

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

Ricky Armando Sembiring¹, Yoshida Sary²

¹ Program Studi Sistem Informasi, Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara, Medan, Indonesia fikti@umsu.ac.id

² Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara, Medan, Indonesia fiktiums@gmail.com

Penulis : Ricky Armando Sembiring rickyarmnd@gmail.com

Abstract: Inventory management plays a vital role in maintaining smooth distribution and operational efficiency within companies. Inaccurate forecasting of inventory needs can cause over-stock or less-stock conditions, leading to increased costs and reduced customer satisfaction. This study applies the Long Short-Term Memory (LSTM) method to forecast inventory requirements based on historical sales data at PT. Gunung Sari Indonesia and compares it with the conventional Moving Average approach. The dataset includes sales transactions from January 2023 to December 2024. The research stages involve data preprocessing, LSTM model construction using window sizes of 14, 30, and 60 days, and performance evaluation using Mean Absolute Deviation (MAD), Mean Squared Error (MSE), and Mean Absolute Percentage Error (MAPE). The results indicate that the LSTM method is more adaptive to fluctuating sales patterns, while the Moving Average method provides more stable predictions for consistent sales patterns. The best MAPE values for the LSTM model range between 102–106%, while the Moving Average method yields values between 85–88%. Therefore, LSTM is preferable for datasets with irregular patterns, whereas Moving Average is more appropriate for stable sales trends.

Keywords: LSTM; Moving Average; Forecasting; Inventory Forecasting; Time Series; PT Gunung Sari.

Abstrak: Manajemen persediaan berperan penting dalam menjaga kelancaran distribusi barang dan efisiensi operasional perusahaan. Ketidaktepatan dalam memprediksi kebutuhan stok dapat menyebabkan *over-stock* maupun *less-stock*, yang berimplikasi pada peningkatan biaya dan penurunan kepuasan pelanggan. Penelitian ini menerapkan metode *Long Short-Term Memory* (LSTM) untuk memprediksi kebutuhan persediaan barang berdasarkan data historis penjualan di PT. Gunung Sari Indonesia serta membandingkannya dengan metode *Moving Average* sebagai pendekatan konvensional. Dataset mencakup transaksi penjualan dari Januari 2023 hingga Desember 2024. Tahapan penelitian meliputi *data preprocessing*, pembentukan model *LSTM* dengan *window size* 14, 30, dan 60 hari, serta evaluasi kinerja menggunakan metrik *Mean Absolute Deviation* (MAD), *Mean Squared Error* (MSE), dan *Mean Absolute Percentage Error* (MAPE). Hasil menunjukkan bahwa metode LSTM lebih adaptif terhadap pola penjualan yang fluktuatif, sedangkan *Moving Average* menghasilkan prediksi yang lebih stabil pada pola penjualan yang konsisten. Nilai *MAPE* terbaik pada *LSTM* berkisar antara 102–106%, sementara *Moving Average* menunjukkan kisaran 85–88%. Dengan demikian, *LSTM* lebih unggul untuk data yang memiliki pola tidak menentu, sedangkan *Moving Average* lebih sesuai untuk pola penjualan stabil.

Kata kunci: LSTM; Moving Average; Forecasting; Prediksi Persediaan; Time Series; PT Gunung Sari.

Diterima: Oktober 20, 2025

Direvisi: Oktober 28, 2025

Diterima: Oktober 29, 2025

Diterbitkan: November 2, 2025

Versi sekarang: November 2, 2025



Hak cipta: © 2025 oleh penulis.

Diserahkan untuk kemungkinan publikasi akses terbuka

berdasarkan syarat dan ketentuan

lisensi Creative Commons

Attribution (CC BY SA) (

<https://creativecommons.org/licenses/by-sa/4.0/>)

1. Pendahuluan

Manajemen persediaan merupakan aspek penting dalam menjaga kelancaran operasional perusahaan, terutama bagi perusahaan distribusi seperti PT. Gunung Sari Indonesia. Pengelolaan stok yang tidak akurat dapat menimbulkan kondisi *over-stock* yang meningkatkan biaya penyimpanan, atau *less-stock* yang menghambat proses penjualan dan menurunkan kepuasan pelanggan [1] [2]. Permasalahan serupa juga terjadi pada perusahaan lain yang masih menggunakan sistem pencatatan manual, seperti PT. Tuffindo Nittoku Autoneum, yang menyebabkan perbedaan antara catatan dan kondisi gudang [3].

Untuk mengatasi permasalahan tersebut, dibutuhkan metode prediksi yang mampu memperkirakan kebutuhan stok secara akurat berdasarkan data historis penjualan [4]. Salah satu metode yang berkembang pesat adalah *Long Short-Term Memory* (LSTM), bagian dari *Recurrent Neural Network* (RNN) yang efektif dalam menganalisis data deret waktu karena mampu mengingat pola jangka panjang. Dibandingkan dengan metode konvensional seperti *Moving Average*, LSTM memiliki kemampuan adaptif yang lebih baik terhadap data fluktuatif [5].

Penelitian ini bertujuan menerapkan metode LSTM untuk memprediksi kebutuhan persediaan barang di PT. Gunung Sari Indonesia serta membandingkan kinerjanya dengan metode *Moving Average*. Hasilnya diharapkan membantu perusahaan dalam mengoptimalkan manajemen stok dan mengurangi risiko ketidakseimbangan persediaan.

2. Tinjauan Literatur

2.1. Manajemen Persediaan

Manajemen persediaan bertujuan menjaga ketersediaan barang pada tingkat biaya yang efisien sambil meminimalkan risiko *over-stock* dan *less-stock* [6]. Pada konteks distribusi, proses manual dan spreadsheet rentan salah input, manipulasi, serta inkonsistensi data sehingga mengganggu akurasi pengambilan keputusan [3].

2.2 Time Series


Data deret waktu (*time series*) merupakan sekumpulan observasi yang dicatat secara berurutan berdasarkan waktu dengan interval yang konsisten. Data ini dapat menunjukkan pola tertentu seperti tren, musiman, dan siklik yang berguna untuk memprediksi nilai pada periode berikutnya [7]. Berdasarkan jumlah variabel yang diamati, *time series* dibedakan menjadi dua jenis, yaitu *univariate* yang hanya melibatkan satu variabel, dan *multivariate* yang melibatkan lebih dari satu variabel pada waktu yang sama [8].

2.3 Machine Learning

Machine Learning merupakan salah satu penerapan dari *Artificial Intelligence* (AI) yang berfokus pada pengembangan sistem yang mampu belajar dari data tanpa perlu pemrograman ulang secara terus-menerus [9]. Proses ini memungkinkan komputer menemukan pola dari data historis untuk digunakan dalam prediksi atau pengambilan keputusan. Semakin optimal algoritma yang digunakan, semakin tinggi tingkat akurasi hasil prediksi yang dihasilkan [10]. Berdasarkan cara pembelajarannya, *machine learning* terbagi menjadi tiga kategori utama, yaitu *supervised learning*, *unsupervised learning*, dan *reinforcement learning*.

2.4 LSTM

Long Short-Term Memory (LSTM) merupakan pengembangan dari *Recurrent Neural Network* (RNN) yang diperkenalkan oleh Hochreiter dan Schmidhuber pada tahun 1997. LSTM dirancang untuk mengatasi kelemahan RNN dalam memproses data sekuensial jangka panjang yang sering mengalami masalah *vanishing gradient* [11][12]. LSTM memiliki struktur utama yang terdiri dari tiga gates utama yang dapat dilihat pada Gambar 1



Gambar 1. Stuktur Aristektur LSTM

Forget Gate 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 data pada waktu saat ini. Jika nilai keluaran mendekati 0, maka informasi tersebut akan dilupakan, sedangkan jika mendekati 1, informasi akan dipertahankan. Selanjutnya, **Input Gate** bertugas mengatur informasi baru yang akan disimpan ke dalam *cell state* melalui kombinasi fungsi *sigmoid* dan *tanh* yang menghasilkan kandidat nilai baru. Kemudian, **Output Gate** menentukan bagian dari *cell state* yang akan dijadikan keluaran, dengan proses normalisasi melalui fungsi aktivasi *tanh*. Ketiga gerbang ini bekerja secara simultan untuk memastikan bahwa informasi penting dalam urutan data dapat dipertahankan dan digunakan pada langkah berikutnya. Dengan mekanisme tersebut, *LSTM* mampu mengingat pola jangka panjang serta mempelajari hubungan kompleks dalam data deret waktu, sehingga lebih akurat dalam menghasilkan prediksi pada dataset yang memiliki pola fluktuatif [13].

2.5 Moving Average

Metode *Moving Average* diterapkan dalam penelitian ini sebagai pendekatan sederhana untuk memprediksi kebutuhan persediaan barang berdasarkan nilai rata-rata dari periode sebelumnya [14]. Teknik ini umum digunakan dalam analisis *time series* karena mampu menghaluskan fluktuasi data dan menampilkan tren tanpa memerlukan proses pelatihan model yang kompleks seperti *LSTM*. Metode ini mudah diimplementasikan serta efisien secara komputasi [15][16].

3. Metode

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk membandingkan performa algoritma *Long Short-Term Memory* (LSTM) dan metode *Moving Average* (MA) dalam peramalan kebutuhan persediaan barang.

3.1 Dataset

Data yang digunakan merupakan data historis penjualan dari PT. Gunung Sari Indonesia selama periode Januari 2023 hingga Desember 2024. Data tersebut diperoleh dari sistem penjualan perusahaan. Keterangan tiap atribut dapat dilihat pada tabel 1 berikut

Tabel 1. Atribut atribut dataset.

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

Sumber : Hasil Penelitian (2025).

3.2 Pra-pemrosesan Data

Tahapan *preprocessing* dilakukan untuk memastikan data dalam kondisi bersih dan siap dianalisis[17]. Proses ini meliputi pembersihan data ganda atau kosong [18], normalisasi nilai numerik dengan *Min-Max Scaling*, serta penyusunan data dalam bentuk deret waktu sesuai urutan tanggal[19]. Dataset kemudian dibagi menjadi data pelatihan (80%), validasi (20%) [20].

3.3 Implementasi Model

Model LSTM dibangun menggunakan *TensorFlow* dengan konfigurasi *window size* 14, 30, dan 60 hari. Setiap model dilatih selama 50 *epoch* dengan *batch size* 16, menggunakan fungsi aktivasi linear pada lapisan keluaran. Proses pelatihan dilakukan menggunakan *optimizer Adam* dan fungsi kehilangan (*loss function*) *Mean Squared Error* (MSE).

Untuk memberikan gambaran umum mengenai konfigurasi model yang digunakan, parameter pelatihan *LSTM* dalam penelitian ini dirangkum pada tabel 2 berikut.

Tabel 2. Konfigurasi paramater model LSTM.

Model	Neuron	Window Size	Batch Size	Epoch	Optimizer	Loss Function
Model 1	16	14	16	50	Adam	MSE
Model 2	16	30	16	50	Adam	MSE
Model 3	32	60	16	50	Adam	MSE

Sumber : Hasil Penelitian (2025).

Sebagai pembanding, metode *Moving Average* digunakan pada periode yang sama (14, 30, dan 60 hari) dengan menghitung rata-rata nilai penjualan untuk memprediksi kebutuhan persediaan pada periode berikutnya.


3.4 Evaluasi Model

Kinerja model dievaluasi menggunakan tiga metrik utama, yaitu *Mean Absolute Deviation* (MAD), *Mean Squared Error* (MSE), dan *Mean Absolute Percentage Error* (MAPE). Metrik ini digunakan untuk mengukur tingkat kesalahan dan ketepatan hasil peramalan, di mana nilai yang lebih kecil menunjukkan akurasi model yang lebih tinggi[21].

4. Hasil dan Pembahasan

4.1 Analisis Tren Penjualan

Hasil eksplorasi awal menunjukkan bahwa ketiga barang memiliki pola yang berbeda. Barang A18232202 menunjukkan tren penjualan paling stabil dengan variasi kecil di bawah 100 unit per hari. Barang A03012101 memperlihatkan fluktuasi sedang dengan kecenderungan naik-turun yang teratur, sedangkan A03012300 memiliki fluktuasi paling tinggi, bahkan mencapai lebih dari 700 unit pada periode puncak. Visualisasi tren penjualan ketiga barang dapat dilihat pada gambar 2 berikut




Gambar 2. Tren penjualan barang dari waktu ke waktu

Terlihat pada gambar 2 memperlihatkan pola fluktuasi yang berbeda beda tiap barang antar periode 2023 – 2024. secara umum, tren penjualan mencerminkan adanya variasi musiman yang memengaruhi kestabilan stok.


4.2 Hasil Prediksi

Prediksi kebutuhan persediaan barang dilakukan menggunakan dua pendekatan, yaitu *Long Short-Term Memory* (LSTM) dan *Moving Average* (MA), dengan periode *window* 14, 30, dan 60 hari. Kedua metode diterapkan pada tiga kode barang A18232202, A03012101, dan A03012300 untuk melihat sejauh mana masing-masing mampu menangkap pola perubahan penjualan harian. gambar berikut menampilkan perbandingan antara data aktual, hasil prediksi MA, dan hasil prediksi LSTM.




Gambar 3. Hasil prediksi LSTM , MA dan data aktual kode barang A18232202

Pada gambar 3 menampilkan perbandingan hasil prediksi barang A18232202. Pola penjualan cenderung stabil dengan fluktuasi rendah, sehingga baik LSTM maupun MA menghasilkan prediksi yang hampir sama dengan data aktual. MA memberikan kurva lebih halus, sedangkan LSTM sedikit lebih responsif terhadap variasi kecil yang terjadi pada data.



Gambar 4. Hasil prediksi LSTM , MA dan data aktual kode barang A03012101

Berbeda dengan gambar 4 yang menunjukkan hasil untuk barang A03012101, yang memiliki pola penjualan fluktuatif sedang. Model *LSTM* mampu mengikuti perubahan tren naik-turun dengan lebih baik dibandingkan *MA*, meskipun masih terdapat sedikit keterlambatan pada saat terjadi lonjakan cepat. Sebaliknya, *MA* menghasilkan pola prediksi yang lebih rata dan cenderung tertinggal dari data aktual.



Gambar 5. Hasil prediksi LSTM , MA dan data aktual kode barang A03012300

Kemudian pada gambar 5 memperlihatkan hasil prediksi barang A03012300 dengan pola penjualan yang sangat dinamis. *LSTM* berhasil menangkap sebagian besar variasi dan lonjakan permintaan, sementara *MA* menghasilkan prediksi yang lebih stabil namun kurang sensitif terhadap perubahan ekstrem. Hasil ini menunjukkan bahwa *LSTM* lebih adaptif pada pola data yang tidak menentu, sedangkan *MA* lebih sesuai untuk pola yang konsisten.

4.3 Evaluasi Hasil

Evaluasi dilakukan menggunakan tiga metrik utama, yaitu *Mean Absolute Deviation* (MAD), *Mean Squared Error* (MSE), dan *Mean Absolute Percentage Error* (MAPE). Hasil perbandingan kinerja metode *LSTM* dan *MA* terhadap tiga kode barang ditunjukkan pada Tabel 3 berikut.

Tabel 3. Metrik evaluasi model LSTM dan MA.

Barang	Metode	Window	MAD	MSE	MAD
A18232202	LSMT(16)	14	4,52	42,91	104,12 %
		30	4,52	42,93	102,82 %
	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	248,04%
		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 %

Sumber : Hasil Penelitian (2025).

Berdasarkan Tabel 3, barang A18232202 dengan pola penjualan stabil menunjukkan bahwa *LSTM* memiliki nilai *MAD* 4.52 dan *MSE* 42.91, jauh lebih kecil dibanding *MA* (*MAD* 52.59, *MSE* 6114.16), meskipun *MAPE LSTM* (104.12%) sedikit lebih tinggi dari *MA* (85.52%). Pada barang A03012101, kinerja keduanya relatif berdekatan dengan *MAD* 17–16 dan *MSE* ± 450 , namun *MAPE LSTM* (206.60%) lebih tinggi dibanding *MA* (168.91%), menunjukkan bahwa *LSTM* lebih adaptif terhadap tren, tetapi masih terdapat deviasi pada lonjakan tajam. Sementara itu, pada barang A03012300 yang paling fluktuatif, *LSTM* unggul dengan *MAPE* 248.04% dibanding *MA* 295.69%, menandakan kemampuannya lebih baik dalam mengikuti perubahan ekstrem. Secara keseluruhan, *LSTM* lebih unggul untuk pola penjualan dinamis, sedangkan *MA* lebih sesuai untuk data stabil, sehingga keduanya dapat digunakan secara komplementer dalam sistem prediksi stok.


4.3 Implementasi Prediksi

Model yang telah dilatih kemudian digunakan untuk memprediksi kebutuhan persediaan selama 30 hari ke depan, dengan hasil perbandingan antara data aktual, prediksi *LSTM*, dan *Moving Average* (MA) terhadap ketiga barang dapat dilihat pada gambar berikut ini.




Gambar 6. Hasil prediksi 30 hari kode barang A03012300

Pada gambar 6 menunjukkan hasil prediksi barang A18232202 yang memiliki pola penjualan stabil. Baik *LSTM* maupun *MA* menghasilkan kurva yang hampir berimpit dengan tren aktual, menunjukkan bahwa kedua metode mampu memberikan estimasi yang konsisten untuk pola data yang konstan.



Gambar 7. Hasil prediksi 30 hari kode barang A03012101

Sedangkan pada gambar 7 hasil prediksi barang A03012101 memperlihatkan bahwa *LSTM* lebih responsif terhadap perubahan tren dibandingkan *MA*. Kurva *LSTM* mengikuti variasi naik-turun dengan baik, sementara *MA* cenderung menghasilkan garis lebih halus dan tertinggal pada titik perubahan mendadak.



Gambar 8. Hasil prediksi 30 hari kode barang A03012300

Kemudian pada gambar 8 memperlihatkan hasil prediksi barang A03012300 dengan pola penjualan paling fluktuatif. *LSTM* mampu menangkap perubahan ekstrem dengan lebih akurat, sedangkan *MA* menghasilkan prediksi yang lebih stabil namun kurang merepresentasikan lonjakan permintaan.

6. Kesimpulan

Penelitian ini menunjukkan bahwa *metode Long Short-Term Memory (LSTM)* dan *Moving Average (MA)* dapat digunakan untuk memprediksi kebutuhan persediaan barang berdasarkan data penjualan historis di PT. Gunung Sari Indonesia. Hasil pengujian memperlihatkan bahwa *LSTM* lebih adaptif terhadap pola penjualan yang fluktuatif, dengan kemampuan mengikuti perubahan tren secara dinamis, sedangkan *MA* lebih stabil dan akurat untuk pola data yang konstan. Nilai evaluasi menunjukkan perbedaan performa antarbarang, di mana *LSTM* unggul pada data dinamis seperti A03012300, sementara *MA* lebih baik pada data stabil seperti A18232202. Temuan ini mendukung hipotesis bahwa model berbasis *deep learning* memiliki keunggulan pada data dengan variasi tinggi, namun metode konvensional masih relevan untuk pola yang konsisten. Implementasi gabungan kedua metode dapat membantu perusahaan dalam mengoptimalkan perencanaan stok dan mengurangi risiko kelebihan atau kekurangan persediaan.

Keterbatasan penelitian ini terletak pada jumlah data dan variabel yang terbatas pada penjualan historis; penelitian selanjutnya disarankan untuk menambahkan faktor eksternal seperti musim, promosi, dan kondisi pasar agar hasil prediksi menjadi lebih akurat dan kontekstual.

Referensi

- [1] G. Tamami and M. Arifin, "Penggunaan LSTM dalam Membangun Prediksi Penjualan untuk Aplikasi Laptop Lens," 2024, [Online]. Available: <https://www.kaggle.com/datasets/artakusuma/laptope>
- [2] M. L. Ashari and M. Sadiki, "PREDIKSI DATA TRANSAKSI PENJUALAN TIME SERIES MENGGUNAKAN REGRESI LSTM," 2020.
- [3] H. Priyandanu, M. Tabrani, and Z. Mutaqin, "MANAJEMEN PERSEDIAAN BAHAN BAKU BERBASIS PADA PT. TUFFINDO NITTOKU AUTONEUM KARAWANG," 2020.
- [4] Amrullah, Affandi Egi, Riansyah Wahyu, and Sobirin, "Peramalan Penjualan Bulanan menggunakan metode Trend Moment pada Toko Suamzu Boutique," *Jurnal Sains Manajemen Informatika dan Komputer*, vol. 19, no. 2, pp. 46–53, Aug. 2020, [Online]. Available: <https://ojs.trigunadharma.ac.id/>
- [5] R. Gunawan, M. B. Dimiliu, K. Valerine, and S. P. Tamba, "ANALISIS PREDIKSI PENJUALAN TOKO FURNITUR DENGAN METODE LONG SHORT-TERM MEMORY (LSTM)," *Jurnal Teknik Informasi dan Komputer (Tekinkom)*, vol. 7, no. 2, p. 716, Dec. 2024, doi: 10.37600/tekinkom.v7i2.1511.
- [6] F. Rahman Lutfi and C. Sasongko, "Perencanaan Produksi dan Manajemen Persediaan pada Perusahaan Kue dan Roti," *Studi Akuntansi dan Keuangan Indonesia*, vol. 5, no. 1, 2022.

- [7] A. Mahfud Al *et al.*, “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,” 2020.
- [8] E. Nur Cahyo and E. Susanti*, “Analisis Time Series Untuk Deep Learning Dan Prediksi Data Spasial Seismik: Studi Literatur,” *J Teknol*, vol. 15, no. 2, pp. 124–136, Jan. 2023, doi: 10.34151/jurtek.v15i2.3581.
- [9] C. Chazar and B. E. Widhiaputra, “INFORMASI (Jurnal Informatika dan Sistem Informasi) Machine Learning Diagnosis Kanker Payudara Menggunakan Algoritma Support Vector Machine,” 2020.
- [10] M. I. Faiza, Gunawan, and W. Andriani, “Tinjauan Pustaka Sistematis: Penerapan Metode Machine Learning untuk Deteksi Bencana Banjir,” Sep. 2022, doi: 10.33299/jpkop.22.2.1752.
- [11] D. I. Puteri, “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*, vol. 11, no. 1, pp. 35–43, May 2023, doi: 10.34312/euler.v11i1.19791.
- [12] B. Masih, “Recurrent neural network model for time series analysis *,” 2024.
- [13] R. Ardianto and S. Kartika Wibisono, “Analisis Deep Learning Metode Convolutional Neural Network Dalam Klasifikasi Varietas Gandum Analysis of Convolutional Neural Network Deep Learning Method in Durum Wheat Variety Classification,” vol. 6, 2023, doi: 10.56338/jks.v6i12.4938.
- [14] I. G. Anjani, A. B. Saputri, A. N. P. Armeira, and D. Januarita, “Analisis Konsumsi Dan Produksi Minyak Kelapa Sawit Di Indonesia Dengan Menerapkan Metode Moving Average,” *JURIKOM (Jurnal Riset Komputer)*, vol. 9, no. 4, p. 1014, Aug. 2022, doi: 10.30865/jurikom.v9i4.4506.
- [15] P. Huriati, A. Erianda, A. Alanda, D. Meidelfi, and A. Irma Suryani, “Implementation of the Moving Average Method for Forecasting Inventory in Cv. Tre Jaya Perkasa,” 2022.
- [16] R. Agung Permana and S. Sahara, “Prediksi Persediaan Barang Menggunakan Indikator Moving Average Studi Kasus Department Store Prediction of Goods Inventory Using the Moving Average Indicator, Department Store Case Study,” 2024.
- [17] B. Hakim, “Analisa Sentimen Data Text Preprocessing Pada Data Mining Dengan Menggunakan Machine Learning,” *JBASE - Journal of Business and Audit Information Systems*, vol. 4, no. 2, Aug. 2021, doi: 10.30813/jbase.v4i2.3000.
- [18] K. Maharana, S. Mondal, and B. Nemade, “A review: Data pre-processing and data augmentation techniques,” *Global Transitions Proceedings*, vol. 3, no. 1, pp. 91–99, Jun. 2022, doi: 10.1016/j.gltp.2022.04.020.
- [19] T. Gori, A. Sunyoto, and H. Al Fatta, “Preprocessing Data dan Klasifikasi untuk Prediksi Kinerja Akademik Siswa,” *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 1, pp. 215–224, Feb. 2024, doi: 10.25126/jtiik.20241118074.
- [20] R. Oktafiani, A. Hermawan, and D. Avianto, “Pengaruh Komposisi Split data Terhadap Performa Klasifikasi Penyakit Kanker Payudara Menggunakan Algoritma Machine Learning,” *Jurnal Sains dan Informatika*, pp. 19–28, Jun. 2023, doi: 10.34128/jsi.v9i1.622.
- [21] E. Sefry *et al.*, “Analisis Peramalan Persediaan Barang Menggunakan Metode Moving Average Dan Exponential Smoothing Pada CV. Sanjaya Bangun Pratama,” 2024.