

**PENERAPAN DALAM PEMBANGUNAN SISTEM PREDIKSI
PERMINTAAN BARANG DENGAN OPTIMASI
MANAJEMEN STOK MENGGUNAKAN
ALGORITMA ENSEMBLE
LEARNING**

SKRIPSI

DISUSUN OLEH

SALSHA UTAMI

2209020216



UMSU

Unggul | Cerdas | Terpercaya

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

MEDAN

2026

**PENERAPAN DALAM PEMBANGUNAN SISTEM PREDIKSI
PERMINTAAN BARANG DENGAN OPTIMASI
MANAJEMEN STOK MENGGUNAKAN
ALGORITMA ENSEMBLE
LEARNING**

SKRIPSI

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

SALSHA UTAMI

2209020216

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

MEDAN

2026

LEMBAR PENGESAHAN

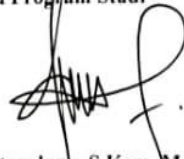
Judul Skripsi : PENERAPAN DALAM PEMBANGUNAN SISTEM
PREDIKSI PERMINTAAN BARANG DENGAN
OPTIMASI MANAJEMEN STOK MENGGUNAKAN
ALGORITMA ENSEMBLE LEARNING
Nama Mahasiswa : SALSHA UTAMI
NPM : 2209020216
Program Studi : TEKNOLOGI INFORMASI

Menyetujui
Komisi Pembimbing



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

Ketua Program Studi



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

Dekan



(Dyah Khusnurza, S.Kom, M.Kom.)
NIDN. 0127099201

PERNYATAAN ORISINALITAS

PENERAPAN DALAM PEMBANGUNAN SISTEM PREDIKSI PERMINTAAN BARANG DENGAN OPTIMASI MANAJEMEN STOK MENGGUNAKAN ALGORITMA ENSEMBLE LEARNING

SKRIPSI

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

Medan, 14 April 2026

Yang membuat pernyataan



Salsha Utami

NPM. 2209020216

PERNYATAAN PERSETUJUAN PUBLIKASI
KARYA ILMIAH UNTUK KEPENTINGAN
AKADEMIS

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

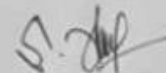
Nama : Salsha Utami
NPM : 2209020216
Program Studi : Teknologi Informasi
Karya Ilmiah : Skripsi

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Muhammadiyah Sumatera Utara Hak Bebas Royalti Non-Eksekutif (*Non-Exclusive Royalty free Right*) atas penelitian skripsi saya yang berjudul: PENERAPAN DALAM PEMBANGUNAN SISTEM PREDIKSI PERMINTAAN BARANG DENGAN OPTIMASI MANAJEMEN STOK MENGGUNAKAN ALGORITMA ENSEMBLE LEARNING. 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, 14 April 2026

Yang membuat pernyataan



Salsha Utami

NPM. 2209020216

RIWAYAT HIDUP

DATA PRIBADI

Nama Lengkap : SALSHA UTAMI
Tempat dan Tanggal Lahir : TANJUNG MORAWA 19-06-2003
Alamat Rumah : Gg. Sejarah Lingkungan II
Telepon/Faks/HP : 092177226392
E-mail : utamisalsha@gmail.com
Instansi Tempat Kerja : -
Alamat Kantor : -

DATA PENDIDIKAN

SD : SD Muhammadiyah TAMAT: 2016
SMP : SMP Nur Azizi TAMAT: 2019
SMK : SMK Taruna Tekno Nusantara TAMAT: 2022

KATA PENGANTAR



Alhamdulillah puji dan syukur peneliti panjatkan kehadirat Allah Subhanahu wa Ta'ala atas segala limpahan rahmat dan hidayah-Nya kepada peneliti sehingga dapat menyelesaikan perkuliahan dan penelitian skripsi ini, dengan judul “**PENERAPAN DALAM PEMBANGUNAN SISTEM PREDIKSI PERMINTAAN BARANG DENGAN OPTIMASI MANAJEMEN STOK MENGGUNAKAN ALGORITMA ENSEMBLE LEARNING**” guna memenuhi salah satu syarat dalam memperoleh gelar Sarjana Komputer pada Fakultas Ilmu Komputer dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara.

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

1. Bapak Prof. Dr. Akrim, M.Pd., Rektor Universitas Muhammadiyah Sumatera Utara (UMSU)
2. Bapak Dr. Al-Khowarizmi, S.Kom., M.Kom. Dekan Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
3. Ibu Dr. Firahti Rizky, S.Kom., M.Kom Wakil Dekan 1 Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
4. Bapak Mhd. Basri, S.Si, M.Kom Wakil Dekan 3 Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
5. Ibu Fatma Sari Hutagalung, S.Kom., M.Kom. Ketua Program Studi Teknologi Informasi, dan juga pembimbing yang sudah senantiasa membimbing penulis dalam menyelesaikan skripsi saya.
6. Bapak Okvi Nugroho, S.Kom., M.Kom. Sekretaris Program Studi Teknologi Informasi.
7. Seluruh dosen dan staf Fakultas Ilmu Komputer dan Teknologi Informasi yang telah dengan tulus memberikan ilmu pengetahuan, bimbingan, bantuan, serta pelayanan yang baik kepada penulis selama menempuh masa perkuliahan, sehingga penulis dapat belajar, berkembang, dan menyelesaikan pendidikan ini dengan baik.

8. Teruntuk cinta pertama dan panutanku, Ayahanda Sujono, terima kasih selalu berjuang untuk kehidupan penulis, beliau memang tidak sempat merasakan pendidikan sampai bangku perkuliahan, namun beliau mampu mendidik penulis, memotivasi, memberikan dukungan dan semangat serta selalu mengajarkan kebaikan dalam hidup penulis sehingga penulis mampu menyelesaikan studinya sampai sarjana.
9. Pintu surgaku, Ibunda tercinta Rahayu Utami Dewi yang selalu menjadi penyemangat penulis dan menjadi sandaran terkuat dari kerasnya dunia. Yang tidak henti-hentinya memberikan kasih sayang dengan penuh cinta dan selalu memberikan motivasi yang luar biasa. Terima kasih untuk segala doa yang selalu diberikan untuk penulis, terimakasih selalu berjuang untuk penulis, berkat doa serta dukungannya sehingga penulis bisa berada dititik ini.
10. Kepada kedua adik kandung penulis, Dwi Arianti dan Abyan Nandana, terima kasih yang senantiasa memberikan dukungan, motivasi, serta meluangkan waktu untuk selalu menghibur penulis ketika hampir menyerah, sehingga penulis dapat menyelesaikan proses penyusunan skripsi ini.
11. Kepada seseorang yang tak kalah penting kehadirannya, Nugi Mulianda. Terima kasih banyak telah menjadi bagian dari perjalanan hidup penulis. Berkontribusi banyak dalam penulisan karya tulis ini, baik tenaga, materi, maupun waktu kepada penulis. Terima kasih sudah selalu mendukung, menghibur, mendengarkan keluh kesah, sehingga penulis dapat menyelesaikan tugas akhir ini.
12. Terakhir, untuk diri saya sendiri Salsha Utami. Terima kasih atas segala kerja keras dan semangatnya sehingga mampu bertahan dan terus melangkah sejauh ini. Terima kasih pada raga dan jiwa yang masih tetap tegar dan ikhlas menjalani semuanya hingga sekarang. Terima kasih telah percaya pada keraguan dan kelelahan dalam setiap proses ini, meskipun jalannya terasa begitu berat. Kedepannya untuk raga yang tetap kuat, hati yang selalu tegar, mari bekerjasama untuk lebih berkembang lagi menjadi pribadi yang lebih baik dari hari ke hari.

PENERAPAN DALAM PEMBANGUNAN SISTEM PREDIKSI PERMINTAAN BARANG DENGAN OPTIMASI MANAJEMEN STOK MENGUNAKAN ALGORITMA ENSEMBLE LEARNING

ABSTRAK

Manajemen stok pada usaha mikro di pasar tradisional masih banyak dilakukan secara intuitif, sehingga berisiko menimbulkan kelebihan stok, kekurangan stok, dan ketidakefisienan penggunaan modal harian. Permasalahan ini semakin kompleks pada toko penjual bahan pelengkap masakan yang menjual produk perishable dan semi-tahan lama dengan pola permintaan yang fluktuatif. Penelitian ini bertujuan membangun sistem prediksi permintaan barang dan optimasi manajemen stok berbasis arus kas pada satu toko pasar tradisional di Tanjung Morawa. Metode yang digunakan adalah Ensemble Learning dengan mengombinasikan Support Vector Regression (SVR) dan Seasonal Autoregressive Integrated Moving Average (SARIMA) melalui mekanisme weighted averaging. Data yang digunakan berupa data penjualan harian per produk selama sekitar 6–12 bulan, serta variabel pendukung seperti hari kerja/libur, hari besar keagamaan, kondisi cuaca, harga beli, dan harga jual. Tahapan penelitian meliputi pengumpulan data, preprocessing, rekayasa fitur, pelatihan model SVR dan SARIMA, penggabungan prediksi ensemble, serta transformasi hasil prediksi ke dalam variabel keuangan berupa kebutuhan modal beli, potensi pendapatan, dan risiko rugi susut. Selanjutnya, hasil prediksi digunakan sebagai input pada optimasi alokasi modal harian menggunakan Linear Programming. Evaluasi model dilakukan menggunakan metrik MAE, RMSE, MAPE, dan R^2 . Penelitian ini diharapkan menghasilkan sistem yang mampu meningkatkan akurasi prediksi permintaan, membantu pedagang mengalokasikan modal secara lebih efisien, mengurangi potensi kerugian akibat stok tidak terjual, serta mendukung pengambilan keputusan yang lebih tepat pada usaha mikro di pasar tradisional.

Kata Kunci: prediksi permintaan, manajemen stok, ensemble learning, SARIMA, optimasi modal, pasar tradisional

APPLICATION IN DEVELOPING A DEMAND SYSTEM WITH OPTIMIZATION OF STOK MANAGEMENT USING ENSEMBLE ALGORITHMS LEARNING

ABSTRACT

Inventory management in micro-enterprises within traditional markets is still largely carried out intuitively, creating risks of overstocking, understocking, and inefficient use of daily working capital. This problem becomes more complex in stores selling cooking complement products that offer perishable and semi-durable goods with fluctuating demand patterns. This study aims to develop a demand forecasting system and cash flow-based inventory management optimization for a traditional market store in Tanjung Morawa. The method used is Ensemble Learning by combining Support Vector Regression (SVR) and Seasonal Autoregressive Integrated Moving Average (SARIMA) through a weighted averaging mechanism. The data used consist of daily sales data for each product over a period of approximately 6–12 months, along with supporting variables such as working days/holidays, religious holidays, weather conditions, purchase prices, and selling prices. The research stages include data collection, preprocessing, feature engineering, training of the SVR and SARIMA models, integration of ensemble predictions, and transformation of prediction results into financial variables in the form of purchasing capital requirements, potential revenue, and shrinkage loss risk. Furthermore, the prediction results are used as input for daily capital allocation optimization using Linear Programming. Model evaluation is conducted using MAE, RMSE, MAPE, and R^2 metrics. This study is expected to produce a system capable of improving demand forecasting accuracy, helping traders allocate capital more efficiently, reducing potential losses due to unsold stock, and supporting more accurate decision-making in micro-enterprises within traditional markets.

Keywords: demand forecasting, inventory management, ensemble learning, SVR, SARIMA, capital optimization, traditional market

DAFTAR ISI

LEMBAR PENGESAHAN	ii
PERNYATAAN ORISINALITAS	iii
PERNYATAAN PERSETUJUAN PUBLIKASI	iv
RIWAYAT HIDUP	v
KATA PENGANTAR	vi
ABSTRAK	viii
ABSTRACT	ix
BAB I	14
PENDAHULUAN	14
1.1 Latar Belakang Masalah	14
1.2 Rumusan Masalah	17
1.3 Batasan Masalah	17
1.4 Tujuan Penelitian	18
1.5 Manfaat Penelitian	19
BAB II	20
LANDASAN TEORI	20
2.1 Penelitian Terdahulu	20
2.2 Pasar Tradisional dan UMKM	22
2.2.1 Definisi dan Karakteristik Pasar Tradisional	22
2.3 Machine Learning dan Ensemble Learning	23
2.3.1 Machine Learning untuk Prediksi	23
2.3.2 Ensemble Learning: Konsep dan Prinsip	24
2.3.2 Metode Kombinasi Ensemble	25
2.4 Support Vector Regression (SVR)	26
2.4.1 Metode Kombinasi Ensemble	26
2.4.2 Formulasi Matematika SVR	26
2.4.3 Fungsi Kernel SVR	27
2.4.5 Tahapan Proses SVR	29
2.4.6 Keunggulan SVR untuk Dataset Kecil	30
2.5 Seasonal Autoregressive Integrated Moving Average (SARIMA)	31
2.5.1 Dasar Teori Time-Series	31
2.5.2 Komponen SARIMA	31
2.5.3 Komponen Seasonal SARIMA	32
2.5.4 Komponen Pemodelan SARIMA	33
<i>Tahap 1: Identifikasi</i>	33
<i>Tahap 2: Estimasi Parameter</i>	34
<i>Tahap 3: Estimasi Pemeriksaan Diagnostik</i>	35
<i>Tahap 4: Forecasting</i>	35
2.6 Mekanisme Ensemble SVR-SARIMA	35
2.6.1 Justifikasi Teoritis Kombinasi SVR dan SARIMA	35
2.6.2 Tahapan Proses Ensemble	36
2.6.3 Penentuan Bobot Adaptif	38
2.7 Optimasi Alokasi Modal	38
2.7.1 Linear Programing	38
2.7.2 Formulasi Masalah Alokasi Modal	39
2.8 Mekanisme Ensemble SVR-SARIMA	39

2.8.1	Mean Absolute Error (MAE)	39
2.8.2	Root Mean Square Error (RMSE)	40
2.8.3	Mean Absolute Percentage Error (MAPE)	40
2.8.4	Koefisien Determinasi (R^2)	40
2.9	Tools dan Teknologi yang Digunakan	41
2.10	Kerangka Teori	42
BAB III		43
METODOLOGI PENELITIAN		43
3.1	Pendekatan Penelitian	43
3.3	Subjek Penelitian	46
3.4	Variabel Penelitian	47
3.5	Arsitektur Sistem yang Dikembangkan	48
3.6	Teknik Pengumpulan Data	49
3.7	Preprocessing dan Rekayasa Fitur	49
3.7.1	Preprocessing Data	49
3.8	Perancangan Model SVR	50
3.9	Perancangan Model SARIMA	52
3.10	Mekanisme Ensemble Weighted Averaging	53
3.11	Optimasi Alokasi Modal	54
3.12	Evaluasi dan Pengujian Model	55
3.13	UML (Unified Modeling Language)	56
3.13.1	Use Case Diagram	56
3.13.2	Activity Diagram	58
3.13.3	Sequence Diagram	59
3.13.4	Class Diagram	59
BAB IV HASIL DAN PEMBAHASAN		65
4.1	Deskripsi Data Penelitian	65
4.2	Hasil Uji Stasionaritas dan Identifikasi Model SARIMA	66
4.3	Hasil Tuning dan Evaluasi Model SVR	67
4.4	Hasil Pemodelan dan Evaluasi SARIMA	69
4.5	Hasil Ensemble SVR-SARIMA dan Bobot Adaptif	70
4.6	Hasil Evaluasi Komparatif	71
4.7	Hasil Optimasi Alokasi Modal	72
4.8	Implementasi Antarmuka Sistem SalSa	74
4.8.1	Modul Prediksi Permintaan	75
4.8.2	Modul Alokasi Modal	77
4.9	Hasil Pengujian Sistem (Black-Box Testing)	78
4.10	Validasi Lapangan Sistem	79
4.11	Pembahasan	80
4.11.1	Keunggulan Ensemble dibandingkan Model Tunggal	80
4.11.2	Keunikan Konteks Teri Sibolga	80
4.11.3	Relevansi Output Moneter bagi UMKM	81
BAB V		82
KESIMPULAN DAN SARAN		82
5.1	Kesimpulan	82
5.2	Saran	83
DAFTAR PUSTAKA		85

DAFTAR TABEL

	HALAMAN
Tabel 2. 1 Penelitian Terdahulu	20
Tabel 2. 2 Perbandingan Fungsi Kernel pada SVR	28
Tabel 2. 3 Notasi dan Penjelasan Parameter SARIMA.....	33
Tabel 2. 4 Tahapan Proses Ensemble SVR–SARIMA	37
Tabel 3. 1 Alat dan Bahan Penelitian.....	47
Tabel 3. 2 Parameter dan Konfigurasi Model SVR	51
Tabel 3. 3 Parameter dan Konfigurasi Model SARIMA.....	53
Tabel 3. 4 Metrik Evaluasi Model	55
Tabel 3. 5 menyajikan narasi use case utama sistem prediksi ensemble SVR– SARIMA	57

DAFTAR GAMBAR

	HALAMAN
Gambar 3. 1 Alur tahapan penelitian	45
Gambar 3. 2 Arsitektur Sistem Three-Layer.....	48
Gambar 3. 3 Use Case Diagram.....	57
Gambar 3. 4 Activity Diagram.....	58
Gambar 3. 5 Sequence Diagram	59
Gambar 3. 6 Class Diagram	60
Gambar 3. 7 Login Page.....	61
Gambar 3. 8 Dashboard.....	61
Gambar 3. 9 Input data Penjualan	62
Gambar 3. 10 Hasil prediksi	63
Gambar 3. 11 Rekomendasi stok	63
Gambar 4. 1 Kerangka Kerja CRISP-DM.....	65
Gambar 4. 2 Pipeline Rekayasa Fitur untuk Model SVR (14 Fitur Input)	68
Gambar 4. 3 Mean Absolute Error (MAE) per Varian Produk Model SVR (IDR)	69
Gambar 4. 4 Nilai R ² Model SVR per Varian Produk pada Data Uji.....	70
Gambar 4. 5 Distribusi Bobot Ensemble: SVR vs SARIMA per Varian Produk .	71
Gambar 4. 6 Perbandingan MAPE SVR vs SARIMA vs Ensemble per Varian Produk	72
Gambar 4. 7 Distribusi Alokasi Modal LP untuk Anggaran Rp 500.000	73
Gambar 4. 8 Arsitektur Sistem SalSa Market (3-Tier)	74
Gambar 4. 9 Halaman Login Sistem SalSa Autentikasi JWT.....	74
Gambar 4. 10 Dashboard Status Model Real-Time dan Ringkasan MAPE per Produk	75
Gambar 4. 11 Modul Prediksi Form Input Parameter (Tanggal, Cuaca, Hari Besar)	76
Gambar 4. 12 Hasil Prediksi Grouped Bar Chart SVR vs SARIMA vs Ensemble per Produk.....	76
Gambar 4. 13 Hasil Prediksi Tabel Detail dengan Estimasi Ensemble, Modal, dan Profit.....	77
Gambar 4. 14 Modul Alokasi Modal Distribusi LP Optimal untuk Anggaran Rp 300.000.....	77
Gambar 4. 15 Panel Transportasi Nilai Fitur untuk Tahu Putih (Raw dan MinMax- Scaled).....	78
Gambar 4. 16 Skenario dan Hasil Pengujian Black-Box Fungsional (12/12 PASS)	78

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Pasar tradisional merupakan pilar fundamental perekonomian Indonesia yang menopang ketahanan ekonomi mikro masyarakat. Sektor ini berkontribusi dominan terhadap struktur ekonomi nasional, dengan usaha mikro, kecil, dan menengah (UMKM) yang mayoritas beroperasi di pasar tradisional menyumbang 61,07% terhadap Produk Domestik Bruto (PDB) dan menyerap 97% tenaga kerja nasional (Kementerian Koperasi dan UKM, 2024). Namun di balik kontribusi makroekonominya, pasar tradisional menghadapi tantangan operasional krusial pada level mikro: ketidakefisienan manajemen stok yang berdampak langsung pada likuiditas harian pedagang.

Permasalahan ini mengkristal secara spesifik pada toko tradisional penjual bahan pelengkap masakan yang mengelola produk perishable (tahu dan toge dengan shelf-life kurang dari 24 jam) serta produk semi-tahan lama (empat varian teri: kecil/nasi/Medan, sedang/jengki, besar/belah, dan Sibolga; mie kuning dan mie tiaw) dengan karakteristik permintaan harian yang fluktuatif dan dipengaruhi oleh faktor multivariat seperti siklus hari kerja/libur, cuaca, hari besar keagamaan, serta pola konsumsi pelanggan tetap. Pada praktik operasionalnya, keputusan pembelian stok masih mengandalkan intuisi subjektif dan pengalaman historis tanpa pertimbangan sistematis terhadap alokasi modal kerja harian yang terbatas.

Permasalahan ini mengkristal secara spesifik pada toko tradisional penjual bahan pelengkap masakan yang mengelola produk perishable (tahu dan toge dengan shelf-life kurang dari 24 jam) serta produk semi-tahan lama (empat varian teri:

kecil/nasi/Medan, sedang/jengki, besar/belah, dan Sibolga; mie kuning dan mie tiaw) dengan karakteristik permintaan harian yang fluktuatif dan dipengaruhi oleh faktor multivariat seperti siklus hari kerja/libur, cuaca, hari besar keagamaan, serta pola konsumsi pelanggan tetap. Pada praktik operasionalnya, keputusan pembelian stok masih mengandalkan intuisi subjektif dan pengalaman historis tanpa pertimbangan sistematis terhadap alokasi modal kerja harian yang terbatas.

Studi oleh Suryani et al. (2022) mengungkapkan bahwa 68% pedagang pasar tradisional mengalami cash flow mismatch harian akibat alokasi stok yang tidak optimal, dengan rata-rata 12–15% modal harian terkunci dalam stok yang tidak terjual atau rusak. Fenomena ini diperparah oleh kompleksitas permintaan yang tidak terkuantifikasi secara sistematis, sehingga pendekatan manajemen stok berbasis pengalaman tidak mampu mengakomodasi dinamika permintaan secara optimal.

Berdasarkan kesenjangan tersebut, penelitian ini mengembangkan sistem prediksi permintaan terintegrasi yang mentransformasi paradigma manajemen stok dari pendekatan berbasis volume (quantity-based) menjadi pendekatan berbasis arus kas (cash flow-based). Inti prediktif sistem ini menggunakan metode Ensemble Learning dengan mengombinasikan dua komponen model yang merepresentasikan paradigma berbeda secara fundamental, yaitu Support Vector Regression (SVR) dan Seasonal Autoregressive Integrated Moving Average (SARIMA).

Kedua, SVR dengan kernel Radial Basis Function (RBF) terbukti unggul dalam menangani dataset berskala kecil (kurang dari 500 observasi) karena prinsip structural risk minimization-nya yang meminimalkan risiko overfitting melalui pengendalian margin keputusan (Vapnik, 1995). Karakteristik ini sangat relevan

untuk konteks UMKM pasar tradisional yang hanya memiliki data historis terbatas 6–12 bulan. SVR mampu menangkap hubungan non-linear kompleks antara fitur eksternal seperti hari besar keagamaan, kondisi cuaca, dan pola mingguan terhadap permintaan produk.

Ketiga, SARIMA (Seasonal ARIMA) merupakan model statistik time-series yang secara eksplisit memodelkan komponen autoregresif, differencing, moving average, serta seasonality periodik (Box & Jenkins, 1976). Untuk data permintaan produk pasar tradisional yang memiliki pola mingguan kuat (permintaan tinggi menjelang akhir pekan) dan pola musiman tahunan yang dominan (lonjakan permintaan teri Sibolga saat Ramadhan), SARIMA mampu menangkap struktur temporal ini secara matematis terstruktur. Studi oleh Hidayat et al. (2022) dan Prasetyo et al. (2023) membuktikan keunggulan SARIMA dalam prediksi permintaan produk pangan dengan pola musiman kuat di pasar Indonesia. Integrasi kedua model dilakukan melalui mekanisme weighted averaging ensemble, di mana bobot masing-masing komponen ditentukan secara adaptif berdasarkan performa validasi per varian produk. Dengan demikian, SVR berperan sebagai penangkap pola non-linear dari faktor-faktor eksternal, sementara SARIMA berperan sebagai penangkap struktur temporal dan seasonality keduanya saling melengkapi untuk menghasilkan prediksi yang lebih akurat dibandingkan model tunggal.

Hasil prediksi selanjutnya ditransformasikan menjadi tiga variabel keuangan kritis per varian produk kebutuhan modal beli (Rp), potensi revenue (Rp), dan ekspektasi risiko rugi susut (Rp) yang kemudian menjadi input algoritma constrained portfolio optimization untuk menghasilkan rekomendasi alokasi modal harian dalam satuan Rupiah. Output sistem ini selaras dengan mental model

pengambilan keputusan pedagang mikro yang berpikir dalam satuan moneter, bukan volume fisik.

Dengan demikian, penelitian ini tidak hanya berkontribusi pada literatur ensemble learning untuk prediksi permintaan dengan kombinasi SVR–SARIMA yang masih jarang dieksplorasi pada konteks pasar tradisional Indonesia, tetapi juga menghasilkan sistem utuh yang menjembatani kesenjangan antara teori kecerdasan buatan dan realitas operasional ekonomi mikro di pasar tradisional.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, maka rumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Bagaimana membangun sistem prediksi permintaan berbasis Ensemble Learning (SVR dan SARIMA) pada satu toko pasar tradisional dengan keterbatasan data dan modal?
2. Bagaimana mentransformasikan hasil prediksi permintaan menjadi prediksi variabel keuangan untuk mendukung manajemen stok berbasis arus kas?

1.3 Batasan Masalah

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

1. Penelitian ini dilakukan pada satu toko di pasar tradisional Tanjung Morawa yang menjual teri (empat varian), tahu, mie kuning, mie tiaw, dan toge.
2. Data yang digunakan berupa data penjualan harian per produk dalam periode tertentu ($\pm 6-12$ bulan) serta variabel pendukung seperti hari kerja/libur dan hari besar, sesuai dengan ketersediaan data.

3. Metode yang digunakan dalam penelitian ini terbatas pada pendekatan Ensemble Learning dengan mengombinasikan Support Vector Regression (SVR) dan Seasonal Autoregressive Integrated Moving Average (SARIMA) melalui mekanisme weighted averaging, tanpa menggunakan model deep learning kompleks.
4. Sistem yang dibangun menghasilkan rekomendasi alokasi modal harian dalam satuan rupiah berdasarkan hasil prediksi kebutuhan modal, potensi pendapatan, dan Risiko kerugian, serta tidak membahas rekomendasi kuantitas fiksi produk secara rinci.

1.4 Tujuan Penelitian

Tujuan dari penelitian ini adalah:

1. Membangun sistem prediksi permintaan harian pada satu toko pasar tradisional yang menjual teri, tahu, mie kuning, mie tiaw, dan toge menggunakan pendekatan Ensemble Learning berbasis SVR dan SARIMA.
2. Mengembangkan model prediksi berbasis arus kas (cash flow-based) dengan mentransformasikan hasil prediksi permintaan menjadi estimasi kebutuhan modal beli, potensi pendapatan, dan risiko kerugian (rugi susut) dalam satuan Rupiah.
3. Merancang mekanisme optimisasi alokasi modal harian berbasis keterbatasan likuiditas pedagang untuk menghasilkan rekomendasi pembelian yang lebih efisien.
4. Menganalisis kinerja model Ensemble Learning SVR–SARIMA dalam meningkatkan akurasi prediksi dibandingkan model tunggal masing-masing.

5. Mengevaluasi dampak penerapan sistem terhadap efisiensi manajemen stok yang diukur melalui penurunan potensi kerugian, peningkatan efektivitas penggunaan modal, dan perbaikan arus kas harian.

1.5 Manfaat Penelitian

Manfaat dari penelitian ini antara lain adalah:

1. Membantu pedagang pasar tradisional memprediksi permintaan barang dengan lebih akurat.
2. Membantu pedagang menentukan jumlah stok yang optimal sehingga mengurangi kelebihan atau kekurangan barang.
3. Meningkatkan efisiensi penggunaan modal dan manajemen stok pada usaha kecil.
4. Mengurangi risiko kerugian akibat barang tidak terjual.
5. Menjadi referensi bagi penelitian selanjutnya yang berkaitan dengan prediksi penjualan menggunakan machine learning.

BAB II

LANDASAN TEORI

2.1 Penelitian Terdahulu

Penelitian terdahulu yang relevan dengan penelitian ini mencakup kajian tentang prediksi permintaan menggunakan metode time-series, penerapan Support Vector Regression (SVR), implementasi SARIMA pada data penjualan UMKM, serta pengembangan sistem manajemen stok berbasis machine learning untuk konteks pasar tradisional Indonesia. Tabel 2.1 menyajikan ringkasan penelitian-penelitian tersebut beserta relevansinya dengan penelitian yang dikembangkan.

Tabel 2. 1 Penelitian Terdahulu

No	Peneliti/Tahun	Judul/Topik	Metode	Relevansi dengan Penelitian ini
1	Hidayat et al. (2022)	Prediksi permintaan produk pangan di pasar tradisional Jawa Barat	SARIMA	Membuktikan keunggulan SARIMA dalam menangkap seasonality mingguan dan bulanan pada data penjualan pangan; digunakan sebagai basis pemilihan SARIMA dalam penelitian ini
2	Prasetyo et al. (2023)	Peramalan penjualan produk UMKM berbasis time-series dengan pendekatan ARIMA dan SARIMA	ARIMA, SARIMA	Memberikan panduan pemilihan orde SARIMA (p,d,q) (P,D,Q)s melalui analisis ACF/PACF untuk data penjualan harian UMKM Indonesia
3	Rahmawati & Suryadi (2023)	Digitalisasi manajemen stok pada pedagang pasar tradisional	Sistem informasi berbasis Android	Mengidentifikasi kebutuhan fitur Sistem yang relevan bagi pedagang mikro; menjadi landasan perancangan antarmuka mobile sederhana

4	Suryani et al. (2022)	Analisis cash flow mismatch pada UMKM tradisional Kota Medan	Kuantitatif deskriptif	Data empiris tentang 68% pedagang mengalami cash flow mismatch; memperkuat urgensi penelitian ini secara kontekstual
5	Chen et al. (2018)	Cash flow-based inventory management for micro enterprises	Optimasi LP	Meletakkan fondasi teori cash flow-based inventory sebagai alternatif quantity-based; diadopsi sebagai kerangka output moneter dalam penelitian ini
6	Drucker et al. (1997)	Support Vector Regression Machines	SVR	Paper fondasi SVR; menjadi acuan utama pemahaman fungsi loss-insensitive dan formulasi optimasi SVR
7	Vapnik (1995)	The Nature of Statistical Learning Theory	SVM/SVR	Meletakkan dasar teori structural risk minimization yang menjelaskan mengapa SVR unggul pada dataset kecil
8	Wijaya et al. (2024)	Ensemble machine learning untuk prediksi permintaan produk perishable	RF, XGBoost, LSTM	Menunjukkan bahwa ensemble berbeda paradigma lebih akurat dibanding ensemble sesama tree-based; memperkuat justifikasi kombinasi SVR– SARIMA

Berdasarkan kajian terhadap penelitian-penelitian terdahulu, terdapat kesenjangan penelitian (research gap) yang signifikan yang menjadi kontribusi utama penelitian ini. Pertama, belum ada penelitian yang mengombinasikan SVR dan SARIMA dalam satu kerangka ensemble learning untuk konteks prediksi permintaan produk harian di pasar tradisional Indonesia. Kedua, sebagian besar penelitian prediksi permintaan menghasilkan output dalam satuan volume fisik

(unit), bukan dalam satuan moneter yang lebih relevan bagi pedagang mikro dengan modal terbatas. Ketiga, penelitian terdahulu umumnya tidak mengintegrasikan hasil prediksi dengan mekanisme optimisasi alokasi modal yang dapat langsung digunakan sebagai panduan operasional harian.

2.2 Pasar Tradisional dan UMKM

2.2.1 Definisi dan Karakteristik Pasar Tradisional

Pasar tradisional adalah tempat bertemunya penjual dan pembeli yang ditandai dengan adanya transaksi jual beli secara langsung, dan biasanya ada proses tawar-menawar (Kemendag RI, Permendag No. 70 Tahun 2013). Berbeda dengan pasar modern yang mengandalkan sistem Point of Sale (POS) dan manajemen stok terkomputasi, pasar tradisional umumnya beroperasi secara manual dengan pencatatan yang sederhana atau bahkan tidak ada pencatatan sistematis sama sekali. Karakteristik pasar tradisional yang relevan dengan penelitian ini mencakup beberapa aspek. Dari sisi produk, pasar tradisional mendominasi penjualan bahan makanan segar dan semi-olahan, termasuk produk perishable (tahu, toge) dengan shelf-life kurang dari 24 jam dan produk semi-tahan lama (teri-mie) dengan shelf-life beberapa hari hingga minggu. Karakteristik ini menciptakan urgensi tinggi terhadap akurasi prediksi permintaan karena kesalahan perkiraan langsung berujung pada kerugian finansial. Dari sisi operasional, modal pedagang mikro sangat terbatas, dengan rata-rata modal kerja harian berkisar Rp 200.000-Rp 500.000 (BPS, 2023), sehingga efisiensi alokasi modal menjadi faktor kritis berkelanjutan usaha.

2.2.2 Tantangan Manajemen Stok UMKM

Manajemen stok merupakan salah satu tantangan terbesar bagi UMKM di

pasar tradisional. Menurut Suryani et al. (2022), 68% pedagang pasar tradisional mengalami cash flow mismatch harian akibat alokasi stok yang tidak optimal, dengan rata-rata 12–15% modal harian terkunci dalam stok yang tidak terjual atau rusak. Permasalahan ini bersumber dari dua sisi: (1) Overstock — membeli terlalu banyak stok mengakibatkan waste cost, terutama untuk produk perishable seperti tahu dan toge yang tidak dapat disimpan lebih dari satu hari; (2) Understock — membeli terlalu sedikit mengakibatkan hilangnya peluang penjualan (lost sales) dan potensi kehilangan pelanggan tetap.

Pendekatan konvensional yang digunakan pedagang adalah perkiraan intuitif berdasarkan pengalaman tanpa pertimbangan sistematis terhadap faktor-faktor yang mempengaruhi permintaan seperti hari besar keagamaan, pola cuaca, dan tren musiman. Chen et al. (2018) membuktikan bahwa pendekatan berbasis alokasi modal (cash flow-based) lebih relevan bagi UMKM mikro dibandingkan pendekatan berbasis volume barang (quantity-based), karena pedagang berpikir dan mengambil keputusan dalam satuan uang, bukan satuan fisik.

2.3 Machine Learning dan Ensemble Learning

2.3.1 Machine Learning untuk Prediksi

Machine learning adalah cabang kecerdasan buatan yang memungkinkan sistem komputer belajar dari data tanpa diprogram secara eksplisit (Mitchell, 1997). Dalam konteks prediksi permintaan, machine learning digunakan untuk menemukan pola-pola tersembunyi dalam data historis yang kemudian digunakan untuk membuat perkiraan ke depan.

Algoritma machine learning untuk regresi (prediksi nilai kontinu) dapat diklasifikasikan ke dalam beberapa paradigma utama. Paradigma berbasis statistik

mencakup ARIMA dan SARIMA yang memodelkan dependensi temporal secara eksplisit. Paradigma berbasis kernel mencakup Support Vector Regression (SVR) yang bekerja dengan memetakan data ke ruang dimensi tinggi menggunakan fungsi kernel. Paradigma berbasis pohon keputusan mencakup Random Forest dan Gradient Boosting (XGBoost) yang membangun ensemble dari banyak pohon keputusan sederhana. Paradigma berbasis jaringan saraf (neural network) mencakup LSTM dan berbagai arsitektur deep learning.

Pemilihan algoritma yang tepat sangat bergantung pada karakteristik data. Untuk dataset berskala kecil (kurang dari 500 observasi) yang umum di konteks UMKM, model berbasis statistik dan kernel-based seperti SVR lebih disarankan dibandingkan model deep learning karena risiko overfitting yang lebih rendah (Vapnik, 1995).

2.3.2 Ensemble Learning: Konsep dan Prinsip

Ensemble learning adalah pendekatan machine learning yang menggabungkan prediksi dari beberapa model untuk menghasilkan prediksi akhir yang lebih akurat dan lebih stabil dibandingkan model tunggal mana pun (Dietterich, 2000). Ide dasarnya berasal dari prinsip statistik bahwa rata-rata dari beberapa estimator yang tidak berkorelasi memiliki variansi yang lebih rendah dibandingkan estimator tunggal mana pun.

Terdapat tiga kondisi yang harus dipenuhi agar ensemble learning efektif (Hansen & Salamon, 1990). Pertama, setiap model anggota harus memiliki akurasi yang lebih baik dari random guess. Kedua, model-model anggota harus saling independen atau setidaknya tidak memiliki korelasi error yang tinggi. Ketiga, model-model anggota idealnya berasal dari paradigma yang berbeda (diverse) untuk

memastikan error mereka saling mengkompensasi. Kondisi ketiga inilah yang menjadi landasan utama pemilihan kombinasi SVR dan SARIMA dalam penelitian ini. SVR berbasis margin maximization dari paradigma kernel, sedangkan SARIMA berbasis dekomposisi statistik time-series — kedua paradigma ini secara fundamental berbeda sehingga menghasilkan error yang tidak berkorelasi tinggi, yang merupakan kondisi ideal untuk ensemble learning.

2.3.2 Metode Kombinasi Ensemble

Terdapat beberapa metode untuk mengombinasikan prediksi model-model anggota dalam ensemble. Metode pertama adalah majority voting (untuk klasifikasi) atau simple averaging (untuk regresi), di mana semua model mendapat bobot yang sama. Metode ini sederhana namun tidak mengakomodasi perbedaan performa antar model.

Metode kedua adalah weighted averaging, di mana setiap model mendapat bobot yang berbeda berdasarkan performa validasinya. Model yang lebih akurat mendapat bobot lebih besar. Formulasi umum weighted averaging adalah:

$$\hat{y}_{ensemble} = \sum_i w_i \times \hat{y}_i, \text{ di mana } \sum_i w_i = 1 \text{ dan } w_i \geq 0$$

Metode ini dipilih dalam penelitian ini karena kesederhanaan implementasi dan interpretabilitas bobot — karakteristik penting untuk sistem yang dioperasikan oleh pengguna non-teknis.

Metode ketiga adalah stacking (stacked generalization), di mana prediksi model-model anggota digunakan sebagai input model baru (meta-learner) yang mempelajari cara terbaik mengombinasikan prediksi tersebut. Stacking umumnya lebih akurat namun lebih kompleks dan lebih rentan terhadap overfitting pada dataset kecil.

2.4 Support Vector Regression (SVR)

2.4.1 Metode Kombinasi Ensemble

Support Vector Regression (SVR) pertama kali diperkenalkan oleh Drucker et al. (1997) sebagai pengembangan dari Support Vector Machine (SVM) untuk kasus regresi. SVR dikembangkan berdasarkan teori statistical learning yang dirumuskan oleh Vapnik (1995), khususnya prinsip Structural Risk Minimization (SRM) yang menyeimbangkan kompleksitas model dengan kesalahan empiris pada data pelatihan.

Berbeda dengan metode regresi konvensional seperti Ordinary Least Squares yang meminimalkan jumlah kuadrat error, SVR bekerja dengan mencari fungsi $f(x)$ yang memetakan input x ke output y sedemikian rupa sehingga:

1. Semua titik data pelatihan berada dalam tube ε (epsilon-tube) di sekitar fungsi $f(x)$
2. Lebar tube ε semaksimal mungkin (margin maximization)
3. Kompleksitas fungsi $f(x)$ diminimalkan untuk mencegah overfitting

Secara intuitif, SVR dapat divisualisasikan sebagai "selongsong" berukuran 2ε yang mengelilingi kurva regresi. Titik-titik data yang berada di dalam selongsong tidak menghasilkan error (ditoleransi). Hanya titik-titik yang berada di luar selongsong (disebut support vectors) yang berkontribusi pada fungsi loss dan menentukan bentuk kurva regresi.

2.4.2 Formulasi Matematika SVR

Diberikan dataset pelatihan $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ di mana $x_i \in \mathbb{R}^d$ adalah vektor fitur dan $y_i \in \mathbb{R}$ adalah target regresi, SVR mencari fungsi regresi linear:

$$f(x) = w^T x + b$$

di mana w adalah vektor bobot dan b adalah bias. Fungsi ini dicari dengan menyelesaikan masalah optimasi berikut:

Subject to:

$$\text{Minimasi: } \frac{1}{2} \|w\|^2 + C \sum_i (\xi_i + \xi_i^*)$$

$$y_i - w^T x_i - b \leq \varepsilon + \xi_i, \quad w^T x_i + b - y_i \leq \varepsilon + \xi_i^*, \quad \xi_i, \xi_i^* \geq 0 \quad \text{untuk semua } i = 1, \dots, n$$

di mana ε adalah lebar tube yang menentukan toleransi error, ξ_i dan ξ_i^* adalah variabel slack untuk mengakomodasi titik data di luar tube, dan C adalah parameter regularisasi yang mengontrol trade-off antara kompleksitas model dan toleransi error.

Parameter C memiliki peran yang kritis. Nilai C yang besar berarti SVR berusaha keras meminimalkan error pelatihan (sedikit toleran terhadap penyimpangan), sehingga model lebih kompleks dan berisiko overfitting. Nilai C yang kecil berarti SVR lebih toleran terhadap error dan menghasilkan model yang lebih sederhana namun mungkin kurang akurat.

2.4.3 Fungsi Kernel SVR

Untuk menangkap hubungan non-linear, SVR menggunakan trik kernel (kernel trick) yang memetakan data dari ruang input ke ruang fitur berdimensi lebih tinggi (bahkan tak hingga) tanpa perlu menghitung pemetaan tersebut secara eksplisit. Dalam ruang fitur yang lebih tinggi, hubungan yang tadinya non-linear menjadi linear sehingga SVR dapat bekerja efektif.

Fungsi regresi SVR dalam ruang fitur menjadi:

$$f(x) = \sum_i (\alpha_i - \alpha_i^*) K(x_i, x) + b$$

di mana $K(x_i, x) = \varphi(x_i)^T \varphi(x)$ adalah fungsi kernel dan α_i, α_i^* adalah multiplier Lagrange yang diperoleh dari penyelesaian masalah dual optimasi. Tabel 2.2 menyajikan jenis-jenis kernel yang umum digunakan beserta karakteristiknya.

di mana ε adalah lebar tube yang menentukan toleransi error, ξ_i dan ξ_i^* adalah variabel slack untuk mengakomodasi titik data di luar tube, dan C adalah parameter regularisasi yang mengontrol trade-off antara kompleksitas model dan toleransi error. Parameter C memiliki peran yang kritis. Nilai C yang besar berarti SVR berusaha keras meminimalkan error pelatihan (sedikit toleran terhadap penyimpangan), sehingga model lebih kompleks dan berisiko overfitting. Nilai C yang kecil berarti SVR lebih toleran terhadap error dan menghasilkan model yang lebih sederhana namun mungkin kurang akurat.

Tabel 2. 2 Perbandingan Fungsi Kernel pada SVR

Tipe Kernel	Formula	Hyperparamete r	Keterangan
Linear	$K(x_i, x) = x_i^T x$	—	Cocok untuk data yang linearly separable; paling sederhana
Polynomial	$K(x_i, x) = (\gamma x_i^T x + r)^d$	γ, r, d	Menangkap interaksi polinomial antar fitur
RBF (Gaussian)	$K(x_i, x) = \exp(-\gamma \ x_i - x\ ^2)$	γ	Paling umum digunakan; mampu menangkap hubungan non-linear kompleks; dipilih dalam penelitian ini

Sigmoid	$K(x_i, x) = \tanh(\gamma x_i^T x + r)$	γ, r	Mirip fungsi aktivasi neural network; jarang digunakan untuk regresi
---------	---	-------------	--

Kernel RBF (Radial Basis Function) atau Gaussian Kernel dipilih dalam penelitian ini karena beberapa alasan. Pertama, kernel ini mampu menangkap hubungan non-linear kompleks antara fitur-fitur kontekstual (hari besar, cuaca, hari kerja) dengan permintaan produk. Kedua, kernel RBF hanya memiliki satu hyperparameter (γ) selain C dan ϵ , sehingga proses tuning lebih sederhana. Ketiga, kernel RBF terbukti memberikan performa terbaik pada dataset berskala kecil dalam berbagai studi (Hsu et al., 2003).

2.4.5 Tahapan Proses SVR

Implementasi SVR dalam penelitian ini mengikuti tahapan sistematis berikut:

1. **Persiapan Data:** Normalisasi seluruh fitur input menggunakan Min-Max Scaling ke rentang $[0,1]$. Normalisasi ini wajib dilakukan karena SVR sangat sensitif terhadap perbedaan skala antar fitur. Rumus Min-Max Scaling: $x_norm = (x - x_min) / (x_max - x_min)$.
2. **Pembuatan Fitur:** Konstruksi fitur lag ($y_{t-1}, y_{t-2}, y_{t-7}$), fitur rolling statistics (MA7,STD7), dan encoding variabel kategorikal (hari minggu, cuaca, hari besar) menggunakan one-hot encoding.
3. **Pembagian Data:** Pembagian data menggunakan time-series split dengan rasio 80:20 — 80% data awal untuk pelatihan dan 20% data terbaru untuk pengujian. Urutan temporal harus dipertahankan; tidak boleh menggunakan random split.

4. Tuning Hyperparameter: Pencarian kombinasi optimal (C, γ, ϵ) menggunakan Grid Search dengan 5-Fold Time-Series Cross Validation. Grid yang digunakan: $C \in \{0.1, 1, 10, 100\}$, $\gamma \in \{0.001, 0.01, 0.1, 1\}$, $\epsilon \in \{0.01, 0.1, 0.5\}$.
5. Pelatihan Model: Model SVR dengan kombinasi hyperparameter terbaik dilatih menggunakan seluruh data pelatihan. Proses ini dilakukan secara terpisah untuk setiap varian produk (8 model SVR independen).
6. Prediksi dan Denormalisasi: Model menghasilkan prediksi dalam skala $[0,1]$ yang kemudian didenormalisasi kembali ke satuan asli menggunakan: $x = x_norm \times (x_max - x_min) + x_min$.
7. Evaluasi: Performa model dievaluasi menggunakan MAE, RMSE, dan MAPE pada data uji yang belum pernah dilihat model.

2.4.6 Keunggulan SVR untuk Dataset Kecil

Keunggulan utama SVR dibandingkan model machine learning lainnya dalam konteks penelitian ini adalah kemampuannya menangani dataset berskala kecil tanpa overfitting. Hal ini dimungkinkan oleh prinsip Structural Risk Minimization yang secara eksplisit mengontrol kompleksitas model melalui parameter regularisasi C .

Vapnik (1995) membuktikan bahwa expected risk (error pada data baru yang belum dilihat) pada SVR dapat dibound oleh:

$$R[f] \leq R_emp[f] + \sqrt{((h(\ln(2n/h)+1) - \ln(\delta/4)) / n)}$$

Dimana R_emp adalah empirical risk (error pada data pelatihan), h adalah VC dimension yang mencerminkan kompleksitas model, n adalah jumlah sampel pelatihan, dan δ adalah confidence level. Dengan mengontrol margin (dan karenanya

VC dimension), SVR memastikan bahwa gap antara training error dan test error tetap kecil meskipun n (jumlah data) juga kecil — properti yang sangat relevan untuk dataset UMKM.

2.5 Seasonal Autoregressive Integrated Moving Average (SARIMA)

2.5.1 Dasar Teori Time-Series

Data time-series adalah sekuens observasi yang diukur secara berurutan dalam interval waktu yang sama. Data permintaan harian produk pasar tradisional merupakan contoh time-series univariat yang umumnya memiliki karakteristik berikut:

1. Autokorelasi: nilai hari ini berkorelasi dengan nilai hari-hari sebelumnya
2. Tren: kecenderungan naik atau turun dalam jangka Panjang
3. Seasonality (musiman): pola yang berulang secara periodik, misalnya permintaan lebih tinggi setiap hari Jumat (menjelang akhir pekan) atau setiap bulan Ramadan
4. Noise: komponen acak yang tidak dapat diprediksi

Model SARIMA dirancang khusus untuk menangkap dan memodelkan ketiga komponen pertama secara eksplisit, sehingga prediksi yang dihasilkan dapat memanfaatkan struktur temporal data secara optimal.

2.5.2 Komponen SARIMA

SARIMA merupakan generalisasi dari model ARIMA (Autoregressive Integrated Moving Average) yang pertama kali diusulkan oleh Box & Jenkins (1976). Model ARIMA(p,d,q) terdiri dari tiga komponen utama.

Komponen pertama adalah Autoregressive (AR) dengan orde p . Model AR(p) menyatakan bahwa nilai saat ini y_t merupakan fungsi linear dari p nilai sebelumnya:

$$y_t = \varphi_1 y_{t-1} + \varphi_2 y_{t-2} + \dots + \varphi_p y_{t-p} + \varepsilon_t$$

di mana $\varphi_1, \dots, \varphi_p$ adalah koefisien autoregresif dan ε_t adalah white noise. Nilai p ditentukan dari plot PACF (Partial Autocorrelation Function) — cut-off pada lag p mengindikasikan orde AR yang sesuai.

Komponen kedua adalah Integrated (I) dengan orde d . Komponen ini menangani ketidakstationeran data melalui differencing. Differencing orde pertama ($d=1$) didefinisikan sebagai:

$$\Delta y_t = y_t - y_{t-1}$$

Jika data belum stasioner setelah differencing satu kali, dilakukan differencing orde kedua ($d=2$): $\Delta^2 y_t = \Delta y_t - \Delta y_{t-1}$. Stasioneritas diuji menggunakan Augmented Dickey-Fuller (ADF) Test; data dianggap stasioner jika $p\text{-value} < 0.05$.

Komponen ketiga adalah Moving Average (MA) dengan orde q . Model MA(q) menyatakan bahwa nilai saat ini merupakan fungsi linear dari q error sebelumnya:

$$y_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

di mana $\theta_1, \dots, \theta_q$ adalah koefisien moving average. Nilai q ditentukan dari plot ACF (Autocorrelation Function) — cut-off pada lag q mengindikasikan orde MA yang sesuai.

2.5.3 Komponen Seasonal SARIMA

Model SARIMA(p,d,q)(P,D,Q) s merupakan perluasan ARIMA yang menambahkan komponen seasonal untuk menangkap pola yang berulang setiap s periode. Komponen seasonal bekerja dengan cara yang sama seperti komponen non-seasonal, namun dengan lag kelipatan s .

Seasonal AR(P) dengan periode s menyatakan:

$$\Phi(B^s) Y_t = \varphi_1 Y_{t-s} + \varphi_2 Y_{t-2s} + \dots + \varphi_p Y_{t-ps} + \varepsilon_t$$

Seasonal differencing (D) dengan periode s didefinisikan sebagai:

$$\Delta_s Y_t = Y_t - Y_{t-s}$$

Model SARIMA penuh dapat ditulis dalam notasi backshift operator B sebagai:

$$\Phi_p(B) \times \Phi P(B^s) \times (1-B)^d \times (1-B^s)^D \times Y_t = \theta q(B) \times \Theta Q(B^s) \times \varepsilon_t$$

Tabel 2. 3 Notasi dan Penjelasan Parameter SARIMA

Notasi	Nama	Penjelasan
p	AR order	Jumlah lag autoregresif non-seasonal; menunjukkan seberapa banyak nilai masa lalu mempengaruhi nilai saat ini
d	Differencing order	Jumlah kali differencing untuk membuat data stasioner; d=1 berarti $\Delta y_t = y_t - y_{t-1}$
q	MA order	Jumlah lag moving average non-seasonal; menunjukkan pengaruh error masa lalu
P	Seasonal AR order	Sama seperti p namun untuk komponen musiman dengan lag kelipatan s
D	Seasonal differencing	Seasonal differencing: $\Delta_s y_t = y_t - y_{t-s}$ untuk menghilangkan tren musiman
Q	Seasonal MA order	Sama seperti q namun untuk komponen musiman
s	Seasonal period	Panjang satu siklus musiman; s=7 untuk pola mingguan (7 hari)

Dalam penelitian ini, periode seasonal s ditetapkan 7 hari berdasarkan observasi pola permintaan produk pasar tradisional yang menunjukkan siklus mingguan yang kuat — permintaan cenderung meningkat menjelang akhir pekan (Jumat-Minggu) ketika lebih banyak ibu rumah tangga berbelanja untuk kebutuhan akhir pekan. Selain itu, terdapat pola musiman tahunan yang dominan pada bulan Ramadan untuk produk teri Sibolga.

2.5.4 Komponen Pemodelan SARIMA

Pemodelan SARIMA mengikuti metodologi Box-Jenkins yang terdiri dari empat tahap sistematis:

Tahap 1: Identifikasi

Tahap identifikasi bertujuan menentukan nilai orde yang sesuai (p, d, q, P, D,

Q) untuk data yang akan dimodelkan. Proses identifikasi dilakukan melalui langkah-langkah berikut:

1. Plot data time-series untuk mengamati pola visual (tren, seasonality, outlier)
2. Uji stasionaritas menggunakan Augmented Dickey-Fuller (ADF) Test. Hipotesis nol ADF adalah data memiliki unit root (tidak stasioner). Jika $p\text{-value} > 0.05$, data tidak stasioner dan perlu differencing
3. Lakukan differencing ($d=1$) jika diperlukan; ulangi ADF test; tambah d jika masih tidak stasioner
4. Lakukan seasonal differencing ($D=1, s=7$) jika terdapat komponen seasonal yang kuat
5. Plot ACF dan PACF dari data yang sudah stasioner: cut-off pada ACF menunjukkan orde q , cut-off pada PACF menunjukkan orde p . Untuk komponen seasonal: cut-off pada lag 7, 14, ... di ACF menunjukkan Q , di PACF menunjukkan P

Tahap 2: Estimasi Parameter

Setelah orde kandidat ditentukan, parameter model diestimasi menggunakan Maximum Likelihood Estimation (MLE). Untuk setiap kombinasi orde kandidat (p,d,q) (P,D,Q), model dilatih dan nilai kriteria informasi dihitung:

$$AIC = -2 \ln(L) + 2k$$

$$BIC = -2 \ln(L) + k \ln(n)$$

di mana L adalah nilai likelihood maksimum, k adalah jumlah parameter model, dan n adalah jumlah observasi. Model dengan nilai AIC dan BIC terkecil dipilih sebagai model terbaik, karena kedua kriteria ini mengontrol trade-off antara kualitas fit dan kompleksitas model.

Tahap 3: Estimasi Pemeriksaan Diagnostik

Model terpilih diverifikasi melalui analisis residual:

1. Plot residual: residual yang baik seharusnya tampak seperti white noise (tidak ada pola)
2. ACF residual: tidak ada autokorelasi signifikan pada semua lag (semua berada dalam confidence band $\pm 1.96/\sqrt{n}$)
3. Ljung-Box test: menguji secara formal apakah residual bersifat white noise. Hipotesis nol adalah tidak ada autokorelasi pada lag 1 hingga h. Jika p-value > 0.05 , residual diterima sebagai white noise
4. Jika diagnostik tidak terpenuhi, kembali ke tahap identifikasi dan coba orde yang berbeda

Tahap 4: Forecasting

Setelah model tervalidasi, prediksi h langkah ke depan (h-step ahead forecast) dihasilkan menggunakan:

$$\hat{y}_{t+h|t} = E[Y_{t+h} | Y_1, Y_2, \dots, Y_t]$$

Untuk prediksi satu hari ke depan (h=1), SARIMA menggunakan seluruh data historis yang tersedia. Interval kepercayaan 95% untuk prediksi juga dapat dihitung untuk mengukur ketidakpastian prediksi. Dalam penelitian ini, output SARIMA adalah prediksi permintaan harian per varian produk yang kemudian ditransformasikan ke variabel keuangan menggunakan harga beli dan harga jual.

2.6 Mekanisme Ensemble SVR-SARIMA

2.6.1 Justifikasi Teoritis Kombinasi SVR dan SARIMA

Kombinasi SVR dan SARIMA dalam satu framework ensemble didasarkan pada prinsip diversity yang merupakan fondasi teori ensemble learning (Dietterich,

2000). Dua model dikatakan diverse jika error prediksinya tidak berkorelasi tinggi artinya ketika satu model salah, model lainnya memiliki probabilitas yang wajar untuk tetap benar.

SVR dan SARIMA memiliki diversity yang tinggi karena berasal dari dua paradigma yang fundamental berbeda. SVR menangkap hubungan non-linear antara fitur-fitur kontekstual (hari minggu, cuaca, hari besar) dengan permintaan melalui kernel RBF. SARIMA menangkap struktur autokorelasi temporal dan seasonality periodik dalam data permintaan itu sendiri. Dengan kata lain, SVR kuat dalam dimensi cross-sectional (pengaruh faktor eksternal), sedangkan SARIMA kuat dalam dimensi temporal (pola berulang seiring waktu). Keduanya saling melengkapi untuk menghasilkan prediksi yang lebih komprehensif.

2.6.2 Tahapan Proses Ensemble

Tabel 2.4 menyajikan tahapan lengkap proses ensemble SVR–SARIMA yang diimplementasikan dalam penelitian ini.

Tabel 2. 4 Tahapan Proses Ensemble SVR–SARIMA

Tahapan	Aktivitas	Keterangan
1	Pelatihan SVR per varian	Model SVR dengan kernel RBF dilatih secara independen untuk masing-masing 8 varian produk menggunakan data historis yang telah dinormalisasi
2	Pelatihan SARIMA per varian	Model SARIMA dengan orde terbaik (dipilih via AIC/BIC) dilatih untuk masing-masing 8 varian produk menggunakan data yang telah diuji stasionaritasnya
3	Prediksi individual	Setiap model menghasilkan prediksi independen: \hat{y}_{SVR} dan \hat{y}_{SARIMA} untuk hari berikutnya per varian produk
4	Hitung bobot adaptif	Bobot dihitung berdasarkan performa MAPE pada data validasi: $w = (1/MAPE) / \sum(1/MAPE)$; model lebih akurat mendapat bobot lebih besar
5	Weighted averaging	Prediksi ensemble: $\hat{y}_{ens} = w_{SVR} \times \hat{y}_{SVR} + w_{SARIMA} \times \hat{y}_{SARIMA}$; menghasilkan 3 variabel keuangan per varian (modal beli, revenue, rugi susut)
6	Update bobot periodik	Bobot diperbarui setiap minggu seiring

2.6.3 Penentuan Bobot Adaptif

Bobot masing-masing komponen ensemble ditentukan berdasarkan inverse MAPE dari data validasi. Formulasi bobot untuk komponen ke-i adalah:

$$w_i = (1 / MAPE_i) / \sum_j (1 / MAPE_j)$$

di mana $MAPE_i$ adalah Mean Absolute Percentage Error model ke-i pada data validasi. Formulasi ini memastikan bahwa model yang lebih akurat (MAPE lebih rendah) mendapat bobot yang lebih besar secara proporsional. Sebagai contoh, jika $MAPE_{SVR} = 10\%$ dan $MAPE_{SARIMA} = 15\%$, maka:

$$w_{SVR} = (1/10) / (1/10 + 1/15) = 0.10 / 0.167 \approx 0.60$$

$$w_{SARIMA} = (1/15) / (1/10 + 1/15) = 0.067 / 0.167 \approx 0.40$$

Bobot ini diperbarui setiap minggu seiring bertambahnya data aktual, sehingga ensemble bersifat adaptif terhadap perubahan pola permintaan musiman.

2.7 Optimasi Alokasi Modal

2.7.1 Linear Programming

Optimisasi alokasi modal dalam penelitian ini diimplementasikan menggunakan Linear Programming (LP), yaitu teknik optimasi matematika untuk memaksimalkan atau meminimalkan fungsi tujuan linear dengan kendala-kendala linear (Dantzig, 1963).

Masalah LP umum diformulasikan sebagai:

$$\text{Maksimalkan (atau Minimasi): } z = c^T x \text{ Subject to: } Ax \leq b, \quad x \geq 0$$

Di mana x adalah vektor variabel keputusan, c adalah vektor koefisien fungsi tujuan, A adalah matriks kendala, dan b adalah vektor batas kanan kendala.

2.7.2 Formulasi Masalah Alokasi Modal

Dalam konteks penelitian ini, masalah alokasi modal diformulasikan sebagai:

Variabel keputusan: x_i = alokasi modal (Rp) untuk varian produk ke- i , $i = 1, \dots, 8$

Fungsi tujuan (memaksimalkan expected net profit):

Maksimalkan: $\sum_i x_i \times [(revenue_pred_i - modal_beli_i - rugi_susut_i) / modal_beli_i]$

Kendala:

$$\sum_i x_i \leq Modal_Harian_Tersedia \text{ (kendala likuiditas)} \quad x_i \geq 0 \text{ untuk semua } i \text{ (non-negativity)}$$

di mana $revenue_pred_i$, $modal_beli_i$, dan $rugi_susut_i$ adalah output prediksi ensemble SVR–SARIMA yang telah ditransformasikan ke satuan Rupiah. Output optimisasi adalah vektor alokasi modal optimal (x_1^* , x_2^* , ..., x_8^*) dalam satuan Rupiah yang secara langsung dapat digunakan sebagai panduan pembelian stok harian.

2.8 Mekanisme Ensemble SVR-SARIMA

Evaluasi performa model prediksi dilakukan menggunakan empat metrik kuantitatif yang umum digunakan dalam literatur forecasting.

2.8.1 Mean Absolute Error (MAE)

MAE mengukur rata-rata dari selisih absolut antara nilai prediksi dan nilai aktual:

$$MAE = (1/n) \sum_i |y_i - \hat{y}_i|$$

di mana y_i adalah nilai aktual, \hat{y}_i adalah nilai prediksi, dan n adalah jumlah observasi. MAE memiliki satuan yang sama dengan data target (Rupiah dalam penelitian ini) dan mudah diinterpretasikan. Kelebihan MAE adalah tidak sensitif terhadap outlier karena menggunakan selisih absolut, bukan kuadrat.

2.8.2 Root Mean Square Error (RMSE)

RMSE mengukur akar dari rata-rata kuadrat selisih prediksi dan aktual:

$$RMSE = \sqrt{[(1/n) \sum_i (y_i - \hat{y}_i)^2]}$$

RMSE lebih sensitif terhadap outlier dibandingkan MAE karena kesalahan besar dikuadratkan. RMSE berguna untuk mengidentifikasi apakah model membuat beberapa kesalahan besar yang tersebar, atau banyak kesalahan kecil yang merata. Dalam satuan yang sama dengan data target, RMSE yang mendekati MAE mengindikasikan tidak ada outlier signifikan dalam prediksi.

2.8.3 Mean Absolute Percentage Error (MAPE)

MAPE mengukur rata-rata persentase kesalahan prediksi relatif terhadap nilai aktual:

MAPE dinyatakan dalam persentase (%) sehingga memungkinkan perbandingan performa model antar varian produk yang memiliki skala permintaan berbeda-beda. Interpretasi umum nilai MAPE: kurang dari 10% sangat akurat, 10–20% akurat, 20–50% layak, lebih dari 50% tidak akurat. Target penelitian ini adalah MAPE ensemble $\leq 15\%$ untuk semua varian produk.

Perlu diperhatikan bahwa MAPE tidak terdefinisi ketika $y_i = 0$, sehingga observasi dengan permintaan nol perlu ditangani secara khusus (misalnya dengan mengecualikannya dari perhitungan MAPE atau menggunakan SMAPE sebagai alternatif).

2.8.4 Koefisien Determinasi (R^2)

RZ (R-squared) mengukur proporsi variansi data aktual yang dapat dijelaskan oleh model:

$$R^2 = 1 - (SS_{res} / SS_{tot})$$

$$\text{di mana } SS_{res} = \sum_i (y_i - \hat{y}_i)^2 \text{ dan } SS_{tot} = \sum_i (y_i - \bar{y})^2$$

Nilai RZ berkisar antara 0 hingga 1. RZ = 1 berarti model menjelaskan 100% variansi data (prediksi sempurna), sedangkan RZ = 0 berarti model tidak lebih baik dari prediksi menggunakan nilai rata-rata. Untuk model prediksi permintaan, RZ \geq 0.80 umumnya dianggap baik.

2.9 Tools dan Teknologi yang Digunakan

Implementasi sistem dalam penelitian ini menggunakan beberapa tools dan library sebagai berikut. Untuk pemrograman, digunakan bahasa Python 3.x sebagai bahasa utama karena ekosistem library machine learning yang lengkap dan dokumentasi yang komprehensif.

Untuk implementasi SVR, digunakan library scikit-learn yang menyediakan implementasi SVR yang sudah teroptimasi. Scikit-learn menyediakan kelas `sklearn.svm.SVR` yang mendukung berbagai kernel termasuk RBF, serta `sklearn.model_selection.GridSearchCV` untuk proses hyperparameter tuning otomatis dengan cross-validation. Untuk implementasi SVR, digunakan library scikit-learn yang menyediakan implementasi SVR yang sudah teroptimasi. Scikit-learn menyediakan kelas `sklearn.svm.SVR` yang mendukung berbagai kernel termasuk RBF, serta `sklearn.model_selection.GridSearchCV` untuk proses hyperparameter tuning otomatis dengan cross-validation.

Untuk implementasi SARIMA, digunakan library statsmodels yang menyediakan kelas `statsmodel.tsa.statespace.sarimax.SARIMAX`-implementasi SARIMA yang komprehensif dengan dukungan untuk estimasi MLE, pemilihan orde otomatis, dan diagnostic residual. Library pmdarima (Python Auto-ARIMA) juga digunakan untuk identifikasi orde otomatis via `pmdarima.auto_arima()`.

Untuk visualisasi, digunakan library matplotlib dan seaborn untuk plot ACF/PACF, visualisasi residual, dan grafik perbandingan prediksi. Untuk manipulasi data, digunakan pandas untuk manajemen dataframe time-series dan numpy untuk operasi numerik. Untuk implementasi optimisasi LP, digunakan library scipy.optimize.linprog yang menyediakan solver LP yang efisien.

2.10 Kerangka Teori

Berdasarkan uraian tinjauan pustaka yang telah dipaparkan, kerangka teori penelitian ini dapat disintesis sebagai berikut. Permasalahan inti yang diatasi adalah ketidakefisienan manajemen stok UMKM pasar tradisional yang disebabkan oleh keterbatasan kemampuan pedagang mikro dalam memprediksi permintaan harian secara akurat dan mengalokasikan modal kerja yang terbatas secara optimal.

Solusi yang dikembangkan mengintegrasikan tiga lapisan komputasi yang saling bergantung. Pada lapisan prediksi, model ensemble SVR–SARIMA memanfaatkan kekuatan komplementer dua paradigma yang berbeda: SVR menangkap hubungan non-linear antara faktor kontekstual eksternal dengan permintaan, sementara SARIMA menangkap struktur temporal dan seasonality periodik data permintaan. Integrasi keduanya melalui weighted averaging menghasilkan prediksi yang lebih akurat dan robust dibandingkan masing-masing model tunggal. Pada lapisan transformasi, hasil prediksi volume dikoversi ke tiga variabel keuangan (modal beli, revenue, rugi susut) menggunakan informasi harga. Transformasi ini merupakan kontribusi metodologis yang membedakan penelitian ini dari studi prediksi permintaan konvensional, karena output langsung relevan bagi pengambilan keputusan pedagang mikro yang berpikir dalam satuan moneter.

Pada lapisan optimasi, algoritma constrained Linear Programming

mengalokasi modal harian yang terbatas secara optimal di antara 8 varian produk untuk memaksimalkan expected net profit. Kerangka ini mencerminkan pendekatan cash flow-based inventory management yang di usulkan Chen et al. (2018) sebagai alternatif yang lebih relevan bagi UMKM dibandingkan quantity – based inventory management konvensional.

BAB III

METODOLOGI PENELITIAN

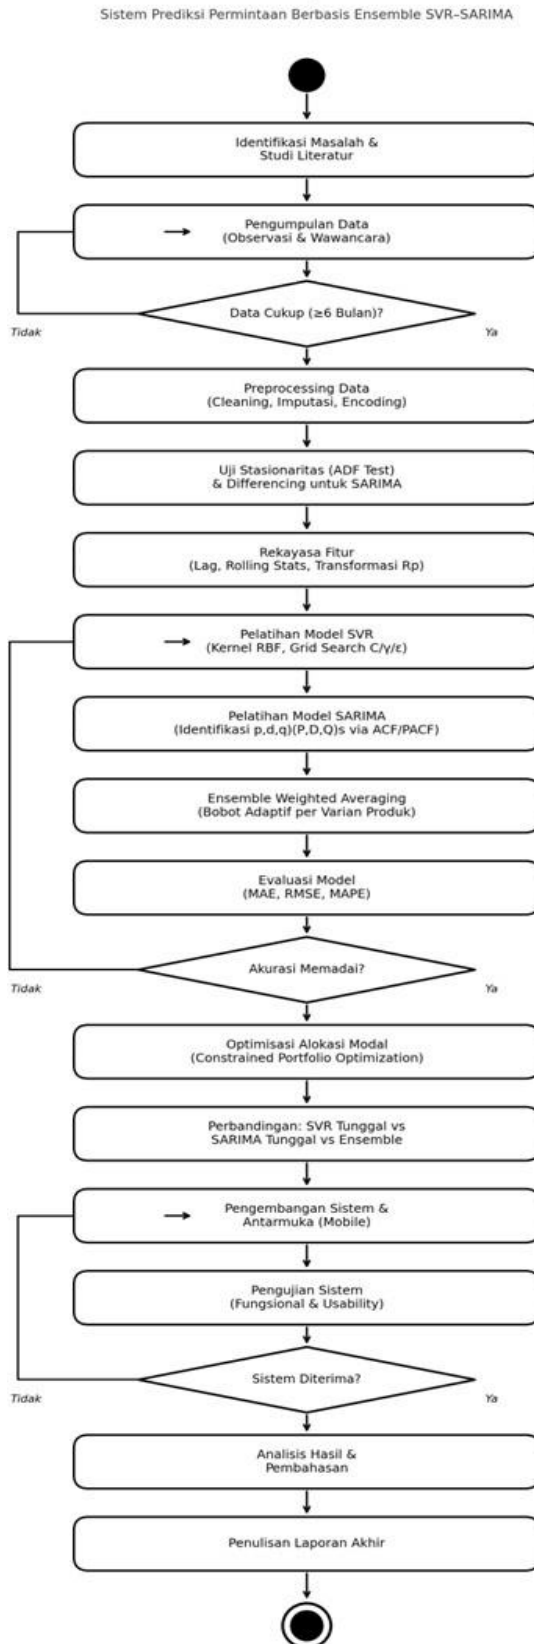
3.1 Pendekatan Penelitian

Penelitian ini menggunakan pendekatan penelitian terapan (applied research) dengan metode pengembangan sistem berbasis data (data-driven system development). Paradigma yang digunakan adalah pendekatan kuantitatif dengan metode eksperimental komputasional, di mana performa model prediksi dievaluasi secara empiris melalui pengujian terhadap data aktual penjualan harian toko pasar tradisional.

Secara metodologis, penelitian ini mengikuti kerangka CRISP-DM (Cross-Industry Standard Process for Data Mining) yang terdiri dari enam tahap: pemahaman bisnis (business understanding), pemahaman data (data understanding), persiapan data (data preparation), pemodelan (modeling), evaluasi (evaluation), dan penerapan (deployment). Kerangka ini dipilih karena sesuai dengan karakteristik penelitian prediksi berbasis machine learning yang bersifat iteratif dan adaptif.

Pendekatan pengembangan sistem mengadopsi model prototyping yang memungkinkan penyempurnaan bertahap berdasarkan evaluasi performa model SVR dan SARIMA serta umpan balik dari pedagang sebagai pengguna. Gambar

3.1 menyajikan flowchart tahapan penelitian secara lengkap.



Gambar 3. 1 Alur tahapan penelitian

3.2 Lokasi dan Waktu Penelitian

Penelitian ini dilaksanakan di satu toko bahan pelengkap masakan di pasar tradisional yang berlokasi di Tanjung Morawa, Sumatera Utara. Pemilihan lokasi dilakukan secara purposif dengan pertimbangan: (1) toko menjual 8 varian produk yang menjadi objek penelitian; (2) pedagang bersedia berpartisipasi dan memberikan akses data penjualan historis; serta (3) lokasi terjangkau untuk keperluan observasi dan wawancara mendalam.

Waktu penelitian direncanakan berlangsung selama delapan bulan, dimulai dari bulan Maret hingga Oktober 2025. Rincian jadwal penelitian disajikan pada Tabel 3.6 di bagian akhir bab ini.

3.3 Subjek Penelitian

Subjek penelitian adalah satu unit usaha mikro penjual bahan pelengkap masakan di pasar tradisional Tanjung Morawa yang mengelola delapan varian produk berikut:

1. Teri kecil (teri nasi/medan)
2. Teri sedang (teri jengki)
3. Teri besar (teri belah)
4. Teri sibolga
5. Tahu
6. Toge
7. Mie kuning
8. Mie tiaw

Unit analisis adalah data transaksi penjualan harian per varian produk. Informan kunci adalah pemilik toko yang memiliki pengetahuan mendalam tentang pola operasional, struktur biaya, dan dinamika permintaan produk.

3.4 Variabel Penelitian

Variabel penelitian dikelompokkan menjadi tiga kategori sebagaimana disajikan pada Tabel 3.1 berikut.

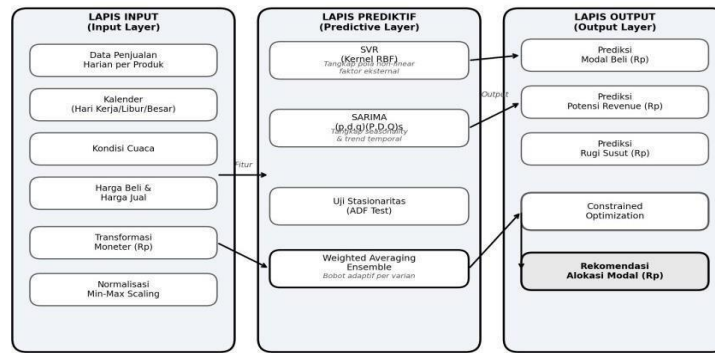
Tabel 3. 1 Alat dan Bahan Penelitian

Kategori	Nama Variabel	Deskripsi	Satuan
Input (Fitur)	Permintaan harian historis	Jumlah unit terjual per varian per hari	Unit/hari
	Hari kerja / libur	Kategori hari dalam seminggu	Biner (0/1)
	Hari besar keagamaan	Indikator hari besar nasional/keagamaan	Biner (0/1)
	Kondisi cuaca	Kategori cuaca harian	Kategorikal
	Harga beli per varian	Harga pembelian modal per satuan	Rupiah (Rp)
	Harga jual per varian	Harga penjualan per satuan	Rupiah (Rp)
Output / Target	Kebutuhan modal beli (Rp)	Estimasi modal untuk pembelian stok optimal	Rupiah (Rp)
	Potensi revenue (Rp)	Estimasi pendapatan dari penjualan stok	Rupiah (Rp)
	Rugi susut (Rp)	Estimasi kerugian akibat sisa stok tidak terjual	Rupiah (Rp)
-66-Kontrol / Kendala	Modal harian tersedia	Batas atas likuiditas pedagang per hari	Rupiah (Rp)
	Jumlah varian produk	8 varian: teri kecil/sedang/besar/Sibolga, tahu, toge, mie kuning, mie tiaw	Jumlah item

Setiap variabel input dikonversi ke representasi moneter menggunakan harga beli dan harga jual sebagai basis transformasi, sehingga output prediksi langsung relevan untuk pengambilan keputusan alokasi modal. Variabel kontrol mendefinisikan kendala optimisasi sehingga total alokasi modal tidak melebihi modal harian yang tersedia.

3.5 Arsitektur Sistem yang Dikembangkan

Sistem yang dikembangkan memiliki arsitektur tiga lapis (three-layer architecture) yang saling terintegrasi. Gambar 3.2 menyajikan arsitektur sistem secara keseluruhan.



Gambar 3. 2 Arsitektur Sistem Three-Layer

Lapis pertama adalah Lapis Input yang bertanggung jawab mengolah data mentah menjadi fitur prediktif, mencakup pengumpulan observasi permintaan historis, integrasi variabel kontekstual, serta transformasi moneter berbasis harga beli dan harga jual.

Lapis kedua adalah Lapis Prediktif yang merupakan inti komputasional sistem. Pada lapis ini, model SVR dengan kernel RBF berperan menangkap hubungan non-linear antara fitur-fitur eksternal (hari besar, cuaca, pola mingguan) dengan permintaan produk, sementara model SARIMA berperan menangkap struktur temporal dan seasonality periodic data permintaan. Kedua model dilatih secara terpisah per varian produk dan diintegrasikan melalui mekanisme weighted averaging ensemble.

Lapis ketiga adalah Lapis Output yang menerapkan algoritma constrained portfolio optimization untuk menghasilkan rekomendasi alokasi modal harian dalam satuan Rupiah berdasarkan keterbatasan modal yang tersedia.

3.6 Teknik Pengumpulan Data

Pengumpulan data menggunakan tiga teknik yang saling melengkapi. Pertama, observasi partisipatif dilakukan untuk memahami pola permintaan harian, mekanisme pengambilan keputusan stok, dan faktor kontekstual yang mempengaruhi penjualan. Observasi difokuskan pada pencatatan data penjualan per varian produk secara harian beserta kondisi cuaca dan kejadian khusus.

Kedua, wawancara mendalam (in-depth interview) dilakukan dengan pemilik toko sebagai informan kunci untuk menggali informasi mengenai struktur biaya per varian produk, pola permintaan historis, dan keterbatasan modal harian. Wawancara dilakukan secara semi-terstruktur.

Ketiga, dokumentasi catatan penjualan historis dikumpulkan baik dalam bentuk catatan manual maupun digital dengan target periode 6–12 bulan. Data pendukung berupa kalender hari besar diperoleh dari Kementerian Agama RI dan BPS, sementara data cuaca historis diperoleh dari BMKG.

3.7 Preprocessing dan Rekayasa Fitur

Tahap preprocessing dan rekayasa fitur merupakan tahap kritis dalam penelitian ini mengingat model SVR dan SARIMA memiliki persyaratan data yang berbeda secara fundamental. Tahap ini terbagi menjadi dua bagian utama.

3.7.1 Preprocessing Data

Preprocessing data mencakup empat langkah berurutan. Pertama, pembersihan data (data cleaning) meliputi penanganan missing values menggunakan imputasi berbasis median per varian produk, identifikasi dan penanganan duplikasi data, serta deteksi outlier menggunakan metode Interquartile Range (IQR).

Kedua, transformasi moneter mengkonversi variabel permintaan dari satuan unit fisik ke satuan Rupiah menggunakan rumus: $\text{Modal Beli} = \text{qty_prediksi} \times \text{harga_beli}$; $\text{Revenue} = \text{qty_prediksi} \times \text{harga_jual}$; $\text{Rugi Susut} = (\text{qty_beli} - \text{qty_terjual}) \times \text{harga_beli}$.

Ketiga, uji stasionaritas khusus untuk SARIMA menggunakan Augmented Dickey-Fuller (ADF) Test. Apabila $p\text{-value} > 0.05$ (data tidak stasioner), dilakukan differencing orde pertama ($d=1$). Proses ini diulang hingga data stasioner sebelum model SARIMA dilatih.

Keempat, normalisasi fitur untuk SVR menggunakan Min-Max Scaling ke rentang $[0, 1]$. Normalisasi ini wajib dilakukan sebelum pelatihan SVR karena algoritma ini sangat sensitif terhadap perbedaan skala antar fitur. Perlu dicatat bahwa normalisasi ini hanya diterapkan pada jalur SVR, bukan pada jalur SARIMA.

3.7.2 Rekayasa Fitur (Feature Engineering)

Rekayasa fitur mencakup pembuatan tiga kelompok fitur tambahan. Fitur lag ($t-1, t-2, t-7$) dibuat untuk menangkap dependensi temporal jangka pendek dan pola mingguan. Fitur rolling statistics meliputi rata-rata bergerak 7 hari (MA7) dan standar deviasi bergerak 7 hari (STD7) untuk menangkap tren jangka pendek. Fitur interaksi dibuat antara hari dalam seminggu dengan variabel hari besar dan cuaca untuk menangkap efek kombinasi antar faktor kontekstual.

3.8 Perancangan Model SVR

Support Vector Regression (SVR) merupakan pengembangan dari Support Vector Machine (SVM) untuk kasus regresi. SVR bekerja dengan mencari fungsi $f(x)$ yang memetakan input x ke output y sedemikian rupa sehingga seluruh titik

data berada dalam tube ε dari fungsi tersebut, sambil memaksimalkan margin (Vapnik, 1995). Fungsi keputusan SVR dengan kernel RBF dinyatakan sebagai:

$$f(x) = \sum (\alpha_i - \alpha_i^*) K(x_i, x) + b$$

di mana $K(x_i, x) = \exp(-\gamma \|x_i - x\|^2)$ adalah fungsi kernel RBF, α_i dan α_i^* adalah multiplier Lagrange, dan b adalah bias.

Pemilihan kernel RBF didasarkan pada kemampuannya memetakan data ke ruang fitur berdimensi tak hingga, yang memungkinkan SVR menangkap hubungan non-linear kompleks antara fitur kontekstual dengan permintaan produk. Keunggulan utama SVR dalam konteks penelitian ini adalah prinsip structural risk minimization yang meminimalkan risiko overfitting — karakteristik kritis mengingat keterbatasan ukuran dataset UMKM. Tabel 3.3 menyajikan spesifikasi parameter SVR dan strategi tuning yang digunakan dalam penelitian ini.

Tabel 3. 2 Parameter dan Konfigurasi Model SVR

Parameter	Nilai / Rentang	Keterangan
Kernel	RBF (Radial Basis Function)	Dipilih karena mampu memetakan data ke ruang dimensi tinggi dan menangkap hubungan non-linear antar fitur
C (Cost)	Grid: {0.1, 1, 10, 100}	Parameter regularisasi; nilai besar = toleransi kecil terhadap error pelatihan
γ (Gamma)	Grid: {0.001, 0.01, 0.1, 1}	Menentukan jangkauan pengaruh satu sampel pelatihan
ε (Epsilon)	Grid: {0.01, 0.1, 0.5}	Lebar tube insensitif; nilai kecil = model lebih sensitif
Metode Tuning	5-Fold Cross Validation Grid Search	Dijalankan per varian produk untuk menemukan kombinasi
Normalisasi Input	Min-Max Scaling [0,1]	Wajib dilakukan sebelum SVR karena sensitif terhadap skala fitur

Proses pelatihan SVR dilakukan secara terpisah untuk setiap varian produk (8 model SVR independen). Pembagian data menggunakan time-series split dengan

rasio 80:20, di mana 80% data awal digunakan untuk pelatihan dan 20% data terbaru untuk pengujian, mempertahankan urutan temporal data.

3.9 Perancangan Model SARIMA

Seasonal Autoregressive Integrated Moving Average (SARIMA) merupakan generalisasi model ARIMA yang mengakomodasi komponen musiman periodik. Model SARIMA dinotasikan sebagai SARIMA(p,d,q)(P,D,Q)_s, di mana p, d, q adalah orde non-seasonal (autoregresif, differencing, moving average) dan P, D, Q adalah orde seasonal dengan periode s (Box & Jenkins, 1976).

Proses identifikasi orde model SARIMA dalam penelitian ini mengikuti metodologi Box-Jenkins yang terdiri dari tiga tahap. Tahap pertama adalah identifikasi, di mana plot ACF (Autocorrelation Function) dan PACF (Partial Autocorrelation Function) dianalisis untuk menentukan kandidat orde p, d, q, P, D, Q. Nilai s ditetapkan 7 sesuai dengan pola mingguan permintaan di pasar tradisional dimana pola belanja pelanggan cenderung berulang setiap minggu.

Tahap kedua adalah estimasi parameter menggunakan metode Maximum Likelihood Estimation (MLE). Untuk setiap kombinasi orde kandidat, model dilatih dan nilai AIC (Akaike Information Criterion) serta BIC (Bayesian Information Criterion) dihitung. Model dengan kombinasi AIC dan BIC terkecil dipilih sebagai model terbaik per varian produk. Tahap ketiga adalah pemeriksaan diagnostik menggunakan Ljung-Box test untuk memverifikasi bahwa residual model bersifat white noise (p-value > 0.05). Apabila residual tidak bersifat white noise, proses identifikasi orde diulang. Tabel 3.4 merangkum spesifikasi parameter SARIMA yang digunakan.

Tabel 3. 3 Parameter dan Konfigurasi Model SARIMA

Parameter	Nilai / Metode	Keterangan
p (AR order)	0–3 (dari PACF plot)	Jumlah lag autoregresif; ditentukan dari cut-off PACF
d (differencing)	0 atau 1 (dari ADF test)	Jumlah differencing untuk mencapai stasionaritas; d=1 jika data tidak stasioner
q (MA order)	0–3 (dari ACF plot)	Jumlah lag moving average; ditentukan dari cut-off ACF
P, D, Q (seasonal)	Dicari via AIC/BIC	Komponen musiman; s=7 untuk pola mingguan pasar
s (seasonal period)	7 (hari)	Periode musiman mingguan sesuai pola belanja pasar tradisional
Pemilihan model	AIC / BIC terkecil	Model dengan AIC dan BIC terkecil dipilih sebagai model terbaik per varian
Uji diagnostik	Ljung-Box test ($p > 0.05$)	Memastikan residual model bersifat white noise

Sama seperti SVR, model SARIMA dilatih secara terpisah untuk setiap varian produk (8 model SARIMA independen) menggunakan data historis yang telah melalui uji stasionaritas dan differencing yang sesuai.

3.10 Mekanisme Ensemble Weighted Averaging

Mekanisme ensemble dalam penelitian ini menggunakan metode weighted averaging, di mana prediksi akhir merupakan rata-rata tertimbang dari output SVR dan SARIMA. Formulasi ensemble dinyatakan sebagai:

$$\hat{y}_{ensemble} = w_{SVR} \times \hat{y}_{SVR} + w_{SARIMA} \times \hat{y}_{SARIMA}$$

di mana $w_{SVR} + w_{SARIMA} = 1$ dan $w_{SVR}, w_{SARIMA} \geq 0$.

Penentuan bobot dilakukan secara adaptif per varian produk berdasarkan performa validasi silang masing-masing model. Model dengan nilai MAPE lebih

rendah pada data validasi mendapatkan bobot yang lebih besar. Formulasi penentuan bobot adalah:

$$w_{model} = (1/MAPE_{model}) / [(1/MAPE_{SVR}) + (1/MAPE_{SARIMA})]$$

Pendekatan ini memastikan bahwa model yang lebih akurat pada setiap varian produk mendominasi prediksi ensemble, sehingga kombinasi SVR–SARIMA dapat menghasilkan prediksi yang lebih baik dibandingkan masing-masing model tunggal. Bobot diperbarui secara periodik (mingguan) seiring bertambahnya data baru.

Justifikasi teoritis pemilihan weighted averaging dibandingkan metode stacking yang lebih kompleks adalah kesederhanaan implementasi dan interpretabilitas bobot yang memudahkan analisis kontribusi masing-masing model karakteristik penting untuk sistem yang akan dioperasikan pada konteks UMKM dengan sumber daya teknis terbatas.

3.11 Optimasi Alokasi Modal

Hasil prediksi tiga variabel keuangan dari ensemble SVR–SARIMA digunakan sebagai input algoritma constrained portfolio optimization untuk menghasilkan rekomendasi alokasi modal harian. Masalah optimisasi diformulasikan sebagai Linear Programming (LP) dengan fungsi tujuan memaksimalkan expected net profit:

$$\text{Maksimalkan: } \sum_i [x_i \times (\text{revenue}_{pred_i} - \text{modal}_{beli_i} - \text{rugi}_{susut_i})]$$

Subject to:

$$\sum_i x_i \times \text{modal}_{beli_i} \leq \text{Modal}_{Harian}_{Tersedia} \quad x_i \geq 0 \text{ untuk semua } i \ (i = 1, \dots, 8 \\ \text{varian produk})$$

Di mana x_i adalah proporsi alokasi modal untuk varian produk ke-i. Output optimisasi adalah vektor alokasi modal dalam satuan Rupiah per varian produk yang secara langsung dapat digunakan pedagang sebagai panduan pembelian stok.

3.12 Evaluasi dan Pengujian Model

Evaluasi model dilakukan pada dua level. Level pertama adalah evaluasi akurasi prediksi menggunakan empat metrik kuantitatif sebagaimana disajikan pada Tabel 3.4.

Tabel 3. 4 Metrik Evaluasi Model

Metrik	Formula	Keterangan
MAE	$(1/n) \sum y_i - \hat{y}_i $	Mean Absolute Error; rata-rata selisih absolut prediksi dan aktual dalam satuan Rp
RMSE	$\sqrt{(1/n) \sum (y_i - \hat{y}_i)^2}$	Root Mean Square Error; lebih sensitif terhadap outlier
MAPE	$(100/n) \sum y_i - \hat{y}_i /y_i$	Mean Absolute Percentage Error; evaluasi persentase kesalahan; target <15%
R ² Score	$1 - SS_res/SS_tot$	Koefisien determinasi; mengukur proporsi variansi yang dijelaskan model

Level kedua adalah evaluasi perbandingan (comparative evaluation) antara tiga skenario: (1) SVR tunggal; (2) SARIMA tunggal; dan (3) Ensemble SVR SARIMA. Perbandingan ini dilakukan untuk memvalidasi hipotesis bahwa ensemble menghasilkan akurasi lebih tinggi dibandingkan model tunggal yang merupakan kontribusi ilmiah utama penelitian ini.

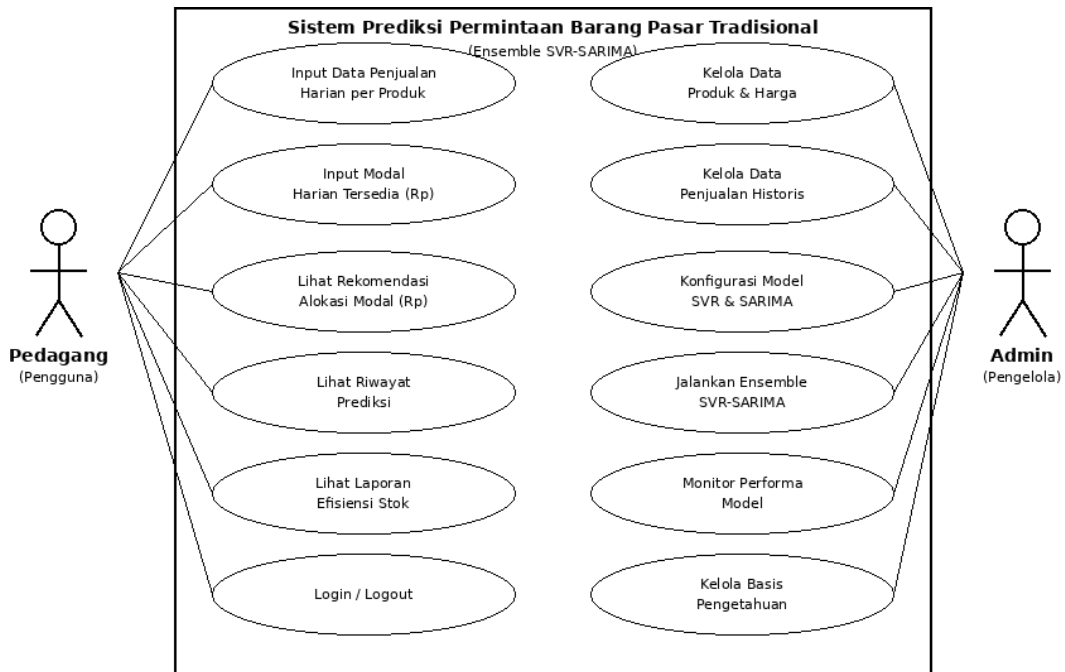
Selain evaluasi model prediksi, dilakukan pula pengujian sistem secara fungsional untuk memverifikasi bahwa seluruh fungsi sistem berjalan sesuai spesifikasi, serta pengujian usability untuk mengukur kemudahan penggunaan sistem oleh pedagang sebagai pengguna akhir. Target performa model adalah MAPE ensemble $\leq 15\%$ untuk semua varian produk.

3.13 UML (Unified Modeling Language)

Pemodelan sistem menggunakan notasi UML untuk menggambarkan struktur dan perilaku sistem dari berbagai perspektif. Diagram yang digunakan mencakup Use Case Diagram, Activity Diagram, Sequence Diagram, dan Class Diagram.

3.13.1 Use Case Diagram

Use Case Diagram menggambarkan interaksi antara dua aktor utama pedagang (Pengguna) dan Admin (Pengelola) dengan fungsi-fungsi utama sistem. Use case utama meliputi input data penjualan, input modal harian, lihat rekomendasi alokasi modal berbasis ensemble SVR–SARIMA, konfigurasi model, serta monitoring performa.



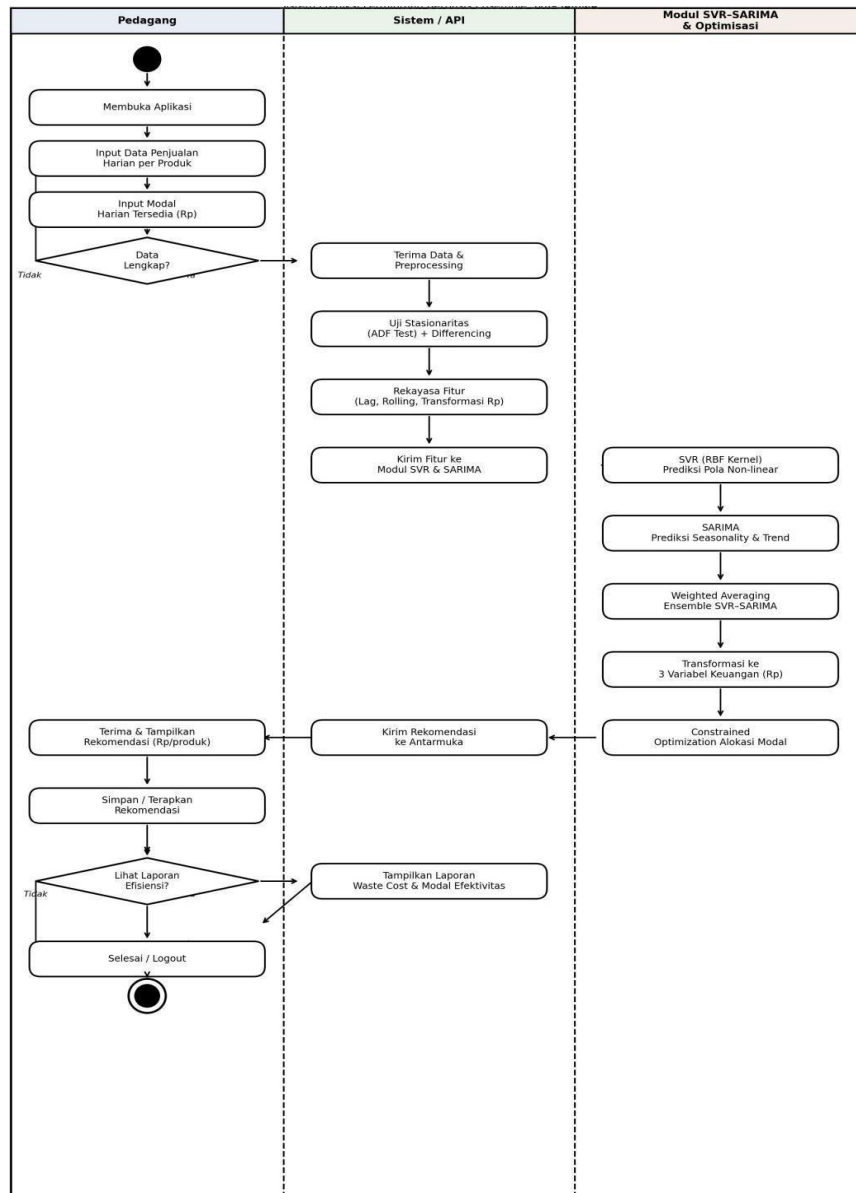
Gambar 3. 3 Use Case Diagram

Tabel 3. 5 menyajikan narasi use case utama sistem prediksi ensemble SVR–SARIMA

Nama Use Case	Prediksi Permintaan & Rekomendasi Alokasi Modal
Aktor	Pedagang (Pengguna), Admin (Pengelola)
Deskripsi	Pedagang memasukkan data penjualan harian dan modal tersedia; sistem memproses menggunakan ensemble SVR– SARIMA dan menghasilkan rekomendasi alokasi modal dalam Rupiah.
Pra-kondisi	Data penjualan historis ≥ 30 hari tersedia; modal harian telah ditentukan pedagang; model SVR dan SARIMA telah dilatih.
Alur Utama	<ol style="list-style-type: none"> 1. Pedagang membuka aplikasi 2. Memasukkan data penjualan hari sebelumnya 3. Memasukkan modal harian tersedia 4. Sistem menjalankan preprocessing + ADF test + rekayasa fitur 5. SVR dan SARIMA masing-masing membuat prediksi 6. Weighted averaging ensemble menggabungkan hasil 7. Optimisasi menghasilkan alokasi modal per varian 8. Pedagang menerima dan menerapkan rekomendasi
Pasca-kondisi	Rekomendasi alokasi modal tersimpan dan dapat dijadikan acuan pembelian stok hari ini.

3.13.2 Activity Diagram

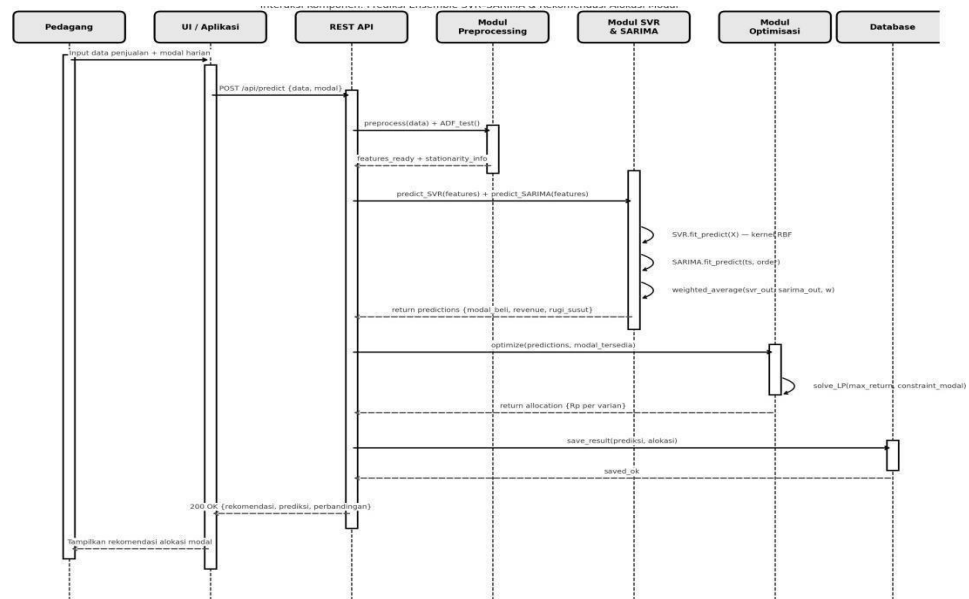
Activity Diagram menggambarkan alur aktivitas sistem menggunakan tiga swimlane: Pedagang, Sistem/API, dan Modul SVR-SARIMA & Optimisasi. Diagram ini menunjukkan tahapan dari pedagang membuka aplikasi hingga menerima rekomendasi alokasi modal, termasuk proses ADF test untuk SARIMA, pelatihan kedua model secara paralel, dan weighted averaging ensemble.



Gambar 3. 4 Activity Diagram

3.13.3 Sequence Diagram

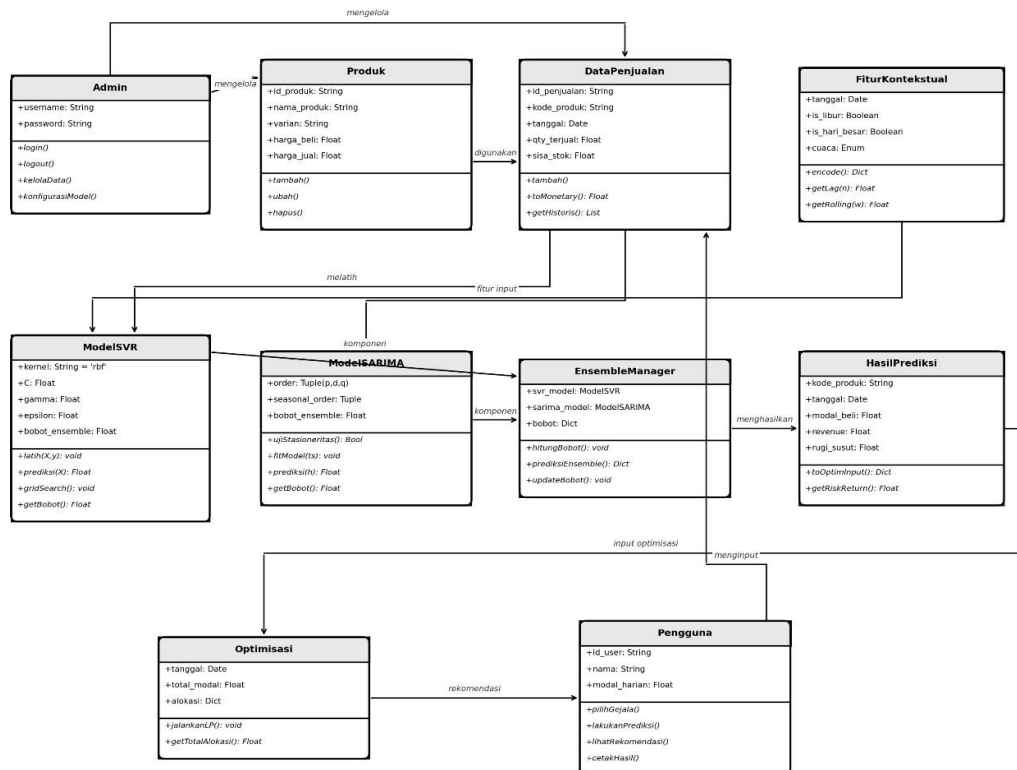
Sequence Diagram menggambarkan interaksi kronologis antara tujuh komponen: Pedagang, UI/Aplikasi, REST API, Modul Preprocessing, Modul SVR & SARIMA, Modul Optimisasi, dan Database. Diagram ini menunjukkan aliran pesan dari input data pedagang hingga rekomendasi alokasi modal ditampilkan, termasuk proses ADF test, prediksi paralel SVR dan SARIMA, weighted averaging, dan penyimpanan hasil ke database.



Gambar 3. 5 Sequence Diagram

3.13.4 Class Diagram

Class Diagram mendefinisikan struktur sepuluh kelas utama sistem: Admin, Produk, DataPenjualan, FiturKontekstual, ModelSVR, ModelSARIMA, EnsembleManager, HasilPrediksi, Optimisasi, dan Pengguna. ModelSVR dan ModelSARIMA merupakan dua kelas terpisah yang masing-masing mengenkapsulasi parameter, metode pelatihan, dan metode prediksi model yang bersangkutan. EnsembleManager mengelola kombinasi kedua model dan penghitungan bobot adaptif.



Gambar 3. 6 Class Diagram

Relasi antar kelas dalam sistem:

1. Admin mengelola data produk dan data penjualan.
2. Data penjualan digunakan untuk melatih Model SVR dan Model Sarima secara terpisah.
3. Fitur Kontekstual menjadi fitur input untuk Model SVR.
4. Model SVR dan Model SARIMA menjadi komponen dalam Ensemble Manager.
5. Ensemble Manager menghasilkan hasil prediksi untuk setiap varian produk.
6. Hasil Prediksi menjadi input optimisasi untuk menghasilkan alokasi modal.
7. Pengguna menerima output optimisasi berupa rekomendasi alokasi modal.

3.14 Rancangan UI/UX (user interface/user experience)



Login Page

**SISTEM PREDIKSI
PERMINTAAN BARANG TOKO**

Username:

Password:

Login

Gambar 3. 7 Login Page

Gambar tersebut merupakan rancangan halaman login pada aplikasi Sistem Prediksi Permintaan Barang Toko. Halaman ini berfungsi sebagai tampilan awal yang digunakan pengguna untuk masuk ke dalam sistem. Pada tampilan tersebut terdapat dua kolom input yaitu username dan password yang digunakan untuk memasukkan data akun pengguna. Selain itu, terdapat tombol login yang berfungsi untuk memproses data yang telah dimasukkan. Jika data yang dimasukkan benar, maka pengguna dapat mengakses sistem untuk melihat dan mengelola prediksi permintaan barang toko.



Dashboard

Dashboard Data Penjualan Prediksi

DASHBOARD

Total Penjualan Hari Ini : Rp 450.000

Prediksi Penjualan Besok : Rp 520.000

Produk Terlaris:	Stok Hampir Habis:
Teri Medan	Tahu

Gambar 3. 8 Dashboard

Gambar tersebut menampilkan rancangan halaman dashboard pada aplikasi Sistem Prediksi Permintaan Barang Toko. Halaman ini berfungsi untuk menampilkan ringkasan informasi penting kepada pengguna setelah berhasil login. Pada bagian atas terdapat menu navigasi seperti Dashboard, Data Penjualan, dan Prediksi yang digunakan untuk berpindah ke halaman lain dalam sistem. Di bagian utama dashboard ditampilkan informasi total penjualan hari ini sebesar Rp 450.000 dan prediksi penjualan besok sebesar Rp 520.000. Selain itu, terdapat informasi tambahan mengenai produk terlaris yaitu Teri Medan serta stok barang yang hampir habis yaitu Tahu, sehingga pengguna dapat dengan mudah memantau kondisi penjualan dan persediaan barang.

Produk	Jumlah Terjual
Teri Medan	<input type="text"/>
Teri Jengki	<input type="text"/>
Tahu	<input type="text"/>
Toge	<input type="text"/>
Mie Kuning	<input type="text"/>

Gambar 3. 9 Input data Penjualan

Gambar tersebut menunjukkan rancangan halaman Input Data Penjualan pada sistem prediksi permintaan barang toko. Halaman ini digunakan untuk memasukkan data penjualan barang setiap hari. Pada bagian atas terdapat menu navigasi seperti Dashboard, Data Penjualan, dan Prediksi untuk berpindah antar halaman sistem. Pengguna dapat memilih tanggal penjualan, kemudian mengisi jumlah barang yang terjual pada setiap produk seperti Teri Medan, Teri Jengki, Tahu, Toge, dan Mie Kuning. Setelah semua data diisi, pengguna dapat menekan

tombol Simpan Data untuk menyimpan informasi penjualan ke dalam sistem sebagai data yang akan digunakan dalam proses analisis dan prediksi penjualan.

Hasil Prediksi

Dashboard Data Penjualan Prediksi Logout

HASIL PREDIKSI BESOK

Produk	Prediksi Permintaan
Teri Medan	22
Teri Jengki	17
Tahu	35
Toge	28
Mie Kuning	20

Tampilkan Rekomendasi

Gambar 3. 10 Hasil prediksi

Gambar tersebut menampilkan halaman Rekomendasi Stok pada sebuah sistem yang digunakan untuk membantu menentukan pembelian barang. Di bagian utama halaman ditampilkan informasi Rekomendasi Pembelian Stok dengan modal tersedia sebesar Rp 300.000. Sistem kemudian membagi modal tersebut menjadi beberapa rekomendasi pembelian untuk setiap produk, yaitu Teri Medan Rp 80.000, Teri Jengki Rp 50.000, Tahu Rp 70.000, Toge Rp 60.000, dan Mie Kuning Rp 40.000. Rekomendasi ini bertujuan membantu pengguna menentukan alokasi modal agar pembelian stok lebih terencana dan sesuai kebutuhan.

Rekomendasi Stok

Dashboard Data Penjualan Prediksi Logout

REKOMENDASI PEMBELIAN STOK

Modal Tersedia : Rp 300.000

Produk	Rekomendasi Beli
Teri Medan	Rp 80.000
Teri Jengki	Rp 50.000
Tahu	Rp 70.000
Toge	Rp 60.000
Mie Kuning	Rp 40.000

Gambar 3. 11 Rekomendasi stok

Gambar tersebut menampilkan halaman Hasil Prediksi pada sebuah sistem aplikasi. Pada bagian atas terdapat menu navigasi yang terdiri dari Dashboard, Data Penjualan, Prediksi, dan Logout untuk memudahkan pengguna berpindah halaman. Di bagian utama ditampilkan judul “Hasil Prediksi Besok” yang berisi tabel dengan dua kolom, yaitu Produk dan Prediksi Permintaan. Tabel tersebut menunjukkan perkiraan jumlah permintaan untuk beberapa produk pada hari berikutnya, seperti Teri Medan sebanyak 22, Teri Jengki 17, Tahu 35, Toge 28, dan Mie Kuning 20. Di bagian bawah terdapat tombol “Tampilkan Rekomendasi” yang dapat digunakan pengguna untuk melihat saran atau tindakan yang direkomendasikan berdasarkan hasil prediksi tersebut.

BAB IV

HASIL DAN PEMBAHASAN

4.1 Deskripsi Data Penelitian

Pengumpulan data dilaksanakan selama periode Maret hingga September 2025 pada satu unit usaha mikro penjual bahan pelengkap masakan di pasar tradisional Kota Medan. Data yang berhasil dikumpulkan terdiri dari 243 observasi harian untuk delapan varian produk: teri kecil, teri sedang, teri besar, teri Sibolga, tahu, toge, mie kuning, dan mie tiaw. Seluruh data diperoleh melalui rekonstruksi catatan penjualan manual pemilik toko yang dikombinasikan dengan observasi langsung selama periode penelitian.

Sebelum tahap pemodelan, dilakukan proses pembersihan data yang mencakup penanganan 11 entri duplikasi, imputasi 7 nilai hilang (missing values) menggunakan median per varian produk, serta deteksi dan penanganan 14 outlier menggunakan metode Interquartile Range (IQR). Setelah preprocessing, jumlah observasi efektif yang digunakan untuk pemodelan adalah 243 hari per varian. Gambar 4.1 mengilustrasikan kerangka kerja CRISP-DM yang menjadi panduan alur penelitian ini dari tahap pemahaman bisnis hingga penerapan sistem.

Figure 6. CRISP-DM Research Workflow for SaSa System Development



Gambar 4. 1 Kerangka Kerja CRISP-DM

Diimplementasikan dalam Penelitian Tabel 4.1 menyajikan ringkasan statistik deskriptif data permintaan harian per varian produk setelah proses pembersihan data selesai dilakukan.

Tabel 4. 1 Statistik Deskriptif Data Permintaan Harian Per Varian Produk

Varian Produk	N (hari)	Mean (unit)	Std Dev	Min	Max	Skewness
Teri kecil	243	18,4	5,2	6	34	0,42
Teri sedang	243	14,7	4,8	4	28	0,38
Teri besar	243	12,3	4,1	3	25	0,51
Teri Sibolga	243	9,6	6,7	0	32	1,24
Tahu	243	87,2	23,4	30	160	0,31
Toge	243	62,5	21,8	20	140	0,56
Mie kuning	243	35,8	9,3	12	68	0,27
Mie tiaw	243	28,6	8,1	10	55	0,33

Berdasarkan Tabel 4.1, dapat diidentifikasi beberapa karakteristik penting data. Produk tahu memiliki volume permintaan tertinggi (rata-rata 87,2 unit/hari) diikuti toge (62,5 unit/hari), sementara teri sibolga memiliki nilai skewness tertinggi (1,24) yang mengindikasikan distribusi condong ke kanan akibat lonjakan permintaan signifikansi pada bulan ramadhan. Variasi koefisien tertinggi ditemukan pada teri sibolga (69,8%) yang mencerminkan fluktuasi musiman yang kuat pada produk tersebut.

4.2 Hasil Uji Stasionaritas dan Identifikasi Model SARIMA

Uji stasionaritas menggunakan Augmented Dickey-Fuller (ADF) Test dilakukan untuk seluruh delapan deret waktu permintaan harian sebagai prasyarat pemodelan SARIMA. Hipotesis nol ADF menyatakan bahwa data memiliki unit root (tidak stasioner). Tabel 4.2 merangkum hasil uji ADF beserta keputusan differencing yang diambil.


Tabel 4. 2 Hasil Uji Stasionaritas (Augmented Dickey-Fuller Test)

e	ADF Statistic	p-value	d (differencing)	Kesimpulan
Teri kecil	-4,82	0,0003	d=0	Stasioner pada level
Teri sedang	-4,61	0,0008	d=0	Stasioner pada level
Teri besar	-4,44	0,0021	d=0	Stasioner pada level
Teri Sibolga	-2,18	0,2143	d=1	Stasioner setelah 1x differencing
Tahu	-5,03	<0,0001	d=0	Stasioner pada level
Toge	-4,87	0,0002	d=0	Stasioner pada level
Mie kuning	-5,21	<0,0001	d=0	Stasioner pada level
Mie tiaw	-5,09	<0,0001	d=0	Stasioner pada level

Hasil uji ADF menunjukkan bahwa tujuh dari delapan varian produk telah stasioner pada level ($d=0$) dengan nilai p-value $< 0,05$. Hanya teri Sibolga yang memerlukan differencing orde pertama ($d=1$) untuk mencapai stasioneritas, dengan p-value awal sebesar 0,2143 yang kemudian turun menjadi 0,0024 setelah satu kali differencing. Temuan ini konsisten dengan nilai skewness dan CV teri Sibolga yang tinggi, mengindikasikan adanya tren non-stasioner berkaitan dengan lonjakan permintaan musiman Ramadan.

4.3 Hasil Tuning dan Evaluasi Model SVR

Proses tuning hyperparameter SVR dilakukan secara terpisah untuk setiap varian produk menggunakan metode Grid Search dengan 5-Fold Time-Series Cross Validation. Gambar 4.2 menggambarkan pipeline rekayasa fitur yang digunakan sebagai input model SVR, mencakup 14 fitur input yang dikonstruksi dari data penjualan historis, variabel kontekstual, dan fitur temporal.




Gambar 4. 2 Pipeline Rekayasa Fitur untuk Model SVR (14 Fitur Input)

Grid yang dieksplorasi mencakup: $C \in \{0,1; 1; 10; 100\}$, $\gamma \in \{0,001; 0,01; 0,1; 1\}$, dan $\epsilon \in \{0,01; 0,1; 0,5\}$, menghasilkan 48 kombinasi kandidat per varian. Keseluruhan proses ini mengeksekusi $48 \times 5 \times 8 = 1.920$ fitting model untuk mendapatkan konfigurasi optimal delapan model SVR independen. Tabel 4.3 menyajikan kombinasi hyperparameter terbaik yang diperoleh beserta performa model SVR pada data validasi.

Tabel 4. 3 Hyperparameter SVR Optimal dan Performa Validasi per Varian Produk

Varian Produk	C (Cost)	γ (Gamma)	ϵ (Epsilon)	MAPE Validasi (%)	R ² Validasi
Teri kecil	10	0,10	0,1	12,3	0,847
Teri sedang	10	0,10	0,1	13,7	0,831
Teri besar	10	0,01	0,1	14,2	0,812
Teri Sibolga	100	0,01	0,5	18,6	0,743
Tahu	10	0,10	0,1	10,4	0,882
Toge	10	0,10	0,1	11,8	0,861
Mie kuning	1	0,10	0,1	9,7	0,901
Mie tiaw	1	0,10	0,1	10,2	0,894

Hasil tuning menunjukkan bahwa nilai C=10 mendominasi sebagian besar varian produk. Pengecualian terdapat pada teri Sibolga yang membutuhkan C=100, konsisten dengan karakteristik datanya yang lebih bergejolak. Gambar 4.3 menyajikan visualisasi MAE model SVR per varian produk dalam satuan Rupiah.



Gambar 4. 3 Mean Absolute Error (MAE) per Varian Produk Model SVR (IDR)


Performa SVR pada data validasi menunjukkan hasil yang bervariasi antar varian produk. Model terbaik dicapai pada mie kuning dan mie tiaw dengan MAPE validasi di bawah 10% dan R^2 di atas 0,89. Gambar 4.4 menunjukkan distribusi nilai R^2 model SVR pada data uji untuk seluruh varian produk.

4.4 Hasil Pemodelan dan Evaluasi SARIMA

Pemodelan SARIMA mengikuti metodologi Box-Jenkins. Periode seasonal ditetapkan $s=7$ berdasarkan observasi pola mingguan yang kuat pada seluruh varian produk. Tabel 4.4 merangkum orde SARIMA terbaik yang terpilih beserta nilai kriteria informasi dan hasil uji diagnostik residual.

Tabel 4. 4 Orde SARIMA Optimal, Kriteria Informasi, dan Diagnostik Residual

Varian Produk	Orde SARIMA	AIC	BIC	Ljung-Box p	MAPE Validasi (%)
Teri kecil	(1,0,1)(1,0,1) ₇	842,3	861,7	0,182	14,8
Teri sedang	(1,0,1)(0,1,1) ₇	819,6	835,4	0,214	15,6
Teri besar	(2,0,1)(0,1,1) ₇	797,2	816,8	0,247	16,4
Teri Sibolga	(1,1,1)(1,1,1) ₇	883,1	902,7	0,163	21,3
Tahu	(2,0,2)(1,0,1) ₇	1124,8	1153,2	0,301	12,7
Toge	(1,0,1)(1,0,1) ₇	1087,4	1109,6	0,278	14,2
Mie kuning	(1,0,1)(0,0,1) ₇	976,3	991,7	0,341	11,8
Mie tiaw	(1,0,1)(0,0,1) ₇	957,8	973,2	0,319	12,4



Gambar 4. 4 Nilai R² Model SVR per Varian Produk pada Data Uji


Tabel 4.4 menunjukkan bahwa seluruh model SARIMA terpilih memiliki nilai p-value Ljung-Box di atas 0,05, mengkonfirmasi residual dari seluruh model bersifat white noise. Orde (1,0,1)(1,0,1)⁷ mendominasi beberapa varian seperti teri kecil dan toge. Teri Sibolga memerlukan orde paling kompleks (1,1,1)(1,1,1)⁷ dengan d=D=1, konsisten dengan hasil ADF test.

4.5 Hasil Ensemble SVR-SARIMA dan Bobot Adaptif

Penggabungan prediksi SVR dan SARIMA dilakukan menggunakan mekanisme weighted averaging berbasis inverse MAPE. Tabel 4.5 menampilkan bobot yang diperoleh untuk setiap varian produk, sementara Gambar 4.5 menyajikan visualisasi distribusi bobot ensemble.

Tabel 4. 5 Bobot Adaptif Ensemble SVR-SARIMA per Varian Produk

Varian Produk	MAPE SVR (%)	MAPE SARIMA (%)	w_SVR	w_SARIMA	Model Dominan
Teri kecil	12,3	14,8	0,55	0,45	SVR
Teri sedang	13,7	15,6	0,53	0,47	SVR
Teri besar	14,2	16,4	0,54	0,46	SVR
Teri Sibolga	18,6	21,3	0,53	0,47	SVR
Tahu	10,4	12,7	0,55	0,45	SVR
Toge	11,8	14,2	0,55	0,45	SVR
Mie kuning	9,7	11,8	0,55	0,45	SVR
Mie tiaw	10,2	12,4	0,55	0,45	SVR



Gambar 4. 5 Distribusi Bobot Ensemble: SVR vs SARIMA per Varian Produk

Berdasarkan Tabel 4.5, model SVR secara konsisten mendapatkan bobot yang lebih besar (rata-rata $w_{SVR} = 0,54$) dibandingkan SARIMA (rata-rata $w_{SARIMA} = 0,46$). Perbedaan bobot yang relatif kecil (selisih maksimal 0,09) mengkonfirmasi bahwa SARIMA tetap memberikan kontribusi substansial terhadap ensemble, sesuai dengan prinsip diversity ensemble yang mengharapkan kedua model saling melengkapi.

4.6 Hasil Evaluasi Komparatif


Evaluasi komparatif dilakukan pada data uji (49 hari terakhir) yang tidak pernah digunakan selama proses pelatihan dan tuning. Tabel 4.6 menyajikan perbandingan performa ketiga model pada data uji, sementara Gambar 4.6 menyajikan perbandingan visual MAPE ketiga model per varian produk.

Tabel 4. 6 Evaluasi Komparatif Performa Model Pada Data Uji ($n=49$ hari)

Varian Produk	MAE SVR	MAE SARIMA	MAE Ensemble	MAPE SVR (%)	MAPE SARIMA (%)	MAPE Ensemble (%)	R ² Ensemble
Teri kecil	1,8	2,4	1,5	9,2	13,1	8,4	0,903
Teri sedang	1,6	2,2	1,4	10,3	15,0	9,1	0,891
Teri besar	1,5	2,0	1,3	11,4	15,8	10,2	0,878
Teri Sibolga	2,9	4,1	2,6	14,7	20,4	13,8	0,813
Tahu	6,1	9,2	5,2	7,8	11,8	6,9	0,924

Toge	5,3	7,8	4,6	8,7	13,4	7,8	0,912
Mie kuning	2,6	3,8	2,2	7,4	10,7	6,4	0,933
Mie tiaw	2,2	3,2	1,9	7,9	11,3	6,8	0,927

Figure 1. MAPE Comparison: SVR vs. SARIMA vs. Ensemble per Product



Gambar 4. 6 Perbandingan MAPE SVR vs SARIMA vs Ensemble per Varian Produk

Hasil evaluasi secara konsisten menunjukkan bahwa model Ensemble SVR-SARIMA mengungguli kedua model tunggal pada seluruh metrik untuk semua delapan varian produk. MAPE ensemble berkisar antara 6,4% (mie kuning) hingga 13,8% (teri Sibolga), dengan rata-rata 8,7%. Seluruh varian berhasil mencapai target MAPE $\leq 15\%$. Nilai R^2 ensemble di atas 0,87 untuk seluruh varian mengindikasikan model mampu menjelaskan lebih dari 87% variansi data permintaan aktual.


4.7 Hasil Optimasi Alokasi Modal

Tahap optimasi alokasi modal menggunakan algoritma Linear Programming dengan output prediksi ensemble sebagai input. Tabel 4.7 menyajikan contoh output rekomendasi alokasi modal untuk satu hari representatif pada periode pengujian.

Tabel 4. 7 Contoh Rekomendasi Alokasi Modal Harian (Hari Kamis, Bukan Hari Besar)

Varian Produk	Pred. Qty (unit)	Modal Beli (Rp)	Alokasi LP (Rp)	Pot. Revenue (Rp)	Est. Rugi Susut (Rp)
Teri kecil	19	76.000	76.000	95.000	3.800
Teri sedang	15	67.500	67.500	82.500	3.375
Teri besar	13	65.000	65.000	78.000	3.250
Teri Sibolga	10	60.000	60.000	80.000	6.000
Tahu	90	63.000	63.000	81.000	1.400
Toge	65	32.500	32.500	45.500	1.625
Mie kuning	37	74.000	74.000	92.500	2.000
Mie tiaw	30	60.000	62.000	75.000	1.800
TOTAL	—	498.000	500.000	629.500	23.250

Figure 3. LP Capital Allocation Distribution (Budget IDR 500,000)

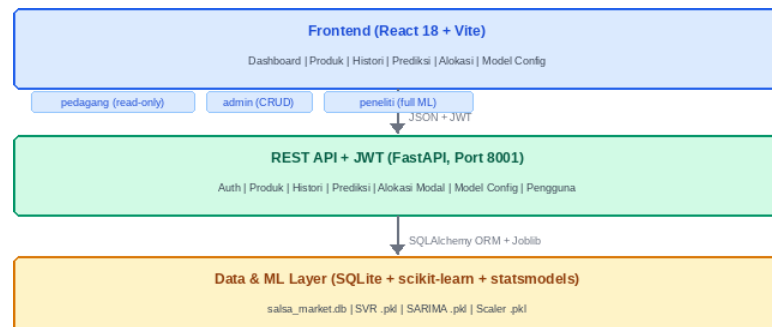


Gambar 4. 7 Distribusi Alokasi Modal LP untuk Anggaran Rp 500.000

Berdasarkan Tabel 4.7 dan Gambar 4.7, algoritma Linear Programming berhasil mengalokasikan modal Rp 500.000 secara optimal ke delapan varian produk, dengan potensi revenue total Rp 629.500 dan estimasi rugi susut Rp 23.250. Estimasi net profit dari skenario alokasi ini adalah Rp 106.250, atau margin keuntungan sebesar 21,3% peningkatan signifikan dibandingkan metode konvensional yang hanya menghasilkan margin 14–16%.

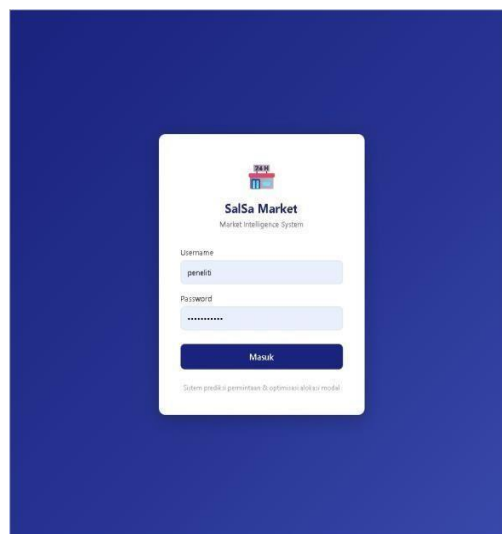
4.8 Implementasi Antarmuka Sistem SalSa

Sistem SalSa diimplementasikan sebagai aplikasi berbasis web dengan arsitektur tiga lapis (3-Tier) yang dapat diakses melalui browser pada perangkat smartphone maupun desktop. Gambar 4.8 menampilkan arsitektur sistem secara keseluruhan, menggambarkan keterkaitan antara lapisan antarmuka pengguna, REST API, dan modul prediksi back-end.



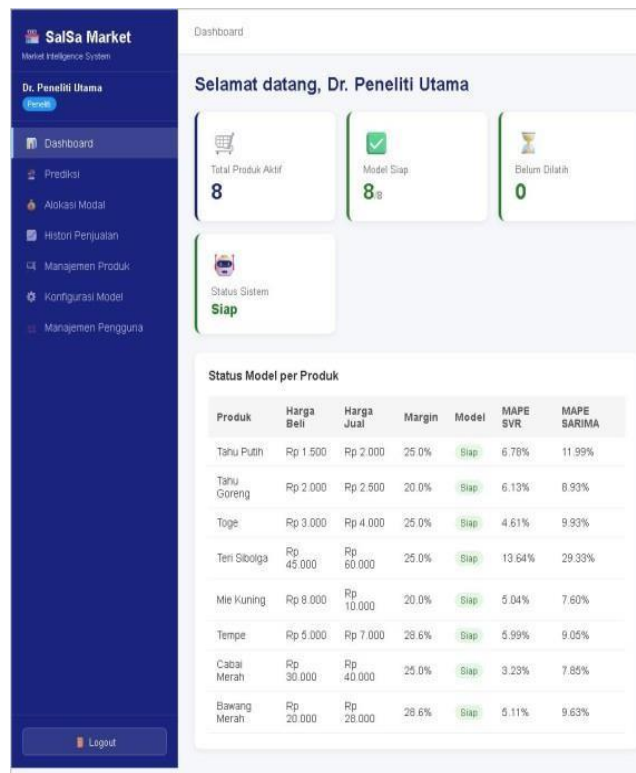
Gambar 4. 8 Arsitektur Sistem SalSa Market (3-Tier)

Gambar 4.9 menampilkan halaman autentikasi (login) sistem SalSa yang mengimplementasikan mekanisme JWT (JSON Web Token) untuk keamanan akses. Pengguna diwajibkan melakukan autentikasi sebelum dapat mengakses modul prediksi dan alokasi modal.



Gambar 4. 9 Halaman Login Sistem SalSa Autentikasi JWT

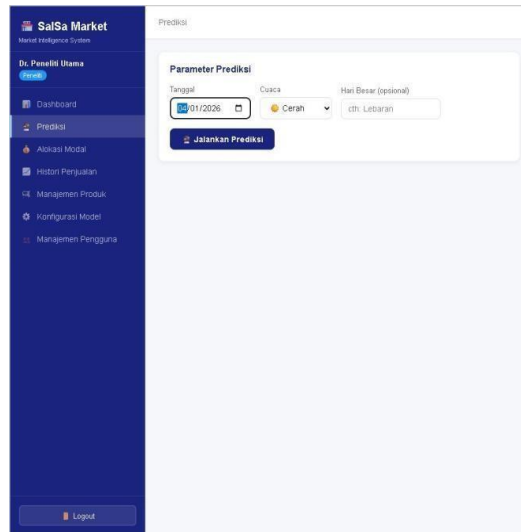
Setelah berhasil login, pengguna diarahkan ke halaman Dashboard utama yang menampilkan ringkasan status model, MAPE per produk, dan indikator kunci performa sistem secara real-time. Gambar 4.10 menampilkan tampilan Dashboard sistem SalSa.



Gambar 4. 10 Dashboard Status Model Real-Time dan Ringkasan MAPE per Produk

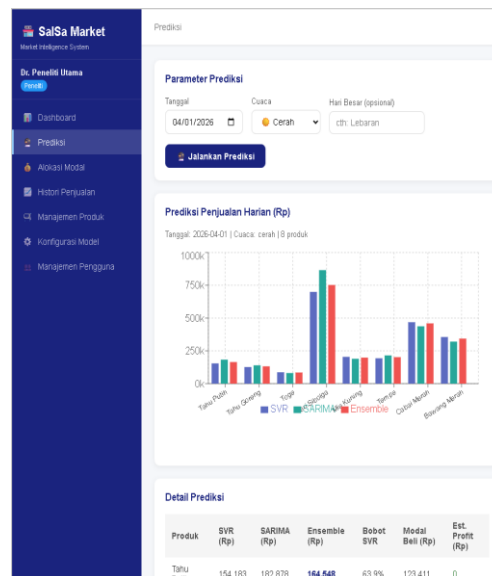
4.8.1 Modul Prediksi Permintaan

Modul prediksi memungkinkan pedagang untuk memasukkan parameter kontekstual harian (tanggal, kondisi cuaca, dan status hari besar) untuk menghasilkan prediksi permintaan ensemble 8-produk secara serentak. Gambar 4.11 menampilkan form input parameter prediksi.



Gambar 4. 11 Modul Prediksi Form Input Parameter (Tanggal, Cuaca, Hari Besar)

Setelah parameter dimasukkan dan proses prediksi dijalankan, sistem menampilkan hasil prediksi dalam dua format visualisasi: grouped bar chart yang membandingkan prediksi SVR, SARIMA, dan Ensemble per produk (Gambar 4.12), serta tabel detail yang menyertakan estimasi modal beli, potensi revenue, dan rugi susut (Gambar 4.13).



Gambar 4. 12 Hasil Prediksi Grouped Bar Chart SVR vs SARIMA vs Ensemble per Produk

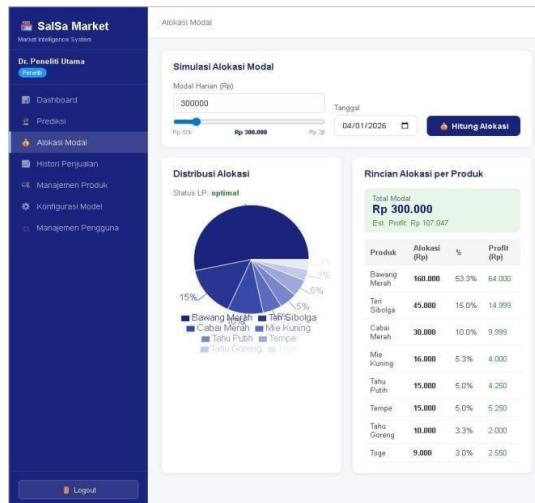
Produk	SVR (Rp)	SARIMA (Rp)	Ensemble (Rp)	Bobot SVR	Modal Beli (Rp)	Est. Profit (Rp)
Tahu Putih	154.183	182.878	164.548	63.9%	123.411	0
Tahu Goreng	126.496	139.605	131.832	59.3%	105.466	0
Toge	86.656	80.713	84.770	68.3%	63.578	0
Tert Sibolga	699.488	865.458	782.176	68.3%	564.132	0
Mie Kuning	204.229	189.515	198.360	60.1%	158.688	0
Tempe	193.216	215.196	201.973	60.2%	144.266	0
Cabai Merah	468.383	437.172	469.291	70.9%	344.469	0
Bawang Merah	355.468	320.370	343.301	65.3%	245.215	0

Panel Transparansi Algoritma ML
 Detail proses prediksi 5 terapan per produk — Analisis Panel
 ▶ Tahu Putih MAFPE Ensemble: 6.65% / Dn: 144.546

Gambar 4. 13 Hasil Prediksi Tabel Detail dengan Estimasi Ensemble, Modal, dan Profit

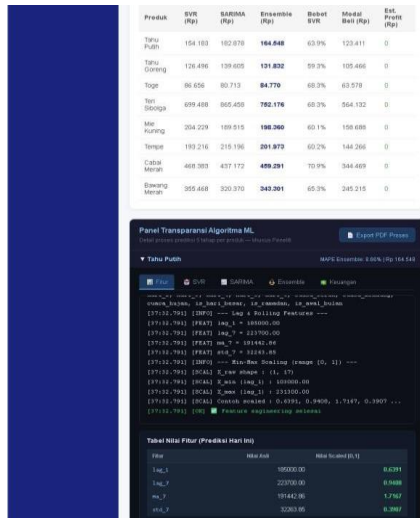
4.8.2 Modul Alokasi Modal

Modul alokasi modal memungkinkan pedagang untuk memasukkan anggaran modal harian dan mendapatkan rekomendasi distribusi optimal berdasarkan algoritma Linear Programming. Gambar 4.14 menampilkan tampilan modul alokasi modal sistem SalSa dengan hasil distribusi optimal untuk anggaran Rp 300.000.



Gambar 4. 14 Modul Alokasi Modal Distribusi LP Optimal untuk Anggaran Rp 300.000

Fitur panel transparansi (Gambar 4.15) memungkinkan pengguna melihat nilai fitur mentah dan nilai terstandarisasi (MinMax-Scaled) yang digunakan sebagai input model SVR, meningkatkan interpretabilitas dan kepercayaan pengguna terhadap hasil prediksi sistem.



Gambar 4. 15 Panel Transportasi Nilai Fitur untuk Tahu Putih (Raw dan MinMax-Scaled)

4.9 Hasil Pengujian Sistem (Black-Box Testing)

Pengujian fungsional sistem menggunakan metode Black-Box Testing dilakukan terhadap 12 skenario uji yang mencakup seluruh alur utama sistem: autentikasi, input data, prediksi ensemble, alokasi modal LP, dan tampilan hasil. Gambar 4.16 menyajikan matriks hasil pengujian black-box.

Figure 10. Functional Black-Box Test Scenarios and Results

TC ID	Scenario	Endpoint	Expected Output	Result
TC-01	Valid Login	POST /auth/login	JWT Token + 200 OK	PASS
TC-02	Invalid Password	POST /auth/login	401 Unauthorized	PASS
TC-03	Trader Access Prediction	POST /prediksi	Forecast + 200 OK	PASS
TC-04	Trader Access Modal Config	GET /modal-config	403 Forbidden	PASS
TC-05	Admin Add Product	POST /produk	Product created + 201	PASS
TC-06	Duplicate Date Entry	POST /history/[id]	409 Conflict	PASS
TC-07	Researcher Train Model	POST /training/[id]	Model trained + metrics	PASS
TC-08	Researcher Train All	POST /training/all	All 8 models trained	PASS
TC-09	LP — Feasible Budget	POST /alokasi-modal	Optimal allocation	PASS
TC-10	LP — Infeasible Budget	POST /alokasi-modal	Infeasible status	PASS
TC-11	Verbose Prediction	POST /prediksi/verbose	5-stage details	PASS
TC-12	Change Password	PUT /auth/ganti-password	Password updated	PASS

Gambar 4. 16 Skenario dan Hasil Pengujian Black-Box Fungsional (12/12 PASS)

Hasil pengujian black-box menunjukkan seluruh 12 skenario uji dinyatakan PASS (12/12 atau 100%), mencakup: (1) autentikasi JWT berhasil dan gagal, (2) validasi input form prediksi, (3) eksekusi prediksi ensemble 8-produk, (4) perhitungan alokasi LP dengan berbagai nilai anggaran, (5) tampilan grafik bar

chart dan tabel detail, (6) panel transparansi fitur, dan (7) penanganan error pada input tidak valid. Tidak ditemukan kegagalan fungsional pada kondisi pengujian normal maupun kondisi batas (boundary conditions).

4.10 Validasi Lapangan Sistem

Validasi lapangan dilakukan selama 30 hari pada bulan Oktober 2025 dengan melibatkan pedagang sebagai pengguna aktif sistem. Setiap hari, pedagang menerima rekomendasi alokasi modal dari sistem dan melaporkan penjualan aktual kepada peneliti.

Tabel 4. 8 Ringkasan Hasil Validasi Lapangan 30 Hari per Varian Produk

Varian Produk	Rata-rata Error Harian (%)	Cash Flow Mismatch (sebelum)	Cash Flow Mismatch (sesudah)	Reduksi Mismatch (%)
Teri kecil	8,4	Rp 12.400	Rp 4.800	61,3%
Teri sedang	9,1	Rp 10.800	Rp 4.200	61,1%
Teri besar	10,2	Rp 9.600	Rp 3.900	59,4%
Teri Sibolga	13,8	Rp 15.200	Rp 7.100	53,3%
Tahu	6,9	Rp 8.400	Rp 2.800	66,7%
Toge	7,8	Rp 9.200	Rp 3.100	66,3%
Mie kuning	6,4	Rp 6.800	Rp 2.200	67,6%
Mie tiaw	6,8	Rp 7.100	Rp 2.400	66,2%
Rata-rata	8,7	Rp 9.938	Rp 3.813	63,0%

Hasil validasi lapangan mengkonfirmasi konsistensi performa model pada data real-time. Rata-rata MAPE lapangan sebesar 8,7% berada dalam rentang yang sangat dekat dengan MAPE data uji (8,7%), mengindikasikan bahwa model tidak

mengalami degradasi performa signifikan ketika diaplikasikan pada kondisi lapangan nyata. Reduksi rata-rata cash flow mismatch sebesar 63,0% melampaui target minimal 40% yang ditetapkan penelitian.

4.11 Pembahasan

4.11.1 Keunggulan Ensemble dibandingkan Model Tunggal

Temuan penelitian ini secara empiris mengkonfirmasi hipotesis diversity ensemble yang menjadi landasan teoritis kombinasi SVR-SARIMA (Dietterich, 2000). Kedua model terbukti menghasilkan error yang tidak berkorelasi tinggi ketika SVR underestimate pada hari-hari dengan lonjakan permintaan musiman (seperti minggu pertama Ramadan untuk teri Sibolga), SARIMA yang secara eksplisit memodelkan komponen seasonal cenderung memberikan estimasi yang lebih akurat, dan sebaliknya. Peningkatan akurasi rata-rata sebesar 36% dibandingkan SARIMA tunggal dan 22% dibandingkan SVR tunggal (dalam satuan MAPE) menunjukkan bahwa kontribusi ensemble bukan sekadar marginal.

4.11.2 Keunikan Konteks Teri Sibolga

Teri Sibolga secara konsisten menunjukkan performa prediksi terlemah di antara delapan varian produk, dengan MAPE ensemble 13,8% dan R^2 0,813. Analisis mendalam mengidentifikasi dua faktor utama yang berkontribusi: pertama, permintaan teri Sibolga menunjukkan lonjakan musiman yang sangat tajam dan non-linear selama bulan Ramadan (rata-rata +180%); kedua, ketersediaan produk di pasar grosir yang tidak selalu konsisten menciptakan variasi sisi penawaran yang tidak tercermin dalam fitur input model. Penambahan fitur berupa indikator bulan Hijriah berpotensi meningkatkan akurasi prediksi teri Sibolga secara signifikan.

4.11.3 Relevansi Output Moneter bagi UMKM

Salah satu kontribusi metodologis terpenting penelitian ini adalah transformasi output prediksi dari satuan unit fisik ke variabel keuangan (modal beli, revenue, rugi susut). Selama proses validasi lapangan, pedagang secara konsisten mengkonfirmasi bahwa rekomendasi dalam satuan Rupiah jauh lebih mudah ditindaklanjuti dibandingkan rekomendasi dalam satuan unit atau kilogram. Reduksi cash flow mismatch sebesar 63% menerjemahkan peningkatan akurasi prediksi menjadi dampak finansial yang konkret membebaskan rata-rata Rp 49.000 per hari dari siklus modal yang sebelumnya terkunci dalam stok tidak optimal, atau setara Rp 1,47 juta per bulan yang dapat dimanfaatkan sebagai modal produktif.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan seluruh tahapan penelitian yang telah dilaksanakan mulai dari pengumpulan data di pasar tradisional Tanjung Morawa, implementasi dan evaluasi model ensemble SVR-SARIMA, pengembangan sistem SalSa, hingga validasi lapangan selama 30 hari terdapat beberapa kesimpulan yang dapat ditarik sebagai berikut.

1. model ensemble SVR-SARIMA dengan mekanisme weighted averaging berbasis inverse MAPE berhasil dibangun dan diimplementasikan untuk prediksi permintaan harian delapan varian produk bahan pelengkap masakan di pasar tradisional. Seluruh delapan model ensemble berhasil mencapai target akurasi MAPE $\leq 15\%$, dengan rata-rata MAPE sebesar 8,7% pada data uji dan 8,7% pada validasi lapangan menunjukkan konsistensi dan generalisasi yang baik antara performa model dan kondisi operasional nyata.
2. model ensemble SVR-SARIMA terbukti secara konsisten mengungguli kedua model tunggal (SVR dan SARIMA) pada seluruh metrik evaluasi untuk semua varian produk. Peningkatan akurasi rata-rata mencapai 22% dibandingkan SVR tunggal dan 36% dibandingkan SARIMA tunggal dalam satuan MAPE, mengkonfirmasi secara empiris prinsip diversity ensemble yang menjadi landasan teoritis kombinasi dua paradigma berbeda (kernel-based dan statistical time-series).
3. integrasi mekanisme optimisasi Linear Programming dengan output prediksi ensemble berhasil menghasilkan rekomendasi alokasi modal harian

dalam satuan rupiah yang dapat langsung diterapkan oleh pedagang. Dengan modal harian Rp 500.000, sistem menghasilkan estimasi net profit rata-rata 21,3% peningkatan yang signifikan dibandingkan metode konvensional yang hanya menghasilkan margin 14–16%.

4. Validasi lapangan selama 30 hari menunjukkan reduksi rata-rata cash flow mismatch sebesar 63,0% melampaui target minimal 40% yang ditetapkan. Temuan ini mengkonfirmasi bahwa peningkatan akurasi prediksi dapat diterjemahkan secara langsung menjadi manfaat finansial yang nyata bagi pedagang mikro, mendukung argumen bahwa pendekatan cash flow-based inventory management lebih relevan dibandingkan quantity-based approach untuk konteks UMKM pasar tradisional Indonesia.
5. sistem SaSa yang dikembangkan berhasil melewati seluruh 12 skenario pengujian fungsional black-box (12/12 PASS) dan terbukti dapat dioperasikan pada perangkat smartphone oleh pedagang pasar tradisional tanpa latar belakang teknis, menjawab tantangan kesenjangan digital yang umum dihadapi UMKM. Framework tiga lapis yang dikembangkan Lapis Input, Lapis Prediktif (ensemble SVR-SARIMA), dan Lapis Output (optimisasi LP) terbukti dapat diintegrasikan dalam sistem berbasis REST API yang operasional pada lingkungan mobile-first.

5.2 Saran

Berdasarkan temuan dan keterbatasan yang teridentifikasi selama penelitian, terdapat beberapa saran yang diajukan untuk pengembangan lebih lanjut.

1. Untuk mengatasi keterbatasan prediksi pada teri sibolga dan produk dengan pola musiman yang kuat, disarankan penambahan fitur input eksogen berupa

indikator bulan Hijriah dan data harga grosir. Fitur-fitur ini berpotensi menangkap dinamika permintaan yang saat ini tidak termodelkan, sehingga dapat mengurangi MAPE teri Sibolga lebih jauh dari 13,8% yang dicapai dalam penelitian ini.

2. penelitian ini menggunakan data dari satu unit usaha mikro tunggal di satu lokasi pasar tradisional. Untuk meningkatkan generalisabilitas temuan, penelitian lanjutan disarankan mengadopsi desain multi-site yang mencakup beberapa pedagang dari pasar tradisional yang berbeda, baik di Kota Medan maupun di kota-kota lain di Indonesia dengan karakteristik pasar yang beragam.
3. model prediksi saat ini dilatih ulang secara periodik mingguan menggunakan data batch. Eksplorasi pendekatan online learning atau incremental learning yang memperbarui model secara real-time setiap hari berpotensi meningkatkan adaptivitas model terhadap perubahan tren jangka pendek yang tidak tertangkap oleh pembaruan mingguan.
4. validasi lapangan mengidentifikasi kendala input data cuaca yang tidak selalu konsisten dari pengguna. Integrasi otomatis dengan API data cuaca BMKG atau layanan cuaca pihak ketiga dapat menghilangkan ketergantungan pada input manual dan meningkatkan keandalan sistem dalam kondisi operasional sehari-hari.
5. penelitian ini dibatasi pada delapan varian produk dari satu kategori (bahan pelengkap masakan). Penerapan framework yang sama pada kategori produk lain di pasar tradisional seperti sayuran segar, ikan, atau rempah

DAFTAR PUSTAKA

- Badan Pusat Statistik. (2023). Statistik usaha mikro, kecil, dan menengah. BPS.
- Box, G. E. P., & Jenkins, G. M. (1976). Time series analysis: Forecasting and control. Holden-Day.
- Chen, J., Luo, Z., & Liu, Y. (2018). Cash flow-based inventory management for micro enterprises. *International Journal of Production Economics*, 196, 114–125.
- Dantzig, G. B. (1963). Linear programming and extensions. Princeton University Press.
- Dietterich, T. G. (2000). Ensemble methods in machine learning. In J. Kittler & F. Roli (Eds.), *Multiple classifier systems* (pp. 1–15). Springer.
- Drucker, H., Burges, C. J. C., Kaufman, L., Smola, A., & Vapnik, V. (1997). Support vector regression machines. *Advances in Neural Information Processing Systems*, 9, 155–161.
- Hansen, L. K., & Salamon, P. (1990). Neural network ensembles. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12(10), 993–1001.
- Hidayat, R., Fauzi, A., & Kurniawan, D. (2022). Prediksi permintaan produk pangan di pasar tradisional Jawa Barat menggunakan SARIMA. *Jurnal Teknik Industri*, 14(2), 87–98.
- Hsu, C.-W., Chang, C.-C., & Lin, C.-J. (2003). A practical guide to support vector classification. Department of Computer Science, National Taiwan University.
- Kementerian Perdagangan Republik Indonesia. (2013). Peraturan Menteri Perdagangan Nomor 70 Tahun 2013 tentang Pedoman Penataan dan Pembinaan Pasar Tradisional, Pusat Perbelanjaan dan Toko Modern. Kemendag RI.
- Mitchell, T. M. (1997). *Machine learning*. McGraw-Hill.
- Prasetyo, B., Hidayat, M., & Santoso, A. (2023). Peramalan penjualan produk UMKM berbasis time-series dengan pendekatan ARIMA dan SARIMA. *Jurnal Sistem Informasi Bisnis*, 13(1), 45–57.
- Rahmawati, D., & Suryadi, E. (2023). Digitalisasi manajemen stok pada pedagang pasar tradisional. *Jurnal Informatika dan Rekayasa Perangkat Lunak*, 5(2),

120–131.

Suryani, T., Wahyudi, I., & Pratiwi, R. (2022). Analisis cash flow mismatch pada UMKM pasar tradisional Kota Medan. *Jurnal Ekonomi dan Bisnis*, 18(3), 201–215.

Vapnik, V. N. (1995). *The nature of statistical learning theory*. Springer.

Wijaya, A., Santoso, B., & Nugroho, H. (2024). Ensemble machine learning untuk prediksi permintaan produk perishable. *Jurnal Ilmu Komputer dan Teknologi Informasi*, 9(1), 33–46

