

**Implementasi Metode *Esemble Learning*, *Decion Tree* Dan  
*Gradient Boosting* Untuk Prediksi Kebutuhan Suku  
Cadang (Studi Kasus : Bengkel Auto 252)**

**SKRIPSI**

**DISUSUN OLEH**

**RIDHO FATYKHAIA TINAMBUNAN**

**NPM. 2209020198**



**UMSU**

Unggul | Cerdas | Terpercaya

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

**MEDAN**

**2026**

**Implementasi Metode *Esemble Learning*, *Decion Tree* Dan  
*Gradient Boosting* Untuk Prediksi Kebutuhan Suku  
Cadang (Studi Kasus : Bengkel Auto 252)**

**SKRIPSI**

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

**RIDHO FATYKHAIA TINAMBUNAN  
NPM. 2209020198**

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

## LEMBAR PENGESAHAN

Judul Skripsi : Implementasi Metode *Esemble Learning, Decion Tree* Dan *Gradient Boosting* Untuk Prediksi Kebutuhan Suku Cadang (Studi Kasus : Bengkel Auto 252)

Nama Mahasiswa : Ridho Fatykhia Tinambunan

NPM : 2209020198

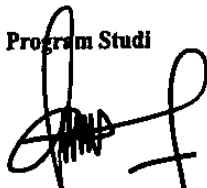
Program Studi : Teknologi Informasi

Menyetujui  
Komisi Pembimbing



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

Ketua Program Studi



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

Dekan



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

## PERNYATAAN ORISINALITAS

### **Implementasi Metode *Esemble Learning*, *Decion Tree* Dan *Gradient Boosting* Untuk Prediksi Kebutuhan Suku Cadang (Studi Kasus : Bengkel Auto 252)**

#### SKRIPSI

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

Medan, Maret 2026

Yang membuat pernyataan



Ridho Fatykhaia Tinambunan

NPM. 2209020198

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

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

Nama : Ridho Fatykhaia Tinambunan  
NPM : 2209020198  
Program Studi : Teknologi Informasi  
Karya Ilmiah : Skripsi

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Muhammadiyah Sumatera Utara Hak Bedas Royalti Non-Eksekutif (*Non-Exclusive Royalty free Right*) atas penelitian skripsi saya yang berjudul: *Implementasi Metode Esemble Learning, Decion Tree Dan Gradient Boosting Untuk Prediksi Kebutuhan Suku Cadang (Studi Kasus : Bengkel Auto 252)*. 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, Maret 2026

Yang membuat pernyataan



Ridho Fatykhaia Tinambunan

NPM. 220902021

## RIWAYAT HIDUP

### DATA PRIBADI

Nama Lengkap : Ridho Fatykhaia Tinambunan  
Tempat dan Tanggal Lahir : Medan, 18 April 2004  
Alamat Rumah : Perumahan Jasari Pasri Blok 3 No 3  
Telepon/Faks/HP : 0819 2997 2082  
E-mail : fatyridho@gmail.com  
Instansi Tempat Kerja : -  
Alamat Kantor : -

### DATA PENDIDIKAN

SD : MIS Islamiyah Guppi TAMAT: 2016  
SMP : IS Islamiyah Guppi TAMAT: 2019  
SMA : MAN 1 Medan TAMAT: 2022

## KATA PENGANTAR



Puji dan syukur penulis panjatkan ke hadirat Allah SWT atas segala rahmat dan hidayah-Nya sehingga skripsi yang berjudul “Implementasi Metode Ensemble Learning, *Decision Tree* dan *Gradient Boosting* untuk Prediksi Kebutuhan Suku Cadang (Studi Kasus: Bengkel Auto 252)” dapat diselesaikan dengan baik. Skripsi ini disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer (S.Kom) pada Program Studi Teknologi Informasi, Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara. Penulis menyadari bahwa dalam proses penyusunannya tidak terlepas dari dukungan, bimbingan, serta doa dari berbagai pihak, sehingga pada kesempatan ini penulis menyampaikan terima kasih yang sebesar-besarnya kepada semua pihak yang telah membantu. Semoga skripsi ini dapat memberikan manfaat bagi pengembangan ilmu pengetahuan dan menjadi referensi bagi penelitian selanjutnya. Penulis tentunya berterima kasih kepada berbagai pihak dalam dukungan serta doa dalam penyelesaian skripsi. Penulis juga mengucapkan terima kasih kepada:

1. Bapak Prof. Dr. Akrim, M.Pd., Rektor Universitas Muhammadiyah Sumatera Utara (UMSU)
2. Bapak Dr. Al-Khowarizmi, S.Kom., M.Kom. Dekan Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
3. Ibu Dr. Firaahmi Rizky, S.Kom., M.Kom selaku Wakil Dekan I Fakultas Ilmu Komputer dan Teknologi Informasi.
4. Bapak Mhd. Basri, S.Si., M.Kom selaku Wakil Dekan III Fakultas Ilmu Komputer dan Teknologi Informasi.
5. Ibu Fatma Sari Hutagalung, S.Kom., M.Kom selaku Ketua Program Studi Teknologi Informasi dengan penuh kesabaran memberikan pengarahan, bimbingan, dan motivasi kepada penulis.
6. Bapak Okvi Nugroho, S.Kom., M.Kom selaku sekretaris Program Studi Teknologi Informasi yang selalu memberi arahan kepada penulis.

7. Bapak Amrullah, S.Kom., M.Kom., selaku dosen pembimbing, yang telah memberikan arahan, bimbingan, dukungan, serta masukan yang sangat berarti selama proses penyusunan skripsi ini hingga selesai dengan baik.
8. Ayahanda Nael Tinambunan atas doa, dukungan, pengorbanan, serta motivasi yang tiada henti sehingga penulis dapat menyelesaikan skripsi ini dengan baik.
9. Ibunda Nurlailan atas doa, kasih sayang, dukungan, serta semangat yang senantiasa diberikan sehingga penulis mampu menyelesaikan skripsi ini dengan baik.
10. Penulis juga mengucapkan terima kasih kepada saudara-saudari tercinta, Rahman Hakim, Naila Putri Dzauharah, dan Nopal Khoir, atas doa, dukungan, serta semangat yang selalu diberikan dalam proses penyelesaian skripsi ini.
11. Penulis juga menyampaikan terima kasih khususnya mahasiswa dengan NPM 2209020214, atas kebersamaan, dukungan, serta semangat yang diberikan selama proses perkuliahan hingga penyusunan skripsi ini.
12. Semua pihak yang terlibat langsung ataupun tidak langsung yang tidak dapat penulis ucapkan satu-persatu yang telah membantu penyelesaian skripsi ini.

Implementasi Metode *Ensemble Learning*, *Decision Tree* dan  
*Gradient Boosting* untuk Prediksi Kebutuhan Suku Cadang  
(Studi Kasus: Bengkel Auto 252)

ABSTRAK

Ketersediaan suku cadang merupakan faktor penting dalam menjaga kelancaran operasional bengkel dan meningkatkan kepuasan pelanggan. Bengkel Auto 252 masih mengelola persediaan berdasarkan perkiraan manual tanpa memanfaatkan analisis data historis penjualan, sehingga berpotensi menyebabkan kekurangan maupun kelebihan stok. Penelitian ini bertujuan untuk mengimplementasikan metode *Decision Tree*, *Gradient Boosting*, dan *Ensemble Learning* dalam memprediksi kebutuhan suku cadang berdasarkan data historis penjualan. Data yang digunakan berasal dari transaksi penjualan suku cadang yang telah melalui tahapan pra-pemrosesan, pembagian data latih dan data uji, serta proses pelatihan model. Evaluasi kinerja model dilakukan menggunakan metrik Mean Absolute Error (MAE) dan Root Mean Squared Error (RMSE). Hasil penelitian menunjukkan bahwa metode *Gradient Boosting* memberikan performa prediksi yang lebih baik dibandingkan *Decision Tree* dan *Ensemble Learning* dalam konteks data Bengkel Auto 252. Dengan demikian, metode tersebut direkomendasikan sebagai model yang paling optimal untuk mendukung pengambilan keputusan pengelolaan stok secara lebih objektif dan berbasis data.

**Kata Kunci:** *Decision Tree*; *Gradient Boosting*; *Ensemble Learning*; Prediksi Stok

Implementation of Ensemble Learning, Decision Tree, and Gradient  
Boosting Methods for Spare Parts Demand Prediction  
(Case Study: Auto 252 Workshop)

ABSTRACT

Spare parts availability plays a crucial role in maintaining smooth workshop operations and enhancing customer satisfaction. Auto 252 Workshop still manages inventory based on manual estimation without utilizing historical sales data analysis, which may lead to stock shortages or overstock conditions. This study aims to implement Decision Tree, Gradient Boosting, and Ensemble Learning methods to predict spare parts demand based on historical sales data. The dataset was processed through preprocessing, data splitting, and model training stages. Model performance was evaluated using Mean Absolute Error (MAE) and Root Mean Squared Error (RMSE). The results indicate that *Gradient Boosting* demonstrates better predictive performance compared to *Decision Tree* and Ensemble Learning for the case of Auto 252 Workshop. Therefore, *Gradient Boosting* is recommended as the most suitable method to support data-driven inventory management decisions.

**Keywords:** Decision Tree; Gradient Boosting; Ensemble Learning; Inventory Prediction.

## DAFTAR ISI

<b>LEMBAR PENGESAHAN</b> .....	<b>ii</b>
<b>PENYATAAN ORISINALITAS</b> .....	<b>iii</b>
<b>PENYATAAN PERSETUJUAN PUBLIKASI</b> .....	<b>iv</b>
<b>RIWAYAT HIDUP</b> .....	<b>v</b>
<b>KATA PENGANTAR</b> .....	<b>vi</b>
<b>ABSTRAK</b> .....	<b>viii</b>
<b>ABSTRACT</b> .....	<b>ix</b>
<b>DAFTAR ISI</b> .....	<b>x</b>
<b>DAFTAR TABEL</b> .....	<b>xi</b>
<b>DAFTAR GAMBAR</b> .....	<b>xii</b>
<b>BAB I. PENDAHULUAN</b> .....	<b>1</b>
1.1. Latar Belakang Masalah .....	1
1.2. Rumusan Masalah .....	4
1.3. Batasan Masalah.....	4
1.4. Tujuan Penelitian.....	5
1.5. Manfaat Penelitian.....	6
<b>BAB II. LANDASAN TEORI</b> .....	<b>7</b>
2.1. <i>Machine learning</i> .....	7
2.2. Prediksi Kebutuhan Suku Cadang .....	8
2.3. <i>Decision Tree</i> .....	10
2.4. <i>Gradient Boosting</i> .....	12
2.5. <i>Ensemble Learning</i> .....	13
2.6. Evaluasi Model.....	14
2.7. Desain dan Tools Pengembangan Sistem.....	16
2.8. Penelitian Terdahulu.....	23
2.7. Analisis GAP .....	26
<b>BAB III. METODOLOGI PENELITIAN</b> .....	<b>27</b>
3.1. Alur Penelitian.....	27
3.2. Diagram Rancangan Sistem dan Pemodelan UML .....	28
3.3. Objek Penelitian .....	30
3.4. Lokasi Penelitian .....	31
3.5. Implementasi Metode <i>Decision Tree</i> .....	32
3.6. Implementasi Metode <i>Gradient Boosting</i> .....	32
3.7. Implementasi Metode <i>Ensemble Learning</i> .....	33
3.8. Desain Perancangan Antar Muka .....	34
3.8 Jadwal Penelitian .....	38
<b>BAB IV. HASIL DAN PEMBAHASAN</b> .....	<b>39</b>
4.1. Hasil.....	39
4.2. Hasil Implementasi <i>Decision Tree</i> .....	43
4.3. Hasil Implementasi <i>Gradient Boosting</i> .....	47
4.4. Hasil Implementasi <i>Ensemble Learning</i> .....	51
4.5. Pembahasan .....	56
<b>BAB V. KESIMPULAN DAN SARAN</b> .....	<b>58</b>
5.1. KESIMPULAN .....	58
5.2. SARAN .....	59
<b>DAFTAR PUSTAKA</b> .....	<b>60</b>

## DAFTAR TABEL

	<b>HALAMAN</b>
Tabel 2.1. Simbol - Simbol Use Case	17
Tabel 2.2. Simbol – Simbol Activity Diagram	18
Tabel 2.3. Simbol Flowchart	20
Tabel 2.4. Ringkasan Penelitian Terdahulu	23
Tabel 3.1. Jadwal Penelitian	38
Tabel 4.1 Data Aktual dan Hasil Prediksi Decision Tree Januari 2025	44
Tabel 4.2 Perhitungan Error Absolut Decision Tree Januari 2025	45
Tabel 4.3 Perhitungan Error Kuadrat Decision Tree Januari 2025	46
Tabel 4.4 Data Aktual dan Hasil Prediksi Gradient Boosting Januari 2025	48
Tabel 4.5 Perhitungan Error Absolut Gradient Boosting Januari 2025	49
Tabel 4.6 Perhitungan Error Kuadrat Gradient Boosting Januari 2025	50
Tabel 4.7 Perbandingan Prediksi Januari 2025	52
Tabel 4.8 Perhitungan Error Absolut <i>Ensemble</i> Januari 2025	52
Tabel 4.9 Perhitungan Error Kuadrat <i>Ensemble</i> Januari 2025	53
Tabel 4.10 Hasil Persentasi Akurasi	55

## DAFTAR GAMBAR

	<b>HALAMAN</b>
Gambar 3.1. Alur Penelitian	27
Gambar 3.2. Diagram Rancangan Sistem	28
Gambar 3.3. Use Case Diagram	29
Gambar 3.4. Activity Diagram	29
Gambar 3.5. Peta Lokasi Mobil Auto 252	31
Gambar 3.6. Desain Interface Menu Login	34
Gambar 3.7. Desain Interface Menu Utama	35
Gambar 3.8. Desain Interface Menu Input Data	35
Gambar 3.9. Desain Interface Menu Prediksi	36
Gambar 3.10. Desain Interface Menu Hasil Prediksi	36
Gambar 3.11. Desain Interface Laporan Hasil Prediksi	37
Gambar 3.12. Desain Interface Menu Logout	37
Gambar 4.1. Menu Login	40
Gambar 4.2. Menu Utama	40
Gambar 4.3. Halaman Input Data	41
Gambar 4.4. Halaman Logout	41
Gambar 4.5. Halaman Prediksi	42
Gambar 4.6. Halaman Hasil Prediksi	42
Gambar 4.7. Laporan Hasil Prediksi	43

# **BAB I**

## **PENDAHULUAN**

### **1.1. Latar Belakang Masalah**

Seiring dengan meningkatnya jumlah kendaraan bermotor di Indonesia, kebutuhan masyarakat akan layanan servis dan suku cadang kendaraan juga terus meningkat, sehingga bengkel dituntut untuk memberikan pelayanan yang cepat dan tepat agar pelanggan merasa puas dan kembali menggunakan layanan tersebut. Ketersediaan stok suku cadang yang memadai merupakan salah satu faktor penting dalam operasional bengkel karena keterlambatan atau kekosongan suku cadang dapat memperpanjang waktu servis dan menurunkan kualitas layanan. Dalam praktiknya banyak bengkel termasuk Bengkel Auto 252 masih mengelola persediaan suku cadang secara manual berdasarkan pengalaman atau perkiraan tanpa didukung analisis data historis permintaan, sehingga sering terjadi kondisi stok habis (*stock out*) pada suku cadang tertentu atau sebaliknya stok menumpuk karena permintaan yang rendah. Ketergantungan terhadap perkiraan tanpa analisis data ini berpotensi menyebabkan inefisiensi biaya, penurunan produktivitas, dan ketidakpuasan pelanggan karena waktu servis yang tidak menentu. Hal ini sesuai dengan temuan pada berbagai penelitian manajemen rantai pasok yang menunjukkan bahwa pendekatan berbasis data secara signifikan dapat meningkatkan akurasi prediksi permintaan dan manajemen inventaris dibanding metode tradisional (Syahputra Manik & Panjaitan, 2025).

Permasalahan di Bengkel Auto 252 menunjukkan belum adanya sistem yang mampu memanfaatkan data historis penjualan untuk memprediksi kebutuhan stok secara akurat dan konsisten. Padahal data historis penjualan yang telah tersedia

memiliki potensi informasi penting untuk menangkap pola permintaan pelanggan dan tren suku cadang yang sering dibutuhkan. Tanpa pemodelan yang tepat, keputusan pengambilan stok akan tetap bergantung pada perkiraan subjektif, sehingga risiko kesalahan tinggi dan sulit terukur secara objektif melalui metrik performa. Literatur ilmiah bidang *demand forecasting* dan *inventory management* telah banyak menekankan pentingnya penggunaan teknik *Machine learning* untuk menangani kompleksitas pola permintaan yang dinamis dan tidak linier dalam data historis. Teknik seperti *Decision Tree* dan *Gradient Boosting* mampu mengolah data dengan struktur non-linier dan interaksi variabel yang kompleks, sehingga dapat memberikan prediksi kebutuhan stok yang lebih baik dibandingkan pendekatan konvensional sederhana (Syahputra Manik & Panjaitan, 2025).

Untuk mengatasi permasalahan prediksi persediaan tersebut, pendekatan *Machine learning* seperti *Decision Tree* dan *Gradient Boosting* menawarkan solusi yang relevan karena kedua metode ini mampu mempelajari hubungan antara variabel input (Seperti jenis suku cadang, tanggal penjualan, dan frekuensi pembelian) dengan variabel target (jumlah permintaan). Sebagai contoh, penelitian yang memanfaatkan algoritma *Decision Tree Learning* berhasil memprediksi permintaan stok produk dan tingkat pendapatan dalam studi kasus bisnis skala menengah, menunjukkan bahwa algoritma pohon keputusan efektif menangkap pola permintaan berdasarkan data historis penjualan. Selain itu, pendekatan *Gradient Boosting* yang merupakan teknik *Ensemble Learning* telah digunakan untuk peramalan kebutuhan inventori yang lebih akurat, di mana model dibangun secara bertahap untuk memperbaiki kesalahan prediksi model sebelumnya dan menghasilkan akurasi yang lebih tinggi. Penelitian peramalan penjualan produk

menggunakan *Extreme Gradient Boosting (XGBoost)* menunjukkan bahwa model ini mampu menghasilkan prediksi yang baik dan mendukung optimasi manajemen persediaan, terutama di sektor ritel (Winurputra & Ratnawati, 2025).

Sejumlah studi empiris juga memberikan bukti bahwa model-model *Machine learning* berbasis *tree-based methods* dapat membantu mengurangi kesalahan prediksi dalam konteks *inventory forecasting*. Penerapan *Decision Tree* untuk prediksi permintaan produk menunjukkan model tersebut dapat membantu perencanaan persediaan berdasarkan pola permintaan historis yang kompleks. *Decision Tree* dipilih karena memiliki kemampuan interpretasi yang tinggi sehingga pola permintaan suku cadang dapat dijelaskan dalam bentuk aturan keputusan yang mudah dipahami. Namun, *Decision Tree* memiliki kelemahan yaitu sensitif terhadap perubahan data dan berpotensi menghasilkan prediksi yang kurang stabil. Oleh karena itu, digunakan *Gradient Boosting* yang dikenal mampu meningkatkan akurasi prediksi dengan cara membangun model secara bertahap untuk memperbaiki kesalahan prediksi sebelumnya. Pemilihan kedua metode ini diharapkan menghasilkan model prediksi yang tidak hanya akurat tetapi juga lebih stabil (F.X. Wisnu Yudo Untoro, 2025).

Berdasarkan uraian di atas, penelitian ini diusulkan untuk mengimplementasikan pendekatan *Ensemble Learning* yang menggabungkan *Decision Tree* dan *Gradient Boosting* dalam merancang model prediksi kebutuhan suku cadang di Bengkel Auto 252. Penggunaan dua metode dilakukan karena setiap algoritma memiliki karakteristik dan tingkat kesalahan yang berbeda. Dengan membandingkan *Decision Tree* dan *Gradient Boosting*, penelitian ini dapat mengetahui metode mana yang lebih sesuai untuk pola permintaan suku cadang.

Selain itu, penggabungan kedua metode melalui *Ensemble Learning* diharapkan mampu menghasilkan prediksi yang lebih stabil karena dapat mengurangi kelemahan model tunggal. Pendekatan ini diharapkan dapat membantu bengkel dalam menentukan jumlah stok yang lebih tepat dengan memanfaatkan data historis penjualan, sehingga dapat mengurangi kejadian stok habis maupun kelebihan stok, menurunkan biaya inventori, serta meningkatkan kualitas pelayanan kepada pelanggan. Dengan dasar bukti empiris dari penelitian sebelumnya yang menunjukkan potensi metode-metode berbasis *Machine learning* dalam peramalan permintaan dan manajemen inventaris, pendekatan ini diyakini relevan dan aplikatif untuk konteks operasional bengkel (Cavalcanti & Fagundes, 2025).

## **1.2. Rumusan Masalah**

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

1. Bagaimana penerapan metode *Decision Tree* dalam memprediksi kebutuhan suku cadang di Bengkel Auto 252 berdasarkan data historis penjualan?
2. Bagaimana penerapan metode *Gradient Boosting* dalam memprediksi kebutuhan suku cadang di Bengkel Auto 252?
3. Bagaimana hasil prediksi yang dihasilkan dapat dimanfaatkan sebagai dasar pengambilan keputusan dalam pengelolaan stok suku cadang di Bengkel Auto 252?

## **1.3. Batasan Masalah**

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

1. Penelitian hanya menggunakan data historis penjualan suku cadang dari Bengkel Auto 252 dalam periode tertentu. Penelitian tidak membedakan merek suku cadang, tetapi berfokus pada jenis suku cadang yang dikelompokkan ke dalam tiga kategori yaitu sistem mesin, sistem pengereman, dan sistem suspensi. Variabel yang digunakan meliputi jumlah penjualan, stok awal, harga, periode waktu (bulan), serta faktor musiman.
2. Penelitian ini membatasi penggunaan metode pada *Decision Tree* , *Gradient Boosting*, dan teknik *Ensemble Learning* dengan pendekatan *averaging*. Proses yang dilakukan meliputi perancangan model, pelatihan model, serta pembuatan prediksi tanpa membahas implementasi sistem secara langsung pada sistem informasi bengkel.
3. Evaluasi kinerja model prediksi hanya menggunakan parameter *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE) untuk menilai tingkat akurasi model yang dihasilkan

#### **1.4. Tujuan Penelitian**

Berdasarkan rumusan masalah yang telah disusun, maka tujuan dari penelitian ini adalah:

1. Untuk mengetahui dan merancang metode *Decision Tree* dalam memprediksi kebutuhan suku cadang di Bengkel Auto 252 berdasarkan data historis penjualan.
2. Untuk mengetahui dan menerapkan metode *Gradient Boosting* dalam memprediksi kebutuhan suku cadang di Bengkel Auto 252.

3. Untuk menghasilkan hasil prediksi kebutuhan suku cadang yang dapat dimanfaatkan sebagai dasar pengambilan keputusan dalam pengelolaan stok suku cadang di Bengkel Auto 252.

### **1.5. Manfaat Penelitian**

Penelitian ini diharapkan memberikan manfaat bagi berbagai pihak yang terkait, baik dari aspek akademis maupun praktis, khususnya bagi universitas, tempat riset, serta mahasiswa sebagai pelaksana penelitian.

1. Bagi Universitas, penelitian ini diharapkan dapat memperkaya khasanah penelitian ilmiah di lingkungan universitas, khususnya dalam bidang teknologi informasi dan penerapan metode *Machine learning* untuk peramalan kebutuhan persediaan. Selain itu, hasil penelitian ini dapat menjadi referensi tambahan bagi mahasiswa maupun peneliti lain yang ingin mengembangkan studi terkait prediksi berbasis data historis.
2. Bagi Tempat Riset (Bengkel Auto 252), Hasil prediksi dalam penelitian ini dapat membantu bengkel dalam menentukan jumlah stok optimal untuk periode berikutnya, sehingga mengurangi risiko stock out yang dapat menghambat proses servis serta mengurangi overstock yang menyebabkan pemborosan biaya penyimpanan., serta hasil prediksi yang dihasilkan dapat digunakan sebagai dasar pengambilan keputusan dalam menentukan jumlah pembelian suku cadang pada periode berikutnya.
3. Bagi Mahasiswa, penelitian ini memberikan kesempatan bagi mahasiswa untuk menerapkan teori yang telah dipelajari selama perkuliahan ke dalam kasus nyata di lapangan, khususnya terkait implementasi *Machine learning* dan pengolahan data historis.

## BAB II

### LANDASAN TEORI

#### 2.1 *Machine learning*

*Machine learning* merupakan subdisiplin dari kecerdasan buatan yang mempelajari fungsi aproksimasi  $f: X \rightarrow Y$  berbasis data historis melalui prosedur estimasi dan generalisasi model pada data baru. Secara keilmuan, machine learning diklasifikasikan ke dalam paradigma *supervised learning*, *unsupervised learning*, dan *reinforcement learning*, yang masing-masing memiliki tujuan prediktif dan struktur pembelajaran yang berbeda. Implementasi machine learning dilakukan melalui tahapan formalisasi masalah, akuisisi dan pembersihan data, pra-pemrosesan, seleksi algoritma, pelatihan parameter, dan evaluasi model. Pada ranah supervised learning, sistem pembelajaran dioptimalkan dengan meminimalkan fungsi kerugian (*loss function*) agar model memiliki *generalization performance* terhadap sampel uji. Kualitas data dan prosedur pra-pemrosesan merupakan komponen krusial, karena keduanya menentukan stabilitas estimasi parameter, kompleksitas model, serta akurasi prediksi terhadap data yang tidak teramati. (Suryati et al., 2025).

Dalam konteks prediksi kuantitatif, *Machine Learning* diposisikan sebagai pendekatan *data-driven modeling* yang mempelajari struktur dependensi antara variabel prediktor dan variabel respon melalui prosedur estimasi berbasis data historis. Pada domain ini, model tidak mengandalkan formulasi analitik eksplisit, tetapi melakukan proses aproksimasi fungsi melalui optimisasi parameter untuk meminimalkan kesalahan prediksi pada data uji. Pendekatan ini berbeda dengan model statistik klasik yang umumnya mensyaratkan asumsi linearitas, normalitas

residual, atau kestasioneran, sehingga Machine Learning lebih fleksibel dalam memodelkan sistem dengan struktur non-linear, heteroskedastisitas, serta dinamika temporal yang kompleks. Kerangka ini menjadikan *Machine Learning* relevan untuk problem prediksi inventori dan peramalan permintaan yang bergantung pada pola permintaan historis dan variabilitas stokastik dalam horizon waktu tertentu (Saputra & Mahdiana, 2025).

Pada implementasikan algoritma *K-Nearest Neighbor* (KNN) pada problem klasifikasi data akademik untuk menentukan konsentrasi program studi siswa. Algoritma KNN beroperasi berdasarkan konsep kemiripan berbasis jarak pada ruang fitur dan mengadopsi paradigma *instance-based learning*, di mana proses generalisasi dilakukan pada tahap inferensi melalui pemilihan tetangga yang paling dekat menggunakan metrik jarak seperti *Euclidean Distance*, tanpa proses pelatihan model secara eksplisit. Temuan penelitian tersebut menunjukkan bahwa algoritma pembelajaran mesin mampu mengekstraksi pola atribut untuk menghasilkan keputusan klasifikasi yang konsisten dan berbasis data. Secara keilmuan, hasil ini mengindikasikan bahwa pendekatan *machine learning* dapat dimanfaatkan sebagai dasar *decision support* pada domain yang berbasis data historis, sehingga relevan dengan penelitian ini yang menerapkan model pembelajaran mesin untuk melakukan prediksi kebutuhan suku cadang berdasarkan pola permintaan yang terekam dalam data penjualan historis (Ramdhani & Amrullah, 2026).

## **2.2 Prediksi Kebutuhan Suku Cadang**

Dalam disiplin *Inventory Management*, suku cadang diklasifikasikan sebagai *spare parts inventory* yang berfungsi untuk menopang kelangsungan proses

pemeliharaan (*maintenance operations*). Pada konteks ini, komponen suku cadang termasuk dalam kategori dependent demand items yang sangat sensitif terhadap ketidakpastian permintaan dan waktu pengadaan (*lead time*). Kegagalan dalam pengendalian inventori dapat menimbulkan dua kondisi fundamental, yaitu *stock-out* dan *overstock*, yang masing-masing memiliki implikasi pada biaya kekurangan persediaan (*shortage cost*) dan biaya penyimpanan (*holding cost*) dalam literatur manajemen persediaan. Oleh karena itu, proses *demand forecasting* menjadi tahapan penting dalam sistem inventori untuk mengestimasi jumlah kebutuhan pada horizon waktu tertentu berdasarkan data historis, sehingga strategi pengadaan dapat dilakukan secara kuantitatif dan terukur. (Suryanto et al., 2024).

Permintaan suku cadang pada sistem pemeliharaan umumnya dimodelkan sebagai proses *stokastik* yang mengikuti distribusi probabilistik tertentu, karena kejadian konsumsi komponen dipengaruhi oleh faktor acak seperti umur pakai, tingkat kegagalan, dan intensitas penggunaan unit. Dalam kerangka *stochastic demand modeling*, fungsi permintaan  $D(t)$  diperlakukan sebagai variabel acak dengan nilai ekspektasi dan variansi tertentu, sehingga estimasi kebutuhan dilakukan melalui pendekatan prediktif untuk mengurangi ketidakpastian pada horizon perencanaan. Oleh karena itu, *forecasting* berfungsi sebagai mekanisme inferensial untuk mengestimasi parameter distribusi permintaan berdasarkan observasi historis. Formulasi ini memungkinkan sistem inventori menerapkan kebijakan pengendalian seperti  $(s, Q)$  atau  $(R, S)$  melalui representasi probabilistik dari risiko kekurangan maupun kelebihan persediaan dalam jangka waktu tertentu. (Rais et al., 2025).

Pada *computational forecasting*, pendekatan prediksi berbasis data dikategorikan sebagai sistem estimasi yang memanfaatkan model matematika dan komputasi untuk merepresentasikan pola temporal pada data deret waktu. Model prediktif berbasis *machine learning* dirancang sebagai fungsi aproksimasi non-linear yang mampu menangkap volatilitas, dependensi antar waktu, dan bentuk distribusi yang kompleks pada data dengan dinamika fluktuatif. Secara metodologis, model-model ini bekerja dengan mempelajari struktur input-output dari data historis untuk menghasilkan model estimatif yang bersifat data-driven, tanpa ketergantungan pada asumsi kestasioneran atau linearitas seperti pada model regresi linier klasik. Dalam konteks *inventory forecasting*, sifat data permintaan yang tidak stasioner dan memiliki variabilitas tinggi menjadikan model pembelajaran mesin sebagai kandidat metodologis yang relevan untuk mendukung analisis permintaan, estimasi stok, dan sistem pendukung keputusan berbasis data historis (B et al., 2025).

### **2.3 Decision Tree**

*Decision Tree* merupakan model prediktif berbasis *rekursif partisi* yang memetakan ruang fitur  $X$  ke dalam region yang lebih kecil melalui prosedur seleksi atribut dengan memaksimalkan kriteria pemisahan (*splitting criterion*). Pada setiap node, proses pemilihan atribut dilakukan dengan mengukur penurunan ketidakmurnian (*impurity reduction*) menggunakan metrik seperti *Gini Index*, *Entropy*, atau *Information Gain* pada kasus klasifikasi, serta *Variance Reduction* pada kasus regresi. Struktur model ini menghasilkan *piecewise constant estimator* pada terminal node, sehingga memungkinkan interpretasi langsung terhadap kontribusi fitur yang memengaruhi nilai prediksi. Dalam pengembangan model

berbasis ansambel, *Decision Tree* berfungsi sebagai *weak learner* dalam algoritma seperti *bagging* dan *boosting*, dimana penekanan diberikan pada pengurangan varians dan peningkatan akurasi generalisasi melalui agregasi model (Cavalcanti & Fagundes, 2025).

Dalam kerangka *statistical learning*, model *Decision Tree* dikategorikan sebagai model *interpretable machine learning* karena struktur pohonnya memfasilitasi proses penelusuran aturan keputusan melalui jalur node yang bersifat deterministik. Interpretabilitas ini berasal dari mekanisme pemilihan atribut yang berbasis pada kriteria impurity, sehingga relasi antar fitur dan label dapat dianalisis secara eksplisit melalui representasi node internal dan terminal. Selain itu, model *Decision Tree* bersifat non-parametrik, sehingga mampu memproses fitur kategorikal maupun numerik tanpa memerlukan asumsi distribusional tertentu. Karakteristik ini menjadikan *Decision Tree* relevan untuk domain analitik eksploratori pada data historis dengan tujuan identifikasi pola dan inferensi struktur keputusan berbasis atribut (Nst et al., 2025).

Pada perspektif *bias–variance trade-off*, *Decision Tree* dikategorikan sebagai model dengan bias rendah dan variance tinggi, karena struktur partisinya mampu menyesuaikan diri secara agresif terhadap data pelatihan. Sifat ini sering menyebabkan *overfitting*, yaitu kondisi ketika model memodelkan noise sebagai informasi, sehingga performa generalisasi terhadap data uji menurun. Untuk mengatasi fenomena tersebut, teknik *pruning* diterapkan dengan menghilangkan node-node yang memberikan kontribusi minor terhadap penurunan impurity. Pruning dapat dilakukan dalam dua pendekatan, yaitu *pre-pruning* yang membatasi pertumbuhan pohon selama pelatihan dengan kriteria tertentu

(misalnya kedalaman maksimum, jumlah sampel minimum per node), dan *post-pruning* yang melakukan pemangkasan setelah pohon terbentuk berdasarkan fungsi biaya (*cost complexity pruning*). Kerangka ini memposisikan *Decision Tree* sebagai model non-parametrik yang memerlukan mekanisme regularisasi struktural agar mencapai keseimbangan antara kompleksitas model dan kemampuan generalisasi (Aini et al., 2025).

## 2.4 Gradient Boosting

Dalam kerangka *Ensemble Learning*, *Gradient Boosting* direpresentasikan sebagai metode *additive modeling* yang mengestimasi fungsi  $f(x)$  melalui komposisi sejumlah *weak learners* yang dioptimalkan menggunakan prosedur *functional gradient descent*. Pada setiap iterasi, model  $h_m(x)$  dibangun untuk mengaproksimasi negatif gradien dari fungsi kerugian terhadap prediksi sebelumnya, sehingga diperoleh pembaruan parameter dalam bentuk:

$$f_m(x) = f_{m-1}(x) + \nu h_m(x)$$

dengan  $\nu$  sebagai *learning rate* yang mengontrol kontribusi pembaruan. Mekanisme ini memungkinkan *Gradient Boosting* untuk memodelkan relasi non-linear dan interaksi antar fitur tanpa memerlukan transformasi eksplisit. Secara keilmuan, pendekatan ini memposisikan *Gradient Boosting* sebagai metode dengan bias rendah dan variance terkontrol melalui regularisasi struktural, sehingga relevan untuk problem prediksi berbasis data historis dengan pola kompleks (Aini et al., 2025).

Dalam kerangka *supervised learning*, *Gradient Boosting* diformulasikan sebagai prosedur *additive modeling* yang mengestimasi fungsi target melalui minimisasi fungsi kerugian (loss function) pada ruang fungsi, bukan pada ruang

parameter. Model dasar ( $h_m(x)$ ) berperan sebagai *weak learner*, umumnya berupa pohon keputusan dengan kedalaman terbatas untuk mengontrol kompleksitas model. Kontribusi *weak learner* terhadap model akhir ditentukan oleh skalar shrinkage ( $\nu$ ), yang berfungsi sebagai mekanisme regularisasi untuk menstabilkan proses pembelajaran dan mencegah *overfitting* dengan cara memperlambat laju pembaruan estimasi. *Loss function* yang digunakan bergantung pada tipe tugas, misalnya *squared error loss* untuk regresi dan *logistic loss* untuk klasifikasi biner. Dengan pendekatan ini, *Gradient Boosting* menjadi metodologi fungsional yang mengoptimalkan performa generalisasi melalui kontrol terstruktur terhadap kompleksitas model, tanpa bergantung pada asumsi linearitas atau transformasi eksplisit pada fitur (Kurniadi & Larasati, 2022).

## 2.5 Ensemble Learning

Dalam kerangka *statistical learning*, *Ensemble Learning* dikategorikan sebagai pendekatan model aggregation yang mengombinasikan sejumlah *base learners* untuk memperoleh fungsi hipotesis dengan karakteristik generalisasi yang lebih baik. Secara taksonomis, *ensemble* terdiri atas tiga strategi utama, yaitu *bagging*, *boosting*, dan *stacking*, yang masing-masing menggunakan mekanisme agregasi berbeda terhadap ruang hipotesis. *Bagging* mengurangi varians model dengan mengestimasi parameter pada sampel *bootstrap* dan menggabungkannya melalui *majority voting* atau *averaging*, sedangkan *boosting* melakukan *sequential learning* dengan menitik beratkan pembelajaran pada sampel berkerugian tinggi untuk menurunkan bias. *Stacking* mengimplementasikan model meta-learner untuk mengkombinasikan prediksi antar *base learners* pada tingkat kedua. Pada perspektif *bias–variance trade-off*, *ensemble* berfungsi sebagai mekanisme

stabilisasi model melalui reduksi varians dan kontrol bias secara struktural, sehingga dapat meningkatkan performa generalisasi tanpa memerlukan asumsi linearitas atau bentuk distribusi tertentu pada ruang fitur. (Syawaludin, 2025)

Dalam kerangka *statistical learning*, *Ensemble Learning* dipandang sebagai prosedur hipotesis kolektif yang menyusun sekumpulan model dasar  $(h_1, h_2, \dots, h_M)$  untuk menghasilkan hipotesis komposit  $H(x)$  melalui aturan agregasi tertentu. Efektivitas pendekatan ini bergantung pada *diversitas error* antar *base learners*, karena ketidakbergantungan residual memungkinkan reduksi varians pada prediksi agregat melalui mekanisme voting atau averaging. Secara teoretis, *Ensemble Learning* menyeimbangkan komponen bias–variance pada fungsi generalisasi dengan menurunkan varians tanpa meningkatkan bias secara signifikan. Pada kasus klasifikasi, fungsi agregasi dapat berupa *majority vote*, sedangkan pada regresi berupa *weighted averaging* atau *stacked meta-estimator*. Dengan formulasi tersebut, *Ensemble Learning* memetakan masalah klasifikasi maupun regresi ke dalam ruang model komposit yang memiliki kapasitas representasi lebih tinggi dibandingkan model tunggal, tanpa memerlukan peningkatan kompleksitas parameter secara langsung pada tiap *base learner* (Syaban, 2025).

## 2.6 Evaluasi Model

Evaluasi model dilakukan untuk mengukur kinerja dan akurasi model pada data pelatihan. Metrik evaluasi yang digunakan adalah:

1. *Mean Absolute Error* (MAE) merupakan metrik evaluasi yang digunakan untuk mengukur rata-rata nilai absolut dari selisih antara nilai prediksi dan nilai aktual. MAE memberikan gambaran yang jelas mengenai besarnya kesalahan

prediksi karena dinyatakan dalam satuan yang sama dengan variabel target, sehingga mudah diinterpretasikan. Nilai MAE yang semakin kecil menunjukkan bahwa kinerja model semakin baik. Perhitungan MAE dapat dirumuskan sebagai berikut:

$$MAE = \frac{1}{n} \sum_{i=1}^N |y_i - \hat{y}_i|$$

Dimana  $n$  adalah jumlah sampel data,  $y_i$  adalah nilai aktual (observasi) ke  $i$ , dan  $\hat{y}_i$  adalah nilai prediksi ke  $i$ .

2. *Root Mean Squared Error (RMSE)* merupakan salah satu metrik evaluasi yang digunakan untuk mengukur rata-rata nilai akar kuadrat dari selisih kuadrat antara hasil prediksi model dan nilai aktual. Dengan adanya proses pengkuadratan, RMSE memberikan penalti yang lebih besar terhadap kesalahan prediksi yang bernilai tinggi, sehingga metrik ini lebih peka terhadap keberadaan *outlier* dibandingkan dengan *Mean Absolute Error (MAE)*. Nilai RMSE yang semakin kecil menunjukkan bahwa model memiliki tingkat kesalahan prediksi yang lebih rendah dan performa yang lebih baik. Oleh karena itu, RMSE sering digunakan untuk mengevaluasi model prediksi yang menuntut tingkat akurasi tinggi, terutama ketika kesalahan besar perlu diminimalkan. Perhitungan RMSE dapat dinyatakan dalam persamaan sebagai berikut:

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

Dimana  $n$  adalah jumlah sampel data,  $y_i$  adalah nilai aktual (observasi) ke  $i$ , dan  $\hat{y}_i$  adalah nilai prediksi ke  $i$  (Untoro, 2025).





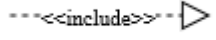
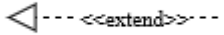
## **2.7 Desain dan *Tools* Pengembangan Sistem**

Pada bidang teknologi informasi, proses pengembangan aplikasi atau sistem memerlukan konsep perancangan, bahasa pemodelan, serta perangkat bantu yang digunakan untuk menggambarkan struktur, alur proses, hingga implementasi teknis secara terstruktur. Desain dan *tools* pengembangan berperan penting untuk memastikan bahwa sistem atau aplikasi yang dibangun sesuai kebutuhan pengguna, dapat dipahami dengan mudah oleh pengembang, serta memenuhi kaidah teknis yang dibutuhkan. Oleh karena itu, pada subbab ini dijelaskan beberapa komponen penting dalam desain dan *tools* pengembangan pada teknologi informasi, yaitu *Unified Modeling Language* (UML), Flowchart, bahasa pemrograman, dan perangkat lunak pendukung yang digunakan dalam proses implementasi.







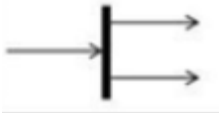
### **2.7.1 *Unified Modeling Language* (UML)**


*Unified Modeling Language* (UML) adalah bahasa pemodelan standar yang digunakan untuk menganalisis, memodelkan, dan mendesain sistem perangkat lunak sebelum tahap implementasi dilakukan. UML membantu pengembang memahami alur sistem dan kebutuhan fungsional melalui representasi grafis seperti *Use Case Diagram*, *Class Diagram*, *Activity Diagram*, dan *Sequence Diagram*, sehingga proses perancangan sistem menjadi lebih terstruktur dan komunikatif antar tim. Studi dalam literatur penelitian juga menegaskan bahwa UML merupakan bahasa pemodelan grafis yang dipakai secara luas dalam rekayasa perangkat lunak untuk memvisualisasikan, mendefinisikan, membangun, dan mendokumentasikan sistem berbasis objek sebagai bagian dari proses desain sistem (Haviluddin, 2011).

**Tabel 2.1 Simbol – simbol Use Case**

No.	Simbol	Nama Simbol	Keterangan
1.		Aktor	Mewakili peran orang, sistem yang lain, atau alat ketika berkomunikasi dengan use case.
2.		Use Case	Abstraksi dan interaksi antara sistem dan aktor.
3.		Directed Association Relationship	Hubungan asosiasi yang diarahkan hanya kepada satu arah.
4.		Generalisasi	Menunjukkan spesialisasi aktor untuk dapat berpartisipasi dengan use case.
5.		Include	Menunjukkan bahwa suatu use case seluruhnya merupakan fungsionalitas dari use case lainnya.
6.		Extend	Menunjukkan suatu use case merupakan tambahan fungsionalitas dari use case lainnya jika suatu kondisi terpenuhi.

**Tabel 2.2 Simbol -simbol Activity Diagram**

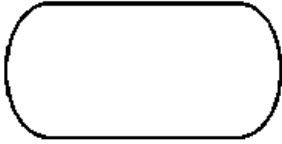


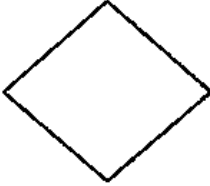

No.	Simbol	Nama Simbol	Keterangan
1.		Activity	Menyatakan bagaimana masing-masing kelas antar muka saling berinteraksi satu sama lain.
2.		Control Flow	Menunjukkan urutan eksekusi.
3.		Object Flow	Menunjukkan aliran objek dari sebuah action atau activity ke action.
4.		Start Point	Menyatakan bahwa sebuah objek dibentuk atau diawali.
5.		End Point	Menyatakan bahwa sebuah objek
6.		Join/Penggabungan	Menyataka untuk menggabungkan kembali activity atau action yang parallel.
7.		Fork	Menyatakan untuk memecah behavior menjadi activity

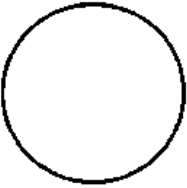
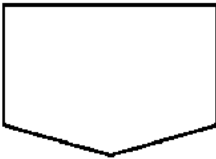

			atau action yang parallel.
8.		Decision	Menunjukkan penggambaran suatu keputusan/tindakan yang harus diambil pada kondisi tertentu.

### 2.7.2 Flowchart

Flowchart adalah diagram grafis yang menggambarkan tahapan proses atau logika suatu program secara sistematis melalui simbol-simbol standar seperti terminator, proses, dan keputusan. Sebagai representasi visual dari urutan langkah serta struktur logika, flowchart digunakan dalam rekayasa perangkat lunak untuk menjabarkan langkah-langkah prosedural dari suatu fungsi atau modul secara runtut dari awal hingga akhir sehingga memudahkan pemahaman terhadap logika yang akan diimplementasikan ke dalam kode program. Studi menunjukkan bahwa flowcharts merupakan alat yang efektif dalam memvisualisasikan proses dan jalur pengambilan keputusan, memungkinkan tugas kompleks dipecah menjadi bagian yang lebih sederhana dan mudah dikelola, serta membantu komunikasi antara perancang dan berbagai pihak terkait dalam pengembangan sistem. Selain itu, penelitian lain menyatakan bahwa flowchart juga dapat berfungsi sebagai media perencanaan dan komunikasi yang jelas dalam perancangan proses, mendukung litbang maupun rekayasa secara umum, serta membantu mendokumentasikan alur berpikir sebelum implementasi teknis dilakukan (Ghritlahare, 2020).

**Tabel 2.3 Simbol Flowchart**

No.	Simbol	Nama Simbol	Keterangan
1.		Terminator	Awal atau akhir konsep (prosedur).
2.		Process	Proses operasional.
3.			Dokumen atau laporan berupa print out.
4.		Decision	Keputusan atau sub point. Garis yang terhubung dengan bentuk decision merujuk pada situasi-situasi yang berbeda sesuai dengan keputusan yang digambarkan,
5.		Data	Input dan Output .

6.		On-Page Reference/Connector	Penghubung alur dalam halaman yang sama.
7.		Off-Page Connector	Penghubung alur dalam halaman yang berbeda.
8.		Flowline	Arah alur dalam konsep (prosedur)

### 2.7.3 Bahasa Pemrograman

Bahasa pemrograman merupakan media penulisan instruksi yang dapat diproses oleh komputer untuk menjalankan fungsi tertentu dalam sistem. Pemilihan bahasa pemrograman ditentukan oleh kebutuhan sistem seperti platform target, kompatibilitas library, struktur data, dan kinerja. Dalam pengembangan aplikasi sistem informasi, bahasa pemrograman sering digunakan untuk menghubungkan antarmuka dengan basis data serta mengimplementasikan logika sistem yang telah dirancang melalui UML atau flowchart (Nurul Awal Delly Murti & Fajri, 2024).

Dalam konteks pengembangan perangkat lunak dan aplikasi khusus, pemilihan bahasa pemrograman dipengaruhi oleh karakteristik bahasa tersebut, termasuk efisiensi eksekusi, fungsionalitas yang tersedia, dan kesesuaian bahasa terhadap kebutuhan proyek yang akan dikembangkan. Hal ini menunjukkan bahwa pemilihan bahasa pemrograman bukan sekedar preferensi, tetapi merupakan

keputusan teknis yang memengaruhi kualitas dan efektivitas pengembangan sistem (Rachmawati et al., 2024).

#### **2.7.4 Software Pengembangan**

*Software* pengembangan mencakup alat bantu yang digunakan dalam proses perancangan, pengkodean, pengujian, hingga pemeliharaan sistem aplikasi berbasis teknologi informasi. Dalam perancangan dan pemodelan, *Software modeling tools* seperti *CASE tools* memungkinkan pengembang untuk membuat diagram UML dan memvisualisasikan struktur sistem secara efektif, sehingga mempermudah proses desain dan dokumentasi sistem sebelum implementasi kode. Studi menunjukkan bahwa penggunaan *CASE tools* dalam proses rekayasa perangkat lunak dapat meningkatkan ketepatan desain dan membantu pengembang dalam memahami aspek struktural dan perilaku sistem secara grafis. Selain itu, selama fase pengkodean dan pengujian, editor kode serta lingkungan pengembangan seperti Visual Studio Code dan XAMPP digunakan untuk menulis instruksi program, mengelola basis data, serta menguji aplikasi yang dikembangkan secara fungsi. Penggunaan *Software* yang tepat tidak hanya membantu mempercepat proses kerja, tetapi juga meningkatkan efisiensi, efektivitas, serta keteraturan dalam setiap tahapan siklus pengembangan perangkat lunak (Cavalcanti & Fagundes, 2025).

*Software* pengembangan merupakan komponen penting dalam siklus pembangunan perangkat lunak karena menyediakan perangkat bantu yang mendukung kegiatan mulai dari desain, penulisan kode, hingga pengujian dan peluncuran aplikasi. Berbagai *Software development tools* seperti *Integrated Development Environments (IDE)* dan *Computer-Aided Software Engineering (CASE) tools* telah diidentifikasi sebagai faktor yang mempengaruhi produktivitas

dan kualitas kerja pengembang. Studi empiris menunjukkan bahwa adopsi tools pengembangan yang tepat dapat membantu pengembang dalam mengelola tugas kompleks, meningkatkan kolaborasi tim, serta mempercepat penyelesaian proyek melalui integrasi fitur analisis, pembuatan kode, serta debugging dalam satu lingkungan kerja. Selain itu, pemilihan dan penggunaan tools yang sesuai dengan kebutuhan proyek akan berdampak positif terhadap efektivitas proses pengembangan perangkat lunak secara keseluruhan, terutama pada fase integrasi dan pengujian sistem (Phillips et al., 2005).

## 2.8 Penelitian Terdahulu

**Tabel 2.4 Ringkasan Penelitian Terdahulu**

NO	Judul dan peneliti	Pembahasan	Metode	Kelebihan atau Kekurangan
1	Peramalan Permintaan Suku Cadang Otomotif Karet dengan Integrasi Agent Based Modelling dan Double Exponential Smoothing.	Penelitian ini mengusulkan teknik berbasis model Penelitian membahas perancangan model peramalan permintaan suku cadang otomotif berbasis karet dengan mengintegrasikan pendekatan Agent Based Modelling (ABM) dan Double Exponential Smoothing (DES) untuk	Agent Based Modelling (ABM), Double Exponential Smoothing (DES), evaluasi error	Kelebihan: Mampu memodelkan interaksi agen dan memantau dampak error peramalan terhadap stok. Kekurangan: Fokus pada metode statistik, belum

NO	Judul dan peneliti	Pembahasan	Metode	Kelebihan atau Kekurangan
	Dewi Auditiya Marizka et al. (2020)	memantau kekurangan dan kelebihan stok akibat kesalahan peramalan.	peramalan	membandingkan dengan metode ensemble atau <i>Machine learning</i> modern.
2	Desain Optimalisasi Peramalan Suku Cadang Berbasis <i>Machine learning</i> . Dewa Made Wikananda Surya Kusuma et al. (2023)	Penelitian ini membandingkan beberapa model peramalan berbasis <i>Machine learning</i> untuk menentukan model terbaik berdasarkan nilai evaluasi kesalahan prediksi, khususnya MAE.	ANN, Autoencoder, LSTM, Random Forest, SVR, Hybrid Autoencoder– LSTM, evaluasi MAE	Kelebihan: Membandingkan banyak model dan menggunakan evaluasi kuantitatif yang jelas. Kekurangan: Fokus utama pada MAE, belum mengkaji metrik evaluasi lain seperti RMSE atau MAPE secara mendalam.

NO	Judul dan peneliti	Pembahasan	Metode	Kelebihan atau Kekurangan
3	Spare Parts Demand Forecasting Method Based on Intermittent Demand <i>Lilin Fan, Xia Liu, Wentao Mao, Kai Yang, dan Zhaoyu Song et al. (2023)</i>	Penelitian ini membahas metode peramalan permintaan suku cadang yang memiliki karakteristik <i>intermittent demand</i> , yaitu pola permintaan yang tidak teratur dan jarang terjadi. Penelitian difokuskan pada peningkatan akurasi prediksi permintaan suku cadang untuk mendukung pengelolaan persediaan yang lebih efisien dan mengurangi risiko kelebihan maupun kekurangan stok.	Metode Croston, Syntetos–Boylan Approximation (SBA), dan Teunter–Syntetos–Babai (TSB) dengan evaluasi kesalahan peramalan	Kelebihan: Mampu menangani karakteristik permintaan suku cadang yang tidak stabil dan jarang muncul. Kekurangan: Kurang optimal untuk data dengan pola permintaan tinggi dan belum memanfaatkan pendekatan <i>Ensemble Learning</i> atau <i>Machine learning</i> modern.

## 2.9 ANALISIS GAP

Berdasarkan kajian terhadap tiga penelitian terdahulu, masih ditemukan keterbatasan dalam pendekatan peramalan kebutuhan suku cadang yang digunakan. Penelitian oleh Lilin Fan dkk. berfokus pada metode statistik untuk menangani *intermittent demand*, yang efektif untuk pola permintaan tidak teratur, namun belum mengadopsi pendekatan *Machine learning* atau *Ensemble Learning* yang lebih adaptif terhadap kompleksitas data. Sementara itu, penelitian peramalan suku cadang otomotif dengan metode time series konvensional masih memiliki keterbatasan dalam menangkap hubungan nonlinier serta perubahan pola permintaan yang dinamis.

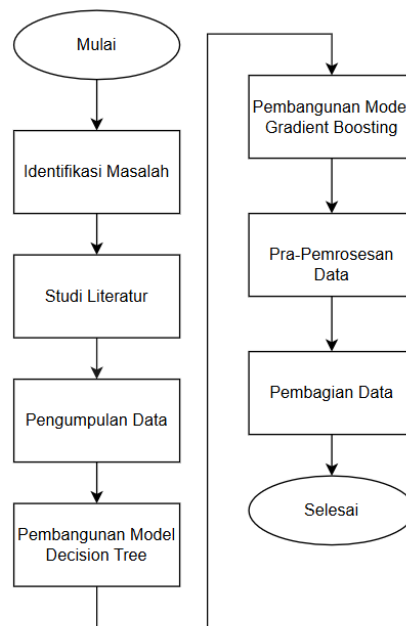
Penelitian lain yang telah menerapkan *Machine learning* menunjukkan peningkatan akurasi, namun masih menggunakan model secara terpisah tanpa mengombinasikan keunggulan beberapa algoritma dalam satu sistem ensemble. Selain itu, evaluasi model belum dilakukan secara komprehensif dengan mempertimbangkan stabilitas dan sensitivitas kesalahan prediksi. Oleh karena itu, diperlukan penelitian yang mengimplementasikan *Ensemble Learning* dengan mengombinasikan *Decision Tree* dan *Gradient Boosting* serta mengevaluasi kinerjanya menggunakan metrik yang tepat, guna meningkatkan akurasi dan keandalan prediksi kebutuhan suku cadang.

## BAB III

### METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen. Pendekatan kuantitatif dipilih karena penelitian berfokus pada pengolahan data numerik berupa data historis penjualan suku cadang Bengkel Auto 252 untuk menghasilkan model prediksi kebutuhan suku cadang menggunakan metode *Machine learning*. Metode eksperimen dilakukan dengan cara membandingkan kinerja algoritma *Decision Tree* dan *Gradient Boosting*, kemudian menggabungkan keduanya menggunakan pendekatan *Ensemble Learning* untuk memperoleh hasil prediksi yang lebih akurat.

#### 3.1 Alur Penelitian

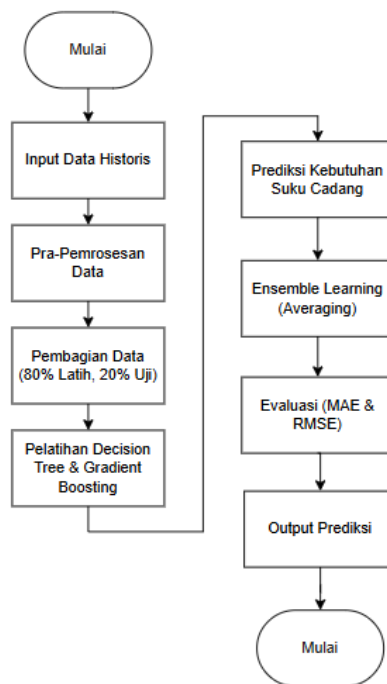


Gambar 3.1 Alur Penelitian

Penelitian ini diawali dengan mengidentifikasi permasalahan persediaan suku cadang di Bengkel Auto 252 yang sering mengalami kekurangan maupun kelebihan stok, kemudian dilanjutkan dengan studi literatur sebagai dasar pemilihan

metode. Data historis penjualan dikumpulkan dan dipra-proses melalui pembersihan data, pengkodean, serta normalisasi, sebelum dibagi menjadi data latih 80% dan data uji 20%. Selanjutnya dibangun model *Decision Tree* dan *Gradient Boosting* untuk mempelajari pola permintaan, lalu hasil keduanya digabungkan menggunakan metode *Ensemble Learning* dengan teknik averaging. Kinerja model dievaluasi menggunakan MAE dan RMSE, dan hasil evaluasi tersebut dianalisis untuk menarik kesimpulan mengenai keakuratan serta efektivitas metode dalam memprediksi kebutuhan suku cadang.

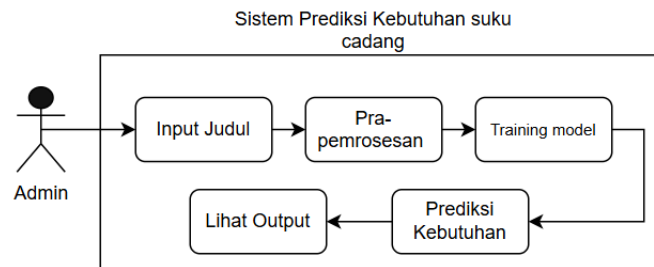
### 3.2 Diagram Rancangan Sistem Dan Pemodelan UML



Gambar 3.2 Diagram Rancangan Sistem

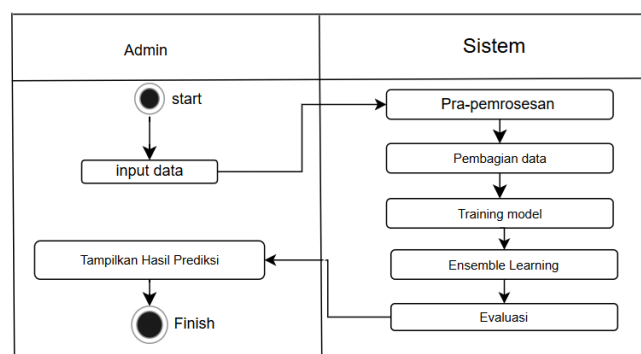
Diagram tersebut menunjukkan alur sistem prediksi kebutuhan suku cadang yang dimulai dari input data historis, kemudian data dipra-proses dan dibagi menjadi data latih dan data uji. Selanjutnya sistem melatih model *Decision Tree* dan *Gradient Boosting*, lalu menghasilkan prediksi yang digabungkan menggunakan metode *Ensemble Learning* (averaging). Hasil prediksi kemudian

dievaluasi menggunakan MAE dan RMSE, dan output akhirnya berupa prediksi kebutuhan suku cadang.



Gambar 3.3 Use Case Diagram

Gambar tersebut merupakan Use Case Diagram sederhana yang menunjukkan alur interaksi antara Admin dengan sistem prediksi kebutuhan suku cadang. Admin memulai proses dengan melakukan Input Data penjualan suku cadang ke dalam sistem. Setelah data dimasukkan, sistem melakukan Pra-Pemrosesan untuk membersihkan dan menyiapkan data agar siap digunakan. Selanjutnya sistem menjalankan proses Training Model untuk membangun model prediksi. Setelah model terbentuk, sistem menghasilkan Prediksi Kebutuhan suku cadang. Hasil prediksi tersebut kemudian dapat diakses oleh Admin melalui fitur Lihat Output, sehingga Admin dapat mengetahui rekomendasi kebutuhan suku cadang untuk periode berikutnya.



Gambar 3.4 Activity Diagram

Gambar tersebut merupakan Activity Diagram dengan swimlane yang memisahkan aktivitas antara Admin dan Sistem pada proses prediksi kebutuhan


suku cadang. Proses dimulai dari sisi Admin, ditandai dengan simbol awal (titik hitam), kemudian Admin melakukan Input Data penjualan suku cadang. Data yang dimasukkan kemudian diteruskan ke sisi Sistem untuk diproses. Sistem melakukan serangkaian tahapan, yaitu Pra-Pemrosesan Data, dilanjutkan dengan Pembagian Data, kemudian Training Model untuk membangun model prediksi, selanjutnya dilakukan *Ensemble Learning* untuk menggabungkan hasil prediksi dari beberapa model, dan terakhir dilakukan Evaluasi untuk menilai akurasi prediksi. Setelah seluruh proses di sistem selesai, hasil dikirim kembali ke sisi Admin untuk Ditampilkan sebagai Hasil Prediksi, kemudian proses diakhiri dengan simbol akhir.

### **3.3 Objek Penelitian**

Objek dalam penelitian ini adalah data historis penjualan suku cadang yang diperoleh dari Bengkel Auto 252. Data yang digunakan dalam penelitian ini adalah data historis penjualan suku cadang Bengkel Auto 252 sebanyak 1081 *record* diambil dari periode Januari 2025 sampai Agustus 2021. Data historis ini digunakan sebagai dasar dalam proses analisis dan pemodelan untuk memprediksi kebutuhan stok suku cadang di masa mendatang menggunakan metode *Decision Tree* dan *Gradient Boosting*. Data yang dikumpulkan mencakup beberapa atribut penting, antara lain:

1. Kode suku cadang, yaitu identitas unik setiap jenis suku cadang.
2. Nama suku cadang, sebagai informasi jenis dan spesifikasi barang..
3. Jumlah penjualan, yaitu kuantitas suku cadang yang terjual pada setiap bulan.
4. Kategori, untuk mengelompokkan penggunaan suku cadang.
5. Bulan dan tahun, untuk penentuan periode

### 3.4 Lokasi Penelitian



Gambar 3.5 Peta Lokasi Mobil Auto 252

Penelitian ini dilaksanakan di Bengkel Auto 252 yang beralamat Jl. Menteng Raya No.252, Binjai, Kec. Medan Denai, Kota Medan, Sumatera Utara 20228, yang berperan sebagai lokasi pengambilan data sekaligus tempat penerapan sistem yang dikembangkan. Bengkel Auto 252 dipilih sebagai lokasi penelitian karena memiliki data penjualan suku cadang yang terdokumentasi dengan baik serta menghadapi permasalahan dalam pengelolaan stok, khususnya dalam menentukan jumlah persediaan yang optimal.

Seluruh data penelitian diperoleh secara langsung dari arsip transaksi Bengkel Auto 252, baik dalam bentuk dokumen manual maupun data digital. Selain itu, observasi proses bisnis bengkel, seperti alur pencatatan penjualan dan pengelolaan stok suku cadang, juga dilakukan untuk memahami kebutuhan sistem secara lebih mendalam. Hasil observasi ini digunakan sebagai dasar dalam perancangan dan implementasi sistem prediksi kebutuhan suku cadang berbasis *Machine learning* yang sesuai dengan kondisi nyata di lapangan.

### **3.5 Implementasi Metode *Decision Tree***

Metode *Gradient Boosting* diterapkan untuk meningkatkan akurasi prediksi dengan cara membangun model secara bertahap menggunakan beberapa model dasar berupa *Decision Tree*. Pada tahap awal, sistem membentuk model pertama berdasarkan data latih yang telah melalui proses pra-pemrosesan. Model ini menghasilkan prediksi awal terhadap kebutuhan suku cadang.

Selanjutnya, sistem menghitung nilai kesalahan (error) antara hasil prediksi dan data aktual. Nilai error tersebut digunakan sebagai dasar untuk membentuk model berikutnya, di mana model baru difokuskan untuk memperbaiki kesalahan yang dihasilkan oleh model sebelumnya. Dengan pendekatan ini, setiap iterasi pelatihan akan menghasilkan model yang semakin baik dalam memprediksi kebutuhan suku cadang.

Proses pembentukan model dilakukan secara berulang hingga diperoleh model dengan tingkat kesalahan yang paling kecil. Melalui mekanisme ini, *Gradient Boosting* mampu menangkap pola data yang lebih kompleks dibandingkan dengan metode tunggal. Hasil prediksi yang dihasilkan oleh model *Gradient Boosting* pada data uji kemudian digunakan sebagai salah satu komponen penting dalam proses *Ensemble Learning* untuk menghasilkan prediksi akhir yang lebih stabil dan akurat.

### **3.6 Implementasi Metode *Gradient Boosting***

Metode *Gradient Boosting* diterapkan untuk meningkatkan akurasi prediksi dengan membangun model secara bertahap. Model awal dibentuk menggunakan data latih, kemudian kesalahan dari hasil prediksi model tersebut dihitung untuk membentuk model berikutnya. Setiap model baru berfungsi memperbaiki kesalahan

dari model sebelumnya sehingga kesalahan prediksi semakin kecil pada setiap iterasi.

Proses ini dilakukan secara berulang sampai diperoleh model dengan tingkat kesalahan yang minimal. Dalam setiap tahap pelatihan, sistem memfokuskan pembelajaran pada data yang sebelumnya sulit diprediksi, sehingga pola permintaan suku cadang yang kompleks dapat dipelajari dengan lebih baik. Pendekatan ini membuat *Gradient Boosting* mampu menghasilkan prediksi yang lebih akurat dibandingkan penggunaan satu model tunggal.

Hasil prediksi dari *Gradient Boosting* pada data uji selanjutnya digunakan sebagai salah satu komponen dalam proses *Ensemble Learning* untuk digabungkan dengan hasil prediksi dari metode *Decision Tree*, sehingga diperoleh prediksi akhir kebutuhan suku cadang yang lebih stabil dan dapat dijadikan dasar pengambilan keputusan pengelolaan stok.

### **3.7 Implementasi Metode *Ensemble Learning***

*Ensemble Learning* digunakan untuk menggabungkan hasil prediksi dari metode *Decision Tree* dan *Gradient Boosting* agar diperoleh hasil prediksi yang lebih stabil dan akurat. Pada penelitian ini digunakan teknik averaging, yaitu dengan menghitung nilai rata-rata dari hasil prediksi kedua model untuk menghasilkan nilai prediksi akhir.

Keterhubungan kedua metode terletak pada karakteristik masing-masing model. *Decision Tree* memiliki kelebihan dalam membentuk aturan keputusan yang mudah dipahami, namun cenderung sensitif terhadap perubahan data sehingga berpotensi menghasilkan prediksi yang kurang stabil. Sebaliknya, *Gradient Boosting* memiliki kemampuan memperbaiki kesalahan prediksi secara bertahap

sehingga mampu menghasilkan model dengan akurasi tinggi, tetapi membutuhkan proses pelatihan yang lebih kompleks.

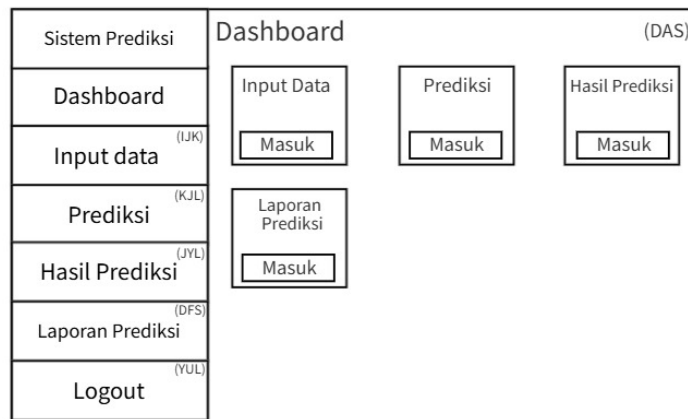
Dengan menggabungkan kedua metode tersebut, kelemahan masing-masing model dapat saling ditutupi. Hasil prediksi dari *Decision Tree* memberikan gambaran pola dasar permintaan, sedangkan *Gradient Boosting* memperhalus hasil prediksi tersebut dengan memperbaiki kesalahan yang terjadi. Pendekatan ini membuat hasil prediksi akhir lebih representatif terhadap pola data historis penjualan suku cadang dan dapat digunakan sebagai dasar pengambilan keputusan dalam pengelolaan stok di Bengkel Auto 252.

### 3.8 Desain Perancangan Antar Muka

The image shows a login interface for a system titled "SISTEM PREDIKSI SUKU CADANG BENGKEL AUTO 252". The interface is contained within a rectangular border. At the top, the title is centered. Below the title, there are two input fields: one for "Username" and one for "Password". Below the "Password" field, there is a button labeled "Login (DAS)".

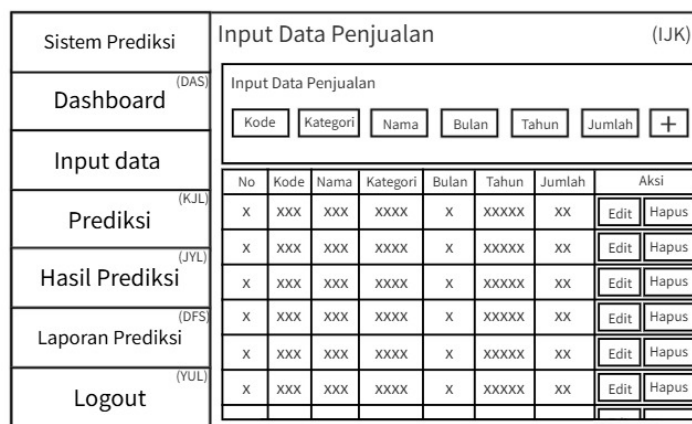
Gambar 3.6 Desain Interface Menu Login

Halaman menampilkan login dari sebuah aplikasi bernama Sistem Prediksi Kebutuhan Suku Cadang (LOG). Pada halaman ini terdapat judul sistem di bagian atas, diikuti dengan dua kolom isian yaitu username dan password yang harus diisi oleh pengguna. Di bawah kolom tersebut terdapat tombol Login yang jika di klik masuk untuk masuk ke dalam tampilan utama (DAS).



Gambar 3.7 Desain Interface Menu Utama

Gambar tersebut menunjukkan tampilan dashboard (DAS) dari Sistem Prediksi Kebutuhan Suku Cadang Bengkel Auto 252. Pada sisi kiri tersedia menu navigasi seperti Input Data, Prediksi, Hasil Prediksi, Laporan Hasil Prediksi dan Logout yang mana masing-masing bisa di klik untuk melihat tampilan dari masing-masing halaman.



Gambar 3.8 Desain Interface Menu Input Penjualan

Gambar tersebut menampilkan halaman input penjualan (IJK) pada Sistem Prediksi Kebutuhan Suku Cadang Bengkel Auto 252. Halaman ini menyediakan kolom untuk menambahkan hasil penjualan beserta kode, kategori dan bulan penjualan. Kemudian dibawahnya terdapat data hasil penjualan yang telah dimasukkan atau data set yang saya gunakan dalam sistem ini. Di sisi kiri terdapat

menu navigasi untuk berpindah ke halaman lain seperti Prediksi, Hasil Prediksi, Laporan hasil Prediksi dan Logout.

Gambar 3.9 Desain Interface Menu Prediksi

Pada Halaman ini kita dapat memilih kategori mana yang akan kita prediksi, lalu memilih nama barang, tahun, bulan dan tombol untuk memproses prediksi. Di sisi kiri terdapat menu navigasi untuk berpindah ke halaman lain seperti Dashboard, Input Data, Hasil Prediksi, Laporan hasil Prediksi dan Logout.

Gambar 3.10 Desain Interface Menu Hasil Prediksi

Gambar tersebut menunjukkan rancangan Menu Hasil sistem prediksi kebutuhan suku cadang yang terdiri dari menu navigasi di sisi kiri dan area utama di sisi kanan. Menu kiri berisi fitur seperti input data, proses prediksi, hasil prediksi, dan logout. Pada bagian kanan terdapat hasil prediksi yang berisi perhitungan

dari *Decision Tree*, *Gradien Boosting*, dan *Ensemble Learning*. Selain itu ditampilkan juga nilai evaluasi akurasi seperti MAE dan MSAE, sehingga pengguna dapat melihat hasil prediksi sekaligus mengukur tingkat kesalahan model secara sederhana.

Sistem Prediksi	(DFS)												
Dashboard (DAS)	LAPORAN HASIL PREDIKSI SUKU CADANG BENGKEL AUTO 252												
Input data (IJK)	Download PDF Laporan												
Prediksi (KJL)	No	Kode	Nama	Kategori	Bulan	Tahun	Penjualan	MAE	RMSE	Decision Tree	Gradient Boosting	Ensemble Learning	Tanggal Prediksi
Hasil Prediksi (JYL)													
Laporan Prediksi													
Logout (YUL)													

Gambar 3.11 Desain Interface Menu Laporan Hasil Prediksi

Pada halaman ini menampilkan hasil prediksi yang sudah sudah kita prediksi pada menu prediksi, hasil dari prediksi akan masuk secara otomatis pada halaman laporan prediksi. Disisi kiri ada navigasi yang berisikan dashboard, input data, prediksi, hasil prediksi dan logout.

Sistem Prediksi	(YUL)
Dashboard (DAS)	<div style="border: 1px solid black; padding: 10px; margin: 0 auto; width: 80%;"> <p>Apakah Anda yakin ingin logout?</p> <div style="display: flex; justify-content: space-around; margin-top: 10px;"> <span>Ya,Logout</span> <span>Tidak</span> </div> </div>
Input data (IJK)	
Prediksi (KJL)	
Hasil Prediksi (JYL)	
Laporan Prediksi (DFS)	
Logout	

Gambar 3.12 Desain Interface Menu Logout

Pada halaman ini ditampilkan pertanyaan apakah anda akan keluar dari sistem, dan ada dua pilihan yang pertama Ya,Logout, yang jika di klik maka kita akan keluar dari sistem, kedua Tidak yang jika di klik maka kita akan tetap berada

dalam sistem.

### 3.9 Jadwal Penelitian

**Tabel 3.1 Jadwal Penelitian**

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

## BAB IV

### HASIL DAN PEMBAHASAN

#### 4.1 Hasil

Hasil tampilan antarmuka merupakan tahapan akhir dari proses implementasi sistem prediksi kebutuhan suku cadang yang telah dirancang berdasarkan analisis dan perancangan sebelumnya. Pada tahap ini, sistem telah siap dioperasikan dalam kondisi nyata untuk membantu Bengkel Auto 252 dalam memprediksi jumlah kebutuhan suku cadang berdasarkan data historis penjualan. Antarmuka aplikasi dirancang secara sederhana dan mudah digunakan agar memudahkan pengguna dalam melakukan penginputan data seperti jenis suku cadang, jumlah penjualan, periode waktu, serta variabel pendukung lainnya. Melalui antarmuka ini, pengguna dapat memperoleh output berupa hasil prediksi kebutuhan suku cadang untuk periode berikutnya yang dihasilkan oleh metode *Decision Tree*, *Gradient Boosting*, dan *Ensemble Learning*. Menu yang tersedia dalam sistem meliputi menu beranda sebagai halaman utama, menu input data untuk memasukkan data yang akan diproses, serta menu hasil prediksi yang menampilkan estimasi jumlah stok yang direkomendasikan sebagai dasar pengambilan keputusan dalam pengelolaan persediaan suku cadang.

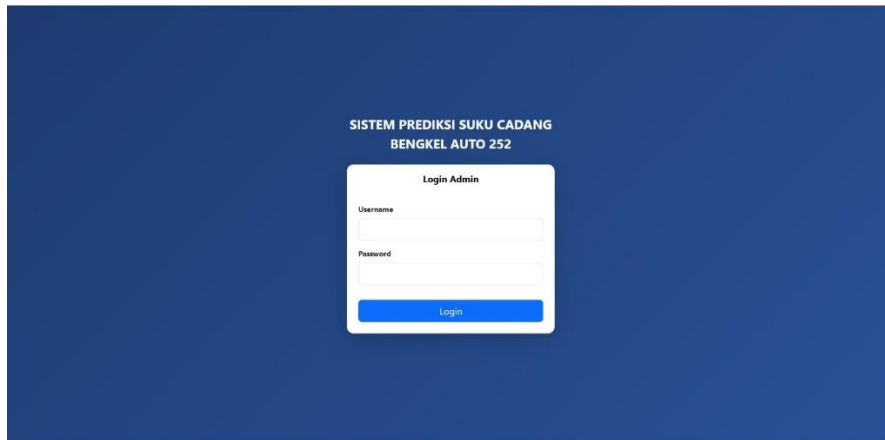
##### 4.1.1 Halaman Admin

Pada halaman Admin terdapat beberapa menu akses yang digunakan untuk mengelola sistem prediksi kebutuhan suku cadang. Adapun Halaman Admin sebagai berikut.

##### 1. Menu Login

Menu Login digunakan untuk mengamankan sistem dari pengguna yang tidak berwenang sebelum masuk ke menu utama. Pada halaman ini, admin harus

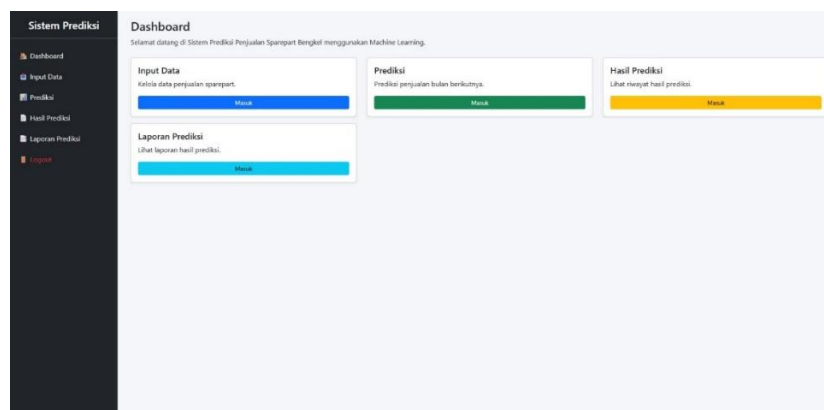
memasukkan username dan password yang telah terdaftar agar dapat mengakses sistem. Berikut merupakan tampilan Menu Login:



Gambar 4.1 Menu Login

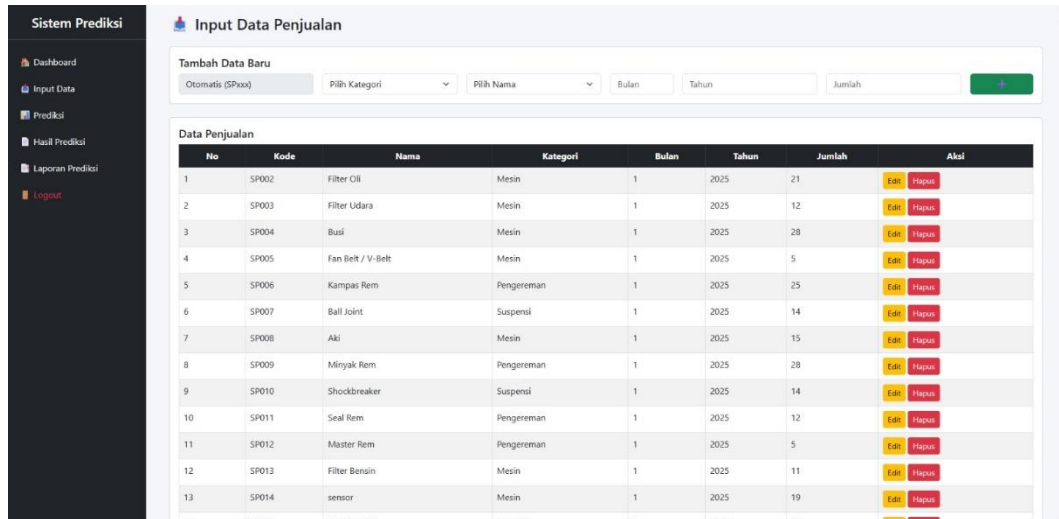
## 2. Menu Utama

Menu Utama merupakan halaman yang tampil setelah admin berhasil melakukan login. Pada halaman ini tersedia beberapa pilihan menu yang dapat digunakan untuk mengelola sistem, menu Utama berfungsi sebagai pusat navigasi untuk mengakses seluruh fitur dalam sistem prediksi kebutuhan suku cadang. Adapun tampilannya berikut.



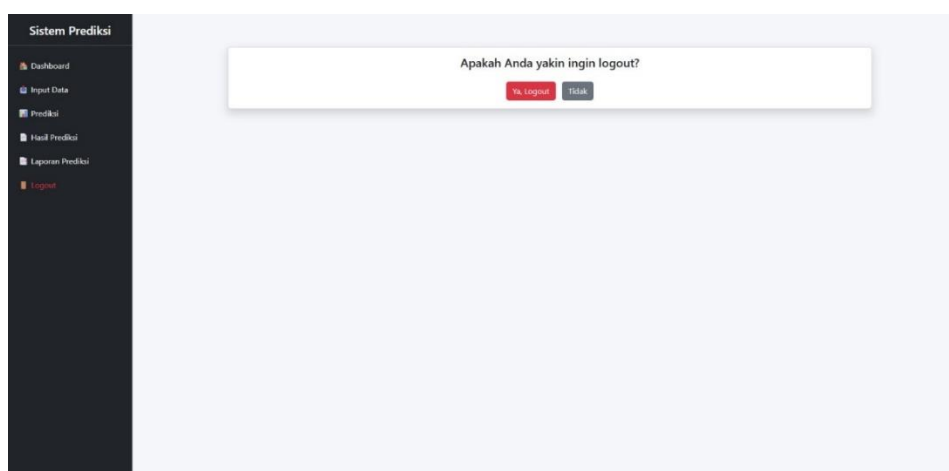
Gambar 4.2 Menu Utama

Halaman ini merupakan dashboard yang isinya berupa, input data, prediksi dan hasil prediksi, dan juga laporan hasil prediksi yang semua itu bisa di klik untuk dilihat atau di update pada halaman masing-masing.



Gambar 4.3 Halaman Input Data

Pada halaman input data ini ditampilkan data yang menjadi data set yang didalamnya berupa kode, nama, kategori, bulan, tahun dan jumlah penjualan dari barang. Pada halaman ini kita juga bisa mengedit dan menghapus data. Halaman ini juga menyediakan fitur untuk menambah data penjualan yang kita inginkan .



Gambar 4.4 Halaman Logout

Halaman ini ada 2 pilihan yaitu “ya, Logout” maka akan keluar dari sistem atau Tidak maka tidak akan keluar dari sistem.

#### 4.1.2 Halaman Prediksi Suku Cadang

The screenshot shows a web interface for 'Sistem Prediksi'. On the left is a dark sidebar with menu items: Dashboard, Input Data, Prediksi, Hasil Prediksi, Laporan Prediksi, and Logout. The main content area is titled 'Prediksi Kebutuhan Sparepart'. It contains a form with the following fields: 'Kategori' (dropdown), 'Nama Barang' (dropdown), 'Tahun' (text input), and 'Pilih Bulan' (a grid of buttons for Jan, Feb, Mar, Apr, Mei, Jun, Jul, Ags, Sep, Okt, Nov, Des). At the bottom of the form is a blue button labeled 'Proses Prediksi'.

Gambar 4.5 Halaman Prediksi

Menu Input Data digunakan untuk memasukkan data penjualan suku cadang yang akan diproses oleh sistem. Pada halaman ini, admin mengisi informasi seperti jenis suku cadang, jumlah penjualan, periode waktu. Data yang telah diinput kemudian akan diproses oleh metode *Decision Tree*, *Gradient Boosting*, dan *Ensemble Learning* untuk menghasilkan prediksi kebutuhan suku cadang pada periode berikutnya.

#### 4.1.3 Menu Hasil Prediksi

The screenshot shows the 'Hasil Prediksi' page. It features a table with the following data row:

No	Kode	Nama Barang	Kategori	Bulan	Tahun	Prediksi DT	Prediksi GB	Prediksi Ensemble	Penjualan	MAE	RMSE	Percentage (%)
1	SP014	wanson	Mesin	1	2023	18.14	19.08	19.21	18	0.13	0.25	1.17%

Below the table is a button labeled 'Prediksi Lagi'.

Gambar 4.6 Halaman Hasil Prediksi

Menu Hasil Prediksi digunakan untuk menampilkan output dari proses perhitungan yang telah dilakukan oleh sistem. Pada halaman ini, admin dapat melihat hasil estimasi jumlah kebutuhan suku cadang untuk periode berikutnya berdasarkan metode *Decision Tree*, *Gradient Boosting*, dan *Ensemble Learning*. Informasi yang ditampilkan dapat digunakan sebagai dasar dalam menentukan jumlah stok yang perlu disediakan guna menghindari kekurangan maupun kelebihan persediaan.

#### 4.1.4 Menu Laporan Prediksi

No	Kode	Nama Barang	Kategori	Bulan	Tahun	Penjualan Aktual	Decision Tree	Gradient Boosting	Ensemble	MAE	RMSE	Tanggal Prediksi	Persentase (%)
1	SP001	Oil Mesin	Mesin	1	2025	60	24,08	24,60	24,84	23,66	23,66	2025-04-13	88,5%
2	SP002	Filter Oli	Mesin	1	2025	21	12,09	9,66	10,88	10,12	10,12	2025-04-12	86,5%
3	SP003	Filter Udara	Mesin	1	2025	12	19,34	19,08	19,21	7,21	7,21	2025-04-13	88,8%
4	SP004	Rudi	Mesin	1	2025	28	87,50	81,20	84,85	6,85	6,85	2025-04-18	92,8%
5	SP005	Fan Belt / V-Belt	Mesin	1	2025	5	15,16	14,12	14,64	9,64	9,64	2025-04-13	92,8%
6	SP006	Kampas Rem	Penggerak	1	2025	25	18,13	19,52	18,83	6,17	6,17	2025-04-13	93,8%
7	SP007	Roll Inot	Suspensi	1	2025	14	13,14	13,57	13,36	0,64	0,64	2025-04-13	87,5%
8	SP008	Aki	Mesin	1	2025	15	15,16	14,12	14,64	0,36	0,36	2025-04-13	87,5%
9	SP009	Minyak Rem	Penggerak	1	2025	28	6,50	10,14	7,32	20,68	20,68	2025-04-13	91,8%
10	SP010	Shockbreaker	Suspensi	1	2025	14	9,29	11,90	10,60	8,40	8,40	2025-04-13	94,2%
11	SP011	Seal Rem	Penggerak	1	2025	12	21,46	21,17	21,31	9,31	9,31	2025-04-13	97,5%
12	SP012	Master Rem	Penggerak	1	2025	5	18,13	15,74	16,93	11,93	11,93	2025-04-13	93,8%
13	SP013	Filter Bensin	Mesin	1	2025	11	15,16	14,38	14,77	3,77	3,77	2025-04-13	94,7%
14	SP014	sensor	Mesin	1	2025	19	19,34	19,08	19,21	0,21	0,21	2025-04-13	97,8%
15	SP015	Bushing Aem	Suspensi	1	2025	11	13,14	13,08	13,11	2,11	2,11	2025-04-13	95,9%
16	SP016	Tie Rod	Suspensi	1	2025	8	13,14	13,08	13,11	5,11	5,11	2025-04-13	93,8%
17	SP017	Lampu	Mesin	1	2025	12	13,25	16,03	14,64	2,64	2,64	2025-04-13	93,8%
18	SP018	kol	Mesin	1	2025	9	19,34	19,08	19,21	10,21	10,21	2025-04-13	93,8%

Gambar 4.7 Laporan Hasil Prediksi

Menu Laporan Hasil Prediksi ini menampilkan hasil semua laporan prediksi, pada halaman ini dilengkapi dengan no, kode, nama barang, kategori, bulan, tahun dan hasil dari decision tree, Gradient Boosting, dan juga ensemble learning. Dan juga tersedia tombol untuk mendownload hasil prediksi berbentuk pdf yang nantinya dapat dicetak atau diprint

#### 4.2 Hasil Implementasi *Decision Tree*

Pada tahap ini dilakukan pengujian model *Decision Tree* terhadap data uji untuk mengetahui kemampuan model dalam memprediksi kebutuhan suku cadang berdasarkan data historis penjualan Bengkel Auto 252. Model yang telah dilatih

sebelumnya kemudian menghasilkan nilai prediksi yang selanjutnya dibandingkan dengan nilai aktual untuk mengukur tingkat akurasi. Berikut contoh hasil prediksi pada data uji :

**Tabel 4.1 Data Aktual dan Hasil Prediksi *Decision Tree* bulan januari 2025**

No	Kategori	Aktual ( $Y_i$ )	Prediksi ( $\hat{Y}_i$ )
1	Oli Mesin	60	24,08
2	Filter Oli	20	12,9
3	Filter Udara	12	19,34
4	Busi	28	37,5
5	Fan Belt / V-Belt	5	15,16
6	Kampas Rem	25	18,13
7	Ball Joint	14	13,14
8	Aki	15	15,16
9	Minyak Rem	28	4,5
10	Shockbreaker	14	9,29
11	Seal Rem	12	21,46
12	Master Rem	5	18,13
13	Filter Bensin	11	15,16
14	sensor	19	19,34
15	Bushing Arm	11	13,14
16	Tie Rod	8	13,14
17	Lampu	12	13,25
18	koil	9	19,34

Berdasarkan tabel di atas, terlihat bahwa terdapat perbedaan antara nilai aktual dan nilai prediksi pada masing-masing jenis suku cadang. Untuk mengetahui seberapa besar tingkat kesalahan prediksi yang dihasilkan oleh model, maka dilakukan perhitungan menggunakan metrik *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE).

Mean Absolute Error (MAE) digunakan untuk mengukur rata-rata selisih absolut antara nilai aktual dan nilai prediksi. MAE memberikan gambaran seberapa besar rata-rata kesalahan prediksi dalam satuan yang sama dengan data asli. Rumus MAE :

$$MAE = \frac{1}{n} \sum_{i=1}^N |y_i - \hat{y}_i|$$

**Tabel 4.2 Perhitungan *Error Absolut Decision Tree* Januari 2025**

No	Aktual (Yi)	Prediksi (Ŷi)	(Yi – Ŷi)
1	60	24,08	35,92
2	20	12,9	7,1
3	12	19,34	-7,34
4	28	37,5	-9,5
5	5	15,16	-10,16
6	25	18,13	6,87
7	14	13,14	1,14
8	15	15,16	-0,16
9	28	4,5	23,5
10	14	9,29	4,71
11	12	21,46	-9,46
12	5	18,13	-13,13
13	11	15,16	-4,16
14	19	19,34	-0,34
15	11	13,14	-2,14
16	8	13,14	-5,14
17	12	13,25	1,25
18	9	19,34	10,34

Total error absolut = 35,92 + 7,1 + (-7,34) + (-9,5) + (-10,16) + 6,87 + 1,14 + (-0,16) + 23,5 + 4,71 + (-9,46) + (-13,13) + (-4,16) + (-0,34) + (-2,14) + (-5,14) + 1,25 + 10,34 = 155,33

Jumlah data (n) = 18 maka,

$$MAE = \frac{155,33}{18}$$

$$MAE = 8,63$$

*Root Mean Squared Error* (RMSE) digunakan untuk mengukur tingkat kesalahan prediksi dengan memberikan penalti lebih besar terhadap kesalahan yang bernilai besar. RMSE lebih sensitif terhadap outlier dibandingkan MAE. Rumus RMSE :

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

**Tabel 4.3 Perhitungan Error Kuadrat *Decision Tree* Januari 2025**

No	(Yi - Ŷi)	(Yi - Ŷi) <sup>2</sup>
1	35,92	1.290,2464
2	7,1	50,41
3	-7,34	53,8756
4	-9,5	90,25
5	-10,16	103,2256
6	9,84	96,8256
7	1,14	1,2996
8	-0,16	0,0256
9	23,5	552,25
10	4,71	22,1841
11	-9,46	89,4916
12	-13,13	172,3969
13	-4,16	17,3056

14	-0,34	0,1156
15	-2,14	4,5796
16	-5,14	26,4196
17	1,25	1,5625
18	10,34	106,9156

Total error kuadrat = 1.290,2464 + 50,41 + 53,8756 + 90,25 + 103,2256 + 96,8256 + 1,2996 + 0,0256 + 552,25 + 22,1841 + 89,4916 + 172,3969 + 17,3056 + 0,1156 + 4,5796 + 26,4196 + 1,5625 + 06,9156 = 2.679,38

Jumlah data (n) 18 maka,

$$RMSE = \sqrt{\frac{2.679,38}{18}}$$

$$RMSE = \sqrt{148,85}$$

$$RMSE = 12,20$$

Berdasarkan hasil perhitungan MAE dan RMSE, dapat disimpulkan bahwa model *Decision Tree* sudah mampu memprediksi kebutuhan suku cadang dengan tingkat kesalahan yang relatif kecil. Nilai RMSE lebih besar dari MAE menunjukkan bahwa terdapat beberapa prediksi dengan error yang cukup tinggi, namun masih dalam batas yang dapat diterima.

#### 4.3 Hasil Implementasi *Gradient Boosting*

Pada tahap ini dilakukan pengujian model *Gradient Boosting* untuk memprediksi kebutuhan suku cadang berdasarkan data historis penjualan Bengkel Auto 252. Berbeda dengan *Decision Tree* yang membentuk satu pohon keputusan, *Gradient Boosting* membangun beberapa pohon secara bertahap (sequential) untuk memperbaiki kesalahan dari model sebelumnya.

Metode ini bekerja dengan cara meminimalkan error secara iteratif sehingga setiap pohon baru yang dibangun akan fokus pada kesalahan prediksi sebelumnya. Dengan mekanisme tersebut, model diharapkan menghasilkan prediksi yang lebih akurat dan stabil dibandingkan model tunggal. Berikut merupakan contoh hasil prediksi model *Gradient Boosting* pada data uji:

**Tabel 4.4 Data Aktual dan Hasil Prediksi *Gradient Boosting* Januari 2025**

No	Kategori	Aktual ( $Y_i$ )	Prediksi ( $\hat{Y}_i$ )
1	Oli Mesin	60	24,6
2	Filter Oli	20	9,66
3	Filter Udara	12	19,08
4	Busi	28	31,2
5	Fan Belt / V-Belt	5	14,12
6	Kampas Rem	25	19,52
7	Ball Joint	14	13,57
8	Aki	15	14,12
9	Minyak Rem	28	10,14
10	Shockbreaker	14	11,9
11	Seal Rem	12	21,17
12	Master Rem	5	15,74
13	Filter Bensin	11	14,38
14	sensor	19	19,8
15	Bushing Arm	11	13,08
16	Tie Rod	8	13,08
17	Lampu	12	16,03
18	koil	9	19,08

Berdasarkan tabel di atas, terlihat bahwa selisih antara nilai aktual dan nilai prediksi lebih kecil dibandingkan hasil *Decision Tree* sebelumnya. Untuk

mengetahui tingkat akurasi model secara kuantitatif, dilakukan perhitungan MAE dan RMSE. Rumus MAE :

$$MAE = \frac{1}{n} \sum_{i=1}^N |y_i - \hat{y}_i|$$

**Tabel 4.5 Perhitungan *Error Absolut Gradient Boosting* Januari 2025**

No	Aktual (Yi)	Prediksi ( $\hat{Y}_i$ )	(Yi - $\hat{Y}_i$ )
1	60	24,6	35,4
2	20	9,66	10,34
3	12	19,08	-7,08
4	28	31,2	-3,2
5	5	14,12	-9,12
6	25	19,52	5,48
7	14	13,57	0,43
8	15	14,12	0,88
9	28	10,14	17,86
10	14	11,9	2,1
11	12	21,17	-9,17
12	5	15,74	-10,74
13	11	14,38	-3,38
14	19	19,8	-0,8
15	11	13,08	-2,08
16	8	13,08	-5,08
17	12	16,03	-4,03
18	9	19,08	-10,08

Total error absolut = 35,4 + 10,34 + (-7,08) + (-3,2) + (-9,12) + 5,48 + 0,43 + 0,88 + 17,86 + 2,1 + (-9,17) + (-10,74) + (-3,38) + (-0,8) + (-2,08) + (-5,08) + (-4,03) + (-10,08) = 137,25 Jumlah data (n) 18 maka =

$$MAE = \frac{137,25}{18}$$

$$MAE = 7,63$$

Root Mean Squared Error (RMSE) digunakan untuk mengukur tingkat kesalahan prediksi dengan memberikan penalti lebih besar terhadap kesalahan yang bernilai besar. RMSE lebih sensitif terhadap outlier dibandingkan MAE. Rumus RMSE:

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

**Tabel 4.6 Perhitungan Error Kuadrat *Gradient Boosting* Januari 2025**

No	(Yi – Ŷi)	(Yi – Ŷi) <sup>2</sup>
1	35,4	1.253,16
2	10,34	106,9156
3	-7,08	50,1264
4	-3,2	10,24
5	-9,12	83,1744
6	5,48	30,0304
7	0,43	0,1849
8	0,88	0,7744
9	17,86	318,9796
10	2,1	4,41
11	-9,17	84,0989
12	-10,74	115,3476
13	-3,38	11,4244
14	-0,8	0,64
15	-2,08	4,3264
16	-5,08	25,8064
17	-4,03	16,2409
18	-10,08	101,6064

Total error kuadrat = 1.253,16 + 106,9156 + 50,1264) + 10,24 + 83,1744 + 30,0304 + 2,4649 + 1,2544 + 318,9796 + 4.41 + 84,0989 + 115,3476 + 11,4244 + 0,64 + 4,3264 + 25,8064 + 18,6624 + -101,6064 = 1.983,45

Jumlah data (n) 18 maka,

$$RMSE = \sqrt{\frac{1.983,45}{18}}$$

$$RMSE = \sqrt{110,19}$$

$$RMSE = 10,50$$

Berdasarkan hasil perhitungan MAE dan RMSE, dapat disimpulkan bahwa model *Gradient Boosting* sudah mampu memprediksi kebutuhan suku cadang dengan tingkat kesalahan yang relatif kecil. Nilai RMSE lebih besar dari MAE menunjukkan bahwa terdapat beberapa prediksi dengan error yang cukup tinggi, namun masih dalam batas yang dapat diterima.

#### 4.4 Hasil Implementasi *Ensemble Learning*

Setelah dilakukan pengujian terhadap metode *Decision Tree* dan *Gradient Boosting*, tahap selanjutnya adalah menggabungkan kedua model tersebut menggunakan teknik *Ensemble Learning* dengan pendekatan *averaging*. Tujuan dari penggabungan ini adalah untuk meningkatkan stabilitas dan akurasi prediksi dengan cara mengurangi kelemahan dari masing-masing model tunggal. Teknik *averaging* dilakukan dengan menghitung rata-rata dari hasil prediksi *Decision Tree* dan *Gradient Boosting* pada setiap data uji. Rumus *Ensemble Averaging* :

$$\text{Prediksi Ensemble} = \frac{\text{Prediksi DT} + \text{Prediksi GB}}{2}$$

Berikut merupakan hasil prediksi dari masing-masing metode:

**Tabel 4.7 Perbandingan Prediksi Januari 2025**

No	Kategori	Aktual	DT	GB	Ensemble
1	Oli Mesin	60	24,08	24,6	23,34
2	Filter Oli	20	12,9	9,66	10,88
3	Filter Udara	12	19,34	19,08	19,21
4	Busi	28	37,5	31,2	34,35
5	Fan Belt / V-Belt	5	15,16	14,12	14,64
6	Kampas Rem	25	18,13	19,52	18,83
7	Ball Joint	14	13,14	13,57	13,36
8	Aki	15	15,16	14,12	14,64
9	Minyak Rem	28	4,5	10,14	7,32
10	Shockbreaker	14	9,29	11,9	10,6
11	Seal Rem	12	21,46	21,17	21,31
12	Master Rem	5	18,13	15,74	16,93
13	Filter Bensin	11	15,16	14,38	14,77
14	sensor	19	19,34	19,8	19,21
15	Bushing Arm	11	13,14	13,08	13,11
16	Tie Rod	8	13,14	13,08	13,11
17	Lampu	12	13,25	16,03	14,64
18	koil	9	19,34	19,08	19,21

Hasil tersebut menunjukkan bahwa metode Ensemble menghasilkan nilai prediksi yang berada di antara hasil *Decision Tree* dan *Gradient Boosting*, sehingga dapat menyeimbangkan perbedaan prediksi dari kedua model. Untuk mengetahui tingkat akurasi metode Ensemble secara kuantitatif, selanjutnya dilakukan perhitungan Mean Absolute Error (MAE).

**Tabel 4.8 Perhitungan *Error Absolut Ensemble* Januari 2025**

No	Aktual ( $Y_i$ )	Prediksi ( $\hat{Y}_i$ )	$(Y_i - \hat{Y}_i)$
1	60	23,34	36,66
2	20	10,88	9,12

3	12	19,21	-7,21
4	28	34,35	-6,35
5	5	14,64	-9,64
6	25	18,83	6,17
7	14	13,36	0,64
8	15	14,64	0,36
9	28	7,32	20,68
10	14	10,6	3,4
11	12	21,31	-9,31
12	5	16,93	-11,93
13	11	14,77	-3,77
14	19	19,21	-0,21
15	11	13,11	-2,11
16	8	13,11	-5,11
17	12	14,64	-2,64
18	9	19,21	-10,21

Berdasarkan Tabel 4.8, dihitung selisih absolut antara nilai aktual dan nilai prediksi Ensemble pada masing-masing data. Selisih absolut ini menunjukkan besarnya kesalahan prediksi tanpa memperhatikan arah kesalahan. Total Keseluruhan. Berikut hasil Perhitungan *Error Absolut Ensemble*. Total error absolut =  $36,66 + 9,12 + (-7,21) + (-6,35) + (-9,64) + 6,17 + 0,64 + 0,36 + 20,68 + 3,4 + (-9,31) + (-11,93) + (-3,77) + 0,21 + (-2,11) + (-5,11) + -2,64 + (-10,21) = 145,51$

$$MAE = \frac{145,51}{18}$$

$$MAE = 8,08$$

**Tabel 4.9 Perhitungan Error Kuadrat Ensemble Januari 2025**

No	$(Y_i - \hat{Y}_i)$	$(Y_i - \hat{Y}_i)^2$
1	36,66	1343,9556
2	9,12	83,1744

3	-7,21	51,9841
4	-6,35	40,3225
5	-9,64	92,9296
6	6,17	38,0729
7	0,64	0,4096
8	0,36	0,1296
9	20,68	427,6624
10	3,4	11,56
11	-9,31	86,6761
12	-11,93	142,3249
13	-3,77	14,2129
14	-0,21	0,0441
15	-2,11	4,4521
16	-5,11	26,1121
17	-2,64	6,9696
18	-10,21	104,2441

Total error kuadrat = 1343,9556+ 83,1744+ 51,9841 + 40,3225+ 92,9296 + 38,0729+ 0,4096+ 0,1296+ 427,6624+ 11,56+ 86,6761+ 142,3249+ 14,2129+ 0,0441+ 4,4521+ 26,1121+ 6,9696+ 104,2441= 2475,2366

Jumlah data (n) 18 maka,

$$RMSE = \sqrt{\frac{2475,2366}{18}}$$

$$RMSE = \sqrt{137,51}$$

$$RMSE = 11,73$$

Berdasarkan hasil perhitungan MAE dan RMSE, dapat disimpulkan bahwa model *Ensemble Learning* sudah mampu memprediksi kebutuhan suku cadang dengan tingkat kesalahan yang relatif kecil. Nilai RMSE lebih besar dari MAE

menunjukkan bahwa terdapat beberapa prediksi dengan error yang cukup tinggi, namun masih dalam batas yang dapat diterima.

**Tabel 4.10 Hasil Persentasi Akurasi**

No	Kategori	Aktual	DT	GB	Ensemble	Hasil Persentasi Akurasi
1	Oli Mesin	60	24,08	24,6	23,34	59,43%
2	Filter Oli	20	12,9	9,66	10,88	48,19%
3	Filter Udara	12	19,34	19,08	19,21	60,08%
4	Busi	28	37,5	31,2	34,35	22,68%
5	Fan Belt / V-Belt	5	15,16	14,12	14,64	192,8%
6	Kampas Rem	25	18,13	19,52	18,83	24,69%
7	Ball Joint	14	13,14	13,57	13,36	4,57%
8	Aki	15	15,16	14,12	14,64	2,4%
9	Minyak Rem	28	4,5	10,14	7,32	73,86%
10	Shockbreaker	14	9,29	11,9	10,6	24,29%
11	Seal Rem	12	21,46	21,17	21,31	77,58%
12	Master Rem	5	18,13	15,74	16,93	238,6%
13	Filter Bensin	11	15,16	14,38	14,77	34,27%
14	sensor	19	19,34	19,8	19,21	1,11%
15	Bushing Arm	11	13,14	13,08	13,11	19,18%
16	Tie Rod	8	13,14	13,08	13,11	63,88%
17	Lampu	12	13,25	16,03	14,64	22,0%
18	koil	9	19,34	19,08	19,21	113,44

Dari tabel diatas dapat disimpulkan bahwa Berdasarkan tabel, terdapat perbedaan antara nilai aktual dan hasil prediksi dari metode Decision Tree (DT), Gradient Boosting (GB), dan Ensemble. Secara umum, metode Gradient Boosting (GB) menghasilkan prediksi yang paling mendekati nilai aktual, sedangkan

Decision Tree (DT) memiliki selisih yang lebih besar. Metode Ensemble memberikan hasil yang lebih stabil karena berada di antara DT dan GB.

#### **4.5 Pembahasan**

Berdasarkan hasil pengujian yang telah dilakukan terhadap tiga metode yaitu Decision Tree, Gradient Boosting, dan Ensemble Learning, diperoleh nilai evaluasi menggunakan metrik Mean Absolute Error (MAE) dan Root Mean Squared Error (RMSE). Evaluasi ini bertujuan untuk mengukur tingkat akurasi masing-masing model dalam memprediksi kebutuhan suku cadang di Bengkel Auto 252 berdasarkan data historis penjualan.

Hasil perhitungan menunjukkan bahwa metode *Decision Tree* menghasilkan nilai MAE sebesar 8,46 dan RMSE sebesar 12,09. Nilai RMSE yang lebih besar dibandingkan MAE menunjukkan adanya beberapa nilai prediksi yang memiliki error cukup tinggi, seperti pada kategori Oli Mesin dan Minyak Rem. Hal ini menunjukkan bahwa meskipun *Decision Tree* mampu menangkap pola dasar permintaan, model ini masih sensitif terhadap variasi data dan cenderung menghasilkan fluktuasi prediksi yang cukup besar pada beberapa jenis suku cadang.

Sementara itu, metode *Gradient Boosting* menunjukkan performa yang lebih baik dengan nilai MAE sebesar 7,63 dan RMSE sebesar 10,50. Nilai error yang lebih kecil ini menunjukkan bahwa *Gradient Boosting* mampu meminimalkan kesalahan prediksi secara lebih efektif dibandingkan Decision Tree. Hal ini sesuai dengan karakteristik *Gradient Boosting* yang membangun model secara bertahap (sequential) dengan memperbaiki kesalahan dari model sebelumnya, sehingga mampu menangkap pola non-linear dan kompleksitas data historis penjualan dengan lebih baik.

Pada metode Ensemble Learning yang menggunakan teknik averaging antara *Decision Tree* dan Gradient Boosting, diperoleh nilai MAE sebesar 8,08 dan RMSE sebesar 11,73. Hasil ini menunjukkan bahwa metode ensemble mampu menghasilkan prediksi yang lebih stabil dibandingkan *Decision Tree*, namun masih sedikit berada di atas performa *Gradient Boosting* secara individu. Hal ini menunjukkan bahwa dalam kasus data Bengkel Auto 252, model *Gradient Boosting* sudah cukup optimal sehingga penggabungan dengan *Decision Tree* tidak secara signifikan meningkatkan akurasi, tetapi tetap memberikan kestabilan prediksi.

Jika dibandingkan secara keseluruhan, metode *Gradient Boosting* merupakan metode dengan performa terbaik karena memiliki nilai MAE dan RMSE paling kecil. Dengan demikian, metode ini lebih direkomendasikan untuk digunakan sebagai dasar pengambilan keputusan dalam menentukan jumlah stok suku cadang pada periode berikutnya.

## BAB V

### PENUTUP

#### 5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan mengenai implementasi metode *Decision Tree*, *Gradient Boosting*, dan *Ensemble Learning* untuk prediksi kebutuhan suku cadang pada Bengkel Auto 252, maka dapat ditarik beberapa kesimpulan sebagai berikut:

1. Metode *Decision Tree* dapat digunakan untuk memprediksi kebutuhan suku cadang berdasarkan data historis penjualan. Hasil evaluasi model menunjukkan nilai Mean Absolute Error (MAE) sebesar 8,63 dan Root Mean Squared Error (RMSE) sebesar 12,20, yang menunjukkan bahwa model mampu menghasilkan prediksi dengan tingkat kesalahan yang masih dapat diterima.
2. Metode *Gradient Boosting* menunjukkan performa prediksi yang lebih baik dibandingkan metode *Decision Tree* karena model dibangun secara bertahap untuk memperbaiki kesalahan prediksi sebelumnya. Berdasarkan hasil evaluasi model diperoleh nilai MAE sebesar 7,63 dan RMSE sebesar 10,50.
3. Metode Ensemble Learning yang menggabungkan hasil prediksi *Decision Tree* dan *Gradient Boosting* mampu menghasilkan prediksi yang lebih stabil. Hasil evaluasi menunjukkan nilai MAE sebesar 8,08 dan RMSE sebesar 11,73. Berdasarkan perbandingan ketiga metode tersebut, *Gradient Boosting* merupakan metode yang paling akurat karena menghasilkan nilai error paling kecil.

## 5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa saran yang dapat dipertimbangkan untuk pengembangan penelitian selanjutnya:

1. Penelitian selanjutnya disarankan menggunakan jumlah data historis yang lebih banyak agar model dapat mempelajari pola permintaan suku cadang secara lebih optimal.
2. Penelitian berikutnya dapat mengembangkan model dengan mencoba algoritma Machine Learning lain seperti Random Forest, XGBoost, atau metode Deep Learning untuk membandingkan tingkat akurasi prediksi.
3. Sistem prediksi yang telah dibangun diharapkan dapat diimplementasikan secara langsung pada sistem manajemen bengkel, sehingga hasil prediksi dapat membantu pemilik bengkel dalam menentukan jumlah stok suku cadang secara lebih tepat.

## DAFTAR PUSTAKA

- Aini, Y. N., Faqih, A., Dwilestari, G., Artikel, S., & Klasifikasi, J. (2025). *Penerapan Metode Decision Tree dalam Penentuan Jurusan Siswa*. *INFORMASI ARTIKEL ABSTRACT KATA KUNCI*, 10.
- B, A., Amrullah, & M.F, A. (2025). *Comparing Linear Regression and Trend Moment with MAPE Optimization for Bitcoin Price Forecasting Accuracy*. 13(6), 4687–4700. <https://doi.org/10.37641/jimkes.v13i6.3968>
- Cavalcanti, J. A., & Fagundes, R. A. de A. (2025). Analysis of Ensembles Applied to Time Series Forecasting of Hydroelectric Dams. In *Proceedings of Brazilian Symposium on Information Systems (SBSI25)* (Vol. 1, Issue 1). Association for Computing Machinery. <https://doi.org/10.5753/sbsi.2025.246412>
- F.X. Wisnu Yudo Untoro. (2025). Resistor Demand Prediction Using Manual Gradient Boosting Implementation for Inventory Optimization. *International Journal of Research in Engineering and Modern Technology (IJREMTE)*, 2(1), 8–15. <https://doi.org/10.30742/ijremte.v2i1.8>
- Ghritlahare, A. (2020). *The Role of Flowcharts in Problem Solving and Process Visualization*. 1–10.
- Haviluddin. (2011). Memahami Penggunaan UML ( Unified Modelling Language ). *Memahami Penggunaan UML (Unified Modelling Language)*, 6(1), 1–15. <https://informatikamulawarman.files.wordpress.com/2011/10/01-jurnal-informatika-mulawarman-feb-2011.pdf>
- Kurniadi, F. I., & Larasati, P. D. (2022). Light Gradient Boosting Machine untuk Deteksi Penyakit Stroke. *Jurnal SISKOM-KB (Sistem Komputer Dan Kecerdasan Buatan)*, 6(1), 67–72. <https://doi.org/10.47970/siskom-kb.v6i1.328>
- Nst, E. N., Nurcahyo, G. W., Informatika, M. T., Begalung, L., & Barat, S. (2025). *Penerapan Machine Learning Menggunakan Algoritma Decision Tree Untuk Prediksi*. 8(2), 428–439.
- Nurul Awal Delly Murti, & Fajri, A. (2024). Perbandingan Penguasaan Bahasa Pemrograman Populer Standar Industri Dunia dan Mahasiswa STMIK Antar Bangsa. *Jurnal Teknik Informatika STMIK Antar Bangsa*, 10(2), 55–59. <https://doi.org/10.51998/jti.v10i2.584>
- Phillips, C., Kemp, E., & Hedderley, D. (2005). *Software Development Methods and Tools: a New Zealand study*. *Australasian Journal of Information Systems*, 12(2), 21–49. <https://doi.org/10.3127/ajis.v12i2.83>
- Rachmawati, O. C. R., Barakbah, A., & Karlita, T. (2024). Programming Language Selection for the Development of Deep Learning Library. *International Journal on Informatics Visualization*, 8(1), 434–441. <https://doi.org/10.62527/joiv.8.1.2437>
- Rais, E. R., Sovia, R., & Carlo, M. (2025). *Analisis Prediksi Penjualan Suku Cadang Motor dengan Metode Monte Carlo*. 8(1). <https://doi.org/10.32877/bt.v8i1.2231>
- Ramdhani, C., & Amrullah. (2026). *Analisis Penerapan Model K-Nearest Neighbors ( KNN ) dalam Machine Learning untuk Menentukan Konsentrasi Program Studi Siswa Kelas 12 di Sekolah SMK Tritech Informatika*.
- Saputra, Y. A., & Mahdiana, D. (2025). *Analisis Penerapan Machine Learning*,

*Deep Learning*, dan *Data Mining dalam Prediksi Penjualan di Industri Otomotif* Magister Ilmu Komputer, Fakultas Teknologi Informasi, Universitas Budi Luhur, Jakarta, Indonesia *Sistem Informasi, Fakultas Teknologi*. 5(6), 1743–1755.

- Suryanto, A., Sevitan Dwiputra, V., Nur Kuncoro, B., Andianingsari, D., & Adi Pratama, S. (2024). Analisis Peramalan Ketersediaan Sparepart Menggunakan Metode Moving Averages Pada PT United Tractors Tbk Jakarta. *IMTechno: Journal of Industrial Management and Technology*, 5(2), 41–46. <https://doi.org/10.31294/imtechno.v5i2.3528>
- Suryati, M., Aldi, T., Saputra, D., & Ikasari, I. H. (2025). Penggunaan Python Dalam Analisis Data Dengan Machine Learning. *Jurnal Riset Informatika Dan Inovasi*, 2(10), 1959–1968. <https://jurnalmahasiswa.com/index.php/jriin>
- Syaban, K. (2025). Evaluasi Model *Ensemble Learning* pada Identifikasi Faktor Risiko Diabetes Mellitus Evaluation of *Ensemble Learning* Models in Identifying Risk Factors for Diabetes Mellitus. *Evaluasi Model Ensemble Learning Models in Identifying Risk Factors for Diabetes Mellitus*, 15(2), 121–130. <https://doi.org/10.34010/jati.v15i2.16238>
- Syahputra Manik, D., & Panjaitan, N. (2025). TALENTA Conference Series: Energy & Engineering Literatur Review: Penggunaan Algoritma Machine Learning untuk Literatur Review: Penggunaan Algoritma Machine Learning untuk Optimalisasi Rantai Pasokan TALENTA Conference Series. *EE Conference Series*, 8(1), 8. <https://doi.org/10.32734/ee.v8i1.2671>
- Syawaludin, A. B. S. W. . (2025). Perbandingan Model *Ensemble Learning* Dalam Memprediksi Harga Sewa Indekos Di Jakarta. *Jurnal Informatika Dan Teknik Elektro Terapan*, 13(3S1). <https://journal.eng.unila.ac.id/index.php/jitet/article/view/7737>
- Untoro, F. X. W. Y. (2025). *Prediksi Permintaan Resistor Menggunakan Implementasi Manual Gradient Boost Untuk Optimasi Inventaris*. 182–191.
- Winurputra, R., & Ratnawati, D. E. (2025). Peramalan Penjualan Produk Menggunakan Extreme *Gradient Boosting* (XGBoost) dan Kerangka Kerja CRISP-DM untuk Pengoptimalan Manajemen Persediaan (Studi Kasus: UB Mart). *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 12(2), 417–428. <https://doi.org/10.25126/jtiik.2025129451>