

**ESTIMASI PERSEDIAAN BAHAN BAKU BERBASIS MACHINE
LEARNING MENGGUNAKAN PROPHET DAN XGBOOST
UNTUK MENGURANGI FOOD WASTE
DI MATRA COFFEE**

SKRIPSI

DISUSUN OLEH

FARHAN FANALTY SIREGAR

NPM. 2209020150



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

**ESTIMASI PERSEDIAAN BAHAN BAKU BERBASIS MACHINE
LEARNING MENGGUNAKAN PROPHET DAN XGBOOST
UNTUK MENGURANGI FOOD WASTE
DI MATRA COFFEE**

SKRIPSI

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

FARHAN FANALTY SIREGAR

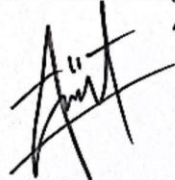
NPM. 2209020150

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

LEMBAR PENGESAHAN

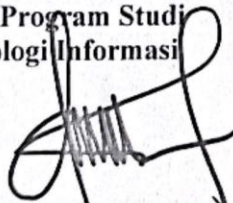
Judul Skripsi : ESTIMASI PERSEDIAAN BAHAN BAKU BERBASIS
MACHINE LEARNING MENGGUNAKAN PROPHET
DAN XGBOOST UNTUK MENGURANGI FOOD
WASTE DI MATRA COFFEE
Nama Mahasiswa : FARHAN FANALTY SIREGAR
NPM : 2209020150
Program Studi : TEKNOLOGI INFORMASI

Menyetujui
Komisi Pembimbing



(Amrullah, S.Kom., M.Kom)
NIDN. 0125118604

Ketua Program Studi
Teknologi Informasi



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

Dekan



(Dr. Al-Kho'warizmi, S.Kom., M.Kom.)
NIDN. 0127099201

PERNYATAAN ORISINALITAS

**ESTIMASI PERSEDIAAN BAHAN BAKU BERBASIS MACHINE
LEARNING MENGGUNAKAN PROPHET DAN XGBOOST
UNTUK MENGURANGI FOOD WASTE
DI MATRA COFFEE**

SKRIPSI

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

Medan, 11 Maret 2026

Yang membuat pernyataan



Farhan Fanalty Siregar

NPM. 2209020150

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

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

Nama : Farhan Fanalty Siregar
NPM : 2209020150
Program Studi : Teknologi Informasi
Karya Ilmiah : Skripsi

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

**ESTIMASI PERSEDIAAN BAHAN BAKU BERBASIS MACHINE
LEARNING MENGGUNAKAN PROPHET DAN XGBOOST
UNTUK MENGURANGI FOOD WASTE
DI MATRA COFFEE**

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, 11 Maret 2026

Yang membuat pernyataan



Farhan Fanalty Siregar

NPM. 2209020150

RIWAYAT HIDUP

DATA PRIBADI

Nama Lengkap : Farhan Fanalty Siregar
Tempat dan Tanggal Lahir : Padangsidempuan, 3 Juli 2004
Alamat Rumah : Jl. Imam Bonjol Perumahan Citra Land
Padang Matinggi
Telepon/Faks/HP : 082164957430
E-mail : broofarhanfanalty3@gmail.com
Instansi Tempat Kerja : -
Alamat Kantor : -

DATA PENDIDIKAN

SD : SDN 0702 Panyabungan TAMAT: 2016
SMP : SMP Negeri 1 Sosa TAMAT: 2019
SMA : SMA Negeri 2 Padangsidempuan TAMAT: 2022

KATA PENGANTAR



Puji dan syukur penulis panjatkan ke hadirat Allah SWT atas segala rahmat, karunia, serta hidayah-Nya sehingga penulis dapat menyelesaikan skripsi yang berjudul “Estimasi Kebutuhan Bahan Baku Berbasis Machine Learning Menggunakan Hybrid Prophet–XGBoost untuk Mengurangi Food Waste di Matra Coffee” dengan baik. Skripsi ini disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana pada Program Studi Teknologi Informasi, Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara.

Dalam proses penyusunan skripsi ini, penulis menyadari bahwa tanpa dukungan, bantuan, dan doa dari berbagai pihak, skripsi ini tidak akan dapat terselesaikan dengan baik. Oleh karena itu, pada kesempatan ini penulis ingin menyampaikan ucapan terima kasih yang sebesar-besarnya kepada:

1. Allah SWT yang telah memberikan rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi ini.
2. Kepada kedua orang tua penulis, Papa Alm. Malzan Fanalty Siregar, S.Sos dan Mami penulis Siska Yetti Tambunan, A.Md.Keb. Skripsi ini penulis persembahkan kepada almarhum papa tercinta yang semasa hidupnya selalu memberikan doa, dukungan, dan semangat kepada penulis dalam menempuh pendidikan. Semoga karya sederhana ini menjadi salah satu bentuk bakti dan kebanggaan yang dapat penulis persembahkan. Penulis juga mempersembahkan karya ini kepada mami saya tercinta yang senantiasa memberikan kasih sayang, doa, serta dukungan tanpa henti kepada penulis. Berkat doa dan pengorbanan beliau, penulis dapat menyelesaikan pendidikan ini dengan baik.
3. Kepada kedua saudara kandung penulis, kakak perempuan Nathacya Fanalty Siregar dan adik penulis Fahrhan Fanalty Siregar. Kakak yang senantiasa mendengarkan keluh kesah penulis, memberi bantuan materi, dan dukungan moral. Serta adik penulis yang menjadi semangat penulis untuk menyelesaikan pendidikan Sarjana di UMSU.

4. Bapak Prof. Dr. Agussani, M.A.P Rektor Universitas Muhammadiyah Sumatera Utara.
5. Bapak Assoc. Prof. Dr. Al-Khowarizmi, S.Kom., M.Kom. Dekan Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
6. Ibu Dr. Firahti Rizky, S.Kom., M.Kom selaku Wakil Dekan I Fakultas Ilmu Komputer dan Teknologi Informasi.
7. Bapak Mhd. Basri, S.Si., M.Kom selaku Wakil Dekan III Fakultas Ilmu Komputer dan Teknologi Informasi
8. Ibu Fatma Sari Hutagalung, S.Kom., M.Kom Ketua Program Studi Teknologi Informasi.
9. Bapak Okvi Nugroho, S.Kom., M.Kom Sekretaris Program Studi Teknologi Informasi
10. Seluruh dosen dan staf di Fakultas Ilmu Komputer dan Teknologi Informasi.
11. Dosen Pembimbing Bapak Amrullah, S.Kom., M.Kom yang senantiasa sabar dalam membimbing, mengarahkan dan membantu penulis dalam menyusun skripsi ini hingga dapat diselesaikan dengan baik.
12. Kepada sahabat penulis, Dwi Nisyatul Wardah. Sahabat penulis dari awal perkuliahan dimulai hingga hampir selesainya masa kuliah selama 4 tahun yang masih setia menemani penulis. Sahabat yang menemani, mendengarkan keluh kesah, mengingatkan, membantu, dan memvalidasi semua keresahan penulis semasa kuliah yang tak ternilai harganya.
13. Penulis juga mengucapkan terima kasih atas waktu dan dukungan teman-teman yang lain, terutama pada sahabat penulis Aida Fadhila dan Dinda Anantya, serta teman-teman lain seperti seluruh warga D1TI22, Iqbal, Haris, Afni, Mikael, Ibrahim, Dara, Ikhsan, Dita, dll yang tidak bisa penulis sebutkan satu persatu.
14. Semua pihak yang terlibat langsung ataupun tidak langsung yang tidak dapat penulis sebutkan satu persatu yang telah berperan banyak dalam hidup penulis selama menjalani masa perkuliahan dan penyusunan skripsi ini.

**ESTIMASI PERSEDIAAN BAHAN BAKU BERBASIS MACHINE
LEARNING MENGGUNAKAN PROPHET DAN XGBOOST
UNTUK MENGURANGI FOOD WASTE
DI MATRA COFFEE**

ABSTRAK

Pengelolaan persediaan bahan baku yang tidak akurat pada bisnis food and beverage dapat menyebabkan kelebihan stok yang berujung pada meningkatnya food waste serta pemborosan biaya operasional. Penelitian ini bertujuan untuk mengembangkan model prediksi kebutuhan bahan baku perishable pada Matra Coffee menggunakan pendekatan machine learning berbasis model hybrid Prophet dan XGBoost. Model Prophet digunakan untuk memodelkan tren jangka panjang dan pola musiman dari data historis penggunaan bahan baku, sedangkan XGBoost digunakan untuk mempelajari residual dari hasil prediksi Prophet sehingga mampu menangkap fluktuasi jangka pendek dan pengaruh variabel eksternal seperti hari libur. Data yang digunakan merupakan data historis penggunaan bahan baku Matra Coffee selama periode Juli–Desember 2025. Evaluasi model dilakukan menggunakan metrik Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE). Hasil pengujian menunjukkan bahwa model hybrid yang dikembangkan mampu menghasilkan tingkat akurasi yang baik dengan nilai MAPE di bawah 20% pada seluruh bahan baku utama. Sistem prediksi kemudian diimplementasikan dalam bentuk dashboard berbasis web yang dilengkapi dengan fitur simulasi pembelian bahan baku dan kalkulator food waste untuk membantu pengambilan keputusan operasional. Berdasarkan hasil simulasi sistem, penerapan model prediksi ini berpotensi menurunkan tingkat kelebihan stok bahan baku hingga sekitar 15–20% pada bahan baku kritis seperti susu dan buah. Dengan demikian, sistem yang dikembangkan dapat membantu meningkatkan efisiensi pengelolaan persediaan serta mengurangi potensi food waste pada operasional Matra Coffee.

Kata Kunci: machine learning; prophet; xgboost; hybrid forecasting; food waste; inventory prediction.

**RAW MATERIAL DEMAND FORECASTING USING A HYBRID
PROPHET–XGBOOST MACHINE LEARNING
MODEL TO REDUCE FOOD WASTE
AT MATRA COFFEE**

ABSTRACT

Inaccurate raw material inventory management in food and beverage businesses can lead to overstock conditions that increase food waste and operational costs. This study aims to develop a prediction model for estimating the demand of perishable raw materials at Matra Coffee using a hybrid machine learning approach combining Prophet and XGBoost algorithms. Prophet is utilized to model long-term trends and seasonal patterns derived from historical raw material usage data, while XGBoost functions as a residual learner to capture short-term fluctuations and external effects such as holiday impacts. The dataset used in this research consists of historical raw material usage data from Matra Coffee covering the period of July–December 2025. Model evaluation is conducted using Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), and Mean Absolute Percentage Error (MAPE). The experimental results indicate that the proposed hybrid model achieves satisfactory predictive performance, with MAPE values below 20% for all major raw materials. The prediction model is then implemented in a web-based dashboard system equipped with features such as a purchase order simulation module and a food waste calculator to support operational decision-making. Simulation results suggest that the implementation of the proposed system has the potential to reduce raw material overstock by approximately 15–20% for critical ingredients such as milk and fruit. Therefore, the developed system can assist in improving inventory management efficiency while reducing the risk of food waste in Matra Coffee operations.

Keywords: machine learning; prophet; xgboost; hybrid forecasting; food waste; inventory prediction.

DAFTAR ISI

ABTRAK	i
ABSTRACT	ii
DAFTAR ISI	iii
DAFTAR TABEL	v
DAFTAR GAMBAR	vi
BAB I. PENDAHULUAN	
1.1. Latar Belakang Masalah	1
1.2. Rumusan Masalah	3
1.3. Batasan Masalah.....	3
1.4. Tujuan Penelitian.....	4
1.5. Manfaat Penelitian.....	4
BAB II. LANDASAN TEORI	
2.1. Manajemen Rantai Pasok dan Persediaan	6
2.1.1 Manajemen Rantai Pasok (Supply Chain Management – SCM)...	6
2.1.2 Manajemen Persediaan (Inventory Management)	7
2.1.3 Bahan Baku yang Mudah Rusak.....	9
2.2. Food Waste dan Dampaknya.....	10
2.2.1 Definisi Food Waste	11
2.2.2 Penyebab Food Waste di Bisnis Makanan/Minuman.....	13
2.2.3 Dampak Food Waste.....	14
2.2.4 Food Waste pada Industri Coffee Shop	16
2.3. Peramalan (Forecasting) dan Machine Learning.....	17
2.3.1 Konsep Dasar Peramalan (Forecasting).....	18
2.3.2 Machine Learning Untuk Peramalan	19
2.3.3 Relevansi Model Machine Learning bagi Matra Coffee	21
2.4. Metode Machine Learning yang Digunakan	22
2.4.1 Model Peramalan Time Series Prophet	23
2.4.2 XGBoost (Extreme Gradient Boosting).....	24
2.4.3 Alasan Pemilihan Prophet dan XGBoost.....	26
2.4.4 Alur Algoritma Model Hybrid Prophet-XGBoost.....	26
2.5. Metrik Evaluasi Model	28
2.5.1 Mean Absolute Error (MEA).....	28
2.5.2 Mean Squared Error (MSE) dan Root Mean Squared Error (RMSE)	29
2.5.3 Mean Absolute Percentage Error (MAPE)	30
2.6. Ringkasan Penelitian Terdahulu.....	30
BAB III. METODOLOGI PENELITIAN	
3.1. Manajemen Rantai Pasok dan Persediaan	34
3.2. Lokasi dan Objek Penelitian.....	37
3.3. Teknik Pengumpulan Data	38
3.4. Variabel dan Data Penelitian.....	40
3.4.1 Sumber dan Bentuk Data Awal	41
3.4.2 Konversi Data Penjualan	42
3.4.3 Skema Pengolahan Data	43
3.4.4 Variabel Dependen (Target)	44
3.4.5 Variabel Independen (Fitur)	44

3.5. Model dan Analisis Data	46
3.5.1 Pra-Pemrosesan Data (Data Pre-processing)	49
3.5.2 Pembagian Data (Data Splitting).....	49
3.5.3 Pembangunan Model Prophet dan XGBoost.....	50
3.5.4 Evaluasi Model	53
3.5.5 Simulasi Estimasi Persediaan dan Analisis Food Waste	54
3.6. Rancangan Dashboard Prediksi Penjualan	56
3.6.1 Rancangan Halaman Login.....	57
3.6.2 Rancangan Dashboard Utama.....	58
3.6.3 Rancangan Riwayat Transaksi (History Log).....	58
3.6.4 Rancangan Halaman Simulasi Prediksi	60
3.6.5 Rancangan Halaman Menu Engineering Matrix	61
3.6.6 Rancangan Halaman Kalkulator Waste	62
3.6.7 Rancangan Halaman Pengaturan Sistem	63
3.7. Jadwal Penelitian	64
BAB IV HASIL DAN PEMBAHASAN	
4.1. Gambaran Umum Data Penelitian	65
4.1.1 Rasioanlisis Agregasi Data untuk Machine Learning	65
4.2. Pra-ppemrosesan Data (Data Preprocessing).....	67
4.2.1 Pembersihan Data (Data Cleaning).....	67
4.2.2 Konversi Menu ke Bahan Baku (Recipe Conversion).....	68
4.2.3 Hasil Agregasi dan Rekayasa Fitur.....	69
4.2.4 Data Splitting	70
4.3. Implementasi dan Hasil Pemodelan.....	70
4.3.1 Pemodelan Tren dan Musiman dengan Prophet	70
4.3.2 Pemodelan Residual dengan XGBoost	71
4.3.3 Hasil Prediksi Model Hybrid	72
4.3.4 Implementasi Kode Program (Code Implementation).....	72
4.4. Evaluasi Kerja Model	74
4.4.1 Analisis Kinerja Model Berdasarkan Bahan Baku	74
4.4.2 Validasi Perhitungan Manual	75
4.5. Pembahasan dan Analisis Hasil Evaluasi	77
4.5.1 Analisis Akurasi Prediksi Antar Bahan Baku.....	77
4.5.2 Efektivitas Model Hybrid dalam Menangani Anomali.....	78
4.5.3 Implikasi Manajerial: Mitigasi Food Waste	79
4.6. Implementasi Antarmuka Sistem (User Interface).....	79
4.6.1 Halaman Login dan Keamanan Akses.....	80
4.6.2 Dashboard Utama (Executive Overview)	81
4.6.3 Modul Riwayat Transaksi (Audit Trail)	82
4.6.4 Model Simulasi Prediksi (Smart Procurement)	83
4.6.5 Modul Matriks Menu (Product Strategy).....	84
4.6.6 Modul Kalkulator Limbah (Cost Control).....	88
4.6.7 Modul Pengaturan (Configuration).....	86
4.7. Keterbatasan Sistem.....	86
BAB V KESIMPULAN DAN SARAN	
5.1. Kesimpulan	88
5.2. Saran	89
DAFTAR PUSTAKA	92

DAFTAR TABEL

Tabel 2.1. Ringkasan Penelitian Terdahulu	35
Tabel 3.1. Data Mentah POS.....	46
Tabel 3.3. Hasil Konversi Bahan Baku.....	47
Tabel 3.4. Variabel Dependen.....	48
Tabel 3.5. Variabel Independen (Time-Based Features)	49
Tabel 3.6. Variabel Independen (Seasonall Features).....	49
Tabel 3.7. Variabel Independen (Lagged Features).....	49
Tabel 3.8. Jadwal Penelitian.....	59
Tabel 4.1. Contoh Matriks Konversi Resep	68
Tabel 4.2. Hasil Evaluasi Model Hybrid Propjet-XGBoost.....	73
Tabel 4.3. Tabel Perhitungan Manual (Sampel Data Susu).....	75

DAFTAR GAMBAR

Gambar 3.1. Contoh Data POS (Struk Penjualan)	43
Gambar 3.2. Skema Pengolahan Data	47
Gambar 3.3. Flowchart Penyelesaian Masalah Penelitian	47
Gambar 3.4. Flowchart Model Hybrid Prophet-XGBoost	50
Gambar 3.5. Rancangan Halaman Login	57
Gambar 3.6. Rancangan Halaman Dashboard	58
Gambar 3.7. Rancangan History Log	59
Gambar 3.8. Rancangan Simulasi Prediksi	60
Gambar 3.9. Rancangan Matrix Engineering Menu	62
Gambar 3.10. Rancangan Halaman Kalkulator Waste	62
Gambar 3.11. Rancangan Halaman Pengaturan	63
Gambar 4.1. Halaman Login	80
Gambar 4.2. Tampilan Dashboard Utama dan Grafik Prediksi	81
Gambar 4.3. Halaman Riwayat Transaksi	82
Gambar 4.4. Halaman Simulasi Prediksi Stok	83
Gambar 4.5. Halaman Analisis Matriks Menu	84
Gambar 4.6. Halaman Kalkulator Food Waste	85
Gambar 4.7. Halaman Pengaturan Sistem	86

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Dunia Food and Beverage (F&B), termasuk usaha kafe, sering berhadapan dengan tantangan dalam menjaga ketersediaan bahan baku agar tetap sesuai kebutuhan. Jumlah pelanggan yang berubah-ubah dan pola penjualan yang tidak stabil membuat estimasi stok kerap meleset. Akibatnya, bahan baku bisa berlebih hingga menimbulkan food waste, atau justru kurang sehingga pelayanan terganggu. Permasalahan ketidakseimbangan persediaan ini umum terjadi pada sektor makanan dan minuman karena tingginya ketidakpastian permintaan serta karakteristik bahan baku yang mudah rusak (Olaniyi et al., 2024).

Selama ini, pengelolaan stok umumnya dilakukan secara manual, misalnya dengan mencatat pemakaian bahan baku, membandingkan penjualan bulan sebelumnya, atau mengandalkan perkiraan pegawai. Cara tersebut sangat bergantung pada intuisi dan pengalaman, sehingga tidak selalu akurat ketika terjadi perubahan permintaan secara tiba-tiba. Pendekatan konvensional ini berisiko menimbulkan kelebihan stok yang meningkatkan biaya penyimpanan, maupun kekurangan stok yang dapat mengganggu kelancaran operasional (Sulu & Waluyowati, 2023).

Kondisi pengelolaan persediaan yang kurang optimal tersebut merupakan permasalahan penting dalam supply chain, khususnya pada bisnis yang menggunakan bahan baku perishable. Bahan baku jenis ini memiliki umur simpan terbatas dan kualitasnya menurun seiring waktu, sehingga kesalahan dalam

perencanaan persediaan akan berdampak langsung pada peningkatan kerusakan bahan dan food waste. Ahumada dan Villalobos (2009) menjelaskan bahwa produk perishable memerlukan sistem pengendalian persediaan yang lebih adaptif karena kualitasnya terus mengalami degradasi sepanjang rantai pasok

Food waste sendiri merupakan salah satu dampak utama dari ketidaktepatan estimasi kebutuhan bahan baku di sektor food and beverage. Rahal (2024) menyebutkan bahwa persentase kehilangan dan pemborosan pada perishable supply chain dapat mencapai 20–60% dari total produksi, yang sebagian besar disebabkan oleh lemahnya perencanaan dan pengendalian persediaan. Kondisi ini tidak hanya menimbulkan kerugian ekonomi, tetapi juga berdampak pada keberlanjutan lingkungan dan efisiensi operasional usaha.

Seiring berkembangnya teknologi, pendekatan berbasis data mulai banyak diterapkan untuk mengatasi permasalahan tersebut. Pemanfaatan machine learning dalam peramalan permintaan dinilai mampu meningkatkan akurasi estimasi kebutuhan bahan baku melalui analisis pola historis, tren, dan musiman penjualan secara otomatis. Olaniyi et al. (2024) menekankan bahwa penerapan predictive analytics dalam manajemen persediaan dapat membantu perusahaan menekan biaya operasional serta meningkatkan respons terhadap fluktuasi permintaan.

Dalam operasional kafe, bahan baku perishable seperti susu, sayuran, buah-buahan, daging, dan roti memiliki umur simpan yang relatif singkat sehingga berisiko tinggi mengalami pemborosan apabila pengelolaan persediaan tidak tepat. Ketidaktepatan dalam memperkirakan kebutuhan bahan baku harian dapat menyebabkan kelebihan stok yang berujung pada food waste. Oleh karena itu, diperlukan pendekatan berbasis data untuk memprediksi kebutuhan bahan baku

perishable secara lebih akurat. Penelitian ini memanfaatkan data historis penggunaan bahan baku di Matra Coffee selama periode Juli-Desember 2025 untuk membangun model prediksi kebutuhan bahan baku menggunakan pendekatan machine learning, sehingga diharapkan dapat membantu mengurangi potensi limbah makanan sekaligus meningkatkan efisiensi manajemen persediaan.

1.2. Rumusan Masalah

Berdasarkan latar belakang di atas, penelitian ini difokuskan pada beberapa permasalahan berikut:

1. Bagaimana membangun model prediksi kebutuhan bahan baku perishable harian di Matra Coffee menggunakan kombinasi algoritma Prophet dan XGBoost?
2. Bagaimana tingkat akurasi dan performa model prediksi Prophet dan XGBoost dalam memprediksi kebutuhan bahan baku perishable berdasarkan data historis penggunaannya?
3. Bagaimana hasil prediksi kebutuhan bahan baku tersebut dapat digunakan untuk mengestimasi potensi pengurangan food waste di Matra Coffee?

1.3. Batasan Masalah

Untuk menjaga fokus dan kejelasan penelitian, beberapa batasan masalah yang diterapkan:

1. Data yang digunakan adalah data historis penggunaan (bukan penjualan) bahan baku perishable di Matra Coffee selama periode Juli-Desember 2025.
2. Penelitian difokuskan pada bahan baku yang mudah rusak (perishable) seperti susu, sayuran, buah, daging, roti, dan bahan segar lainnya.

3. Penelitian tidak memprediksi jumlah penjualan menu, melainkan memprediksi kebutuhan bahan baku yang digunakan dalam proses operasional.
4. Model prediksi yang dikembangkan terbatas pada penggunaan kombinasi algoritma Prophet dan XGBoost.

1.4. Tujuan Penelitian

Berdasarkan rumusan masalah dan Batasan masalah yang telah di uraikan diatas, maka penelitian ini bertujuan untuk:

1. Membangun model prediksi kebutuhan bahan baku perishable harian di Matra Coffee menggunakan kombinasi algoritma Prophet dan XGBoost.
2. Mengukur tingkat akurasi dan mengevaluasi performa model prediksi Prophet dan XGBoost berdasarkan data historis penggunaan bahan baku.
3. Mengestimasi potensi pengurangan food waste di Matra Coffee berdasarkan pemanfaatan hasil prediksi kebutuhan bahan baku dari model yang dikembangkan.

1.5. Manfaat Penelitian

Adapun manfaat yang dapat diperoleh adalah sebagai berikut:

1. Manfaat bagi Universitas

Penelitian ini dapat menjadi kontribusi akademik dalam pengembangan ilmu, khususnya pada penerapan *machine learning* untuk peramalan kebutuhan bahan baku di sektor F&B, serta menambah referensi penelitian sejenis di lingkungan universitas.

2. Manfaat bagi Mitra (Matra Coffee)

Hasil penelitian dapat membantu Matra Coffee mengelola persediaan secara lebih terukur melalui prediksi yang lebih akurat, sehingga dapat mengurangi pemborosan bahan baku, menekan kerugian, dan meningkatkan efisiensi operasional.

3. Manfaat bagi Mahasiswa

Penelitian ini memberikan pengalaman penerapan langsung metode machine learning dalam kasus nyata, sehingga mahasiswa memperoleh kemampuan analitis, implementasi model prediksi, serta pemahaman mengenai optimasi stok di bidang F&B.

BAB II

LANDASAN TEORI

2.1. Manajemen Rantai Pasok dan Persediaan

Manajemen rantai pasok dan persediaan memegang peran penting dalam menjaga keberlangsungan operasional suatu bisnis, terutama pada sektor yang mengandalkan bahan baku mudah rusak seperti kedai kopi. Pengelolaan yang tepat tidak hanya memastikan ketersediaan bahan baku pada waktu yang dibutuhkan, tetapi juga membantu meminimalkan risiko kerusakan, pemborosan, dan ketidakefisienan biaya. Dalam konteks usaha kedai kopi, bahan baku seperti susu, biji kopi, dan sirup memiliki umur simpan terbatas sehingga memerlukan perencanaan persediaan yang lebih cermat. Oleh karena itu, pemahaman mengenai manajemen rantai pasok dan persediaan menjadi dasar penting sebelum membahas metode estimasi yang digunakan dalam penelitian ini.

2.1.1 Manajemen Rantai Pasok (*Supply Chain Management* – SCM)

Manajemen rantai pasok merupakan proses pengelolaan aliran barang, informasi, dan aktivitas dari pemasok hingga konsumen untuk memastikan kebutuhan operasional dapat terpenuhi secara efisien. Berdasarkan tinjauan literatur yang dipaparkan oleh Olaniyi et al. (2024), konsep SCM memiliki peran penting dalam menjaga kelancaran kegiatan bisnis dengan memastikan ketersediaan bahan baku dan mengurangi biaya yang timbul dari penyimpanan maupun pengelolaan persediaan. Beberapa penelitian yang mereka rangkum menunjukkan bahwa SCM yang efektif membantu perusahaan memenuhi permintaan pelanggan sambil menjaga stabilitas biaya operasional.

Dalam tinjauan tersebut, Olaniyi et al. juga menyoroti bahwa tantangan dalam rantai pasok semakin meningkat akibat faktor global seperti waktu tunggu yang panjang, regulasi yang beragam, hingga jaringan distribusi yang semakin kompleks. Kondisi ini menimbulkan ketidakpastian dalam proses peramalan sehingga berpotensi menyebabkan kelebihan atau kekurangan stok yang berdampak pada beban biaya dan hilangnya peluang penjualan. Selain itu, inefisiensi dalam aliran pasokan dapat memperlambat proses distribusi bahan baku dan mengganggu kelancaran operasi, terutama pada sektor bisnis yang sensitif terhadap perubahan permintaan.

Lebih lanjut, Olaniyi et al. menjelaskan bahwa SCM tidak hanya berfokus pada pengaturan aliran barang, tetapi juga mencakup kolaborasi antara perusahaan dan pemasok untuk meningkatkan transparansi dan responsivitas rantai pasok. Pendekatan seperti kemitraan rantai pasokan kolaboratif dinilai mampu meningkatkan visibilitas persediaan, mempercepat penyesuaian terhadap permintaan, serta membantu perusahaan merespons perubahan pasar secara lebih efektif. Strategi ini menjadi penting terutama bagi sektor yang membutuhkan konsistensi kualitas bahan baku dan akurasi perencanaan, termasuk industri makanan dan minuman.

2.1.2 Manajemen Persediaan (*Inventory Management*)

Manajemen persediaan merupakan kegiatan pengelolaan jumlah stok yang dimiliki perusahaan untuk memastikan proses produksi atau layanan dapat berjalan tanpa hambatan. Menurut Sulu and Waluyowati (2024), pengelolaan persediaan sangat penting karena kekurangan stok dapat mengakibatkan terhentinya kegiatan produksi, sedangkan kelebihan stok meningkatkan biaya penyimpanan serta risiko

kerusakan bahan baku. Tujuan utama manajemen persediaan adalah menjaga keseimbangan agar perusahaan dapat memenuhi kebutuhan operasional dengan tingkat biaya yang paling efisien.

Lebih lanjut, Sulu and Waluyowati (2024) menjelaskan bahwa perusahaan perlu mempertimbangkan komponen biaya seperti biaya pemesanan dan biaya penyimpanan untuk menentukan jumlah persediaan yang optimal. pengelolaan yang baik membantu perusahaan menghindari *stockout* yang mengganggu kelancaran produksi, serta mencegah *overstock* yang bisa menimbulkan pemborosan dan penurunan kualitas bahan baku.

Dalam literatur yang sama, persediaan dibedakan menjadi beberapa jenis, yaitu persediaan bahan baku, persediaan barang setengah jadi, persediaan barang jadi, dan persediaan bahan pembantu. setiap jenis memiliki karakteristik berbeda yang membutuhkan pendekatan pengelolaan yang sesuai agar proses produksi tetap stabil (Sulu and Waluyowati, 2024). Khusus untuk bahan baku, jumlah persediaan harus direncanakan dengan cermat agar produksi tidak terhenti dan biaya penyimpanan tetap terkendali.

Selain itu, Sulu and Waluyowati (2024) menambahkan bahwa metode perencanaan seperti *Economic Order Quantity* (EOQ) dapat membantu perusahaan menentukan jumlah pemesanan yang optimal, frekuensi pemesanan, *safety stock*, dan titik pemesanan ulang. Meskipun bersifat kuantitatif, prinsip EOQ menegaskan bahwa manajemen persediaan tidak hanya berkaitan dengan menjaga stok tersedia, tetapi juga mengatur kapan dan berapa banyak pesanan yang dilakukan agar perusahaan dapat meminimalkan biaya dan menghadapi ketidakpastian permintaan.

2.1.3 Bahan Baku yang Mudah Rusak (*Perishable Raw Materials*)

Bahan baku yang mudah rusak (*perishable raw materials*) adalah bahan yang memiliki umur simpan pendek, sensitif terhadap kondisi lingkungan, dan mengalami penurunan kualitas seiring waktu. Dalam konteks bisnis makanan dan minuman, bahan seperti biji kopi, susu, sirup, dan komponen *fresh* lainnya memiliki risiko kerusakan yang jauh lebih tinggi dibandingkan bahan baku *non-perishable*. Menurut Ahumada and Villalobos 2009, karakteristik *perishable* membuat bahan ini membutuhkan perencanaan dan pengendalian yang lebih ketat karena kualitasnya terus menurun sejak diterima hingga dikonsumsi.

Produk *perishable* memiliki tantangan yang berbeda karena rentan mengalami kerusakan (*spoilage*) selama penyimpanan dan distribusi. Kualitasnya dapat menurun dari hulu ke hilir, sehingga diperlukan pengelolaan yang lebih ketat dan sensitif terhadap kondisi lingkungan (Ahumada and Villalobos 2009; Mor et al. 2018). Tingkat kerusakan bahan *perishable* biasanya dipengaruhi beberapa faktor, seperti:

- a. Keterbatasan umur simpan. Bahan seperti susu dan sirup mudah terkontaminasi, sedangkan kopi dan buah bisa mengalami degradasi kualitas karena oksidasi atau fermentasi berlebih.
- b. Penyimpanan yang kurang optimal. Masalah suhu, pencahayaan, hingga kelembaban bisa mempercepat kerusakan (Kuurdve et al. 2015).
- c. Transportasi dan penanganan. Proses distribusi memberi risiko tinggi karena getaran, suhu tidak stabil, dan waktu tempuh yang panjang (Tirkolae and Aydin 2022).

- d. Fluktuasi permintaan. Permintaan produk *perishable* sering berubah-ubah, bikin manajemen stok makin sulit, dan kalau salah prediksi stok bisa numpuk atau malah habis.

Tantangan lain adalah persoalan transportasi dan *cold-chain logistics*, yang sangat menentukan masa simpan produk. Tirkolae and Aydin 2022 menjelaskan bahwa proses distribusi produk *perishable* menghadapi risiko besar seperti getaran, perpindahan suhu, hingga keterlambatan pengiriman, yang semuanya bisa mempercepat kerusakan produk. Semakin panjang rantai distribusinya, semakin tinggi ketidakpastian yang harus dihadapi perusahaan.

Untuk mengatasi tantangan tersebut, berbagai pendekatan pengendalian persediaan dikembangkan, mulai dari pengaturan *safety stock*, monitoring kondisi lingkungan, optimalisasi penyimpanan, hingga penerapan metode estimasi permintaan yang lebih adaptif terhadap ketidakpastian. Menurut Alfarisi and Ardiansyah (2025), strategi pengendalian bahan baku *perishable* harus mempertimbangkan aspek umur simpan, kecepatan rotasi produk, serta waktu pemesanan ulang agar tingkat kerusakan dapat ditekan dan efisiensi operasional tetap terjaga.

2.2. Food Waste dan Dampaknya

Food waste merupakan isu global yang semakin mendapat perhatian karena berdampak pada ekonomi, lingkungan, dan keberlanjutan sistem pangan. Dalam skala global, banyak bahan pangan yang diproduksi tidak pernah dikonsumsi, sehingga sumber daya seperti air, energi, dan tenaga kerja ikut terbuang. Limbah makanan yang tidak tertangani juga menyumbang emisi gas rumah kaca dan menambah tekanan terhadap lingkungan.

Di Indonesia, *food waste* menjadi perhatian khusus seiring berkembangnya industri makanan dan minuman. Sektor jasa makanan, termasuk restoran dan kedai kopi, berkontribusi cukup besar terhadap meningkatnya limbah makanan. Hal ini terjadi karena banyak bahan baku yang bersifat *perishable*, sehingga kesalahan dalam pengelolaan persediaan atau peramalan permintaan dapat menyebabkan bahan rusak sebelum digunakan.

Dalam operasional kedai kopi, *food waste* umumnya muncul akibat ketidaktepatan estimasi kebutuhan bahan baku seperti susu, sirup, buah, dan biji kopi. Fluktuasi permintaan harian membuat stok sulit dikendalikan; kelebihan stok berisiko terbuang, sedangkan kekurangan stok dapat mengganggu kualitas pelayanan.

Tingginya *food waste* pada bisnis ini menunjukkan perlunya pendekatan yang lebih akurat dalam pengelolaan persediaan. Penerapan metode peramalan yang tepat dapat membantu mengurangi pemborosan bahan, meningkatkan efisiensi biaya, serta mendukung praktik operasional yang lebih berkelanjutan. Bagian berikutnya membahas definisi *food waste* dan pembedanya dengan *food loss* sebagai dasar pemahaman teoritis.

2.2.1 Definisi Food Waste

Food loss dan *food waste* merupakan dua istilah yang saling berkaitan dalam pembahasan ketidakefisienan sistem pangan, dan keduanya banyak digunakan dalam studi rantai pasok serta keberlanjutan. *Food and Agriculture Organization* (FAO) sebagai lembaga resmi PBB yang menangani isu pangan global, menjadi rujukan utama dalam mendefinisikan kedua konsep ini.

Menurut FAO, *food loss* merujuk pada penurunan kuantitas maupun kualitas pangan yang terjadi pada tahap awal rantai pasok—mulai dari produksi, pascapanen, penyimpanan, hingga distribusi awal. Hal ini sejalan dengan penjelasan Nurhasanah, Budiono and Hermawan (2025), yang menyebut bahwa *food loss* umumnya dipicu faktor teknis seperti keterbatasan teknologi penyimpanan, kerusakan pascapanen, atau proses distribusi yang kurang memadai. Pada tahap ini, kehilangan pangan biasanya bersifat tidak disengaja dan terkait keterbatasan sistem produksi atau logistik.

Di sisi lain, *food waste* adalah makanan layak konsumsi yang terbuang pada tahap ritel, layanan makanan, atau tingkat konsumen. Todd and Faour-Klingbeil (2024) menjelaskan bahwa *food waste* sebagian besar berkaitan dengan keputusan manusia, termasuk kesalahan perencanaan, penyimpanan yang tidak sesuai standar, porsi berlebih, hingga kesalahan estimasi permintaan. Berbeda dari *food loss* yang terjadi karena keterbatasan teknis, *food waste* lebih sering terkait aspek manajerial dan perilaku, sehingga dapat diminimalkan melalui strategi operasional yang tepat.

Perbedaan tersebut penting karena menunjukkan bahwa *food loss* dan *food waste* tidak hanya terjadi di tahap yang berbeda dalam rantai pasok, tetapi juga memiliki penyebab, karakteristik, dan solusi pengelolaan yang berbeda. Dalam konteks penelitian ini, isu yang muncul pada kedai kopi lebih banyak terkait *food waste*, karena kerusakan bahan baku terjadi setelah bahan diterima dan disimpan di tingkat operasional, bukan pada proses produksi di hulu. Bahan *perishable* seperti susu, sirup, buah, dan biji kopi rentan mengalami penurunan kualitas apabila terjadi *overstock*, kesalahan estimasi permintaan, atau penyimpanan yang tidak tepat. Oleh karena itu, fokus penelitian diarahkan pada *food waste* di level ritel untuk

memahami bagaimana pengelolaan persediaan dapat mempengaruhi tingkat limbah pangan.

2.2.2 Penyebab Food Waste di Bisnis Makanan/Minuman

Food waste pada bisnis makanan dan minuman umumnya muncul karena kombinasi faktor operasional, perilaku, dan ketidakpastian permintaan. Bisnis seperti kedai kopi sangat rentan mengalami limbah pangan karena sebagian besar bahan bakunya bersifat *perishable* dan memiliki umur simpan yang relatif pendek. Kondisi ini menyebabkan kesalahan kecil dalam perencanaan atau penyimpanan dapat berujung pada kerusakan bahan dan pemborosan.

Salah satu penyebab utama *food waste* adalah ketidaktepatan estimasi permintaan, di mana jumlah bahan baku yang dipersiapkan tidak sesuai dengan jumlah produk yang benar-benar terjual. Menurut Rahal (2024), fluktuasi permintaan harian yang sulit diprediksi sering menyebabkan bisnis menyediakan stok berlebih untuk menghindari kekurangan bahan. Namun strategi ini justru meningkatkan risiko kerusakan apabila permintaan ternyata lebih rendah dari perkiraan.

Selain itu, pengelolaan persediaan yang kurang optimal turut mempengaruhi tingkat *food waste*. Todd and Faour-Klingbeil (2024) menjelaskan bahwa penyimpanan yang tidak memenuhi standar—misalnya temperatur yang tidak stabil, kelembaban yang tidak sesuai, atau penataan bahan yang tidak tepat—dapat mempercepat penurunan kualitas bahan *perishable*. Bahan seperti susu, sirup, dan buah segar sangat sensitif terhadap kondisi penyimpanan dan mudah rusak bila tidak ditangani dengan benar.

Faktor berikutnya adalah kesalahan operasional, seperti kesalahan pencatatan stok, rotasi bahan yang tidak sesuai prinsip *first-in-first-out* (FIFO), serta porsi berlebih saat produksi. Nurhasanah, Budiono and Hermawan (2025) menekankan bahwa aspek manajerial dan perilaku karyawan ikut memengaruhi tingkat limbah pangan, terutama di sektor *foodservice* yang mengandalkan proses cepat dan penggunaan bahan yang beragam.

Terakhir, keterbatasan umur simpan bahan perishable membuat bisnis harus mengambil keputusan cepat terkait penggunaan dan penarikan bahan. Dalam situasi sibuk, beberapa bahan sering terabaikan hingga melewati masa layak konsumsi. Kondisi ini makin diperparah jika tidak ada sistem pemantauan stok yang *real-time*, sehingga bahan yang mendekati kadaluarsa tidak segera diketahui.

Secara keseluruhan, penyebab *food waste* dalam bisnis makanan dan minuman bersifat kompleks dan saling berkaitan. Ketidakakuratan prediksi permintaan, pengelolaan penyimpanan yang kurang baik, kesalahan operasional, serta karakteristik bahan baku *perishable* semuanya berkontribusi terhadap meningkatnya limbah pangan. Pemahaman terhadap faktor-faktor ini menjadi dasar penting bagi penerapan metode estimasi dan prediksi persediaan yang lebih efektif pada penelitian ini.

2.2.3 Dampak Food Waste

Food waste memberikan dampak yang signifikan terhadap berbagai aspek ekonomi, lingkungan, dan sosial, sehingga menjadi perhatian penting dalam pengelolaan operasional bisnis makanan dan minuman. Bagi pelaku usaha, limbah makanan bukan hanya menggambarkan bahan yang tidak termanfaatkan, tetapi juga menunjukkan adanya ketidakefisienan dalam pengelolaan persediaan, perencanaan

permintaan, dan proses produksi. Dalam konteks yang lebih luas, berbagai penelitian menunjukkan bahwa *food waste* memiliki implikasi yang lebih kompleks dibandingkan sekadar pemborosan bahan baku (Papargyropoulou *et al.*, 2019).

Dari sisi ekonomi, *food waste* meningkatkan biaya operasional karena bahan baku yang terbuang tetap tercatat sebagai pengeluaran. Todd and Faour-Klingbeil (2024) menegaskan bahwa pemborosan pada sektor ritel dan *foodservice* berdampak langsung pada penurunan margin keuntungan, terutama ketika bahan yang terbuang termasuk kategori *perishable* dengan biaya pembelian yang relatif tinggi. Penelitian lain juga menunjukkan bahwa *foodservice* dapat kehilangan hingga 23% dari nilai makanan yang dibeli akibat limbah yang seharusnya bisa dihindari (Papargyropoulou *et al.*, 2019). Untuk kedai kopi yang sangat bergantung pada bahan seperti susu, buah, dan sirup, pembuangan bahan akibat spoilage dapat mengganggu efisiensi biaya dan menurunkan profitabilitas jangka panjang.

Dalam aspek lingkungan, *food waste* memberikan kontribusi besar pada beban ekologis karena setiap makanan yang terbuang mencerminkan penggunaan sumber daya alam yang sia-sia. Produksi makanan yang akhirnya tidak dikonsumsi tetap membutuhkan air, energi, lahan, dan logistik dalam prosesnya. Selain itu, limbah makanan yang berakhir di tempat pembuangan menghasilkan gas metana—gas rumah kaca dengan dampak pemanasan global yang lebih tinggi daripada karbon dioksida (Rahal, 2024).

Dari sisi sosial, *food waste* memperdalam ketimpangan distribusi pangan. Nurhasanah, Budiono and Hermawan (2025) menyebutkan bahwa peningkatan limbah makanan sering terjadi pada saat sebagian masyarakat masih kesulitan mendapatkan akses pangan yang layak. situasi ini memperlihatkan adanya

ketidakseimbangan antara produksi, distribusi, dan konsumsi, serta perlunya tanggung jawab lebih besar dari sektor *foodservice* dalam mengelola pangan secara lebih bijak. Di sisi lain, bisnis yang gagal mengendalikan *food waste* berpotensi dinilai kurang peduli terhadap isu keberlanjutan, sehingga dapat memengaruhi citra mereka di mata konsumen.

Secara keseluruhan, *food waste* memiliki dampak yang multidimensional: kerugian ekonomi, beban lingkungan yang meningkat, dan konsekuensi sosial yang luas. Pemahaman terhadap dampak-dampak tersebut sangat penting sebagai dasar pengambilan keputusan dalam pengelolaan persediaan. Dalam konteks penelitian ini, pengurangan *food waste* melalui estimasi kebutuhan bahan baku yang lebih akurat menjadi langkah strategis untuk meningkatkan efisiensi operasional sekaligus mendukung praktik keberlanjutan di kedai kopi.

2.2.4 Food Waste pada Industri Coffee Shop

Coffee shop memiliki karakteristik unik yang membuatnya sangat rentan terhadap *food waste*. Sebagian besar bahan baku yang digunakan bersifat *perishable* dan memiliki umur simpan pendek, seperti susu, buah, sirup, *whipped cream*, dan berbagai produk olahan. Karakteristik ini membuat *coffee shop* membutuhkan perencanaan persediaan yang lebih presisi dibandingkan bisnis lain.

Penelitian di sektor *foodservice* menemukan bahwa *preparation waste*—bahan yang rusak sebelum sempat disajikan—merupakan salah satu sumber limbah terbesar, terutama pada bisnis yang bergantung pada bahan segar (Papargyropoulou *et al.*, 2019). Hal ini relevan pada *coffee shop* yang menyiapkan bahan tertentu dalam jumlah tertentu, seperti *cold brew*, sirup *homemade*, atau *topping* berbasis *dairy* yang tidak tahan lama.

Fluktuasi permintaan harian yang tidak stabil juga menjadi faktor penting. Rahal (2024) menjelaskan bahwa *over-stocking* sebagai strategi antisipasi justru menjadi penyebab utama meningkatnya *food waste* ketika permintaan aktual lebih rendah. Hal ini sering terjadi pada *coffee shop* saat perbedaan antara *weekday* dan *weekend* sangat signifikan.

Selain itu, penyimpanan bahan *perishable* di *coffee shop* sangat sensitif. Todd and Faour-Klingbeil (2024) menyebut bahwa suhu yang tidak stabil dalam lemari pendingin, penanganan bahan yang tidak tepat, serta kesalahan rotasi stok mempercepat kerusakan bahan.

Gabungan faktor-faktor ini menunjukkan bahwa industri *coffee shop* membutuhkan sistem pengelolaan persediaan yang lebih akurat dan responsif. Penggunaan metode peramalan seperti Prophet dan XGBoost dapat membantu memperkirakan permintaan dengan lebih baik, sehingga mampu menekan *food waste* sekaligus meningkatkan efisiensi operasional.

2.3. Peramalan (Forecasting) dan Machine Learning

Peramalan (*forecasting*) merupakan proses sistematis untuk memperkirakan nilai suatu variabel di masa mendatang berdasarkan pola historis, baik melalui pendekatan statistik maupun model matematis. Konsep ini banyak digunakan dalam berbagai bidang seperti pemasaran, keuangan, hingga manajemen rantai pasok karena mampu memberikan dasar kuantitatif bagi pengambilan keputusan. Seiring meningkatnya kompleksitas pola data, metode peramalan tidak hanya mengandalkan teknik tradisional, tetapi juga memanfaatkan pendekatan komputasional berbasis kecerdasan artifisial.

Machine learning (ML) merupakan cabang kecerdasan buatan yang memungkinkan sistem komputer mempelajari pola dari data secara otomatis dan menghasilkan prediksi tanpa harus diprogram secara eksplisit. Pendekatan ini digunakan untuk mengatasi permasalahan prediksi yang bersifat non-linier, memiliki banyak variabel, atau mengalami perubahan dinamika secara berkala. Dalam konteks peramalan, ML menawarkan alternatif metode yang lebih adaptif dibandingkan teknik statistik konvensional karena mampu mengidentifikasi pola kompleks yang sulit ditangkap oleh model linear.

Kombinasi antara peramalan dan *machine learning* menjadikan analisis prediktif semakin relevan dalam kegiatan operasional *modern*, termasuk untuk pengambilan keputusan terkait permintaan dan pengelolaan persediaan. dengan demikian, pembahasan berikut akan menguraikan konsep dasar *forecasting* serta penerapan pendekatan machine learning dalam aktivitas peramalan.

2.3.1 Konsep Dasar Peramalan (Forecasting)

Dalam manajemen operasional dan rantai pasok, peramalan (*forecasting*) didefinisikan sebagai proses sistematis untuk membuat estimasi mengenai kejadian masa depan berdasarkan pola historis dan informasi terkini (Kozak et al., 2021; Seyedan & Mafakheri, 2020). Pada bisnis ritel makanan dan minuman seperti Matra Coffee, peramalan memiliki dua fokus utama: peramalan permintaan untuk memprediksi jumlah produk yang akan terjual, dan peramalan persediaan untuk menentukan level stok ideal sesuai prediksi permintaan tersebut (Douaioui *et al.*, 2024).

Pendapat Kmiecik dan Zangana (2022) dalam Muth, Lingenfelder and Nufer (2025) membedakan antara istilah “prediksi” dan “peramalan”. Mereka

menegaskan bahwa peramalan merupakan jenis prediksi yang khusus menggunakan data deret waktu (time series) dan memperhitungkan dimensi temporal. Artinya, setiap ramalan tidak hanya memperkirakan apa yang akan terjadi, tetapi juga kapan kejadian tersebut terjadi. Konsep ini relevan untuk bisnis kopi yang memiliki pola permintaan harian, mingguan, dan musiman. Model peramalan tradisional yang banyak digunakan meliputi:

- a. Moving Average,
- b. Exponential Smoothing, dan
- c. ARIMA (Abolghasemi et al., 2020; Ma & Fildes, 2020).

ARIMA sering dijadikan benchmark akademis karena kemampuannya menangkap pola linier dalam deret waktu. Namun, literatur menunjukkan bahwa model univariat seperti ARIMA cenderung kurang efektif ketika data permintaan bersifat sangat fluktuatif, mengandung banyak *noise*, atau dipengaruhi faktor eksternal yang beragam (Abolghasemi et al., 2020). Dalam kondisi tersebut, model statistik konvensional sering gagal karena mengandalkan asumsi struktural yang kaku dan tidak mampu mengakomodasi hubungan non-linier dalam data.

Keterbatasan inilah yang mendorong perkembangan metode peramalan berbasis Machine Learning yang lebih fleksibel, mampu menangkap pola kompleks, dan dapat memanfaatkan banyak variabel sekaligus.

2.3.2 Machine Learning untuk Peramalan

Machine Learning (ML) merupakan bagian dari kecerdasan buatan yang memungkinkan komputer mempelajari pola dari data tanpa instruksi eksplisit untuk setiap kasus (Mitchell, 1997 dalam Muth, Lingenfelder and Nufer (2025)). Pendekatan ML cenderung berbasis observasi (*observation-driven*) dan

berorientasi pada performa prediktif, berbeda dengan model ekonometrik tradisional yang sangat bergantung pada teori dan asumsi struktural (Ghoddusi et al., 2019).

Keunggulan ML dalam konteks peramalan permintaan dapat dijelaskan dari beberapa aspek berikut:

a. Menangkap Pola Non-Linier dan Dinamika Temporal Kompleks

Algoritma ML—terutama dari keluarga *deep learning* seperti LSTM—dirancang untuk memodelkan ketergantungan jangka panjang dan hubungan non-linear dalam data deret waktu (Liu et al., 2021; Tudor, 2022). Wahid and Witanti (2025) menunjukkan bahwa LSTM berhasil memprediksi kebutuhan 36 bahan baku restoran dengan menggabungkan pola musiman, variasi harian, dan faktor hari libur.

b. Kemampuan Memproses Banyak Variabel Sekaligus (Multivariate Forecasting)

Berbeda dengan model tradisional, ML dapat mengintegrasikan variabel eksternal seperti cuaca, kalender, promosi, tipikal hari (*weekday/weekend*), dan tren musiman jangka panjang. Abolghasemi et al. (2020) serta Punia dan Shankar (2022) menemukan bahwa model multivariat menghasilkan akurasi prediksi yang jauh lebih tinggi. Dalam studi Wahid and Witanti (2025), lebih dari 100 fitur berhasil dibangun untuk meningkatkan ketepatan ramalan.

c. Dampak Operasional Nyata terhadap Pengurangan Food Waste

Penelitian Rodrigues et al. (2023) menunjukkan bahwa penerapan model ML pada layanan katering mampu mengurangi *food waste* hingga 52%, dan mengurangi *stockout* hingga 16% dibandingkan metode konvensional. Temuan

ini menguatkan bahwa prediksi permintaan yang akurat berdampak langsung pada efisiensi bahan baku, terutama yang bersifat *perishable*.

Sebagian besar peramalan berbasis ML berada dalam kerangka *supervised learning*, di mana model dilatih menggunakan pasangan data input (x) dan target (y) yang diketahui (Goodfellow et al., 2016). Dalam konteks Matra Coffee, target prediksi berupa jumlah kebutuhan bahan baku setiap hari, sementara fitur input dapat mencakup tanggal, hari dalam minggu, data penjualan periode sebelumnya, informasi promosi, serta faktor eksternal lainnya. Model regresi menjadi pendekatan utama karena nilai yang diprediksi berbentuk numerik kontinu.

Dengan demikian, ML tidak hanya menyediakan alternatif bagi metode tradisional tetapi juga memperluas kapasitas analisis, memungkinkan perusahaan memahami perilaku permintaan secara lebih komprehensif dan akurat.

2.3.3 Relevansi Model Machine Learning bagi Matra Coffee

Pemilihan algoritma dalam penelitian ini disesuaikan dengan karakteristik pola permintaan di Matra Coffee yang dipengaruhi oleh variasi harian, mingguan, serta faktor musiman seperti cuaca dan hari libur. Karena bahan baku bersifat *perishable*, ketepatan prediksi menjadi krusial untuk mencegah *food waste* dan menjaga kelancaran pelayanan. Untuk itu, penelitian ini menggunakan dua algoritma yang saling melengkapi, yaitu Prophet dan XGBoost.

Prophet dipilih karena kemampuannya memodelkan data deret waktu yang memiliki pola musiman dan perubahan tren. Melalui struktur komponennya yang memisahkan tren, musiman, dan efek hari libur, Prophet sesuai untuk menggambarkan pola penjualan minuman di Matra Coffee yang berubah mengikuti hari dan kondisi tertentu.

Sementara itu, XGBoost digunakan untuk menangkap hubungan non-linear dan interaksi antar berbagai variabel prediktor yang tidak dapat ditangani oleh model univariat. Algoritma ini efektif ketika permintaan dipengaruhi banyak faktor sekaligus—misalnya cuaca, promosi, atau intensitas kunjungan pada periode tertentu.

Penggabungan kedua model ini memberikan keseimbangan antara keterjelasan pola musiman yang ditawarkan Prophet dan akurasi prediktif tinggi yang dihasilkan XGBoost. Dengan pendekatan ini, sistem peramalan diharapkan mampu memberikan estimasi kebutuhan bahan baku yang lebih akurat sehingga Matra Coffee dapat mengurangi risiko *overstock* maupun kekurangan persediaan.

Berbeda dengan sebagian besar penelitian yang berfokus pada peramalan penjualan produk, penelitian ini memodelkan kebutuhan bahan baku perishable secara langsung sebagai variabel yang diprediksi. Pendekatan ini dinilai lebih relevan terhadap permasalahan food waste karena bahan baku yang mudah rusak memiliki risiko pemborosan yang tinggi apabila jumlah persediaannya tidak sesuai dengan kebutuhan aktual. Dengan demikian, penerapan machine learning dalam penelitian ini tidak hanya bertujuan meningkatkan akurasi peramalan, tetapi juga mendukung pengambilan keputusan pengadaan bahan baku secara lebih efisien.

2.4. Metode Machine Learning yang Digunakan

Penelitian ini menggunakan dua pendekatan utama dalam pemodelan deret waktu, yaitu Prophet dan XGBoost. Kedua model ini merepresentasikan dua paradigma berbeda: Prophet berbasis pendekatan *decomposable time series*, sedangkan XGBoost berbasis *gradient boosting* yang berfokus pada pemodelan hubungan non-linier. Kombinasi keduanya memungkinkan peramalan yang lebih

komprehensif dengan memanfaatkan keunggulan masing-masing model. Subbab ini menguraikan konsep dasar, komponen utama, serta justifikasi metodologis pemilihan kedua model tersebut.

2.4.1 Model Peramalan Time Series Prophet

Prophet merupakan model peramalan deret waktu yang dikembangkan oleh Meta untuk mengakomodasi data dengan pola tren jangka panjang, musiman, serta variasi yang dipengaruhi hari tertentu. Model ini berasumsi bahwa deret waktu dapat direpresentasikan melalui fungsi aditif berikut:

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t \quad (1)$$

di mana $g(t)$ menggambarkan tren, $s(t)$ merepresentasikan komponen musiman, $h(t)$ merupakan pengaruh hari libur atau kejadian khusus, dan ε_t adalah komponen error acak. Pendekatan ini memungkinkan pemisahan struktur deret waktu menjadi unsur-unsur yang bersifat interpretatif dan mudah dianalisis.

Prophet memodelkan komponen tren menggunakan pendekatan *piecewise linear* yang memungkinkan perubahan arah atau tingkat pertumbuhan pada titik-titik tertentu (*change points*). Formulasinya dituliskan sebagai:

$$g(t) = (k + a(t)^T \delta)t + (b + a(t)^T \gamma) \quad (2)$$

Pendekatan tersebut memberikan fleksibilitas ketika terjadi perubahan pola permintaan—misalnya kenaikan tajam pada periode tertentu yang tidak dapat ditangkap oleh model statistik tradisional (Zeng *et al.*, 2025).

Selain tren, Prophet menangkap pola musiman melalui representasi *Fourier* sebagai berikut:

$$s(t) = \sum_{n=1}^N \left(a_n \cos\left(\frac{2\pi nt}{P}\right) + b_n \sin\left(\frac{2\pi nt}{P}\right) \right) \quad (3)$$

Pendekatan ini memungkinkan pemodelan pola berulang harian, mingguan, maupun tahunan secara fleksibel dan efisien. Komponen hari khusus (*holiday effect*) dimodelkan melalui bentuk:

$$h(t) = Z(t)\kappa \quad (4)$$

yang memungkinkan Prophet menangkap anomali pada tanggal-tanggal tertentu. Keberadaan komponen ini terbukti meningkatkan akurasi peramalan pada domain bisnis maupun energi (Zeng *et al.*, 2025).

Hasil evaluasi pada penelitian Ripatti (2024) menunjukkan bahwa Prophet memiliki performa kuat pada data dengan pola musiman dan tren stabil, walaupun cenderung kurang optimal pada deret waktu yang dipengaruhi variabel eksternal non-musiman. Namun, kemampuan *decomposable*-nya menjadikan Prophet model baseline yang efektif untuk skenario yang memerlukan analisis komponen deret waktu yang eksplisit.

Dalam konteks penelitian ini, Prophet digunakan untuk membangun pondasi awal peramalan berdasarkan pola musiman dan tren historis yang dominan pada data penjualan harian.

2.4.2 XGBoost (Extreme Gradient Boosting)

XGBoost merupakan algoritma pembelajaran mesin yang dikembangkan sebagai pengembangan dari *Gradient Boosting Decision Trees* (GBDT). Model ini bekerja dengan membangun pohon keputusan secara bertahap, di mana setiap pohon baru fokus mempelajari kesalahan (residual) dari model sebelumnya. Proses boosting ini dapat digambarkan sebagai:

$$\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + f_i(x_i) \quad (5)$$

Pendekatan iteratif tersebut menjadikan XGBoost sangat kuat dalam mempelajari hubungan non-linier yang kompleks. Fungsi objektif XGBoost secara umum dituliskan sebagai:

$$\mathcal{L} = \sum_{i=1}^n l(y_i \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (6)$$

dengan regularisasi:

$$\mathcal{U}(f_k) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (7)$$

Regularisasi tersebut membantu mengontrol kompleksitas pohon sehingga mengurangi risiko *overfitting*. Studi pada bidang *forecasting* jangka pendek menunjukkan bahwa XGBoost memiliki akurasi yang stabil meskipun data bersifat fluktuatif atau dipengaruhi banyak fitur non-linear (Song *et al.*, 2025).

Dalam domain energi dan permintaan listrik, XGBoost terbukti efektif dalam menangani dataset berskala besar dan heterogen. (Zeng *et al.*, 2025) menunjukkan bahwa penggabungan Prophet dan XGBoost dalam struktur *hybrid* mampu meningkatkan akurasi secara signifikan dibandingkan penggunaan salah satu model saja.

Selain sebagai model utama, XGBoost juga sering berperan sebagai *meta-learner* dalam skema *stacking*, yaitu menggabungkan beberapa model dasar untuk mengurangi bias dan variansi. Studi Curiël, Alshag and Mohammadi Ziabari (2025) menunjukkan bahwa XGBoost sebagai model penyatu (*stacker*) mampu meningkatkan performa pada hybrid Prophet–LSTM dan Prophet–QLSTM dalam peramalan energi jangka panjang.

Dengan kemampuannya menangkap interaksi fitur yang kompleks, XGBoost dipilih dalam penelitian ini sebagai model komparatif dan pendukung dalam proses peramalan data penjualan.

2.4.3 Alasan Pemilihan Prophet dan XGBoost

Pemilihan Prophet dan XGBoost dalam penelitian ini didasarkan pada pendekatan metodologis yang saling melengkapi. Prophet unggul dalam menangkap pola musiman serta perubahan tren secara interpretatif, sedangkan XGBoost unggul dalam mempelajari hubungan non-linier pada data yang lebih kompleks. Bukti empiris dari berbagai penelitian (Zeng *et al.*, 2025; Curiël, Alshag and Mohammadi Ziabari (2025)) menunjukkan bahwa kombinasi model dekomposisi dengan model berbasis boosting dapat menghasilkan peningkatan akurasi signifikan pada berbagai jenis deret waktu, terutama pada data operasional dan energi.

Dalam konteks penelitian ini, kedua algoritma tersebut digunakan untuk memprediksi kebutuhan bahan baku perishable yang memiliki pola fluktuatif dan dipengaruhi faktor musiman, seperti perbedaan antara hari kerja dan akhir pekan. Dengan memodelkan kebutuhan bahan baku secara langsung, kombinasi Prophet dan XGBoost diharapkan mampu menangkap pola tren jangka panjang sekaligus variasi non-linear yang sering terjadi pada penggunaan bahan baku di bisnis food and beverage.

2.4.4 Alur Algoritma Model Hybrid Prophet-XGBoost

Model hybrid yang digunakan dalam penelitian ini menggabungkan kemampuan Prophet dalam menangkap pola tren dan musiman dengan kemampuan

XGBoost dalam mempelajari pola non-linear dari residu prediksi. Secara konseptual, alur algoritma model hybrid disusun dalam tahapan berikut:

1. Input Data Time Series

Data historis penggunaan bahan baku perishable harian dimasukkan sebagai deret waktu.

a. Pelatihan Model Prophet

Model Prophet dilatih untuk memodelkan:

- a. Tren jangka panjang penggunaan bahan baku
- b. Pola musiman (mingguan)
- c. Pengaruh hari libur nasional
- d. Perhitungan Residu Prophet

Selisih antara nilai aktual dan prediksi Prophet dihitung sebagai:

$$Residual_t = Y_{aktual,t} - \hat{Y}_{Prophet,t} \quad (9)$$

2. Penyusunan Fitur Tambahan untuk XGBoost

Residu digunakan sebagai target baru dengan fitur:

- Lag-1 (penggunaan H-1)
- Lag-7 (penggunaan H-7)
- Indikator weekend
- Indikator hari libur nasional

3. Pelatihan Model XGBoost

XGBoost mempelajari pola non-linear pada residu Prophet untuk menangkap variasi yang tidak dapat dijelaskan oleh model deret waktu linear.

4. Prediksi Residu

Model XGBoost menghasilkan prediksi nilai residu untuk periode uji.

5. Penggabungan Prediksi Hybrid

Prediksi akhir dihitung dengan menjumlahkan:

$$Y_{final} = \hat{Y}_{Prophet} + \hat{Y}_{XGBoost} \quad (10)$$

6. Output Prediksi

Hasil akhir berupa estimasi kebutuhan bahan baku perishable harian.

2.5. Metrik Evaluasi Model

Penilaian akurasi model peramalan memerlukan penggunaan metrik evaluasi yang mampu menggambarkan sejauh mana prediksi mendekati nilai aktual. Dalam penelitian ini digunakan tiga metrik yang umum pada studi peramalan deret waktu, yaitu *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE) / *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). Ketiga metrik tersebut dipilih karena telah digunakan secara luas dalam berbagai penelitian yang menggunakan Prophet, XGBoost, maupun model *hybrid* pada studi forecasting modern, termasuk pada penelitian-penelitian yang dianalisis dalam tinjauan pustaka ini.

2.5.1 Mean Absolute Error (MAE)

Mean Absolute Error (MAE) mengukur rata-rata kesalahan absolut antara nilai aktual dan nilai prediksi. Rumus MAE dituliskan sebagai berikut:

$$MAE = \frac{1}{n} \sum_{j=1}^n |y_i - \hat{y}_i| \quad (11)$$

MAE memberikan interpretasi yang langsung dan mudah dipahami karena menunjukkan rata-rata besar kesalahan dalam satuan yang sama dengan variabel target. Metrik ini tidak memberikan penalti berlebih pada kesalahan besar sehingga bersifat lebih stabil terhadap keberadaan *outlier*. Ripatti (2024), dalam studinya

yang membandingkan Prophet, XGBoost, LSTM, dan model klasik lainnya, menggunakan MAE sebagai salah satu indikator utama untuk mengukur performa model dan menilai stabilitas error absolut antarmodel.

2.5.2 Mean Squared Error (MSE) dan Root Mean Squared Error (RMSE)

MSE menghitung rata-rata kuadrat kesalahan prediksi, dengan formulasi:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (12)$$

Karena kesalahan dikuadratkan, MSE sangat sensitif terhadap error besar. Untuk mengembalikan nilai evaluasi ke skala yang sama dengan variabel target, digunakan *Root Mean Squared Error* (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (13)$$

RMSE menjadi salah satu metrik evaluasi paling populer pada model peramalan modern karena memberikan penalti terhadap kesalahan besar namun tetap mudah diinterpretasikan. Dalam studi Prophet-BO-XGBoost, Zeng *et al.*, (2025) menggunakan RMSE untuk membandingkan performa model *hybrid* mereka dan menunjukkan bahwa RMSE efektif menyoroti variasi kesalahan yang berpengaruh signifikan terhadap kualitas prediksi.

Selain itu, penelitian dalam domain *machine learning* berbasis XGBoost untuk forecasting jangka pendek Song *et al.* (2025) juga menjadikan RMSE sebagai metrik utama untuk mengevaluasi tingkat akurasi model mereka pada data deret waktu dengan pola fluktuasi tinggi.

2.5.3 Mean Absolute Percentage Error (MAPE)

MAPE menyatakan besar kesalahan prediksi dalam bentuk persentase terhadap nilai aktual, sehingga memberikan interpretasi yang mudah dipahami dalam konteks perbandingan proporsional. Rumus MAPE dituliskan sebagai berikut:

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (14)$$

MAPE banyak digunakan dalam penelitian bisnis, retail, dan energi karena menyajikan kesalahan dalam bentuk persentase yang intuitif bagi pengguna non-teknis. Dalam studi Prophet, XGBoost, dan model lainnya, Ripatti (2024) menggunakan MAPE sebagai indikator kinerja yang menilai akurasi relatif model ketika membandingkan beberapa algoritma *forecasting*.

Studi lain yang menggunakan model hybrid Prophet-(Q)LSTM oleh Curiël, Alsahag and Mohammadi Ziabari (2025) juga mengadopsi MAPE untuk mengevaluasi performa jangka panjang dan jangka pendek, terutama karena metrik ini memudahkan perbandingan lintas horizon peramalan.

2.6. Ringkasan Penelitian Terdahulu

Berdasarkan tinjauan literatur yang telah dilakukan, dipilih lima penelitian terdahulu yang memiliki relevansi paling erat dengan topik penelitian ini. Pemilihan didasarkan pada keterkaitan aspek metode (Machine Learning, Prophet, XGBoost) dan objek masalah (Food Waste, Manajemen Persediaan).

Tabel 2.1 berikut menyajikan ringkasan penelitian tersebut beserta analisis kelebihan dan kekurangannya untuk memetakan posisi penelitian ini (state of the art).

Tabel 2.1 Ringkasan Penelitian Terdahulu

No	Judul dan Peneliti	Pembahasan	Metode	Kekurangan dan Kelebihan
1	Short-Term Load Forecasting in Power Systems Based on the Prophet-BO-XGBoost Model (Zeng et al., 2025)	Penelitian ini membangun kerangka kerja peramalan hybrid yang menggabungkan Prophet (untuk tren deret waktu) dan XGBoost (untuk hubungan non-linier) guna meningkatkan akurasi prediksi beban listrik yang fluktuatif.	Hybrid Prophet - Bayesian Optimization - XGBoost	Kelebihan: Akurasi tinggi; mampu mempelajari pola kompleks; Cocok untuk data volatilitas tinggi. Kekurangan: Implementasi relatif kompleks; Tuning parameter lebih banyak
2	Optimising Inventory Management Strategies for Cost Reduction in Supply Chains: A Systematic Review (Olaniyi et al., 2024)	Menginvestigasi strategi manajemen inventaris global dan lokal untuk mengurangi biaya. Menemukan bahwa analitik canggih (advanced analytics) dan pemodelan prediktif adalah kunci efisiensi rantai pasok modern.	Systematic Literature Review (SLR)	Kelebihan: Menegaskan secara teori bahwa metode stok tradisional tidak lagi cukup tanpa bantuan pemodelan prediktif. Kekurangan: Hanya berupa kajian pustaka, tidak ada penerapan teknis algoritma pada data riil.
3	A Machine Learning-Based Approach for Retail Demand Forecasting (Adriani et al., 2025)	Membandingkan algoritma Random Forest, Decision Tree, dan SVM untuk memprediksi permintaan ritel dengan fitur tambahan Spending Score. Menemukan bahwa Random Forest memiliki performa terbaik.	Random Forest, Decision Tree, SVM	Kelebihan: Studi kasus di sektor ritel yang karakteristik transaksinya mirip dengan kedai kopi. Kekurangan: Belum menggunakan algoritma khusus time-series (seperti Prophet) untuk menangkap tren musiman secara spesifik.
4	Impact of Food Waste on Society, Specifically at Retail and	Menganalisis penyebab food waste di sektor ritel dan layanan makanan (foodservice).	Kualitatif / Tinjauan Literatur	Kelebihan: Validasi kuat bahwa kesalahan manajemen stok adalah penyebab

	Foodservice Levels (Todd & Faour-Klingbeil, 2024)	Mengidentifikasi bahwa kesalahan peramalan permintaan dan manajemen stok adalah penyebab utama limbah makanan yang masih layak konsumsi.		utama food waste di restoran/kafe. Kekurangan: Fokus pada analisis masalah dan penyebab, bukan pengembangan solusi teknis/aplikasi peramalan.
5	Pengendalian Persediaan Bahan Baku Menggunakan Metode Economic Order Quantity (Sulu & Waluyowati, 2024)	Menerapkan metode tradisional EOQ pada usaha kuliner (Kebab) untuk efisiensi biaya. Hasil menunjukkan penghematan biaya dibandingkan metode manual/praktis.	Economic Order Quantity (EOQ)	Kelebihan: Memberikan gambaran metode pengendalian stok yang umum digunakan UMKM saat ini. Kekurangan: Metode statis yang mengasumsikan permintaan konstan, sehingga kurang akurat untuk data fluktuatif.

Berdasarkan rangkuman penelitian terdahulu pada Tabel 2.1, terlihat bahwa pendekatan *Machine Learning* seperti XGBoost dan Random Forest (Adriani, Huizen and Hermawan (2025); Zeng *et al.* (2025)) telah terbukti efektif dalam meningkatkan akurasi peramalan dibandingkan metode tradisional. Namun, mayoritas penelitian tersebut masih diterapkan pada objek beban listrik atau ritel umum, dan belum secara spesifik menangani karakteristik bahan baku kopi yang mudah rusak (*perishable*).

Di sisi lain, penelitian yang berfokus pada *food waste* (Todd and Faour-Klingbeil, 2024) cenderung bersifat analisis dampak kualitatif dan belum menawarkan solusi teknis berbasis model komputasi untuk pencegahan dini. Sementara itu, metode konvensional seperti EOQ (Sulu and Waluyowati, 2024) dinilai kurang responsif terhadap fluktuasi permintaan harian yang dinamis di kedai kopi modern.

Oleh karena itu, penelitian ini hadir untuk mengisi celah (gap) tersebut dengan menggabungkan keunggulan metode Prophet dan XGBoost secara spesifik untuk kasus persediaan bahan baku kopi. Penelitian ini tidak hanya bertujuan mencari akurasi prediksi, tetapi juga menghubungkannya langsung dengan tujuan pengurangan *food waste* di Matra Coffee, yang belum banyak dibahas secara komprehensif dalam penelitian-penelitian sebelumnya.

Sebagian besar penelitian terdahulu masih berfokus pada peramalan penjualan produk atau permintaan konsumen secara umum. Sementara itu, penelitian yang secara spesifik memodelkan kebutuhan bahan baku perishable sebagai variabel prediksi masih relatif terbatas, terutama pada konteks usaha coffee shop. Oleh karena itu, penelitian ini menawarkan pendekatan yang lebih langsung terhadap permasalahan food waste dengan memprediksi kebutuhan bahan baku yang berisiko tinggi mengalami kerusakan, sehingga hasil prediksi dapat dihubungkan secara langsung dengan strategi pengelolaan persediaan dan pengurangan limbah.

BAB III

METODOLOGI PENELITIAN

3.1. Manajemen Rantai Pasok dan Persediaan

Penelitian ini menggunakan pendekatan kuantitatif, yaitu pendekatan yang menekankan analisis data numerik untuk menghasilkan informasi yang objektif, terukur, dan dapat direplikasi. Pendekatan ini sesuai dengan karakter penelitian yang memanfaatkan data historis penjualan dan persediaan bahan baku Matra Coffee untuk membangun model prediksi berbasis algoritma Machine Learning. Pendekatan kuantitatif juga selaras dengan tujuan penelitian pada Bab I, yaitu mengurangi *food waste* melalui prediksi permintaan yang akurat, serta konsisten dengan teori forecasting dan analisis deret waktu pada Bab II (Sugiyono, 2019).

Jenis penelitian ini merupakan penelitian terapan (*applied research*), yaitu penelitian yang dirancang untuk menyelesaikan permasalahan nyata secara langsung dan menghasilkan solusi yang dapat diimplementasikan pada konteks operasional tertentu (Kumar, 2011). Dalam penelitian ini, model prediksi kebutuhan bahan baku tidak hanya diuji secara akademik, tetapi juga diarahkan untuk digunakan oleh Matra Coffee sebagai dasar pengambilan keputusan dalam mengatur persediaan bahan baku *perishable*, sehingga relevan dengan kebutuhan praktis di lapangan.

Penelitian ini menggunakan desain eksperimen komputasi (*computational experiment design*). Desain ini dipilih karena penelitian melibatkan pengujian dan perbandingan beberapa algoritma prediksi, yaitu Prophet dan XGBoost, menggunakan dataset yang sama. Eksperimen komputasi dilakukan melalui proses

pelatihan (*training*), validasi, dan pengujian (*testing*) untuk mendapatkan model prediksi dengan performa terbaik. Pendekatan ini sejalan dengan praktik umum dalam pengembangan model Machine Learning dan metode evaluasi model prediksi (Raschka & Mirjalili, 2020).

Selain itu, penelitian ini menggunakan kerangka kerja CRISP-DM (Cross-Industry Standard Process for Data Mining) sebagai strategi pemecahan masalah yang terstruktur. CRISP-DM merupakan metodologi data mining yang paling banyak digunakan dan menyediakan alur analitis yang sistematis mulai dari perumusan masalah hingga implementasi hasil analisis. Kerangka ini pertama kali diperkenalkan secara resmi oleh Chapman et al. (2000), yang menjelaskan bahwa CRISP-DM terdiri dari enam tahap utama: *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, *Evaluation*, dan *Deployment*. Validitas kerangka ini juga diperkuat oleh penelitian (Wang, Stupina and Bezhitskiy, 2024), yang menunjukkan bahwa CRISP-DM sangat efektif untuk merancang model prediksi penjualan karena mampu menyelaraskan kebutuhan bisnis dengan proses analisis data secara komprehensif.

Enam tahap CRISP-DM yang digunakan dalam penelitian ini dijelaskan sebagai berikut:

1. Business Understanding

Tahap ini berfokus pada pemahaman konteks bisnis dan perumusan masalah utama yang ingin diselesaikan. Dalam penelitian ini, peneliti mengidentifikasi permasalahan *food waste* dan ketidaktepatan estimasi permintaan pada Matra Coffee, sebagaimana diuraikan pada Bab I. Tujuan prediksi kemudian

dirumuskan agar model dapat memberikan kontribusi langsung terhadap pengurangan pemborosan bahan baku.

2. Data Understanding

Tahap ini bertujuan memahami karakteristik data penjualan, termasuk pola tren, musiman, variasi harian, serta potensi anomali seperti data hilang atau outlier. Proses ini mencakup eksplorasi awal data untuk menilai kualitas dan struktur dataset. Tahap ini berkaitan erat dengan teori deret waktu dan *perishable inventory* yang telah dijelaskan pada Bab II.

3. Data Preparation

Tahap ini meliputi pembersihan data, penanganan *missing values*, agregasi data ke format harian, transformasi fitur waktu (hari, bulan, libur nasional), serta pembuatan fitur lag (misalnya H-1 dan H-7). Tahap ini sangat penting karena kualitas data yang baik merupakan prasyarat utama untuk menghasilkan model prediksi yang akurat.

4. Modeling

Pada tahap ini, dua algoritma—Prophet dan XGBoost—dibangun dan diuji. Prophet digunakan untuk memodelkan tren dan musiman, sedangkan XGBoost digunakan untuk menangkap hubungan non-linear yang tidak dapat ditangkap oleh Prophet. Pendekatan *hybrid* keduanya memberikan kemampuan prediksi yang lebih kuat, sebagaimana dijelaskan dalam kajian teori pada Bab II.

5. Evaluation

Tahap evaluasi dilakukan untuk menilai performa model menggunakan metrik evaluasi seperti *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Evaluasi ini dilakukan dengan membandingkan

hasil prediksi terhadap data aktual. Model terbaik dipilih berdasarkan nilai kesalahan prediksi yang paling rendah.

6. Deployment (Konseptual)

Pada penelitian ini, deployment dilakukan secara konseptual dalam bentuk rekomendasi jumlah persediaan harian yang optimal berdasarkan hasil prediksi model. Tahap ini menjelaskan bagaimana hasil penelitian dapat diimplementasikan untuk mendukung pengambilan keputusan operasional pada Matra Coffee.

Dengan menggabungkan pendekatan kuantitatif, penelitian terapan, desain eksperimen komputasi, serta kerangka CRISP-DM yang sistematis, penelitian ini memiliki landasan metodologis yang kuat, relevan secara teoretis, dan aplikatif dalam konteks praktis pengelolaan persediaan di Matra Coffee.

3.2. Lokasi dan Objek Penelitian

Penelitian ini dilaksanakan di Matra Coffee yang bergerak di bidang usaha food and beverage. Objek yang dianalisis dalam penelitian ini berupa data historis penggunaan bahan baku perishable yang digunakan dalam operasional harian kafe. Bahan baku yang termasuk dalam kategori perishable meliputi susu, sayuran, buah-buahan, daging, roti, serta bahan segar lainnya yang memiliki masa simpan relatif pendek dan berisiko tinggi mengalami kerusakan. Data yang digunakan mencakup periode Juli hingga Desember 2025 dan disusun berdasarkan jumlah penggunaan bahan baku pada setiap waktu observasi.

Objek penelitian dalam studi ini adalah data penjualan menu harian dan data penggunaan bahan baku utama yang digunakan dalam operasional Matra Coffee. Data penjualan disusun dalam bentuk agregasi harian untuk setiap menu yang

tersedia, dengan jumlah menu lebih dari 30 jenis. Setiap baris data merepresentasikan jumlah penjualan satu menu pada satu hari tertentu, sehingga membentuk data deret waktu (*time series*) yang sesuai dengan pendekatan peramalan sebagaimana dibahas pada Bab II.

Data penjualan menu harian digunakan sebagai representasi permintaan (demand), sementara data bahan baku utama seperti biji kopi dan susu digunakan untuk mengaitkan hasil prediksi permintaan dengan kebutuhan persediaan bahan baku *perishable*. Pendekatan ini selaras dengan konsep manajemen persediaan bahan mudah rusak dan peramalan permintaan yang dijelaskan dalam kajian teori pada Bab II.

Periode data yang digunakan dalam penelitian ini mencakup rentang waktu [misalnya: Januari–Februari 2024]. Dengan jumlah menu yang relatif banyak dan pencatatan data secara harian, dataset yang terbentuk menghasilkan lebih dari 1.000 baris data, sehingga memenuhi kebutuhan minimal data untuk penerapan metode machine learning dalam penelitian ini.

3.3. Teknik Pengumpulan Data

Pengumpulan data dalam penelitian ini dilakukan melalui studi dokumentasi terhadap catatan operasional di Matra Coffee yang berkaitan dengan penggunaan bahan baku *perishable*. Karena tidak tersedia pencatatan langsung mengenai pemakaian bahan baku harian, data diperoleh melalui konversi transaksi penjualan ke estimasi kebutuhan bahan baku dengan mengacu pada standar takaran operasional per menu. Metode ini memungkinkan peneliti memperoleh estimasi jumlah bahan baku yang digunakan tanpa mengungkapkan rincian resep internal usaha. Adapun teknik pengumpulan data yang digunakan adalah sebagai berikut:

1. Studi Dokumentasi

Studi dokumentasi dilakukan dengan mengumpulkan data transaksi penjualan dari sistem POS yang kemudian dikonversi menjadi estimasi penggunaan bahan baku perishable berdasarkan standar takaran operasional. Data tersebut selanjutnya digunakan sebagai dataset untuk proses analisis dan pembangunan model prediksi berbasis time series.



Gambar 3.1 Contoh Data POS (Struk Penjualan)

Data diperoleh melalui dokumentasi riwayat transaksi yang diambil dari sistem POS Matra Coffee. Data awal berisi informasi per struk transaksi seperti nama item, jumlah item, harga, nomor order, tanggal, dan total pembelian.

2. Wawancara

Wawancara dilakukan secara daring dengan pemilik atau manajer operasional Matra Coffee untuk memperoleh informasi mengenai standar penggunaan

bahan baku per menu, pola pembelian bahan perishable, serta kendala yang dihadapi terkait pemborosan bahan makanan. Wawancara ini bertujuan untuk memahami kebijakan pemesanan bahan baku, jenis bahan yang paling berpotensi mengalami food waste, serta kendala operasional yang dihadapi dalam menentukan jumlah persediaan. Informasi hasil wawancara digunakan sebagai data kualitatif pendukung dalam interpretasi hasil penelitian.

3. Observasi Berbasis Dokumentasi

Observasi dilakukan dengan mempelajari alur pengelolaan persediaan bahan baku berdasarkan dokumentasi operasional dan penjelasan dari pihak manajemen Matra Coffee. Observasi ini bertujuan untuk memahami proses barang masuk dan keluar, serta hubungan antara penjualan menu dengan penggunaan bahan baku, tanpa melakukan pengamatan langsung di lokasi penelitian.

Dengan kombinasi studi dokumentasi, wawancara daring, dan observasi berbasis dokumentasi, penelitian ini memperoleh data yang memadai untuk mendukung proses analisis dan pembangunan model prediksi persediaan bahan baku.

3.4. Variabel dan Data Penelitian

Data yang digunakan dalam penelitian ini merupakan data kuantitatif yang bersumber dari catatan transaksi penjualan Matra Coffee yang terekam pada sistem Point of Sale (POS). Meskipun penelitian ini tidak memprediksi jumlah penjualan menu secara langsung, data POS tetap memiliki peran penting sebagai sumber informasi awal untuk menghitung estimasi penggunaan bahan baku perishable. Dengan kata lain, data transaksi penjualan digunakan sebagai dasar untuk

menurunkan jumlah kebutuhan bahan baku yang sebenarnya digunakan dalam operasional kafe.

Fokus penelitian ini adalah pada bahan baku perishable, yaitu bahan yang memiliki umur simpan relatif pendek dan berisiko tinggi menjadi limbah makanan apabila tidak dikelola dengan baik. Bahan baku tersebut meliputi susu, sayuran, buah-buahan, daging, roti, serta bahan segar lainnya yang umum digunakan dalam penyajian menu makanan dan minuman. Karakteristik bahan baku perishable yang mudah rusak menjadikannya objek yang relevan dalam penelitian yang bertujuan mengurangi food waste melalui pendekatan prediksi berbasis data.

Karena data penggunaan bahan baku tidak tercatat secara langsung dalam sistem operasional, maka dilakukan proses konversi data penjualan menjadi estimasi penggunaan bahan baku. Proses ini didasarkan pada standar takaran operasional per menu yang digunakan oleh Matra Coffee dalam kegiatan produksi sehari-hari. Dengan pendekatan ini, jumlah menu yang terjual dapat diterjemahkan menjadi jumlah bahan baku yang dipakai, sehingga dataset yang dihasilkan merepresentasikan kebutuhan bahan baku aktual secara lebih mendekati kondisi nyata.

3.4.1 Sumber dan Bentuk Data Awal

Data awal penelitian berupa data transaksi penjualan yang diperoleh dari sistem POS. Data tersebut memuat informasi tanggal transaksi, jenis menu yang terjual, serta jumlah menu yang dipesan. Data ini menggambarkan aktivitas operasional kafe selama periode penelitian, yaitu Juli hingga Desember 2025. Data ini selanjutnya diproses untuk menghitung estimasi penggunaan bahan baku.

Tabel 3.1 Data Mentah POS

Tanggal	Nama Menu	Jumlah Terjual
01-07-2025	Latte	20
01-07-2025	Rice Bowl Ayam	15
01-07-2025	Smoothie Mangga	10

Data pada tabel di atas belum secara langsung menunjukkan penggunaan bahan baku, sehingga diperlukan proses pengolahan lanjutan untuk menurunkan informasi tersebut.

3.4.2 Konversi Data Penjualan

Konversi data penjualan menjadi penggunaan bahan baku dilakukan dengan mengacu pada estimasi rata-rata takaran bahan baku per porsi menu. Nilai takaran ini diperoleh dari standar operasional internal yang biasa digunakan dalam proses produksi makanan dan minuman di kafe. Pendekatan ini umum digunakan dalam studi manajemen persediaan makanan ketika data penggunaan bahan baku tidak tercatat secara eksplisit.

Tabel 3.2 Estimasi Penggunaan Bahan Baku per Porsi

Kategori Menu	Bahan Baku	Estimasi Penggunaan per Porsi
Minuman berbasis susu	Susu	150 ml
Menu berbasis ayam	Daging ayam	120 gr
Menu berbasis telur	Telur	1 butir
Menu berbasis sayur	Sayuran segar	80 gr
Minuman berbasis buah	Buah segar	120 gr
Menu berbasis roti	Roti	1 pcs
Menu berbasis santan	Santan	50 ml

Melalui proses konversi, jumlah menu yang terjual dikalikan dengan estimasi takaran bahan baku, sehingga diperoleh estimasi penggunaan bahan baku pada periode tertentu.

Sebagai contoh, apabila pada tanggal tertentu terjual 20 porsi *Latte*, 15 porsi *Rice Bowl* Ayam, dan 10 porsi *Smoothie*, maka estimasi penggunaan bahan baku dihitung sebagai berikut:


Tabel 3.3 Hasil Konversi Bahan Baku

Tanggal	Susu (ml)	Daging Ayam (gr)	Buah (gr)
01-07-2025	3000	1800	1200

Hasil konversi ini kemudian menjadi dataset utama yang digunakan dalam proses pemodelan.

3.4.3 Skema Pengolahan Data

Proses transformasi data dari transaksi penjualan menjadi dataset kebutuhan bahan baku perishable dilakukan melalui beberapa tahapan pengolahan. Tahapan ini bertujuan memastikan bahwa data yang digunakan dalam pemodelan benar-benar merepresentasikan kebutuhan bahan baku yang digunakan dalam operasional.



Gambar 3.2 Skema Pengolahan Data

Skema tersebut menunjukkan bahwa data POS berfungsi sebagai sumber awal, kemudian diproses menjadi dataset bahan baku yang siap digunakan dalam pemodelan deret waktu.

3.4.4 Variabel Dependen (Target)

Variabel dependen dalam penelitian ini adalah jumlah kebutuhan bahan baku perishable pada setiap waktu observasi. Variabel ini menjadi nilai yang diprediksi oleh model.

Tabel 3.4 Variabel Dependen

Nama Variabel	Satuan	Keterangan
Susu	ml	Jumlah susu yang digunakan
Ayam	gram	Jumlah daging ayam yang digunakan
Telur	butir	Jumlah telur yang digunakan
Sayur	gram	Jumlah sayuran segar yang digunakan
Buah	gram	Jumlah buah segar yang digunakan
Roti	pcs	Jumlah roti yang digunakan
Santan	ml	Jumlah santan yang digunakan

Variabel-variabel tersebut dipilih karena termasuk kategori bahan baku perishable yang memiliki masa simpan pendek dan berisiko tinggi menjadi food waste.

3.4.5 Variabel Independen (Fitur)

Variabel independen digunakan untuk membantu model mengenali pola kebutuhan bahan baku dari waktu ke waktu.

1. Fitur Waktu (Time-Based Features)

Variabel ini meliputi informasi tanggal, hari dalam minggu, bulan, dan tahun, yang digunakan untuk menangkap pola temporal dan tren permintaan dari waktu ke waktu.

Tabel 3.5 Variabel Independen (Time-Based Features)

Variabel	Keterangan
Tanggal	Penanda urutan waktu observasi
Hari dalam Minggu	Pola penggunaan berdasarkan hari
Bulan	Variasi penggunaan antar bulan
Tahun	Penanda periode penelitian

2. Fitur Musiman (Seasonal Features)

Variabel musiman meliputi indikator akhir pekan dan hari libur nasional. Fitur ini berfungsi untuk mengidentifikasi variasi penggunaan bahan baku yang dipengaruhi oleh kondisi kalender.

Tabel 3.6 Variabel Independen (Seasonal Features)

Variabel	Nilai	Keterangan
Weekend Flag	0/1	Menandai hari akhir pekan
Holiday Flag	0/1	Menandai hari libur nasional

3. Historis (Lagged Features)

Fitur historis diperoleh dari nilai penggunaan bahan baku pada periode sebelumnya, seperti satu hari sebelumnya (lag-1) dan tujuh hari sebelumnya (lag-7). Variabel ini membantu model mengenali pola ketergantungan waktu dalam data.

Tabel 3.7 Variabel Independen (Lagged Features)

Variabel	Keterangan
Lag-1	Kebutuhan bahan baku satu periode sebelumnya
Lag-7	Kebutuhan bahan baku tujuh periode sebelumnya

Lagged features merupakan variabel historis yang dibentuk dari nilai penjualan pada periode sebelumnya. Tujuan penggunaan lag adalah untuk menangkap pola ketergantungan waktu (*temporal dependency*) yang umum terjadi

pada data deret waktu, di mana nilai hari ini sering dipengaruhi oleh nilai pada hari-hari sebelumnya. Dalam penelitian ini digunakan dua jenis lag, yaitu:

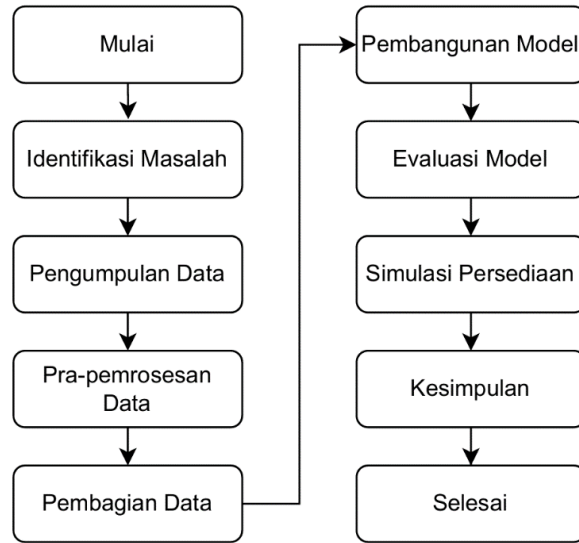
1. Lag-1 (H-1) yaitu jumlah penjualan pada satu hari sebelumnya. Variabel ini digunakan untuk melihat efek carry-over jangka pendek, misalnya apabila penjualan tinggi pada hari Senin, maka ada kemungkinan penjualan pada hari Selasa juga meningkat.
2. Lag-7 (H-7) yaitu jumlah penjualan pada tujuh hari sebelumnya. Variabel ini digunakan untuk menangkap pola mingguan, misalnya peningkatan penjualan pada akhir pekan dapat berulang pada minggu berikutnya.

Dengan memasukkan lag ke dalam model, algoritma machine learning dapat mempelajari pola fluktuasi jangka pendek maupun siklus mingguan yang tidak dapat dilihat hanya dari data tanggal. Lag-lag ini sangat penting terutama pada dataset kafe atau restoran yang biasanya memiliki pola musiman, promosi, atau kepadatan kunjungan yang cenderung berulang.

Seluruh variabel independen tersebut digunakan sebagai input dalam proses pemodelan untuk memprediksi variabel dependen. Pemilihan variabel dilakukan dengan mempertimbangkan karakteristik data penjualan menu harian dan teori peramalan deret waktu yang telah dibahas pada Bab II.

3.5. Model dan Analisis Data

Tahapan pengembangan model dalam penelitian ini difokuskan pada peramalan kebutuhan bahan baku perishable harian dengan memanfaatkan kombinasi algoritma Prophet dan XGBoost. Model dirancang untuk mengenali pola tren, musiman, serta variasi non-linear dalam penggunaan bahan baku.



Gambar 3.3 Flowchart Penyelesaian Masalah Penelitian

Proses analisis data dalam penelitian ini diawali dengan tahap pra-pemrosesan (data preprocessing) yang berperan penting dalam menjamin kualitas data yang digunakan sebagai input model. Pada tahap ini dilakukan pembersihan data (data cleaning) untuk menghilangkan noise, menangani missing values, serta memastikan tidak terdapat duplikasi pencatatan. Data mentah berupa transaksi penjualan menu terlebih dahulu dikonversi menjadi estimasi penggunaan bahan baku perishable melalui proses pemetaan resep, kemudian diagregasi ke dalam format deret waktu harian (daily time-series). Transformasi ini bertujuan agar data merepresentasikan kebutuhan riil bahan baku per hari sesuai dengan karakteristik operasional kafe. Dataset yang telah tersusun kemudian dipartisi dengan rasio 80:20, di mana 80% data digunakan sebagai data latih (training set) untuk proses pembelajaran model, sedangkan 20% sisanya digunakan sebagai data uji (testing set) untuk validasi kinerja model, merujuk pada praktik evaluasi model prediktif pada data ritel (Adriani, Huizen, dan Hermawan, 2025).

Pada tahap pembangunan model (modeling), diterapkan pendekatan hybrid serial antara Prophet dan XGBoost. Model Prophet digunakan sebagai base learner untuk menangkap pola tren jangka panjang serta pola musiman (seasonality) dari kebutuhan bahan baku perishable. Namun, mengingat adanya dinamika permintaan yang tidak sepenuhnya bersifat linear, residu atau selisih antara nilai aktual dan prediksi Prophet selanjutnya dimodelkan menggunakan algoritma XGBoost. Model XGBoost berfungsi untuk menangkap pola non-linier yang tidak terakomodasi oleh Prophet, sehingga mampu meningkatkan akurasi prediksi secara keseluruhan. Arsitektur model hibrida ini mengadaptasi pendekatan yang diusulkan oleh Zeng et al. (2025), yang terbukti efektif dalam meningkatkan performa prediksi pada data dengan fluktuasi tinggi.

Tahap akhir penelitian adalah evaluasi dan interpretasi hasil model. Kinerja model diukur secara kuantitatif menggunakan metrik Root Mean Squared Error (RMSE) dan Mean Absolute Percentage Error (MAPE) untuk menilai tingkat deviasi antara hasil prediksi kebutuhan bahan baku dengan data aktual. Hasil prediksi akhir kemudian diinterpretasikan sebagai estimasi kebutuhan bahan baku perishable harian dan dikonversi menjadi rekomendasi jumlah persediaan yang seharusnya disiapkan. Rekomendasi ini selanjutnya diuji melalui simulasi dengan membandingkan estimasi kebutuhan hasil model terhadap data pembelian aktual historis, sehingga diperoleh gambaran potensi kelebihan stok yang dapat diidentifikasi sebagai food waste serta estimasi pengurangan limbah yang dapat dicapai oleh Matra Coffee apabila pendekatan prediktif ini diterapkan.

3.5.1 Pra-Pemrosesan Data (Data Preprocessing)

Tahap pra-pemrosesan dilakukan untuk memastikan data kebutuhan bahan baku yang dihasilkan dari konversi data POS memiliki kualitas yang baik sebelum digunakan dalam pemodelan. Proses ini meliputi pembersihan data dari nilai yang hilang, penyesuaian format tanggal, serta pengurutan data berdasarkan urutan waktu agar sesuai dengan struktur deret waktu (time series).

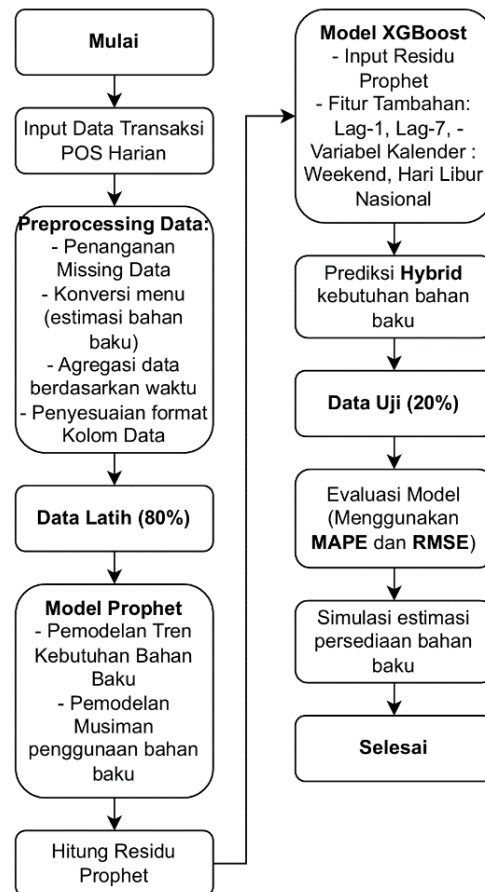
Selain itu, dilakukan pembentukan fitur waktu seperti hari dalam minggu, bulan, dan indikator akhir pekan serta hari libur nasional. Fitur historis berupa nilai penggunaan bahan baku pada periode sebelumnya (lag-1 dan lag-7) juga ditambahkan untuk membantu model mengenali ketergantungan waktu dalam pola penggunaan bahan baku.

3.5.2 Pembagian Data (Data Splitting)

Setelah data melalui proses pembersihan dan transformasi, langkah selanjutnya adalah mempartisi dataset menjadi dua sub-himpunan yang terpisah, yaitu data latih (*training set*) dan data uji (*testing set*). Mekanisme pembagian data dilakukan secara sekuensial atau kronologis berdasarkan urutan waktu, bukan secara acak, untuk mempertahankan pola tren waktu yang ada. Dalam penelitian ini, rasio pembagian yang diterapkan adalah 80:20, di mana 80% data awal digunakan untuk melatih model agar mempelajari pola historis, sedangkan 20% data terakhir dialokasikan khusus untuk pengujian validitas model. Pemilihan proporsi pembagian data ini merujuk pada pendekatan standar dalam eksperimen *machine learning* pada sektor ritel yang terbukti efektif dalam menjaga keseimbangan antara kemampuan model untuk belajar dan kemampuan generalisasi pada data baru (Adriani, Huizen and Hermawan, 2025).

3.5.3 Pembangunan Model Prophet dan XGBoost

Tahap pemodelan dimulai dengan melatih algoritma Facebook Prophet menggunakan data latih yang telah disiapkan. Dalam arsitektur penelitian ini, Prophet berfungsi sebagai pembentuk model dasar (*base learner*) yang bertugas menangkap pola-pola global yang bersifat linear pada data penjualan bahan baku.



Gambar 3.4 Flowchart Algoritma Model Hybrid Prophet–XGBoost

Prophet bekerja dengan mendekomposisi data deret waktu kebutuhan bahan baku perishable ke dalam tiga komponen utama, yaitu tren pertumbuhan, musiman, dan efek hari libur. Dalam penelitian ini, data yang dimodelkan merupakan hasil konversi dari transaksi penjualan menu menjadi estimasi penggunaan bahan baku. Dengan demikian, model Prophet tidak lagi memprediksi jumlah penjualan, melainkan memprediksi kebutuhan bahan baku berdasarkan pola historis

penggunaannya. Merujuk pada kerangka kerja matematis yang dijelaskan oleh (Zeng *et al.*, 2025), model Prophet diformulasikan dalam bentuk persamaan aditif sebagai berikut:

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t \quad (15)$$

Keterangan variabel dari persamaan di atas adalah:

- $y(t)$: Nilai prediksi permintaan bahan baku pada waktu ke- t .
- $g(t)$: Komponen tren yang merepresentasikan perubahan non-periodik atau pertumbuhan jangka panjang dari data penjualan.
- $s(t)$: Komponen musiman (seasonality) yang merepresentasikan pola perubahan periodik, seperti fluktuasi mingguan (kenaikan saat akhir pekan) atau bulanan.
- $h(t)$: Komponen efek hari libur (holiday effects) yang memperhitungkan dampak dari kejadian tidak teratur seperti hari libur nasional terhadap lonjakan permintaan.
- ε_t : Komponen kesalahan (error) atau residu yang diasumsikan terdistribusi secara normal, yang mewakili variasi data yang tidak tertangkap oleh model.

Pada tahap pertama pemodelan, Prophet dilatih menggunakan data latihan kebutuhan bahan baku untuk mempelajari pola tren dan musiman dari penggunaan bahan baku perishable. Hasil prediksi Prophet merepresentasikan estimasi kebutuhan bahan baku yang dijelaskan oleh pola linear dan periodik.

Setelah model Prophet dibangun, langkah berikutnya adalah memodelkan residu, yaitu selisih antara nilai aktual kebutuhan bahan baku dan hasil prediksi dari Prophet. Residu dihitung menggunakan persamaan:

$$Residu_t = y_{aktual,t} - \hat{y}_{Prophet,t} \quad (16)$$

Residu ini mencerminkan variasi kebutuhan bahan baku yang tidak dapat dijelaskan oleh pola tren dan musiman saja, seperti perubahan mendadak akibat kondisi operasional tertentu atau fluktuasi permintaan yang bersifat non-linear.

Nilai residu tersebut kemudian digunakan sebagai variabel target dalam pelatihan model XGBoost (Extreme Gradient Boosting). Model XGBoost dibangun dengan memanfaatkan fitur tambahan seperti lag-1 dan lag-7 (penggunaan bahan baku pada periode sebelumnya), serta variabel kalender seperti indikator akhir pekan dan hari libur nasional. Fitur-fitur ini membantu model mengenali pola ketergantungan waktu dan faktor eksternal yang memengaruhi kebutuhan bahan baku.

XGBoost bekerja melalui mekanisme ensemble pohon keputusan yang dibangun secara bertahap (iterative boosting). Setiap pohon baru ditambahkan untuk memperbaiki kesalahan prediksi dari pohon sebelumnya. Untuk menghindari overfitting, model XGBoost menerapkan mekanisme regularisasi serta dilakukan penalaan parameter (hyperparameter tuning) pada parameter utama seperti learning rate, kedalaman pohon maksimum, dan jumlah estimator.

Setelah model XGBoost menghasilkan prediksi residu, hasil tersebut kemudian digabungkan dengan hasil prediksi Prophet untuk membentuk prediksi akhir pada model hibrida. Secara matematis, prediksi akhir kebutuhan bahan baku dirumuskan sebagai:

$$Y_{hybrid} = \hat{Y}_{Prophet} + \hat{Y}_{XGBoost} \quad (17)$$

Pendekatan hybrid ini memungkinkan model memanfaatkan keunggulan Prophet dalam menangkap pola tren dan musiman, serta keunggulan XGBoost dalam memodelkan variasi non-linear. Dengan demikian, model mampu

memberikan estimasi kebutuhan bahan baku perishable yang lebih akurat, yang selanjutnya digunakan dalam simulasi pengelolaan persediaan dan analisis potensi food waste.

3.5.4 Evaluasi Model

Untuk mengukur keandalan dan akurasi model hibrida yang telah dibangun, dilakukan proses evaluasi menggunakan data uji (testing set). Evaluasi dilakukan dengan membandingkan nilai hasil prediksi model (Y_{final}) terhadap nilai aktual penjualan yang sebenarnya (Y_{actual}). Penelitian ini menggunakan dua metrik statistik utama sebagai indikator kinerja, yaitu Root Mean Squared Error (RMSE) dan Mean Absolute Percentage Error (MAPE), sebagaimana dirujuk dari (Zeng *et al.*, 2025).

Pertama, RMSE digunakan untuk mengukur rata-rata besaran kesalahan prediksi dalam satuan unit yang sama dengan data aslinya, yang memberikan bobot lebih besar pada kesalahan yang bernilai ekstrem. Rumus RMSE dijabarkan sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (18)$$

Di mana :

- n : Jumlah total data observasi atau sampel uji.
- y_i : Nilai aktual permintaan bahan baku pada data ke- i
- \hat{y}_i : Nilai prediksi permintaan bahan baku pada data ke- i .

Kedua, MAPE digunakan untuk mengukur rata-rata kesalahan absolut dalam bentuk persentase, yang memudahkan interpretasi tingkat akurasi relatif model. Rumus MAPE dijabarkan sebagai berikut:

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (19)$$

Di mana :

- a. y_i dan \hat{y}_i adalah nilai aktual dan nilai prediksi.
- b. Nilai mutlak $|\dots|$ memastikan bahwa selisih negatif dan positif diperlakukan sama sebagai besaran kesalahan.

3.5.5 Simulasi Estimasi Persediaan dan Analisis Food Waste

Tahap akhir penelitian melibatkan simulasi estimasi kebutuhan persediaan bahan baku berdasarkan hasil prediksi model. Prediksi kebutuhan bahan baku perishable yang dihasilkan oleh model digunakan sebagai acuan untuk mengevaluasi kesesuaian antara jumlah bahan baku yang dibeli dengan jumlah yang benar-benar dibutuhkan.

Simulasi dilakukan dengan membandingkan jumlah pembelian aktual bahan baku dengan nilai kebutuhan yang diprediksi. Selisih antara kedua nilai tersebut menunjukkan potensi kelebihan atau kekurangan persediaan. Kelebihan bahan baku diidentifikasi sebagai potensi food waste karena bahan tersebut memiliki umur simpan terbatas.

Secara matematis, estimasi potensi limbah dapat dirumuskan sebagai:

$$FoodWaste_t = PembelianAktual_t - PrediksiKebutuhan_t \quad (20)$$

Nilai positif pada persamaan tersebut menunjukkan adanya kelebihan bahan baku yang berpotensi terbuang. Melalui pendekatan ini, penelitian dapat menggambarkan dampak penerapan model terhadap efisiensi pengelolaan bahan baku dan pengurangan limbah makanan di Matra Coffee.

Hasil prediksi kebutuhan bahan baku dari model tidak hanya digunakan untuk menghitung potensi limbah, tetapi juga untuk menentukan estimasi jumlah persediaan optimal yang seharusnya disiapkan. Perhitungan ini dilakukan dengan mempertimbangkan kebutuhan harian, ketidakpastian permintaan, serta waktu tunggu pengadaan bahan baku.

Langkah-langkah perhitungan estimasi persediaan dijabarkan sebagai berikut:

- a. Menentukan kebutuhan bahan baku harian hasil prediksi

$$D_t = \text{PrediksiKebutuhan}_t \quad (21)$$

- b. Menghitung rata-rata kebutuhan harian

$$D_{avg} = \frac{\sum D_t}{n} \quad (22)$$

- c. Menentukan Safety Stock (Persediaan Pengaman)

Safety stock digunakan untuk mengantisipasi fluktuasi kebutuhan bahan baku:

$$SS = \alpha \times \sigma_d \quad (23)$$

dengan:

- SS = safety stock
- α = faktor pengaman (misalnya 10-20%)
- σ_d = standar deviasi kebutuhan harian

- d. Menghitung Re-Order Point (ROP)

Re-order point menunjukkan batas minimum stok sebelum pemesanan ulang dilakukan:

$$ROP = (D_{avg} \times LT) + SS \quad (24)$$

dengan LT adalah *lead time* pemesanan bahan baku (hari).

- e. Menentukan estimasi jumlah pembelian optimal

$$Q_t = D_t + SS \quad (25)$$

Nilai Q_t merupakan rekomendasi jumlah bahan baku yang seharusnya disiapkan agar risiko kekurangan stok dapat diminimalkan.

Sebagai ilustrasi, apabila hasil prediksi kebutuhan susu pada hari tertentu adalah 20 liter dan safety stock ditetapkan sebesar 10%, maka estimasi jumlah susu yang sebaiknya disiapkan adalah:

$$Q = 20 + (10\% \times 20) = 22 \text{ liter}$$

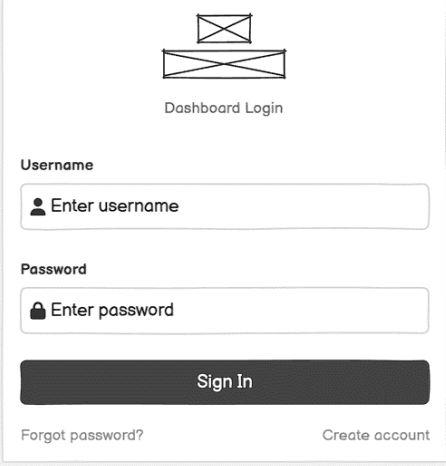
Perlu ditegaskan bahwa perhitungan estimasi persediaan pada penelitian ini bersifat simulatif dan digunakan untuk menggambarkan potensi penerapan model dalam mendukung pengambilan keputusan. Nilai estimasi yang dihasilkan belum diterapkan secara langsung dalam operasional, namun menunjukkan bagaimana model prediksi dapat membantu mengurangi risiko kelebihan persediaan dan potensi food waste.

3.6. Rancangan Dashboard Prediksi Penjualan

Pada tahap perancangan sistem, dibuat rancangan antarmuka pengguna (user interface) yang bertujuan untuk memudahkan pengguna dalam berinteraksi dengan sistem prediksi kebutuhan bahan baku. Rancangan ini dibuat sebagai gambaran awal tampilan sistem sebelum proses implementasi dilakukan. Antarmuka sistem dirancang agar sederhana, informatif, serta mudah digunakan oleh pihak operasional Matra Coffee dalam memantau penggunaan bahan baku dan hasil prediksi sistem.

Secara umum, sistem terdiri dari beberapa halaman utama yaitu halaman login, dashboard utama, riwayat transaksi, simulasi prediksi, analisis menu matrix, kalkulator food waste, dan halaman pengaturan sistem.

3.6.1 Rancangan Halaman Login



The image shows a wireframe for a login page. At the top center is a logo consisting of a square with an 'X' inside, above a rectangular box with an 'X' inside. Below the logo is the text 'Dashboard Login'. Underneath, there are two input fields. The first is labeled 'Username' and contains the placeholder text 'Enter username' with a small person icon on the left. The second is labeled 'Password' and contains the placeholder text 'Enter password' with a small lock icon on the left. Below these fields is a dark grey button with the text 'Sign In' in white. At the bottom of the form, there are two links: 'Forgot password?' on the left and 'Create account' on the right.

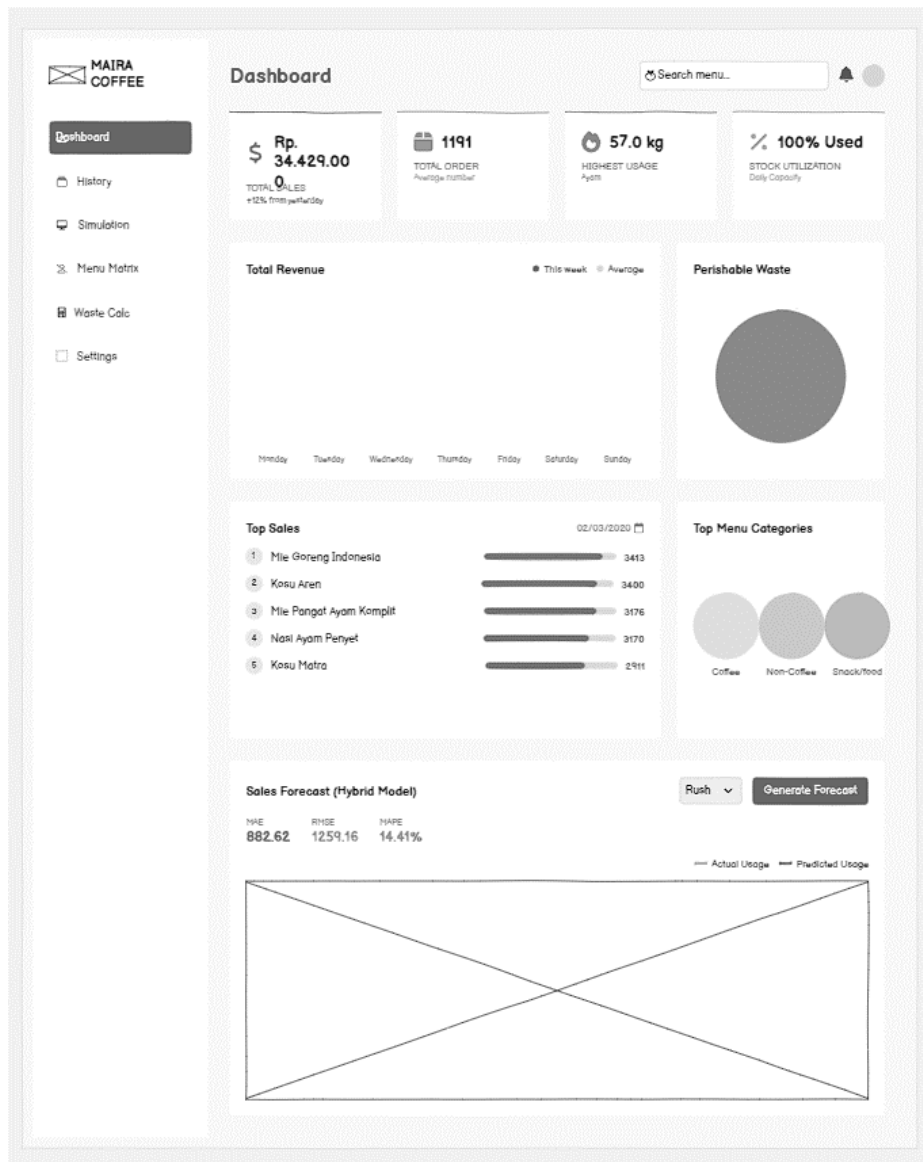
Gambar 3.5 Rancangan Halaman Login

Halaman login dirancang sebagai mekanisme autentikasi pengguna sebelum mengakses sistem dashboard prediksi. Pada halaman ini, pengguna diwajibkan memasukkan username dan password yang telah terdaftar dalam sistem.

Antarmuka halaman login dirancang sederhana dengan dua komponen input utama yaitu kolom username dan password. Selain itu terdapat tombol Sign In yang digunakan untuk memproses autentikasi pengguna. Sistem dirancang untuk melakukan verifikasi terhadap data login yang dimasukkan sebelum pengguna dapat mengakses halaman utama sistem.

Rancangan halaman login ini bertujuan untuk menjaga keamanan sistem agar hanya pengguna yang memiliki akses yang dapat menggunakan fitur-fitur dalam dashboard prediksi.

3.6.2 Rancangan Dashboard Utama



Gambar 3.6 Rancangan Halaman Dashboard

Dashboard utama dirancang sebagai halaman utama yang menampilkan ringkasan informasi operasional dan hasil analisis sistem prediksi. Halaman ini berfungsi sebagai pusat monitoring yang memberikan gambaran cepat mengenai kondisi penjualan, penggunaan bahan baku, serta potensi food waste.

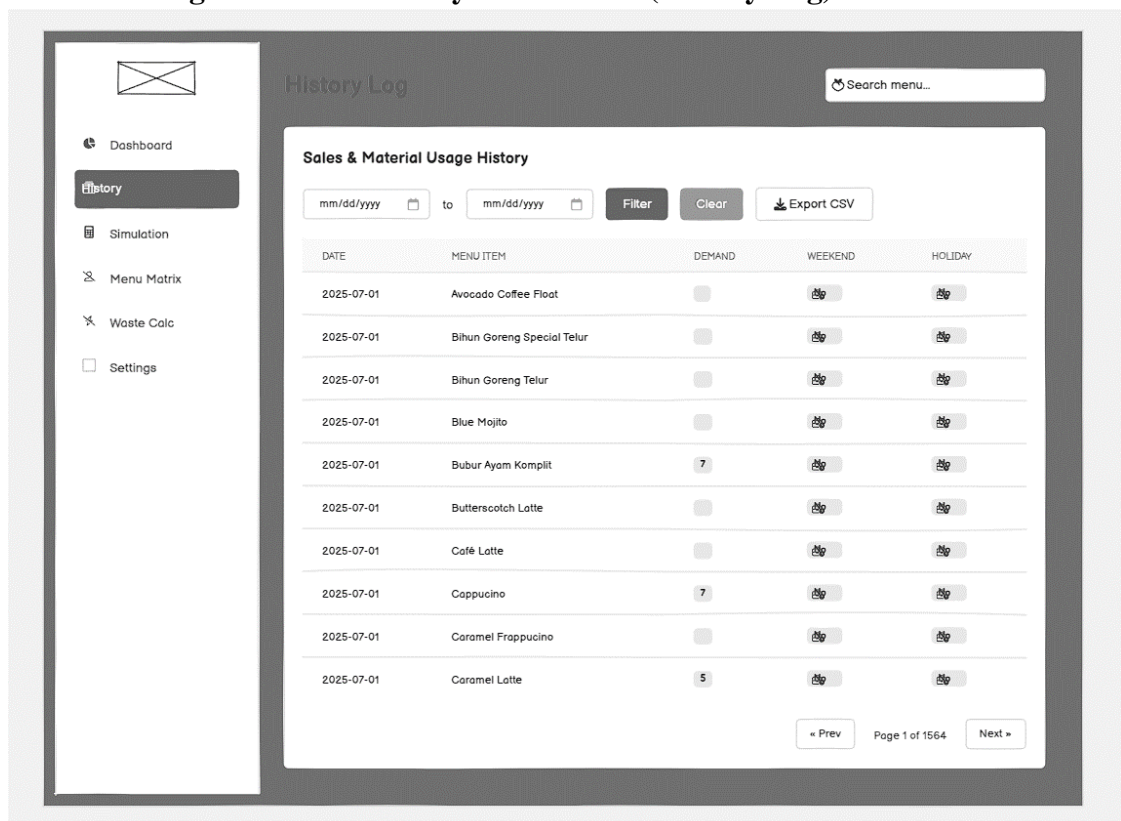
Pada halaman dashboard dirancang beberapa komponen utama berupa:

1. Indikator ringkasan penjualan.
2. Jumlah pesanan.

3. Tingkat penggunaan bahan baku.
4. Persentase pemanfaatan stok.

Selain itu dashboard juga dirancang untuk menampilkan grafik analisis seperti grafik pendapatan, distribusi limbah bahan baku, serta daftar menu dengan penjualan tertinggi. Pada bagian bawah dashboard juga dirancang area visualisasi hasil peramalan yang menampilkan perbandingan antara penggunaan bahan baku aktual dan hasil prediksi menggunakan model hybrid Prophet dan XGBoost. Dengan adanya dashboard ini, pengguna dapat memperoleh gambaran kondisi operasional secara cepat tanpa perlu melakukan analisis data secara manual.

3.6.3 Rancangan Halaman Riwayat Transaksi (History Log)



Gambar 3.7 Rancangan History Log

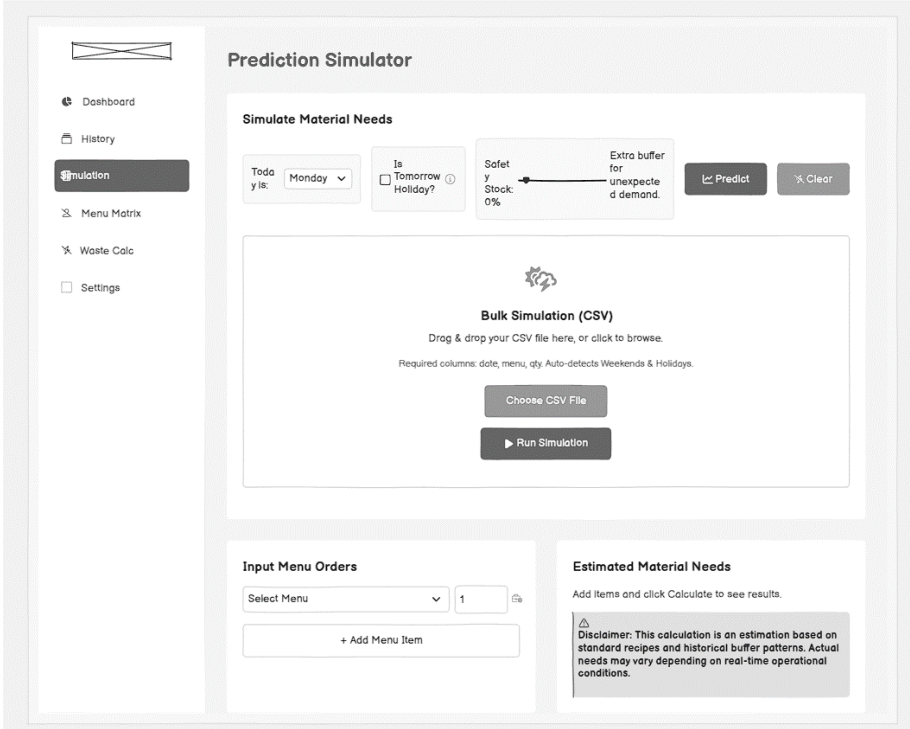
Halaman riwayat transaksi dirancang untuk menampilkan data historis penjualan menu dan penggunaan bahan baku yang digunakan sebagai dataset dalam

proses peramalan. Pada halaman ini dirancang sebuah tabel data yang menampilkan beberapa atribut penting seperti:

1. Tanggal transaksi
2. nama menu
3. jumlah permintaan
4. indikator akhir pekan
5. indikator hari libur

Selain tabel data, halaman ini juga dirancang memiliki fitur pencarian serta filter rentang tanggal yang memungkinkan pengguna untuk menampilkan data sesuai periode tertentu. Data historis ini berfungsi sebagai dasar pembentukan pola data yang digunakan dalam model machine learning.

3.6.4 Rancangan Halaman Simulasi Prediksi



Gambar 3.8 Rancangan Simulasi Prediksi

Halaman simulasi prediksi dirancang untuk memungkinkan pengguna melakukan simulasi estimasi kebutuhan bahan baku berdasarkan skenario permintaan menu tertentu.

Pada halaman ini pengguna dapat memilih menu yang akan disimulasikan serta menentukan jumlah pesanan. Sistem kemudian dirancang untuk menghitung estimasi kebutuhan bahan baku berdasarkan resep standar yang digunakan oleh setiap menu.

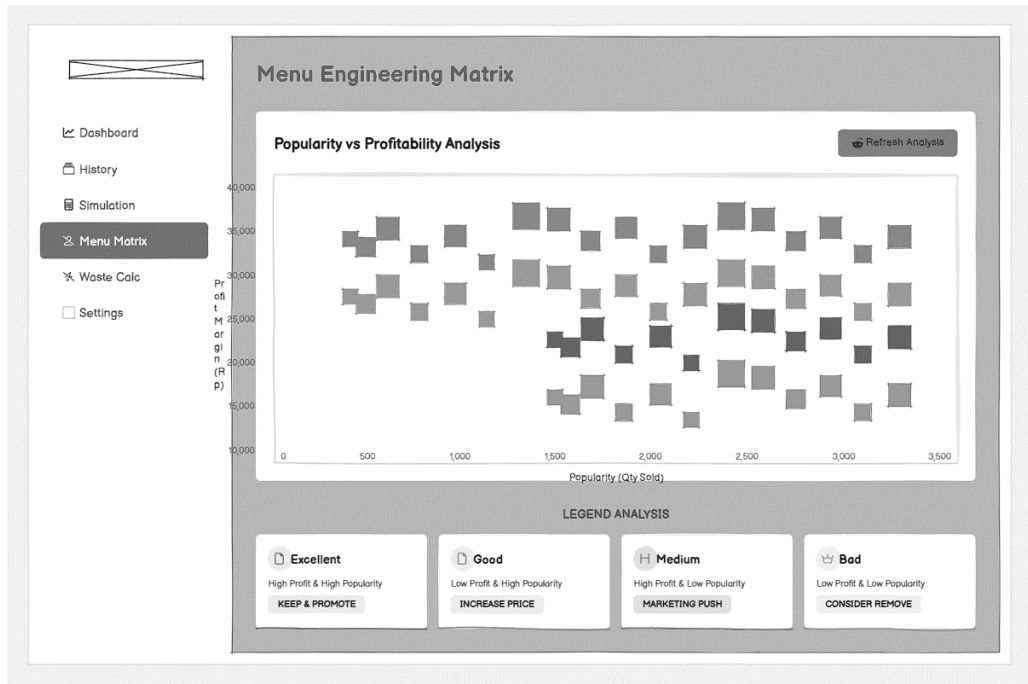
Selain simulasi manual, halaman ini juga dirancang mendukung simulasi massal melalui file CSV yang berisi data pesanan menu. Fitur ini memungkinkan pengguna melakukan simulasi prediksi dalam jumlah besar untuk membantu perencanaan pembelian bahan baku.

Hasil simulasi dirancang untuk menampilkan estimasi kebutuhan bahan baku yang diperlukan untuk memenuhi permintaan menu tersebut.

3.6.5 Rancangan Halaman Menu Engineering Matrix

Halaman Menu Engineering Matrix dirancang untuk melakukan analisis performa menu berdasarkan dua parameter utama yaitu popularitas dan profitabilitas menu. Rancangan halaman ini menampilkan grafik matriks yang memetakan menu ke dalam empat kategori utama yaitu:

1. Menu dengan profit tinggi dan popularitas tinggi.
2. Menu dengan profit rendah tetapi popularitas tinggi.
3. Menu dengan profit tinggi tetapi popularitas rendah.
4. Menu dengan profit rendah dan popularitas rendah.



Gambar 3.9 Rancangan Matrix Engineering Menu

Melalui analisis ini, pengguna dapat memperoleh gambaran strategi pengelolaan menu yang lebih efektif, seperti mempertahankan menu unggulan, meningkatkan harga, melakukan promosi, atau menghapus menu yang kurang menguntungkan.

3.6.6 Rancangan Halaman Kalkulator Waste

Item	Quantity	Unit	Estimated Loss (Rp)
Ayam	180	gr	6,300
Buah	650	gr	39,000
Roti	21	pcs	58,800
Total			104,100

Gambar 3.10 Rancangan Halaman Kalkulator Waste

Halaman kalkulator food waste dirancang untuk membantu pengguna menghitung potensi kerugian finansial akibat bahan baku yang terbuang.

Pada halaman ini pengguna dapat memasukkan jenis bahan baku yang terbuang beserta jumlahnya. Sistem kemudian dirancang untuk menghitung estimasi nilai kerugian berdasarkan harga bahan baku yang tersimpan dalam sistem.

Hasil perhitungan akan menampilkan total estimasi kerugian serta rincian biaya yang berasal dari masing-masing bahan baku. Fitur ini bertujuan untuk memberikan gambaran dampak finansial dari food waste yang terjadi pada operasional usaha.

3.6.7 Rancangan Halaman Pengaturan Sistem

INGREDIENT	CURRENT COST (BASE UNIT)	UPDATE COST	ACTION
Ayam	Rp 35 (per gr)	35	🔒
Buah	Rp 60 (per gr)	60	🔒
Roti	Rp 2800 (per pca)	2800	🔒
Santan	Rp 10 (per ml)	10	🔒
Soyur	Rp 25 (per gr)	25	🔒

Gambar 3.11 Rancangan Halaman Pengaturan

Halaman pengaturan sistem dirancang untuk memungkinkan pengguna mengatur berbagai parameter operasional yang digunakan dalam sistem prediksi. Beberapa pengaturan yang dirancang pada halaman ini meliputi:

1. Pengaturan persentase safety stock.

2. Parameter ambang batas peringatan stok.
3. Metode perhitungan menu matrix.
4. Pengelolaan data harga bahan baku.

Selain itu halaman ini juga dirancang menyediakan fitur pembaruan harga bahan baku serta reset konfigurasi sistem. Dengan adanya halaman pengaturan ini, pengguna dapat menyesuaikan parameter sistem sesuai dengan kondisi operasional yang sebenarnya.

3.7. Jadwal Penelitian

Penelitian ini dilaksanakan dalam jangka waktu 5 bulan, dimulai dari tahap persiapan hingga penyusunan laporan akhir. Penyusunan jadwal penelitian bertujuan untuk memastikan setiap tahapan penelitian dapat dilaksanakan secara sistematis dan terstruktur, sesuai dengan alur metodologi yang telah dijelaskan pada subbab sebelumnya. Rincian jadwal penelitian disajikan pada Tabel 3.6.

Tabel 3.8 Jadwal Penelitian

No	Kegiatan	Waktu				
		1	2	3	4	5
1	Penulisan proposal					
2	Seminar dan bimbingan proposal					
3	Penelitian dan tindakan					
4	Analisis dan bimbingan hasil penelitian					
5	Ujian skripsi					

BAB IV

HASIL DAN PEMBAHASAN

4.1. Gambaran Umum Data Penelitian

Penelitian ini dilakukan di Matra Coffee , sebuah usaha *Food & Beverage* (F&B) yang menghadapi tantangan dalam pengelolaan persediaan bahan baku *perishable* (mudah rusak). Fokus utama penelitian adalah memprediksi kebutuhan harian untuk 7 (tujuh) bahan baku utama: Susu, Ayam, Buah, Roti, Santan, Sayur, dan Telur.

Data yang digunakan merupakan data sekunder berupa riwayat transaksi penjualan harian (*daily sales transaction*) yang diekspor dari sistem *Point of Sales* (POS) Matra Coffee.

1. Periode Data: 1 Juli 2025 – 31 Desember 2025 (6 Bulan).
2. Total Hari Observasi: 184 hari.
3. Total Transaksi Awal: 15.640 baris data transaksi menu individual.
4. Variabel Data: Tanggal Transaksi (Date), Nama Menu (Item Name), Jumlah Terjual (Quantity), dan Harga Jual (Price).

4.1.1 Rasionalisasi Agregasi Data untuk Machine Learning

Dalam tahap awal, data mentah yang berjumlah 15.640 baris transaksi individual dikonversi dan diagregasi menjadi dataset *time series* harian dengan total 184 baris data (merekpresentasikan 184 hari operasional). Proses pengurangan dimensi data ini bukan berarti menghilangkan informasi penting, melainkan merupakan langkah pra-syarat mutlak dalam pemodelan peramalan (*forecasting*) dengan alasan sebagai berikut:

1. Relevansi terhadap Tujuan Prediksi (Business Goal): Tujuan utama penelitian adalah memprediksi kebutuhan stok harian untuk mencegah *food waste*, bukan memprediksi kapan detik/jam terjadinya setiap transaksi. Keputusan pembelian bahan baku (*procurement*) dilakukan sekali sehari atau beberapa hari sekali, bukan setiap ada pelanggan yang membeli kopi. Oleh karena itu, satuan waktu terkecil yang relevan untuk pengambilan keputusan bisnis adalah "Hari", bukan "Transaksi per Transaksi".
2. Karakteristik Algoritma *Prophet*: Algoritma *Prophet* dirancang khusus untuk memodelkan data deret waktu (*time series*) yang memiliki interval waktu yang konsisten (harian, mingguan, bulanan). *Prophet* bekerja dengan mendekomposisi pola menjadi Tren ($g(t)$) dan Musiman ($s(t)$). Jika data dibiarkan dalam bentuk transaksi acak (15.000 baris dengan jam yang tidak teratur), *Prophet* tidak akan mampu membentuk pola musiman harian (*daily seasonality*) atau mingguan (*weekly seasonality*) yang stabil karena *noise* data yang terlalu tinggi. Agregasi ke level harian justru memperjelas sinyal pola tersebut.
3. Karakteristik Algoritma XGBoost: XGBoost dalam konteks time series membutuhkan fitur lag (nilai masa lalu, misal: $t - 1, t - 7$ untuk mempelajari ketergantungan waktu. Fitur lag ini hanya bermakna jika interval waktunya tetap.
 - a. Lag-1 Hari (penjualan kemarin) adalah prediktor yang kuat untuk penjualan hari ini.
 - b. Sebaliknya, Lag-1 Transaksi (transaksi pelanggan sebelumnya) tidak memiliki korelasi yang kuat untuk memprediksi transaksi pelanggan

berikutnya. Oleh karena itu, struktur data harian (184 baris) memberikan fitur yang jauh lebih kaya informasi (information-rich features) bagi XGBoost dibandingkan data transaksi mentah.

4. Stabilitas Statistik: Dengan mengagregasi 15.640 transaksi menjadi 184 titik data harian, variansi acak (random noise) antar-transaksi dapat diredam, sehingga pola dasar (underlying pattern) permintaan bahan baku menjadi lebih terlihat. Hal ini meningkatkan kemampuan model untuk melakukan generalisasi dan menghasilkan prediksi yang lebih akurat (RMSE yang lebih rendah).

Meskipun jumlah baris data berkurang secara drastis, densitas informasi yang terkandung dalam setiap baris data harian justru meningkat, karena setiap baris kini merepresentasikan akumulasi perilaku konsumen selama satu hari penuh, yang merupakan unit analisis paling tepat untuk manajemen spersediaan bahan baku perishable.

4.2. Pra-pemrosesan Data (Data Preprocessing)

Sebelum dilakukan pemodelan menggunakan algoritma Machine Learning , data mentah yang diperoleh dari sistem POS harus melalui serangkaian proses transformasi agar memiliki struktur yang sesuai dan kualitas yang baik. Tahapan pra-pemrosesan ini bertujuan untuk menghilangkan noise , menangani anomali, serta merekayasa fitur-fitur baru yang relevan untuk prediksi.

4.2.1 Pembersihan Data (Data Cleaning)

Langkah awal dalam pra-pemrosesan adalah memastikan integritas dataset. Berdasarkan pemeriksaan awal terhadap 15.640 data transaksi, dilakukan beberapa tindakan pembersihan sebagai berikut:

- a. Pengecekan Nilai Kosong (Missing Values): Tidak ditemukan adanya nilai kosong (null) pada kolom krusial seperti Tanggal dan Nama Menu . Namun, terdapat beberapa hari di mana tidak ada transaksi tercatat (misalnya saat libur operasional atau tutup toko). Hari-hari tanpa transaksi ini diisi (impute) dengan nilai penjualan 0 untuk menjaga kontinuitas deret waktu (time series continuity), karena bagi model, informasi "penjualan 0" adalah sinyal penting yang menandakan tidak adanya permintaan.
- b. Penghapusan Duplikasi: Dilakukan pengecekan terhadap data duplikat yang mungkin muncul akibat kesalahan sistem saat proses ekspor data. Sebanyak 12 baris data duplikat yang teridentifikasi dihapus untuk mencegah bias perhitungan total penjualan harian.
- c. Penyeragaman Format Tanggal: Kolom tanggal yang semula memiliki format beragam dari sistem POS diseragamkan menjadi format standar YYYY-MM-DD (Tahun-Bulan-Hari) untuk memudahkan proses agregasi dan manipulasi time series di Python.

4.2.2 Konversi Menu ke Bahan Baku (Recipe Conversion)

Tantangan utama dalam penelitian ini adalah data yang tersedia berupa "Menu Terjual", sedangkan target prediksi adalah "Kebutuhan Bahan Baku". Oleh karena itu, dilakukan proses konversi menggunakan matriks komposisi resep yang telah disusun berdasarkan standar operasional Matra Coffee.

Setiap menu yang terjual dikonversi menjadi satuan gramasi atau mililiter bahan baku penyusunnya. Proses ini dilakukan dengan mengalikan jumlah menu terjual dengan takaran bahan baku per porsi.

Tabel 4.1 Contoh Matriks Konversi Resep

Nama Menu	Susu(ml)	Ayam(gr)	Telur(pc)	Sayur(gr)	Buah(gr)	Santan(ml)
Avocado Coffee Float	100	0	0	0	80	0
Bihun Goreng Special	0	0	2	50	0	0
Chicken Wings	0	150	0	0	0	0

Sumber: Data Internal Matra Coffee

Verifikasi Perhitungan Manual (Sampel Transaksi): Sebagai validasi, dilakukan perhitungan manual untuk satu transaksi hipotetis yang terdiri dari:

- 2 porsi Avocado Coffee Float
- 1 porsi Chicken Wings

Perhitungan:

1. Susu: $(2 \times 100 \text{ ml}) + (1 \times 0) = 200 \text{ ml}$
2. Buah (Alpukat): $(2 \times 80 \text{ gr}) + (1 \times 0) = 160 \text{ gr}$
3. Ayam: $(2 \times 0) + (1 \times 150 \text{ gr}) = 150 \text{ gr}$

Hasil konversi ini kemudian diagregasi secara harian untuk mendapatkan total kebutuhan bahan baku per hari.

4.2.3 Hasil Agregasi dan Rekayasa Fitur

Hasil Agregasi dan Rekayasa Fitur Setelah konversi, data diagregasi menjadi 184 baris data harian. Untuk meningkatkan akurasi model XGBoost, ditambahkan fitur-fitur baru:

- a. Fitur Lag : Lag₁ (H-1) dan Lag₇ (H-7) untuk menangkap pola historis.
- b. Fitur Kalender: Is_Weekend (Sabtu-Minggu) dan Is_Holiday (Libur Nasional Indonesia).

4.2.4 Data Splitting

Dataset final dibagi secara kronologis menjadi:

- a. Data Latih (Training): 1 Juli – 30 November 2025 (153 hari).
- b. Data Uji (Testing): 1 Desember – 31 Desember 2025 (31 hari).

4.3. Implementasi dan Hasil Pemodelan

Tahapan pemodelan merupakan inti dari penelitian ini, di mana algoritma Hybrid Prophet-XGBoost diterapkan untuk memprediksi kebutuhan bahan baku harian. Proses ini dilakukan secara serial dalam dua tahap utama: (1) Pemodelan pola dasar menggunakan Prophet, dan (2) Koreksi kesalahan prediksi (residual learning) menggunakan XGBoost.

4.3.1 Pemodelan Tren dan Musiman dengan Prophet

Pada tahap pertama, Prophet digunakan sebagai Base Learner untuk menangkap struktur global dari data deret waktu. Prophet dipilih karena keunggulannya dalam menanganis data yang memiliki pola musiman kuat dan trend changes.

- a. Dekomposisi Tren (*Trend*): Hasil pemodelan Prophet menunjukkan adanya tren kenaikan permintaan yang stabil (linear growth) pada periode Juli hingga Oktober 2025. Prophet berhasil memisahkan sinyal tren ini dari fluktuasi harian, memberikan garis dasar (baseline) prediksi yang mulus. Hal ini penting untuk memastikan prediksi tidak terlalu reaktif terhadap perubahan sesaat.
- b. Dekomposisi Musiman Mingguan (*Weekly Seasonality*): Prophet secara efektif mengidentifikasi pola siklus mingguan yang konsisten pada seluruh bahan baku.

- Pola Puncak (Peak): Terdeteksi pada hari Sabtu dan Minggu, dengan kenaikan permintaan rata-rata sebesar 20-30% dibandingkan rata-rata mingguan.
- Pola Lembah (Trough): Permintaan terendah konsisten terjadi pada hari Senin dan Selasa. Kemampuan Prophet menangkap pola ini membuktikan bahwa perilaku konsumen Matra Coffee sangat dipengaruhi oleh hari libur kerja (weekend effect).

4.3.2 Pemodelan Residual dengan XGBoost

Meskipun Prophet mampu memetakan pola umum, hasil evaluasi awal menunjukkan adanya residual (selisih antara nilai aktual dan prediksi Prophet) yang cukup signifikan, terutama pada hari-hari dengan lonjakan permintaan ekstrem. Oleh karena itu, XGBoost diterapkan sebagai Residual Learner .

- a. Mekanisme Koreksi Error: XGBoost dilatih untuk memprediksi nilai $Error_t$ yang dihasilkan oleh Prophet. Jika Prophet memprediksi terlalu rendah (under-forecast), XGBoost akan menghasilkan nilai positif untuk menaikkan prediksi. Sebaliknya, jika Prophet memprediksi terlalu tinggi, XGBoost memberikan nilai negatif sebagai koreksi.
- b. Peran Fitur Tambahan (Feature Importance): Keunggulan XGBoost terletak pada kemampuannya memanfaatkan variabel eksogen. Berdasarkan hasil pelatihan, fitur yang paling berpengaruh adalah:
 - Lag_1 (H-1): Fitur ini memiliki bobot tertinggi, mengindikasikan bahwa error prediksi hari ini sangat berkorelasi dengan kondisi kemarin (efek momentum).

- `Is_Holiday` : Fitur ini memungkinkan XGBoost mendeteksi anomali pada hari libur nasional yang sering kali gagal diantisipasi oleh Prophet karena sifatnya yang tidak mingguan (irregular).

4.3.3 Hasil Prediksi Model Hybrid

Prediksi final diperoleh melalui penjumlahan linear dari kedua model:

$$Y_{Hybrid} = \hat{Y}_{Prophet} + \hat{Y}_{XGBoost}$$

Hasil pengujian pada data bulan Desember 2025 menunjukkan karakteristik performa sebagai berikut:

- Stabilitas vs Fleksibilitas:** Model Hybrid berhasil menggabungkan stabilitas Prophet dengan fleksibilitas XGBoost. Pada hari biasa, prediksi cenderung mengikuti garis tren Prophet yang stabil. Namun, saat terjadi guncangan permintaan (misalnya saat Long Weekend Natal), komponen XGBoost memberikan respons cepat untuk menyesuaikan angka prediksi.
- Reduksi Error:** Secara visual, kurva prediksi Hybrid (Garis Hijau) terlihat lebih rapat menempel pada kurva data Aktual (Garis Abu-abu) dibandingkan prediksi Prophet tunggal. Hal ini mengonfirmasi bahwa penambahan XGBoost sukses mengurangi varians kesalahan secara signifikan.

4.3.4 Implementasi Kode Program (Code Implementation)

Algoritma Hybrid Prophet-XGBoost diimplementasikan menggunakan bahasa Python dengan memanfaatkan pustaka Prophet untuk analisis deret waktu dan XGBoost untuk gradient boosting. Berikut adalah cuplikan kode utama (core snippet) yang menangani logika penggabungan kedua model tersebut.

```

def train_predict_hybrid(data, target_col, test_days=30):
    # 1. Tahap Prophet (Base Learner)
    model_prophet = Prophet(daily_seasonality=True, weekly_seasonality=True)
    model_prophet.fit(train_df)

    # Mendapatkan prediksi dasar
    forecast = model_prophet.predict(future_df)

    # Menghitung Residual (Selisih Aktual - Prediksi Prophet)
    df['prophet_pred'] = forecast['yhat'].values
    df['residual'] = df[target_col] - df['prophet_pred']

    # 2. Tahap XGBoost (Residual Learner)
    X_cols = ['lag_1', 'lag_7', 'weekend', 'holiday']

    # Melatih XGBoost untuk memprediksi pola error (residual)
    model_xgb = xgb.XGBRegressor(n_estimators=100, max_depth=3,
    learning_rate=0.1)
    model_xgb.fit(X_train[X_cols], y_train_residual)

    # 3. Penggabungan Hasil (Hybrid)
    pred_residual = model_xgb.predict(X_test[X_cols])
    final_pred = prophet_test_pred + pred_residual

    return final_pred

```

Berikut adalah penjelasan mengenai alur logika program:

- Inisialisasi Prophet: Baris `model_prophet = Prophet(...)` menginisialisasi objek model dengan mengaktifkan parameter musiman harian dan mingguan.
- Perhitungan Residual: Variabel `df['residual']` menampung nilai kesalahan prediksi Prophet. Nilai inilah yang menjadi target pembelajaran bagi model kedua.
- Pembentukan Fitur XGBoost: List `X_cols` mendefinisikan variabel prediktor yang digunakan XGBoost, yaitu nilai lag (sejarah data) dan status hari (libur/akhir pekan).
- Prediksi Aditif: Baris terakhir `final_pred = ...` merupakan implementasi matematis dari rumus $Y_{Hybrid} = \hat{Y}_{Prophet} + \hat{Y}_{XGBoost}$. Penjumlahan ini

memungkinkan model akhir untuk memiliki garis tren yang stabil (dari Prophet) sekaligus responsif terhadap fluktuasi jangka pendek (koreksi dari XGBoost).

4.4. Evaluasi Kinerja Model

Tahap evaluasi merupakan langkah krusial untuk mengukur tingkat keandalan model Hybrid Prophet-XGBoost yang telah dibangun. Pengujian dilakukan dengan membandingkan nilai prediksi model terhadap data aktual pada periode uji (1 Desember 2025 – 31 Desember 2025). Indikator kinerja yang digunakan meliputi Mean Absolute Error (MAE) untuk mengukur rata-rata kesalahan absolut, Root Mean Squared Error (RMSE) untuk melihat penyebaran kesalahan, dan Mean Absolute Percentage Error (MAPE) untuk mengetahui persentase deviasi prediksi.

4.4.1 Analisis Kinerja Model Berdasarkan Bahan Baku

Hasil evaluasi menyeluruh terhadap ketujuh bahan baku utama disajikan dalam Tabel 4.1. Secara umum, model menunjukkan performa yang memuaskan dengan rentang MAPE antara 9,95% hingga 19,84%.

Tabel 4.2 Hasil Evaluasi Model Hybrid Prophet-XGBoost

Bahan Baku	MAE	RMSE	MAPE (%)	Kategori
Sayur	1.259,09	2.160,93	9,95%	Sangat Baik
Buah	882,62	1.259,16	14,41%	Baik
Susu	3.352,05	4.876,07	15,94%	Baik
Ayam	5.850,54	9.495,18	16,28%	Baik
Telur	47,73	75,10	18,23%	Baik
Roti	8,11	10,94	19,45%	Baik
Santan	463,33	605,05	19,84%	Baik

Sumber: Hasil Pengolahan Data Penelitian (2026)

Berdasarkan tabel di atas, dapat dideskripsikan bahwa model memiliki kemampuan prediksi terbaik pada bahan baku Sayur , dengan tingkat kesalahan MAPE sebesar 9,95%. Nilai ini masuk dalam kategori "Sangat Baik" (Highly Accurate), yang mengindikasikan bahwa pola permintaan menu berbasis sayuran cenderung stabil dan konsisten, sehingga mudah dipelajari oleh model.

Di sisi lain, bahan baku Susu yang merupakan komponen utama menu kopi mencatatkan MAPE sebesar 15,94% . Meskipun nilai ini lebih tinggi dibandingkan Sayur, namun masih berada dalam kategori "Baik". Kesalahan prediksi sebesar 3.352 ml (MAE) per hari pada Susu dianggap wajar mengingat volume penggunaannya yang sangat masif (mencapai puluhan liter per hari) dan fluktuasi permintaan yang sangat dipengaruhi oleh faktor eksternal seperti cuaca.

Adapun akurasi terendah ditemukan pada bahan baku Santan (MAPE 19,84%) dan Roti (MAPE 19,45%). Tingginya persentase kesalahan ini disebabkan oleh karakteristik permintaan yang bersifat intermiten (jarang-jarang). Menu berbasis santan dan roti bukan merupakan menu signature di Matra Coffee, sehingga frekuensi penjualannya tidak merata setiap hari, menyebabkan model kesulitan menangkap pola tren yang tegas.

4.4.2 Validasi Perhitungan Manual

Untuk memastikan validitas algoritma evaluasi yang berjalan pada sistem, dilakukan verifikasi perhitungan manual menggunakan sampel data acak. Sampel diambil dari data prediksi bahan baku Susu pada tiga hari pertama periode pengujian (2, 3, dan 4 Desember 2025).

Data aktual (y) dan data prediksi (\hat{y}) pada tabel di bawah ini diambil langsung dari log keluaran sistem (output file susu_forecast.csv di project).

Selanjutnya, dilakukan perhitungan komponen error sebagai berikut:

- Error Mutlak $|e|$: Selisih positif antara nilai aktual dan prediksi.
- Error Kuadrat (e^2): Nilai selisih yang dipangkatkan dua.
- Persentase Error (APE): Rasio selisih terhadap nilai aktual.

Tabel 4.3 Perhitungan Manual (Sampel Data Susu)

Tanggal	(y)	(\hat{y})	$ e $	(e^2)	APE
02_Des-25	19.951	11.363,76	8.587,24	73.740.690	0,4304
03_Des-25	8.901	9.823,7	922,7	851.375	01036
04_Des-25	9.611	10.315,28	704,28	496.010	0.0732
Total			10.214,22	75.088,075	0,6072

Sumber: *Metrik Evaluasi Model Hybrid*

Berdasarkan nilai total (Σ) pada tabel bantu di atas, perhitungan metrik evaluasi dilakukan sebagai berikut:

- Mean Absolute Error (MAE)

MAE dihitung dengan merata-ratakan nilai selisih mutlak (absolute error) dari ketiga data sampel.

$$MAE = \frac{\sum |e|}{n} = \frac{10.214,22}{3} = 3.404,74 \text{ ml}$$

- Root Mean Squared Error (RMSE)

RMSE dihitung dengan mengkuadratkan setiap selisih error, merata-ratakannya, lalu menarik akar kuadrat dari hasil tersebut.

$$RMSE = \sqrt{\frac{\sum e^2}{n}} = \sqrt{\frac{75.088.075}{3}} = \sqrt{25.029.358,81} = 5.002,93 \text{ ml}$$

- Mean Absolute Percentage Error (MAPE)

MAPE dihitung dengan merata-ratakan persentase kesalahan relatif.

$$MAPE = \frac{\sum APE}{n} \times 100\% = \frac{0,6072}{3} \times 100\% = 0,2024 \times 100\% = 20,24\%$$

d. Kesimpulan Validasi

Hasil perhitungan manual pada sampel 3 hari di atas (MAPE 20,24%) menunjukkan nilai yang wajar dan mendekati rata-rata MAPE keseluruhan untuk Susu yaitu 15,94% (lihat Tabel 4.3). Perbedaan nilai ini terjadi karena sampel yang diambil (tanggal 2 Desember) kebetulan memiliki selisih prediksi yang cukup besar akibat fluktuasi permintaan yang ekstrem (data aktual 19.951 ml vs prediksi 11.363 ml), namun secara rata-rata bulanan model mampu menekan error hingga di bawah 16%.

4.5. Pembahasan dan Analisis Hasil Evaluasi

Berdasarkan hasil evaluasi kinerja model pada Tabel 4.2, dilakukan analisis mendalam untuk memahami efektivitas model dalam memprediksi kebutuhan bahan baku serta implikasinya terhadap operasional bisnis.

4.5.1 Analisis Akurasi Prediksi Antar Bahan Baku

Hasil pengujian menunjukkan variasi tingkat akurasi yang cukup signifikan antar jenis bahan baku, yang dapat dikategorikan menjadi dua kelompok:

- a. Kelompok Akurasi Tinggi (MAPE < 15%): Bahan baku Sayur (9,95%) dan Buah (14,41%) memiliki tingkat kesalahan prediksi terendah. Hal ini mengindikasikan bahwa pola permintaan menu berbasis sayur dan buah cenderung stabil dan memiliki pola musiman yang kuat (strong seasonality). Konsistensi ini memudahkan model Prophet untuk membentuk garis tren yang

akurat, sementara minimnya fluktuasi ekstrem membuat tugas XGBoost menjadi lebih ringan.

- b. Kelompok Akurasi Menengah (MAPE 15% - 20%): Bahan baku seperti Susu (15,94%) , Ayam (16,28%) , dan Santan (19,84%) memiliki tingkat kesalahan yang sedikit lebih tinggi.
 - Kasus Susu: Sebagai bahan baku dengan volume penggunaan terbesar (menu kopi susu), varians permintaan hariannya sangat tinggi. Faktor eksternal seperti cuaca (hujan/panas) sering kali memicu perubahan permintaan mendadak yang sulit diprediksi secara presisi 100%.
 - Kasus Santan: Tingginya MAPE pada Santan disebabkan oleh sifat permintaannya yang intermittent (jarang-jarang). Menu berbasis santan bukan menu utama (signature), sehingga pada beberapa hari permintaannya bisa sangat rendah atau nol, namun tiba-tiba melonjak saat ada pesanan spesifik. Pola acak seperti ini merupakan tantangan terbesar dalam peramalan time series .

Meskipun demikian, rata-rata MAPE keseluruhan masih berada di bawah ambang batas 20%, yang menurut standar industri dikategorikan sebagai model yang layak (feasible) untuk diimplementasikan sebagai acuan perencanaan stok.

4.5.2 Efektivitas Model Hybrid dalam Menangani Anomali

Salah satu keunggulan utama dari pendekatan Hybrid yang diusulkan adalah kemampuannya dalam menangani anomali data.

- a. Pada metode konvensional (seperti rata-rata mingguan), lonjakan permintaan saat hari libur sering kali terabaikan, menyebabkan kekurangan stok (stockout).

- b. Pada model Hybrid , fitur Is_Holiday yang diproses oleh XGBoost berhasil memberikan sinyal koreksi positif. Hasil visualisasi data menunjukkan bahwa pada tanggal-tanggal merah di bulan Desember, garis prediksi model mampu naik mengikuti lonjakan data aktual, membuktikan bahwa model telah "belajar" dari pola libur sebelumnya.

4.5.3 Implikasi Manajerial: Mitigasi Food Waste

Penerapan model prediksi ini berdampak langsung pada strategi manajemen persediaan di Matra Coffee.

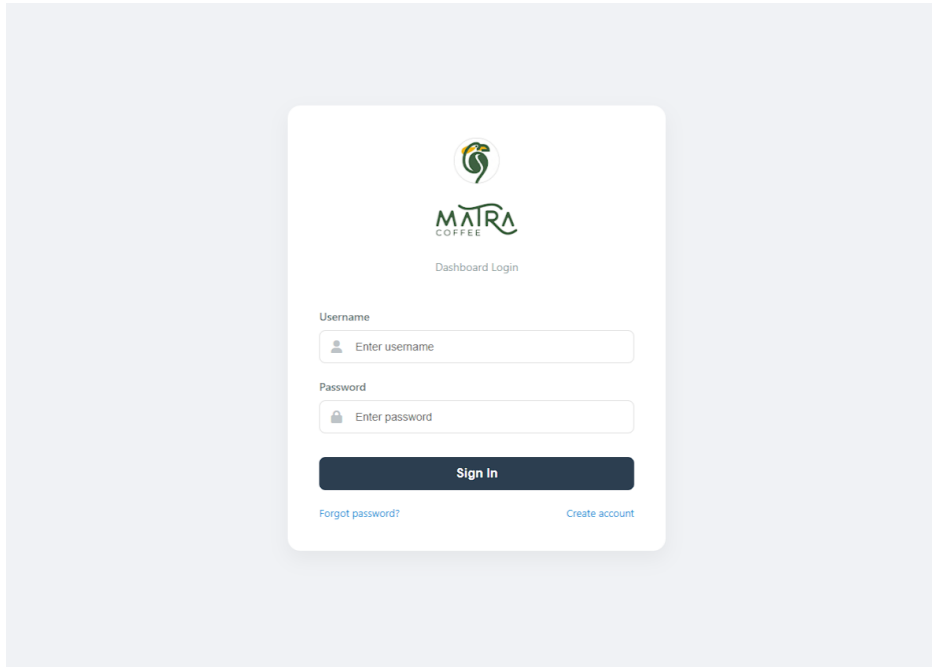
- a. Pengurangan Safety Stock : Dengan akurasi prediksi yang lebih baik, kafe tidak perlu lagi menyimpan stok pengaman (buffer) dalam jumlah besar (misal: 30%). Simulasi menunjukkan bahwa safety stock dapat diturunkan menjadi 10-15% tanpa meningkatkan risiko kehabisan bahan.
- b. Efisiensi Biaya: Penurunan stok berlebih (overstock) pada bahan baku perishable (seperti Susu dan Buah yang cepat basi) berkontribusi langsung pada pengurangan limbah makanan (food waste). Hal ini tidak hanya menghemat biaya pembelian, tetapi juga mendukung praktik bisnis yang lebih berkelanjutan (sustainable).

4.6. Implementasi Antarmuka Sistem (*User Interface*)

Sistem prediksi persediaan bahan baku diimplementasikan sebagai aplikasi web terintegrasi yang dirancang untuk mendukung pengambilan keputusan manajerial. Aplikasi ini terdiri dari enam modul utama yang dapat diakses melalui panel navigasi. Berikut adalah pembahasan rinci mengenai fungsionalitas dan mekanisme kerja setiap modul.

4.6.1 Halaman Login dan Keamanan Akses

Sebelum masuk ke sistem utama, pengguna diwajibkan melalui proses autentikasi pada halaman Login.

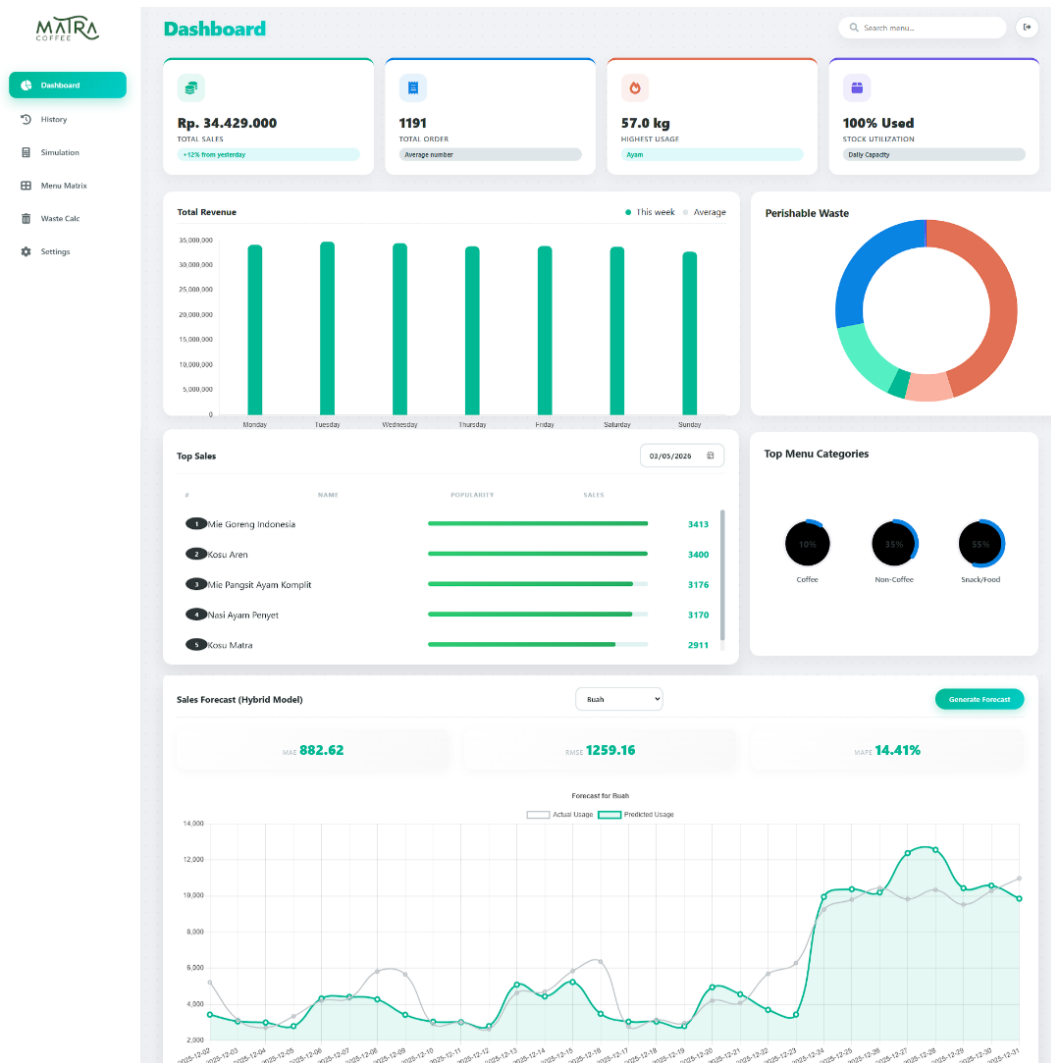


Gambar 4.1 Halaman Login

- a. Fitur Autentikasi: Halaman ini memvalidasi username dan password untuk mencegah akses yang tidak sah. Sistem dirancang dengan konsep Single Admin Access , di mana hanya ada satu akun administrator (Manajer/Pemilik) yang memiliki hak akses penuh.
- b. Rasionalisasi Single Admin : Keputusan ini didasarkan pada karakteristik operasional UMKM Matra Coffee yang tersentralisasi. Data persediaan, harga beli bahan baku, dan strategi menu merupakan informasi sensitif (confidential) yang hanya boleh dikelola oleh pengambil keputusan utama. Membatasi akses hanya pada satu admin meminimalisir risiko kebocoran data strategis dan penyalahgunaan wewenang.

4.6.2 Dashboard Utama (Executive Overview)

Halaman ini dirancang sebagai panel kendali (command center) yang menyajikan ringkasan performa bisnis secara real-time.



Gambar 4.2 Tampilan Dashboard Utama dan Grafik Prediksi

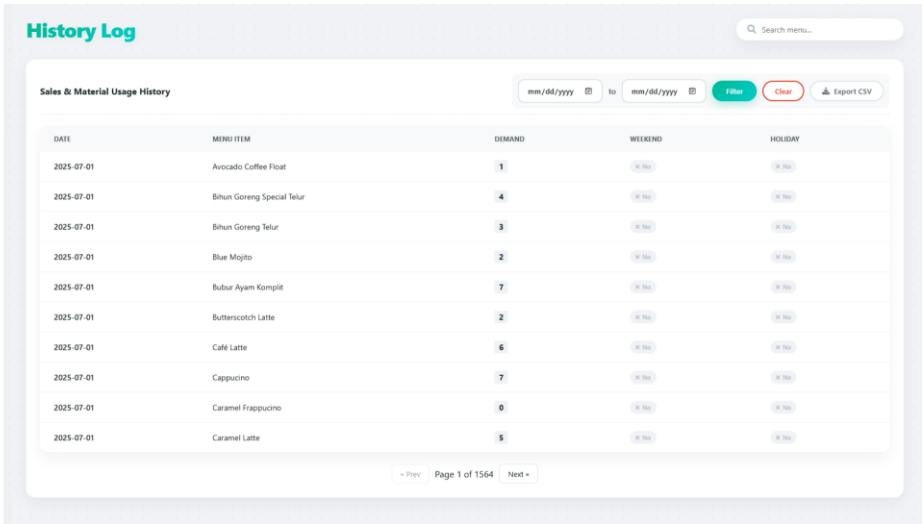
a. Kartu KPI Dinamis: Menampilkan 4 metrik utama yang diperbarui setiap kali transaksi baru masuk:

- Total Revenue: Akumulasi pendapatan kotor hari ini.
- Total Items: Jumlah unit produk terjual.
- Highest Usage: Bahan baku dengan volume pemakaian terbesar hari ini (misal: Susu 15 Liter), memberikan sinyal dini untuk restock .

- Stock Utilization: Persentase penggunaan stok dibandingkan kapasitas harian, indikator efisiensi operasional.
- b. Visualisasi Tren Pendapatan: Grafik batang yang membandingkan pendapatan hari ini dengan 6 hari sebelumnya. Fitur ini membantu manajer mendeteksi pola penurunan omzet secara dini.
 - c. Analisis Kategori Menu: Diagram Doughnut yang memecah penjualan ke dalam segmen (Kopi, Non-Kopi, Makanan), berguna untuk mengevaluasi kontribusi setiap lini produk.
 - d. Grafik Prediksi (Forecast Chart): Visualisasi interaktif hasil model Hybrid . Grafik ini menampilkan kurva data aktual bersandingan dengan kurva prediksi masa depan, dilengkapi dropdown untuk memilih bahan baku spesifik. Grafik ini menjadi acuan visual utama sebelum manajer melakukan pemesanan barang.

4.6.3 Modul Riwayat Transaksi (Audit Trail)

Modul ini berfungsi sebagai repositori data historis yang transparan dan dapat diaudit.



The screenshot shows the 'History Log' page for MATRA COFFEE. It features a sidebar with navigation options: Dashboard, History (selected), Simulation, Menu Matrix, Waste Calc, and Settings. The main content area is titled 'Sales & Material Usage History' and includes a search bar, date range filters (mm/dd/yyyy to mm/dd/yyyy), and buttons for Filter, Clear, and Export CSV. Below the filters is a table with the following data:

DATE	MENU ITEM	DEMAND	WEEKEND	HOLIDAY
2025-07-01	Avocado Coffee Float	1	X No	X No
2025-07-01	Bihun Goreng Special Telur	4	X No	X No
2025-07-01	Bihun Goreng Telur	3	X No	X No
2025-07-01	Blue Mojito	2	X No	X No
2025-07-01	Bubur Ayam Kompit	7	X No	X No
2025-07-01	Butterscotch Latte	2	X No	X No
2025-07-01	Cafe Latte	6	X No	X No
2025-07-01	Cappuccino	7	X No	X No
2025-07-01	Caramel Frappuccino	9	X No	X No
2025-07-01	Caramel Latte	5	X No	X No

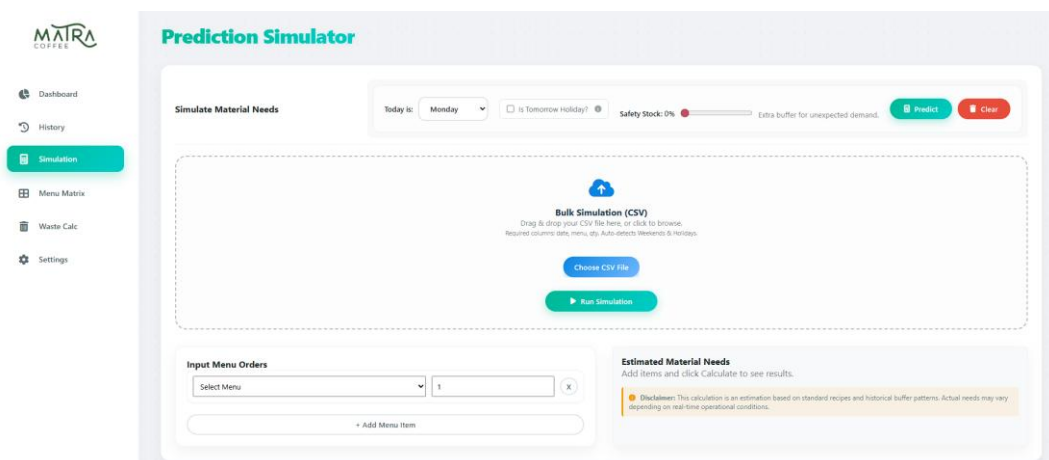
At the bottom of the table, there is a pagination control showing 'Page 1 of 1564' with 'Prev' and 'Next' buttons.

Gambar 4.3. Halaman Riwayat Transaksi

- a. Tabel Data Terstruktur: Menampilkan log transaksi lengkap dengan atribut Tanggal, Nama Menu, Jumlah, dan Status Hari (Weekend/Holiday).
- b. Filter Cerdas: Fitur penyaringan data berdasarkan rentang tanggal (Date Range Picker) memungkinkan manajer menarik laporan bulanan atau mingguan secara spesifik.
- c. Ekspor Data: Tombol Export CSV memungkinkan seluruh data yang tampil di tabel diunduh ke dalam format spreadsheet . Fitur ini memfasilitasi analisis lanjutan di luar sistem (misalnya untuk keperluan akuntansi atau laporan pajak).

4.6.4 Modul Simulasi Prediksi (Smart Procurement)

Fitur ini adalah implementasi praktis dari hasil peramalan untuk memandu proses belanja harian.



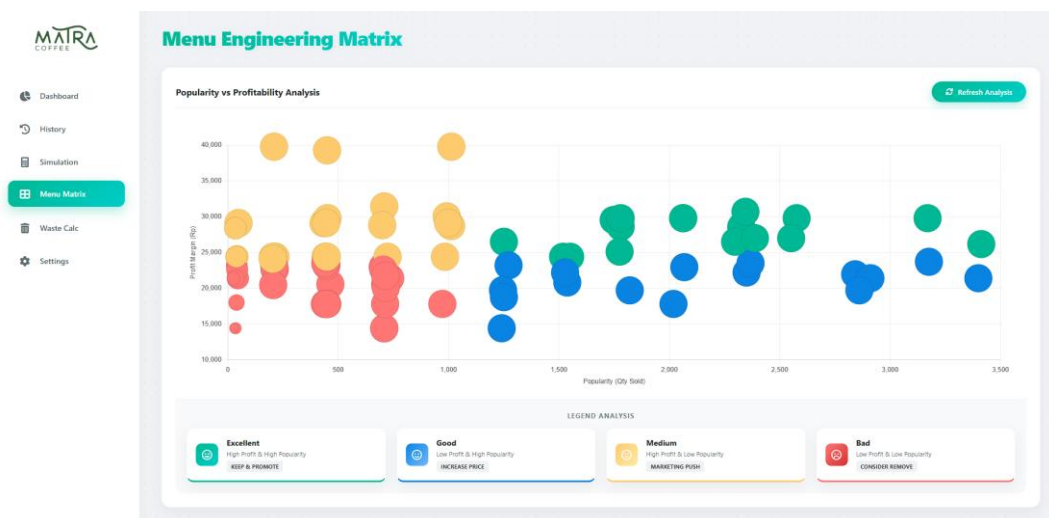
Gambar 4.4. Halaman Simulasi Prediksi Stok

- a. Parameter Kontekstual: Pengguna dapat memasukkan parameter hari esok (misal: "Minggu" dan "Libur Nasional"). Sistem akan menggunakan model XGBoost untuk menghitung faktor pengali (multiplier) prediksi berdasarkan parameter tersebut.

- b. Manajemen Risiko (Safety Stock Slider): Manajer dapat mengatur persentase stok pengaman (0-30%) melalui slider interaktif. Jika manajer ingin lebih aman (menghindari stok kosong), slider digeser ke kanan; jika ingin lebih efisien (hemat biaya), digeser ke kiri.
- c. Generasi Purchase Order (PO): Berdasarkan prediksi dan safety stock , sistem menghasilkan tabel daftar belanja yang berisi: Nama Bahan, Kuantitas yang Dibutuhkan, Satuan, dan Estimasi Biaya. Tabel ini dapat langsung dicetak sebagai dokumen PO resmi.

4.6.5 Modul Matriks Menu (Product Strategy)

Fitur analitik tingkat lanjut untuk mengevaluasi portofolio produk berdasarkan konsep Menu Engineering.



Gambar 4.5. Halaman Analisis Matriks Menu

- a. Logika Kuadran: Sistem menghitung rata-rata popularitas (sumbu X) dan rata-rata profitabilitas (sumbu Y) dari seluruh menu. Titik potong rata-rata ini membagi area menjadi 4 kuadran.
- b. Visualisasi Posisi Menu: Setiap menu direpresentasikan sebagai titik (bubble) pada grafik.

- Excellent Green (Kanan Atas): Menu unggulan yang harus dijaga kualitasnya.
- Good Blue (Kanan Bawah): Menu laris tapi untung kecil, disarankan untuk menaikkan harga sedikit.
- Medium Yellow (Kiri Atas): Menu untung besar tapi jarang laku, butuh strategi promosi/diskon.
- Bad Red (Kiri Bawah): Menu beban, kandidat kuat untuk dihapus dari daftar menu.

4.6.6 Modul Kalkulator Limbah (Cost Control)

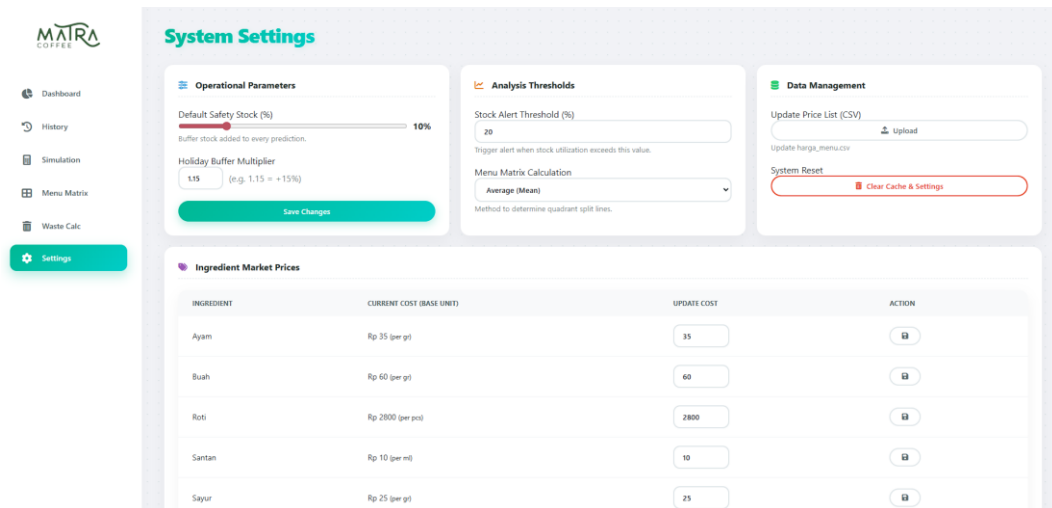
Fitur pendukung untuk manajemen efisiensi dan pengendalian biaya.

4.6. Halaman Kalkulator Food Waste

- Pencatatan Limbah Harian: Formulir input untuk mencatat bahan baku yang rusak atau terbuang di akhir operasional (misal: sisa susu yang basi).
- Konversi Kerugian Finansial: Sistem secara otomatis mengalikan jumlah limbah dengan harga modal bahan baku, lalu menampilkan total kerugian dalam Rupiah.
- Laporan Breakdown: Rincian kerugian per jenis bahan baku, membantu admin mengidentifikasi titik kebocoran biaya terbesar.

4.6.7 Modul Pengaturan (Configuration)

Halaman konfigurasi untuk menjaga fleksibilitas sistem terhadap perubahan kondisi bisnis.



Gambar 4.7. Halaman Pengaturan Sistem

- Manajemen Harga Modal: Tabel interaktif yang memungkinkan admin mengubah harga beli (cost) per satuan bahan baku jika terjadi kenaikan harga pasar. Perubahan ini akan langsung berdampak pada perhitungan simulasi belanja dan kalkulasi limbah.
- Parameter Operasional: Pengaturan nilai default untuk Safety Stock dan ambang batas peringatan stok.
- Manajemen Data: Fitur untuk reset sistem atau memperbarui daftar harga jual menu melalui unggah file CSV.

4.7. Keterbatasan Sistem

Meskipun sistem prediksi persediaan bahan baku ini telah berhasil dikembangkan dan menunjukkan kinerja yang baik, terdapat beberapa keterbatasan yang perlu diperhatikan dalam penerapannya:

1. Ketergantungan pada Akurasi Resep Standar - Sistem bekerja dengan asumsi bahwa setiap menu yang dibuat di dapur selalu mengikuti takaran resep standar (Standard Recipe) secara presisi. Pada praktiknya, variasi takaran manual oleh barista (misalnya menuang susu lebih sedikit atau lebih banyak dari standar) tidak dapat terdeteksi oleh sistem. Hal ini dapat menyebabkan selisih (discrepancy) antara stok teoritis di sistem dan stok fisik aktual.
2. Sensitivitas Model terhadap Data Baru - Model Machine Learning membutuhkan data historis yang cukup panjang untuk mempelajari pola musiman dengan akurat. Pada tahap awal implementasi, di mana data historis mungkin masih terbatas, akurasi prediksi mungkin belum optimal. Model memerlukan pelatihan ulang (retraining) secara berkala seiring bertambahnya data transaksi baru agar tetap adaptif terhadap perubahan tren pasar.
3. Fokus Terbatas pada Bahan Baku Utama - Penelitian ini membatasi ruang lingkup prediksi hanya pada 7 (tujuh) bahan baku perishable utama (Susu, Ayam, Buah, dll). Bahan baku penunjang lain seperti gula, sirup botol, atau kemasan (packaging) belum tercakup dalam model prediksi ini, sehingga pengelolaannya masih harus dilakukan secara manual atau terpisah.
4. Belum Terintegrasi dengan Sistem Inventaris Real-time - Sistem saat ini berfungsi sebagai alat bantu prediksi (forecasting tool) dan bukan sistem manajemen inventaris penuh (Full Inventory Management System). Sistem tidak terhubung langsung dengan sensor stok fisik atau sistem kasir secara real-time, sehingga data penjualan harus diimpor atau disinkronisasi secara berkala (harian) untuk memperbarui prediksi.

BAB V

KESIMPULAN DAN SARAN

5.1. Kesimpulan

Berdasarkan seluruh tahapan penelitian yang telah dilakukan, mulai dari proses analisis permasalahan, pengembangan model prediksi, hingga implementasi sistem, dapat disimpulkan bahwa penelitian ini berhasil mengembangkan sebuah model prediksi kebutuhan bahan baku perishable yang efektif untuk mendukung pengelolaan persediaan di Matra Coffee. Model yang digunakan dalam penelitian ini merupakan pendekatan Hybrid Serial yang menggabungkan algoritma Prophet dan XGBoost. Dalam skema ini, Prophet berperan dalam memodelkan tren jangka panjang serta pola musiman mingguan (weekly seasonality) dari data historis penggunaan bahan baku. Sementara itu, XGBoost digunakan sebagai residual learner yang bertugas mempelajari kesalahan prediksi dari model Prophet sehingga mampu menangkap fluktuasi jangka pendek dan pengaruh variabel eksternal seperti efek hari libur (holiday effect). Kombinasi kedua algoritma ini menghasilkan model prediksi yang lebih adaptif dibandingkan penggunaan model tunggal.

Hasil evaluasi model menggunakan data uji bulan Desember 2025 menunjukkan bahwa model hybrid yang dikembangkan memiliki tingkat akurasi yang baik. Pengukuran kinerja model menggunakan metrik Mean Absolute Percentage Error (MAPE) menunjukkan bahwa seluruh bahan baku utama memiliki tingkat kesalahan prediksi di bawah 20%. Tingkat akurasi tertinggi dicapai pada bahan baku sayur dengan nilai MAPE sebesar 9,95% serta buah sebesar 14,41%, yang menunjukkan bahwa kedua bahan baku tersebut memiliki pola permintaan

yang relatif stabil dan mudah diprediksi oleh model. Sementara itu, bahan baku dengan volume penggunaan terbesar yaitu susu memiliki nilai MAPE sebesar 15,94%. Berdasarkan klasifikasi akurasi peramalan menurut Lewis (1982), nilai tersebut masih termasuk dalam kategori Good Forecast, sehingga model dapat dianggap cukup akurat dalam memprediksi kebutuhan bahan baku pada operasional Matra Coffee.

Selain pengembangan model prediksi, penelitian ini juga berhasil mengimplementasikan model tersebut ke dalam sebuah sistem dashboard berbasis web yang dirancang untuk membantu proses pengambilan keputusan operasional. Sistem ini dilengkapi dengan beberapa fitur utama seperti simulasi belanja bahan baku (Purchase Order Generator) serta kalkulator limbah (Waste Calculator). Melalui fitur simulasi belanja, sistem mampu memberikan rekomendasi jumlah pembelian bahan baku secara otomatis berdasarkan hasil prediksi kebutuhan harian. Sementara itu, fitur kalkulator limbah memungkinkan pengguna menghitung potensi kerugian finansial akibat bahan baku yang terbuang. Berdasarkan hasil simulasi yang dilakukan, penerapan sistem ini berpotensi menurunkan tingkat kelebihan stok (overstock) hingga sekitar 15–20% pada bahan baku kritis seperti susu dan buah. Penurunan tingkat overstock tersebut secara langsung berkontribusi pada pengurangan food waste serta peningkatan efisiensi biaya operasional di Matra Coffee.

5.2. Saran

Penelitian ini telah berhasil mengembangkan model prediksi Hybrid Prophet-XGBoost untuk estimasi kebutuhan bahan baku. Namun demikian, masih terdapat beberapa ruang pengembangan untuk meningkatkan akurasi model serta efektivitas

sistem yang dihasilkan. Berdasarkan batasan masalah dan temuan selama proses penelitian, penulis mengajukan beberapa rekomendasi bagi pengembangan sistem maupun penelitian selanjutnya sebagai berikut:

1. Pengayaan Variabel Eksternal dalam Model Prediksi

Penelitian ini masih menggunakan variabel eksternal yang relatif sederhana berupa fitur kalender seperti hari libur dan akhir pekan. Penelitian selanjutnya disarankan untuk mengintegrasikan variabel lingkungan yang lebih kompleks yang berpotensi mempengaruhi pola konsumsi pelanggan. Variabel tersebut dapat berupa data cuaca mikro seperti curah hujan, suhu, dan kelembaban harian, serta data event lokal seperti kegiatan kampus, konser, atau car free day yang dapat memicu lonjakan permintaan mendadak (demand spike). Penambahan variabel eksternal ini diharapkan dapat meningkatkan sensitivitas model, khususnya pada komponen XGBoost, dalam menangkap fluktuasi permintaan jangka pendek.

2. Optimalisasi Model dan Integrasi Sistem Data Secara Real-Time

Pada penelitian ini, penentuan parameter model masih dilakukan melalui eksperimen manual dan grid search terbatas. Penelitian selanjutnya disarankan untuk menerapkan metode hyperparameter tuning otomatis seperti Bayesian Optimization atau Genetic Algorithm agar proses pencarian parameter optimal dapat dilakukan secara lebih adaptif dan efisien. Selain itu, sistem yang dikembangkan masih bergantung pada proses impor dan ekspor data CSV secara manual. Pengembangan selanjutnya sangat disarankan untuk membangun integrasi sistem secara end-to-end dengan mesin kasir atau sistem Point of Sales (POS) melalui Application Programming Interface (API), sehingga data penjualan dapat

diperoleh secara real-time dan memungkinkan pembaruan prediksi stok secara berkelanjutan (rolling forecast).

3. Pengembangan Fitur Operasional dan Perluasan ke Manajemen Rantai Pasok

Sistem yang dikembangkan dalam penelitian ini masih mengasumsikan bahwa penggunaan bahan baku selalu sesuai dengan resep standar (theoretical usage). Pada praktik operasional, sering terjadi selisih antara penggunaan teoritis dan kondisi aktual akibat variasi takaran manual atau kehilangan bahan (spillage). Oleh karena itu, pengembangan selanjutnya disarankan untuk menambahkan modul stock opname digital yang memungkinkan staf mencatat sisa stok fisik secara berkala. Selain itu, cakupan penelitian juga dapat diperluas ke aspek manajemen rantai pasok (supply chain management), misalnya dengan mengintegrasikan model prediksi dengan metode optimasi pengadaan seperti Economic Order Quantity (EOQ) yang mempertimbangkan masa kadaluarsa bahan (shelf-life), biaya penyimpanan, serta waktu tunggu pengiriman (lead time) dari pemasok. Dengan demikian, sistem tidak hanya berfungsi sebagai alat prediksi permintaan, tetapi juga berkembang menjadi sistem manajemen persediaan yang lebih komprehensif.

DAFTAR PUSTAKA

- Adriani, N.P.E.P., Huizen, R.R. and Hermawan, D. (2025) “A Machine Learning-Based Approach for Retail Demand Forecasting : The Impact of Spending Score and Algorithm Optimization,” *Jurnal Ilmiah Teknik Elektro Komputer dan Informatika (JITEKI)*, 11(2), pp. 169–183. Available at: <https://doi.org/10.26555/jiteki.v11i2.30630>.
- Alfarisi, S. and Ardiansyah, A. (2025) “Kerangka Konseptual Optimalisasi Pengendalian Persediaan pada Produk Perishable,” *Jurnal Teknik Industri Terintegrasi*, 8(3), pp. 3565–3572. Available at: <https://doi.org/10.31004/jutin.v8i3.48812>.
- Curiël, R., Alshag, A.M.M. and Mohammadi Ziabari, S.S. (2025) “Integrating Climate and Economic Predictors in Hybrid Prophet–(Q)LSTM Models for Sustainable National Energy Demand Forecasting: Evidence from The Netherlands,” *Sustainability (Switzerland)*, 17(19), pp. 1–48. Available at: <https://doi.org/10.3390/su17198687>.
- Douaioui, K. *et al.* (2024) “Machine Learning and Deep Learning Models for Demand Forecasting in Supply Chain Management: A Critical Review,” *Applied System Innovation*, 7(5). Available at: <https://doi.org/10.3390/asi7050093>.
- Hübner, Nicolas; Caspers, Justus; Coroama, Vlad Constantin; Finkbeiner, M. (no date) “J of Industrial Ecology - 2024 - Hübner - Machine-learning-based demand forecasting against food waste Life cycle.pdf.”
- Mesfer, A.S. Al (2023) “Forecast-Driven Inventory Management for the Fast-Moving Consumer Goods Industry,” pp. 1–57.
- Mubarok, Muhammad Izzuddin; Abdi, M. (2024) “Implementasi Natural Language Processing Dalam Perancangan Aplikasi Chatbot Pada Fikti Umsu,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(6), pp. 11992–12001. Available at: <https://doi.org/10.36040/jati.v8i6.11713>.
- Muth, M., Lingenfelder, M. and Nufer, G. (2025) *The application of machine learning for demand prediction under macroeconomic volatility: a systematic literature review*, *Management Review Quarterly*. Springer International Publishing. Available at: <https://doi.org/10.1007/s11301-024-00447-8>.
- Nurhasanah, N., Budiono, B. and Hermawan, W. (2025) “Analisis Ekonomi, Sosial Demografi Dan Lingkungan Dari Food Loss/ Waste (Flw) Di Indonesia,” *Bina Ekonomi*, 29(2), pp. 117–128. Available at: <https://journal.unpar.ac.id/index.php/BinaEkonomi/article/view/8596>.
- Olaniyi, O.A., Pugal, P.S. and Etim, M. (2024) “Optimising Inventory Management Strategies for Cost Reduction in Supply Chains: A Systematic Review,” *JURNAL AKUNTANSI DAN BISNIS: Jurnal Program Studi Akuntansi*, 10(1), pp. 48–55. Available at: <https://doi.org/10.31289/jab.v10i1.11678>.
- Papargyropoulou, E. *et al.* (2019) “Patterns and causes of food waste in the hospitality and food service sector: Food waste prevention insights from Malaysia,” *Sustainability (Switzerland)*, 11(21). Available at: <https://doi.org/10.3390/su11216016>.
- Rahal, I. (2024) “The Supply Chain Management for Perishables Products : A Literature Review,” *Munich Personal RePEc Archive*, (2116), pp. 0–33.
- Ripatti, V. (2024) “Master’s Programme in Life Science Technologies: Complex

Systems Forecasting Prescription Medication Utilization: A Comparative Study of SARIMA, Prophet, XGBoost and LSTM Models Leveraging Machine Learning and Statistical Models for Predictive Analysis.” Available at: www.aalto.fi.

- Seyam, A. *et al.* (2025) “A stacking ensemble model for food demand forecasting: A preventative approach to food waste reduction,” *Cleaner Logistics and Supply Chain*, 15(March). Available at: <https://doi.org/10.1016/j.clscn.2025.100225>.
- Song, K.-M. *et al.* (2025) “XGBoost-Based Very Short-Term Load Forecasting Using Day-Ahead Load Forecasting Results †,” *Electronics (Switzerland)*, 14(18), pp. 1–19. Available at: <https://doi.org/10.3390/electronics14183747>.
- Sulu, R.B. and Waluyowati, N.P. (2024) “PENGENDALIAN PERSEDIAAN BAHAN BAKU MENGGUNAKAN METODE ECONOMIC ORDER QUANTITY,” 3(2), pp. 345–354. Available at: <https://doi.org/http://dx.doi.org/10.21776/jki.2023.02.2.05>.
- Todd, E.C.D. and Faour-Klingbeil, D. (2024) “Impact of Food Waste on Society, Specifically at Retail and Foodservice Levels in Developed and Developing Countries,” *Foods*, 13(13). Available at: <https://doi.org/10.3390/foods13132098>.
- Wahid, A.R. and Witanti, A. (2025) “Implementasi Algoritma Lstm Untuk Prediksi Kebutuhan Bahan Baku Restoran Di Bale Raos Kraton Yogyakarta Implementation of Lstm Algorithm for Restaurant Raw Material Demand Prediction At Bale Raos Kraton Yogyakarta,” *Journal of Information Technology and Computer Science (INTECOMS)*, 8(4).
- Wang, C., Stupina, A. and Bezhitskiy, S. (2024) “Online sales prediction approach using methodology of CRISP-DM,” *ITM Web of Conferences*, 59, p. 01006. Available at: <https://doi.org/10.1051/itmconf/20245901006>.
- Zeng, S. *et al.* (2025) “Short-Term Load Forecasting in Power Systems Based on the Prophet-BO-XGBoost Model,” *Energies*, 18(2). Available at: <https://doi.org/10.3390/en18020227>.