

**ANALISA DAN IMPLEMENTASI LONG SHORT-TERM
MEMORY (LSTM) DALAM KEBUTUHAN PERSEDIAAN
BARANG DI PT. GUNUNG SARI INDONESIA**

SKRIPSI

DISUSUN OLEH

RICKY ARMANDO SEMBIRING

2109010066



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


MEDAN

2025

LEMBAR PENGESAHAN

Judul Skripsi : ANALISA DAN IMPLEMENTASI LONG SHORT-
TERM MEMORY (LSTM) DALAM KEBUTUHAN
PERSEDIAAN BARANG DI PT. GUNUNG SARI
INDONESIA
Nama Mahasiswa : RICKY ARMANDO SEMBIRING
NPM : 2109010066
Program Studi : SISTEM INFORMASI

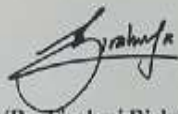
Menyetujui
Komisi Pembimbing

a.n


(Yoshida Sarv, S.E., S.Kom, M.Kom)
NIDN. 0105067603

Ketua Program Studi

Dekan



(Dr. Firahmi Rizky, M.Kom)
NIDN. 0116079201



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

PERNYATAAN ORISINALITAS

ANALISA DAN IMPLEMENTASI LONG SHORT-TERM MEMORY
(LSTM) DALAM KEBUTUHAN PERSEDIAAN BARANG DI PT.
GUNUNG SARI INDONESIA

SKRIPSI

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

Medan, 12 Februari 2025

Yang membuat pernyataan



Ricky Armando Sembiring

2109010066

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

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

Nama : Ricky Armando Sembiring
NPM : 2109010066
Program Studi : Sistem Informasi
Karya Ilmiah : Skripsi

Demi pengembangan ilmu pengetahuan, dengan ini saya menyatakan bahwa Universitas Muhammadiyah Sumatera Utara memiliki Hak Bebas Royalti Noneksklusif (Non-exclusive Royalty-Free Right) atas karya ilmiah saya yang berjudul:

**ANALISA DAN IMPLEMENTASI LONG SHORT-TERM MEMORY
(LSTM) DALAM KEBUTUHAN PERSEDIAAN BARANG DI PT.
GUNUNG SARI INDONESIA**

Beserta perangkat yang ada (jika diperlukan). Dengan hak bebas royalti ini Universitas Muhammadiyah Sumatera Utara dapat menyimpan, mengalih mediakan/mengalih formatkan, mengelola dalam bentuk pangkalan data (database), merawat, dan mempublikasikan disertasi saya tanpa perlu meminta izin dari saya selama tetap mencantumkan identitas saya sebagai penulis dan sebagai pemilik Hak Cipta. Demikian pernyataan ini saya buat dengan sebenarnya.

Medan, 12 Februari 2025

Yang membuat pernyataan



Ricky Armando Sembiring
2109010066

RIWAYAT HIDUP

DATA PRIBADI

Nama Lengkap : Ricky Armando Sembiring
Tempat dan Tanggal Lahir : Medan, 12 Oktober 2002
Alamat Rumah : JL. SEI KERA GG SAUDARA NO 55
Telepon/Faks/HP : 087867000052
E-mail : rickyarmnd@gmail.com
Instansi Tempat Kerja : -
Alamat Kantor : -

DATA PENDIDIKAN

SD : SD SWASTA HUSNI THAMRIN TAMAT: 2014
SMP : SMP SWASTA HUSNI THAMRIN TAMAT: 2017
SMK : SMK NEGERI 1 PERCUT SEI TUAN TAMAT: 2020

KATA PENGANTAR



PENDAHULUAN

Segala puji dan syukur penulis panjatkan kehadirat Allah SWT yang telah memberikan kesempatan, rahmat, dan karunia berupa insan, Islam, kesehatan, kesejahteraan, kemudahan, dan kesabaran kepada penulis sehingga penulis dapat menyelesaikan tesis yang berjudul " ANALISA DAN IMPLEMENTASI LONG SHORT-TERM MEMORY (LSTM) DALAM KEBUTUHAN PERSEDIAAN BARANG DI PT. GUNUNG SARI INDONESIA." Shalawat serta salam tak lupa kami haturkan kepada Nabi Besar Muhammad SAW, yang merupakan Nabi dan Rasul yang diutus oleh Allah SWT. Karena keterbatasan pengalaman dan banyaknya kekurangan, penulis sangat menyadari bahwa karya ini masih jauh dari kesempurnaan dan masih banyak kekurangan. Hal ini dikarenakan keterbatasan kemampuan dan banyaknya kekurangan penulis. Untuk itu penulis mengharapkan kritik dan saran yang bersifat membangun dari semua pihak demi kesempurnaan skripsi ini. Sulit untuk memisahkan dorongan dan bantuan yang saya terima dari berbagai sumber yang telah mendorong dan menginspirasi saya untuk menulis skripsi saya. Oleh karena itu, saya ingin mengucapkan terima kasih yang sebesar-besarnya kepada semua pihak yang telah membantu, terutama

1. Puji syukur yang tulus saya panjatkan kepada Allah SWT atas segala nikmat dan karunia yang telah diberikan kepada saya, baik nikmat keislaman, kemanusiaan, kesehatan, dan kesejahteraan, serta kemudahan, kesabaran, dan kesempatan untuk menyelesaikan

skripsi ini dengan baik. Penulis sadar bahwa Tuhan selalu ada untuk membantu dan membimbingnya dalam perjalanannya. Selain sebagai ungkapan rasa syukur dan ibadah kepada Allah, penulis berharap karya ini dapat memberikan manfaat bagi penulis dan para pembaca. penulis ingin menyampaikan rasa terima kasih yang tak terhingga. Cinta, dukungan, dan doa yang senantiasa mereka berikan telah menjadi pilar kekuatan dan motivasi penulis dalam setiap langkah perjalanan. Semoga kebaikan dan kasih sayang yang diberikan dapat menjadi bekal berharga bagi keluarga ini dalam menghadapi setiap liku hidup. Terima kasih atas kebersamaan, pengorbanan, dan kasih sayang yang tak pernah surut. Semoga Allah SWT senantiasa melimpahkan berkah dan kebahagiaan kepada keduanya. Aamiin.

2. Bapak Prof. Dr. Agussani, M.AP selaku Rektor Universitas Muhammadiyah Sumatera Utara.
3. Bapak Dr. Al-Khowarizmi, S.Kom., M.Kom selaku Dekan Fakultas Ilmu Komputer dan Teknologi Informasi.
4. Ibu Yoshida Sary, S.E., S.Kom, M.Kom selaku Dosen Pembimbing penulis yang sangat berperan dalam membantu penulis menyelesaikan skripsi ini dengan tepat waktu. Keberhasilan penulisan ini tidak bisa dilepaskan dari bimbingan, saran, dan arahan yang mendalam yang diberikan oleh Bapak. Kami sangat berterima kasih atas dedikasi dan waktu yang telah diberikan untuk membimbing penulis. Semoga semua pengetahuan

dan kebaikan yang telah diberikan menjadi amal yang diridhai oleh Allah SWT.

5. Bapak Dr. Lutfi Basit, S.Sos., M.I.Kom selaku Wakil Dekan III Fakultas Ilmu Komputer dan Teknologi Informasi.
6. Bapak Martiano, S.Pd, S.Kom, M.Kom selaku Ketua Program Studi Sistem Informasi Fakultas Ilmu Komputer dan Teknologi Informasi.
7. Kepada PT Gunung Sari Indonesia, penulis mengucapkan terima kasih atas izin yang diberikan untuk melakukan pengumpulan data penelitian.
8. Terakhir, kepada diri sendiri, penulis ingin mengucapkan rasa terima kasih atas ketekunan, kegigihan, dan tekad yang telah diperlihatkan selama proses penyusunan skripsi ini. Kemampuan serta tantangan yang timbul, tanpa pernah menyerah dalam menghadapi kesulitan selama penyusunan skripsi, merupakan hal yang patut disyukuri. Semua usaha dan kerja keras yang telah ditanamkan menjadi pondasi keberhasilan dalam menyelesaikan skripsi ini. Demikianlah penutup kata pengantar ini. Harapannya, Proposal Skripsi ini dapat memberikan sumbangan ilmiah yang bermanfaat bagi siapa pun yang membacanya. Terima kasih atas perhatian dan kesempatan yang diberikan. Semoga karya ini dapat menjadi pijakan awal untuk pengembangan pengetahuan lebih lanjut di bidang yang bersangkutan.

ANALISA DAN IMPLEMENTASI LONG SHORT-TERM MEMORY (LSTM) DALAM KEBUTUHAN PERSEDIAAN BARANG DI PT. GUNUNG SARI INDONESIA

ABSTRAK

PT. Gunung Sari Indonesia menghadapi tantangan dalam menjaga keseimbangan stok agar tidak terjadi kelebihan atau kekurangan persediaan. Penelitian ini bertujuan memprediksi kebutuhan stok menggunakan metode Long Short-Term Memory (LSTM) dan membandingkannya dengan Moving Average (MA). Data penjualan Januari 2023–Desember 2024 dianalisis melalui tahapan preprocessing, pelatihan model, dan evaluasi menggunakan Mean Absolute Deviation (MAD), Mean Squared Error (MSE), dan Mean Absolute Percentage Error (MAPE). Hasil menunjukkan bahwa LSTM lebih akurat menangkap pola fluktuatif dan tren jangka panjang, sedangkan Moving Average lebih sesuai untuk pola penjualan stabil. Pendekatan ini diharapkan membantu perusahaan meningkatkan efisiensi pengelolaan persediaan dan mendukung keputusan berbasis data.

Kata Kunci: LSTM, Moving Average, Prediksi Persediaan, Time Series, Manajemen Stok, PT Gunung Sari

ANALYSIS AND IMPLEMENTATION OF LONG SHORT-TERM MEMORY (LSTM) IN THE NEEDS OF INVENTORY OF GOODS AT PT. GUNUNG SARI INDONESIA

ABSTRACT

PT. Gunung Sari Indonesia faces challenges in maintaining balanced inventory levels to avoid overstocking or shortages. This study aims to predict inventory needs using the Long Short-Term Memory (LSTM) method and compare its performance with the Moving Average (MA) approach. Sales data from January 2023 to December 2024 were analyzed through preprocessing, model training, and evaluation using Mean Absolute Deviation (MAD), Mean Squared Error (MSE), and Mean Absolute Percentage Error (MAPE) metrics. The results show that LSTM provides higher accuracy in capturing fluctuating and long-term patterns, while Moving Average performs better for stable sales trends. This approach is expected to help the company improve inventory management efficiency and support data-driven decision-making.

Keywords: LSTM, Moving Average, Inventory Forecasting, Time Series, Stock Management, PT Gunung Sari

DAFTAR ISI

SKRIPSI	i
LEMBAR PENGESAHAN	Error! Bookmark not defined.
PERNYATAAN ORISINALITAS	Error! Bookmark not defined.
RIWAYAT HIDUP	iv
KATA PENGANTAR	v
ABSTRAK	viii
ABSTRACT	ix
DAFTAR TABEL	xiii
DAFTAR GAMBAR	xiv
BAB I PENDAHULUAN	1
1.1. Latar Belakang Masalah	1
1.2. Rumusan Masalah	3
1.3. Batasan Masalah	3
1.4. Tujuan Penelitian	4
1.5. Manfaat Penelitian	4
BAB II LANDASAN TEORI	6
2.1. Manajemen Persediaan	6
2.1.1. Pengertian Manajemen Persediaan	6
2.1.2. Tujuan Manajemen Persediaan	6
2.2. Time Series	7
2.3. Forecasting	8
2.4. Machine Learning	8
2.5. Artificial Neural Network	10
2.6. Deep Learning	12
2.7. Long Short-Term Memory (LSTM)	13
2.7.1. Pengertian Long Short-Term Memory (LSTM)	13
2.7.2. Arsitektur Long Short-Term Memory (LSTM)	14
2.7.3. Keunggulan Long Short-Term Memory (LSTM)	16
2.8. Moving Average	16
2.9. Analisis Data	17
2.10. Tensorflow	17
2.11. Jupyter Notebook	18

2.12.	Python.....	18
2.13.	Penelitian Terdahulu	19
BAB III METODOLOGI PENELITIAN		22
3.1.	Desain Penelitian	22
3.2.	Dataset.....	23
3.2.1.	Sumber Data.....	25
3.2.2.	Periode Data.....	25
3.3.	Preprocessing Data	25
3.3.1.	Data Cleaning.....	26
3.3.2.	Data Transformation	27
3.3.3.	Data Split.....	28
3.4.	Implementasi Metode	28
3.4.1.	LSTM	28
3.4.2.	Arsitektur Model LSTM.....	29
3.4.3.	Perhitungan Model LSTM	31
3.4.4.	Moving Average.....	36
3.4.5.	Perhitungan Moving Average	36
3.5.	Evaluasi Metode dan Model	37
3.5.1.	Metrik Evaluasi	38
BAB IV HASIL DAN PEMBAHASAAN.....		40
4.1.	Pengolahan Data.....	40
4.1.1.	Deskripsi Dataset	40
4.1.2.	Pembersihan Data.....	41
4.1.3.	Analisis Tren Penjualan	42
4.1.4.	Transformasi Data.....	43
4.2.	Implementasi Model	45
4.2.1.	LSTM	46
4.2.2.	Moving Average	48
4.3.	Proses Pengujian Model LSTM	48
4.3.1.	Model LSTM.....	49
4.3.2.	Pelatihan Model LSTM	50
4.4.	Analisis dan Perbandingan Hasil	53
4.4.1.	Evaluasi Visual	53
4.4.2.	Evaluasi Kuantitatif	56

4.5. Implementasi Prediksi	58
BAB V PENUTUP	61
5.1. Kesimpulan	61
5.2. Saran	62
DAFTAR PUSTAKA	63
LAMPIRAN	68

DAFTAR TABEL

Tabel 2.1	Penelitian Terdahulu	19
Tabel 3.1.	Contoh dataset penjualan/pembelian.....	24
Tabel 3.2.	Ringkasan nilai bobot dan bias	32
Tabel 4.1	Daftar atribut barang	40
Tabel 4.2	Daftar tahapan pra-pemrosesan data	41
Tabel 4.3	Tahapan transformasi data	43
Tabel 4.4	Contoh pembentukan window time series (2 hari)	45
Tabel 4.5	Parameter model LSTM window size 14 dan 30	47
Tabel 4.6	Parameter model LSTM window size 14 dan 30	47
Tabel 4.7	Contoh perhitungan MA 2 hari	48
Tabel 4.8	Parameter setiap model LSTM	49
Tabel 4.9	Metrik evaluasi model LSTM dan MA.....	56

DAFTAR GAMBAR

Gambar 2.1	Kategori Machine Learning	9
Gambar 2.2	Arsitektur Artificial Neural Network	10
Gambar 2.3	Arsitektur Deep Learning	13
Gambar 2.4	Struktur LSTM	14
Gambar 3.1	Diagram aslur Penelitian	23
Gambar 4.1	Tren penjualan barang dari waktu ke waktu	42
Gambar 4.2	Hasil grafik pelatihan nilai loss dan nilai val_loss Model A	51
Gambar 4.3	Hasil grafik pelatihan nilai loss dan nilai val_loss Model B	51
Gambar 4.4	Hasil grafik pelatihan nilai loss dan nilai val_loss Model C	52
Gambar 4.5	hasil prediksi LSTM , MA dan Data Aktual Kode Barang A18232202	54
Gambar 4.6	hasil prediksi LSTM , MA dan Data Aktual kode barang A03012101	54
Gambar 4.7	hasil prediksi LSTM , MA dan Data Aktual kode barang A03012300	55
Gambar 4.8	Hasil prediksi 30 hari kedepan Kode Barang A18232202	59
Gambar 4.9	Hasil prediksi 30 hari kedepan Kode Barang A03012101	59
Gambar 4.10	Hasil prediksi 30 hari kedepan Kode Barang A03012300	60

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Manajemen persediaan barang merupakan salah satu faktor penentu utama dalam kelancaran operasional perusahaan, khususnya bagi perusahaan distribusi seperti PT. Gunung Sari Indonesia. Pengelolaan persediaan barang yang efektif memungkinkan perusahaan untuk menjaga keseimbangan antara kebutuhan persediaan barang dan penjualan barang, yang pada gilirannya dapat meningkatkan efisiensi operasional serta kepuasan pelanggan (Priyandanu et al., 2020).

Namun, dalam praktiknya, perusahaan distribusi sering menghadapi risiko ketidakseimbangan stok. Misalnya, produk A berpotensi mengalami kelebihan stok hingga menimbulkan biaya gudang yang tinggi, sementara produk B justru kekurangan sehingga pesanan pelanggan tertunda. Ketidakpastian ini dapat mengakibatkan kondisi *over-stock* maupun *less-stock*, yang pada akhirnya berdampak pada biaya operasional dan tingkat kepuasan pelanggan (Tamami & Arifin, 2024). Kondisi *over-stock* terjadi ketika persediaan melebihi kebutuhan aktual, sehingga meningkatkan biaya penyimpanan dan berisiko menimbulkan pemborosan. Sebaliknya, *less-stock* terjadi ketika stok tidak mencukupi, sehingga proses penjualan terganggu, pengiriman tertunda, dan pelanggan berpotensi beralih ke kompetitor (Ashari & Sadiki, 2020).

Kasus serupa juga ditemukan pada PT. Tuffindo Nittoku Autoneum, di mana penggunaan metode perhitungan persediaan periodik menimbulkan berbagai masalah, seperti pemasukan barang yang tidak sesuai, kelalaian dalam pencatatan

permintaan, hingga perbedaan antara catatan dengan kondisi sebenarnya di gudang. Hal ini menunjukkan bahwa sistem manual rentan menimbulkan ketidaksesuaian data sehingga dibutuhkan metode prediksi yang lebih akurat dan terstruktur (Priyandanu et al., 2020). Fenomena ini mempertegas bahwa persoalan persediaan tidak hanya dialami oleh perusahaan lain, tetapi juga berpotensi besar terjadi di PT. Gunung Sari Indonesia.

Selain itu, permintaan pelanggan yang berubah setiap hari menuntut perusahaan untuk lebih cermat dalam merancang strategi penjualan. Salah satu langkah penting yang dapat dilakukan manajemen adalah melaksanakan peramalan penjualan guna menyesuaikan persediaan dengan kebutuhan pasar (Amrullah et al., 2020). Namun, hingga saat ini PT. Gunung Sari Indonesia belum memiliki sistem peramalan permintaan yang terstruktur. Pengelolaan persediaan masih dilakukan secara manual dengan mengandalkan intuisi dan pengalaman manajemen. Pendekatan yang subjektif ini membuat perusahaan kesulitan beradaptasi terhadap dinamika permintaan pasar yang semakin kompetitif.

Seiring dengan perkembangan teknologi, metode peramalan berbasis kecerdasan buatan (Artificial Intelligence) mulai banyak digunakan untuk mengatasi keterbatasan metode konvensional. Salah satu metode yang menjanjikan adalah *Long Short-Term Memory* (LSTM), sebuah teknik *deep learning* yang dirancang khusus untuk menganalisis data runtun waktu. *LSTM* memiliki keunggulan signifikan karena mampu mempelajari pola data secara mendalam, menangkap ketergantungan jangka panjang, serta mengidentifikasi fluktuasi musiman yang kompleks (Gunawan et al., 2024).

Penelitian ini menerapkan *LSTM* untuk memprediksi kebutuhan persediaan barang serta membandingkannya dengan metode *Moving Average*. Hasilnya diharapkan menunjukkan efektivitas, kelebihan, dan keterbatasan masing-masing metode. penelitian ini tidak hanya berkontribusi praktis bagi PT. Gunung Sari Indonesia dalam strategi pengadaan, namun sekaligus memberi kontribusi ilmiah pada pengembangan metode peramalan berbasis kecerdasan buatan.

1.2. Rumusan Masalah

- a. Bagaimana penerapan metode Long Short-Term Memory (*LSTM*) dalam meramalkan kebutuhan persediaan barang berdasarkan data historis perusahaan?
- b. Bagaimana penerapan metode *Moving Average* sebagai pendekatan konvensional dalam peramalan kebutuhan persediaan barang?
- c. Bagaimana performa metode *LSTM* dan *Moving Average* dalam memprediksi kebutuhan persediaan barang, serta apa saja kelebihan dan keterbatasannya berdasarkan kondisi data yang tersedia?

1.3. Batasan Masalah

- a. Penelitian ini dilakukan hanya di PT. Gunung Sari Indonesia.
- b. Data yang digunakan dalam penelitian ini berasal dari catatan historis penjualan barang PT. Gunung Sari Indonesia, selama Januari 2023 – Desember 2024

- c. Model yang digunakan dalam penelitian ini adalah *Long Short-Term Memory* (LSTM) sebagai metode utama peramalan persediaan barang.
- d. Untuk keperluan perbandingan, penelitian ini juga menggunakan metode konvensional seperti *Moving Average*, sebagai pembanding
- e. Penelitian ini berfokus pada pengukuran akurasi prediksi dan efektivitas metode

1.4. Tujuan Penelitian

- a. Menerapkan model Long Short-Term Memory (LSTM) untuk meramalkan kebutuhan persediaan barang berdasarkan data historis.
- b. Menerapkan metode *Moving Average* sebagai pendekatan konvensional untuk perbandingan dalam peramalan kebutuhan persediaan barang
- c. Mengevaluasi performa metode LSTM dan *Moving Average* dalam memprediksi kebutuhan persediaan barang, serta mengidentifikasi kelebihan dan keterbatasannya sesuai kondisi data yang tersedia.

1.5. Manfaat Penelitian

- a. Bagi peneliti:
Sebagai pengalaman dalam pengolahan data historis dan penerapan metode *LSTM*, sekaligus memahami keunggulan dan keterbatasannya dibandingkan metode konvensional seperti *Moving Average*.

b. Bagi Akademisi dan Peneliti Lain:

Menjadi referensi untuk penelitian terkait prediksi persediaan barang, khususnya dalam membandingkan efektivitas metode *LSTM* dengan metode peramalan konvensional.

c. Bagi PT. Gunung Sari Indonesia:

Membantu meningkatkan akurasi prediksi persediaan, mengurangi risiko *over-stock* atau *less-stock*, serta mengoptimalkan biaya dan pengambilan keputusan dalam manajemen persediaan.

BAB II

LANDASAN TEORI

2.1. Manajemen Persediaan

2.1.1. Pengertian Manajemen Persediaan

Manajemen persediaan adalah proses yang mencakup perencanaan, pengendalian, dan pengawasan terhadap jumlah serta jenis barang yang dimiliki oleh suatu perusahaan atau organisasi. Persediaan menjadi aset yang krusial karena berperan dalam memastikan kelancaran operasional dan memenuhi kebutuhan pelanggan secara efektif (Priyandanu et al., 2020).

2.1.2. Tujuan Manajemen Persediaan

Pengelolaan persediaan menjadi elemen penting dalam operasional perusahaan karena bertujuan untuk memastikan ketersediaan barang demi mendukung kelancaran distribusi serta memenuhi permintaan pelanggan secara berkelanjutan. Selain itu, pengelolaan yang efektif juga membantu mengoptimalkan biaya operasional dan meminimalkan risiko kekurangan atau kelebihan stok (Rahman Lutfi & Sasongko, 2022). Untuk mencapai tujuan tersebut, manajemen persediaan biasanya difokuskan pada hal-hal berikut:

- a. Meminimalisasi biaya penyimpanan dengan mencegah terjadinya penumpukan stok (over-stock).
- b. Meningkatkan efisiensi pengelolaan persediaan melalui keseimbangan antara permintaan dan ketersediaan barang.
- c. Menghindari kekosongan stok (less-stock) yang dapat menghambat proses pemenuhan kebutuhan pelanggan.

2.2. Time Series

Data deret waktu (*time series*) merupakan sekumpulan observasi yang dicatat secara berurutan berdasarkan waktu dengan interval yang konsisten. Data jenis ini umum dijumpai dalam berbagai aktivitas sehari-hari karena pengumpulannya dilakukan secara berkala, seperti harian, mingguan, maupun bulanan (Mahfud Al et al., 2020). Melalui data tersebut, sering kali muncul pola-pola tertentu. Pola dalam time series umumnya dikategorikan menjadi tiga, yaitu pola tren (*trend*), pola siklis (*cyclical*), dan pola musiman (*seasonal*). Pola musiman ditandai dengan kemunculan pola berulang secara konsisten pada interval waktu tertentu. Dalam konteks analisisnya, data deret waktu dapat diklasifikasikan menjadi dua tipe utama, yaitu *univariate* dan *multivariate*.

- a. *Time series univariate* adalah data deret waktu yang hanya mencakup satu variabel yang diamati secara berkelanjutan dalam periode waktu tertentu.
- b. *Time series multivariate* merupakan data deret waktu yang mencakup lebih dari satu variabel yang diukur secara bersamaan pada setiap titik waktu.

Klasifikasi ini penting untuk menentukan pendekatan analisis yang tepat, karena data multivariate memungkinkan analisis yang lebih kompleks, mencakup keterkaitan antar variabel dalam periode waktu yang sama. Kedua tipe data tersebut mendukung berbagai kebutuhan analisis, seperti peramalan, pemodelan, dan pengambilan keputusan berbasis data deret waktu, misalnya dalam bidang keuangan, cuaca, atau kesehatan (Nur Cahyo & Susanti*, 2023).

2.3. Forecasting

Peramalan (*Forecasting*) merupakan proses memperkirakan, memproyeksikan, atau mengestimasi tingkat kejadian yang belum pasti, sehingga diperlukan waktu untuk menarik suatu kesimpulan mengenai kebutuhan di masa mendatang. Proses ini mencakup perkiraan terhadap jumlah, kualitas, waktu, serta lokasi yang diperlukan guna memenuhi permintaan barang maupun jasa. Selain itu, peramalan juga bertujuan untuk meminimalkan kemungkinan kesalahan data di masa yang akan datang. Dengan kata lain, peramalan atau prediksi adalah suatu pendekatan dalam memperkirakan besaran tertentu, seperti permintaan suatu produk atau beberapa produk pada periode waktu berikutnya (Lubis et al., 2022).

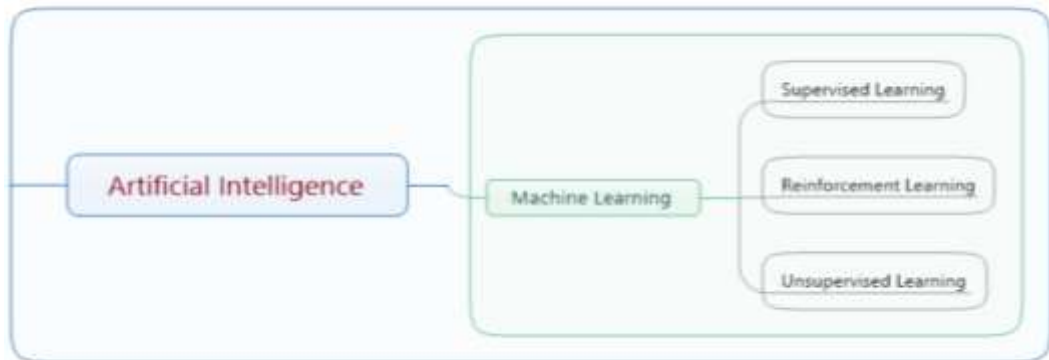
2.4. Machine Learning

Machine Learning (ML) merupakan salah satu penerapan dari *Artificial Intelligence* (AI) yang berfokus pada pengembangan sistem yang mampu belajar secara mandiri tanpa memerlukan pemrograman ulang secara terus-menerus. Dalam prosesnya, ML membutuhkan data pelatihan (*training data*) sebagai bahan pembelajaran sebelum menghasilkan output atau prediksi. Secara umum, *machine learning* dapat diartikan sebagai proses pemrograman komputer untuk mencapai kinerja atau performa tertentu dengan memanfaatkan kumpulan data pelatihan atau pengalaman sebelumnya (*past experience*) (Chazar & Widhiaputra, 2020)

Semakin optimal algoritma *machine learning* yang digunakan, semakin tinggi pula tingkat akurasi dalam pengambilan keputusan atau prediksi yang dihasilkan. *Machine learning* sendiri merupakan cabang dari kecerdasan buatan (*Artificial Intelligence*) yang berfokus pada pengembangan sistem yang dapat

belajar secara otomatis dari data, tanpa perlu instruksi pemrograman manual secara berulang. Melalui proses pembelajaran ini, sistem mampu meningkatkan performanya secara bertahap seiring bertambahnya jumlah data dan pengalaman yang diolah (Faiza et al., 2022).

Secara umum, *machine learning* terbagi ke dalam tiga kategori utama, yaitu:



Gambar 2.1 Kategori Machine Learning

a. *Supervised Learning*

Supervised Learning adalah metode pembelajaran yang menggunakan dataset berlabel. Setiap data pelatihan memiliki *input* dan *output* yang telah ditentukan, sehingga memungkinkan algoritma untuk mempelajari hubungan di antara keduanya. Dengan demikian, model yang dihasilkan dapat melakukan prediksi atau klasifikasi terhadap data baru yang belum pernah dianalisis sebelumnya.

b. *Unsupervised Learning*


Unsupervised Learning merupakan metode pembelajaran yang menggunakan dataset tanpa label. Dalam pendekatan ini, algoritma berusaha secara mandiri untuk menemukan pola, struktur tersembunyi, atau hubungan dalam data tanpa bantuan supervisi

c) *Reinforcement Learning*

Reinforcement Learning adalah metode pembelajaran di mana agen belajar melalui interaksi langsung dengan lingkungan. Agen tersebut melakukan tindakan dan menerima umpan balik berupa penghargaan (reward) atau hukuman (punishment). Berdasarkan umpan balik ini, agen secara bertahap belajar untuk mengambil keputusan terbaik guna mencapai tujuan tertentu.

2.5. **Artificial Neural Network**

Artificial Neural Network (ANN), atau dalam bahasa Indonesia dikenal sebagai Jaringan Syaraf Tiruan (JST), merupakan sistem komputasi yang meniru cara kerja jaringan saraf manusia. Konsep dasar dari jaringan ini dikembangkan dengan mengadaptasi struktur dan fungsi otak manusia sebagai sumber inspirasinya. Jaringan syaraf tiruan mampu menyelesaikan berbagai tugas yang kompleks, seperti mengklasifikasikan data dan mengenali pola. Selain itu, *ANN* juga dapat digunakan untuk melakukan prediksi terhadap berbagai model statistik, serta mampu merepresentasikan data yang bersifat *linier* maupun *non-linier* secara fleksibel (Mahendra et al., 2023).



Gambar 2.2 *Arsitektur Artificial Neural Network*

Dalam pengembangan Jaringan Syaraf Tiruan (JST), terdapat tiga arsitektur dasar yang umum digunakan untuk memproses data dan menghasilkan prediksi atau klasifikasi. Setiap arsitektur ini memiliki struktur dan kompleksitas yang berbeda, bergantung pada kebutuhan dan tujuan penggunaannya (Fadilah et al., 2024).

a. *Single Layer Neural Network*

Single Layer Neural Network adalah bentuk paling sederhana dari jaringan syaraf tiruan. Pada arsitektur ini, hanya terdapat satu lapisan pemrosesan yang secara langsung menghubungkan lapisan input (*input layer*) dengan lapisan output (*output layer*) melalui bobot-bobot tertentu. Model ini menerima data dari input, memprosesnya secara langsung, lalu menghasilkan keluaran. Karena strukturnya yang sederhana, jenis jaringan ini umumnya digunakan untuk menyelesaikan masalah yang linier dan tidak terlalu kompleks, seperti klasifikasi biner sederhana. Diagram dari arsitektur *single layer* ini biasanya menunjukkan hubungan langsung antar *node input* ke *node output* tanpa lapisan tersembunyi.

b. *Multilayer Neural Network*

Multilayer Neural Network atau jaringan syaraf multi-lapisan, memiliki arsitektur yang lebih kompleks dibandingkan *single layer*. Pada jaringan ini, terdapat satu atau lebih *hidden layer* (lapisan tersembunyi) yang terletak di antara input layer dan *output layer*. *Hidden layer* bertugas untuk memproses dan mengekstraksi fitur dari data input sebelum diteruskan ke output layer. Setiap *neuron* di *hidden layer* akan menerima input, melakukan perhitungan berbasis bobot dan fungsi aktivasi

tertentu, lalu meneruskan hasilnya ke lapisan berikutnya. Semakin banyak *hidden layer* yang digunakan, jaringan ini menjadi *deep neural network* (DNN), yang memungkinkan pemrosesan data yang lebih rumit seperti pengenalan gambar, suara, dan prediksi pola *non-linier*

c. *Recurrent Neural Network* (RNN)


Selain arsitektur *single layer* dan *multilayer*, terdapat juga *Recurrent Neural Network* (RNN) yang dirancang khusus untuk memproses data yang bersifat berurutan atau *time series*. Berbeda dari jaringan *feedforward* standar, *RNN* memiliki mekanisme *feedback* di mana output dari satu tahap dapat digunakan kembali sebagai input untuk tahap berikutnya. Ini memungkinkan jaringan untuk "mengingat" informasi sebelumnya dan mempertahankan konteks waktu dalam prediksi atau klasifikasi, sangat bermanfaat dalam pemrosesan bahasa alami (*Natural Language Processing*), prediksi *time series*, serta pengenalan pola data sekuensial lainnya

2.6. Deep Learning

Deep Learning merupakan salah satu metode pembelajaran yang memanfaatkan *Artificial Neural Network* (ANN) dengan arsitektur berlapis-lapis (*multi-layer*). Jaringan saraf tiruan ini dirancang meniru cara kerja otak manusia, di mana *neuron-neuron* saling terhubung membentuk sebuah jaringan yang kompleks. Melalui penerapan berbagai transformasi *non-linear* secara bertahap, *deep learning* mampu melakukan pemrosesan data secara mendalam (Adi Nugroho et al., 2020).

Secara umum, teknologi ini dapat dipandang sebagai integrasi antara teknik *machine learning* dan kecerdasan buatan berbasis jaringan saraf.

Sebagai bagian dari perkembangan *machine learning*, *deep learning* memungkinkan komputer untuk belajar menyelesaikan tugas-tugas yang biasanya dilakukan oleh manusia dengan menggunakan model matematika yang diinspirasi oleh jaringan saraf otak manusia. Hal ini memberikan kemampuan kepada sistem komputer untuk memahami dan menganalisis data secara lebih mendalam, sehingga menghasilkan prediksi atau analisis yang lebih. Jaringan Saraf Tiruan (JST), yang terdiri dari beberapa lapisan tersembunyi, berfungsi mengekstraksi fitur-fitur penting dari data yang besar dan kompleks. Teknologi ini telah banyak diterapkan dalam berbagai bidang, seperti pengenalan gambar, pemrosesan bahasa alami, serta prediksi pola data dalam skala besar (Ardianto & Kartika Wibisono, 2023).



Gambar 2.3 Arsitektur *Deep Learning*

2.7. Long Short-Term Memory (LSTM)

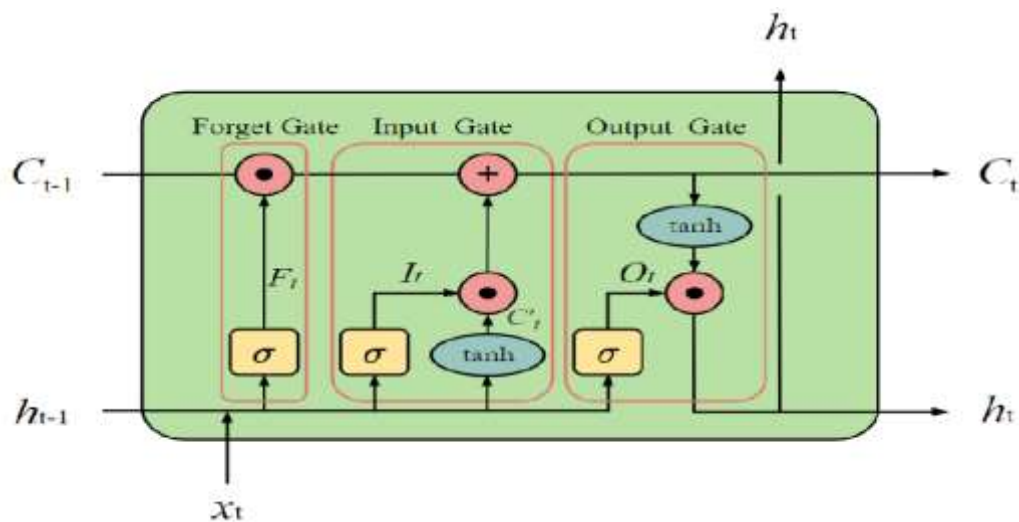
2.7.1. Pengertian Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) adalah suatu pengembangan dari model *Recurrent Neural Network* (RNN) yang diperkenalkan oleh Sepp Hochreiter dan Jürgen Schmidhuber pada tahun 1997. *LSTM* dikembangkan untuk mengatasi

permasalahan vanishing gradient yang kerap muncul pada *RNN*, terutama saat memproses data berurutan dalam rentang waktu yang panjang. Melalui adanya memory cell, *LSTM* mampu mempertahankan informasi lebih lama dan menjaga kestabilan gradien selama proses pelatihan, yang pada akhirnya meningkatkan akurasi dalam analisis data berbasis waktu. Selain itu, arsitektur ini dilengkapi dengan mekanisme gate yang berfungsi untuk mengatur seleksi informasi secara adaptif, sehingga membuat *LSTM* lebih efektif dalam mengenali pola data yang kompleks dan bersifat dinamis (Puteri, 2023).

2.7.2. Arsitektur Long Short-Term Memory (LSTM)

LSTM memiliki struktur utama yang terdiri dari memory cell dan tiga gates utama seperti gambar berikut, yaitu:



Gambar 2.4 Struktur LSTM

- a. *Forget Gate* (f_t) berfungsi untuk menentukan informasi mana yang perlu dihapus dari *cell state*. Nilai ini diperoleh melalui fungsi *sigmoid* yang menerima input dari *hidden state* sebelumnya dan persamaannya sebagai berikut

$$f_t = \sigma(W_{fh} [h_{t-1}], W_{fx} [x_t], b_f) \quad (1)$$

Jika nilai *forget gate* mendekati 0, maka informasi akan dilupakan, sedangkan jika mendekati 1, informasi tetap dipertahankan.

- b. *Input Gate* (i_t) berfungsi mengatur informasi baru yang akan ditambahkan ke *cell state*. Proses ini terdiri dari dua tahap, yaitu menentukan nilai penting melalui fungsi *sigmoid* dan menghasilkan kandidat nilai baru melalui fungsi *tanh*:

$$i_t = \sigma(W_{ih} [h_{t-1}], W_{ix} [x_t], b_i) \quad (2)$$

$$C_t = \tanh(W_{ch} [h_{t-1}], W_{cx} [x_t], b_c) \quad (3)$$

Hasilnya kemudian dikombinasikan dengan nilai *forget gate* untuk memperbarui *cell state*:

$$C_t = f_t * C_{t-1} + i_t * C_t \quad (4)$$

- c. *Output Gate* (O_t) menentukan bagian dari *cell state* yang akan dijadikan keluaran. Proses ini melibatkan fungsi *sigmoid* untuk menentukan bobot keluaran dan fungsi *tanh* untuk menormalisasi nilai:

$$O_t = \sigma(W_{oh} [h_{t-1}], W_{ox} [x_t], b_o) \quad (5)$$

$$h_t = O_t * \tanh(C_t) \quad (6)$$

Hasil *hidden state* digunakan sebagai output dari unit *LSTM* saat ini dan diteruskan ke langkah berikutnya.

2.7.3. Keunggulan Long Short-Term Memory (LSTM)

Dibandingkan dengan *RNN* biasa, *LSTM* memiliki beberapa keunggulan utama, di antaranya:

- a. Mampu menangani dependensi jangka panjang berkat mekanisme *cell state*.
- b. Mengatasi masalah *vanishing gradient* yang sering terjadi pada *RNN* standar.
- c. Cocok untuk data sekuensial, seperti teks, ucapan, dan data deret waktu.

2.8. Moving Average

Metode *Moving Average*, yang juga dikenal sebagai model rata-rata bergerak, merupakan salah satu indikator dalam analisis teknikal yang digunakan untuk menghitung rata-rata dari suatu data dalam rentang waktu tertentu. Setelah proses peramalan dilakukan, tingkat kesalahan atau akurasi prediksi diukur menggunakan metode *Mean Absolute Percentage Error* (MAPE). Menurut Lewis (1982), interpretasi nilai *MAPE* dibagi menjadi empat kategori, yaitu: nilai kurang dari 10% menunjukkan tingkat akurasi yang sangat tinggi, nilai antara 10% hingga 20% termasuk dalam kategori baik, nilai antara 20% hingga 50% dianggap cukup wajar, sedangkan nilai lebih dari 50% dikategorikan sebagai tidak akurat. Dengan demikian, semakin kecil nilai *MAPE* yang dihasilkan, semakin rendah tingkat kesalahan dalam peramalan. Sebaliknya, semakin besar nilai *MAPE*, maka semakin tinggi pula tingkat kesalahan prediksi yang diperoleh (Anjani et al., 2022).

2.9. Analisis Data

Analisis data merupakan suatu proses untuk menelusuri dan menyusun data secara sistematis, yang diperoleh melalui wawancara, catatan lapangan, maupun sumber lainnya, agar lebih mudah dipahami serta disampaikan kepada pihak lain. Kegiatan analisis ini mencakup pengorganisasian data, penguraian menjadi bagian-bagian kecil, melakukan sintesis, menyusun pola, menentukan informasi yang relevan untuk dipelajari, hingga menarik kesimpulan.

Tahapan analisis dimulai dengan melakukan telaah terhadap seluruh data yang telah terkumpul dari berbagai sumber seperti hasil wawancara, dokumen pribadi, dokumen resmi, foto, dan lainnya. Mengingat jumlah data yang cukup banyak, setelah proses penelaahan, langkah selanjutnya adalah reduksi data dengan membuat abstraksi. Abstraksi ini bertujuan untuk merangkum inti informasi, proses, serta pernyataan penting agar tetap terjaga keutuhannya di dalam hasil analisis tersebut (Fadila & Wulandari, 2023).

2.10. Tensorflow

TensorFlow merupakan sebuah *library open-source* yang dikembangkan oleh tim Google Brain untuk kebutuhan komputasi numerik dan machine learning dalam skala besar. Platform ini mendukung berbagai model dan algoritma, termasuk machine learning dan deep learning (jaringan saraf tiruan). *TensorFlow* memanfaatkan bahasa pemrograman *Python* sebagai antarmuka (*API*) untuk membangun berbagai aplikasi, serta memungkinkan eksekusi aplikasi tersebut dengan performa yang tinggi (Muharram et al., 2022). *TensorFlow* mampu digunakan untuk melatih dan menjalankan jaringan saraf tiruan pada berbagai

tugas, seperti klasifikasi tulisan tangan, pengenalan gambar, *word embedding*, *model recurrent neural network*, *model sequence-to-sequence* untuk penerjemahan bahasa, pemrosesan bahasa alami (*NLP*), serta simulasi berbasis Persamaan Diferensial Parsial (*Partial Differential Equation/PDE*)

2.11. Jupyter Notebook

Aplikasi *Jupyter Notebook* adalah sebuah platform analisis data yang dirilis pada tahun 2015 dan kini banyak digunakan oleh para data *scientist* di bidang *big data*. Saat ini, data menjadi elemen penting dalam berbagai sektor, terutama perusahaan yang memanfaatkan data untuk mendukung strategi branding dan pengambilan keputusan penting di masa depan. Nama *Jupyter Notebook* sendiri merupakan akronim dari tiga bahasa pemrograman, yaitu *Julia* (Ju), *Python* (Py), dan R. Aplikasi ini berbasis web, bersifat *open-source* dan gratis, serta memungkinkan pengguna untuk membuat dan berbagi kode, melakukan perhitungan, visualisasi data hasil analisis, serta menyusun narasi komputasi secara interaktif (Asyrofi & Asyrofi, 2023).

2.12. Python

Python adalah salah satu bahasa pemrograman yang populer dan banyak dimanfaatkan oleh perusahaan besar maupun para pengembang untuk membuat berbagai jenis aplikasi, baik berbasis desktop, web, maupun mobile. Bahasa ini diciptakan oleh Guido van Rossum di Belanda pada tahun 1990, dan penamaannya terinspirasi dari acara televisi favoritnya, *Monty Python's Flying Circus*. Awalnya dikembangkan sebagai proyek pribadi atau hobi, Python kemudian berkembang

menjadi bahasa pemrograman yang banyak digunakan di dunia industri dan pendidikan. Hal ini karena Python dikenal sederhana, ringkas, memiliki sintaks yang intuitif, serta didukung oleh pustaka (*library*) yang sangat luas (Romzi & Kurniawan, 2020).

2.13. Penelitian Terdahulu

Penelitian terdahulu berfungsi sebagai landasan dalam memahami perkembangan studi terkait dan membantu dalam mengidentifikasi perbedaan serta kontribusi penelitian yang akan dilakukan. Berikut ini beberapa penelitian yang relevan dengan topik penelitian ini:

Tabel 2.1 Penelitian Terdahulu

No	Penulis	Judul	Tahun	Hasil Penelitian
1	Ashari, M. L., & Sadikin, M.	Prediksi Data Transaksi Penjualan <i>Time Series</i> Menggunakan Regresi <i>LSTM</i>	2020	Penelitian ini menggunakan metode <i>Long Short-Term Memory</i> (<i>LSTM</i>) untuk memprediksi data penjualan di PT. Metiska Farma. Hasilnya, model <i>LSTM</i> menghasilkan nilai <i>Root Mean Squared Error</i> (<i>RMSE</i>) sebesar 286 juta pada data <i>training</i> dan 187 juta pada data <i>testing</i> . Penelitian ini menunjukkan bahwa <i>LSTM</i> dapat digunakan untuk memprediksi data penjualan <i>time series</i> , meskipun akurasi model masih perlu ditingkatkan
2	Gunawan, R., Dimiliu, M. B., Valerine, K., & Tamba, S. P	Analisis Prediksi Penjualan Toko Furnitur dengan Metode <i>Long</i>	2024	Hasil penelitian menunjukkan bahwa <i>LSTM</i> lebih baik dalam memprediksi penjualan dibandingkan metode konvensional seperti <i>Moving Average</i> . Model <i>LSTM</i> mampu

		<i>Short-Term Memory (LSTM).</i>		menangkap pola tren dan fluktuasi pada data penjualan, sehingga menghasilkan prediksi yang lebih akurat dan andal. Berdasarkan evaluasi menggunakan <i>Mean Absolute Percentage Error (MAPE)</i> , <i>LSTM</i> menunjukkan akurasi yang lebih tinggi. Penelitian ini juga merekomendasikan pengoptimalan lebih lanjut pada model <i>LSTM</i> untuk meningkatkan ketepatan peramalan penjualan
3	Lutfi, F. R., & Sasongko, C	Manajemen Persediaan dalam Operasional Bisnis	2022	Hasil penelitian menunjukkan bahwa metode <i>LSTM</i> memiliki kemampuan prediksi penjualan yang lebih baik dibandingkan metode konvensional seperti <i>Moving Average</i> . <i>LSTM</i> mampu mengidentifikasi pola tren dan fluktuasi dalam data penjualan secara lebih akurat, sehingga menghasilkan prediksi yang lebih stabil dan dapat diandalkan. Evaluasi menggunakan <i>Mean Absolute Percentage Error (MAPE)</i> membuktikan bahwa <i>LSTM</i> memiliki tingkat akurasi yang lebih tinggi. Penelitian ini juga merekomendasikan pengembangan lebih lanjut pada model <i>LSTM</i> .
4	Priyandanu, H., Tabrani, M., Suhardi, & Mutaqin, Z	Manajemen Persediaan Bahan Baku Berbasis pada PT. Tuffindo Nittoku Autoneum Karawang	2020	Hasil penelitian menunjukkan bahwa proses manajemen persediaan bahan baku di PT. Tuffindo Nittoku Autoneum Karawang masih dilakukan secara manual, mulai dari pencatatan penerimaan barang hingga pembuatan laporan

				<p>inventarisasi. Kondisi ini menyebabkan adanya ketidakakuratan data dan potensi manipulasi informasi oleh pihak yang tidak bertanggung jawab. Selain itu, penggunaan Microsoft Excel dalam pengelolaan data persediaan meningkatkan risiko terjadinya kesalahan input dan pengolahan data. Penelitian ini merekomendasikan pengembangan sistem informasi manajemen persediaan berbasis komputer untuk meningkatkan efisiensi, akurasi, dan keamanan dalam pengelolaan bahan baku di perusahaan</p>
5	Tamami, G., & Arifin, M	Penggunaan <i>LSTM</i> dalam Membangun Prediksi Penjualan untuk Aplikasi Laptop Lens	2024	<p>Hasil penelitian menunjukkan bahwa metode <i>Long Short-Term Memory</i> (<i>LSTM</i>) berhasil memprediksi tren penjualan laptop e-commerce tahun 2017 berdasarkan tiga kategori harga: <i>low-end</i>, <i>mid-end</i>, dan <i>high-end</i>. Model <i>low-end</i> menghasilkan tingkat loss sebesar 91 unit dengan variasi 82,4%. Kategori <i>mid-end</i> mencatat loss terendah, yaitu 22 unit dengan variasi 98,9%, sedangkan kategori <i>high-end</i> menunjukkan loss sebesar 96 unit dengan variasi 84,3%. Secara keseluruhan, <i>LSTM</i> memberikan prediksi yang akurat untuk semua kategori harga dan dapat mendukung perencanaan stok serta strategi pemasaran perusahaan.</p>

BAB III

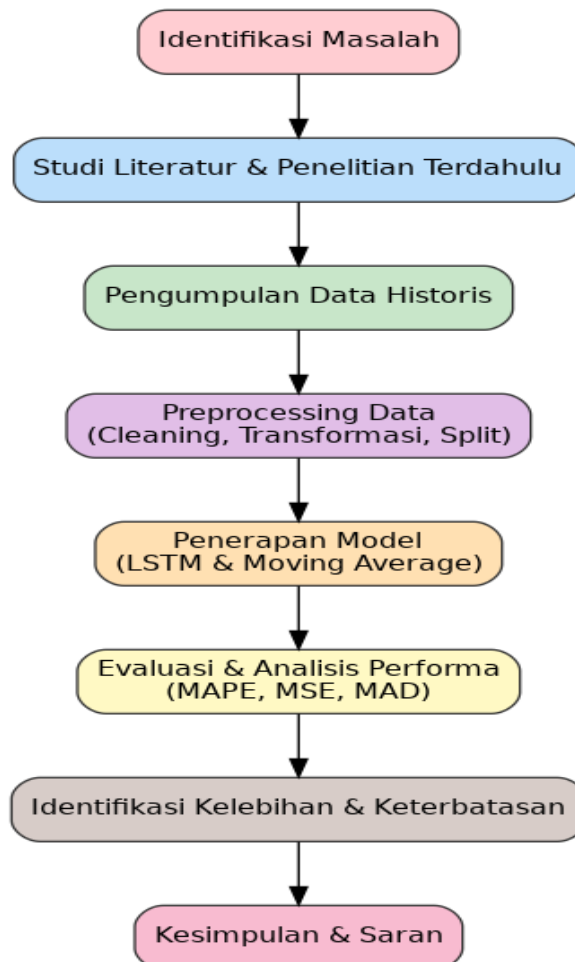
METODOLOGI PENELITIAN

3.1. Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimen. Pendekatan ini dipilih karena penelitian bertujuan untuk mengimplementasikan algoritma *Long Short-Term Memory* (LSTM) dalam memprediksi kebutuhan persediaan barang di PT. Gunung Sari Indonesia serta membandingkan performanya dengan metode *Moving Average*. Melalui desain eksperimen ini, penelitian dapat mengevaluasi secara langsung hasil prediksi dari kedua metode berdasarkan data historis yang tersedia. Dengan pendekatan kuantitatif dan desain eksperimen, penelitian ini berupaya mengukur tingkat akurasi serta efektivitas masing-masing metode secara sistematis melalui analisis numerik. Dengan demikian, hasil yang diperoleh lebih objektif, terukur, dan dapat dijadikan sebagai acuan dalam pengambilan keputusan perusahaan.

Dalam implementasinya, penelitian ini membandingkan dua metode utama. Metode pertama adalah *Long Short-Term Memory* (LSTM), yaitu algoritma berbasis jaringan saraf tiruan yang dikenal efektif dalam mengolah data *time series* atau data dengan pola yang kompleks. Algoritma ini memerlukan proses pengembangan serta pelatihan model menggunakan data historis perusahaan agar mampu mengenali pola-pola tersembunyi di dalamnya. Metode kedua adalah *Moving Average*, yaitu metode prediksi sederhana yang menghasilkan perkiraan berdasarkan rata-rata data historis tanpa proses pelatihan khusus. Pemilihan dua metode dengan tingkat kompleksitas yang berbeda bertujuan untuk mengevaluasi

akurasi, efektivitas, dan efisiensi masing-masing dalam menghasilkan prediksi kebutuhan persediaan barang di Perusahaan.



Gambar 3.1 Diagram aslur Penelitian

3.2. Dataset

Dalam Dalam penelitian ini, *dataset* yang digunakan merupakan data historis persediaan barang dari PT. Gunung Sari Indonesia. *Dataset* tersebut mencatat transaksi penjualan dan pembelian barang selama periode tertentu, yang digunakan sebagai dasar dalam membangun model prediksi.

Dataset yang digunakan mencakup berbagai atribut penting yang merepresentasikan kondisi aktual penjualan dan pembelian. Setiap atribut pada dataset memiliki peran signifikan dalam membantu algoritma machine learning

mengenali pola historis yang dapat dijadikan dasar dalam membuat prediksi ke depannya. Adapun atribut-atribut yang terdapat dalam dataset penjualan barang ini meliputi:

- a. Tanggal : Tanggal transaksi penjualan terjadi.
- b. Nama Barang : Nama barang yang terjual.
- c. Kode Barang : Identitas unik untuk setiap jenis barang.
- d. Harga Satuan : Harga barang per item/pcs
- e. Jumlah : Banyaknya unit barang yang terjual pada tanggal tersebut.
- f. Sub Total : Total nilai transaksi barang dikali harga satuan per item.

Dataset ini digunakan sebagai data pelatihan (*data training*) dalam membangun model prediksi menggunakan algoritma *Long Short-Term Memory* (LSTM) dan metode *Moving Average*. Tujuan dari prediksi ini adalah untuk memperkirakan jumlah barang yang perlu disiapkan pada periode mendatang, sehingga dapat membantu perusahaan dalam mengelola stok secara lebih efisien.

Sebagai gambaran, berikut adalah contoh dataset yang digunakan dalam penelitian ini

Tabel 3.1. Contoh dataset penjualan/pembelian

Tanggal	Nama Barang	Kode Barang	Harga Satuan	Jumlah	Sub total
2023-01-01	BARANG A	A0001	10.000,00	10,00	100.000,00
2023-01-02	BARANG B	A0002	15.000,00	2,00	30.000,00
2023-01-03	BARANG A	A0001	10.000,00	5,00	50.000,00
...
2023-12-30	BARANG C	A0003	25.000,00	7,00	175.000,00
2023-12-31	BARANG B	A0002	15.000,00	20,00	300.000,00

3.2.1. Sumber Data

Dataset yang digunakan dalam penelitian ini diperoleh dari sistem pencatatan persediaan barang di PT. Gunung Sari Indonesia. Data ini dikumpulkan secara sistematis dari berbagai sumber internal perusahaan yang mencatat transaksi keluar-masuk barang dalam operasional sehari-hari. Yang terdiri dari:

- a. Sistem Penjualan
 1. Mencatat seluruh transaksi penjualan barang ke pelanggan
 2. Memuat informasi mengenai tanggal penjualan, jumlah barang terjual dan harga penjualan barang

3.2.2. Periode Data

Dataset dalam penelitian ini mencakup periode Januari 2023 – Desember 2024, yang memungkinkan analisis terhadap:

- a. Pola penjualan barang berdasarkan riwayat transaksi dengan pelanggan.
- b. Fluktuasi permintaan atau penjualan barang ke pelanggan dalam periode tertentu.

Dengan cakupan data yang menyeluruh, penelitian dapat menghasilkan prediksi yang lebih akurat untuk membantu PT. Gunung Sari Indonesia meningkatkan efisiensi pengelolaan persediaan, mengurangi risiko kekurangan atau kelebihan stok, serta mendukung keputusan strategis dalam perencanaan bisnis.

3.3. Preprocessing Data

Sebelum *dataset* digunakan dalam proses analisis dan pelatihan model prediksi, diperlukan tahapan *preprocessing* untuk memastikan bahwa data yang

digunakan bersih, terstruktur, dan siap untuk diproses oleh algoritma *Long Short-Term Memory* (LSTM) dan *Moving Average*. *Preprocessing* ini bertujuan untuk meningkatkan kualitas data serta meminimalkan kesalahan dalam prediksi, sehingga model dapat bekerja lebih optimal dalam mengekstraksi pola dari data. Tahapan *preprocessing* meliputi pembersihan data, normalisasi, dan penghapusan data yang tidak relevan guna meningkatkan akurasi dan efektivitas *model machine learning* (Hakim, 2021). Proses ini memastikan data yang digunakan telah siap untuk dianalisis dan diolah oleh algoritma secara optimal.

3.3.1. Data Cleaning

Tahap ini bertujuan untuk membersihkan *dataset* dari kesalahan, ketidak-konsistenan, atau data yang tidak lengkap agar analisis lebih akurat dan hasil prediksi lebih optimal. Dengan memastikan bahwa data yang digunakan bersih dan valid, proses pemodelan dapat berjalan lebih efektif dan menghasilkan estimasi yang lebih dapat diandalkan (Maharana et al., 2022). Beberapa langkah yang dilakukan meliputi

a. Menghapus data yang tidak lengkap

Jika ada transaksi yang tidak memiliki informasi penting seperti tanggal, jumlah stok, atau jumlah penjualan, data tersebut akan dihapus atau diperbaiki.

b. Menyesuaikan data yang tidak wajar

Jika terdapat kesalahan pencatatan, seperti jumlah barang yang terlalu tinggi atau terlalu rendah dibandingkan pola normal, data tersebut akan diperiksa dan disesuaikan agar tetap sesuai dengan kondisi sebenarnya

c. Menghilangkan data ganda

Jika ada transaksi yang tercatat lebih dari satu kali, data duplikat akan dihapus agar tidak menyebabkan bias dalam analisis

3.3.2. Data Transformation

Tahap ini bertujuan untuk mengubah representasi data agar sesuai dengan kebutuhan metode dan lebih mudah diproses oleh model prediksi, sehingga analisis dapat dilakukan dengan lebih akurat dan. Penyesuaian ini memastikan bahwa data memiliki format yang seragam dan memenuhi asumsi analisis yang digunakan dalam pembuatan model prediksi (Gori et al., 2024). Proses transformasi ini melibatkan beberapa langkah, antara lain:

a. Menyesuaikan Format Tanggal

Memastikan semua tanggal transaksi dicatat dalam format yang seragam agar dapat diurutkan dengan benar dalam analisis time series. Hal ini penting untuk mencegah kesalahan dalam pemrosesan data berbasis waktu.

b. Mengubah data kategorikal menjadi angka

Data kategorikal, seperti kode barang atau kategori produk, diubah menjadi data numerik menggunakan metode seperti *Label Encoding*. Dengan pendekatan ini, setiap kategori akan diberikan label atau kode numerik yang memungkinkan data tersebut diproses lebih efektif oleh algoritma prediksi yang membutuhkan input dalam bentuk angka.

3.3.3. Data Split

Tahap ini membagi dataset menjadi data latih dan data uji menggunakan metode *Holdout*. Sebagian besar data (contoh: 80%) digunakan untuk melatih model, sementara sisanya (20%) digunakan untuk menguji akurasi model. Data latih digunakan untuk membangun model, sedangkan data uji mengevaluasi kinerja model terhadap data yang belum pernah dilihat sebelumnya. Jika data bersifat *time series*, pembagian dilakukan secara berurutan untuk menjaga kronologi data.

Proses ini bertujuan untuk mencegah *overfitting* dan memastikan metode dapat melakukan prediksi secara akurat pada data baru. Serta mengurangi kesalahan prediksi (Oktafiani et al., 2023).

3.4. Implementasi Metode

Pada penelitian ini, digunakan dua pendekatan utama dalam melakukan prediksi kebutuhan persediaan barang, yaitu *Long Short-Term Memory (LSTM)* dan *Moving Average*. *LSTM* adalah model berbasis jaringan saraf tiruan yang dirancang untuk menangani data *time series*, sementara *Moving Average* adalah metode statistik sederhana yang menghitung rata-rata nilai historis untuk memprediksi tren masa depan. Implementasi kedua metode ini dilakukan dengan tahapan yang berbeda sesuai dengan karakteristik masing-masing

3.4.1. LSTM

Metode *Long Short-Term Memory (LSTM)* diterapkan dalam penelitian ini untuk memprediksi kebutuhan stok barang dengan pendekatan berbasis *deep*

learning. *LSTM* merupakan salah satu jenis jaringan saraf tiruan yang dirancang khusus untuk menangani data *time series*, di mana informasi masa lalu memiliki pengaruh terhadap prediksi masa depan.

Model ini dipilih karena kemampuannya dalam mengenali pola dalam data historis serta mempertimbangkan dependensi waktu dalam urutan data. Berbeda dengan metode prediksi konvensional, *LSTM* memiliki memori jangka panjang yang memungkinkan model untuk menyimpan dan mengingat informasi penting dari periode sebelumnya, sekaligus mengabaikan informasi yang kurang relevan.

Hal ini membuat *LSTM* sangat efektif dalam menangani permasalahan yang melibatkan data berurutan, seperti peramalan permintaan stok barang. Dengan kemampuan tersebut, diharapkan prediksi yang dihasilkan lebih akurat dan mendukung pengambilan keputusan yang lebih tepat dalam manajemen persediaan.

3.4.2. Arsitektur Model LSTM

Model *LSTM* yang digunakan dalam penelitian ini dibangun dengan beberapa lapisan utama untuk menangani data *time series* secara efektif dan menghasilkan prediksi kebutuhan stok barang yang akurat. Struktur model terdiri atas

a. Input Layer

Lapisan ini berfungsi sebagai pintu masuk data ke dalam model. Data historis stok barang yang telah melalui tahap preprocessing digunakan sebagai input dalam bentuk *time series*. Input ini mencakup beberapa fitur penting, seperti:

1. Tanggal transaksi

2. Kode Barang
3. Jumlah stok barang
4. Jumlah permintaan pelanggan

b. *LSTM Layer*

Merupakan inti dari model, lapisan *LSTM* dirancang untuk menangkap pola dalam data time series dengan menyimpan informasi penting dari waktu sebelumnya dan mengabaikan informasi yang tidak relevan. Proses ini dikendalikan oleh mekanisme *gates*, yaitu

1. *Forget Gate*: Menentukan informasi mana yang harus dihapus dari memori.
2. *Input Gate*: Memilih informasi baru yang akan disimpan dalam memori.
3. *Output Gate*: Menghasilkan nilai output berdasarkan informasi yang telah diproses

c. *Dense Layer*

Setelah melalui lapisan *LSTM*, data diteruskan ke *Dense Layer* yang berfungsi mengubah keluaran dari *LSTM* ke dalam format yang dapat diinterpretasikan sebagai prediksi akhir. Pada lapisan ini, digunakan fungsi aktivasi seperti *ReLU* atau *Linear Activation* untuk mengkonversi hasil pemrosesan ke dalam nilai numerik yang sesuai dengan kebutuhan prediksi

d. *Output Layer*

Sebagai tahap akhir, setelah melewati *Dense Layer*, data diproses pada lapisan terakhir, yaitu *Output Layer*. Lapisan ini menghasilkan prediksi

akhir berupa nilai numerik yang merepresentasikan estimasi jumlah stok barang untuk periode berikutnya.

3.4.3. Perhitungan Model LSTM

Agar lebih mudah dipahami, penelitian ini menyajikan contoh ilustrasi perhitungan sederhana. Pada ilustrasi ini, digunakan data input, *hidden state*, serta *cell state* dengan nilai 0 sebagai nilai awal. Untuk inisialisasi parameter, penelitian ini membedakan antara bobot (*weight*) dan bias. Inisialisasi bobot dilakukan dengan menggunakan metode *Xavier-Glorot* yang dirancang untuk menjaga kestabilan (Datta, 2020). Dengan metode ini, setiap elemen bobot pada kernel input-ke-gerbang maupun hidden-ke-gerbang diambil dari distribusi seragam dalam rentang yang menggunakan rumus:

$$\mathcal{W} \sim U \left(-\sqrt{\frac{6}{N_i + N_o}}, \sqrt{\frac{6}{N_i + N_o}} \right) \quad (7)$$

Dimana :

$\mathcal{W} - U$ = bobot

N_i = unit masukan

N_o = unit keluaran

Salah satu model yang digunakan dalam penelitian ini terdiri dari satu lapisan *LSTM* dengan jumlah unit tersembunyi (*hidden units*) sebanyak 16 Unit dan satu fitur input pada setiap langkah waktu. Lapisan *LSTM* ini kemudian diikuti oleh lapisan *Dense* dengan satu neuron keluaran untuk menghasilkan nilai prediksi. Sehingga angka yang akan di gunakan untuk melakukan penentuan bobot adalah sebagai berikut

No (*Hidden Unit*) = 16

Ni (Fitur Input pada Setiap Langkah) = 1

Kemudian perhitungan di lanjutkan menggunakan persamaan (7) untuk penentuan bobot. Sehingga menjadi

$$w \sim U\left(-\sqrt{\frac{6}{1+16}}, \sqrt{\frac{6}{1+16}}\right)$$

$$w \sim U\left(-\sqrt{\frac{6}{17}}, \sqrt{\frac{6}{17}}\right)$$

$$w \sim U\left(-\sqrt{0,3529}, \sqrt{0,3529}\right)$$

$$w \sim U(-0,5941, 0,5941)$$

Dengan demikian, untuk keperluan ilustrasi perhitungan, semua bobot pada gerbang *LSTM* diambil secara acak dari rentang ini (-0,5941, 0,5941). Rentang tersebut dipilih agar nilai bobot tidak terlalu besar maupun terlalu kecil pada awal pelatihan, sehingga proses pembelajaran dapat berlangsung lebih stabil. Sementara itu, seluruh bias pada masing-masing gerbang diinisialisasi dengan nilai nol (0). Seluruh ringkasan nilai bobot random dan bias dapat di lihat pada table 3.2 berikut

Tabel 3.2. Ringkasan nilai bobot dan bias

Keterangan	Rentang	Nilai
Wfh	(-0,5941, 0,5941).	0,12
Wfx	(-0,5941, 0,5941).	0,24
Wih	(-0,5941, 0,5941).	0,25
Wix	(-0,5941, 0,5941).	0,5
Wch	(-0,5941, 0,5941).	0,3

Keterangan	Rentang	Nilai
Wcx	(-0,5941, 0,5941).	0,4
Woh	(-0,5941, 0,5941).	0,1
Wox	(-0,5941, 0,5941).	0,2
bf	-	0
bc	-	0
bi	-	0
bo	-	0

Selanjutnya dilakukan perhitungan menggunakan dataset dengan window size 14 hari untuk memprediksi nilai jumlah pada hari ke – 15

Diketahui:

Data = [2, 13, 1, 6, 4, 7, 2, 21, 0, 0, 2, 3, 5, 7]

$H_t_{prev} = 0$

$C_t_{Prev} = 0$

Selanjutnya dilakukan perhitungan dengan metode LSTM, proses perhitungan untuk setiap *gate* dan sel memori dilakukan sebagai berikut

a. Perhitungan *Forget Gate*

Perhitungan dilakukan menggunakan persamaan rumus

$$\text{Forget Gate: } ft = \sigma(Wfh [ht-1], Wfx [xt] + bf)$$

$$Ft = \sigma(0,12 \times 0 + 0,24 \times \text{avg}([2,13,1\dots 5,7]) + 0)$$

$$= \sigma(0 + 0,24 \times 5,21 + 0) = \sigma(1.2514)$$

Kemudian dilanjutkan dengan fungsi aktivasi *sigmoid* dengan rumus

$$\sigma = \frac{1}{1 + e^{-x}} \quad (8)$$

Setelah di hitung menggunakan persamaan (8) hasilnya akan menjadi

$$F_t = \sigma = 0.778$$

b. Perhitungan *Input Gate*

Perhitungan dilakukan menggunakan persamaan rumus

$$\text{Input Gate: } i_t = \sigma(W_{ih} [h_{t-1}], W_{ix} [x_t], b_i)$$

$$\begin{aligned} I_t &= \sigma(0,25 \times 0 + 0,5 \times \text{avg}([2,13,1\dots5,7]) + 0) \\ &= \sigma(0+2,607+0) = \sigma(2,607) \end{aligned}$$

Kemudian dilanjutkan dengan fungsi aktivasi *sigmoid* dengan rumus persamaan (8) sehingga hasilnya menjadi

$$I_t = \sigma = 0,931$$

c. Perhitungan *Cell State Candidate*

Perhitungan dilakukan menggunakan persamaan rumus

$$\text{Cell State Candidate: } C_t = \tanh(W_{ch} [h_{t-1}], W_{cx} [x_t], b_c)$$

$$\begin{aligned} C_t &= \tanh(0,3 \times 0 + 0,4 \times \text{avg}([2,13,1\dots5,7]) + 0) \\ C_t &= \tanh(0 + 2.08571428 + 0) = \tanh(2.08571428) \end{aligned}$$

Kemudian dilanjutkan dengan fungsi aktivasi *sigmoid* dengan rumus

Persamaan (9) hasilnya menjadi

$$\tanh = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (9)$$

$$C_t = 0,970$$

d. Perhitungan *New Cell State*

Perhitungan dilakukan menggunakan rumus

$$\text{New Cell State: } C_t = f_t * C_{t-1} + i_t * C_t$$

$$C_t = 0,778 \times 0 + 0,931 \times 0,970$$

$$C_t = 0,903$$

e. Perhitungan *Output Gate*

Perhitungan dilakukan menggunakan rumus

$$\text{Output Gate: } O_t = \sigma(W_{oh} [h_{t-1}], W_{ox} [x_t], b_o)$$

$$O_t = \sigma(0,1 \times 0 + 0,2 \times \text{avg}([2,13,1\dots5,7]) + 0)$$

$$O_t = \sigma(0 + 1.04285714 + 0)$$

$$O_t = \sigma(1,0428)$$

Kemudian dihitung menggunakan rumus *sigmoid* hasilnya menjadi

$$O_t = 0,739$$

f. Perhitungan *New Hidden State*

Perhitungan dilakukan menggunakan rumus

$$\text{New Hidden State : } h_t = O_t * \tanh(C_t)$$

$$H_t = 0,739 \times \tanh(0,903)$$

$$H_t = 0,739 \times 0,718$$

$$H_t = 0,530$$

Hasil perhitungan hidden state yang diperoleh dari mekanisme *LSTM* kemudian digunakan sebagai dasar untuk menghasilkan nilai prediksi. Proses ini dilakukan melalui lapisan *dense (fully connected layer)* yang mengubah representasi internal (h_t) menjadi keluaran numerik. Secara matematis, prediksi dirumuskan sebagai berikut :

$$y_t = w_y \cdot h_t + b_y \quad (10)$$

di mana W_y adalah bobot dan B_y adalah bias yang ditentukan melalui proses pelatihan model. Rumus ini umum digunakan dalam implementasi LSTM modern,

bahwa prediksi diperoleh dari kombinasi linear antara *hidden state* dengan parameter lapisan keluaran (Masih, 2024).

3.4.4. Moving Average

Metode *Moving Average* diterapkan dalam penelitian ini sebagai pendekatan sederhana untuk memprediksi kebutuhan persediaan barang berdasarkan nilai rata-rata dari periode sebelumnya. *Moving Average* sering digunakan dalam analisis *time series* karena mampu menghaluskan fluktuasi data serta mengidentifikasi tren secara lebih jelas tanpa perlu pelatihan model yang kompleks seperti *LSTM*. Selain itu, metode ini mudah diimplementasikan dan efisien secara komputasi, sehingga cocok digunakan untuk dataset dengan volume data yang tidak terlalu besar (Huriati et al., 2022).

3.4.5. Perhitungan Moving Average

Moving Average bekerja dengan menghitung rata-rata dari sejumlah data historis sebelumnya untuk memperkirakan nilai pada periode selanjutnya. Semakin banyak periode yang digunakan dalam perhitungan rata-rata, semakin halus hasil prediksi yang diperoleh, meskipun respons terhadap perubahan tren menjadi lebih lambat. Perhitungan *Moving Average* dalam penelitian ini menggunakan rumus berikut :

$$MA_t = \frac{X_{t-1} + X_{t-2} + \dots + X_{t-n}}{n} \quad (11)$$

Di mana:

MA_t = Nilai *Moving Average* pada waktu t

$X_{t-1} + X_{t-2} + \dots + X_{t-n}$ = Nilai aktual stok barang dalam n periode sebelumnya

n = Jumlah periode yang digunakan dalam perhitungan rata-rata

Jika n lebih kecil, maka metode *Moving Average* menjadi lebih sensitif dalam merespons perubahan stok yang terjadi pada setiap periode, sehingga dapat dengan cepat menangkap adanya pergeseran atau anomali data. Namun, hal ini juga menyebabkan metode tersebut lebih rentan terhadap fluktuasi yang tidak teratur atau *noise*, yang dapat menghasilkan prediksi yang kurang stabil. Sebaliknya, jika n lebih besar, prediksi yang dihasilkan cenderung lebih stabil dan halus karena mengurangi pengaruh fluktuasi data jangka pendek, tetapi respons model menjadi lebih lambat dalam menyesuaikan diri terhadap perubahan tren baru yang muncul dalam data (Agung Permana & Sahara, 2024).

3.5. Evaluasi Metode dan Model

Setelah metode LSTM dan *Moving Average* diterapkan, langkah selanjutnya adalah mengevaluasi kinerjanya dalam memprediksi kebutuhan stok barang. Evaluasi ini bertujuan untuk mengetahui tingkat akurasi prediksi yang dihasilkan kedua metode, sekaligus mengidentifikasi metode yang lebih optimal dan konsisten dalam mendukung pengambilan keputusan manajemen persediaan di PT. Gunung Sari Indonesia.

Evaluasi dilakukan menggunakan beberapa metrik kesalahan yang umum dipakai dalam prediksi data *time series*, yaitu Mean Absolute Deviation (MAD), Mean Squared Error (MSE), dan Mean Absolute Percent Error (MAPE). Hasil evaluasi ini kemudian dianalisis untuk memahami kelebihan dan kekurangan masing-masing metode dalam memprediksi stok barang, sekaligus menilai tingkat akurasi serta konsistensi model dalam berbagai kondisi data. (Sefry et al., 2024).

3.5.1. Metrik Evaluasi

Untuk mengukur keakuratan prediksi, digunakan beberapa metrik evaluasi yang membandingkan hasil prediksi dengan data aktual. Metrik yang digunakan dalam penelitian ini adalah (Sefry et al., 2024).

a. *Mean Absolute Deviation* (MAD)

Mengukur rata-rata selisih absolut antara nilai prediksi dan nilai aktual. *MAD* menunjukkan seberapa besar kesalahan prediksi secara umum, tanpa memperhitungkan apakah prediksi lebih tinggi atau lebih rendah dari nilai aktual. Metrik ini memberikan gambaran langsung mengenai tingkat kesalahan rata-rata, di mana semakin kecil nilai *MAD*, semakin akurat prediksi yang dihasilkan.

$$MAE = \frac{\sum | \text{Aktual} - \text{Prediksi} |}{n} \quad (12)$$

Di mana:

n = adalah jumlah data

b. *Mean Squared Error* (MSE)

Mengukur rata-rata selisih kuadrat antara nilai prediksi dan nilai aktual. *MSE* memberikan penalti lebih besar pada kesalahan yang besar, sehingga lebih sensitif terhadap outlier dalam dataset.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (13)$$

Di mana:

Y_i = adalah nilai aktual stok barang

Y_i = adalah nilai peramalan persediaan stok barang

n = adalah jumlah data

c. *Mean Absolute Percent Error* (MAPE)

Menunjukkan perbedaan rata-rata absolut antara nilai prediksi dan nilai aktual, yang dinyatakan sebagai persentase dari nilai aktual. *MAPE* dapat dihitung dengan rumus sebagai berikut

$$MAPE = \frac{\sum \frac{|Aktual - permalan|}{Aktual} \times 100 \%}{n} \quad (14)$$

Di mana:

n = adalah jumlah data

MAPE yang lebih kecil menunjukkan bahwa metode memiliki tingkat kesalahan yang rendah dalam prediksi.

BAB IV

HASIL DAN PEMBAHASAAN

4.1. Pengolahan Data

Langkah pertama dalam penelitian ini adalah melakukan proses penggabungan data yang berasal dari periode 1 Januari 2023 hingga 31 Desember 2024. Proses ini bertujuan untuk membentuk satu himpunan data (dataset) yang utuh dan representatif, sehingga dapat digunakan sebagai dasar yang valid dalam melakukan analisis terhadap tren, pola, atau fenomena yang terjadi sepanjang periode tersebut.

4.1.1. Deskripsi Dataset

Dataset penelitian ini terdiri dari tiga kode barang, yaitu A03012101, A03012300, dan A18232202. Setiap data transaksi memiliki beberapa atribut yang dijelaskan pada Tabel 4.1

Tabel 4.1 Daftar atribut barang

Atribut	Keterangan
Kode Barang	Identitas unik tiap barang
Tanggal	Tanggal transaksi penjualan
Jumlah	Banyaknya jumlah unit terjual

Dataset ini berfungsi sebagai dasar bagi proses pra-pemrosesan, transformasi, serta pembentukan model prediksi. Dengan adanya atribut kode barang, transaksi dapat dipisahkan berdasarkan jenis produk; atribut tanggal

digunakan untuk menyusun data dalam bentuk deret waktu (*time series*), sedangkan atribut jumlah merepresentasikan volume penjualan yang menjadi target prediksi.

4.1.2. Pembersihan Data

Pada tahap ini, dilakukan proses pengelompokan dan penggabungan data untuk menyiapkan data mentah menjadi bentuk yang siap digunakan dalam proses analisis. Tujuannya adalah untuk merapikan struktur data dan memastikan setiap transaksi tercatat secara ringkas dan terkelompok dengan baik. Beberapa langkah yang dilakukan dapat dilihat pada table 4.2

Tabel 4.2 Daftar tahapan pra-pemrosesan data

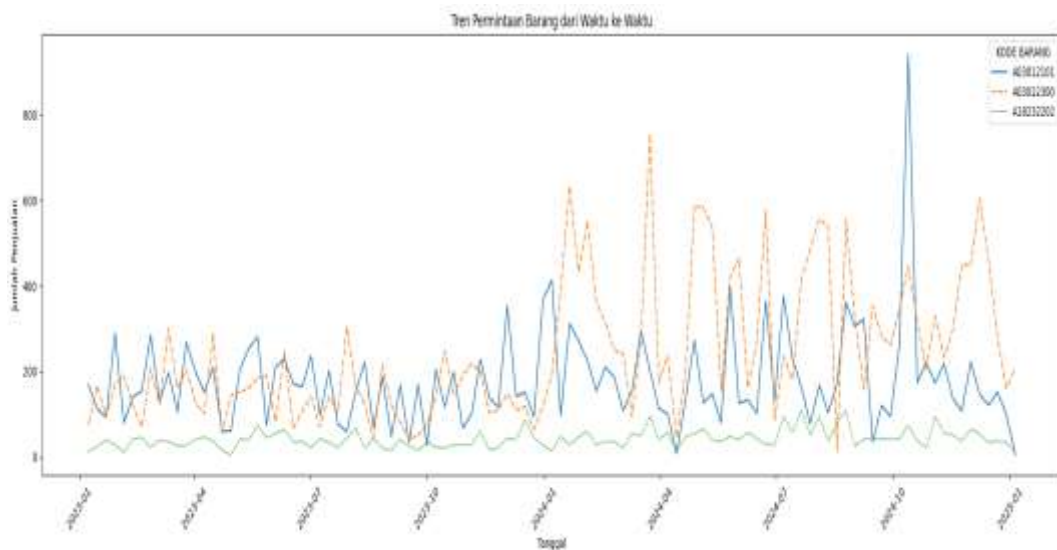
Tahapan	Keterangan
Pengelompokan Data	Data dikelompokkan berdasarkan kode barang agar analisis dilakukan per barang.
Penggabungan Transaksi	Transaksi harian untuk barang yang sama dijumlahkan sehingga diperoleh total penjualan harian.
Pengisian Nilai Kosong	Jika pada suatu tanggal tidak ada transaksi, nilai Jumlah = 0 untuk menjaga konsistensi deret waktu
Penyusunan Ulang Data	Dataset diurutkan berdasarkan tanggal agar sesuai dengan format deret waktu.

Melalui tahapan pra-pemrosesan, dataset menjadi lebih terstruktur dan siap digunakan pada tahap transformasi. Pengelompokan membuat analisis per barang lebih jelas, penggabungan menyederhanakan data harian, pengisian nilai kosong

menjaga konsistensi deret waktu, dan penyusunan ulang memastikan urutan kronologis tetap terjaga.

4.1.3. Analisis Tren Penjualan

Untuk memahami pola dasar dari data penjualan, langkah awal dilakukan eksplorasi dalam bentuk visualisasi grafik. Grafik tren penjualan harian dari Januari 2023 hingga Desember 2024 ditampilkan secara terpisah untuk setiap kode barang. Melalui visualisasi ini dapat diamati pola fluktuasi penjualan, periode dengan tingkat kestabilan, serta indikasi adanya kecenderungan musiman pada barang tertentu. Hasil visualisasi tren penjualan tersebut disajikan pada gambar 4.1.



Gambar 4.1 Tren penjualan barang dari waktu ke waktu

Terlihat pada Gambar 4.1, tren penjualan ketiga kode barang (A03012101, A03012300, dan A18232202) memperlihatkan pola fluktuasi yang berbeda sepanjang periode Januari 2023 hingga Desember 2024. Barang A03012101 (garis biru) menunjukkan pola penjualan dengan fluktuasi sedang, ditandai dengan naik-turun yang cukup teratur, namun tetap berada pada rentang nilai yang tidak terlalu

ekstrem. Barang A03012300 (garis oranye putus-putus) memiliki pola paling fluktuatif, dengan lonjakan permintaan yang tajam pada beberapa periode, bahkan mencapai lebih dari 700 unit. Hal ini menunjukkan bahwa barang ini lebih dipengaruhi oleh faktor musiman atau permintaan tidak teratur. Sebaliknya, barang A18232202 (garis hijau titik-titik) relatif stabil, dengan volume penjualan yang konsisten rendah dan variasi kecil, umumnya berada di bawah 100 unit per periode

4.1.4. Transformasi Data

Setelah melalui tahap pembersihan, data perlu ditransformasikan agar sesuai dengan kebutuhan model *LSTM*. Proses transformasi ini bertujuan untuk mengubah data mentah menjadi bentuk yang dapat diolah oleh model, khususnya dalam format deret waktu (*time series*) sehingga pola, tren, maupun fluktuasi yang ada pada data dapat dipelajari dengan lebih efektif oleh algoritma *deep learning*. Dengan adanya transformasi ini, data tidak hanya menjadi lebih terstruktur, tetapi juga meminimalisasi adanya ketidaksesuaian format yang dapat memengaruhi kinerja model. Tahapan transformasi yang dilakukan dalam penelitian ini dapat dilihat pada table 4.3.

Tabel 4.3 Tahapan transformasi data

Tahapan	Keterangan
Normalisasi Data	Data penjualan (jumlah) dinormalisasi dengan metode <i>Min-Max Scaling</i> ke rentang [0–1] agar tidak ada nilai yang mendominasi.

Tahapan	Keterangan
Pembagian Dataset	Data dibagi menjadi 70% pelatihan, 15% validasi, dan 15% pengujian.
Pembentukan Window Time Series	Data disusun dalam bentuk urutan (sliding window). menggunakan tiga skenario panjang window: 14, 30, dan 60 hari.

Normalisasi dilakukan untuk menyamakan skala nilai penjualan. Misalnya, jika jumlah penjualan suatu barang berada pada rentang 0–100 unit, maka setelah normalisasi nilai tersebut diubah menjadi 0–1. Dengan demikian, model tidak dipengaruhi oleh perbedaan skala antaratribut.

Tahap berikutnya adalah pembagian dataset. Dari total 730 hari data penjualan (dua tahun), sekitar 511 hari digunakan sebagai data pelatihan, 109 hari sebagai data validasi, dan 110 hari sisanya sebagai data pengujian. Pembagian ini dilakukan secara berurutan agar model belajar dari data masa lalu dan diuji pada data yang belum pernah digunakan dalam pelatihan.

Tahap terakhir adalah pembentukan *window time series*. *Window* berfungsi sebagai jendela yang melihat sejumlah hari sebelumnya untuk memprediksi hari berikutnya. Dengan menggunakan tiga skenario panjang *window* (14, 30, dan 60 hari), model dapat mempelajari pola jangka pendek, menengah, hingga musiman.

Dalam proses ini, data penjualan beberapa hari terakhir disusun sebagai input (X), sedangkan nilai penjualan pada hari berikutnya dijadikan target (Y). Dengan demikian, model *LSTM* dapat belajar hubungan antara pola historis (X)

dengan nilai yang akan diprediksi (Y). Sebagai ilustrasi, jika digunakan panjang window = 2 hari, maka pembentukan data ditunjukkan pada Tabel 4.4 berikut:

Tabel 4.4 Contoh pembentukan window time series (2 hari)

Hari	Penjualan	Input (x)	Target (y)
1	100	-	-
2	110	-	-
3	120	[100 , 110]	130
4	130	[110, 120]	140

Dari contoh tersebut terlihat bahwa dua data penjualan sebelumnya digunakan sebagai input untuk menebak nilai pada hari berikutnya. Semakin panjang window yang digunakan, semakin banyak informasi historis yang dipelajari model. Hal ini dapat meningkatkan kemampuan dalam mengenali pola jangka panjang, meskipun juga membutuhkan waktu komputasi yang lebih besar.

Pada penelitian ini, tiga skenario panjang *window* (14, 30, dan 60 hari) digunakan untuk menguji seberapa baik model *LSTM* mampu menangkap pola jangka pendek, menengah, hingga musiman pada data penjualan.

4.2. Implementasi Model

Setelah data berhasil diolah dan ditransformasi menjadi format yang sesuai, tahap selanjutnya adalah mengimplementasikan metode prediksi. Model dilatih menggunakan data historis, kemudian dilakukan *forecasting* untuk seluruh data guna mengevaluasi akurasi prediksi terhadap data aktual.

4.2.1. LSTM

Model *LSTM* yang digunakan dalam penelitian ini dirancang untuk melakukan peramalan jumlah kebutuhan stok berdasarkan data historis harian. Arsitektur model *LSTM* dibangun dengan mempertimbangkan dua aspek utama, yaitu ukuran *window* (jumlah hari historis yang digunakan sebagai input) dan jumlah unit neuron pada layer *LSTM*.

Dalam penelitian ini digunakan tiga skenario *window size*, yaitu 14, 30, dan 60 hari, yang masing-masing merepresentasikan horizon historis jangka pendek, menengah, dan panjang. Pemilihan *window size* ini didasarkan pada pertimbangan siklus operasional perusahaan, di mana:

- a. *Window size* 14 hari ditujukan untuk menangkap pola mingguan dan fluktuasi jangka pendek.
- b. *Window Size* 30 hari untuk menangkap pola bulanan dan fluktuasi jangka menengah.
- c. *Window Size* 60 hari digunakan untuk melihat dampak historis jangka panjang yang mungkin mengandung pola musiman atau tren.

Untuk *window size* 14 dan 30, digunakan arsitektur *LSTM* dengan 16 unit *neuron*, sedangkan untuk *window size* 60 digunakan 32 unit *neuron*, guna menangkap pola jangka panjang yang lebih kompleks. Selain variasi *window size*, model *LSTM* dalam penelitian ini juga dikonfigurasi dengan sejumlah parameter penting untuk meningkatkan akurasi dan stabilitas prediksi, yaitu jumlah unit pada lapisan *Dense*, tingkat *dropout*, ukuran *batch* (*batch size*), dan jumlah *epoch*.

Struktur model terdiri atas satu lapisan *LSTM* yang diikuti oleh dua lapisan *Dense*; lapisan pertama memiliki 30 unit *neuron* sebagai pemroses lanjutan, dan

lapisan kedua memiliki 1 unit neuron sebagai *output layer* untuk menghasilkan prediksi jumlah kebutuhan stok harian. Fungsi aktivasi pada lapisan *output* adalah *linear*, karena target yang diprediksi bersifat kontinu. Untuk mencegah overfitting, digunakan lapisan *Dropout* sebesar 0.2 – 0.3 yang ditempatkan antara *LSTM* dan *Dense*, yang berfungsi menonaktifkan sebagian *neuron* secara acak selama pelatihan. Ringkasan arsitektur yang diterapkan dalam model *LSTM* dapat dilihat pada Tabel 4.5 dan 4.6 berikut.

Tabel 4.5 Parameter model LSTM window size 14 dan 30

Layer (type)	Output Shape	Param #
LSTM	(None, 16)	1152
Dropout	(None, 16)	0
Dense	(None, 30)	510
Dense	(None ,1)	31
Total		1693

Tabel 4.6 Parameter model LSTM window size 14 dan 30

Layer (type)	Output Shape	Param #
LSTM	(None, 32)	4352
Dropout	(None, 32)	0
Dense	(None, 30)	990
Dense	(None ,1)	31
Total		5373

4.2.2. Moving Average

Moving Average (MA) adalah metode peramalan sederhana namun efektif untuk mengidentifikasi tren umum dalam data deret waktu. Prinsip dasarnya adalah menghitung rata-rata nilai dari sejumlah periode sebelumnya, lalu menggunakan hasil tersebut sebagai prediksi untuk periode berikutnya.. Dalam penelitian ini digunakan tiga periode MA, yaitu 14 hari, 30 hari, dan 60 hari, agar hasil prediksi dapat dibandingkan secara adil dengan tiga skenario *window* pada model LSTM.

- a. MA 14: menghitung rata-rata penjualan 14 hari terakhir.
- b. MA 30: menghitung rata-rata penjualan 30 hari terakhir.
- c. MA 60: menghitung rata-rata penjualan 60 hari terakhir.

Proses perhitungan dilakukan secara bertahap untuk seluruh data, dan hasilnya disimpan dalam kolom baru, masing-masing dinamai sesuai periode yang digunakan (MA_14, MA_30, MA_60). Sebagai ilustrasi, contoh perhitungan MA dengan periode 2 hari ditunjukkan pada Tabel 4.7 berikut:

Tabel 4.7 Contoh perhitungan MA 2 hari

Hari	Penjualan	MA (2)
1	100	-
2	110	-
3	120	$(100+110) / 2 = 105$
4	130	$(110 + 120) / 2 = 115$

4.3. Proses Pengujian Model LSTM

Setelah model *LSTM* selesai diimplementasikan, tahap selanjutnya adalah melakukan pengujian terhadap data uji untuk mengetahui sejauh mana kemampuan

masing-masing metode dalam memprediksi kebutuhan persediaan barang. Tujuan utama dari tahap ini adalah untuk melihat performa awal dari kedua pendekatan sebelum dilakukan evaluasi kuantitatif lebih lanjut menggunakan metrik *error* seperti *MSE*, *MAE*, atau *RMSE*.

4.3.1. Model LSTM

Model *LSTM* dibangun dengan tiga variasi konfigurasi yang disesuaikan dengan panjang *window* data (14, 30, dan 60 hari) serta jumlah unit neuron (16 dan 32 Unit). Setiap model dilengkapi lapisan *Dropout* untuk mengurangi risiko *overfitting*, dan dua lapisan *Dense* sebagai pemroses lanjutan serta lapisan keluaran. Optimizer yang digunakan adalah Adam dengan *learning rate* default, dan proses pelatihan dijalankan maksimal selama 50 *epoch* dengan *batch size* 16. Ringkasan parameter model LSTM ditampilkan pada Tabel 4.9 berikut.

Tabel 4.8 Parameter setiap model LSTM

Model	Window (Hari)	Unit Neuron	Dropout	Dense Layer	Output Layer	Epoch	Batch Size
1 (16 Unit)	14	16	0.2	30	1 (<i>linear</i>)	50	16
2 (16 Unit)	30	16	0.2	30	1 (<i>linear</i>)	50	16
3 (32 Unit)	60	32	0.3	30	1 (<i>linear</i>)	50	16

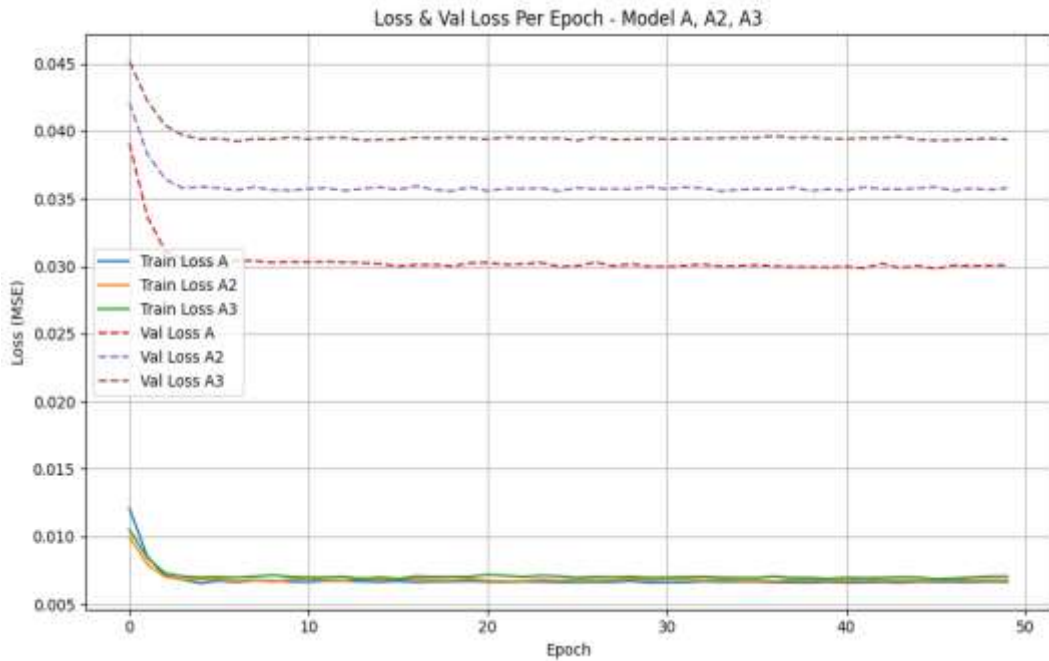
Tabel 4.9 memperlihatkan bahwa setiap konfigurasi disesuaikan dengan kompleksitas data. Semua barang diuji menggunakan tiga variasi *window size* (14, 30, dan 60 hari). Model dengan 14 dan 30 hari menggunakan 16 unit neuron, sedangkan model dengan 60 hari menggunakan 32 unit neuron. Variasi *window size* ini bertujuan untuk menangkap pola jangka pendek, menengah, hingga musiman pada data penjualan.

4.3.2. Pelatihan Model LSTM

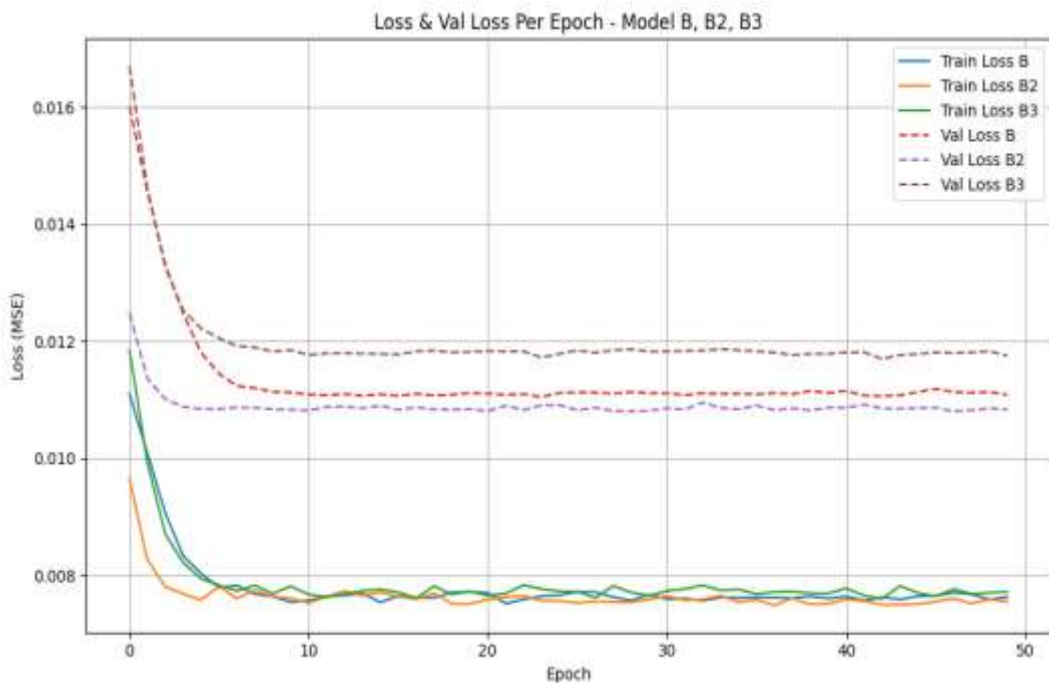
Proses pelatihan model *LSTM* dilakukan menggunakan fungsi `model.fit()`, yang merupakan metode utama dalam pustaka Keras Tensorflow untuk menjalankan pembelajaran model terhadap data historis. Dalam penelitian ini, model dilatih menggunakan data latih (X_{train} , y_{train}) selama maksimal 50 epoch, dengan *batch size* sebesar 16. Artinya, data pelatihan dibagi ke dalam kelompok-kelompok kecil yang masing-masing terdiri dari 16 sampel. Pemrosesan data per batch ini dilakukan secara bertahap pada setiap *epoch*, sehingga proses pembaruan bobot model menjadi lebih efisien dan stabil.

Selama proses pelatihan, model juga dievaluasi terhadap data uji (X_{test} , y_{test}) yang berfungsi sebagai data validasi. Evaluasi ini dilakukan pada setiap epoch untuk memantau sejauh mana model mampu melakukan generalisasi terhadap data yang tidak dilibatkan dalam proses pelatihan. Nilai *loss* dari data pelatihan dan *val_loss* dari data validasi dicatat dalam objek *history* dan digunakan untuk memvisualisasikan performa model selama pelatihan.

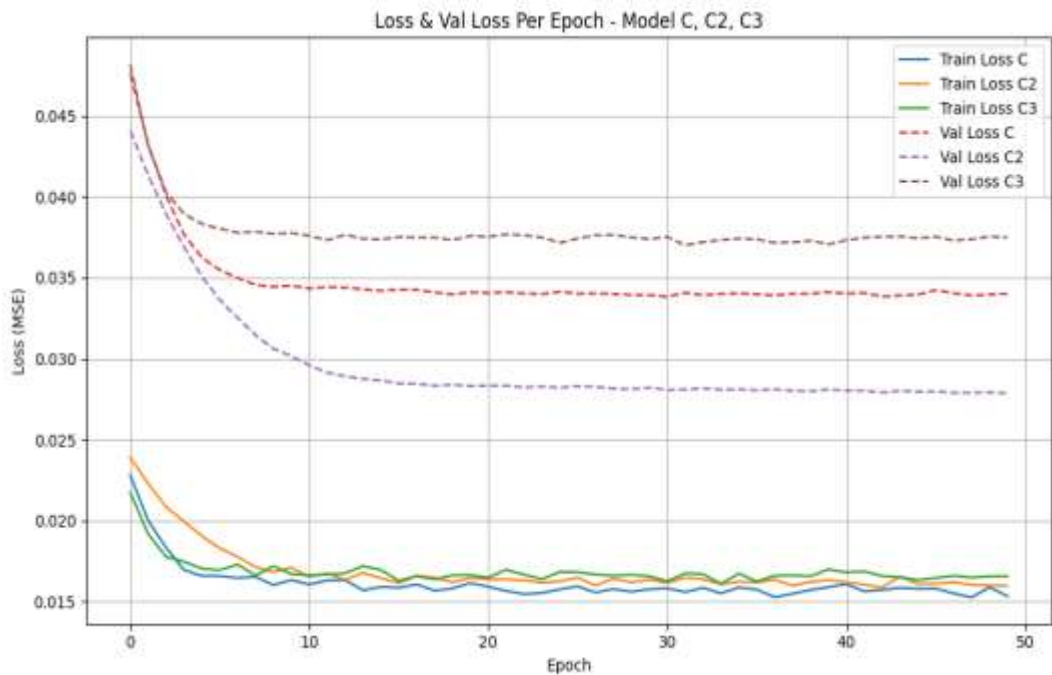
Hasil pelatihan model *LSTM* dengan variasi *window size* dapat dilihat pada Gambar 4.2, Gambar 4.3, dan Gambar 4.4. Setiap grafik menampilkan perubahan nilai *loss* pada data latih serta *validation loss* pada data uji selama proses pelatihan.



Gambar 4.2 Hasil grafik pelatihan nilai loss dan nilai val_loss Model A



Gambar 4.3 Hasil grafik pelatihan nilai loss dan nilai val_loss Model B



Gambar 4.4 Hasil grafik pelatihan nilai loss dan nilai val_loss Model C

Pada gambar 4.2 memperlihatkan tren penurunan nilai loss pada data latih dan validation loss pada data uji yang konsisten hingga akhir epoch. Hal ini menunjukkan bahwa Model A mampu belajar dengan baik dan tidak mengalami gejala overfitting. Lalu pada gambar 4.3 pola penurunan loss dan val_loss pada Model B terlihat stabil serta mendekati titik minimum yang sama. Kondisi ini menandakan bahwa model dapat melakukan generalisasi dengan baik terhadap data uji. Dan terakhir pada gambar 4.4 terlihat Model C menunjukkan penurunan loss yang lebih lambat dibandingkan dengan Model A dan B. Meskipun demikian, nilai loss tetap stabil di akhir proses pelatihan, menandakan model tetap mencapai konvergensi meski dengan kecepatan berbeda.

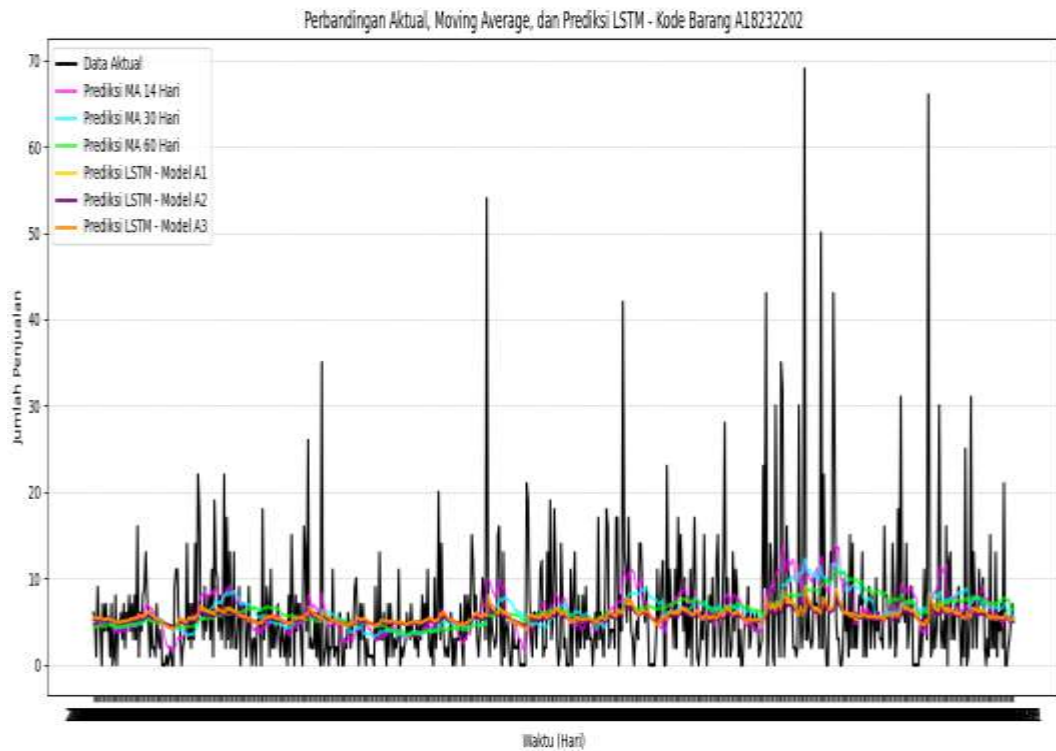
4.4. Analisis dan Perbandingan Hasil

Setelah model *Long Short-Term Memory* (LSTM) di latih dan metode *Moving Average* (MA) diimplementasikan. Selanjutnya akan dilakukan pengujian hasil prediksi menggunakan data yang sama, tahap ini bertujuan untuk membandingkan hasil prediksi dari kedua pendekatan tersebut dalam keseluruhan data. Perbandingan dilakukan baik secara visual maupun kuantitatif untuk mengevaluasi seberapa akurat dan stabil masing-masing metode dalam memprediksi kebutuhan persediaan jumlah barang.

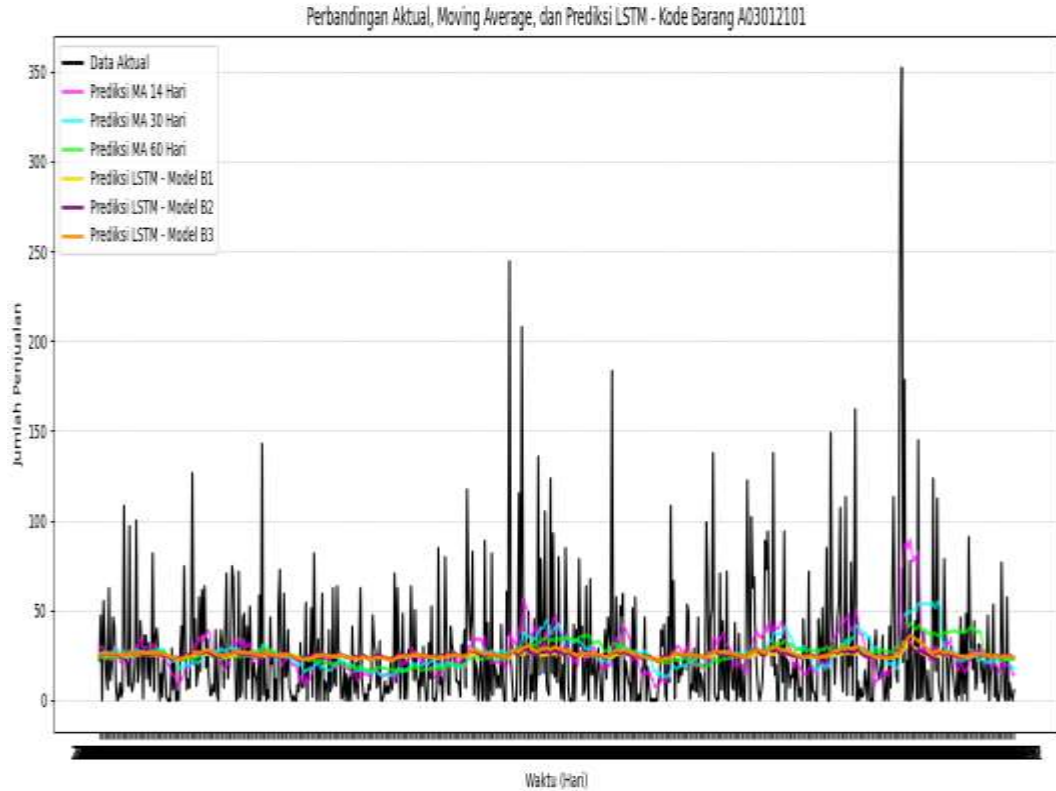
Dengan menggunakan window size 14 hari, 30 dan 60 hari sebagai acuan evaluasi, analisis ini juga mempertimbangkan faktor-faktor seperti responsivitas terhadap fluktuasi permintaan serta kemampuan masing-masing metode dalam menangani pola musiman atau tren yang mungkin ada pada data persediaan.

4.4.1. Evaluasi Visual

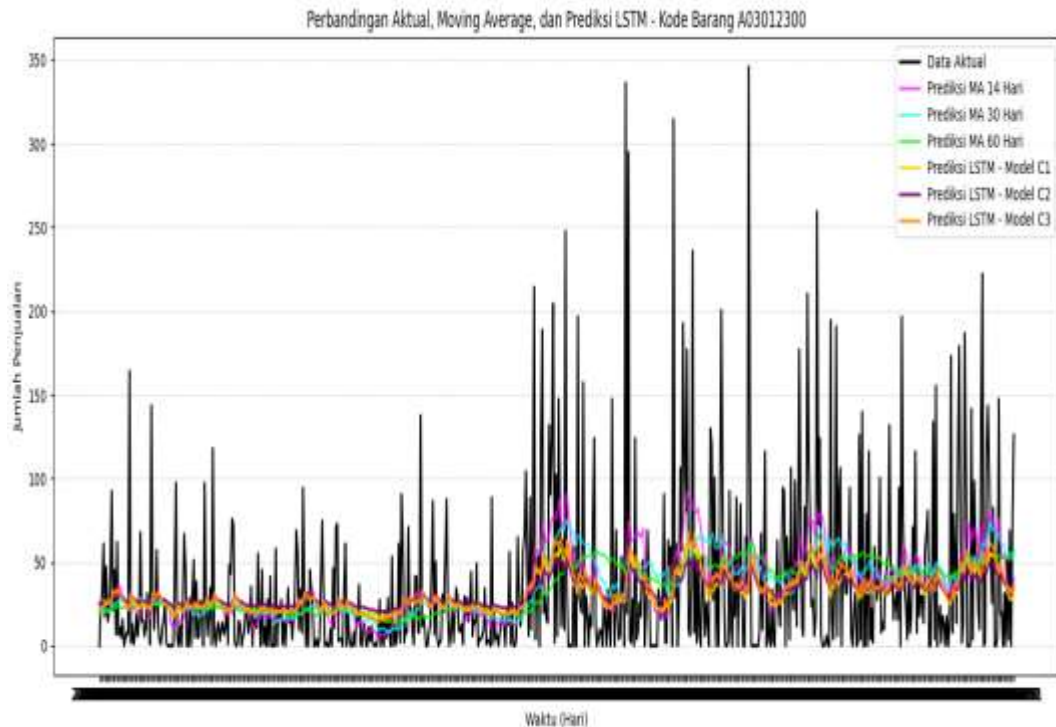
Evaluasi visual dilakukan dengan membandingkan hasil prediksi dari tiga model *LSTM* yang memiliki jumlah unit berbeda (16 dan 32 unit) serta metode *MA* dengan window size 14 hari, 30 hari, dan 60 hari terhadap data aktual. Visualisasi ini bertujuan untuk melihat sejauh mana prediksi mendekati pola data aktual. Dengan adanya perbandingan ini, dapat diamati model mana yang mampu memberikan hasil prediksi paling sesuai. Hasil prediksi model *LSTM* dan *Moving Average* yang menggunakan *window size* 14 hari, 30 hari, dan 60 hari dapat dilihat pada gambar 4.5, gambar 4.6, dan gambar 4.7.



Gambar 4.5 hasil prediksi LSTM , MA dan data Aktual Kode barang A18232202



Gambar 4.6 hasil prediksi LSTM , MA dan Data Aktual Kode Barang A03012101



Gambar 4.7 hasil prediksi LSTM , MA dan Data Aktual Kode Barang A03012300

Pada Gambar 4.5, pola penjualan barang A18232202 menunjukkan kestabilan dengan fluktuasi yang rendah. Metode *Moving Average* (MA) memberikan hasil prediksi yang cukup baik karena tren penjualan relatif konsisten, sehingga nilai prediksi mendekati data aktual. Model *LSTM* (A1, A2, A3) juga mampu mengikuti pola data dengan baik, meskipun keunggulannya dibandingkan *MA* tidak terlalu signifikan, mengingat karakteristik data yang stabil. Hal ini menunjukkan bahwa untuk barang dengan pola penjualan yang relatif stabil, metode sederhana seperti *MA* sudah cukup efektif.

Pada Gambar 4.6, prediksi *MA* dengan periode 14, 30, dan 60 hari menghasilkan pola yang halus dan stabil, namun cenderung tertinggal ketika terjadi perubahan mendadak pada data aktual. Sebaliknya, model *LSTM* (B1, B2, B3) lebih

adaptif dalam mengikuti pola fluktuatif, meskipun pada lonjakan ekstrem prediksi masih sedikit meredam pergerakan aktual. Hal ini mengindikasikan bahwa *LSTM* lebih sesuai untuk data dengan dinamika yang lebih tinggi.

Selanjutnya, pada Gambar 4.7 terlihat bahwa barang A03012300 memiliki tingkat fluktuasi yang lebih tinggi dibandingkan A03012101. *MA* dengan window 14 hari relatif lebih responsif terhadap perubahan, namun menghasilkan prediksi yang lebih berisik, sementara *MA* 30 dan 60 hari cenderung menghasilkan pola yang terlalu rata. Model *LSTM* (C1, C2, C3) mampu menangkap tren jangka pendek serta lonjakan permintaan dengan lebih baik, menunjukkan keunggulan signifikan *LSTM* dalam menghadapi data dengan volatilitas tinggi, meskipun prediksi belum sepenuhnya mengikuti lonjakan ekstrem.

4.4.2. Evaluasi Kuantitatif

Selanjutnya Evaluasi kuantitatif dilakukan untuk mengukur tingkat akurasi model secara objektif menggunakan data uji (*test set*). Pemilihan data uji sebagai dasar evaluasi bahwa data ini tidak pernah digunakan pada proses pelatihan, sehingga hasil pengukuran benar-benar merefleksikan kemampuan model. Beberapa metrik yang digunakan dalam penelitian ini adalah *Mean Absolute Deviation* (MAD), *Mean Squared Error* (MSE), dan *Mean Absolute Percentage Error* (MAPE).

Tabel 4.9 Metrik evaluasi model LSTM dan MA

Kode Barang	Metode	Window	MAD	MSE	MAPE
A18232202	LSTM	14	4,52	42,91	104,12 %
	(16)	30	4,52	42,93	102,82 %

Kode Barang	Metode	Window	MAD	MSE	MAPE
A18232202	LSTM (32)	60	4,56	42,95	106,97 %
	MA 14	14	52,59	6.114,16	85,52 %
	MA 30	30	52,56	6.083,04	87,95 %
	MA 60	60	52,51	6.073,39	87,96 %
A03012101	LSTM (16)	14	17,60	455,02	206,60 %
		30	17,79	458,98	205,49%
	LSTM (32)	60	17,89	461,28	206,00%
	MA 14	14	16,28	413,63	168,91 %
	MA 30	30	16,75	413,83	183,86 %
	MA 60	60	20,38	565,11	252,71 %
	A03012300	LSTM (16)	14	50,76	4.112,88
		30	50,29	4.063,01	241,68 %
LSTM (32)		60	50,84	4.015,90	272,96 %
MA 14		14	49,95	3.491,03	295,69 %
MA 30		30	50,17	3.657,27	301,55 %
MA 60		60	50,13	3.722,43	277,63 %

Terlihat pada table 4.10 hasil evaluasi kuantitatif menunjukkan perbedaan kinerja metode *LSTM* dan *Moving Average* (MA) pada masing-masing kode barang. Untuk barang A18232202 yang memiliki pola relatif stabil, model *LSTM*

menghasilkan nilai *MAD* lebih kecil dibanding *MA*, namun nilai *MAPE* justru lebih tinggi. Hal ini menunjukkan bahwa meskipun *LSTM* mampu menekan kesalahan absolut, *MA* lebih konsisten dalam menghasilkan kesalahan relatif yang lebih rendah sehingga lebih sesuai untuk pola data yang stabil.

Pada barang A03012101 dengan fluktuasi sedang, metode *MA* cenderung lebih baik ditinjau dari nilai *MAPE*, sementara nilai *MSE* dan *MAD* antara kedua metode relatif sebanding. Sementara itu, pada barang A03012300 yang memiliki pola sangat fluktuatif, model *LSTM* menunjukkan performa lebih unggul dibanding *MA* dengan nilai *MAPE* yang lebih rendah, sehingga lebih adaptif dalam menangkap pola penjualan yang tidak teratur. Secara umum, hasil ini mengindikasikan bahwa pemilihan metode prediksi perlu disesuaikan dengan karakteristik data, di mana *MA* lebih tepat digunakan pada pola penjualan stabil hingga sedang, sedangkan *LSTM* lebih sesuai diterapkan pada pola penjualan dengan tingkat fluktuasi tinggi.

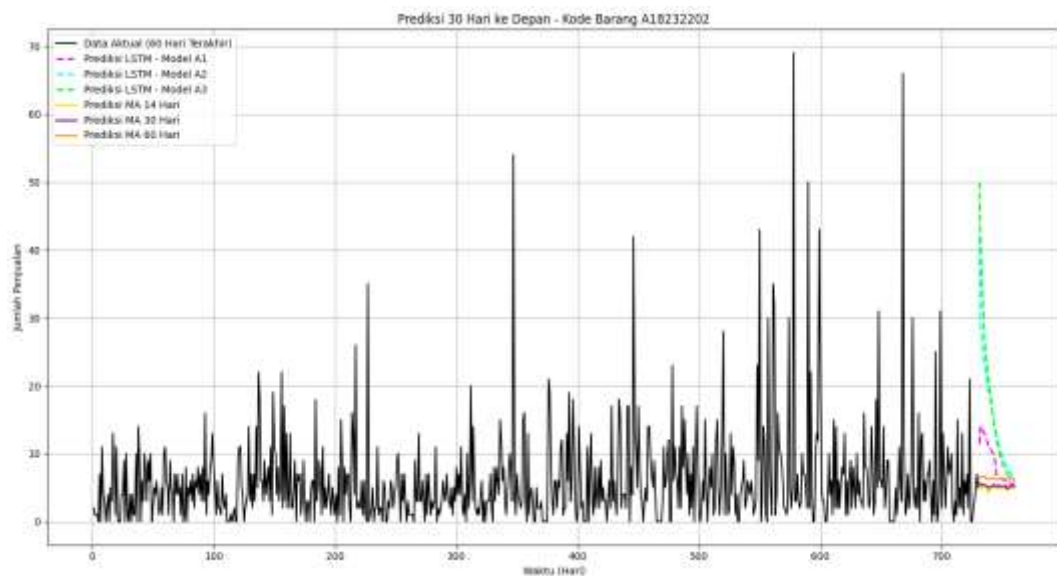
4.5. Implementasi Prediksi

Setelah model dievaluasi secara visual maupun kuantitatif, tahap selanjutnya adalah mengimplementasikan model untuk melakukan prediksi pada periode yang akan datang. Implementasi ini bertujuan untuk menunjukkan bagaimana hasil peramalan dapat digunakan secara praktis dalam mendukung pengambilan keputusan, khususnya dalam perencanaan persediaan barang.


Dalam penelitian ini, implementasi dilakukan dengan memproyeksikan penjualan untuk horizon 30 hari ke depan. Pemilihan horizon 30 hari didasarkan pada pertimbangan operasional, di mana sebagian besar proses pengadaan dan

distribusi barang berlangsung dalam siklus bulanan. Dengan demikian, prediksi 30 hari ke depan diharapkan dapat memberikan informasi yang lebih relevan dan aplikatif bagi pengelola dalam menentukan kebutuhan stok.


Proses prediksi dilakukan dengan pendekatan *recursive forecasting*, yaitu hasil prediksi pada hari sebelumnya digunakan kembali sebagai input untuk memprediksi hari berikutnya hingga mencapai horizon 30 hari. Hasil Grafik prediksi untuk 30 hari kedepan dapat dilihat pada gambar 4.8 , 4.9 dan 4.10 berikut



Gambar 4.8 Hasil prediksi 30 hari kedepan Kode Barang A18232202



Gambar 4.9 Hasil prediksi 30 hari kedepan Kode Barang A03012101



Gambar 4.10 Hasil prediksi 30 hari kedepan Kode BarangA03012300

Pada Gambar 4.8 (A03012101) terlihat bahwa metode *Moving Average* (MA) menghasilkan pola prediksi yang relatif rata dan stabil, sedangkan model *LSTM* memberikan variasi yang sedikit lebih dinamis dengan tetap mengikuti kecenderungan historis. Selanjutnya, pada Gambar 4.9 (A03012300), hasil prediksi *MA* tampak cenderung mendatar, sementara *LSTM* menunjukkan fluktuasi yang lebih jelas sehingga lebih adaptif terhadap pola data yang tidak stabil. Adapun Gambar 4.10 (A18232202) memperlihatkan bahwa kedua metode sama-sama menghasilkan prediksi yang stabil, meskipun *LSTM* menunjukkan kecenderungan sedikit menurun, sedangkan *MA* lebih mendatar mengikuti tren historis.

Secara keseluruhan, hasil ini menunjukkan bahwa prediksi 30 hari ke depan menghasilkan nilai yang masih wajar dan mengikuti tren umum dari data historis. *MA* lebih memberikan prediksi stabil, sedangkan *LSTM* lebih mampu menangkap variasi, terutama pada barang dengan pola penjualan yang fluktuatif.

BAB V

PENUTUP

5.1. Kesimpulan

Penelitian ini telah berhasil menerapkan model *Long Short-Term Memory* (LSTM) dan metode *Moving Average* (MA) dalam meramalkan kebutuhan persediaan barang pada PT. Gunung Sari Indonesia. Model *LSTM* mampu menangkap pola data historis dengan mempertimbangkan ketergantungan jangka pendek, menengah, maupun panjang melalui variasi *window* 14, 30, dan 60 hari. Hasil pengujian menunjukkan bahwa *LSTM* lebih adaptif terhadap pola data yang dinamis, terutama pada barang dengan tingkat fluktuasi permintaan yang tinggi. Sementara itu, metode *Moving Average* yang digunakan sebagai pendekatan konvensional terbukti mampu memberikan hasil prediksi yang stabil dan sederhana, khususnya pada barang dengan pola penjualan yang konsisten.

Berdasarkan evaluasi visual dan kuantitatif, performa kedua metode menunjukkan hasil yang bervariasi sesuai karakteristik data. Untuk barang dengan pola penjualan stabil atau fluktuasi ringan, *Moving Average* memberikan tingkat kesalahan relatif yang lebih rendah sehingga lebih sesuai digunakan. Sebaliknya, pada barang dengan pola fluktuasi tinggi, *LSTM* menunjukkan keunggulan dalam mengantisipasi perubahan tren yang tajam dengan tingkat akurasi yang lebih baik. Dengan demikian, penelitian ini menyimpulkan bahwa pemilihan metode peramalan perlu disesuaikan dengan karakteristik pola data, di mana *Moving Average* lebih efektif untuk pola data stabil, sedangkan *LSTM* lebih relevan untuk pola data yang kompleks dan dinamis.

5.2. Saran

Berdasarkan hasil penelitian ini, terdapat beberapa hal yang dapat dijadikan saran untuk pengembangan model prediksi ke depan. Pertama, sebaiknya penggunaan data diperluas baik dari segi jumlah hari historis maupun dengan penambahan variabel eksternal seperti hari libur, musim, atau aktivitas promosi, karena faktor-faktor tersebut berpotensi memengaruhi pola permintaan barang. Kedua, pengaturan parameter pada model *LSTM*, seperti jumlah unit, epoch, dan *learning rate*, perlu dieksplorasi lebih lanjut guna meningkatkan akurasi prediksi.

Ketiga, penggunaan pendekatan hybrid yang menggabungkan *LSTM* dengan metode konvensional seperti *ARIMA* atau *Moving Average* dapat menjadi alternatif untuk menghasilkan model yang lebih adaptif namun tetap stabil. Selain itu, model yang telah dibangun diharapkan tidak hanya berhenti pada proses evaluasi, tetapi juga dapat diintegrasikan ke dalam sistem manajemen persediaan perusahaan agar dapat digunakan sebagai alat bantu pengambilan keputusan dalam perencanaan stok. Terakhir, kinerja model perlu dievaluasi secara berkala agar tetap relevan dan mampu beradaptasi dengan perubahan pola permintaan yang mungkin terjadi dari waktu ke waktu.

DAFTAR PUSTAKA

- Adi Nugroho, P., Fenriana, I., & Arijanto, R. (2020). IMPLEMENTASI DEEP LEARNING MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) PADA EKSPRESI MANUSIA. *JURNAL ALGOR*, 2(1). <https://jurnal.buddhidharma.ac.id/index.php/algor/index>
- Agung Permana, R., & Sahara, S. (2024). Prediksi Persediaan Barang Menggunakan Indikator Moving Average Studi Kasus Department Store Prediction of Goods Inventory Using the Moving Average Indicator, Department Store Case Study. In *JTSI* (Vol. 5, Issue 1).
- Amrullah, Affandi Egi, Riansyah Wahyu, & Sobirin. (2020). Peramalan Penjualan Bulanan menggunakan metode Trend Moment pada Toko Suamzu Boutique. *Jurnal Sains Manajemen Informatika Dan Komputer*, 19(2), 46–53. <https://ojs.trigunadharma.ac.id/>
- Anjani, I. G., Saputri, A. B., Armeira, A. N. P., & Januarita, D. (2022). Analisis Konsumsi Dan Produksi Minyak Kelapa Sawit Di Indonesia Dengan Menerapkan Metode Moving Average. *JURIKOM (Jurnal Riset Komputer)*, 9(4), 1014. <https://doi.org/10.30865/jurikom.v9i4.4506>
- Ardianto, R., & Kartika Wibisono, S. (2023). Analisis Deep Learning Metode Convolutional Neural Network Dalam Klasifikasi Varietas Gandum *Analysis of Convolutional Neural Network Deep Learning Method in Durum Wheat Variety Classification.* 6. <https://doi.org/10.56338/jks.v6i12.4938>

- Ashari, M. L., & Sadiki, M. (2020). *PREDIKSI DATA TRANSAKSI PENJUALAN TIME SERIES MENGGUNAKAN REGRESI LSTM* (Vol. 9, Issue 1).
- Asyrofi, R. R., & Asyrofi, R. (2023). IMPLEMENTASI APLIKASI JUPYTER NOTEBOOK SEBAGAI ANALISIS KRETERIA PLAGIASI DENGAN TEKNIK SIMANTIK. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 8(2), 627–637. <https://doi.org/10.29100/jipi.v8i2.3699>
- Chazar, C., & Widhiaputra, B. E. (2020). *INFORMASI (Jurnal Informatika dan Sistem Informasi) Machine Learning Diagnosis Kanker Payudara Menggunakan Algoritma Support Vector Machine.*
- Datta, L. (2020). *A Survey on Activation Functions and their relation with Xavier and He Normal Initialization.* <http://arxiv.org/abs/2004.06632>
- Fadila, R. A., & Wulandari, A. P. (2023). *LITERATURE REVIEW ANALISIS DATA KUALITATIF: TAHAP PENGUMPULAN DATA.*
- Fadilah, F., Komarudin, A., & Melina. (2024). *PREDIKSI PENJUALAN OBAT BERBASIS ARTIFICIAL NEURAL NETWORK (ANN).*
- Faiza, M. I., Gunawan, & Andriani, W. (2022). *Tinjauan Pustaka Sistematis: Penerapan Metode Machine Learning untuk Deteksi Bencana Banjir.* <https://doi.org/10.33299/jpkop.22.2.1752>
- Gori, T., Sunyoto, A., & Al Fatta, H. (2024). Preprocessing Data dan Klasifikasi untuk Prediksi Kinerja Akademik Siswa. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 11(1), 215–224. <https://doi.org/10.25126/jtiik.20241118074>

- Gunawan, R., Dimiliu, M. B., Valerine, K., & Tamba, S. P. (2024). ANALISIS PREDIKSI PENJUALAN TOKO FURNITUR DENGAN METODE LONG SHORT-TERM MEMORY (LSTM). *Jurnal Teknik Informasi Dan Komputer (Tekinkom)*, 7(2), 716. <https://doi.org/10.37600/tekinkom.v7i2.1511>
- Hakim, B. (2021). Analisa Sentimen Data Text Preprocessing Pada Data Mining Dengan Menggunakan Machine Learning. *JBASE - Journal of Business and Audit Information Systems*, 4(2). <https://doi.org/10.30813/jbase.v4i2.3000>
- Huriati, P., Erianda, A., Alanda, A., Meidelfi, D., & Irma Suryani, A. (2022). Implementation of the Moving Average Method for Forecasting Inventory in Cv. Tre Jaya Perkasa. In *International Journal of Advanced Science Computing and Engineering* (Vol. 4, Issue 2).
- Lubis, H. M., Tanjung, A. A., & Martina, D. (2022). *FORECASTING UNTUK PRODUKSI BATIK DENGAN SINGLE MOVING AVERAGE*.
- Maharana, K., Mondal, S., & Nemade, B. (2022). A review: Data pre-processing and data augmentation techniques. *Global Transitions Proceedings*, 3(1), 91–99. <https://doi.org/10.1016/j.gltp.2022.04.020>
- Mahendra, H. B., Chaerani, L., & Gumay, G. M. (2023). Analisis Perbandingan Prediksi Harga Saham menggunakan Algoritma Artificial Neural Network dan Linear Regression. *Jurnal Ilmiah Komputasi*, 22(2). <https://doi.org/10.32409/jikstik.22.2.3357>
- Mahfud Al, A., Kurniasari, D., Mustofa Usman, dan, Matematika, J., Mipa, F., Lampung Jl Sumantri Brojonegoro No, U., Lampung, B., kunci, K.,

- Spektral, A., Waktu, D., & Pesawat, P. (2020). Peramalan Data Time Series Seasonal Menggunakan Metode Analisis Spektral Berdasarkan data yang tersedia diperoleh model terbaik untuk peramalan penumpang pesawat di Bandar Udara Raden Intan II adalah Seasonal ARIMA (0. In *Jurnal Siger Matematika* (Vol. 01, Issue 01).
- Masih, B. (2024). *Recurrent neural network model for time series analysis* *.
- Muharram, R. F., Suryadi, A., Raya, J., No, T., Gedong, K., Rebo, P., & Timur, J. (2022). Implementasi artificial intelligence untuk deteksi masker secara realtime dengan tensorflow dan ssdmobilenet Berbasis python. *Jurnal Widya*, 3(2), 281–290. <https://jurnal.amikwidyaloka.ac.id/index.php/awl>
- Nur Cahyo, E., & Susanti*, E. (2023). Analisis Time Series Untuk Deep Learning Dan Prediksi Data Spasial Seismik: Studi Literatur. *Jurnal Teknologi*, 15(2), 124–136. <https://doi.org/10.34151/jurtek.v15i2.3581>
- Oktafiani, R., Hermawan, A., & Avianto, D. (2023). Pengaruh Komposisi Split data Terhadap Performa Klasifikasi Penyakit Kanker Payudara Menggunakan Algoritma Machine Learning. *Jurnal Sains Dan Informatika*, 19–28. <https://doi.org/10.34128/jsi.v9i1.622>
- Priyandanu, H., Tabrani, M., & Mutaqin, Z. (2020). MANAJEMEN PERSEDIAAN BAHAN BAKU BERBASIS PADA PT. TUFFINDO NITTOKU AUTONEUM KARAWANG. In *JURNAL ILMIAH M-PROGRESS* (Vol. 10, Issue 1).
- Puteri, D. I. (2023). Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi

- Harga Saham Syariah. *Euler : Jurnal Ilmiah Matematika, Sains Dan Teknologi*, 11(1), 35–43. <https://doi.org/10.34312/euler.v11i1.19791>
- Rahman Lutfi, F., & Sasongko, C. (2022). Perencanaan Produksi dan Manajemen Persediaan pada Perusahaan Kue dan Roti. *Studi Akuntansi Dan Keuangan Indonesia*, 5(1).
- Romzi, M., & Kurniawan, B. (2020). *PEMBELAJARAN PEMROGRAMAN PYTHON DENGAN PENDEKATAN LOGIKA ALGORITMA* (Issue 2).
- Sefry, E., Gulo, D., Hartati, T., Hulu, S., Kakisina, S. M., Surya, M., & Mendrofa, D. (2024). *Analisis Peramalan Persediaan Barang Menggunakan Metode Moving Average Dan Exponential Smoothing Pada CV. Sanjaya Bangun Pratama*.
- Tamami, G., & Arifin, M. (2024). *Penggunaan LSTM dalam Membangun Prediksi Penjualan untuk Aplikasi Laptop Lens*. <https://www.kaggle.com/datasets/artakusuma/laptope>

LAMPIRAN



UMSU
Unggul | Cerdas | Terpercaya

MAJELIS PENDIDIKAN TINGGI PENELITIAN & PENGEMBANGAN PIMPINAN PUSAT MUHAMMADIYAH

UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA

FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI

UMSU Terakreditasi A Berdasarkan Keputusan Badan Akreditasi Nasional Perguruan Tinggi No. 88/SK/BAH-PT/Akred/PT/08/2019

Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20238 Telp. (061) 6622400 - 66224567 Fax. (061) 6625474 - 6631003

<http://id.umsu.ac.id>

info@umsu.ac.id

[umsu.medan](#)

[umsu.medan](#)

[umsu.medan](#)

[umsu.medan](#)

**PENETAPAN DOSEN PEMBIMBING
PROPOSAL/SKRIPSI MAHASISWA
NOMOR : 899/IL3-AU/UMSU-09/F/2024**

Assalamu'alaikum Warahmatullahi Wabarakatuh

Dekan Fakultas Ilmu Komputer dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara, berdasarkan Persetujuan permohonan judul penelitian Proposal / Skripsi dari Ketua / Sekretaris.

Program Studi : Sistem Informasi
Pada tanggal : 20 November 2024

Dengan ini menetapkan Dosen Pembimbing Proposal / Skripsi Mahasiswa.

Nama : Ricky Armando Sembiring
NPM : 2109010066
Semester : VII (Tujuh)
Program studi : Sistem Informasi
Judul Proposal / Skripsi : Analisis Dan Implementasi Long Short-Term Memory (LSTM) Dalam Kebutuhan Stoking Barang Di PT. Gunung Sari Indonesia

Dosen Pembimbing : Yoshida Sary, S.Kom., M.Kom.

Dengan demikian di izinkan menulis Proposal / Skripsi dengan ketentuan

1. Penulisan berpedoman pada buku panduan penulisan Proposal / Skripsi Fakultas Ilmu Komputer dan Teknologi Informasi UMSU
2. Pelaksanaan Sidang Skripsi harus berjarak 3 bulan setelah dikeluarkannya Surat Penetapan Dosen Pembimbing Skripsi.
3. **Proyek Proposal / Skripsi dinyatakan " BATAL "** bila tidak selesai sebelum Masa Kadaluarsa tanggal : **20 November 2025**
4. Revisi judul.....

Wassalamu'alaikum Warahmatullahi Wabarakatuh.

Ditetapkan di : Medan
Pada Tanggal : 18 Jumadil Awwal 1446 H
20 November 2024 M

Dekan

Dr. Al. Khawarizmi, S.Kom., M.Kom.
NIDN 0127099201



Cc. File





UMSU
Unggul | Cerdas | Terpercaya

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

UMSU Terakreditasi A Berdasarkan Keputusan Badan Akreditasi Nasional Perguruan Tinggi No. 16/SK/BIAN-PT/Akred/PT/10/2019
Pusat Administrasi: Jalan Mukhtar Satri No. 3 Medan 20238 Telp. (061) 6622409 - 66224067 Fax. (061) 6625474 - 6631003
Website: <http://www.umsu.ac.id> Email: info@umsu.ac.id [umsumedan](https://www.facebook.com/umsumedan) [umsumedan](https://www.instagram.com/umsumedan) [umsumedan](https://www.youtube.com/umsumedan) [umsumedan](https://www.tiktok.com/umsumedan)

PERSETUJUAN TOPIK/JUDUL PENELITIAN

Nomor Agenda : 899/IL3-AU/UMSU-09/F/2024
 Nama : Ricky Armando Sembiring
 Npm : 2109010066
 Tanggal Persetujuan : 20 November 2024
 Topik Yang Disetujui Program Studi : Analisis Dan Implementasi Long Short-Term Memory (LSTM) Dalam Kebutuhan Stoking Barang di PT. Gunung Sari Indonesia
 Nama Dosen Pembimbing : Yoshida Sary, S.E., S.Kom, M.Kom
 Judul Yang Disetujui Dosen Pembimbing : Analisis Dan Implementasi Long Short-Term Memory (LSTM) Dalam Kebutuhan Persediaan Barang di PT. Gunung Sari Indonesia

Medan, 21 Maret 2025

Disahkan oleh
Ketua Program Studi
Sistem Informasi

Persetujuan
Dosen Pembimbing

(Yoshida Sary)





UMSU
Unggul | Cerdas | Terpercaya

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

UMSU Terakreditasi A Berdasarkan Keputusan Badan Akreditasi Nasional Perguruan Tinggi No. 20/SK/BAN-PT/Akred/PT/III/2019
Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20228 Telp. (061) 8622400 - 86224567 Fax. (061) 8625474 - 6631903
Website: www.umsu.ac.id Email: info@umsu.ac.id Instagram: [umsuamedan](https://www.instagram.com/umsuamedan) Facebook: [umsuamedan](https://www.facebook.com/umsuamedan) Twitter: [umsuamedan](https://twitter.com/umsuamedan) YouTube: [umsuamedan](https://www.youtube.com/umsuamedan)

**PERMOHONAN
SEMINAR PROPOSAL SKRIPSI**

Kepada Yth.
Bapak Dekan FIKTI UMSU
Di
Medan

Medan, 21 Maret 2025

Assalamu 'alaikum Warahmatullahi Wabarakatuh

Dengan hormat, saya yang bertanda tangan di bawah ini mahasiswa Fakultas Ilmu Komputer dan Teknologi Informasi UMSU :

Nama Lengkap : Ricky Armando Sembiring
NPM : 2109010066
Program Studi : Sistem Informasi

Mengajukan permohonan Mengikuti **Seminar Proposal Skripsi** yang ditetapkan dengan Surat Penetapan Judul Skripsi dan Pembimbing Nomor 899/II.3-AU/UMSU-09/F/2024 Tanggal 20 November 2024 dengan judul sebagai berikut :

Analisis Dan Implementasi Long Short-Term Memory (LSTM) Dalam Stoking Barang Persediaan Barang di PT. Gunung Sari Indonesia

Bersama permohonan ini saya lampirkan :

1. Surat Penetapan Judul Skripsi (SK-1),
2. Surat Penetapan Pembimbing (SK-2),
3. DEKAM yang telah disahkan,
4. Kartu Hasil Studi Semester 1 s/d terakhir **ASLI**,
5. Tanda Bukti Lunas Beban SPP tahap berjalan,
6. Tanda Bukti Lunas Biaya Seminar Proposal Skripsi,
7. Proposal Skripsi yang telah disahkan oleh Pembimbing (rangkap-3),
8. Semua berkas dimasukkan ke dalam MAP warna **BIRU**.

Demikian permohonan saya untuk pengurusan selanjutnya. Atas perhatian Bapak saya ucapkan terima kasih.

Wassalamualaikum Warahmatullahi Wabarakatuh.





UMSU

Unggul | Cerdas | Terpercaya

MAJELIS PENDIDIKAN TINGGI PENELITIAN & PENGEMBANGAN PIMPINAN PUSAT MUHAMMADIYAH

UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA

FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI

UMSU Terakreditasi A Berdasarkan Keputusan Badan Akreditasi Nasional Perguruan Tinggi No. 89/DK/BAN-PT/Akred/PT/2019
Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20238 Telp. (061) 6822401 - 6622467 Fax. (061) 6625474 - 6631803

Website: www.umma.ac.id

Email: info@umma.ac.id


Facebook: [umsumedan](https://www.facebook.com/umsumedan)

Instagram: [umamedan](https://www.instagram.com/umamedan)

Twitter: [umsumedan](https://twitter.com/umsumedan)

LinkedIn: [umsumedan](https://www.linkedin.com/company/umsumedan)

Menyetujui :
Pembimbing


(Gochida Savij)

Pemohon


(Riky Amara Sembiring)



UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA
 Nomor : 592/IL.3-AU/UMSU-09/F/2025

UNDANGAN SEMINAR PROPOSAL

Fakultas : Ilmu Komputer dan Teknologi Informasi
 Program Studi : Sistem Informatika
 Hari/Tanggal : Jum'at, 02 Mei 2025
 Waktu /Tempat : 09.00/G
 Pemimpin Seminar : Yoshida Sary, S.E., S.Kom., M.Kom.

No	Nama Mahasiswa	Dosen Pembimbing	Tema/ Judul	Topik
1	Ricky Armando Sembiring	Yoshida Sary, S.E., S.Kom., M.Kom.	Halim Maulana, S.T., M.Kom.	Analisa Dan Implementasi Long Short-Term Memory (LSTM) Dalam Kebutuhan Persediaan Barang Di PT Gunung Sari Indonesia
2	Dafa Gemilang Lubis	Amrullah, S.Kom., M.Kom	Yoshida Sary, S.E., S.Kom., M.Kom.	Evaluasi Efektivitas Metode SAW Dan AHP Dalam Pemilihan Siswa Berprestasi Di Zahira School
3	Muhammad Fauzan Alwi Sitompul	Indah Purnama Sari, S.T., M.Kom.	Dr. Al-Khowarizmi, M.Kom.	Implementasi Algoritma Dijkstra Dalam Penentuan Rate Distribusi Beras SPHP Di Permukiman Bulog Kamwil SUMUT
4	Dhaya Azmi	Fatma Sari Hutagalung, S.Kom., M.Kom.	Dr. Firahtmi Rizky, M.Kom.	Perbandingan Metode Topsis Dan SAW Untuk Menentukan Reward Bagi Guru (Studi Kasus TK. Jabal Rahmah Mulia)



NB. - Laki-laki berhiasan hitam putih dan memakai dasi
 Perempuan berhiasan muslimah hitam putih

Medan, 01 Dzulkadah 1446 H
 29 April 2025 M






UMSU
Jujur | Cerdas | Terpercaya

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

UMSU Terakreditasi A Berdasarkan Keputusan Badan Akreditasi Nasional Perguruan Tinggi No. 89/SK/BAN-PT/Akred/PT/2019
Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20238. Telp. (061) 6622400 - 66224567. Fax. (061) 6625474 - 6631003
http://ikm.umsu.ac.id | ikm@umsu.ac.id | umsumedan | umsumedan | umsumedan | umsumedan



BERITA ACARA SEMINAR PROPOSAL
TAHUN AJARAN 2024/2025

Hari/Tanggal...../.....20...

Nama Mahasiswa : Ricky Armanda
NPM : 2109019066
Program Studi :
Nama Dosen Penanggap :
Judul Proposal :

Materi/Point yang Diperbaiki :

Perbaikan Bab I

Dosen Penanggap
[Signature]
(.....)

Mahasiswa
[Signature]
(Ricky Armanda.....)



UNIVERSITAS MUBHAMMADIYAH SUMATERA UTARA
 Nomor : 880/IL3-AU/UMSU-09/F/2025
HAL UJIAN MEJA HIJAU SARJANA (SI)


UNDANGAN
PANGGILAN

Kepada Yang Terhormat
 Bapak/Ibu Dosen Penguji Meja Hijau
 di
 Medan



Fakultas : Ilmu Komputer dan Teknologi Informasi
 Program Studi : Sistem Informasi
 Hari/Tanggal : Selasa, 02 September 2025
 Waktu /Tempat : 08.00-14.00 WIB/Gedung G

Catatan :
 •Harap datang tepat waktu karena ujian dalam bentuk tim (2 Orang) penguji I & II
 •Dosen Penguji yang terlambat 30 menit akan digamit



No	NAMA MAHASISWA	NPM	JUDUL SKRIPSI	PROSEKUSI	Dosen Pembimbing
8	Audri Aisyah Fitri	2109010074	Analisis Persediaan Obat Dengan Menggunakan Metode Fifo Dan Average Di Klinik Asrama Arhanud Binjai	Dr. Firahmi Rizky, S.Kom., M.Kom.	Yohanni Syabra, S.Si., M.Kom.
9	Ricky Armando Sembiring	2109010066	Analisa Dan Implementasi Long Short-Term memory (LSTM) Dalam Kebutuhan Persediaan Barang Di PT.Gunung Sari Indonesia	Halim Maulana, S.T., M.Kom.	Yoshida Sary, S.E., S.Kom., M.Kom.

Asisten Pengambilan Berita Acara :
 1. Suvia Agustin S.I.Kom
 2. Andika Suras Saputra, S.M

Ditetapkan Oleh



Prof. Dr. Mubhammad Arifin, S.H., M.Hum.

Panitia Ujian



Dr. Al-Ridwan Rizani, M.Kom.

Sekretaris
 Wakil Dekan I

Halim Maulana, S.T., M.Kom.

Medan, 05 Rabi'ul Awwal 1447 H
 28 Agustus 2025 M