlukan hubungan pemasok yang stabil. Menurut (Aji et al., 2023) UMKM di Indonesia yang menerapkan kombinasi antara EOQ, ROP, dan persediaan pengaman cenderung memiliki manajemen pasokan yang lebih akurat dan terkendali.

2.1.5. Peran Sistem Informasi dalam Manajemen Persediaan

Kemajuan teknologi informasi mendorong perusahaan untuk menggunakan sistem informasi terintegrasi sebagai alat dalam pengelolaan persediaan. Sistem ini membantu meningkatkan pencatatan dan pelaporan, mengurangi kesalahan manusia, serta menyediakan data yang akurat dan *real-time*. Informasi ini sangat penting untuk analisis permintaan, keputusan pembelian, dan penilaian barang dagangan. Menurut (Aji et al., 2023) penggunaan sistem informasi persediaan berbasis web di berbagai perusahaan di Indonesia dapat meningkatkan efektivitas pemeliharaan stok karena data dapat diakses dengan cepat dan diproses secara otomatis. Selain itu, sistem informasi tersebut memfasilitasi integrasi data transaksi untuk analisis selanjutnya, seperti mengklasifikasikan barang menjadi *Fast-Moving* dan *Slow-Moving* menggunakan algoritma *data mining* seperti XGBoost.

2.2. Fast-Moving dan Slow-Moving Item

Konsep *Fast, Slow*, dan *Non-Moving* (FSN) adalah metode klasifikasi yang digunakan untuk mengelompokkan produk berdasarkan tingkat pergerakan stok selama periode tertentu. Menurut (Rodjimin eit al., 2023) dalam sebuah penelitian berjudul *"Analisis Kelompok Persediaan Barang Menggunakan FSN (Fast, Slow, Non-Moving) Berdasarkan Analisis Turn Over Ratio pada Gudang Pabrik PT Sasana Yudha Bhakti"*, metode FSN membantu perusahaan mengidentifikasi produk yang bergerak cepat (*Fast-Moving*), lambat (*Slow-Moving*), atau tidak bergerak sama sekali (*Non-Moving*). Melalui klasifikasi ini, perusahaan dapat menerapkan strategi pengadaan dan penyimpanan yang berbeda sesuai dengan karakteristik masing-masing kategori produk, sehingga pengelolaan stok menjadi lebih efektif dan efisien. Dalam konteks penelitian ini, kategori *Non-Moving* tidak dimasukkan dalam analisis karena fokus utamanya adalah pada dua kategori utama, yaitu *Fast-Moving* dan *Slow-Moving*, yang paling relevan dengan data transaksi penjualan di PT Rodes Chemindo.

2.2.1. Definisi Fast-Moving Item

Barang bergerak cepat adalah produk dengan perputaran stok yang sangat cepat di gudang atau sistem persediaan. Menurut analisis FSN dalam studi XYZ, suatu produk diklasifikasikan sebagai barang bergerak cepat jika rasio perputarannya (TOR) lebih besar dari 3 (Arifin eit al., 2023). Menurut (Hidayat & Yanto, 2022) barang bergerak cepat biasanya hanya tersedia dalam waktu singkat sebelum diproduksi kembali untuk memenuhi permintaan atau kebutuhan pelanggan.

2.2.2. Definisi Slow-Moving Item

Di sisi lain, barang lambat pergerakan adalah barang dengan perputaran stok yang lambat, yang berarti stok tersebut akan bergerak perlahan dalam jangka waktu yang lebih lama. Dalam metode FSN, barang yang pergerakannya lambat biasanya didefinisikan sebagai barang dengan TOR 3 ≥ TOR ≥ 1 dalam rentang waktu saat ini (Arifin eit al., 2023). Karena pergerakannya yang lambat, barang-barang yang pergerakannya lambat berisiko menjadi usang (kedaluwarsa, rusak), menumpuk, atau menjadi stok mati jika tidak ditangani dengan benar.

2.2.3. Faktor Penyebab Perubahan Kecepatan Pergerakan Barang

Sejumlah faktor yang memengaruhi kecepatan di mana barang *Fast-Moving* berubah menjadi *Slow-Moving* (atau sebaliknya) (Larasati, 2024) , antara lain:

1. Perubahan Permintaan Pelanggan

   Fluktuasi permintaan dapat mengubah produk yang populer menjadi barang yang kurang diminati. Menurut penelitian (Larasati, 2024) alah satu faktor yang berkontribusi terhadap barang *Slow-Moving* (juga dikenal sebagai SLOB: *Slow* + *Obsolete*) adalah ketidakakuratan perencanaan permintaan, perubahan permintaan, dan faktor eksternal lainnya.

2. Kesalahan Peramalan dan Perencanaan

   Jumlah pemesanan dan stok mungkin tidak tepat jika perusahaan membuat perkiraan yang terlalu optimis atau pesimis.

3. Masalah Operasional

   Faktor manusia (karyawan), metode kerja, tata letak gudang, dan lingkungan gudang dapat memengaruhi frekuensi pengambilan barang. Dalam sebuah studi 3PL, faktor-faktor "Manusia / Metode / Lingkungan / *Material*"

diidentifikasi sebagai faktor-faktor yang berkontribusi terhadap status *Fast* atau *Slow Moving.*

4. Hubungan dengan Pemasok dan Pelanggan

   Perubahan dalam persediaan, waktu tunggu pembelian, atau perilaku pelanggan dapat memengaruhi ketersediaan produk dan mengakibatkan kelebihan atau kekurangan stok. (Larasati, 2024) juga menyebut *"masalah hubungan dengan pemasok dan pelanggan"* sebagai salah satu faktor SLOB.

5. Spesifikasi Produk

   Produk dengan spesifikasi khusus atau yang ditujukan untuk pasar niche mungkin tidak memiliki permintaan yang tinggi. (Larasati, 2024) menyoroti *"ketidaksesuaian spesifikasi produk"* sebagai salah satu faktor.

2.2.4. Dampak Fast-Moving & Slow-Moving pada Operasional Perusahaan

Pergerakan barang yang sangat cepat atau sangat lambat dapat berdampak signifikan pada berbagai aspek operasional bisnis, seperti:

1. Pengadaan
   a. Pengadaan harus dilakukan dengan cepat dan konsisten untuk barang-barang yang pergerakannya cepat guna menghindari kehabisan stok. Penjualan akan berkurang jika prediksi salah.
   b. Untuk barang yang perputarannya lambat, pemesanan yang terlalu sedikit dapat mengakibatkan stok habis ketika permintaan tiba-tiba meningkat (meskipun hal ini jarang terjadi), namun pemesanan yang berlebihan dapat menimbulkan biaya persediaan dan risiko barang menjadi usang.

2. Gudang / Tata Letak Penyimpanan
    a. Barang-barang yang cepat terjual sebaiknya ditempatkan di lokasi yang mudah dijangkau untuk memastikan waktu perputaran yang cepat (tingkat pengambilan yang tinggi).
    b. Barang-barang yang lambat terjual dapat ditempatkan di area yang kurang *"strategis"* (seperti bagian belakang) sehingga area garis depan untuk barang-barang yang cepat terjual dapat digunakan secara efisien. Hal ini juga sering diterapkan dengan menggunakan metode penyimpanan berbasis kelas.
    c. Penataan yang salah (penempatan yang tidak tepat) dapat meningkatkan waktu penanganan dan biaya operasional. Menurut studi *G-Tech* (Yahya eit al., 2023) pembelian barang yang tidak sesuai dengan frekuensi pergerakan (cepat vs. lambat) mengakibatkan proses yang melelahkan karena karyawan harus mencari barang di lokasi yang kurang ideal.
3. Arus Keuangan
    a. Barang bergerak cepat, jika stoknya berpotensi menarik pelanggan dan meningkatkan pendapatan; Jika modalnya berlebih, biasanya jumlahnya banyak.
    b. Barang bergerak lambat berpotensi meningkatkan modal dalam jangka panjang, biaya penyimpanan, risiko kedaluwarsa, kerusakan, atau diskon pelunasan. Menurut analisis dampak terhadap perusahaan ritel Indonesia, penumpukan barang bergerak lambat dapat mengurangi pendapatan dan likuiditas.

2.2.5. Indikator Penilaian Fast / Slow Moving

Untuk mengklasifikasikan suatu barang kei dalam kategori Barang Berputar Cepat atau Barang Berputar Lambat, digunakan beberapa indikator kuantitatif yang diperoleh dari data historis, antara lain:

1. *Turn Over Ratio* (TOR)

   Salah satu indikator yang paling sering digunakan adalah TOR = (Total penggunaan / penjualan dalam periode) ÷ rata-rata persediaan. TOR digunakan sebagai dasar analisis FSN dalam penelitian ini (Arifin eit al., 2023), TOR > 3 menunjukkan Barang Bergerak Cepat, 3 ≥ TOR ≥ 1 menunjukkan Barang Bergerak Lambat, dan TOR < 1 menunjukkan Barang Tidak Bergerak. Klasifikasi produk dalam metode FSN didasarkan pada Rasio Perputaran Persediaan (TOR), yang menunjukkan seberapa sering suatu produk diproduksi atau dijual dalam periode tertentu. Berikut ini adalah rumus dasar perhitungannya:

$$TOR = \frac{Jumlah\ Barang\ Terjual}{Rata - rata\ Persediaan}$$

(Rumus 2.1 *Turn Over Ratio*)

   Seiring meningkatnya Rasio Perputaran (*Turn Over Ratio* / TOR), laju produksi suatu produk pun meningkat (*Fast-Moving*). Selain itu, nilai TOR yang rendah menandakan bahwa produk yang bersangkutan memiliki pergerakan yang lambat (*Slow-Moving*). Menurut (Habibi & Ulkhaq, 2025) pengelompokan produk menggunakan metode FSN membantu perusahaan menetapkan prioritas dalam proses pengadaan. Produk *Fast-Moving* memerlukan cadangan pasokan yang lebih besar, sedangkan produk *Slow-*

Moving ditandai dengan strategi pengadaan yang lebih selektif untuk mencegah penumpukan stok di gudang.

2. Penjualan / Penggunaan Frekuensi

   Pada periode saat ini, terdapat beberapa SKU yang dikeluarkan dari gudang (misalnya mingguan, bulanan). Hal ini sering digunakan dalam berbagai studi FSN dan analisis kinerja stok, seperti yang dipublikasikan dalam jurnal Logistik Bisnis.

3. Waktu Tinggal (*Dwell Time*)

   Rata-rata lama barang berada di gudang dari awal hingga akhir (untuk konsumsi atau penjualan). Semakin banyak barang yang disimpan di gudang, semakin besar potensi barang tersebut menjadi barang yang lambat terjual atau bahkan tidak terjual sama sekali.

4. Kontribusi Nilai Penjualan atau Nilai Persediaan

   Selain pergerakan fisik, nilai moneter juga dapat diamati: Misalnya, produk *Fast-Moving* dengan volume besar dapat berdampak signifikan terhadap keseluruhan penjualan dan layanan. Penggabungan analisis FSN dengan ABC (nilai) sering digunakan dalam manajemen persediaan.

Hasil penelitian menunjukkan bahwa penerapan metode FSN dapat meningkatkan efektivitas sekaligus mengurangi biaya penyimpanan persediaan. Menurut (Rodjimin eit al., 2023) metode ini dapat mengoptimalkan manajemen stok dengan meningkatkan pemanfaatan ruang penyimpanan dan memperbaiki pengambilan keputusan selama proses pengadaan. Temuan ini juga dijelaskan oleh (Habibi & Ulkhaq, 2025), yang menyatakan bahwa pengelompokan produk

berdasarkan frekuensi pergerakan stok meningkatkan pengendalian persediaan dan mengurangi risiko barang.

Berdasarkan premis yang telah disebutkan di atas, penerapan metode FSN di PT Rodes Chemindo diharapkan dapat membantu perusahaan dalam menyeimbangkan permintaan dan pasokan produk. Selain itu, metode ini berpotensi meningkatkan efektivitas sistem pengendalian persediaan dengan mengidentifikasi kategori *Fast-Moving* dan *Slow-Moving* secara tepat dan akurat. Dengan menggunakan metode FSN untuk mengelompokkan produk, perusahaan dapat memperoleh hasil klasifikasi yang kemudian dianalisis menggunakan algoritma *Extreme Gradient Boosting* (XGBoost). Tujuan analisis ini adalah untuk mengembangkan sistem klasifikasi otomatis yang dapat menghasilkan akurasi tinggi.

2.3. Data Mining

2.3.1. Data Mining

Data mining adalah proses analitis yang bertujuan untuk mengekstrak informasi berharga, pola, dan tren dari sejumlah besar data. Proses ini menggabungkan metode statistik, pembelajaran mesin, dan kecerdasan buatan untuk mengidentifikasi pola tersembunyi yang sulit diidentifikasi secara manual. Menurut penelitian (Fajarudin & Wijaya, 2023) yang diterbitkan dalam Jurnal ALGOR, *data mining* didefinisikan sebagai proses menganalisis data untuk menemukan pola tertentu dalam jumlah data yang besar, dan istilah ini sering digunakan bersamaan dengan Penemuan Pengetahuan dalam Basis Data (KDD). Penjelasan ini memperjelas bahwa *data mining* merupakan komponen penting dalam proses mengekstraksi pengetahuan dari data. Dalam penerapannya, *data*

mining memiliki beberapa fungsi utama yang digunakan untuk menghasilkan informasi yang mendukung pengambilan keputusan. Fungsi-fungsi tersebut meliputi:

1. *Classification* (Klasifikasi)

   Klasifikasi adalah teknik *supervised learning* yang mengelompokkan data kei dalam kategori tertentu berdasarkan model yang telah dikembangkan sebelumnya. Dalam penelitian ini, klasifikasi digunakan untuk mengelompokkan produk kei dalam kategori *Fast-Moving* atau *Slow-Moving* berdasarkan transaksi penjualan dengan menggunakan algoritma XGBoost.

2. *Clustering* (Pengelompokan)

   Clustering adalah teknik un*supervised learning* yang mengelompokkan data berdasarkan karakteristik tanpa label target. (Julianto eit al., 2022) menggunakan algoritma *K-Means* dan *K-Medoids* untuk mengelompokkan pangan di Indonesia, sedangkan (Mahmudah eit al., 2025) menggunakan *K-Means* untuk mengelompokkan daerah rawan stunting menggunakan KDD.

3. *Association* (Asosiasi)

   Asosiasi digunakan untuk menemukan hubungan atau kombinasi antara item dalam suatu kumpulan data. Metode ini sering digunakan dalam analisis keranjang belanja untuk memahami hubungan antarproduk, sehingga dapat mendukung pengelolaan persediaan dan strategi pemasaran.

4. *Forecasting* (Peramalan)

   Peramalan adalah fungsi *data mining* yang digunakan untuk memperkirakan nilai atau kondisi berdasarkan data historis, seperti memperkirakan volume penjualan atau permintaan produk.

2.3.2. Knowledge Discovery in Database (KDD)

Knowledge Discovery in Database (KDD) adalah proses sistematis yang digunakan untuk mengekstrak pengetahuan atau informasi dari sejumlah besar data. KDD tidak hanya mendukung proses *data mining*, tetapi juga memfasilitasi analisis dan evaluasi data sehingga informasi yang diperoleh dapat digunakan sebagai dasar pengambilan keputusan. Menurut (Syafrinal & Febrianti, 2023) proses KDD terdiri dari lima langkah berikut:

1. Pemilihan Data

   Pemilihan data adalah proses memilih data yang relevan dengan tujuan penelitian dari seluruh data yang tersedia. Penelitian ini menggunakan data transaksi penjualan PT Rodes Chemindo sebagai dasar untuk klasifikasi produk.

2. Pembersihan dan prapemrosesan

   Prapemrosesan, yang juga dikenal sebagai pembersihan, adalah langkah dalam proses pemrosesan data yang melibatkan penghapusan nilai yang hilang, data duplikat, dan data yang tidak konsisten agar kualitas data meningkat sebelum analisis.

3. Transformasi Data

   Transformasi data adalah proses mengubah data kei dalam format yang sesuai untuk analisis. Dalam penelitian ini, ditentukan atribut-atribut yang diperlukan, seperti jumlah total penjualan, frekuensi transaksi, dan variabel lain yang digunakan sebagai masukan untuk algoritma klasifikasi.

4. *Data Mining*

   Data Mining merupakan langkah utama dalam proses KDD, yang melibatkan penggunaan algoritma untuk menemukan pola atau informasi yang terkandung dalam data. Dalam penelitian ini, algoritma *Extreme Gradient Boosting* (XGBoost) digunakan untuk mengklasifikasikan produk kei dalam kategori *Fast-Moving* dan *Slow-Moving* berdasarkan data transaksi.

5. Interpretasi dan Penilaian

   Interpretasi dan Penilaian merupakan langkah terakhir yang bertujuan untuk menganalisis dan menilai hasil model yang telah dikembangkan. Dalam penelitian ini, *Confusion Matrix* digunakan untuk mengevaluasi kinerja klasifikasi model dalam mengklasifikasikan produk *Fast-Moving* dan *Slow-Moving* dengan menghitung *Accuracy*, *Precision*, *Recall*, dan *F1-score*.

KDD yang disebutkan di atas memastikan bahwa proses analisis data dilakukan secara sistematis, mulai dari pengumpulan data hingga evaluasi model, sehingga hasilnya dapat diandalkan, akurat, dan dapat dijadikan landasan untuk pengambilan keputusan dalam pengembangan produk.

2.4. Classification (Klasifikasi)

Klasifikasi merupakan salah satu teknik *data mining* utama yang bertujuan untuk mengelompokkan data berdasarkan karakteristik tertentu. Menurut (Riza, 2022) klasifikasi dilakukan dengan membuat model menggunakan data pelatihan untuk memprediksi kelas pada data baru (data pengujian). Model ini mempelajari hubungan antara variabel masukan (fitur) dan target (label) guna menghasilkan prediksi yang sistematis. Dalam dunia bisnis, klasifikasi digunakan untuk

mendukung pengambilan keputusan berdasarkan pola yang diperoleh dari data historis.

Klasifikasi digunakan dalam analisis transaksi untuk mengidentifikasi karakteristik produk, seperti mengelompokkan produk kei dalam kategori *Fast-Moving* dan *Slow-Moving*, sehingga bisnis dapat memaksimalkan penjualan. Menurut (Arunika & Dewi, 2025) teknik klasifikasi membantu perusahaan memahami cara memproduksi barang agar proses distribusi, pengadaan, dan penyimpanan dapat dilaksanakan dengan lebih efektif.

Banyak algoritma yang dapat digunakan dalam proses klasifikasi, termasuk *Decision Tree*, *Random Forest*, *K-Nearest Neighbors* (KNN), *Support Vector Machine* (SVM), *Logistic Regression*, dan *Extreme Gradient Boosting* (XGBoost). Setiap algoritma memiliki karakteristik, kelebihan, dan keterbatasan yang berbeda-beda, sehingga pemilihannya harus sesuai dengan karakteristik data dan tujuan penelitian (Astrani & Rahayuda, 2025). Dalam penelitian ini, algoritma XGBoost dipilih karena memiliki kemampuan untuk menganalisis data tabular dalam jumlah besar, memberikan akurasi yang tinggi, serta meningkatkan kinerja model dengan menggunakan teknik *boosting* (Latif & Wildah, 2025).

2.5. Unified Modeling Language (UML)

Sebelum proses implementasi dilaksanakan, perancangan sistem harus diselesaikan terlebih dahulu guna memberikan gambaran mengenai sistem yang akan dikembangkan. Arsitektur sistem berfungsi sebagai alat untuk mengembangkan sistem lunak, baik yang bersifat *front-end* maupun *back-end* (Irmayani & Munandar, 2020; Perdana & Munggaran, 2021). *Unified Modeling Language* (UML) adalah bahasa pemodelan standar yang digunakan untuk

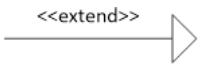
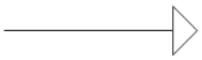
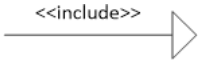
memvisualisasikan, merancang, membangun, dan mendokumentasikan sistem lunak berbasis objek. Dalam penelitian ini, UML digunakan sebagai alat analisis sistem yang terdiri dari *Uisei Case Diagram*, *Activity Diagram*, *Sequence Diagram*, dan *Class Diagram* untuk menggambarkan fungsi, proses, interaksi, serta struktur sistem yang diklasifikasikan sebagai *Fast-Moving* dan *Slow-Moving* menggunakan algoritma XGBoost. Diagram UML yang digunakan dalam penelitian ini dijelaskan sebagai berikut:

1. *Use Case Diagram*

   Menurut (Ridwanto & Capah, 2020), *use case diagram* adalah jenis model yang digunakan untuk menggambarkan fungsi-fungsi sistem yang akan dikembangkan. Diagram ini menggambarkan bagaimana satu atau lebih aktor berinteraksi dengan sistem yang dirancang. Berikut ini adalah beberapa simbol yang terdapat dalam *use case diagram*:

Tabel 2.1 Simbol-simbol Use Case Diagram

No	Simbol	Keterangan
1	*Use Case* 	Fungsi yang disediakan oleh sistem sebagai unit-unit yang secara terus-menerus berinteraksi dengan aktor.
2	Aktor / *Actor* 	Merupakan entitas eksternal (manusia atau sistem lain) yang berinteraksi secara langsung dengan sistem.

No	Simbol	Keterangan
3	Asosiasi / *Association*	Garis yang menghubungkan aktor dengan *uisei case*, yang menunjukkan adanya interaksi.
4	Ekstensi / *extend* 	Relasi dari *uisei case* tambahan ke *uisei case* utama, di mana *uisei case* utama dapat berdiri sendiri tanpa fungsi tambahan tersebut.
5	Generalisasi 	Pewarisan sifat, spesialisasi, atau generalisasi antara dua *uisei case* atau aktor.
6	*Include* / *Use Case* 	Hubungan dari *uisei case* tambahan ke *uisei case* utama, di mana *uisei case* utama harus menjalankan fungsi ini agar sistem dapat dimulai.

Berdasarkan Tabel 2.1, simbol-simbol dalam *Uisei Case Diagram* digunakan untuk menggambarkan interaksi antara aktor dan sistem yang dikembangkan. Setiap simbol memiliki fungsi yang berbeda-beda, seperti mewakili seorang aktor, suatu proses (kasus penggunaan), atau hubungan antarelemen sistem. Simbol-simbol tersebut digunakan dalam *Uisei Case Diagram* pada penelitian ini.

2. *Activity Diagram*

Menurut (Ridwanto & Capah, 2020), *Activity diagram* digunakan sebagai alat pemodelan untuk menggambarkan seluruh proses dalam suatu sistem secara

terstruktur, mulai dari aktivitas awal hingga aktivitas akhir. Simbol-simbol yang terdapat dalam *activity diagram* adalah sebagai berikut:

Tabel 2.2 Simbol-simbol Activity Diagram

No	Simbol	Deskripsi
1	Status awal 	Status awal aktivitas sistem; Diagram aktivitas memiliki status awal.
2	Aktivitas 	Istilah kerja biasanya digunakan untuk menggambarkan aktivitas sistemik.
3	Percabangan (*Decision*) 	Pilihan kondisi yang mengalihkan alur kendali kei jalur alternatif jika terdapat lebih dari satu aktivitas.
4	Aliran Kendali (*Control Flow*)	Tunjukkan urutan perpindahan kendali dari satu aktivitas kei aktivitas-aktivitas berikutnya di dalam sistem.
5	Status akhir (*Final Node*) 	Status akhir suatu sistem digambarkan oleh diagram aktivitas.

Berdasarkan Tabel 2.2, simbol-simbol dalam *Activity Diagram* digunakan untuk menggambarkan berbagai aktivitas atau proses yang terjadi dalam sistem secara berurutan, dimulai dari keadaan awal dan berakhir pada keadaan akhir. Setiap simbol memiliki fungsi yang berbeda dalam hal menggambarkan aktivitas, keputusan percabangan, alur proses, atau bahkan menganalisis suatu

aktivitas. Simbol-simbol yang disebutkan di atas digunakan dalam *Activity Diagram* pada penelitian ini.

3. *Sequence Diagram*

Menurut (Mulyati eit al., 2024), *Seiquieincei Diagram* adalah salah satu jenis diagram dalam *Unified Modeling Language* (UML) yang digunakan untuk menggambarkan interaksi antar objek dalam suatu sistem berdasarkan urutan waktu. Diagram ini memvisualisasikan aliran pesan yang terjadi antar objek sehingga dapat menunjukkan bagaimana suatu proses berlangsung dari awal hingga akhir. *Seiquieincei Diagram* digunakan dalam penelitian ini untuk menggambarkan interaksi antara aktor dan komponen sistem selama proses klasifikasi produk *Fast-Moving* dan *Slow-Moving* menggunakan algoritma XGBoost. Berikut ini adalah beberapa simbol yang terdapat dalam *Seiquieincei Diagram*:

Tabel 2.3 Simbol-simbol Sequence Diagram

No	Simbol	Deskripsi
1	*Object* 	Mewakili suatu objek atau komponen yang terlibat dalam interaksi suatu sistem.
2	*Lifeline*	Menjelaskan keberadaan objek tersebut selama proses interaksi berlangsung.
3	*Activation* (*Execution Specification*)	Menunjukkan bahwa objek tersebut sedang memulai suatu proses.

No	Simbol	Deskripsi
		
4	*Message* (*Synchronous Message*)	Pengiriman pesan atau permintaan antar objek.
5	*Return Message*	Menunjukkan balasan atau hasil dari proses yang telah selesai.

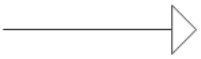
Berdasarkan Tabel 2.3, simbol-simbol dalam *Seiquieincei Diagram* digunakan untuk menggambarkan komunikasi antar objek dalam sistem selama suatu proses yang berkelanjutan. Setiap simbol memiliki fungsi yang berbeda, seperti mewakili suatu objek, keadaan aktif suatu objek (garis hidup), proses yang sedang berlangsung (aktivasi), pengiriman pesan (pesan), atau respons dari suatu proses (pesan balik). Simbol-simbol yang disebutkan di atas digunakan dalam analisis *Seiquieincei Diagram* pada penelitian ini.

4. *Class Diagram*

Menurut (Suhartini et al., 2020), *class diagram* adalah model yang menggambarkan struktur statistik suatu sistem melalui definisi kelas-kelas yang akan digunakan pada tahap pengembangan. Setiap kelas dalam diagram memiliki komponen berupa atribut serta metode atau operasi. Sementara metode atau operasi merupakan kumpulan tindakan yang dapat dilakukan oleh

suatu kelas tertentu, atribut berfungsi sebagai komponen data variabel yang dimiliki oleh suatu kelas tertentu. Berikut ini adalah simbol-simbol standar yang digunakan dalam *class diagram*:

Tabel 2.4 Simbol-simbol Class Diagram

No	Simbol	Deskripsi
1	Kelas 	Kelas dalam sistem struktur.
2	Antarmuka / *Interface* 	Mirip dengan konsep antarmuka dalam pemrograman berorientasi objek.
3	Asosiasi/*Association*	Asosiasi biasanya ditandai oleh multiplisitas dalam kaitannya dengan kelas-kelas yang memiliki nama yang sama.
4	Asosiasi Berarah (*Directed Association*) 	Relasi antar kelas ditandai oleh fakta bahwa satu kelas digunakan oleh kelas lain secara searah, yang ditentukan oleh multiplisitas.
5	Generalisasi (*Generalization*) 	Relasi antar kelas menggunakan metode generalisasi-spesialisasi (umum-khusus).

No	Simbol	Deskripsi
6	Kebergantungan (*Dependency*)	Relasi antar kelas yang melibatkan ketergantungan antar kelas.
7	Agregasi (*Aggregation*) 	Relasi antar kelas yang menggambarkan hubungan antara (bagian dari atau memiliki), di mana satu kelas menjadi komponen dari kelas lain, namun kedua kelas tersebut tetap dapat berdiri sendiri.

Berdasarkan Tabel 2.4, simbol-simbol dalam *Class Diagram* digunakan untuk menggambarkan struktur statistik sistem, yang terdiri dari kelas, atribut, metode, dan hubungan antar kelas. Setiap simbol memiliki fungsi yang berbeda dalam merepresentasikan komponen sistem dan hubungan di antara komponen-komponen tersebut, seperti asosiasi, generalisasi, agregasi, atau ketergantungan (*dependence*). Simbol-simbol yang disebutkan di atas digunakan dalam *class diagram* pada penelitian ini.

2.6. Penelitian Terdahulu

Penelitian terdahulu digunakan sebagai landasan untuk memahami perkembangan penelitian yang berkaitan dengan topik yang diteliti serta sebagai bahan perbandingan dengan penelitian yang sedang dilakukan. Melalui penelitian terdahulu, dimungkinkan untuk memahami metode yang telah digunakan, hasil yang diperoleh, keterbatasan penelitian, dan kesenjangan penelitian yang menjadi landasan bagi penelitian ini. Beberapa studi yang relevan mengenai manajemen

persediaan, *data mining*, teknik *Fast-Moving* dan *Slow-Moving*, serta algoritma *Extreme Gradient Boosting* (XGBoost) disajikan dalam Tabel 2.5.

Tabel 2.5 Penelitian Terdahulu

Peneliti	Fokus Penelitian	Metode	Hasil Penelitian	Keterbatasan	Relevansi Penelitian
(Aji et al., 2023)	Manajemen persediaan UMKM.	EOQ, ROP, *Safety Stock*.	Pengelolaan stok lebih akurat.	Tidak membahas klasifikasi produk.	Menjadi referensi pengendalian persediaan.
(Arai et al., 2023)	Estimasi *churn* pelanggan.	LightGBM, XGBoost.	Akurasi tinggi pada data berukuran besar.	Membutuhkan volume data yang besar.	Referensi perbandingan algoritma *Boosting*.
(Arifin et al., 2023)	Analisis *Fast-Moving* dan *Slow-Moving*.	FSN dan TOR.	Menentukan kategori produk berdasarkan nilai TOR.	Analisis masig bersifat deskriptif.	Menjadi dasar penentuan label *Fast-Moving* dan *Slow-Moving*.

Peneliti	Fokus Penelitian	Metode	Hasil Penelitian	Keterbatasan	Relevansi Penelitian
(Arunika & Dewi, 2025)	Klasifikasi pergerakan barang.	Metode klasifikasi.	Mendukung pengambilan keputusan manajemen.	Membutuhkan data yang terstruktur.	Referensi penerapan klasifikasi pada persediaan.
(Astrani & Rahayuda, 2025)	Prediksi penjualan ritel.	XGBoost dan LightGBM.	Akurasi prediksi tinggi.	Bergantung pada kualitas fitur.	Referensi pemilihan algoritma XGBoost.
(Fajarudin & Wijaya, 2023)	Implementasi *data mining.*	KDD.	Menjelaskan tahapan proses KDD.	Tidak membahas implementasi sistem.	Landasan metodologi penelitian.
(Habibi & Ulkhaq, 2025)	Optimasi pengadaan barang.	FSN.	Mengurangi biaya persediaan.	Berfokus pada analisis FSN.	Referensi analisis persediaan.
(Hidayat & Yanto, 2022)	Analisis durasi stok.	Analisis waktu.	Menentukan *Fast-Moving*.	Tidak membahas *machine learning*.	Referensi klasifikasi berdasarkan waktu.

Peneliti	Fokus Penelitian	Metode	Hasil Penelitian	Keterbatasan	Relevansi Penelitian
(Kurniawansyah et al., 2025)	Akurasi klasifikasi.	XGBoost.	Menghasilkan performa klasifikasi yang tinggi.	Model cukup kompleks.	Referensi evaluasi performa XGBoost.
(Latif & Wildah, 2025)	Klasifikasi data kompleks.	XGBoost.	Mampu menangani variasi data yang tinggi.	Membutuhkan proses *hyperparameter tuning*.	Mendukung penggunaan XGBoost.
(Massaro et al., 2021)	Algoritma *ensemble*.	XGBoost.	Komputasi cepat dan efisien.	Tidak dijelaskan secara spesifik.	Referensi performa XGBoost.
(Munyaka & Yadavalli, 2022)	Teknologi Informasi pada persediaan.	Sistem Informasi.	Mempercepat pengambilan keputusan.	Bergantung pada infrastruktur.	Referensi penerapan TI pada persediaan.
(Opitasari et al., 2024)	Optimasi klasifikasi.	XGBoost.	Mengurangi risiko *overfitting*.	Model matematis	Referensi penggunaan XGBoost.

Peneliti	Fokus Penelitian	Metode	Hasil Penelitian	Keterbatasan	Relevansi Penelitian
				cukup kompleks.	
(Patappari & Muhlisa, 2023)	Pengendalian persediaan.	EOQ.	Mengurangi biaya persediaan.	Terbatas pada UMKM.	Referensi metode pengendalian persediaan.
(Rahman & Nursyamsiah, 2023)	*Monitoring* stok ritel.	*Monitoring* stok.	Pengendalian stok lebih efektif.	Berfokus pada sektor ritel.	Referensi *monitoring* persediaan.
(Rodjimin et al., 2023)	Klasifikasi produk.	FSN dan TOR.	Menentukan indikator pergerakan produk.	Belum menggunakan *machine learning*.	Referensi pembentukan label klasifikasi.
(Saputra et al., 2025)	Prioritas persediaan.	ABC *Analysis*.	Mempermudah pengendalian nilai persediaan.	Klasifikasi kelas hanya berdasarkan nilai.	Referensi pengelompokan persediaan.

Peneliti	Fokus Penelitian	Metode	Hasil Penelitian	Keterbatasan	Relevansi Penelitian
(Singh, 2022)	Terminologi persediaan	*Literature Review*.	Menjelaskan konsep persediaan.	Bersifat teoritis.	Landasan teori persediaan.
(Suriyani et al., 2020)	Manajemen persediaan	Analisis persediaan	Mengurangi pemborosan persediaan	Pembahasan masih uimuim	Landasan teori manajemen persediaan
(Wang, 2023)	*Forecast* penjualan.	LightGBM dan XGBoost.	Menurunkan nilai kesalahan prediksi.	Berfokus pada peramalan.	Referensi performa *boosting*.
(Zahra eit al., 2025)	Operasional persediaan.	*Monitoring* stok.	Operasional menjadi lebih efisien.	Pembahasan masih uimum.	Referensi pengelolaan persediaan.

Berdasarkan penelitian awal yang disajikan dalam Tabel 2.5, dapat disimpulkan bahwa sebagian besar penelitian di bidang manajemen rantai pasok masih menggunakan metode konvensional seperti *Economic Order Quantity* (EOQ), *Reorder Point* (ROP), *Safety Stock*, FSN, *Turn Over Ratio* (TOR), dan Analisis ABC untuk meningkatkan manajemen rantai pasok. Di konteks lain, perkembangan teknik pembelajaran mesin menunjukkan bahwa algoritma *Extreme Gradient*

Boosting (XGBoost) berkinerja baik dalam berbagai tugas klasifikasi dan prediksi karena mampu menghasilkan akurasi tinggi, mengurangi risiko *overfitting*, dan secara efektif menangani data tabel. Meskipun demikian, penelitian yang secara khusus mengintegrasikan konsep *Fast-Moving* dan *Slow-Moving* berdasarkan data transaksi menggunakan algoritma XGBoost masih tergolong terbatas. Sebagian besar penelitian hanya berfokus pada analisis deskriptif dengan menggunakan metode FSN dan TOR atau pada penerapan algoritma XGBoost untuk berbagai kasus klasifikasi. Oleh karena itu, penelitian ini mengusulkan penggunaan algoritma *Extreme Gradient Boosting* (XGBoost) untuk mengklasifikasikan produk *Fast-Moving* dan *Slow-Moving* berdasarkan data transaksi penjualan di PT Rodes Chemindo. Diharapkan hasil klasifikasi ini dapat membantu perusahaan dalam mengembangkan keputusan pengelolaan persediaan yang lebih objektif, efektif, dan berbasis data.

BAB III

ANALISA DAN PERANCANGAN SISTEM

3.1. Jenis dan Pendekatan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metodologi studi kasus. Pendekatan kuantitatif dipilih karena penelitian ini menggunakan data numerik, yaitu data transaksional yang dianalisis menggunakan metode statistik dan algoritma *machine learning* untuk memecahkan masalah secara sistematis, objektif, dan komprehensif. Menurut (Sugiyono, 2022), penelitian kuantitatif adalah metode penelitian yang menggunakan data angka yang dianalisis dengan teknik statistik untuk menjelaskan suatu fenomena secara objektif.

Dalam penelitian ini, data riwayat transaksi digunakan sebagai dasar untuk mengklasifikasikan produk ke dalam kategori *Fast-Moving* dan *Slow-Moving* menggunakan algoritma *Extreme Gradient Boosting* (XGBoost). Jenis penelitian yang digunakan adalah studi kasus karena berfokus pada satu objek penelitian, yaitu PT Rodes Chemindo, yang memungkinkan peneliti menganalisis masalah klasifikasi produk secara konsisten dengan kondisi bisnis.

Penelitian ini dilakukan di PT Rodes Chemindo, yang berlokasi di Jalan Sekip Baru No. 2, Kelurahan Petisah Tengah, Kecamatan Medan Petisah, Kota Medan, Sumatera Utara 20111. Objek penelitian ini adalah data riwayat transaksi produk yang digunakan sebagai dataset untuk mengembangkan dan mengevaluasi model klasifikasi *Fast-Moving* dan *Slow-Moving* menggunakan algoritma XGBoost. Pemilihan pendekatan kuantitatif dengan jenis penelitian studi kasus dinilai sesuai karena dapat menghasilkan analisis yang objektif berdasarkan data numerik serta

memberikan hasil yang dapat digunakan untuk memperkuat pengambilan keputusan dalam pengelolaan persediaan produk.

Berdasarkan metodologi kuantitatif yang digunakan, penelitian kuantitatif umumnya dilakukan melalui beberapa langkah, antara lain pengumpulan data, analisis data, interpretasi data, dan penarikan kesimpulan. Temuan-temuan ini kemudian diterapkan dan dibandingkan dengan penelitian yang dilakukan di PT Rodes Chemindo sebagai berikut:

1. Pengumpulan Data

   Langkah pertama melibatkan pengumpulan data historis mengenai transaksi penjualan produk dari PT Rodes Chemindo. Data yang digunakan terdiri dari data numerik yang mencakup jumlah transaksi, kode barang, nama barang, jumlah yang terjual, harga per unit, serta atribut lain yang mendukung proses analisis.

2. Pengolahan Data

   Data yang telah dikumpulkan kemudian diseleksi sesuai dengan kebutuhan penelitian. Selanjutnya, dilakukan proses pembersihan data untuk menghilangkan data duplikat, data yang tidak lengkap (nilai yang hilang), dan data yang tidak relevan. Setelah itu, dilakukan transformasi data dengan membuat fitur-fitur yang diperlukan, seperti frekuensi transaksi, jumlah total yang terjual, serta penentuan kategori *Fast-Moving* dan *Slow-Moving* berdasarkan *Turn Over Ratio* (TOR).

3. Analisis Data (*Data Analysis*)

   Setelah diproses, kumpulan data dibagi menjadi data pelatihan (latih) dan data pengujian (uji). Pada tahap ini, analisis data dilakukan menggunakan metode

statistik dan algoritma pembelajaran mesin, termasuk *Extreme Gradient Boosting* (XGBoost). Kumpulan data yang telah diproses dibagi menjadi data pelatihan (latih) dan data pengujian (uji) untuk membuat model klasifikasi yang dapat mengklasifikasikan produk ke dalam kategori *Fast-Moving* dan *Slow-Moving* berdasarkan volume penjualan.

4. Interpretasi Hasil

   Model yang dikembangkan dievaluasi menggunakan *Confusion Matrix* dengan menghitung *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Hasil evaluasi tersebut kemudian diinterpretasikan untuk memahami tingkat kinerja model dalam mengklasifikasikan produk dan mencapai tujuan penelitian yang telah ditentukan.

5. Penarikan Kesimpulan

   Langkah terakhir dilakukan dengan mengambil keputusan berdasarkan hasil analisis. Kesimpulan yang disebutkan di atas digunakan untuk memberikan rekomendasi guna meningkatkan keputusan pengelolaan persediaan di PT Rodes Chemindo.

3.2. Analisis Permasalahan dan Metode Analisis

Berdasarkan pengamatan dan wawancara yang dilakukan di PT Rodes Chemindo, teridentifikasi beberapa masalah terkait proses klasifikasi produk. Untuk mengatasi masalah ini, penelitian ini menggunakan algoritma *Extreme Gradient Boosting* (XGBoost) sebagai metode analisis untuk mengklasifikasikan produk kei dalam kategori *Fast-Moving* dan *Slow-Moving*. Meskipun demikian, analisis yang dilakukan adalah sebagai berikut:

1. Analisis Permasalahan

   Tujuan dari tahap ini adalah mengidentifikasi masalah yang muncul selama proses persediaan di PT Rodes Chemindo. Berdasarkan hasil analisis, teridentifikasi masalah-masalah berikut:

   a. Identifikasi produk masih dilakukan secara manual menggunakan lembar kerja *Microsoft Excel*.
   b. Proses analisis data membutuhkan waktu yang relatif lama dan rentan terhadap kesalahan manusia.
   c. Belum ada sistem klasifikasi otomatis berbasis *machine learning*.
   d. Data transaksi berskala besar belum dimanfaatkan sepenuhnya sebagai dasar pengambilan keputusan.
   e. Akibat proses klasifikasi yang kurang optimal, terdapat risiko kelebihan stok atau kekurangan stok.

2. Penentuan Metode Analisis

   Setelah mengidentifikasi masalah, langkah selanjutnya adalah memilih metode analisis yang sesuai untuk memecahkan masalah tersebut. Penelitian ini menggunakan algoritma *Extreme Gradient Boosting* (XGBoost) karena algoritma ini memiliki kinerja yang baik dalam mengklasifikasikan data berskala besar. Beberapa alasan pemilihan metode ini adalah sebagai berikut:

   a. Mampu menganalisis data transaksi dalam jumlah besar.
   b. Memiliki tingkat akurasi yang tinggi.
   c. Mengurangi kesulitan dengan menggunakan proses *boosting*.
   d. Lebih efektif daripada proses klasifikasi manual.

3. Analisis Dataset

   Langkah ini digunakan untuk mengidentifikasi data yang digunakan dalam proses klasifikasi. Dataset diperoleh dari data transaksi historis PT Rodes Chemindo yang telah disesuaikan dengan kebutuhan penelitian. Dataset yang digunakan terdiri dari:

   a. Terdapat sekitar 46.025 transaksi selama periode 2024–2026 yang digunakan sebagai data untuk visualisasi.
   b. Pada tahun 2025, terdapat sekitar 17.973 transaksi yang digunakan sebagai dataset klasifikasi utama.
   c. Atribut-atribut yang digunakan meliputi kode barang, nama barang, tanggal transaksi, jumlah penjualan (kuantitas), harga satuan, dan atribut pendukung lainnya.

4. Pra-pemrosesan Data

   Sebelum proses klasifikasi diselesaikan, dataset diperiksa dengan cermat untuk memastikan kualitas datanya baik. Tahap ini bertujuan untuk mengurangi kesulitan selama proses pembangunan model. Tahapan pra-pemrosesan meliputi:

   a. Pembersihan data, yang melibatkan penghapusan data duplikat dan data kosong.
   b. Transformasi data, yang melibatkan pembuatan fitur seperti jumlah total yang terjual, frekuensi transaksi, serta penentuan kategori *Fast-Moving* dan *Slow-Moving* berdasarkan *Turn Over Ratio* (TOR).

5. Pengembangan Model Klasifikasi

   Fase ini bertujuan untuk mengembangkan model klasifikasi menggunakan algoritma XGBoost berdasarkan dataset yang telah diproses sebelumnya. Langkah-langkah yang dilakukan meliputi:

   a. Membagi dataset menjadi 80% data latih dan 20% data uji.
   b. Model ini menggunakan algoritma *Extreme Gradient Boosting* (XGBoost).
   c. Mengembangkan model yang dapat mengklasifikasikan produk berdasarkan jenis transaksi.

6. Evaluasi Model

   Setelah model berhasil dikembangkan, dilakukan proses evaluasi untuk menentukan tingkat kinerja model dalam klasifikasi produk. Evaluasi dilakukan menggunakan *Confusion Matrix* dengan parameter-parameter berikut:

   a. *Accuracy*
   b. *Precision*
   c. *Recall*
   d. *F1-Score*

7. Penyajian Hasil Klasifikasi

   Langkah terakhir dilakukan dengan menampilkan hasil klasifikasi melalui sistem yang telah dikembangkan. Hasil tersebut digunakan sebagai data pendukung untuk pengambilan keputusan pengelolaan persediaan PT Rodes Chemindo. Sistem ini menyediakan beberapa fungsi, antara lain:

   a. Mengunggah data transaksi.
   b. Memulai proses klasifikasi menggunakan algoritma XGBoost.

c. Menampilkan hasil klasifikasi dalam bentuk tabel dan grafik / diagram.

3.3. Teknik Pengumpulan Data

Untuk memperoleh data yang sah, akurat, dan relevan dengan tujuan penelitian, para peneliti menggunakan teknik pengumpulan data yang meliputi analisis dokumen, observasi, dan wawancara. Ketiga teknik ini digunakan untuk mengumpulkan data yang mendukung proses klasifikasi produk *Fast-Moving* dan *Slow-Moving* di PT Rodes Chemindo dengan menggunakan algoritma XGBoost.

1. Studi Dokumentasi

   dilakukan dengan mengumpulkan dan meninjau dokumen-dokumen yang berkaitan dengan transaksi penjualan produk di PT Rodes Chemindo. Data primer yang digunakan adalah data riwayat transaksi yang menyediakan informasi berikut:

   a. Tanggal transaksi penjualan.
   b. Kode barang atau ID produk.
   c. Nama barang.
   d. Jumlah total unit yang terjual (kuantitas/qty).

   Data transaksi tersebut kemudian digunakan sebagai dataset utama untuk penelitian. Data ini digunakan untuk mendukung proses analisis, yang meliputi:

   a. Pembersihan data (*data cleansing*) dari data duplikat dan nilai kosong (*missing value*).
   b. Menggunakan Jumlah Total Kuantitas dan Frekuensi Transaksi sebagai variabel penelitian.

c. Menentukan label *Fast-Moving* dan *Slow-Moving* berdasarkan Rasio Perputaran (*Turn Over Ratio*/TOR) sebagai tingkat objektif.

d. Setiap dataset digunakan dalam prosedur pembuatan model klasifikasi teknik *Extreme Gradient Boosting* (XGBoost).

2. Wawancara

Wawancara dilakukan secara semi-terstruktur kepada karyawan yang terlibat langsung dalam operasional PT Rodes Chemindo, seperti *Supervisor* Logistik, Staf Administrasi Gudang, Bagian Penjualan, dan Kepala Gudang. Wawancara digunakan untuk mengumpulkan data yang tidak terdapat dalam catatan perusahaan, seperti:

a. Faktor-faktor yang memengaruhi kinerja produk.

b. Kendala dalam proses pengelolaan persediaan manual.

c. Strategi perusahaan dalam mengklasifikasikan produk.

d. Dampak kondisi kelebihan stok dan kekurangan stok terhadap operasional bisnis.

3. Observasi Lapangan

Observasi dilakukan dengan mengunjungi lokasi operasional PT Rodes Chemindo, khususnya area gudang dan proses distribusi barang. Tujuan observasi adalah untuk mengumpulkan informasi mengenai proses pengelolaan persediaan, mekanisme pencatatan barang masuk dan keluar, serta kondisi operasional bisnis yang berkaitan dengan pengelolaan stok.

Studi kombinasi antara dokumentasi, wawancara, dan observasi digunakan untuk memperoleh data yang valid, akurat, dan relevan guna mendukung proses

analisis serta menghasilkan model klasifikasi yang sesuai dengan kondisi data di PT Rodes Chemindo.

3.4. Algoritma Extreme Gradient Boosting (XGBoost)

3.4.1. Pengertian Algoritma XGBoost

Extreme Gradient Boosting (XGBoost) merupakan implementasi yang efisien dari algoritma *Gradient*. Teknik *boosting* digunakan untuk mengoptimalkan kinerja komputer dan prediksi melalui optimasi algoritma dan teknik regularisasi. XGBoost menciptakan model yang kuat dengan menggabungkan (*ensemble*) pohon keputusan lemah (*weak learners*) secara berurutan, di mana setiap pohon berikutnya berusaha memperbaiki kesalahan residual (sisa) yang sebelumnya dihasilkan oleh pohon-pohon sebelumnya. Implementasi XGBoost banyak digunakan dalam berbagai masalah klasifikasi karena efisiensi komputasinya yang tinggi dan kemampuannya untuk memberikan akurasi tinggi pada berbagai dataset dari dunia nyata (Opitasari eit al., 2024).

Beberapa penelitian juga menunjukkan bahwa algoritma XGBoost memiliki kinerja yang lebih baik daripada algoritma lain dalam berbagai skenario klasifikasi. Menurut (Opitasari eit al., 2024) XGBoost menghasilkan kinerja klasifikasi yang lebih baik daripada LightGBM pada beberapa dataset tabular. Selain itu, (Dachi & Sitompul, 2023) menyatakan bahwa setelah penyesuaian hiperparameter, XGBoost dapat memberikan hasil evaluasi yang lebih tinggi daripada *Random Forest*. Hasil tersebut menunjukkan bahwa XGBoost merupakan algoritma yang dapat digunakan untuk menganalisis klasifikasi produk berdasarkan data transaksi.

3.4.2. Mekanisme Dasar Boosting

Boosting adalah salah satu teknik pembelajaran *ensemble* yang mengubah beberapa model dengan kinerja buruk menjadi model yang lebih kuat melalui proses pembelajaran yang sistematis dan berulang. Pada setiap iterasi, model akan lebih memperhatikan data yang sebelumnya mengalami kesulitan sehingga model berikutnya dapat mengatasi kesulitan tersebut. Dalam algoritma *Gradient Boosting*, proses ini dilakukan dengan menganalisis fungsi kerugian (*loss function*) menggunakan pendekatan *gradient*, di mana setiap model baru dibangun untuk mempelajari residual dari model sebelumnya.

XGBoost mengembangkan konsep *Gradient Boosting* dengan memasukkan beberapa teknik optimasi, seperti aproksimasi orde dua *Taylor* untuk fungsi kerugian, regulasi untuk mengurangi kompleksitas model, dan mekanisme pemangkasan otomatis untuk mengurangi risiko *overfitting*. Berbagai optimasi ini memungkinkan XGBoost menghasilkan model yang lebih akurat, efisien, dan stabil ketika diterapkan pada data berskala besar atau data dengan karakteristik yang kompleks (Opitasari et al., 2024).

3.4.3. Struktur Model dalam XGBoost (Decision Trees & Boosting Iteration)

Model XGBoost didasarkan pada ensembel pohon. Singkatnya:

1. *Base learner*: CART (*Classification And Regression Tree*) dengan kedalaman terbatas biasanya digunakan.
2. Iterasi *boosting*: Untuk setiap iterasi t, XGBoost menambahkan pohon ft yang meminimalkan fungsi objektif keseluruhan $Obj^{(t)} = \sum_i l\,(y_i, \hat{y}_i^{(t-1)} +$

$f_t(x_i)) + \Omega(f_t)$, di mana l adalah *loss* (mis. *logistic loss* untuk klasifikasi), dan Ω Adalah *term* regularisasi untuk kompleksitas pohon.

3. Penyesuaian parameter via *gradient* dan *Hessian*: XGBoost menggunakan aproksimasi *Taylor* orde dua (*Gradient* dan *Hessian*) untuk mempercepat optimasi dan menghitung kontribusi potensial *split* di pohon.
4. Struktur iteratif ini memungkinkan model untuk menangkap hubungan non-linear dan interaksi antara fitur-fitur kompleks dalam data penjualan.

Penerapan XGBoost dalam berbagai studi di Indonesia menunjukkan kemampuannya beradaptasi pada berbagai domain klasifikasi (Dachi & Sitompul, 2023).

3.4.4. Rumus XGBoost

Rumus dasar yang digunakan dalam metode XGBoost (*Extreme Gradient Boosting*) adalah sebagai berikut (Opitasari eit al., 2024):

$$Obj = \sum_{i=1}^{n} l(y_i, \hat{y}_i) + \sum_{k=i}^{K} \Omega(f_k)$$

Dengan komponen regularisasi pohon:

$$\Omega(f) = \gamma T + \frac{1}{2}\lambda \sum_{j=1}^{T} w_j^2$$

Rumus untuk menghitung *gain* (kualitas pemecahan *node*):

$$Gain = \frac{1}{2}\left(\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda}\right) - \gamma$$

Rumus untuk nilai bobot *leaf*:

$$w_j = -\frac{G_j}{H_j + \lambda}$$

Rumus pembaharuan prediksi:

$$\hat{y}^{(t)} = \hat{y}^{(t-1)} + \eta f_t(x_i)$$

Tabel 3.1 Rumus XGBoost

Simbol	Keterangan
$l(y_i, \hat{y}_i)$	*Loss function* (misal: *Squared error*, *log loss*).
f_k	Pohon ke-k yang dibangun.
$\Omega(f)$	Regularisasi kompleksitas pohon.
T	Jumlah *leaf* dalam pohon.
w_j	Bobot *leaf* ke-j.
γ, λ	Parameter regularisasi.
G_L, G_R	Jumlah *first-order gradient* (turunan pertama) kiri dan kanan.
H_L, H_R	Jumlah *second-order gradient* (turunan kedua) kiri dan kanan.
η	*Learning rate*.
$\hat{y}^{(t)}$	Prediksi pada iterasi ke-t.
x_i	Data fitur ke-i.

Penjelasan Rumus:

Metode XGBoost bekerja dengan membangun model secara bertahap menggunakan prinsip *gradient boosting*, yaitu meningkatkan akurasi prediksi secara bertahap dengan menambahkan pohon keputusan baru pada setiap iterasi. Setiap pohon dibangun menggunakan nilai *Gradient* (orde pertama) dan *Hessian* (orde kedua), yang menunjukkan beberapa masalah signifikan pada model

sebelumnya. Regularisasi (γ,) merupakan komponen penting dalam XGBoost karena model ini dapat menjadi sangat kompleks, yang berpotensi menyebabkan *overfitting*. Nilai *gain* menunjukkan bahwa pemecahan *node* dilakukan; Jika nilai *gain* kecil atau negatif, pemecahan *node* tersebut tidak digunakan. Proses ini membuat XGBoost lebih efektif, cepat, dan akurat dibandingkan teknik *boosting* lainnya.

3.4.5. Langkah–Langkah Perhitungan XGBoost

1. Hitung prediksi awal (*base prediction*): Biasanya menggunakan rata-rata atau *log-odds* (untuk klasifikasi).
2. Hitung nilai *gradient* dan *hessian* untuk setiap data: Digunakan sebagai dasar membangun pohon baru.
3. Bangun pohon keputusan pertama
   a. Hitung total *gradient* dan hessian tiap *node*.
   b. Lakukan *split* berdasarkan nilai *gain.*
   c. Hitung bobot *leaf* menggunakan rumus:

$$w_j = -\frac{G_j}{H_j + \lambda}$$

4. *Update* prediksi

$$\hat{y}^{(t)} = \hat{y}^{(t-1)} + \eta f_t(x_i)$$

5. Bangun pohon berikutnya: Diulang sampai jumlah iterasi (K) terpenuhi.
6. Evaluasi model: Menggunakan RMSE, MAE, *Log Loss*, atau AUC (tergantung jenis data).

3.4.6. Contoh Perhitungan Sederhana XGBoost

Agar lebih mudah dipahami, berikut ini disajikan sebuah contoh sederhana (bukan contoh panjang yang mencakup seluruh pohon, melainkan langkah-langkah dasar). Sebagai contoh, nilai penjualan diprediksi menggunakan satu fitur (X) dan tiga data berikut:

Tabel 3.2 Contoh Perhitungan Sederhana XGBoost

Data	X	Y (Aktual)
1	2	10
2	4	12
3	6	18

Penjelasan Perhitungan:

1. Prediksi awal (*baseline*): Gunakan rata-rata y

$$\hat{y}^{(0)} = \frac{10+12+18}{3} = \frac{40}{3} = 13.33$$

2. Hitung *gradient* (turunan pertama) untuk regresi *square error*:

$$g_1 = \hat{y}^{(0)} - y_1 = \frac{40}{3} - 10 = \frac{10}{3} = 3.33$$

$$g_2 = \hat{y}^{(0)} - y_2 = \frac{40}{3} - 12 = \frac{4}{3} = 1.33$$

$$g_3 = \hat{y}^{(0)} - y_3 = \frac{40}{3} - 18 = -\frac{14}{3} = -4.66$$

Dan $h_1 = h_2 = h_3 = 1$.

3. Pertimbangkan satu calon *split*: Misalkan kandidat *split* berdasarkan *X* adalah:

   Left node: $X \leq 3 \rightarrow$ hanya data No.1.

   Right node: $X > 3 \rightarrow$ data No.2 dan No.3.

   Hitung jumlah *gradient* dan *hessian* tiap sisi:

Left: $G_L = g_1 = \frac{10}{3}, \quad H_L = h_1 = 1$

Right: $G_R = g_2 + g_3 = \frac{4}{3} + (-\frac{14}{3}) = -\frac{10}{3}, \quad H_R = h_2 + h_3 = 1 + 1 = 2$

Catatan : $G_L + G_R = \frac{10}{3} + (-\frac{10}{3}) = 0$.

4. Hitung *Gain* untuk *split* (gunakan rumus XGBoost).

   Rumus *gain*:

$$Gain = \frac{1}{2}(\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda}) - \gamma$$

   Substitusi nilai:

$$G_L^2 = (\frac{10}{3})^2 = \frac{100}{9}$$

$$G_R^2 = (-\frac{10}{3})^2 = \frac{100}{9}$$

$$H_L + \lambda = 1 + 1 = 2$$

$$H_R + \lambda = 2 + 1 = 3$$

$$(G_L + G_R)^2 = 0^2 = 0$$

$$H_L + H_R + \lambda = 1 + 2 + 1 = 4$$

$$\gamma = 0$$

   Maka:

$$Gain = \frac{1}{2}(\frac{\frac{100}{9}}{2} + \frac{\frac{100}{9}}{3} - 0) - 0$$

$$Gain = \frac{1}{2}(\frac{100}{9} \times \frac{1}{2} + \frac{100}{9} \times \frac{1}{3})$$

$$Gain = \frac{1}{2}(\frac{100}{18} + \frac{100}{27})$$

$$Gain \approx 4.6296296296$$

$$Gain \approx 4.63$$

Karena $Gain > 0$, *split* tersebut menguntungkan dan dapat diterima.

5. Hitung bobot (*weight*) tiap *leaf*

   Rumus bobot *leaf j*:

$$w_j = -\frac{G_j}{H_j + \lambda}$$

   Untuk *Left leaf*:

$$w_L = -\frac{G_L}{H_L + \lambda} = \frac{-\frac{10}{3}}{2} = -\frac{5}{3} \approx -1.6666666667$$

   Untuk *Right leaf:*

$$w_R = -\frac{G_R}{H_R + \lambda} = \frac{-\frac{10}{3}}{3} = \frac{10}{9} \approx 1.1111111111$$

6. *Update* prediksi dengan *learning rate* $\eta = 0.3$

   Formula *update* untuk setiap data *i*:

$$\hat{y}^{(1)} = \hat{y}^{(0)} + \eta f_1(x_i)$$

   di mana $f_1(x_i)$ adalah *weight leaf* yang memetakan x_i

   a. Untuk data No.1 (kiri): $f_1(x_1) = w_L = -\frac{5}{3}$

$$\hat{y}_1^{(1)} = \frac{40}{3} + 0.3\left(-\frac{5}{3}\right) = \frac{40}{3} - \frac{0.3 \times 5}{3} = 12.8333333$$

   (atau perhitungan desimal: $13.3333333 - 0.3 \times 1.6666667 = 13.3333333 - 0.5 = 12.8333333$.

   b. Untuk data No.2 dan No.3 (kanan): $f_1(x) = w_R = \frac{10}{9}$

$$\hat{y}_{2,3}^{(1)} = \frac{40}{3} + 0.3\left(\frac{10}{9}\right) = \frac{40}{3} + \frac{3}{9} = 13.6666667$$

(atau perhitungan desimal: $13.3333333 + 0.3 \times 1.1111111 = 13.3333333 + 0.33333333 = 13.6666667$.

7. Evaluasi perubahan *error* (sekilas)

   Sebelum pohon: *Residual* (gradien awal) untuk No.1 adalah $g_1 = 3.3333333$. Setelah *update*, *residual* untuk data No.1 menjadi:

$$g_1^{(1)} = \hat{y}_1^{(1)} - y_1 = 12.8333333 - 10 = 2.8333333$$

   berkurang dari 3.333333 menjadi 2.833333. Untuk data No.2 *residual*: $g_2^{(0)} = 1.3333333$ meningkat sedikit menjadi $g_2^{(1)} = 13.6666667 - 12 = 1.6666667$, sedangkan untuk data No.3 *residual* berkurang magnitudenya dari $g_1^{(3)} = -4.6666667$ menjadi $g_1^{(3)} = 13.6666667 - 18 = -4.3333333$.

   Secara keseluruhan, proses *boosting* tetap menunjukkan perlunya perbaikan karena model tersebut akan terus mengembangkan pohon berikutnya guna mengurangi ketidakakuratan.

3.4.7. Parameter Penting XGBoost

Beberapa parameter yang sering disesuaikan untuk penggunaan praktis pada dataset (seperti klasifikasi *Fast-Moving* vs. *Slow-Moving*) adalah sebagai berikut:

1. *Learning_rate* / eta (η): Laju pembelajaran bobot untuk setiap iterasi; Nilai kecil (misalnya 0,01–0,1) meningkatkan pembelajaran tetapi juga meningkatkan generalisasi. Nilai ini dikombinasikan dengan *learning_rate* untuk menentukan kompleksitas keseluruhan.
2. *N_estimators* (*num_boost_round*): Jumlah iterasi (pohon) dalam proses *boosting*.

3. *Max_depth*: Kedalaman maksimum per pohon; Pengendali utama kompleksitas model. Nilai kecil (misalnya 3–8) biasanya digunakan untuk mencegah *overfitting*.
4. *Subsample*: Proporsi sampel yang digunakan pada setiap iterasi (*bagging*). Nilai < 1.0 menunjukkan adanya unsur acak dan memudahkan generalisasi.
5. *Colsample_bytree* / *colsample_bylevel*: Fitur yang digunakan per pohon atau per *level*. Gunakan dataset yang besar.
6. *Gamma* (γ): Jumlah pengurangan kerugian minimum yang diperlukan untuk membagi; Semakin besar nilai *gamma*, semakin konservatif simpul tersebut.
7. *Min_child_weight*: Jumlah bobot *instance* (*hessian*) terkecil yang diperlukan untuk sebuah anak; Hal ini mencegah pembentukan daun dengan jumlah pengamatan yang sangat sedikit.
8. *Reg_alpha* (L1) dan *reg_lambda* (L2): Parameter regularisasi tambahan.

Parameter-parameter ini sering dioptimalkan dengan menggunakan pencarian *grid*, pencarian acak, atau optimisasi *Bayesian* untuk mendapatkan keseimbangan terbaik antara bias dan variasi dalam data teks. Teknik penyetelan ini terlihat jelas dalam studi yang membandingkan algoritma XGBoost dengan data Indonesia (Dachi & Sitompul, 2023).

3.4.8. Kelebihan XGBoost dibanding Model Lain

Menurut (Opitasari et al., 2024) terdapat beberapa keunggulan XGBoost yang membuatnya populer dalam klasifikasi penjualan:

1. Kinerja tinggi: Sering kali memberikan hasil dan metrik yang lebih akurat dibandingkan pohon klaster klasik berkat regularisasi bawaan dan optimasi *gradient* orde dua.

2. Efisiensi komputasi: Penerapan teknik optimasi (pembuatan pohon secara paralel, kesadaran *cache*) yang membuatnya relatif cepat untuk dataset besar.
3. Regularisasi adalah pengendalian terhadap kompleksitas.
4. *γ, λ, reg_alpha, min_child_weight,* pemangkasan (*pruning*) membantu mencegah *overfitting*.
5. Fleksibilitas *loss function*: Mendukung berbagai *loss* (*logistic*, *squared error*, *poisson*, dll.) sehingga mudah dipakai untuk klasifikasi maupun regresi.
6. Kemampuan untuk menangani nilai yang hilang secara internal serta berbagai jenis fitur (numerik dan kategorikal setelah pengkodean).

3.4.9. Kelemahan XGBoost

Meskipun demikian, XGBoost juga memiliki keterbatasan (Opitasari eit al., 2024):

1. Membutuhkan upaya penyesuaian: Banyaknya hiperparameter mengharuskan proses penyesuaian yang cukup intensif untuk mencapai kinerja optimal.
2. Kurang interpretabilitas: Interpretasi yang dilakukan oleh sekelompok orang bisa jadi kurang jelas dibandingkan keputusan sederhana yang dibuat oleh satu orang; Selain itu, interpretasi memerlukan penggunaan teknik tambahan (SHAP, signifikansi fitur).
3. Sensitif terhadap ketidakseimbangan data: Tanpa penyesuaian kelas (*class weighting*, *sampling*, atau *scale_pos_weight*), kinerja kelas minor mungkin terganggu. Analisis perbandingan LightGBM vs. XGBoost di Indonesia menyoroti masalah ini serta solusi terkait sampling dan penyesuaian.
4. Penggunaan memori: Untuk dataset besar, penggunaan memori XGBoost dapat sebanding dengan implementasi *boosting* yang tidak dioptimalkan.

Berdasarkan karakteristik yang disebutkan di atas, algoritma XGBoost dipilih untuk penelitian ini karena kemampuannya menganalisis data penjualan dalam jumlah besar serta menghasilkan model klasifikasi yang akurat dan efisien. Fitur total_qty dan frekuensi transaksi digunakan sebagai masukan dalam penelitian ini untuk menggambarkan tingkat penjualan produk.

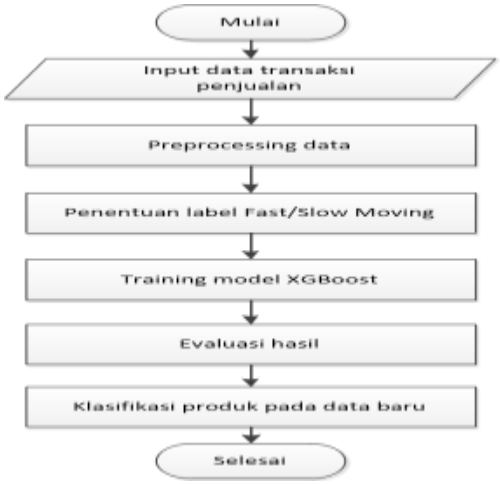
3.5. Perancangan Sistem

3.5.1. Flowchart Sistem

Prosedur keseluruhan sistem ini adalah menggunakan diagram alir untuk menggambarkan proses pengolahan data dari awal hingga akhir. Langkah pertama sistem ini melibatkan pemasukan data transaksi dari PT Rodes Chemindo sebagai sumber informasi utama untuk analisis klasifikasi produk. Data transaksi yang telah selesai kemudian dimasukkan kei dalam fase persiapan, yaitu proses analisis data secara otomatis menggunakan program untuk mengatasi masalah nilai yang hilang, data ganda, dan format data sehingga semuanya dapat dianalisis. Setelah analisis data yang menyeluruh, langkah selanjutnya adalah menentukan label *Fast-Moving* dan *Slow-Moving* berdasarkan fitur agregat frekuensi transaksi dan total penjualan produk.

Data yang telah diberi label kelas target kemudian digunakan dalam fase pelatihan XGBoost. Pada fase ini, algoritma diterapkan secara sistematis untuk menganalisis karakteristik penjualan produk dan menciptakan model klasifikasi yang andal. Setelah proses evaluasi selesai, sistem akan menggunakan metrik evaluasi statistik seperti, seperti *Accuracy*, *Precision*, *Recall*, dan *F1-score* untuk menentukan tingkat kinerja model dalam klasifikasi produk.

Berdasarkan hasil evaluasi tersebut, model matematis yang ideal kemudian digunakan untuk melakukan klasifikasi produk pada data baru. Proses ini akan secara otomatis menentukan apakah suatu produk termasuk dalam kategori *Fast-Moving* atau *Slow-Moving* berdasarkan pola yang sebelumnya dipelajari dari model. Setiap langkah dalam proses ini telah diselesaikan, yang menandakan bahwa sistem *online* telah berhasil menjalankan fungsi klasifikasi produk secara otomatis.



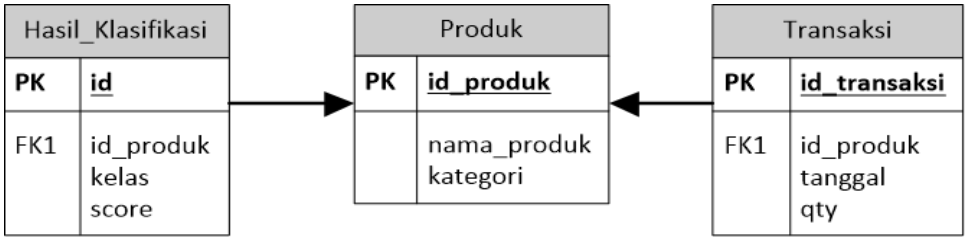
Gambar 3.1 Flowchart Sistem

3.5.2. Struktur Data

Struktur data merupakan landasan penting dalam pengembangan sistem karena menunjukkan bagaimana data diorganisasikan, dihubungkan, dan dianalisis selama proses analisis atau klasifikasi model. Dalam penelitian ini, struktur data digunakan untuk memastikan bahwa seluruh informasi yang berkaitan dengan produk, transaksi penjualan, dan hasil klasifikasi dapat disajikan secara teratur. Analisis struktur data dilakukan dengan menggunakan diagram hubungan entitas, yang juga dikenal sebagai *Entity Relationship Diagram* (ERD) untuk menggambarkan hubungan antar tabel dalam sistem. Melalui ERD, data mulai dari transaksi penjualan hingga proses klasifikasi dapat dipahami dengan jelas dan

sistematis. Struktur data yang digunakan dalam penelitian ini dijelaskan sebagai berikut:

1. Diagram Hubungan Entitas (ERD): Dalam penelitian ini, ERD terdiri dari tiga entitas utama: Produk, Transaksi, dan Hasil Klasifikasi.
   a. Tujuan Entitas Produk adalah untuk menyediakan informasi induk mengenai setiap produk yang didistribusikan oleh perusahaan.
   b. Entitas Transaksi menganalisis data historis mengenai aktivitas penjualan produk secara terperinci, termasuk jumlah unit yang terjual dan tanggal faktur.
   c. Entitas Hasil_Klasifikasi berfungsi secara khusus untuk menampilkan data keluaran (*output*), yaitu prediksi status label model XGBoost berdasarkan pergerakan tingkat kepercayaannya.



Gambar 3.2 Relasi Antar Tabel (ERD)

Hubungan antara entitas-entitas ini digambarkan secara relasional. Hubungan Satu-ke-Banyak (1: ∞), antara entitas Produk dan Transaksi menunjukkan bahwa satu produk dapat termasuk dalam beberapa transaksi. Sebaliknya, hubungan antara entitas Produk dan Hasil_Klasifikasi adalah Satu-ke-Satu 1: 1, di mana setiap ID produk hanya memiliki satu baris catatan keputusan hasil klasifikasi akhir dari model *machine learning*. Struktur tabel yang digunakan dalam basis data penelitian ini adalah sebagai berikut:

Tabel 3.3 Tabel Produk

Field	Tipe	Keterangan
id_produk (PK)	INT	Kode identifikasi produk unik (Kunci Utama).
nama_produk	VARCHAR (255)	Deskripsi nama produk.
kategori	VARCHAR (100)	Jenis atau kategori produk.

Tabel produk menampilkan data barang yang menjadi objek analisis. Informasi dalam tabel ini digunakan sebagai acuan utama untuk menghubungkan transaksi dan hasil klasifikasi.

Tabel 3.4 Tabel Transaksi

Field	Tipe	Keterangan
id_transaksi (PK)	INT	Kunci Utama (Kode unik nota transaksi).
id_produk (FK)	INT	Kunci utama yang merujuk ke tabel produk utama.
tanggal	*DATE*	Durasi transaksi.
qty	INT	Total volume barang yang terjual.

Tabel transaksi menampilkan riwayat penjualan setiap produk. Jumlah dan frekuensi transaksi merupakan faktor krusial dalam menentukan label *Fast-Moving* dan *Slow-Moving*, serta digunakan dalam model XGBoost.

Tabel 3.5 Tabel Hasil_Klasifikasi

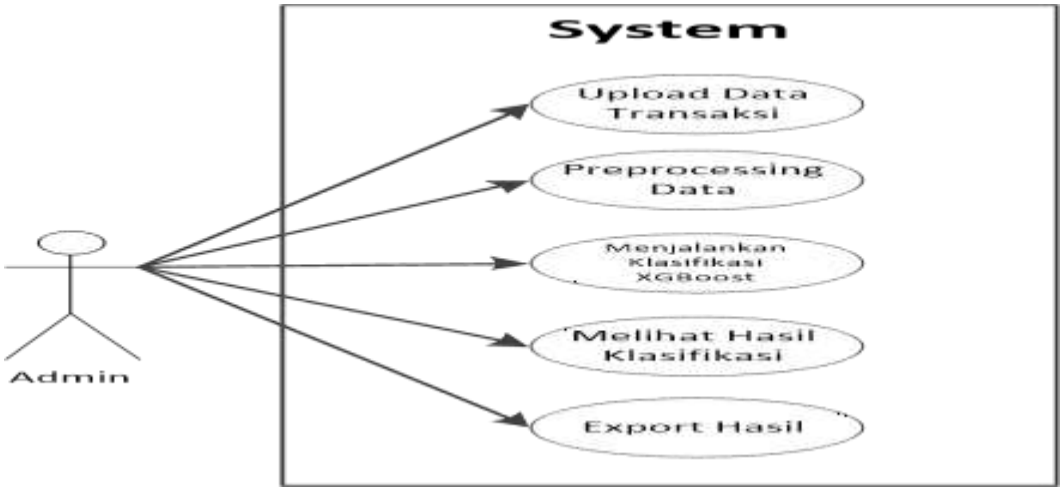
Field	Tipe	Keterangan
Id (PK)	INT	Kode klasifikasi baris unik (Kunci Utama).
id_produk (FK)	INT	Kunci yang mewakili produk terpilih.
kelas	ENUM (*Fast, Slow*)	Label hasil klasifikasi model.
score	*FLOAT*	Nilai tingkat probabilitas/kepercayaan prediksi model.

Tujuan tabel hasil_klasifikasi adalah untuk menampilkan hasil proses klasifikasi XGBoost. Nilai kelas menunjukkan apakah suatu produk termasuk *Fast-Moving* atau *Slow-Moving*, sedangkan skor menunjukkan tingkat kepercayaan model terhadap prediksi tersebut.

3.5.3. Use Case Diagram

Setelah memahami simbol-simbol utama yang digunakan dalam Tabel 2.1, berikut ini disajikan *Use Case Diagram* dari sistem yang dikembangkan dalam penelitian ini. *Diagram Use Case* tersebut digunakan untuk menggambarkan hubungan antara aktor (pengguna sistem) dan fungsi-fungsi utama yang tersedia dalam sistem. Diagram ini menggambarkan secara terstruktur bagaimana pengguna berinteraksi dengan proses sistem, seperti menghubungkan kumpulan data transaksi penjualan, menganalisis data prapemrosesan, menjalankan model klasifikasi menggunakan algoritma XGBoost, dan akhirnya melihat serta menganalisis hasil

klasifikasi.



Gambar 3.3 Use Case Diagram Sistem

Penjelasan *Use Case*:

Tabel 3.6 Peran Aktor

No	Aktor	Peran
1	Admin	Memiliki akses penuh untuk menganalisis data transaksi, melakukan analisis data, mengevaluasi model *machine learning*, dan menganalisis hasil klasifikasi produk.

Tabel 3.7 Definisi Use Case Sistem

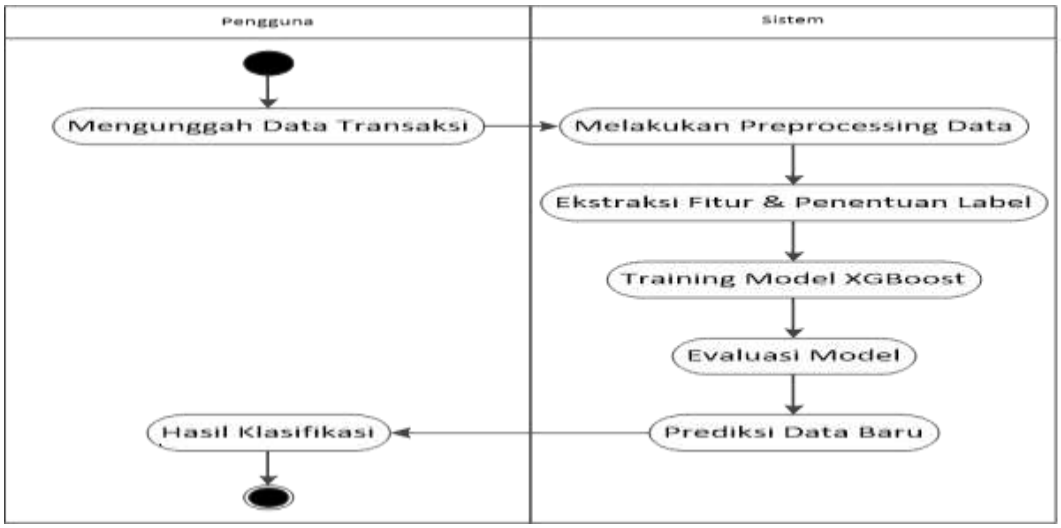
No	Aktor	Nama *Use Case*	Keterangan
1	Admin	Input Data Transaksi	Unggah berkas transaksi .CSV atau masukkan data transaksi secara manual melalui situs web.

No	Aktor	Nama *Use Case*	Keterangan
2	Admin / Sistem	*Preprocessing Data*	Pengguna memanfaatkan sistem ini untuk melakukan analisis data transaksi dari nilai kosong (*null*), mengidentifikasi data duplikat, serta mengukur jumlah dan frekuensi penjualan produk.
3	Admin / Sistem	Menjalankan Klasifikasi XGBoost	Dengan memanfaatkan algoritma XGBoost, pengguna mengevaluasi proses pengumpulan dan analisis data guna memperoleh hasil klasifikasi produk yang akurat.
4	Admin	Melihat Hasil Klasifikasi	Sistem menampilkan bagian tabel dasbor yang berisi kode produk, nama produk, beserta label keputusan *Fast-Moving* atau *Slow-Moving*, serta probabilitasnya.
5	Admin	*Export* Hasil	Pengguna dapat melihat hasil klasifikasi produk akhir dalam format dokumen *Excel* atau PDF.

3.5.4. Activity Diagram

Setelah memahami simbol-simbol *Activity Diagram* yang telah dijelaskan dalam Tabel 2.2, berikut ini disajikan *Activity Diagram* dari sistem yang telah dikembangkan dalam penelitian ini. Dalam proses mengklasifikasikan produk sebagai *Fast-Moving* atau *Slow-Moving* menggunakan algoritma *Extreme Gradient Boosting* (XGBoost), Diagram ini digunakan untuk menggambarkan berbagai

aktivitas yang dilakukan oleh pengguna dan sistem secara sistematis. Diagram ini menggambarkan langkah-langkah yang terlibat dalam berbagai aktivitas, seperti mengumpulkan data transaksi, melakukan prapemrosesan data, membuat model, mengklasifikasikan data, dan menampilkan hasilnya kepada pengguna.



Gambar 3.4 Activty Diagram

Aktivitas sistem dimulai di sisi Pengguna ketika Administrator memulai tahap awal dengan melakukan tindakan untuk memasukkan data transaksi kei dalam sistem menggunakan dua opsi; Baik dengan mengimpor data transaksi yang telah diformat dalam format .CSV maupun memasukkan data transaksi secara manual menggunakan formulir yang tersedia di aplikasi. Alur kendali sepenuhnya berpindah kei sisi Sistem untuk mengevaluasi proses persiapan data secara otomatis setelah data yang valid diperoleh. Proses ini melibatkan pengumpulan data yang kosong (*null*) dan analisis data transaksi yang terduplikasi.

Langkah selanjutnya adalah ekstraksi fitur dan penentuan label, di mana sistem menghitung jumlah total unit yang terjual (total_qty) serta frekuensi transaksi dari setiap produk untuk membuat label target *Fast-Moving* atau *Slow-Moving*. Setelah data diberi label, sistem melanjutkan ke proses pelatihan model XGBoost. Pada fase

ini, dataset dibagi menjadi data latih dan data uji, setelah itu algoritma XGBoost Classifier diterapkan untuk mempelajari pola pergerakan barang.

Setelah model berhasil dibangun, sistem beralih kei fase evaluasi model dengan menggunakan metrik seperti *Confusion Matrix, Accuracy, Precision, Recal* dan *F1-Score*. Selanjutnya, berdasarkan pola historis yang telah dipelajari sebelumnya, model ini digunakan untuk mengevaluasi fungsi prediksi secara otomatis terhadap data baru. Hasil prediksi akhir sistem kemudian dikirim kembali ke sistem pengguna untuk menampilkan tabel hasil klasifikasi produk di dasbor. Seluruh rangkaian proses kegiatan ini berakhir dengan aman pada status akhir (*node* akhir).

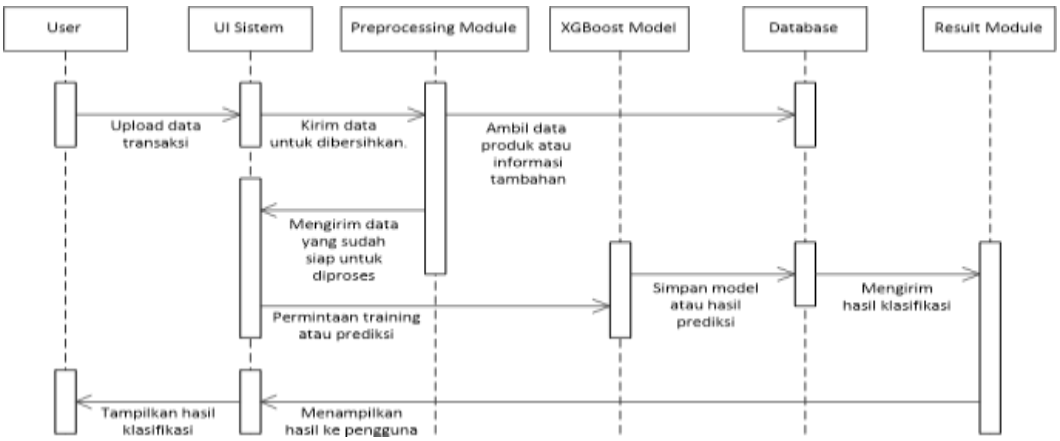
3.5.5. Sequence Diagram

Setelah memahami simbol-simbol *Seiquieincei Diagram* yang telah dijelaskan dalam Tabel 2.3, berikut ini disajikan *Seiquieincei Diagram* dari sistem yang telah dikembangkan dalam penelitian ini. *Sequence Diagram* digunakan untuk menggambarkan bagaimana aktor berinteraksi dengan komponen sistem berdasarkan urutan waktu selama proses klasifikasi produk *Fast-Moving* dan *Slow-Moving* menggunakan algoritma *Extreme Gradient Boosting* (XGBoost). Objek utama atau *lifeline* dalam arsitektur sistem adalah:

1. *User*: Aktor atau komponen pengguna yang menginisiasi jalannya sistem.
2. UiI Sistem: Antarmuka pengguna grafis (*frontend*) yang memfasilitasi interaksi pengguna.
3. *Preprocessing Module*: Modul *backend Python* yang dapat menganalisis dan menyajikan data dalam bentuk tabel.
4. XGBoost Model: Algoritma *machine learning* yang diimplementasikan.

5. *Database*: Sistem manajemen basis data relasional MySQL sebagai media penyimpanan.

Alur *Sequence*:



Gambar 3.5 Sequence Diagram

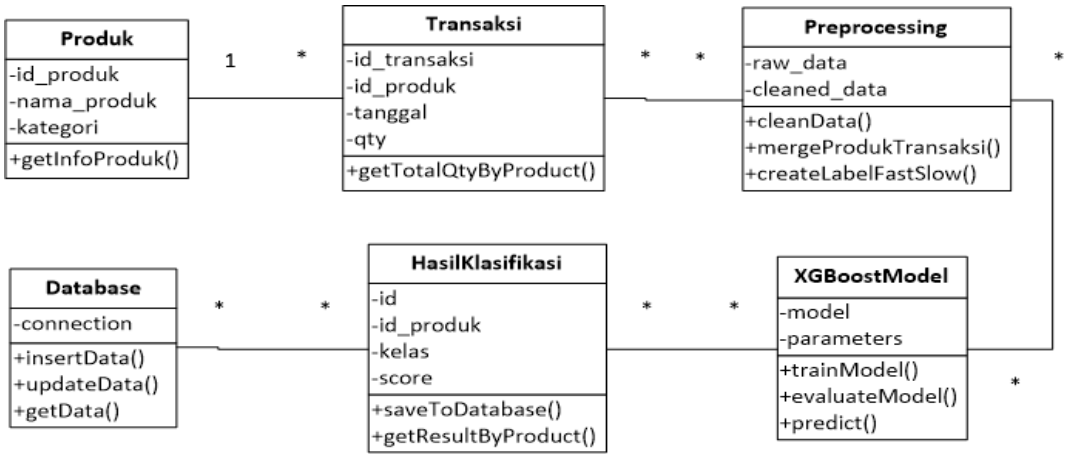
Proses urutan dimulai ketika objek pengguna melakukan tindakan untuk memasukkan data transaksi melalui sistem pengguna, sebaiknya dengan memasukkan data transaksi dalam format .CSV atau memasukkan data secara manual menggunakan rumus yang tersedia. Setelah pengumpulan data, Sistem Antarmuka Pengguna (UI) mengirimkan data kei Modul Pra-pemrosesan. Dalam proses pembersihan yang telah dijelaskan sebelumnya, Modul Pra-pemrosesan memproses komponen data dasar untuk memperoleh data transaksi atau data produk yang diperlukan sebagai informasi tambahan. Modul Pra-pemrosesan mengembalikan objek data yang telah diproses kei Sistem Antarmuka Pengguna setelah proses pembersihan, manipulasi, dan ekstraksi fitur selesai. Selanjutnya, Sistem Antarmuka Pengguna mengirimkan permintaan analisis atau prediksi kei objek Model XGBoost.

Setelah objek algoritma melakukan perhitungan komputasional, Model XGBoost mengirimkan data untuk menentukan hasil klasifikasi atau prediksi model ke basis

data. Selanjutnya, basis data menyimpan hasil klasifikasi tersebut di Modul Hasil untuk digunakan sebagai representasi laporan. Pada akhirnya, Modul Hasil mengirimkan data kei Antarmuka Pengguna Sistem (UI) untuk menampilkan hasil klasifikasi produk sebagai *Fast-Moving* atau *Slow-Moving* dengan cara yang mudah dipahami.

3.5.6. Class Diagram

Setelah memahami simbol-simbol *Class Diagram* yang telah dijelaskan pada Tabel 2.4, berikut ini disajikan *Class Diagram* perancangan dari sistem yang dikembangkan dalam penelitian ini. *Class Diagram* digunakan untuk menggambarkan struktur sistem, yang terdiri dari kelas, atribut, metode, dan hubungan antar kelas. Diagram ini berfungsi sebagai alat untuk menggambarkan struktur sistem klasifikasi produk. Dengan menggunakan algoritma XGBoost, Produk yang Cepat Terjual dan Produk yang Lambat Terjual.



Gambar 3.6 Class Diagram

Rincian fungsionalitas dari masing-masing kelas dijelaskan sebagai berikut:

a. *Class*: Produk

   Deskripsi Singkat: Kelas Produk menyajikan struktur data induk barang yang didistribusikan oleh perusahaan.

Atribut:

id_produk: int — Penanda unik (kunci utama) untuk setiap produk.

nama_produk: *string* — Menjelaskan nama produk yang ada dalam sistem.

kategori: *string* — Rumpun jenis atau kelompok kategori produk.

Metode:

*getInfo*Produk — Menyediakan informasi data produk yang komprehensif untuk memenuhi kebutuhan visualisasi tabel atau penggabungan.

b. *Class*: Transaksi

Deskripsi Singkat: Kelas Transaksi mencatat setiap aktivitas transaksi untuk setiap barang beserta tanggal kejadiannya.

Atribut:

id_transaksi: int — Identifikasi unik untuk setiap transaksi.

id_produk: int — Kunci tamu (*foreign key*) yang terkait dengan kelas produk.

tanggal: *date* — Tanggal terjadinya transaksi penjualan.

qty: int — Jumlah total unit produk yang terjual.

Metode:

getTotalQtyByProduct — Fungsi ini menghitung dan menampilkan jumlah total yang terjual untuk suatu produk dalam proses *feature engineering*.

c. *Class*: *Preprocessing*

Deskripsi Singkat: Sebelum memasuki proses pemodelan *machine learning*, semua tahap transformasi dan persiapan data dibahas secara terperinci

Atribut:

raw_data: *DataFrame* — Representasi tabel data transaksi dari file .CSV atau input manual pengguna.

cleaned_data: *DataFrame* — Ini adalah kumpulan data yang telah dibersihkan dan ditransformasi setelah setiap ekstraksi.

Metode:

cleanData — Membersihkan data dari nilai kosong (*null*) dan menghapus data duplikat.

*merge*ProdukTransaksi — Menggabungkan tabel produk dan transaksi menjadi satu kumpulan data berdasarkan kunci hubungan.

createLabelFastSlow —Fungsi ini menghitungjumlah total beserta frekuensinya untuk menetapkan label target *Fast* atau *Slow* pada suatu produk.

d. *Class*: XGBoostModel

Deskripsi Singkat: Kelas XGBoostModel menghubungkan seluruh proses di balik pembuatan, analisis, evaluasi metrik, dan penilaian algoritma XGBoost.

Atribut:

model: *XGBClassifier* — Objek instansiasi model XGBoost yang ditentukan setelah proses analisis.

parameters: *dict* — Hiperparameter yang digunakan untuk mengonfigurasi model.

Metode:

trainModel(data) — Mengambil dataset pelatihan untuk melakukan proses penyesuaian klasifikasi XGBoost.

evaluateModel(*data_test*) — Metode ini mencakup *Confusion Matrix, Accuracy, Precision, Recall,* dan *F1-Score*.

predict(data_baru) — Melakukan prediksi berdasarkan data baru untuk mendapatkan kelas target dengan probabilitas tertentu.

e. *Class*: Hasil_Klasifikasi

Deskripsi Singkat: Kelas Hasil_Klasifikasi menampilkan data keluaran (*output*) model yang dapat ditampilkan atau dikirim kei web.

Atribut:

id: int — Identifikasi unik untuk baris hasil klasifikasi.

id_produk: int — Kunci yang menunjukkan referensi produk.

kelas: *string* — Label keputusan akhir hasil prediksi (Cepat/Lambat).

score: *float* — Nilai tingkat probabilitas, atau skor kepercayaan, model terkait kelas yang dipilih.

Metode:

saveToDatabase — Fungsi ini menyimpan hasil klasifikasi baris data kei dalam tabel basis data.

getResultByProduct — Mengambil hasil klasifikasi untuk produk saat ini dari basis data untuk ditampilkan di dasbor.

f. *Class*: *Database*

Deskripsi Singkat: Kelas *Database* menyediakan abstraksi dari modul konektivitas serta operasi data relasional pada basis data MySQL.

Atribut:

connection: *object* — Objek koneksi basis data (konektor MySQL/mesin SQLAlchemy).

Metode:

insertData — Menambahkan data baru kei tabel basis data yang relevan.

updateData — Fungsi ini melakukan pembaruan atau modifikasi pada basis data berdasarkan keadaan saat ini.

getData — Mengambil data dari basis data menggunakan kueri SQL yang sesuai.

BAB IV

IMPLEMENTASI DAN PENGUJIAN SISTEM

4.1. Kebutuhan Sistem

Kebutuhan sistem mencakup spesifikasi perangkat keras dan perangkat lunak yang digunakan untuk mendukung pengembangan, pengujian, dan penerapan sistem klasifikasi berbasis web untuk produk *Fast-Moving* dan *Slow-Moving* dengan menggunakan algoritma *Extreme Gradient Boosting* (XGBoost). Tujuan dari kebutuhan sistem ini adalah untuk memastikan bahwa seluruh proses pengolahan data, pengembangan model, dan evaluasi model berjalan lancar, stabil, dan sesuai dengan sistem yang telah ditetapkan. Perangkat keras (*hardware*) dan perangkat lunak (*software*) merupakan komponen sistem yang diperlukan untuk penelitian ini.

1. Kebutuhan Perangkat Keras (*Hardware*)

   Perangkat keras yang digunakan dalam penelitian ini adalah komputer atau laptop dengan spesifikasi yang memungkinkan pemrosesan awal data, analisis model pembelajaran mesin, pengujian model, dan implementasi sistem berbasis web. Spesifikasi perangkat keras yang digunakan adalah sebagai berikut:

   a. Prosesor: *Intel Core* i3/i5/i7 atau prosesor setara dengan arsitektur multi-core untuk mendukung pemrosesan data, rekayasa fitur, dan analisis algoritma XGBoost.
   b. RAM: Minimal 4 GB (disarankan 8–16 GB) untuk menganalisis kumpulan data besar selama prapemrosesan, analisis, dan pengembangan model.

c. *Storage*: Gunakan *Solid State Drive* (SSD) dengan kapasitas minimal 256 GB dan ruang penyimpanan tersedia sebesar 20 GB untuk menyimpan lingkungan *Python*, kumpulan data penelitian, data dasar, data transaksi yang disimpan dalam berkas .CSV atau dimasukkan secara manual kei dalam sistem, serta proses entri dan keluaran data.

d. Perangkat Input dan *Output*: *Keyboard*, *mouse*, dan monitor digunakan sebagai alat interaksi pengguna selama pengembangan atau pengujian sistem.

Spesifikasi perangkat keras ini digunakan untuk mengevaluasi setiap langkah proses penelitian, termasuk analisis data transaksi, pengembangan model XGBoost, evaluasi kinerja model, dan implementasi sistem klasifikasi berbasis web.

2. Kebutuhan Perangkat Lunak (*Software*)

Perangkat lunak ini digunakan untuk memfasilitasi pemrosesan data, pengembangan model pembelajaran mesin, pemrosesan basis data, dan implementasi aplikasi web. Saat ini, perangkat lunak yang digunakan adalah sebagai berikut:

a. Sistem Operasi (Windows 10/11)

Sistem operasi ini digunakan sebagai sistem operasi utama karena kompatibilitasnya dengan berbagai alat pengembangan seperti *Python*, MySQL, XAMPP, dan *Visual Studio Code*.

b. Pemrograman *Python*

Bahasa pemrograman ini digunakan sebagai bahasa pemrograman utama untuk pengembangan sistem, prapemrosesan data, rekayasa fitur, evaluasi

model XGBoost, dan integrasi dengan aplikasi web menggunakan kerangka kerja *Flask*.

c. *Library Machine Learning* dan Pengolahan Data

1) *Pandas* digunakan untuk memeriksa, mengatur, memanipulasi, dan menganalisis kumpulan transaksi penjualan dalam format *DataFrame*.
2) *NumPy* digunakan untuk meningkatkan perhitungan numerik dan pemrosesan data secara efisien.
3) *Scikit-learn* digunakan untuk pemisahan dataset (pemisahan *train-test*) dan metrik evaluasi model seperti *Confusion Matrix*, *Accuracy*, *Precision*, *Recall*, dan *F1-score*.
4) XGBoost digunakan sebagai perpustakaan utama dalam pengembangan model klasifikasi produk *Fast-Moving* dan *Slow-Moving* karena kinerjanya yang tinggi dalam menganalisis data tabel dan menghasilkan akurasi klasifikasi yang baik.

d. *Framework Flask*

Digunakan untuk mengintegrasikan model XGBoost ke dalam aplikasi berbasis web sehingga pengguna dapat melakukan proses klasifikasi melalui antarmuka sistem.

e. *Visual Studio Code* (VS *Code*)

Digunakan sebagai Lingkungan Pengembangan Terpadu (IDE) untuk menulis, menguji, dan men-debug kode *Python*, *HTML*, *CSS*, dan *JavaScript*.

f. MySQL

Digunakan sebagai Sistem Manajemen Basis Data Relasional (RDBMS) untuk menyimpan data transaksional, data master produk, dan hasil klasifikasi yang dihasilkan sistem.

g. XAMPP

Digunakan sebagai server lokal yang menyediakan layanan *Apache* dan MySQL sehingga sistem dapat diuji dalam lingkungan lokal selama proses pengembangan (Muludin eit al., 2025).

h. phpMyAdmin

Aplikasi berbasis web ini digunakan untuk memudahkan operasi basis data MySQL, seperti membuat tabel, menganalisis data transaksi, dan melakukan administrasi basis data menggunakan antarmuka pengguna grafis.

i. Web *Browser* (*Google Chrome* atau *Microsoft Edge*)

Digunakan sebagai sarana untuk memantau, mengevaluasi, dan mendemonstrasikan berbagai sistem klasifikasi berbasis web yang telah dikembangkan.

Perangkat lunak yang disebutkan di atas secara konsisten mengintegrasikan semua fase pengembangan sistem, mulai dari analisis data transaksi dan klasifikasi model menggunakan algoritma XGBoost hingga implementasi dan pengujian aplikasi web.

4.2. Implementasi Sistem

Fase implementasi sistem melibatkan penerapan hasil sistem, yang telah dijelaskan dalam Bab III, kei dalam aplikasi berbasis web. Pada fase ini, sistem

diimplementasikan sebagai sistem yang mampu mengklasifikasikan produk menjadi *Fast-Moving* atau *Slow-Moving* menggunakan algoritma *Extreme Gradient Boosting* (XGBoost). Beberapa komponen utama dari implementasi sistem ini meliputi pengelolaan data transaksi, proses prapemrosesan dan pemodelan fitur, model klasifikasi XGBoost, analisis data menggunakan MySQL sebagai basis data, serta analisis hasil menggunakan kerangka kerja *Flask*. Sistem ini dirancang untuk memfasilitasi pemrosesan dan klasifikasi data terstruktur, mulai dari penghubungan data transaksi hingga penampilan hasil klasifikasi kepada pengguna.

4.2.1. Gambaran dan Arsitektur Sistem

Aplikasi prototipe berbasis web yang dikembangkan dalam penelitian ini dapat membantu mengklasifikasikan produk kei dalam kategori *Fast-Moving* dan *Slow-Moving* berdasarkan data transaksi. Algoritma *Extreme Gradient Boosting* (XGBoost) merupakan metode klasifikasi sistem yang mengevaluasi kualitas produk berdasarkan data dari transaksi penjualan. Kerangka kerja *Flask* digunakan untuk membuat akun pengguna, prosedur pemrosesan data, model klasifikasi, dan basis data MySQL.

PT Rodes Chemindo dapat memanfaatkan sistem ini untuk menganalisis data transaksi dengan lebih cepat, efektif, dan efisien. Pengguna dapat memasukkan data transaksi melalui dua cara; Baik dengan mengimpor data transaksi dalam format .CSV maupun memasukkan data secara manual menggunakan formulir yang tersedia dalam sistem. Data yang dimasukkan secara manual dapat diimpor kei dalam basis data MySQL sehingga dapat digunakan kembali sebagai sumber data untuk analisis dan klasifikasi. Di sisi lain, data yang berasal dari berkas .CSV akan

diproses berdasarkan struktur atribut yang telah ditetapkan dan kemudian dapat diimpor ke dalam basis data untuk digunakan dalam proses analisis. Dengan demikian, kedua metode input ini dapat digunakan sebagai sumber data transaksi yang selanjutnya diproses untuk menghasilkan klasifikasi produk *Fast-Moving* dan *Slow-Moving*. Gunakan struktur atribut yang telah ditetapkan dan dapat digunakan untuk analisis.

Setelah data transaksi tersedia, pengguna dapat memilih rentang waktu untuk transaksi yang akan dianalisis, misalnya 2 Februari 2025 hingga 2 Desember 2025. Sistem kemudian menyusun data sesuai dengan rentang waktu tersebut, sehingga hanya transaksi yang terjadi dalam rentang waktu tersebut yang digunakan dalam proses analisis dan klasifikasi.

Pra-pemrosesan digunakan untuk memproses data transaksi setelah data tersebut dipilih. Sebelum digunakan dalam proses klasifikasi, langkah ini dilakukan untuk memastikan kualitas data. Pra-pemrosesan meliputi pemeriksaan dan penyesuaian nilai kosong (nilai *null* atau tidak ada), penghapusan data duplikat, serta penyelarasan format data agar sesuai dengan kebutuhan penelitian di masa mendatang. Setelah data dinyatakan dengan jelas, sistem memulai proses rekayasa fitur dengan mengubah data transaksi menjadi data produk. Pada fase ini, sistem menghitung jumlah total barang yang terjual (total_qty) dan frekuensi transaksi untuk setiap produk, yang keduanya digunakan untuk menggambarkan pola transaksi dan penjualan produk.

Algoritma XGBoost kemudian menggunakan fitur data untuk klasifikasi. Algoritma ini memanfaatkan model yang telah dikembangkan sebelumnya untuk menghasilkan kategori produk seperti *Fast* atau *Slow*. Setelah itu, hasil klasifikasi

tersebut dimasukkan ke dalam basis data MySQL, sehingga aplikasi dapat menganalisis dan menampilkan kembali hasilnya.

Dasbor sistem menampilkan hasil klasifikasi yang telah diperoleh. Informasi seperti nama, kode, nilai fitur, pergerakan kategori, dan informasi lainnya dapat ditampilkan. Selain itu, sistem menyediakan visualisasi seperti grafik distribusi, tabel, dan diagram lingkaran (pie chart). Hal ini digunakan untuk membandingkan jumlah produk berdasarkan kategori *Fast-Moving* dan *Slow-Moving*. Selain itu, sistem ini menawarkan kemampuan untuk mengonversi hasil klasifikasi kei dalam format PDF dan *Excel*. Hal ini memudahkan penyimpanan, pencetakan, dan penggunaan hasil analisis sebagai dasar pengembangan produk PT Rodes Chemindo. Secara umum, arsitektur sistem klasifikasi produk yang dibuat terdiri dari beberapa tahapan yang saling terkait, seperti:

1. Memasukkan Data Transaksi Pengguna atau Administrator

   Pengguna atau administrator dapat memasukkan data transaksi kei dalam sistem dengan dua cara; Pertama, dengan mengimpor data dalam format .CSV atau memasukkan data secara manual menggunakan rumus yang tersedia di sistem. Data yang dimasukkan secara manual dapat diimpor ke dalam basis data MySQL sebagai data baru sehingga dapat digunakan kembali untuk analisis dan klasifikasi. Sebaliknya, data yang berasal dari berkas .CSV akan diproses sesuai dengan struktur atribut yang telah ditetapkan dan dapat diimpor kei dalam basis data untuk dimanfaatkan pada tahap pemrosesan berikutnya. Dengan demikian, baik data yang diunggah melalui berkas .CSV maupun data yang dimasukkan secara manual dapat digunakan sebagai sumber data transaksi sistem.

2. Rentang Waktu Pemilihan

   Untuk menentukan durasi transaksi yang akan dianalisis, pengguna memilih tanggal awal dan tanggal akhir. Sistem kemudian menampilkan data dalam rentang waktu yang telah ditentukan sebelumnya.

3. Pra-pemrosesan Data

   Sistem menganalisis dan menyediakan data untuk transaksi saat ini. Hal ini mencakup mengidentifikasi nilai kosong atau nol, menghilangkan data duplikat, dan menyelaraskan format data agar masing-masing dapat diproses.

4. Fitur Data Transaksi Yang Telah Disiapkan

   Data dikelompokkan berdasarkan produk guna menyediakan fitur-fitur yang digunakan untuk klasifikasi. Penelitian ini menggunakan dua metrik; Jumlah total yang terjual (total_qty) dan frekuensi transaksi untuk setiap produk.

5. Klasifikasi XGBoost

   Model XGBoost yang telah dikembangkan dan diuji digunakan untuk menganalisis data fitur. Berdasarkan jenis transaksinya, model ini mengklasifikasikan produk menjadi *Fast-Moving* atau *Slow-Moving*.

6. Penyimpanan Hasil

   Hasil klasifikasi diimpor kei dalam basis data MySQL. Informasi seperti kode produk, nama produk, nilai fitur, kategori hasil klasifikasi, dan informasi pendukung lainnya dapat ditemukan disana.

7. Analisis dan Visualisasi Hasil Klasifikasi Data

   Hasil klasifikasi ditampilkan di dasbor dalam bentuk tabel dan visualisasi seperti grafik distribusi atau diagram lingkaran (*pie chart*). Hal ini

memudahkan pengguna untuk membandingkan produk yang laku cepat dan produk yang laku lambat.

8. Laporan Ekspor

   Sistem ini memungkinkan Anda mengekspor hasil klasifikasi kei dalam format PDF dan *Excel*, sehingga memudahkan pengguna untuk memanfaatkan hasil tersebut sebagai sumber daya dalam menganalisis stok produk.

4.2.2. Implementasi dan Pembagian Dataset

Penelitian ini menggunakan data historis PT Rodes Chemindo mengenai transaksi penjualan internal, dengan total 46.025 transaksi dari tahun 2024 hingga 2026. Data ini digunakan sebagai sumber data dalam sistem untuk membantu pengumpulan, analisis, dan penyampaian informasi mengenai transaksi penjualan. Data dikumpulkan berdasarkan waktu dan digunakan dalam sistem sesuai dengan kebutuhan penelitian. Data transaksi dari tahun 2024 hingga 2026 digunakan sebagai pendukung sistem, terutama untuk menyediakan informasi historis dan membantu visualisasi dasbor. Kumpulan data utama, yang terdiri dari 17.973 catatan transaksi dari Januari hingga Desember 2025, digunakan untuk klasifikasi menggunakan algoritma XGBoost. Untuk memastikan bahwa proses analisis menggunakan data secara konsisten setiap tahun, pengumpulan data dilakukan pada tahun 2025.

Kumpulan data, yang sering disebut sebagai data mentah, untuk tahun 2025 memiliki enam belas fitur yang memberikan informasi mengenai transaksi penjualan. Tabel 4.1 menyajikan struktur kumpulan data transaksi, yang digunakan sebagai landasan untuk analisis data.

Tabel 4.1 Struktur Atribut Dataset Transaksi Penjualan

No	Nama Kolom / Atribut	Tipe Data	Deskripsi / Keterangan
1	Tanggal	*Date Time*	Menunjukkan tanggal transaksi penjualan produk.
2	No Faktur	*String*	Nomor nota atau faktur transaksi.
3	*Customer*	*String*	Nama pelanggan atau pihak pembeli produk.
4	*Tipe*	*String*	Kode penanda jenis transaksi.
5	*Is Comment*	*Boolean*	Menunjukkan status komentar pada data transaksi.
6	No Urut	*Integer*	Nomor urut baris item barang dalam satu faktur.
7	Kode Barang	*String*	Kode identifikasi barang.
8	Nama Barang	*String*	Nama atau deskripsi produk yang dijual.
9	*Loc Code*	*String*	Kode lokasi penempatan barang.
10	Qty	*Float*	Jumlah atau kuantitas produk yang terjual.
11	Harga Satuan	*Float*	Harga jual produk per satuan.
12	Hpo Kok	*Float*	Nilai harga pokok penjualan barang.
13	Pct *Disc*	*Float*	Persentase potongan harga yang diberikan.

No	Nama Kolom / Atribut	Tipe Data	Deskripsi / Keterangan
14	Amt *Disc*	*String*	Nilai nominal potongan harga.
15	Jumlah	*Float*	Total nilai transaksi bersih per item.
16	*Posted*	*Boolean*	Status transaksi telah dibukukan atau belum.

Data yang ditampilkan dalam Tabel 4.1 didasarkan pada volume transaksi, sehingga tidak dapat digunakan sebagai objek klasifikasi secara keseluruhan. Untuk memenuhi persyaratan proses klasifikasi, sistem melakukan proses pengolahan dengan memilih atribut-atribut yang relevan dengan tujuan penelitian, yaitu Kode Barang, Nama Barang, Tanggal, dan Qty. Atribut Kode Barang mengidentifikasi setiap produk, sedangkan Nama Barang memberikan informasi mengenai produk yang dianalisis, atribut Tanggal menunjukkan tanggal transaksi, dan Qty menunjukkan jumlah barang yang dibeli. Setelah dilengkapi dengan atribut yang diperlukan, data transaksi kemudian dianalisis dan dihubungkan sesuai dengan produknya. Pada fase ini, jumlah setiap produk dihitung untuk menghasilkan Total Qty, atau total_qty, dan jumlah setiap transaksi dihitung untuk menghasilkan Frekuensi Transaksi. Proses ini mengubah data dari volume transaksi menjadi volume produk. Hasil keseluruhan menunjukkan bahwa sekitar 17.973 transaksi menghasilkan 413 produk unik yang masih dalam proses klasifikasi. Oleh karena itu, selama proses pemodelan, unit analisisnya adalah setiap baris transaksi, tetapi setiap produk kini memiliki fitur agregat. Kumpulan data utama yang digunakan dalam penelitian ini ditunjukkan pada Tabel 4.2.

Tabel 4.2 Ringkasan Dataset Utama Periode 2025

No	Parameter Dataset	Nilai / Ukuran Aktual	Satuan Analisis	Peruntukan Komputasi
1	Total Volume Data	17.973	*Records* / Baris	Data transaksi awal.
2	Total Atribut	16	Kolom	Struktur Dataset.
3	Produk Unik	413	Produk	Objek Klasifikasi.
4	Fitur Utama	2	Variable	Total_qty dan Frekuensi Transaksi.

Sebanyak 17.973 baris data transaksi digunakan sebagai data awal dalam proses pengolahan, dan 413 produk secara khusus digunakan dalam proses klasifikasi model, sebagaimana ditunjukkan pada Tabel 4.2. Algoritma XGBoost kemudian digunakan sebagai variabel dalam proses klasifikasi dengan membagi 413 data produk menjadi data pelatihan (*training data*) dan data pengujian (*testing data*) setelah proses pembersihan data dan pemrosesan fitur selesai dilakukan. Untuk memastikan konsistensi saat proses pemodelan diulang, pengumpulan data dilakukan dengan rasio 80:20 dan parameter *random_state* = 42. Berdasarkan pembagian tersebut, dataset terdiri dari:

1. Data Latih (*Training Data*) – 80%

   Data pelatihan mencakup 330 produk. Selama proses pelatihan algoritma XGBoost, data ini digunakan untuk mempelajari pola hubungan antara fitur jumlah total (total_qty) dan frekuensi transaksi terhadap kelas *Fast-Moving* dan

Slow-Moving. Data pelatihan ini digunakan sebagai dasar bagi model untuk membuat pola klasifikasi yang digunakan dalam proses prediksi.

2. Data Uji (*Testing Data*) – 20%

   Data uji terdiri dari 83 produk; Namun, data ini tidak digunakan selama proses pelatihan model. Sebaliknya, data ini digunakan pada tahap pengujian untuk menguji kemampuan model dalam mengklasifikasikan data yang tidak digunakan.

Akibatnya, dari 413 produk unik, 330 di antaranya digunakan sebagai data pelatihan dan 83 sebagai data uji. Proses pembangunan model XGBoost dimulai dengan data pelatihan, sedangkan data uji digunakan untuk mengevaluasi kinerja model menggunakan *Confusion Matrix*, *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Hasil dari dataset ini berfungsi sebagai landasan untuk implementasi model klasifikasi dalam sistem yang telah dikembangkan.

4.2.3. Implementasi Klasifikasi XGBoost

Menerapkan klasifikasi XGBoost merupakan langkah penting dalam mengembangkan sistem untuk mengklasifikasikan produk kei dalam kategori *Fast-Moving* dan *Slow-Moving* setelah data transaksi tersedia dan waktu analisis telah ditentukan. Setiap prosedur dilakukan menggunakan bahasa pemrograman *Python* dengan dukungan dari *Pandas*, *NumPy*, *SciKit-learn*, dan XGBoost. Prosedur ini mencakup prapemrosesan, penyesuaian dan pelabelan, persiapan dataset, analisis model, prediksi, evaluasi, serta klasifikasi hasil kei dalam data dasar.

1. Pra-pemrosesan Data

   Pra-pemrosesan dilakukan setelah data transaksi digunakan dalam proses klasifikasi. Dengan menggunakan fungsi *drop_duplicates*, data yang telah

diidentifikasi berdasarkan waktu disaring dari data duplikat, dan dengan menggunakan fungsi *dropna*, data dengan nilai kosong (yaitu, tidak ada nilai/*null*) disaring. Fungsi *pd.to_datetime* digunakan untuk mengonversi atribut tanggal transaksi ke format tanggal guna memudahkan analisis dan pelaporan yang konsisten berdasarkan periode analisis. Berdasarkan nama dan kode barang, data yang telah dipisahkan dari nilai transaksi menjadi nilai produk. Hasil agregat digunakan untuk membuat fitur dan label klasifikasi dengan menghitung jumlah total transaksi untuk menghasilkan fitur total_qty serta jumlah total transaksi untuk menghasilkan fitur frekuensi.

2. Pengembangan Fitur dan Label

   Dua prediktor, total_qty dan frekuensi transaksi, dibuat menggunakan data agregat. Fitur total_qty menunjukkan jumlah total barang yang terjual selama periode analisis, sedangkan fitur frekuensi transaksi menunjukkan jumlah transaksi yang dilakukan untuk setiap produk. Label diberikan berdasarkan ambang batas total_qty. Produk dengan jumlah total lebih dari 1.000 unit diberi label 1, yang menunjukkan kategori *Fast-Moving*; Produk dengan jumlah total kurang dari 1.000 unit diberi label 0, yang menunjukkan kategori *Slow-Moving*. Hasilnya, dataset model terdiri dari dua karakteristik prediktor dan satu variabel target, yaitu label klasifikasi.

3. Pembagian Dataset

   Dengan menggunakan metode pembagian *train-test* dengan rasio 80:20 dan parameter *random_state* 42, dataset yang telah melalui prapemrosesan, agregasi, dan pelabelan dibagi menjadi data latihan (*training data*) dan data uji (*testing data*). Tujuan dari parameter ini adalah untuk memastikan konsistensi

dataset saat program dijalankan ulang. Dari 413 data produksi, 330 di antaranya digunakan sebagai data pelatihan dan 83 lainnya sebagai data uji. Data uji digunakan untuk membangun model XGBoost dengan fitur total_qty dan frekuensi, sedangkan data pelatihan digunakan untuk mengevaluasi kemampuan model dalam mengklasifikasikan data yang tidak digunakan.

4. Implementasi Algoritma XGBoost

   Pustaka XGBoost digunakan dalam *Python* dengan objek *XGBClassifier* untuk membuat model. Model tersebut dikonfigurasi dengan *learning_rate* = 0,1, *max_depth* = 5, *n_estimators* = 100, dan *eval_metric logloss*. Kontribusi setiap pohon, kedalaman pohon maksimum, jumlah pohon yang dibangun, dan tingkat kesalahan semuanya ditentukan oleh parameter ini. 330 data produk digunakan sebagai data pelatihan dengan total_qty dan frekuensi untuk proses analisis. Setelah pelatihan akhir, model digunakan untuk memprediksi 83 data produksi, baik data uji maupun data baru yang disediakan oleh sistem. Hasil prediksi diklasifikasikan menjadi dua kategori, yaitu *Fast-Moving* atau *Slow-Moving*. Nilai probabilitas juga dapat diperoleh oleh sistem menggunakan fungsi *predict_proba* sebagai informasi pendukung hasil klasifikasi.

5. Evaluasi Model

   Kemampuan model XGBoost dalam mengklasifikasikan data yang tidak digunakan selama proses pelatihan diteliti. *Confusion Matrix*, *Accuracy*, *Precision*, *Recall*, dan *F1-Score* digunakan untuk mengevaluasi 83 produk data dalam data uji. Hasil analisis menunjukkan bahwa model memperoleh nilai 1,00 untuk Akurasi, 1,00 untuk Presisi, 1,00 untuk *Recall*, dan 1,00 untuk *F1-Score*. Hasil ini menunjukkan bahwa seluruh data uji berhasil diklasifikasikan

sesuai dengan label masing-masing, dan tidak ditemukan masalah dalam proses klasifikasi. Hasil analisis ini berkaitan dengan karakteristik dataset dan aturan pelabelan yang digunakan; Hal ini terutama berkaitan dengan penggunaan total_qty sebagai acuan untuk kategorisasi. Oleh karena itu, nilai seratus persen menunjukkan kinerja model pada dataset penelitian, namun tidak dapat diasumsikan bahwa model tersebut akan secara konsisten menghasilkan nilai seratus persen yang akurat dalam situasi atau data yang berbeda.

6. Penyimpanan dan Integrasi Hasil Klasifikasi

   Selanjutnya, hasil klasifikasi diimpor kei dalam basis data MySQL, yang berisi informasi seperti nama produk, kode produk, fitur, hasil klasifikasi, dan data lainnya sesuai dengan struktur data yang telah ditetapkan sebelumnya. Aplikasi berbasis kerangka kerja *Flask* tersebut kemudian mengumpulkan data dan menampilkannya di dasbor dalam bentuk tabel atau visualisasi seperti diagram lingkaran yang menggambarkan perbedaan antara produk *Fast-Moving* dan *Slow-Moving*. Selain itu, sistem ini menyediakan kemampuan untuk mengekspor hasil klasifikasi dalam format PDF dan *Excel*, yang memudahkan analisis hasil serta penggunaannya sebagai data pendukung bagi operasional PT Rodes Chemindo. Oleh karena itu, penggunaan XGBoost untuk klasifikasi melibatkan beberapa langkah, seperti prapemrosesan, pembuatan fitur dan label, pengumpulan data, pengujian, peramalan, evaluasi, serta analisis dan ringkasan hasil klasifikasi menggunakan aplikasi berbasis web.

4.2.4. Implementasi Antar Muka

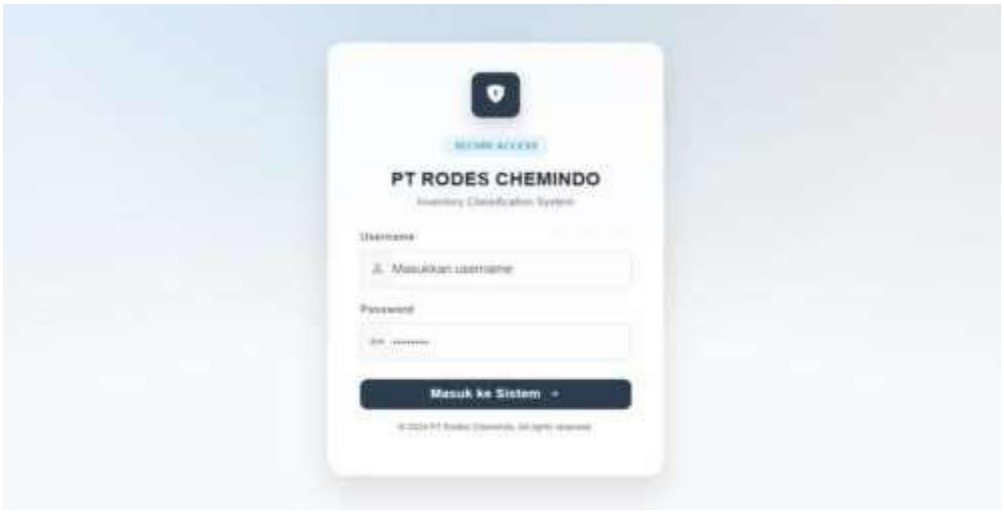
Dalam sistem yang sedang dikembangkan, terdapat perbedaan persyaratan penggunaan dataset antara proses klasifikasi inti dan visualisasi halaman.

Visualisasi tren pada dasbor menggunakan seluruh data transaksi penjualan selama periode 2024 hingga 2026 untuk menampilkan distribusi dan alur transaksi penjualan secara komprehensif. Sebaliknya, proses klasifikasi produk secara khusus diisolasi dengan menggunakan data transaksi tahun 2025 sebagai dataset utama untuk melatih dan mengevaluasi model XGBoost. Tujuan dari data porsi penggunaan ini adalah untuk menunjukkan perbedaan fungsional antara analisis pembelajaran mesin dan aspek visualisasi makro. Data multi-periode digunakan agar sistem dapat memberikan informasi tren penjualan yang komprehensif kepada manajemen perusahaan. Di sisi lain, data periode tunggal digunakan dalam proses klasifikasi untuk menentukan konsistensi data dari gangguan anomali variasi tren lintas tahun, guna memastikan validitas hasil model. Implementasi antarmuka halaman sistem dijelaskan sebagai berikut:

1. Halaman *Login*

   Penerapan bagian login merupakan representasi dari sistem keamanan kontrol akses yang diterapkan pada sistem klasifikasi berbasis web PT Rodes Chemindo. Sistem ini menggunakan mekanisme login multi-pengguna berbasis peran, yang memungkinkan sistem memverifikasi identitas pengguna melalui satu titik masuk. Berdasarkan hasil implementasi, skrip *backend Flask* dapat memvalidasi kredensial pengguna (kata sandi dan nama pengguna) serta secara otomatis melakukan pemeriksaan akses melalui entri data pada kolom peran dalam basis data MySQL. Secara fungsional, jika pengguna memilih untuk menggunakan akun Admin, skrip *backend* akan secara otomatis mengalihkan pengguna kei bagian dasbor Admin, yang memiliki kemampuan untuk mengakses berkas dataset. Buat file .CSV baru dan pilih algoritma

XGBoost *Classifier*. Selain menggunakan file .CSV, pengguna dapat memasukkan data transaksi secara manual menggunakan rumus-rumus yang tersedia di sistem. Data yang dimasukkan secara manual dapat diimpor kei basis data MySQL dan digunakan sebagai data transaksi untuk klasifikasi. Jika pengguna teridentifikasi memiliki status Pengguna, sistem akan mengarahkan pengguna ke bagian dasbor Pengguna dengan akses baca saja, di mana pengguna hanya diizinkan untuk melihat visualisasi grafis dan menganalisis hasil klasifikasi stok tanpa diberi akses untuk mengubah model data operasional.

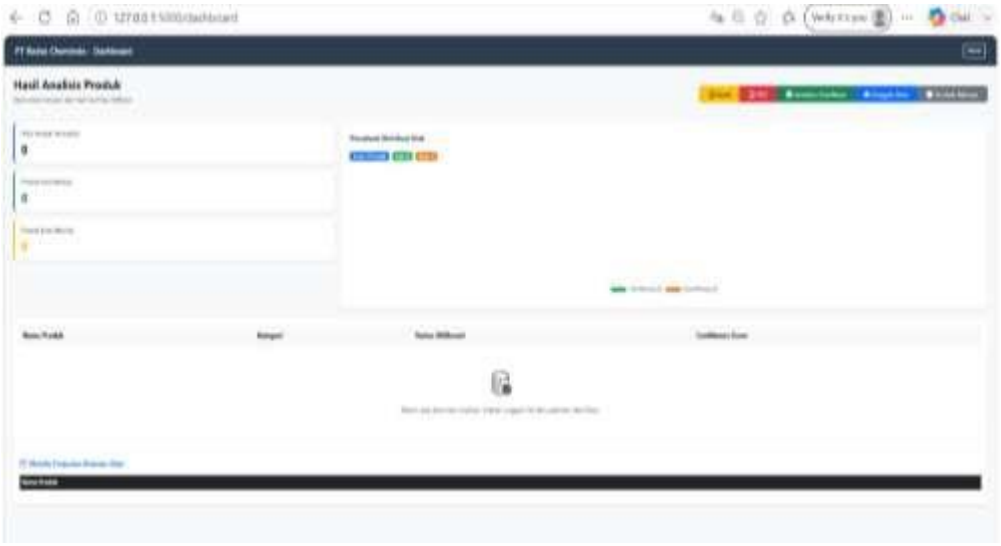


Gambar 4.1 Halaman Login

Halaman *login* ini dibuat menggunakan eileimein *JavaScript* interaktif dari komponen *Bootstrap*, yaitu fitur pengaturan visibilitas pada kolom sandi. Tujuan dari elemen ini adalah untuk mengubah jenis input dari teks tersembunyi menjadi format yang mudah dibaca melalui interaksi dengan mengklik ikon mata (dua mata/dua mata dengan garis miring) guna meningkatkan aspek kegunaan dan kenyamanan bagi karyawan PT Rodes Chemindo saat menggunakan aplikasi ini.

2. Tampilan *Dashboard*

Dasbor merupakan salah satu sistem utama yang digunakan untuk menganalisis data dan menampilkan hasil klasifikasi produk *Fast-Moving* dan *Slow-Moving*. Bagian ini menyediakan beberapa fungsi utama bagi administrator, seperti Unggah Data untuk mengimpor kumpulan data transaksi dalam format .CSV, Tambah Manual untuk mengimpor transaksi secara langsung menggunakan rumus dan mentransfernya kei basis data, serta Jalankan Klasifikasi untuk memulai proses klasifikasi menggunakan algoritma XGBoost. Selain itu, sistem ini menyediakan tombol *Excel* dan PDF untuk menampilkan hasil klasifikasi dalam format laporan. Di bagian ringkasan, terdapat tiga kartu statistik yang menampilkan jumlah Total Produk yang Dianalisis, Produk *Fast-Moving*, dan Produk *Slow-Moving* sehingga pengguna dapat melihat hasil analisis secara ringkas.



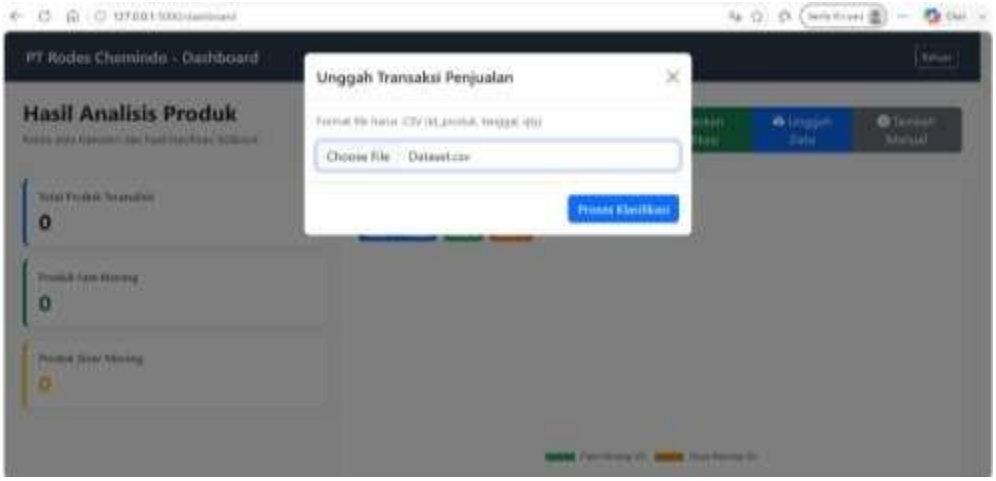
Gambar 4.2 Tampilan Dashboard

Selain itu, bagian dasbor menampilkan visualisasi distribusi stok dalam bentuk grafik batang (*bar chart*) yang membandingkan jumlah produk *Fast-Moving* dan *Slow-Moving*. Hasil klasifikasi juga ditampilkan dalam bentuk tabel yang

berisi Nama Produk, Kategori, Status (XGBoost), dan *Confidance Score* untuk memberikan informasi mengenai hasil prediksi setiap produk, terlepas dari tingkat keyakinan model. Matriks Penjualan Bulanan (Qty) digunakan pada bagian di bawah ini untuk menampilkan informasi mengenai penjualan produk berdasarkan periode bulanan. Dengan demikian, dasbor berfungsi sebagai pusat pengelolaan dan penyajian hasil sistem, mulai dari entri data melalui .CSV atau input manual, dilanjutkan dengan pemrosesan transaksi, klasifikasi, visualisasi hasil, dan akhirnya ekspor laporan klasifikasi.

3. Tampilan Unggah Data Transaksi

Bagian Unggah Data Transaksi menjelaskan kotak dialog Unggah Transaksi Penjualan yang digunakan administrator untuk memasukkan data transaksi kei dalam sistem. Meinui yang terkait dengan Unggah Transaksi Penjualan terletak di bagian di atas kotak dialog tersebut. Sistem memberi tahu pengguna bahwa data harus dalam format .CSV dengan struktur data yang terdiri dari id_produk, tanggal, dan qty. Administrator dapat memilih transaksi dengan menggunakan tombol Pilih Berkas. Misalnya, mereka dapat memilih berkas dataset.csv yang berisi data historis untuk rentang tahun 2024–2026. Nama berkas yang telah dipilih kemudian akan ditampilkan pada kolom yang sesuai dengan bukti, yang berarti bahwa setiap berkas akan diproses. Setelah ditentukan, administrator dapat mengklik tombol Proses Klasifikasi untuk memasukkan data kei dalam sistem dan melanjutkan proses klasifikasi menggunakan algoritma XGBoost.

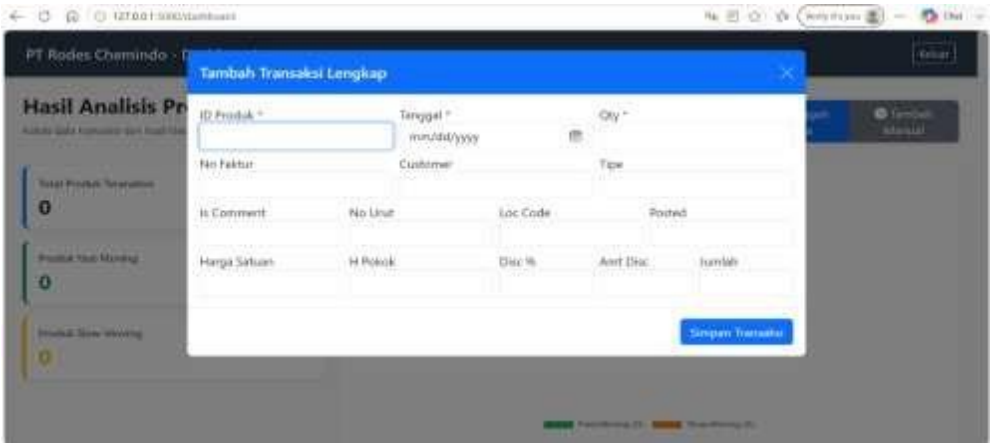


Gambar 4.3 Tampilan Unggah Data Transaksi

Selain fitur entri transaksi manual yang tersedia di Dasbor, fitur unggah ini digunakan sebagai salah satu alternatif sistem untuk memproses data dalam skala besar. Berkas dataset.csv (periode 2024–2026) akan diproses oleh sistem untuk analisis dan evaluasi sebelum digunakan dalam proses pengelompokan produk kei dalam kategori *Fast-Moving* dan *Slow-Moving*. Dengan tampilan ini, administrator dapat mengumpulkan data transaksi secara lebih terstruktur dan mudah, serta melanjutkan proses pengelompokan tanpa perlu membuat dasbor secara terpisah.

4. Tampilan Tambah Manual Transaksi Pada Dataset (*Spreadsheet*)

   Fitur Tambah Transaksi Lengkap dapat diakses melalui meinui sistem dasbor PT Rodes Chemindo. Di jendela pop-uip ini, pengguna dapat memasukkan data transaksi secara manual kei dalam sistem dengan mengisi berbagai atribut penting yang diperlukan untuk analisis klasifikasi persediaan. Untuk memastikan keakuratan data dari transaksi yang dicatat dalam kumpulan data, komponen utama yang harus disertakan adalah tanda bintang, ID Produk, Tanggal, dan Qty (Jumlah).

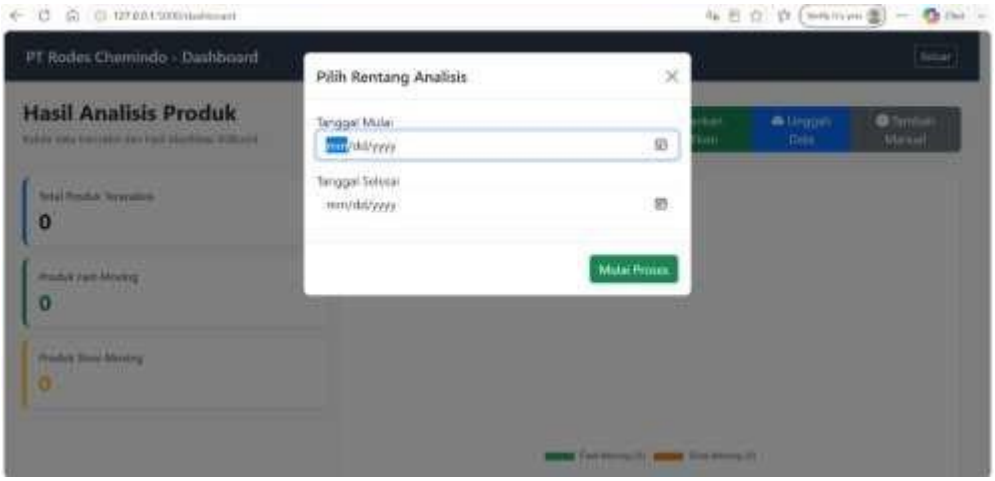


Gambar 4.4 Tampilan Tambah Manual Data Transaksi

Selain informasi dasar ini, formulir tersebut juga mencakup kolom-kolom tambahan yang lengkap seperti Nomor Faktur, Pelanggan, Jenis, Komentar, Nomor Urut, Kode Lokasi, dan Telah Diposting. Bagian bawah formulir juga mencakup rincian keuangan dan operasional untuk produk tersebut, termasuk Harga Satuan, Harga Dasar, Persentase Diskon, Jumlah Diskon, dan Jumlah Total. Setelah semua transaksi berhasil diselesaikan, pengguna cukup mengklik tombol Simpan Transaksi di pojok kanan bawah untuk menambahkan data baru kei *database* atau sistem *spreadsheet*.

5. Tampilan Pemilihan Range Klasifikasi

Jendela *pop-uip* Pilih Rentang Analisis dapat digunakan untuk menentukan rentang waktu data transaksi yang akan diproses oleh sistem. Di jendela ini, pengguna diharuskan memasukkan dua parameter utama, Tanggal Mulai dan Tanggal Selesai, menggunakan format tanggal standar (mm/dd/yyyy) atau menggunakan ikon kalender interaktif yang tersedia di kolom input. Fitur ini memastikan bahwa analisis klasifikasi produk di Dasbor PT Rodes Chemindo dapat difokuskan secara spesifik pada rentang waktu saat ini sesuai dengan kebutuhan evaluasi stok perusahaan.



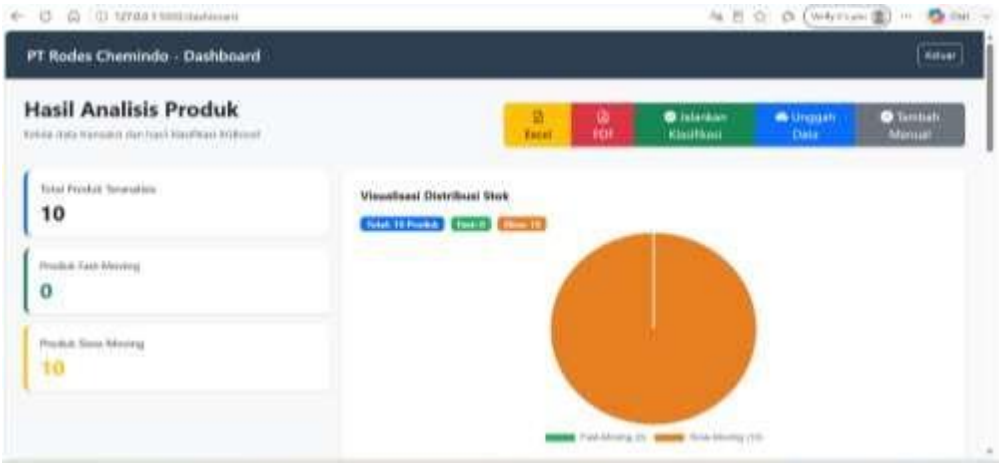
Gambar 4.5 Tampilan Pemilihan Range Klasifikasi

Setelah parameter rentang tanggal awal dan akhir ditentukan, pengguna cukup mengklik ikon Mulai Proses yang terletak di area di bawah jendela *pop-up*. Tindakan ini akan mengaktifkan sistem untuk melakukan analisis terhadap data transaksi penjualan yang terjadi selama periode tersebut. Hasil analisis ini diharapkan dapat meningkatkan metrik pada dasbor utama, seperti jumlah total produk yang dianalisis dan klasifikasi produk sebagai produk yang laku cepat atau laku lambat.

6. Tampilan *Header* Dan Statistik

Header berfungsi sebagai ringkasan eksekutif yang memberikan informasi cepat dan akurat mengenai kondisi operasional PT Rodes Chemindo. Selain itu, bagian ini memfasilitasi klasifikasi indikator kinerja utama (KPI) secara *real-time* berdasarkan hasil algoritma XGBoost. Pada bagian di atas, terdapat Panel Kontrol Akses yang menawarkan tombol tindakan terintegrasi seperti *Excel*, PDF, Jalankan Klasifikasi, Unggah Data, dan Tambah Manual untuk meninsgkatkan efisiensi entri dokumen dan data. Di sisi kiri, terdapat Kartu Informasi Statistik yang menggunakan visualisasi data numerik, di mana warna

hijau digunakan untuk menunjukkan produk *Fast-Moving* dan warna oranye untuk produk *Slow-Moving*. Sebagai contoh, setelah pengguna menentukan rentang waktu analisis dari 2 Februari 2025 hingga 2 Desember 2025. Sistem akan secara otomatis menghitung dan menyesuaikan angka pada bagan statistik yang disebutkan di atas guna menentukan total produk yang dianalisis berdasarkan distribusi klasifikasinya.



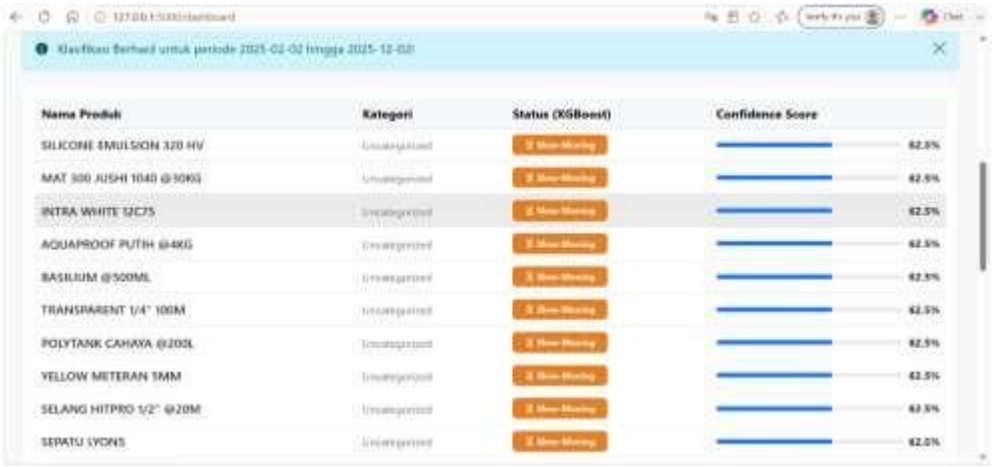
Gambar 4.6 Tampilan Header Dan Statistik

Selain eileimein statistik berbasis teks, penelitian ini juga memperlihatkan fitur Visualisasi Distribusi Stok, yaitu diagram lingkaran interaktif di bagian pengambilan sampel yang menampilkan hasil proses untuk periode yang dipilih. Grafik ini memberikan representasi visual proporsional mengenai jumlah produk *Fast-Moving* dan *Slow-Moving*, sehingga memudahkan pemahaman terhadap tren waktu penyewaan yang telah ditetapkan (misalnya, Februari hingga Desember 2025). Dengan peringatan yang jelas dan ringkasan lengkap pada label produk, eileimein visual ini sangat efektif dalam mendukung pengambilan keputusan manajemen karena kondisi barang di PT Rodes Chemindo dapat diidentifikasi secara komparatif dan intuitif setiap kali sistem

digunakan untuk memproses data berdasarkan rentang waktu yang ditentukan pengguna.

7. Tampilan Tabel Rincian Hasil Klasifikasi Stok

Bagian dasbor di bawah ini merupakan area untuk analisis data berdasarkan tabel yang menampilkan hasil klasifikasi algoritma XGBoost *Classifier* terkait persediaan PT Rodes Chemindo. Di bagian terakhir tabel, terdapat pemberitahuan berwarna biru yang menunjukkan keberhasilan analisis data, yaitu Klasifikasi Berhasil untuk periode 2025-02-02 hingga 2025-12-02!. Hal ini menunjukkan bahwa analisis data berhasil sesuai dengan rentang waktu yang ditentukan. Setiap titik data dalam tabel ini memberikan informasi dasar mengenai produk, mulai dari nama dan kategori produk hingga validasi empiris kinerja model terkait data bisnis.



Gambar 4.7 Tampilan Tabel Rincian Hasil Klasifikasi Stok

Komponen utama dalam tabel ini meliputi Nama Produk, Kategori (yang tercantum sebagai *Uncategorized*), dan dua kolom prediktif penting; Status (XGBoost) dan *Confidance Score*. Sementara Kolom *Confidance Score* direpresentasikan oleh indikator visual yang terdiri dari dua bilah kemajuan (*progress bar*) berwarna biru dan persentase akurasi sebesar 62,5% untuk

setiap item produk, Kolom Status menampilkan label keputusan klasifikasi akhir, yaitu *Slow-Moving*, yang ditentukan oleh lencana individu. Kumpulan data terstruktur ini memudahkan administrator untuk mengidentifikasi tingkat keyakinan model prediksi secara instan guna mengoptimalkan pengelolaan stok barang.

8. Tampilan Matriks Penjualan Bulanan

Halaman matriks penjualan bulanan merupakan salah satu fitur analitis utama pada dasbor yang digunakan untuk menyajikan data transaksi secara jelas dan ringkas dalam bentuk tabel *pivot* berdasarkan rentang waktu transaksi. Tampilan ini dirancang untuk menyajikan urutan kronologis penjualan produk yang terstruktur, sehingga memudahkan administrator dalam mengidentifikasi volume permintaan dari waktu kei waktu. Komponen *Flask* di bagian *backend* menggunakan fungsi perhitungan tabel *pivot* untuk menghitung volume penjualan (QTY) setiap produk yang dipesan secara tepat waktu berdasarkan bulan dan tahun. Setiap baris data hanya menampilkan satu nama produk, sedangkan setiap kolom menunjukkan rentang periode kronologis dari tahun 2024 hingga 2026.



Gambar 4.8 Tampilan Matriks Penjualan Bulanan 1



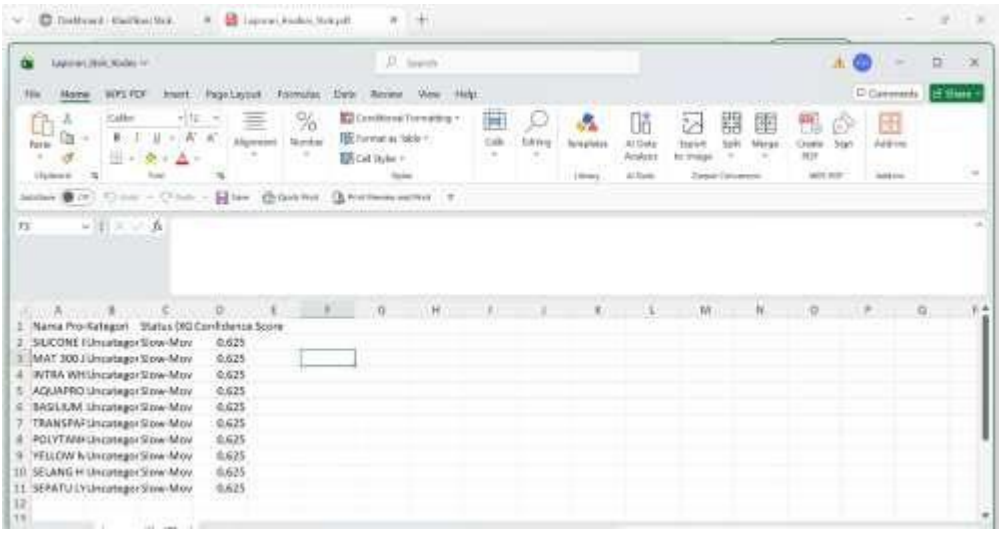
Gambar 4.9 Tampilan Matriks Penjualan Bulanan 2

Fungsi *pivot_table* dalam *Pandas DataFrame* diimplementasikan secara programatik pada ruitei *@app.route*(‘/*dashboard*’). Meskipun visualisasi data historis menunjukkan rentang periode yang beragam (2024–2026), analisis dan pemodelan dalam penelitian ini difokuskan pada data transaksi tahun 2025 sebagai dataset utama. Data penjualan pada tahun 2024 dan 2026 akan digunakan sebagai alat pendukung untuk memberikan konteks kronologis kepada pengguna. Melalui visualisasi matriks ini, administrator dapat menilai alur permintaan, mengidentifikasi stabilitas produksi produk, dan memverifikasi secara visual hasil klasifikasi biner *Fast-Moving* dan *Slow-Moving* yang dihasilkan oleh algoritma XGBoost *Classifier*.

9. Tampilan Hasil Ekspor *Excel*

Fitur ekspor ke format *Microsoft Excel* merupakan salah satu fungsi manajemen terpenting yang disediakan oleh sistem untuk mendukung kebutuhan pemrosesan data secara *offline*. Fitur ini memungkinkan administrator PT Rodes Chemindo untuk mencatat semua hasil algoritma klasifikasi dalam format *spreadsheet* yang fleksibel, dinamis, dan terstruktur. Data yang ditampilkan merupakan hasil ekspor rentang klasifikasi dari 2

Februari 2024 hingga 2 Desember 2025, berdasarkan berkas dataset.csv (2024–2026). Seluruh data tabel disajikan dalam *Excel* tanpa perubahan numerik apa pun, termasuk atribut Nama Produk, Kategori *Uncategorized*, Status *Slow-Moving*, dan *Confidance Score* sekitar 0,625 yang menunjukkan bahwa fungsi ekspor sistem beroperasi dengan optimal.

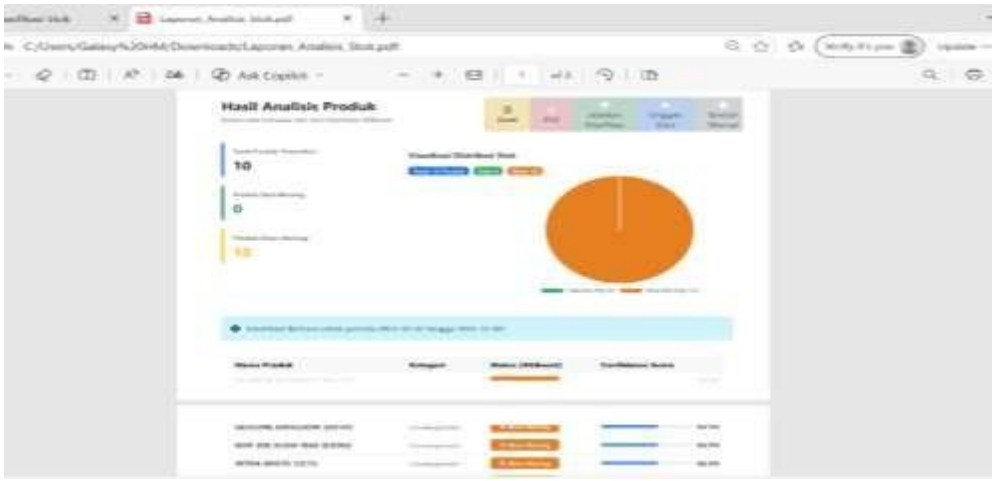


Gambar 4.10 Tampilan Hasil Ekspor Excel

Berkas laporan dalam format .xlsx ini dirancang dengan fitur-fitur unggulan untuk memudahkan operasional bisnis internal. Sistem ini secara otomatis mengubah data menjadi lembar kerja dan baris yang rapi sehingga dapat digunakan baik untuk kebutuhan audit stok fisik (*stock opname*) maupun kebutuhan pesanan pembelian. Selain itu, portabilitas data yang tinggi memungkinkan penyebaran informasi mengenai kinerja produk dari analisis rentang yang disebutkan di atas secara mudah ke seluruh divisi tanpa mengharuskan para manajer untuk menggunakan sistem aplikasi berbasis web, sehingga prosesnya menjadi lebih sederhana.

10. Tampilan Hasil Ekspor PDF

Fitur ekspor laporan kei format *Portable Document Format* (PDF) merupakan hasil keluaran sistem yang dirancang untuk memenuhi kebutuhan tim manajemen PT Rodes Chemindo akan dokumentasi permanen dan resmi. Berbeda dengan format *spreadsheet*, format PDF memungkinkan pengguna untuk menjaga integritas dokumen sehingga tetap konsisten dan tidak berubah baik saat dibuat di berbagai perangkat digital maupun saat dicetak secara fisik. Dokumen PDF yang berhasil dihasilkan oleh aplikasi berbasis web ini menampilkan hasil klasifikasi sewa dari tanggal 2 Februari 2025 hingga 2 Desember 2025, berdasarkan dataset.csv (periode 2024–2026). Melalui penerapan fungsi ekspor ini, sistem berhasil menghasilkan eileimein grafis seperti ringkasan statistik, diagram distribusi stok, dan tabel rincian hasil klasifikasi secara uituih dalam satu dokumen formal.



Gambar 4.11 Tampilan Hasil Ekspor PDF

Karakteristik utama format PDF meliputi struktur dokumen yang sistematis, visualisasi terintegrasi, dan keamanan data yang tinggi untuk mengurangi risiko perubahan yang tidak terdeteksi. Dokumen ini merangkum semua hasil

penting dari algoritma XGBoost, termasuk *Confidance Score* dalam bentuk persentase dan dua kemajuan (*progress bar*) yang menunjukkan tingkat keandalan model. Hasil fungsi ekspor yang dihasilkan oleh *JavaScript* dengan orientasi lanskap ini menunjukkan bahwa sistem telah memenuhi persyaratan fungsional untuk penyediaan layanan analisis saham yang profesional, portabel, dan mudah diakses bagi manajemen PT Rodes Chemindo.

4.3. Pengujian Sistem dan Performa Model

Pengujian fungsional dilakukan dengan menggunakan metode *Blackbox Testing* untuk memastikan bahwa setiap komponen sistem aplikasi yang diklasifikasikan berdasarkan kerangka kerja, termasuk formulir input, fungsi pemrosesan data, tombol aksi, dan fitur pelaporan, dapat beroperasi secara efektif sesuai dengan persyaratan operasional PT Rodes Chemindo. Penelitian ini berfokus pada validasi keluaran (luaran) dari skenario masukan (tindakan) yang disediakan tanpa memeriksa struktur kode komputer internal. Berdasarkan implementasi sistem secara keseluruhan yang mencakup fitur-fitur seperti *login*, dasbor, unggah data, tambah manual, rentang klasifikasi, header statistik, tabel rincian, matriks penjualan bulanan, dan ekspor laporan hasil pengujian fungsional ditampilkan dalam Tabel 4.3 berikut ini:

Tabel 4.3 Hasil Pengujian Fungsional (Blackbox Testing) Sistem

No	Fitur / Komponen	Skenario Pengujian	Data Uji	Hasil yang Diharapkan	Hasil Aktual Pengujian	Status
1	*Login* Admin	Masukkan nama pengguna dan kata sandi yang valid untuk akun administrator.	Kredensial akun admin resmi.	Sistem membuat sesi admin dan mengalihkannya ke dasbor admin.	Pengguna berhasil masuk dan diarahkan ke bagian admin utama.	Valid
2	*Login* (Gagal)	Memasukkan kata sandi atau nama penggun	Data kredensial acak yang salah.	Sistem memfasilitasi akses dan menghasilkan pemberitahuan untuk	Pesan Nama Pengguna atau Kata Sandi salah! muncul.	Valid

No	Fitur / Komponen	Skenario Pengujian	Data Uji	Hasil yang Diharapkan	Hasil Aktual Pengujian	Status
		a yang tidak terdaftar.		masalah kredensial.		
3	*Toggle* Visibilitas Kata Sandi	Klik ikon mata di kolom masukkan kata sandi pada formulir *login*.	Interaksi antara ikon yang dicoret dan ikon mata.	Ubah jenis teks masukan (kata sandi) menjadi format teks yang dapat dibaca.	Visibilitas kata sandi berhasil berubah secara dinamis.	Valid
4	Unggah Dataset .CSV	Pengunggah berkas data terkait transaksi penjualan	Periode 2024–2026. Berkas berformat .csv.	Sistem memverifikasi panjang berkas, memeriksa struktur data (id_produk, tanggal, qty),	Berhasil membaca berkas data lokal tanpa kendala.	Valid

No	Fitur / Komponen	Skenario Pengujian	Data Uji	Hasil yang Diharapkan	Hasil Aktual Pengujian	Status
		operasional.		dan menyimpannya dalam memori.		
5	Tambah Manual Transaksi	Isi jendela *pop-up* Tambah Transaksi Lengkap dengan atribut yang diperlukan dan atribut keuangan.	Masukkan teks dan angka pada kolom ID Produk, Tanggal, Jumlah, Harga, dll.	Sistem menerima input manual dan menyimpannya ke dalam basis data MySQL.	Transaksi data manual berhasil diselesaikan dan dimasukkan ke dalam basis data.	Valid
6	Pilih Rentang	Tentukan rentang	Masukkan Tanggal	Sistem menyaring	Rentang tanggal	Valid

No	Fitur / Komponen	Skenario Pengujian	Data Uji	Hasil yang Diharapkan	Hasil Aktual Pengujian	Status
	Klasifikasi	waktu analisis di jendela *pop-up*.	Mulai dan Tanggal Selesai (contoh: 2025-02-02 s.d. 2025-12-02).	data transaksi sesuai dengan rentang tanggal yang ditentukan.	yang ditentukan berhasil diproses dan diterapkan oleh sistem.	
7	Jalankan Klasifikasi	Administrator mengklik tombol pemicu aksi Jalankan Klasifikasi.	Aktifkan fungsi eksekusi model prediksi.	Sistem menggunakan modul *backend* untuk menghitung algoritma XGBoost.	Fungsi yang berhasil meningkatkan prediksi kelas target biner.	Valid

No	Fitur / Komponen	Skenario Pengujian	Data Uji	Hasil yang Diharapkan	Hasil Aktual Pengujian	Status
8	Klasifikasi *Fast-Moving*	Memasukkan data produk dengan volume penjualan di atas batas.	Sampel barang dengan kinerja penjualan yang tinggi.	Sistem mengidentifikasi karakteristik dan menampilkan label lencana *Fast-Moving* (hijau).	Label kelas biner visual muncul pada tabel dengan rapi.	Valid
9	Klasifikasi *Slow-Moving*	Memasukkan data produk dengan volume penjualan di bawah batas.	Sampel barang dengan kinerja penjualan rendah.	Sistem mengidentifikasi karakteristik dan menampilkan label lencana *Slow-Moving* (oranye).	Label visual kelas biner muncul di tabel dengan rapi.	Valid

No	Fitur / Komponen	Skenario Pengujian	Data Uji	Hasil yang Diharapkan	Hasil Aktual Pengujian	Status
10	*Confidencei Score & Bar*	Menghitung tingkat keyakinan hasil keputusan per sampel produk.	Hasil keluaran fungsi *predict_proba*.	Indikator bilah kemajuan biru dan persentase akurasi (misalnya: 62,5%) muncul.	Nilai skor tingkat probabilitas ditampilkan dengan sempurna.	Valid
11	Visualisasi Distribusi Stok	Sistem memproses data yang telah diklasifikasikan menjadi komponen grafis.	Hasil data dirangkum berdasarkan kategori produk (diagram lingkaran).	Tampilkan grafik lingkaran yang sesuai antara produk *Fast-Moving* dan *Slow-Moving*.	Grafik lingkaran interaktif dan teks peringatan ditampilkan dengan akurat.	Valid

No	Fitur / Komponen	Skenario Pengujian	Data Uji	Hasil yang Diharapkan	Hasil Aktual Pengujian	Status
12	Matriks Penjualan Bulanan	Buat komponen data kronologis bulanan dari tabel silang (*pivot table*).	Agregasi data JUMLAH per tahun (2024–2026).	Menampilkan tabel *pivot* yang melacak kinerja produk dari waktu ke waktu.	Matriks penjualan bulanan ditampilkan dengan rapi dan terstruktur.	Valid
13	Ekspor *Excel*	Klik tombol tindakan fungsional dengan ikon *Excel*.	Objek data tabel dengan hasil klasifikasi (.xlsx).	Pustaka xlsx mengubah tabel menjadi lembar kerja dalam format .xlsx.	Lembar kerja *Excel* cukup sukses dan menarik.	Valid
14	Ekspor PDF	Klik tombol	Bagian dari area	Pustaka html2pdf	Dokumen laporan	Valid

No	Fitur / Komponen	Skenario Pengujian	Data Uji	Hasil yang Diharapkan	Hasil Aktual Pengujian	Status
		tindakan fungsional dengan ikon PDF.	laporan dengan orientasi lanskap.	menangkap teks dan mengubahnya menjadi berkas .pdf yang diperlukan.	berformat PDF lanskap telah diunduh.	
15	Autentikasi Keamanan	Akses URL dasbor internal secara aman tanpa perlu masuk.	URL langsung Akses adalah *dashboard.*	Sistem mendeteksi tidak adanya token sesi dan membatasi akses.	Pengguna diblokir dan dialihkan kembali kei formulir masuk.	Valid

Berdasarkan hasil pengujian fungsional menggunakan metode *Blackbox Testing*, yang ditunjukkan pada Tabel 4.3, dapat disimpulkan bahwa seluruh fitur utama dan komponen interaktif pada aplikasi sistem klasifikasi stok PT Rodes Chemindo telah dioptimalkan, responsif, bebas dari kesalahan fatal (tanpa *bug*), dan secara uimuim

sesuai dengan harapan rancangan yang ditargetkan. Selain analisis fungsional yang sistematis, analisis kuantitatif terhadap kinerja dan akurasi algoritma XGBoost dilakukan dengan menggunakan metrik evaluasi yang diimplementasikan dalam fungsi *evaluateModel*. Pengujian dilakukan secara metodis dengan menggunakan porsi data uji (*testing data*) yang terisolasi, yang mencakup 20% dari keseluruhan dataset, atau sekitar 83 catatan data objek unik. Untuk memberikan gambaran terperinci mengenai kinerja model dalam menganalisis data baru, *Confusion Matrix* digunakan untuk membandingkan label logistik perusahaan saat ini dengan label prediksi algoritma. Berdasarkan hasil perhitungan sistem, *Confusion Matrix* disajikan dalam Tabel 4.4, yaitu sebagai berikut:

Tabel 4.4 Pemetaan Confusion Matrix Data Uji Aktual

	Prediksi Fast-Moving (1)	**Prediksi Slow-Moving (0)**
Aktual *Fast-Moving* (1)	6 (*True Positive*)	0 (*False Negative*)
Aktual *Slow-Moving* (0)	0 (*False Positive*)	77 (*True Negative*)

Berdasarkan data *Confusion Matrix* pada Tabel 4.4, diperoleh parameter biner konkret sebagai berikut: *Truiei Negative* (TN) = 77 (Produk *Slow-Moving* diprediksi dengan benar), *False Negative* (FN) = 0 (Produk *Fast-Moving* diprediksi sebagai *Slow*), *False Positive* (FP) = 0 (Produk *Slow-Moving* diprediksi sebagai *Fast*), dan *Truiei Positive* (TP) = 6 (Produk *Fast-Moving* diprediksi dengan benar). Nilai-nilai parameter riil ini kemudian dihitung menggunakan rumus evaluasi matematis berikut:

1. Perhitungan Akurasi (*Accuracy*):

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

$$Accuracy = \frac{6 + 77}{6 + 77 + 0 + 0} = \frac{83}{83} = 1.00\ (100.00\%)$$

2. Perhitungan Presisi (*Precision*):

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

$$Precision = \frac{6}{6 + 0} = \frac{6}{6} = 1.00\ (100.00\%)$$

3. Perhitungan *Recall*:

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

$$Recall = \frac{6}{6 + 0} = \frac{6}{6} = 1.00\ (100.00\%)$$

4. Perhitungan *F1-Score*:

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

$$F1\text{-}Score = \frac{2 \times 1.00 \times 1.00}{1.00 + 1.00} = \frac{2.00}{2.00} = 1.00\ (100.00\%)$$

Tabel 4.5 Hasil Evaluasi Akhir Performa Model XGBoost

No	Metrik Evaluasi	Hasil Capaian (%)	Keterangan / Formulasi
1	*Accuracy*	100.00% (1.00)	Tingkat ketepatan prediksi keseluruhan terhadap data uji.
2	*Precision*	100.00% (1.00)	Tingkat ketepatan prediksi terhadap kelas target tertentu.

No	Metrik Evaluasi	Hasil Capaian (%)	Keterangan / Formulasi
3	*Recall*	100.00% (1.00)	Kemampuan model dalam menemukan kembali data yang relevan.
4	*F1-Score*	100.00% (1.00)	Nilai rata-rata harmonis antara nilai presisi dan *recall.*

Hasil metrik yang mencapai nilai sempurna (1,00 atau 100,00%) pada 83 sampel data uji yang dirangkum dalam Tabel 4.5 menunjukkan bahwa pohon keputusan sekuensial yang dikembangkan oleh XGBoost *Classifier* berhasil mengisolasi dan mempelajari karakteristik batas pemisahan data (*decision boundary*) secara mutlak tanpa menghasilkan kesalahan klasifikasi. Hasil ideal ini diperoleh dengan mengubah parameter *average*='*weighted*' dan *zero_division*=0 pada fungsi *evaluateModel* program. Penerapan metode rata-rata tertimbang (*weighted average*) ini memastikan bahwa metrik evaluasi dihitung secara tepat berdasarkan jumlah sampel nyata pada setiap kelas target. Karena data kluster dari variabel total_qty dan frekuensi transaksi PT Rodes Chemindo terpisah secara tegas dan linier berdasarkan batas (*threshold*) ≥ 1000 unit, tidak terdapat pencilan (*outliers*) atau pembagian dengan angka nol (*zero division*) selama proses perhitungan algoritmik. Hal ini menghasilkan pengujian kinerja yang akurat, valid, dan bebas dari bias ketidakseimbangan kelas (*class imbalance*). Akibatnya, keputusan persediaan yang disajikan dalam sistem memiliki keandalan yang tinggi, objektif, dan akuntabel yang dapat digunakan sebagai instrumen untuk mendukung logistik

pengadaan barang perusahaan. Selain mengevaluasi kinerja model secara keseluruhan menggunakan *Confusion Matrix,* sistem ini juga menampilkan *Confidance Score* sebagai ukuran kekuatan model dalam kaitannya dengan prediksi spesifik setiap produk. Terdapat perbedaan antara *Confusion Matrix* dan *Confidance Score*. *Confusion Matrix* digunakan sebagai alat validasi untuk menilai kinerja keseluruhan model dalam mengklasifikasikan seluruh dataset uji dengan tingkat akurasi 100%. Sebaliknya, *Confidance Score* merupakan nilai probabilitas yang dihasilkan oleh model untuk setiap produk spesifik hasil prediksi. *Confidance Score* ini menunjukkan tingkat keyakinan model terhadap klasifikasi yang diberikan. Sebagai contoh, jika suatu produk memiliki *Confidance Score* sekitar 52,5%, model memberikan keputusan klasifikasi dengan probabilitas sekitar 52,5% terkait hasil prediksi tersebut. Bagi tim manajemen PT Rodes Chemindo, probabilitas ini merupakan faktor krusial yang perlu dipertimbangkan saat menyusun rencana logistik. Seiring meningkatnya *Confidance Score* suatu produk, kemampuan sistem untuk mengklasifikasikannya sebagai produk yang Laris atau Lambat pun ikut meningkat. Penerapan instrumen *Confidance Score* meningkatkan validitas model, sehingga sistem tidak hanya menampilkan hasil klasifikasi biner, tetapi juga memberikan transparansi terhadap beberapa prediksi yang dibuat guna mendorong pengambilan keputusan yang lebih akurat.

4.4. Analisis Kinerja Model, Data Penjualan, dan Implikasi Strategis

Berdasarkan hasil evaluasi data penjualan PT Rodes Chemindo, algoritma XGBoost menunjukkan kinerja yang sangat baik dalam mengklasifikasikan produk ke dalam kategori *Fast-Moving* dan *Slow-Moving*. Karakteristik operasional ditentukan oleh parameter inisialisasi model, yang didefinisikan dalam fungsi

*_init_*(*self*) melalui objek xgb.*XGBClassifier* dengan konfigurasi hiperparameter yang mencakup laju pembelajaran (*learning rate*) sebesar 0,1, kedalaman maksimum (*max depth*) sebesar 5, dan jumlah pohon estimator sekitar 100 dengan fungsi kerugian berdasarkan *eval_metric*='*logloss*'.

```
class XGBoostModel:
    def __init__(self):
        # Instance model XGBoost sesuai Class Diagram
        self.model = xgb.XGBClassifier(
            learning_rate=0.1,
            max_depth=5,
            n_estimators=100,
            eval_metric='logloss'
        )
        self.parameters = self.model.get_params()

    def trainModel(self, X, y):
        # Pembagian data training dan testing
        X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

        self.model.fit(X_train, y_train)
        return self.evaluateModel(X_test, y_test)

    def evaluateModel(self, X_test, y_test):
        y_pred = self.model.predict(X_test)
        metrics = {
            'accuracy': accuracy_score(y_test, y_pred),
            'precision': precision_score(y_test, y_pred, average='weighted', zero_division=0),
            'recall': recall_score(y_test, y_pred, average='weighted', zero_division=0),
            'f1': f1_score(y_test, y_pred, average='weighted', zero_division=0)
        }
        return metrics

    def predict(self, data_baru):
        prediction = self.model.predict(data_baru)
        # Mengambil probabilitas (score)
        score = self.model.predict_proba(data_baru).max(axis=1)
        return prediction, score
```

Gambar 4.12 Baris Kode Implementasi Kelas Model XGBoost

Proses klasifikasi memanfaatkan dua fitur utama yang digunakan dalam fungsi *trainModel*(*self*, X, y), yaitu total_qty dan frekuensi transaksi, yang dapat menggambarkan karakteristik penjualan produk secara akurat. Dengan menggunakan metode *train_test_split* yang membagi data menjadi 80% data pelatihan dan 20% data uji berdasarkan pengunci *random_state*=42, model ini dapat dengan jelas mengidentifikasi produk dengan tingkat perputaran tinggi dan rendah. *Accuracy_score*, *Precision_score*, *Recall_score*, dan *F1_score* digunakan untuk menentukan tingkat keberhasilan model dalam fungsi *evaluateModel*(*self*, X_*test*, y_*test*). Skor kepercayaan yang diperoleh dari fungsi *predict*(*self*, data_baru) menggunakan fungsi probabilitas *predict_proba*(data_baru).*max*(axis=1)

menunjukkan bahwa model memiliki tingkat kepercayaan yang tinggi terkait hasil prediksi berbagai objek barang pada dasbor. Hasil evaluasi yang tinggi ini didominasi oleh metode prapemrosesan yang menggunakan variabel kuantitatif total_qty sebagai dasar kategorisasi, sehingga tingkat kesalahan klasifikasi menjadi nol (tidak ada kesalahan klasifikasi). Analisis data bulanan tahun 2025 digunakan sebagai dasar untuk mengidentifikasi karakteristik masing-masing produk setelah akurasi algoritma ditentukan. Distribusi volume transaksi per unit antara Januari dan Desember tahun 2025 dari sepuluh sampel produk utama ditampilkan menggunakan data tabel berikut:

Tabel 4.6 Data Penjualan AQUAPROOF PUTIH @4KG

Bulan	Jumlah (Unit)	Bulan	Jumlah (Unit)
Jan-25	9.557	Jul-25	12.570
Feb-25	10.853	Aug-25	13.264
Mar-25	7.459	Sep-25	10.943
Apr-25	6.522	Oct-25	13.873
May-25	8.836	Nov-25	12.463
Jun-25	8.882	Dec-25	12.400

Tabel 4.7 Data Penjualan BASILIUM @500ML

Bulan	Jumlah (Unit)	Bulan	Jumlah (Unit)
Jan-25	80	Jul-25	169
Feb-25	130	Aug-25	131
Mar-25	81	Sep-25	75
Apr-25	72	Oct-25	19

Bulan	Jumlah (Unit)	Bulan	Jumlah (Unit)
May-25	121	Nov-25	55
Jun-25	118	Dec-25	64

Tabel 4.8 Data Penjualan INTRA WHITE 12C75

Bulan	Jumlah (Unit)	Bulan	Jumlah (Unit)
Jan-25	40.125	Jul-25	37.133
Feb-25	44.415	Aug-25	36.426
Mar-25	44.812	Sep-25	39.587
Apr-25	66.050	Oct-25	50.150
May-25	24.760	Nov-25	30.600
Jun-25	43.501	Dec-25	52.025

Tabel 4.9 Data Penjualan MAT 300 JUSHI 1040 @30KG

Bulan	Jumlah (Unit)	Bulan	Jumlah (Unit)
Jan-25	12.675	Jul-25	24.680
Feb-25	25.904	Aug-25	22.756
Mar-25	13.826	Sep-25	24.318
Apr-25	14.998	Oct-25	20.927
May-25	17.774	Nov-25	20.238
Jun-25	21.129	Dec-25	22.573

Tabel 4.10 Data Penjualan POLYTANK CAHAYA @200L

Bulan	Jumlah (Unit)	Bulan	Jumlah (Unit)
Jan-25	32	Jul-25	178

Bulan	Jumlah (Unit)	Bulan	Jumlah (Unit)
Feb-25	77	Aug-25	34
Mar-25	93	Sep-25	147
Apr-25	69	Oct-25	66
May-25	46	Nov-25	79
Jun-25	0	Dec-25	80

Tabel 4.11 Data Penjualan SELANG HITPRO 1/2" @20M

Bulan	Jumlah (Unit)	Bulan	Jumlah (Unit)
Jan-25	4	Jul-25	0
Feb-25	14	Aug-25	0
Mar-25	21	Sep-25	0
Apr-25	0	Oct-25	0
May-25	0	Nov-25	0
Jun-25	0	Dec-25	0

Tabel 4.12 Data Penjualan SEPATU LYONS

Bulan	Jumlah (Unit)	Bulan	Jumlah (Unit)
Jan-25	0	Jul-25	0
Feb-25	25	Aug-25	0
Mar-25	0	Sep-25	20
Apr-25	0	Oct-25	12
May-25	0	Nov-25	0
Jun-25	34	Dec-25	20

Tabel 4.13 Data Penjualan SILICONE EMULSION 320 HV

Bulan	Jumlah (Unit)	Bulan	Jumlah (Unit)
Jan-25	9	Jul-25	0
Feb-25	0	Aug-25	3
Mar-25	0	Sep-25	2
Apr-25	3	Oct-25	0
May-25	2	Nov-25	1
Jun-25	0	Dec-25	0

Tabel 4.14 Data Penjualan TRANSPARENT 1/4" 100M

Bulan	Jumlah (Unit)	Bulan	Jumlah (Unit)
Jan-25	95	Jul-25	589
Feb-25	215	Aug-25	206
Mar-25	310	Sep-25	585
Apr-25	58	Oct-25	91
May-25	274	Nov-25	205
Jun-25	291	Dec-25	38

Tabel 4.15 Data Penjualan YELLOW METERAN 5MM

Bulan	Jumlah (Unit)	Bulan	Jumlah (Unit)
Jan-25	0	Jul-25	3
Feb-25	0	Aug-25	3
Mar-25	0	Sep-25	1
Apr-25	0	Oct-25	0
May-25	0	Nov-25	0

Bulan	Jumlah (Unit)	Bulan	Jumlah (Unit)
Jun-25	0	Dec-25	0

Berdasarkan statistik di atas mengenai penjualan bulanan pada tahun 2025, setiap komoditas menunjukkan karakteristik volume perputaran yang sangat bervariasi. *INTRA WHITE* 12C75 (509.584 unit), MAT 300 JUSHI 1040 @30KG (241.798 unit), *AQUAPROOF* PUTIH @4KG (127.622 unit), *TRANSPARENT* 1/4" 100M (2.957 unit), dan *BASILIUM* @500ML (1.115 unit). Permintaan yang terus-menerus dari tahun kei tahun pada kelompok barang ini menjadi landasan yang kuat bagi model untuk memprediksi status biner 1 (barang bergerak cepat). Hasil proses klasifikasi label, yang dihasilkan secara terintegrasi oleh sistem, memberikan gambaran objektif mengenai kondisi tata kelola persediaan barang di PT Rodes Chemindo. Korelasi antara data empiris bulanan dan fitur matematis algoritma XGBoost menunjukkan bahwa variabel total volume penjualan (total_qty) memiliki peran penting sebagai indikator akurat tingkat logistik. Tiga implikasi strategis utama bagi bisnis disajikan melalui analisis data interaktif biner yang didasarkan pada skor probabilitas:

1. Optimalisasi Pengadaan (Efisiensi Pengadaan): Produk kimia utama yang termasuk dalam kategori *Fast-Moving* diprioritaskan dalam siklus pembelian ulang persediaan barang guna meminimalkan risiko potensial terjadinya kehabisan stok.
2. Efisiensi Penyimpanan (Pengurangan Biaya Penyimpanan): Produk-produk yang termasuk dalam kategori *Slow-Moving* dievaluasi oleh manajer dengan menggunakan program bundling promosi diskon penjualan, atau mengurangi

kuantitas ke tingkat serendah mungkin guna meminimalkan biaya ruang gudang dan meminimalkan pengeluaran terkait pekerjaan.

3. Pendukung Keputusan Manajerial (Sistem Berbasis Data): Visualisasi klasifikasi klaster yang ditampilkan pada dasbor memudahkan manajemen operasional dalam mengambil keputusan logistik berdasarkan data mentah secara jelas, ringkas, dan mudah dipahami tanpa subjektivitas tenaga manusia.

4.5. Validasi Sistem, Kelebihan, dan Kekurangan Aplikasi

Sistem ini telah berhasil mengintegrasikan aspek keamanan tingkat tinggi melalui mekanisme kontrol login multi-pengguna. Kontrol akses berbasis peran, atau hak akses, merupakan cara yang efektif untuk melindungi integritas data dan keamanan sistem operasional. Melalui validasi sesi token pada sistem *backend Flask*, akses diverifikasi secara tepat waktu, di mana hanya pengguna dengan izin admin yang diberikan akses kei dataset baru Dataset2025.csv, menganalisis data prapemrosesan, dan memulai prosedur pelatihan XGBoost *Classifier*. Akibatnya, fungsionalitas pengguna dibatasi sedemikian rupa sehingga mereka hanya dapat melihat hasil visualisasi dasbor analitik, matriks bulanan, dan tren temporal lintas tahun.

Selain itu, format *spreadsheet Microsoft Excel* (.xlsx) dan PDF (.pdf) dari laporan cetak dibuat menggunakan data yang disimpan dalam basis data MySQL. Validasi data antara tabel tampilan dinamis pada halaman dasbor dengan file hasil ekspor fisik menunjukkan tingkat konsistensi 100%. Pengujian pencocokan (*cross-validation*) digunakan untuk menentukan akurasi data bit ini untuk masing-masing dari 413 parameter entitas produk unik, yang mencakup atribut seperti kode barang, nama barang, akumulasi fitur kuantitas total (total_qty), frekuensi penjualan

bulanan, label keputusan target biner, dan persentase tingkat kepercayaan (*confidence score*) hasil perhitungan fungsi *predict_proba*. Berdasarkan analisis perbandingan yang disebutkan di atas, tidak ditemukan perbedaan karakter, pergeseran baris, atau bahkan satu kesalahan pengetikan angka dalam lembar dokumen hasil unduhan. Hasil optimal ini menunjukkan bahwa transformasi dan penguraian komponen teks (*data parsing*) yang dilakukan oleh pustaka interaktif antara xlsx.full.min.js di bagian *backend* dan area rendering *HTML* oleh pustaka html2pdf.bundle.min.js berjalan lancar tanpa mengalami kehilangan informasi (*zero data loss*). Akibatnya, sistem klasifikasi produk PT Rodes Chemindo mampu menyediakan dokumentasi yang akurat, valid, dan mudah dipahami guna mendukung kebutuhan rapat manajerial dalam pengembangan logistik berbasis data.

Berdasarkan hasil evaluasi fungsional dan analisis kinerja sistem yang telah diselesaikan, aplikasi untuk mengklasifikasikan stok barang PT Rodes Chemindo ini memiliki beberapa keunggulan utama, antara lain:

1. Klasifikasi Otomatis Berbasis *Machine Learning*

   Sistem ini menggunakan algoritma XGBoost *Classifier*, yang memiliki kemampuan sangat tinggi dalam menganalisis data tabel. Proses pengklasifikasian satuan kuantitas (total_qty) diotomatiskan menggunakan fungsi *predict*, yang menghilangkan subjektivitas pekerjaan manual.

2. Transparansi Hasil melalui Skor Keyakinan

   Sistem ini menggunakan metode *predict_proba*.*max*(axis=1) untuk menghitung tingkat kepastian prediksi. Visualisasi tingkat keyakinan ini meningkatkan akuntabilitas hasil algoritma pada dasbor.

3. Mekanisme Pencegahan Kesalahan Basis Data (Sinkronisasi Skema Otomatis)

   Sistem ini dilengkapi dengan logika prapemrosesan cerdas yang dapat mendeteksi kode produk baru selama proses unggah menggunakan berkas Dataset2025.csv. Jika ditemukan entitas produk yang belum terdaftar dalam tabel referensi utama, sistem secara otomatis membuat objek baru yang dimaksud untuk menghilangkan risiko kegagalan kunci asing dalam basis data MySQL.

2. Fungsionalitas Ekspor Laporan yang Kompatibel

   Fitur ekspor laporan melalui pustaka xlsx.full.min.js dan html2pdf.bundle.min.js memudahkan pengguna untuk mengonversi tabel keputusan menjadi berkas *Excel* atau PDF yang menarik dengan kehilangan data minimal.

3. Portabilitas Dokumen Sumber (Kode Sumber Siap Dipenerapkan)

   Seluruh pemrograman *Flask* di bagian *backend*, konfigurasi pembungkus basis data, dan antarmuka visualisasi telah disusun kei dalam satu direktori dokumen. Karakteristik ini memudahkan proses digitalisasi dalam format .zip sebagai syarat mutlak untuk penyerahan aset kode sumber asli pada sidang tugas akhir.

Selain keunggulan yang dimiliki, terdapat beberapa kendala teknis dan kekurangan dalam sistem yang dapat dijadikan dasar untuk pengembangan di masa mendatang:

1. Keterbatasan Aksesibilitas Lingkungan Localhost

   Saat ini, aplikasi ini berjalan di server lokal (server pengembangan lokal) menggunakan *Flask* dan data MySQL internal. Hambatan infrastruktur ini membuat sistem tidak dapat diakses dari luar jaringan lokal melalui domain

internet publik. Namun, lingkungan lokal ini aman dan dapat digunakan oleh PT Rodes Chemindo sebagai prototipe tahap awal.

2. Ketergantungan yang Ketat pada Validitas Format Input

   Fleksibilitas entri data kei dalam modal unggah masih terbatas. Modul *backend* hanya dikonfigurasi untuk membuat file tabel dalam format .CSV dengan 16 atribut kolom baku. Karena kurangnya fleksibilitas dalam struktur tabel, sistem otomatis ini mencegah terjadinya kesalahan perhitungan algoritmik.

3. Dimensi Variabel Fitur Prediktor yang Terbatas

   Fase pelatihan algoritma XGBoost dalam fungsi *trainModel* baru-baru ini dioptimalkan dengan memanfaatkan dua variabel fitur agregat, yaitu jumlah total (total_qty) dan frekuensi catatan. Sistem ini tidak menggunakan variabel prediktor eksternal yang lebih kompleks, seperti analisis tren musiman atau analisis tren penjualan musiman.

4. Skalabilitas Waktu Komputasi Data Skala Besar

   Ketika sistem menerima data transaksi penjualan dengan jumlah baris yang sangat besar, beban pemrosesan di *backend* meningkat secara bertahap. Hal ini disebabkan oleh proses pemurnian data, penggabungan tipe data, agregasi tingkat produk, dan prediksi *Gradient Boosting* yang dilakukan secara berurutan dalam memori komputer lokal.

BAB V

PENUTUP

5.1. Kesimpulan

Berdasarkan hasil seluruh penelitian, pengembangan, implementasi, dan evaluasi sistem klasifikasi stok barang menggunakan algoritma XGBoost *Classifier* di PT Rodes Chemindo yang telah diselesaikan, dapat ditarik kesimpulan utama sebagai berikut:

1. Efisiensi Mutlak Sistem Klasifikasi

   XGBoost telah berhasil menerapkan model objek xgb.*XGBClassifier* dengan parameter *learning rate* 0,1 dan *max depth* 5 untuk mengklasifikasikan produk ke dalam kategori *Fast-Moving* (Label 1) dan *Slow-Moving* (Label 0). Berdasarkan hasil analisis kuantitatif terhadap 83 data uji yang diisolasi (20% dari total 413 produk unik), model tersebut menghasilkan hasil yang akurat dengan akurasi, presisi, *recall*, dan *F1-score* sekitar 100,00% (1,00). Kinerja yang sempurna tanpa kesalahan (*zero misclassification*) ini dipengaruhi oleh konsistensi linier dari variabel fitur agregat kuantitas total (total_qty) dan frekuensi transaksi yang sangat tinggi pada tahun 2025. Selain itu, fungsi *predict_proba* berguna untuk menampilkan Skor Keyakinan yang valid dan objektif di dasbor.

2. Keamanan Data dan Kontrol Akses

   Penerapan mekanisme kontrol *login* multi-pengguna berbasis token sesi pada *backend Flask* telah berhasil mengurangi tindakan otoritas. Berbeda dengan akun Pengguna, yang hanya digunakan untuk fungsi tinjauan laporan

operasional (hanya baca), akun Admin memantau seluruh proses pembacaan menggunakan Dataset2025.csv serta eksekusi model pelatihan. Hal ini memastikan bahwa integritas data MySQL tetap terjaga.

3. Sinkronisasi Sistem dan Fungsi Pelaporan

   Seluruh fitur interaktif pada aplikasi web, mulai dari visualisasi grafik tren temporal dan formulir unggah berkas dengan ekstensi khusus .csv hingga fitur ekspor laporan fisik, terbukti berfungsi secara optimal. Parsing data adalah proses yang menggunakan xlsx.full.min.js dan html2pdf.bundle.min.js untuk memastikan format dokumen. Berkas *Excel* dan PDF dapat disimpan dalam basis data tanpa kehilangan informasi apa pun (tanpa kehilangan data).

4. Optimalisasi Pengambilan Keputusan Manajemen Persediaan

   Dengan penerapan sistem klasifikasi otomatis ini, manajemen PT Rodes Chemindo kini memiliki landasan data objektif untuk menentukan skala prioritas barang. Secara bijaksana, sistem ini membantu perusahaan meminimalkan risiko menangani barang mati (*dead stock*) dan mengurangi kemungkinan kehabisan stok.

5.2. Saran

Meskipun prototipe sistem ini telah beroperasi dengan sangat baik dan memenuhi semua tujuan penelitian, terdapat beberapa rekomendasi teoretis dan praktis untuk pengembangan sistem di masa mendatang, antara lain:

1. Peramalan Perkembangan Stok

   Diharapkan penelitian lanjutan dapat melakukan perluasan fungsional dengan mengintegrasikan model peramalan stok berbasis algoritma deret waktu, seperti LSTM atau ARIMA, sehingga sistem tidak hanya mampu

mengklasifikasikan status terkini barang perputaran, tetapi juga memprediksi jumlah kebutuhan stok tertentu pada periode mendatang.

2. Integrasi Data Secara *Real-Time*

   Arsitektur aplikasi web ini dirancang untuk memudahkan penggunaan Antarmuka Pemrograman Aplikasi (API) guna mengakses data penjualan utama atau sistem ERP (*Enterprise Resource Planning*) internal PT Rodes Chemindo. Dengan demikian, administrator tidak perlu membuka setiap berkas .CSV secara manual setiap hari.

3. Dimensi Perluasan Model Prediktor

   Untuk menganalisis variasi tren transaksi lintas tahun yang diperkirakan akan lebih sering terjadi di masa depan, penelitian lebih lanjut dilakukan untuk menambahkan dimensi variabel prediktor baru ke fase analisis fungsi *trainModel*, seperti klasifikasi jenis komoditas kimia, margin produk, dan analisis pasar (analisis tren musiman).

DAFTAR PUSTAKA

Aji, G., Shafira, H., Zahro, S. K., & Juliyanti, A. (2023). Analisis Manajemen Persediaan Bahan Baku Pada UMKM Risol Kekasih Pekalongan. *Jurnal Manajemen Bisnis Kewirausahaan*, *2*(3), 43–54. https://doi.org/10.56910/jumbiwira.v2i3.1077

Arai, K., Fujikawa, I., Nakagawa, Y., Momozaki, R., & Ogawa, S. (2023). Churn Customer Estimation Method based on LightGBM for Improving Sales. *International Journal of Advanced Computer Science and Applications (IJACSA)*, *14*(2), 119–125. https://doi.org/10.14569/IJACSA.2023.0140215

Arifin, C. A. Z., Nugraha, A. E., & Winarno. (2023). Klasifikasi Persediaan pada Gudang Bahan Kemasan XYZ dengan Metode FSN Analysis (Fast , Slow , Non-Moving) Berdasarkan Turn Over Ratio (TOR). *Go-Integratif : Jurnal Teknik Sistem Dan Industri*, *04*(02), 76–87. https://doi.org/10.35261/gijtsi.v4i02.8906

Arunika, K. R., & Dewi, L. J. E. (2025). Perbandingan Model SARIMA , EXPONENTIAL SMOOTHING, dan XGBOOST Untuk Prediksi Penjualan Super Store. *JITET (Jurnal Informatika Dan Teknik Elektro Terapan)*, *13*(3S1), 2021–2032. https://doi.org/10.23960/jitet.v13i3S1.8173

Astrani, I. G. A. R., & Rahayuda, I. G. S. (2025). Analisis Perbandingan XGBoost dan LightGBM dalam Prediksi Penjualan Ritel Walmart Store Sales. *Jurnal Nasional Teknologi Informasi Dan Aplikasinya (JNATIA)*, *3*(4), 717–728. https://doi.org/10.24843/JNATIA.2025.v03.i04.p01

Dachi, J. M. A. S., & Sitompul, P. (2023). Analisis Perbandingan Algoritma XGBoost dan Algoritma Random Forest Ensemble Learning pada Klasifikasi Keputusan Kredit. *Jurnal Riset Rumpun Matematika Dan Ilmu Pengetahuan Alam (JURRIMIPA)*, *2*(2), 87–103. https://doi.org/10.55606/jurrimipa.v2i2.1336

Fajarudin, & Wijaya, Y. A. (2023). Penerapan Metode K-Means Clustering dalam Mengelompokan Pelanggan PT. PLN Kota Cirebon. *JURNAL ALGOR*, *V*(I), 10–19.

Habibi, N. H., & Ulkhaq, M. M. (2025). Strategi pengendalian persediaan dengan pendekatan klasifikasi ABC-FSN dan metode Min-Max pada material Spiral Wound Gaskets di PT XYZ. *Jurnal Teknik Industri*, *20*(1), 1–10. https://ejournal3.undip.ac.id/index.php/ieoj/article/view/49853/33359

Hidayat, Y. R., & Yanto, A. J. (2022). Dedicated Storage pada Gudang Penyimpanan PT. ATS Inti Sampoerna. *Jurnal Logistik Indonesia*, *6*(2), 178–184. https://doi.org/10.31334/logistik.v6i2.2745

Irmayani, D., & Munandar, M. H. (2020). Sistem Informasi Pengelolaan Data Siswa Pada SMA NEGERI 02 BILAH HULU Berbasis Web. *Informatika : Jurnal Ilmiah Fakultas Sains Dan Teknologi*, *8*(2), 65–71. https://doi.org/10.36987/informatika.v8i2.1427

Julianto, I. T., Kurniadi, D., Nashrulloh, M. R., & Mulyani, A. (2022). Data Mining Clustering Food Expenditure in Indonesia. *Jurnal Teknik Informatika (JUTIF)*, *3*(6), 1491–1500. https://doi.org/10.20884/1.jutif.2022.3.6.331

Kurniawansyah, K., Marthiawati, N., Rohayani, H., & Nugraha, H. (2025). Pelatihan Pengelolaan Database MenggunakAn XAMPP Untuk Meningkatkan Keterampilan Mahasiswa di Universitas Muhammadiyah Jambi. *Masyarakat Berkarya : Jurnal Pengabdian Dan Perubahan Sosial*, *2*(2), 151–161.

Larasati, T. A. (2024). *Analisis faktor penyebab persediaan slow moving and obsolete (SLOB) pada distributor alat kesehatan PT XYZ*. Universitas Gadjah Mada (Fakultas Ekonomika dan Bisnis).

Latif, A., & Wildah, S. K. (2025). Analisis Kinerja Algoritma ENSEMBLE Dalam Prediksi Perilaku Pembelian Pelanggan. *JATI (Jurnal Mahasiswa Teknik Informatika)*, *9*(1), 557–563. https://doi.org/10.36040/jati.v9i1.12413

Mahmudah, F., Rahaningsih, N., Dana, R. D., & Rohmat, C. L. (2025). Implementasi data mining menggunakan algoritma K-Means untuk mempermudah pengelompokkan wilayah rawan stunting di Kabupaten Cirebon. *INTEK: Jurnal Teknologi Terapan*. https://ebook.umpwr.ac.id/intek/article/view/5794

Massaro, A., Panarese, A., Giannone, D., & Galiano, A. (2021). Augmented data and XGBoost improvement for sales forecasting in the large-scale retail sector. *Applied Sciences*, *11*(17), 1–22. https://doi.org/10.3390/app11177793

Muludin, L., Aisyah, N., Suwanita, T., Zahra, R. A., & Stinka, E. (2025). Integrasi Dan Optimalisasi Alur Kerja Pengembangan Website Lokal Menggunakan Aplikasi Xampp Tools Berbasis Electron. *OKTAL : Jurnal Ilmu Komputer*

Dan Science, *4*(5), 115–124.

Mulyati, S., Herdiansah, A., Taufiq, R., Prianggodo, D. Y., & Bukhori, S. (2024). Implementasi Rapid Application Development (Rad) Studi Kasus Pengembangan Sistem Informasi Sekolah Yayasan Al Abaniyah. *JIKA (Jurnal Informatika)*, *8*(2), 156. https://doi.org/10.31000/jika.v8i2.10268

Munyaka, J.-C. B., & Yadavalli, S. V. (2022). Inventory Management Concepts and Implementations: A Systematic Review. *The South African Journal of Industrial Engineering*, *33*(2), 15–36. https://doi.org/10.7166/33-2-2527

Opitasari, Natsir, F., & Marsiani, E. S. (2024). Klasifikasi Diagnosis untuk Penyakit Kanker Serviks Menggunakan Algoritma Extreme Gradient Boosting (XGBoost). *JURNAL ILMIAH FIFO*, *16*(1), 55–63. https://doi.org/10.22441/fifo.2024.v16i1.006

Patappari, A., & Muhlisa, N. (2023). Sistem Informasi Persediaan Barang Berbasis Web Pada Toko Throve Store Soppeng. *Jurnal Ilmiah Sistem Informasi Dan Teknik Informatika (JISTI)*, *6*(1), 1–8. https://doi.org/10.57093/jisti.v6i1.142

Perdana, A. A., & Munggaran, L. C. (2021). Penerapan BPMN Pada Pemodelan Proses Bisnis Sistem Informasi Elektronik Jabatan Fungsional. *Jurnal Ilmiah KOMPUTASI*, *20*(2), 237–245. https://doi.org/10.32409/jikstik.20.2.2723

Rahman, M. F., & Nursyamsiah, S. (2023). Pengaruh Praktik Manajemen Persediaan terhadap Kinerja Perusahaan yang Dimediasi oleh Pengetahuan Manajemen Persediaan: Studi Empiris pada Toko Ritel di D.I. Yogyakarta. *Selekta Manajemen: Jurnal Mahasiswa Bisnis & Manajemen*, *02*(05), 194–

206. https://journal.uii.ac.id/selma/article/download/32947/16406/108043

Ridwanto, & Capah, D. A. H. (2020). Aplikasi Pengelolaan Dokumen dan Arsip berbasis Web untuk mengatur Sistem kearsipan dengan menggunakan Metode Waterfall. *Explore:Jurnal Sistem Informasi Dan Telematika*, *11*(2), 84–90. https://doi.org/10.36448/jsit.v11i2.1469

Riza, F. (2022). Analisis dan Prediksi Data Penjualan Menggunakan Machine Learning dengan Pendekatan Ilmu Data. *DSI: Jurnal Data Science Indonesia*, *1*(2), 62–68. https://doi.org/10.47709/dsi.v1i2.1308

Rodjimin, Y. B., Isnainny, & Situmorang, E. (2023). Analisis Kelompok Persediaan Barang Menggunakan FSN (Fast, Slow, Non-Moving) Berdasarkan Analisis Turn Over Ratio pada Gudang Pabrik PT Sasana Yudha Bhakti. *Jurnal Citra Widya Edukasi*, *15*(1), 35–44.

Saputra, H., Yudherta, A., & Triadi, A. (2025). Perancangan Sistem Informasi Pengelolaan Surat Di Fakultas Sains Dan Teknologi Universitas Islam Negeri Sulthan Thaha Saifuddin Jambi. *JURNAL MEDIA INFORMATIKA [JUMIN]*, *6*(3), 2195–2210. https://ejournal.sisfokomtek.org/index.php/jumin/article/view/6353/3894

Singh, D. J. (2022). Concepts of Inventory and Related Technical Terminologies: A Literature Review. *International Journal for Research Trends and Innovation (IJRTI)*, *7*(8), 1784–1796. https://www.ijrti.org/viewpaperforall.php?paper=IJRTI2208274

Sugiyono. (2022). *Metode Penelitian Kuantitatif, Kualitatif, dan R&D*.

Suhartini, Sadali, M., & Putra, Y. K. (2020). Sistem Informasi Berbasis Web Sma Al- Mukhtariyah Mamben Lauk Berbasis Php Dan Mysql Dengan Framework Codeigniter. *Infotek : Jurnal Informatika Dan Teknologi*, *3*(1), 79–84. https://doi.org/10.29408/jit.v3i1.1793

Suriyani, N., Siregar, L. H., & Zahari. (2020). Analisis Perencanaan dan Pengawasan Persediaan Barang Dagang pada CV. Sumber Indoraya. *Jurnal Bisnis Net*, *III*(1), 62–69. https://journal.dharmawangsa.ac.id/index.php/bisnet/article/view/690/640

Syafrinal, I., & Febrianti, E. L. (2023). Penerapan Algoritma K-MEANS Pada Aplikasi Data Mining Untuk Menentukan Pola Penjualan (Studi Kasus: Zahra Mart). *JURNAL DIGIT*, *13*(1), 31–40. https://doi.org/10.51920/jd.v13i1.320

Wang, G. (2023). Sales Forecast of Retail Commodity on the Basis of LightGBM and Xgboost. *In Proceedings of the 2022 International Conference on Frontiers of Finance and Information Technology (FFIT 2022)*, 1–9. https://doi.org/10.4108/eai.28-10-2022.2328402

Yahya, R., Wisnugroho, A. D. H., & Asrory, F. F. (2023). Perencanaan Re-Layout Penempatan Barang Ownstok Dengan Menggunakan Metode Class Based Storage(CBS) Di Warehouse PT. Pamapersada Nusantara Site BRCB (Binungan Blok 8). *G-Tech : Jurnal Teknologi Terapan*, *7*(3), 816–826. https://doi.org/10.33379/gtech.v7i3.2477

Zahra, A., Aulia, S. I., Destiyani, S., susilo, & Togatorop, Y. F. (2025). Inventory Management As The Key To Improving The Company's Operational

Performance (MANAJEMEN PERSEDIAAN SEBAGAI KUNCI PENINGKATAN KINERJA OPERASIONAL PERUSAHAAN). *Jurnal Ilmiah Ekonomi Dan Manajemen*, *3*(3), 418–428.

DAFTAR LAMPIRAN

Lampiran 1. Surat Izin Penelitian



UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA

FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI

UMSU

Nomor : 442/II.3-AU/UMSU-09/F/2026 Medan, 08 Rajab 1447 H

Lampiran : - 14 Januari 2026 M

Perihal : **IZIN PENELITIAN**

Kepada Yth

Bapak/Ibu Pimpinan

PT. Roden Chemindo

Jl. Setia Budi No.2, Pulasi Tengah,

Kec. Medan Petisah, Kota Medan, Sumatera Utara 20111

Di Tempat

Assalamu'alaikum Warahmatullahi Wabarakatuh

Dengan hormat, sehubungan mahasiswa kami akan melaksanakan riset untuk itu kami memohon kesediaan Bapak / Ibu untuk memberikan kesempatan pada mahasiswa kami melakukan riset di **Perusahaan / Instansi** yang Bapak / Ibu pimpin, guna untuk penyusunan skripsi yang merupakan salah satu persyaratan dalam menyelesaikan Program **Studi Strata Satu (S-1)**

Adapun Mahasiswa di Fakultas Ilmu Komputer dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara tersebut adalah:

Nama	**: Erlina Agustuk**
Npm	**: 2209010063**
Jurusan	**: Sistem Informasi**
Semester	**: VIII (Delapan)**
Judul	**: Klasifikasi Fast-Moving Dan Slow-Moving Terhadap Data Transaksi Penjualan Menggunakan Algoritma NEBOOST Pada PT Roden Chemindo**
Email	**: fellinaq1@gmail.com**
Hp/Wa	**: 082268135240**

Demikianlah surat kami ini atas perhatian dan kerjasama yang Bapak / Ibu berikan kami ucapkan terimakasih

Wassalamu'alaikum Warahmatullahi Wabarakatuh

a.n. Dekan

Dr. Fatma Sarie, S.Kom., M.Kom.

NIDN: 0127118402

MQA STARS

Lampiran 2. Surat Balasan Izin Penelitian



PT. RODEN CHEMINDO

Importer & Supplier of Industrial Chemicals

Alamat : Jl. Setia Budi No. 2

Medan 20111 Sumatera Utara

Phone : (061) 8224578 - 79 - 80 - 81

Fax : (061) 8224574 - 8224582

E-mail : roden@indosat.net.id

Nomor : 001/RC-UMSU/II/2026 Medan, 08 April 2026

Klasifikasi : Biasa

Lampiran : -

Hal : Balasan Izin Penelitian

Yth. Dekan Fakultas Ilmu Komputer dan Teknologi Informasi

Universitas Muhammadiyah Sumatera Utara

Di Tempat

Menindaklanjuti surat Dekan Fakultas Ilmu Komputer dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara Nomor: 442/II.3-AU/UMSU-09/F/2026 tanggal 14 Januari 2026 hal izin Penelitian.

Sehubungan dari tersebut di atas, bersama ini disampaikan bahwa pada prinsipnya kami telah menyetujui untuk memberikan izin kepada mahasiswa yang namanya tersebut di bawah ini untuk melaksanakan penelitian pada PT Roden Chemindo.

NO	NAMA	NPM	PROGRAM STUDI
1	Erlina Agustuk	2209010063	Sistem Informasi

Adapun kegiatan penelitian yang bersangkutan telah dilakukan sebagai berikut:

1. Pengumpulan data mengambil data awal pada tanggal 05 Januari 2026.
2. Pengumpulan kuisioner ke perusahaan untuk pengambilan kuisioner dan data tanggal 08 Januari 2026.

Demikian disampaikan, atas perhatian dan kerjasamanya diucapkan terima kasih.

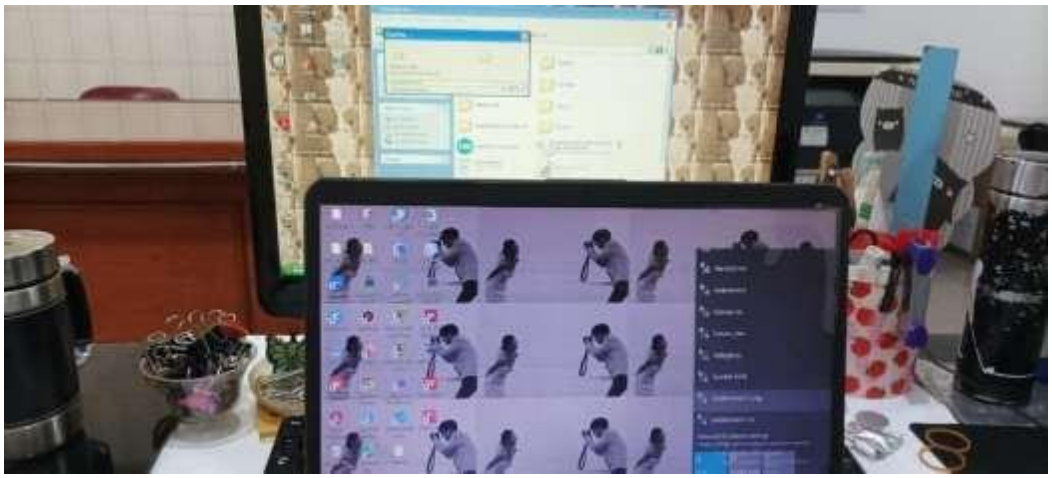
Hormat Kami,

PT. Roden Chemindo

Lim Hoklan

Direktur Perusahaan

Lampiran 3. Pemindahan Awal Data Transaksi



Lampiran 4. Form Revisi Sidang



UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA

FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI

UMSU

FORMULIR PERBAIKAN UJIAN SKRIPSI

Nama Mahasiswa : Febria Agustik

Program Studi : Sistem Informasi

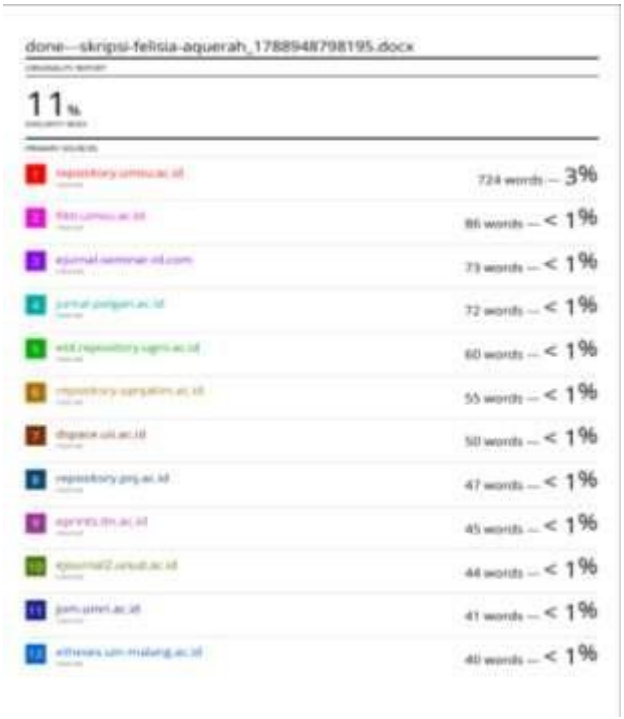
Judul : Klasifikasi Face Meeting Dan Non-Meeting Terhadap Data Transaksi Perusahan Menggunakan Algoritma XGBOOST Pada PT. Rodex Chemindo

Materi Point yang Diperbaiki

		Paraf
Mahareksa Pinem, S.Kom., M.Kom	Tolong lebih diperjelas pada bab 4 Manfaat Sistem Rekomendasi	
Dr. Fatahul Arifin, M.Kom	1. Perbaiki pada penginputan data 2. perbaiki langkah penelitian di Bab 3 3.	
Dr. Al-Khowarizmi, M.Kom	Lanjut	

Revisi acara ini ditandatangani setelah skripsi diperbaiki antara pembimbing dan Penguji Pembahas.

Lampiran 5. Turnitin



Lampiran 6. Bukti Submit Jurnal

