

Raw Material Stock Prediction Using the Long Short-Term Memory Algorithm (Case Study: Mizan and Sunan Grilled Bread Producers)

Pipin Anjarwati^{1*}, Pipin Widyaningsih², Pramono³

^{1,2,3}Teknik Informatika, Fakultas Ilmu Komputer, Universitas Duta Bangsa Surakarta, Surakarta, 57154, Indonesia

Informasi Artikel

Diterima : 19 Juni 2025
Revisi : 21 Juli 2025
Publikasi : 30 September 2025

Kata Kunci:

Prediksi stok
Long Short-Term Memory (LSTM)
Waterfall
Manajemen persediaan
Python


ABSTRAK

Ketidakakuratan pengelolaan persediaan bahan baku menimbulkan inefisiensi operasional dan pemborosan biaya pada usaha mikro, kecil, dan menengah (UMKM), khususnya di industri kuliner yang permintaannya fluktuatif dan sulit diprediksi. Penelitian ini mengembangkan sistem prediksi kebutuhan stok bahan baku menggunakan algoritma *Long Short-Term Memory* (LSTM) dengan pendekatan pengembangan sistem *Waterfall*, studi kasus pada produsen roti bakar "Mizan dan Sunan" yang memiliki tujuh cabang. Dataset berupa data historis permintaan selama sembilan bulan dengan 5.142 entri dan delapan atribut utama. Pra-pemrosesan data dilakukan melalui normalisasi *Min-Max Scaling*, pembentukan data sekuensial dengan sliding window berdurasi tiga hari, serta pembagian data latih dan uji secara kronologis. Model LSTM dilatih untuk memprediksi kebutuhan stok harian, dengan evaluasi menggunakan *Mean Squared Error* (MSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Hasil menunjukkan MSE sebesar 403,28; MAE sebesar 10,38; dan MAPE sebesar 10,79%, menandakan akurasi prediksi yang baik. Kebaruan penelitian ini terletak pada penerapan model LSTM berbasis data historis multi-cabang UMKM kuliner dengan karakteristik permintaan fluktuatif, serta pengembangan sistem prediksi yang adaptif untuk mendukung pengambilan keputusan pengadaan stok secara presisi. Temuan ini membuktikan efektivitas LSTM sebagai solusi praktis berbasis data dalam pengelolaan logistik UMKM multi-cabang.

ABSTRACT

Inaccurate management of raw material inventory leads to operational inefficiency and cost overruns in micro, small, and medium enterprises (MSMEs), particularly in the culinary industry where demand is highly fluctuating and difficult to predict. This study develops a raw material stock prediction system using the Long Short-Term Memory (LSTM) algorithm with a Waterfall system development approach, applied to the case of "Mizan and Sunan" grilled bread producers operating across seven branches. The dataset consists of nine months of historical demand data, comprising 5,142 entries with eight main attributes. Data preprocessing includes Min-Max Scaling normalization, sequential data formation using a three-day sliding window, and chronological splitting of training and testing datasets. The LSTM model is trained to predict daily stock requirements, with evaluation conducted using Mean Squared Error (MSE), Mean Absolute Error (MAE), and Mean Absolute Percentage Error (MAPE). The results show an MSE of 403.28, MAE of 10.38, and MAPE of 10.79%, indicating good predictive accuracy. The novelty of this research lies in the application of an LSTM model based on multi-branch MSME culinary historical data characterized by fluctuating demand, along with the development of an adaptive prediction system to support precise procurement decision-making. These findings demonstrate the effectiveness of LSTM as a practical data-driven solution for inventory management in multi-branch MSME operations.

This is an open-access article under the [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license



***Penulis Koresponden**

Email: 210103140@mhs.udb.ac.id

Cara sitasi IEEE:

P. Anjarwati, P. Widyaningsih, & Pramono, "Raw Material Stock Prediction Using the Long Short-Term Memory Algorithm (Case Study: Mizan and Sunan Grilled Bread Producers)," *Journal of Artificial Intelligence and Software Engineering (J-AISE)*, vol. 5, no. 3, pp. 1296-1308, September 2025, doi: 10.30811/jaise.v5i3.7199

1. PENDAHULUAN

Pengelolaan persediaan bahan baku merupakan salah satu tantangan utama dalam industri makanan, khususnya bagi pelaku usaha mikro, kecil, dan menengah (UMKM). Ketidakstabilan stok bahan baku dapat menimbulkan berbagai kendala operasional, mulai dari kerugian akibat bahan yang kedaluwarsa hingga kehilangan potensi penjualan karena kekosongan produk [1]. Masalah ini sering kali disebabkan oleh ketidaktepatan dalam memprediksi kebutuhan bahan baku serta keterbatasan sistem manajemen stok yang digunakan. Beberapa UMKM di Indonesia juga mengalami kendala serupa dalam menyeimbangkan persediaan bahan baku dan permintaan konsumen. Penelitian pada UMKM pengolahan makanan di Rengasdengklok menunjukkan bahwa pelaku usaha sering mengalami penumpukan bahan baku yang tidak terpakai dan pemborosan biaya penyimpanan [2].

Pada UMKM kue kering "Caisy Cookies" di Bandung, kekurangan bahan baku dan keterlambatan produksi terjadi karena lonjakan permintaan musiman yang tidak terprediksi [3]. Sementara itu, UMKM "Chicken Fighter" di Yogyakarta menghadapi hambatan dalam pengendalian stok yang menyebabkan ketidaksesuaian jumlah bahan baku dengan kebutuhan produksi [4]. Ketiga studi tersebut mengindikasikan perlunya sistem pengelolaan persediaan yang lebih efisien dan akurat untuk meminimalkan kerugian akibat ketidakstabilan stok.

Permasalahan serupa juga dihadapi oleh usaha produsen roti bakar "Mizan dan Sunan" di Karanganyar, yang telah berkembang menjadi tujuh cabang aktif. Usaha ini menerapkan sistem distribusi bahan baku secara terpusat, yaitu seluruh kebutuhan bahan seperti roti, selai, margarin, krimer, dan *topping* didistribusikan dari satu pusat penyimpanan utama ke setiap cabang. Meskipun sistem ini bertujuan menjaga konsistensi dan efisiensi pengadaan, dalam praktiknya menimbulkan kendala dalam pengaturan stok di masing-masing cabang. Ketidaktepatan dalam memprediksi permintaan menyebabkan kelebihan stok yang berisiko tidak termanfaatkan dan kekurangan bahan yang menghambat kelancaran produksi. Kompleksitas permasalahan ini semakin meningkat akibat koordinasi antar cabang yang kurang efektif tanpa dukungan sistem prediksi yang andal, terutama ketika permintaan konsumen bersifat fluktuatif dan sulit diperkirakan.

Untuk mengatasi masalah pengelolaan stok yang kompleks ini, pemanfaatan teknologi kecerdasan buatan menjadi solusi yang relevan dan potensial. Salah satunya adalah algoritma *Long Short-Term Memory* (LSTM), yang efektif dalam mengolah data deret waktu (*time series*) dan mengenali pola jangka panjang, sehingga sangat cocok digunakan untuk memprediksi kebutuhan stok bahan baku [5]. *Long Short-Term Memory* (LSTM) memiliki tingkat akurasi prediksi yang lebih tinggi dibandingkan dengan metode konvensional seperti *Autoregressive Integrated Moving Average* (ARIMA) atau *Recurrent Neural Network* (RNN) [6]. Meskipun demikian, implementasi LSTM dalam sistem prediksi stok berbasis web yang mudah diakses dan ramah pengguna masih sangat terbatas [7].

Meskipun telah banyak studi yang menerapkan algoritma LSTM dalam prediksi *time series*, sebagian besar penelitian tersebut berfokus pada skenario *single-site* atau data homogen dengan cakupan cabang tunggal, serta tidak secara khusus mengkaji kompleksitas operasional multi-cabang UMKM dengan variasi karakteristik permintaan di setiap unit usaha. Di sisi lain, mayoritas implementasi LSTM dalam pengelolaan stok bahan baku umumnya hanya terbatas pada model prediksi, tanpa diintegrasikan ke dalam sistem pendukung keputusan yang adaptif dan berbasis web. Oleh karena itu, terdapat gap penelitian pada pengembangan sistem prediksi stok berbasis LSTM yang mampu menangani data historis multi-cabang secara komprehensif, sekaligus diimplementasikan dalam platform digital yang praktis untuk memudahkan manajemen distribusi bahan baku secara terpusat di lingkungan UMKM kuliner. Posisi unik penelitian ini terletak pada kombinasi antara penerapan model LSTM dengan konfigurasi data multi-cabang, pengembangan sistem berbasis web

yang mudah diakses oleh manajemen usaha, serta studi kasus pada industri roti bakar sebagai representasi sektor kuliner UMKM yang menghadapi dinamika permintaan harian yang fluktuatif.

Berdasarkan permasalahan di atas, penelitian ini bertujuan untuk merancang dan mengembangkan sistem prediksi kebutuhan stok bahan baku menggunakan algoritma *Long Short-Term Memory* (LSTM) berbasis *website*, dengan studi kasus pada usaha produsen roti bakar “Mizan dan Sunan”. Sistem ini membantu pelaku usaha memprediksi kebutuhan bahan baku dengan lebih akurat dan efisien, serta mempermudah koordinasi distribusi antar cabang melalui *platform* digital yang mudah diakses. Dengan demikian, sistem yang dibangun dapat menjadi solusi praktis dan aplikatif untuk meningkatkan efektivitas pengelolaan stok, dan dapat diadaptasi oleh UMKM kuliner lainnya yang menghadapi tantangan serupa dalam produksi.

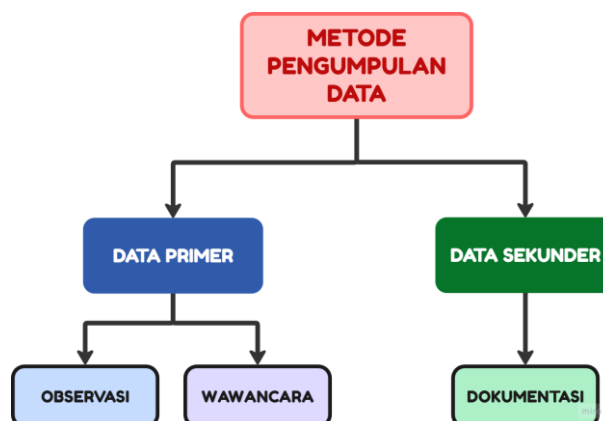
2. METODE

2.1. Jenis dan Sumber Data

Data yang digunakan dalam penelitian ini merupakan data sekunder berupa catatan historis permintaan bahan baku dari tujuh cabang usaha roti bakar “Mizan dan Sunan” selama sembilan bulan terakhir. Data ini mencakup jenis bahan baku utama seperti roti, selai, *topping*, krimer, margarin, dan kertas box. Informasi permintaan dicatat secara manual oleh masing-masing pengelola cabang, baik melalui buku catatan maupun komunikasi langsung via WhatsApp dengan pihak produsen. Interval pencatatan bervariasi, yaitu setiap 1 hingga 3 hari, tergantung pada frekuensi permintaan dari masing-masing cabang. Data manual tersebut digunakan sebagai dasar dalam proses prediksi kebutuhan stok bahan baku dengan menerapkan algoritma *Long Short-Term Memory* (LSTM).

2.2. Metode Pengumpulan Data

Gambar 1 menyajikan skema metode pengumpulan data yang digunakan dalam penelitian ini untuk mendukung proses analisis prediksi kebutuhan bahan baku secara akurat dan relevan. Pengumpulan data dilakukan melalui dua jenis sumber, yaitu data primer dan data sekunder, guna memperoleh informasi komprehensif terkait proses distribusi dan permintaan bahan baku pada setiap cabang usaha.



Gambar 1. Diagram Alur Metode Pengumpulan Data

2.2.1. Data Primer

Data primer adalah data yang dikumpulkan langsung oleh peneliti dari sumber pertama melalui interaksi atau pengamatan lapangan [8]. Dalam penelitian ini, data primer diperoleh melalui:

- a. **Observasi**, dilakukan secara langsung terhadap proses pencatatan dan distribusi bahan baku di setiap cabang guna memperoleh pemahaman faktual atas alur operasional yang berjalan.
- b. **Wawancara**, dilakukan dengan pemilik usaha dan pengelola cabang untuk menggali informasi terkait kebijakan pengadaan bahan, hambatan distribusi, serta strategi pengelolaan stok yang diterapkan.

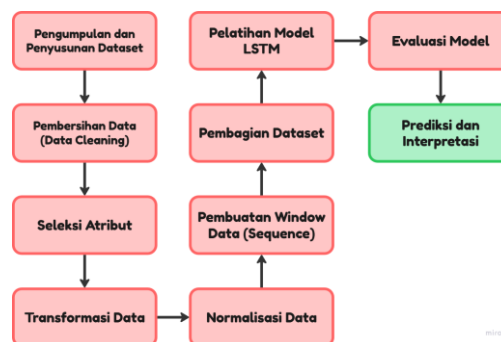
2.2.2. Data Sekunder

Data sekunder merupakan data yang diperoleh dari dokumen yang telah tersedia sebelumnya dan bukan dikumpulkan langsung oleh peneliti [9]. Dalam penelitian ini, data sekunder diperoleh melalui dokumentasi seperti catatan permintaan bahan baku, data stok harian, laporan distribusi, serta komunikasi digital antara produsen dan cabang. Data ini digunakan untuk memperkuat temuan dari observasi dan wawancara, sekaligus menjadi dasar pembentukan dataset pada tahap analisis.

2.3. Metode Pengolahan Data

Sebagai bagian dari tahap pra-pemodelan, dilakukan pengumpulan dan penyusunan dataset yang menjadi dasar pelatihan model prediksi berbasis algoritma *Long Short-Term Memory* (LSTM). Dataset diperoleh dari arsip internal produsen usaha “Mizan dan Sunan”, mencakup transaksi permintaan bahan baku dari tujuh cabang selama bulan Agustus 2024 hingga Mei 2025. Dataset terdiri dari delapan atribut yang meliputi:

1. tanggal : waktu pencatatan transaksi
2. cabang : nama cabang yang melakukan permintaan
3. bahan_baku: jenis bahan baku yang diminta
4. jumlah_keluar: jumlah bahan baku yang didistribusikan
5. satuan: satuan pengukuran (pcs atau kg)
6. harga_satuan: harga per satuan bahan baku
7. total_harga: total nilai transaksi
8. nama_pengelola: pihak yang bertanggung jawab atas permintaan di tiap cabang



Gambar 2. Diagram Alur Metode Pengolahan Data

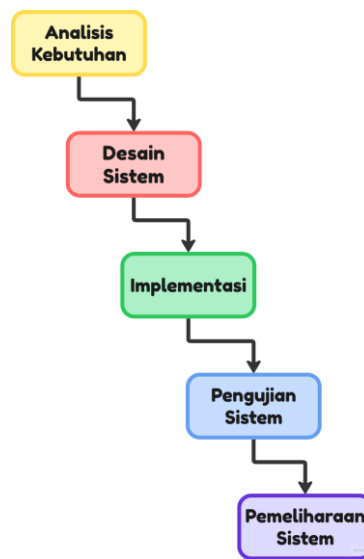
Data yang telah dikumpulkan kemudian dianalisis untuk mengidentifikasi pola permintaan yang fluktuatif pada masing-masing cabang. Tahapan analisis tersebut ditunjukkan pada Gambar 2, yang dimulai dari pembersihan data, seperti penghapusan duplikasi, penanganan nilai kosong, dan deteksi anomali. Setelah itu, dilakukan pemilihan atribut yang relevan untuk keperluan prediksi, antara lain tanggal, cabang, bahan baku, dan jumlah permintaan. Selanjutnya, data ditransformasikan ke dalam format deret waktu (*time series*) agar sesuai dengan kebutuhan model LSTM, termasuk pembentukan urutan *input-output* berdasarkan rentang waktu historis tertentu.

Atribut kategori seperti nama cabang dan jenis bahan baku dikodekan menggunakan metode label *encoding* agar dapat diproses oleh model prediksi. Data kemudian dinormalisasi dengan *Min-Max Scaling* untuk menyamakan skala nilai numerik pada setiap atribut. Setelah tahap praproses, dataset dibagi secara berurutan berdasarkan waktu menjadi dua bagian, yaitu 80% untuk data pelatihan dan 20% untuk data pengujian. Model LSTM dilatih menggunakan data sekuensial tersebut untuk mengenali pola permintaan bahan baku dan melakukan prediksi jumlah kebutuhan di masa mendatang. Evaluasi model dilakukan dengan membandingkan hasil prediksi terhadap data aktual menggunakan tiga metrik utama, yaitu *Mean Absolute Percentage Error* (MAPE) untuk mengukur persentase kesalahan, *Mean Absolute Error* (MAE) untuk menghitung rata-rata selisih absolut, dan *Mean Squared Error* (MSE) untuk menilai rata-rata kuadrat dari selisih antara nilai aktual dan prediksi. Ketiga metrik ini digunakan untuk memperoleh gambaran yang lebih komprehensif terhadap akurasi dan keandalan model dalam memprediksi permintaan stok bahan baku.

2.4. Metode Pengembangan Sistem

Metode pengembangan sistem yang digunakan dalam penelitian ini adalah metode *Waterfall*, yaitu pendekatan terstruktur yang dilakukan secara berurutan mulai dari analisis kebutuhan, desain, implementasi, pengujian, hingga pemeliharaan sistem. Metode ini dipilih karena sesuai dengan karakteristik proyek yang memiliki ruang lingkup kebutuhan yang jelas sejak awal, serta tahapan kerja yang linear dan terdefinisi dengan baik [10].

Visualisasi tahapan metode *Waterfall* dalam penelitian ini disajikan pada Gambar 3, yang menggambarkan alur proses pengembangan sistem mulai dari analisis kebutuhan hingga pemeliharaan.

Gambar 3. Alur Metode *Waterfall*

2.4.1. Analisis Kebutuhan

Tahap analisis kebutuhan dilakukan untuk mengidentifikasi elemen-elemen utama yang diperlukan dalam pengembangan sistem, baik dari sisi teknis maupun kebutuhan pengguna. Kebutuhan fungsional yang dianalisis mencakup kemampuan sistem untuk menerima *input* data permintaan bahan baku dari masing-masing cabang, menyimpan data secara terstruktur, serta menghasilkan *output* dalam bentuk informasi yang dapat digunakan untuk mendukung proses perencanaan.

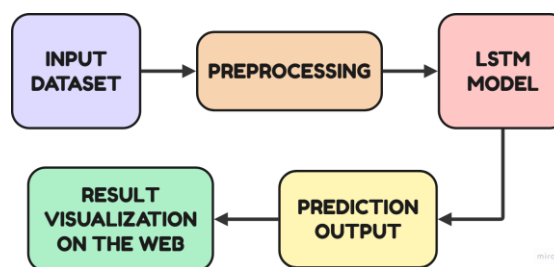
Sementara itu, kebutuhan non-fungsional mencakup kemudahan penggunaan antarmuka, kecepatan proses prediksi, serta keandalan sistem dalam menampilkan hasil yang akurat. Sistem ini ditujukan bagi produsen pusat sebagai pengguna utama, yang akan memasukkan data permintaan dan menggunakan hasil prediksi untuk merencanakan distribusi bahan baku secara efisien. Oleh karena itu, analisis kebutuhan ini menjadi fondasi dalam merancang sistem yang sesuai dengan kebutuhan pengguna dan mendukung kelancaran operasional bisnis.

2.4.2. Desain Sistem

Desain sistem prediksi stok bahan baku terdiri atas dua bagian utama, yaitu antarmuka pengguna (*frontend*) dan pemrosesan data serta model prediksi (*backend*). Antarmuka pengguna dikembangkan dengan fokus pada kesederhanaan dan kemudahan navigasi, sehingga pengguna dapat memasukkan data serta mengakses hasil prediksi secara intuitif. Informasi hasil prediksi ditampilkan dalam bentuk tabel dan grafik untuk memudahkan interpretasi oleh pengguna.

Sementara itu, bagian *backend* mencakup proses prapengolahan data, pelatihan model *Long Short-Term Memory* (LSTM) menggunakan bahasa pemrograman Python, serta pengintegrasian model prediksi ke dalam sistem berbasis web. Pustaka yang digunakan meliputi *NumPy*, *Pandas*, *TensorFlow*, dan *Keras*. Alur kerja *backend* disusun agar data yang dimasukkan dapat diproses otomatis dan hasilnya langsung ditampilkan pada antarmuka.


Gambar 4 memperlihatkan keseluruhan arsitektur sistem, mulai dari input data oleh pengguna, pemrosesan prediktif di sisi server, hingga visualisasi hasil melalui antarmuka web.



Gambar 4. Diagram Arsitektur Sistem Prediksi

Selama proses pelatihan, data validasi diambil dari subset data uji yang telah dipisahkan sebelumnya. Model dilatih menggunakan data *input* sekuensial tiga *time steps* hasil pra-pemrosesan *sliding window*, dengan

target berupa nilai jumlah keluar pada hari berikutnya. Gambar 5 memperlihatkan arsitektur sederhana model LSTM yang digunakan dalam penelitian ini.



Gambar 5. Arsitektur Model LSTM

2.4.3. Implementasi

Tahap implementasi dilakukan berdasarkan struktur sistem yang telah disusun sebelumnya. *Backend* dibangun menggunakan Python dan pustaka pendukung seperti *TensorFlow* dan *Keras*, sedangkan *frontend* dikembangkan menggunakan HTML, CSS, dan JavaScript untuk menyediakan antarmuka yang responsif dan mudah dioperasikan.

Data historis yang dikumpulkan dari produsen diproses ke dalam format deret waktu dan digunakan untuk pelatihan serta pengujian model LSTM. Sistem dikembangkan agar mampu menerima *input* baru dari pengguna dan menghasilkan prediksi secara langsung (*real-time*). Sebelum sistem digunakan secara penuh, dilakukan pengujian awal untuk memastikan bahwa setiap fitur berjalan sesuai dengan kebutuhan.

2.4.4. Pengujian Sistem

Pengujian dilakukan untuk memastikan bahwa fungsi dan performa sistem sesuai dengan spesifikasi yang telah ditentukan. Uji fungsionalitas diterapkan dengan metode *black-box testing* terhadap fitur utama seperti *input* data, pemrosesan prediksi, dan tampilan hasil. Akurasi model diuji menggunakan tiga metrik evaluatif: *Mean Absolute Percentage Error* (MAPE), *Mean Absolute Error* (MAE), dan *Mean Squared Error* (MSE), guna mendapatkan gambaran yang menyeluruh terhadap performa model prediksi.

Selain itu, pengujian pengguna dilakukan dengan melibatkan pihak produsen pusat untuk menilai aspek kemudahan penggunaan, kejelasan tampilan, serta efektivitas hasil prediksi dalam mendukung pengambilan keputusan operasional.

2.4.5. Pemeliharaan Sistem

Selama masa operasional, sistem dipantau secara berkala untuk mendeteksi potensi bug dan memastikan kinerja tetap optimal. Penyesuaian juga dilakukan apabila terdapat perubahan kebutuhan pengguna atau dinamika permintaan bahan baku, sehingga sistem tetap relevan dan adaptif terhadap kondisi usaha yang terus berkembang.

3. HASIL DAN PEMBAHASAN

Pengembangan sistem prediksi stok bahan baku dalam penelitian ini dilakukan secara sistematis dengan menggunakan pendekatan *Waterfall*, dimana algoritma *Long Short-Term Memory* (LSTM) digunakan sebagai inti dari model prediksi. Proses pengembangan mencakup beberapa tahapan berurutan, meliputi analisis kebutuhan, perancangan sistem, implementasi model, serta pengujian dan evaluasi performa model prediksi.

Pemanfaatan algoritma LSTM didasarkan pada kemampuannya dalam mempelajari pola deret waktu secara mendalam, khususnya dalam mengidentifikasi tren musiman maupun fluktuasi harian yang terjadi pada penggunaan bahan baku di masing-masing cabang produksi [11]. Keunggulan LSTM dalam mempertahankan

informasi jangka panjang memungkinkan model memetakan hubungan temporal yang kompleks dari data historis operasional.

Evaluasi performa model dilakukan menggunakan metrik *Mean Squared Error* (MSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE), yang secara kuantitatif merepresentasikan tingkat akurasi prediksi model dalam memetakan kebutuhan bahan baku. Pembahasan hasil dilakukan secara kritis, tidak hanya untuk menilai efektivitas model berdasarkan capaian metrik numerik, namun juga untuk mengkaji relevansi implementasi model dalam mendukung pengambilan keputusan perencanaan pengadaan stok secara praktis di lingkungan bisnis operasional.

3.1. Karakteristik Dataset

Dataset penelitian ini terdiri atas 5.142 baris data yang merepresentasikan catatan historis penggunaan bahan baku harian pada tujuh cabang produsen roti bakar, yaitu Mizan, Sunan Nglarangan, Sunan Ngringo, Sunan Papahan, Sunan Taman Pancasila, Sunan Sembungan, dan Sunan Bekonang. Data dikumpulkan selama periode 29 Agustus 2024 hingga 13 Mei 2025 dan terdiri atas 8 atribut, meliputi informasi kategorikal (*tanggal, cabang toko, jenis bahan baku, satuan, dan nama pengelola*) serta numerik (*jumlah keluar, harga satuan, dan total harga*). Variabel jumlah keluar dipilih sebagai target prediksi karena mencerminkan konsumsi aktual bahan baku, yang secara langsung berkaitan dengan perencanaan pengadaan stok. Distribusi jumlah entri per cabang disajikan pada Tabel 1 berikut:

Tabel 1. Distribusi Jumlah Entri per Cabang

No	Nama Cabang	Jumlah Entri	Persentase(%)
1	Mizan	1536	29,87%
2	Sunan Nglarangan	892	17,35%
3	Sunan Ngringo	451	8,77%
4	Sunan Papahan	552	10,74%
5	Sunan Taman Pancasila	833	16,20%
6	Sunan Sembungan	612	11,90%
7	Sunan Bekonang	266	5,17%
Total		5.142	100%

Distribusi ini menunjukkan bahwa meskipun data terdistribusi ke seluruh cabang, terdapat dominasi entri dari cabang Mizan. Ketimpangan ini berpotensi memengaruhi kemampuan generalisasi model jika tidak diantisipasi melalui teknik penyeimbangan data (*data balancing*) atau segmentasi berdasarkan lokasi. Oleh karena itu, strategi pemodelan perlu mempertimbangkan proporsi ini agar tidak menimbulkan bias terhadap cabang dengan jumlah entri yang dominan.

Untuk menggambarkan struktur dataset, Tabel 2 menyajikan cuplikan entri data harian dari berbagai cabang. Setiap entri merepresentasikan penggunaan bahan baku aktual, lengkap dengan informasi jumlah keluar, satuan, harga satuan, total harga, serta nama pengelola yang bertanggung jawab atas pencatatan transaksi.

Tabel 2. Entri Data Harian Semua Cabang

Tanggal	Cabang	Bahan Baku	Jumlah Keluar	Satuan	Harga Satuan	Total Harga	Nama Pengelola
2024-08-29	Sunan Sembungan	Coklat	1	kg	Rp40.000	Rp40.000	Sugiyanto
2024-08-29	Sunan Sembungan	Meses	1,5	kg	Rp24.000	Rp36.000	Sugiyanto
2024-08-29	Sunan Sembungan	Roti	35	pcs	Rp4.300	Rp150.500	Sugiyanto
2024-09-01	Sunan Nglarangan	Kardus	20	pcs	Rp650	Rp13.000	Galuh Mahendra
2024-09-02	Sunan Taman Pancasila	Roti	15	pcs	Rp4.300	Rp64.500	Endang
2024-09-03	Sunan Nglarangan	Strawberry	0,5	kg	Rp20.000	Rp10.000	Galuh Mahendra
2025-05-13	Mizan	Roti	57	pcs	Rp4.300	Rp245.100	Joko Wahyono
....
2025-05-13	Mizan	Taro	0,25	kg	Rp48.000	Rp12.000	Joko Wahyono

3.2. Pra-pemrosesan Data

Pra-pemrosesan data dilakukan untuk memastikan kualitas dataset dan kesiapan data sebagai *input* model prediksi [12]. Langkah awal diawali dengan pemeriksaan kelengkapan data untuk mengidentifikasi keberadaan nilai kosong (*missing values*) atau entri duplikat. Pemeriksaan menunjukkan bahwa dataset tidak mengandung nilai kosong maupun duplikasi, sehingga tidak memerlukan proses imputasi atau pembersihan data tambahan.

Selanjutnya, dilakukan normalisasi pada atribut numerik menggunakan metode *Min-Max Scaling* untuk mengubah rentang nilai jumlah keluar, harga satuan, dan total harga ke dalam skala [0,1]. Normalisasi ini penting karena model *Long Short-Term Memory* (LSTM) sensitif terhadap perbedaan skala antar fitur, yang dapat memengaruhi stabilitas proses pembelajaran.

Untuk mempersiapkan data dalam format sekuensial sesuai kebutuhan arsitektur LSTM, diterapkan teknik *sliding window* dengan panjang jendela tiga hari, yaitu memanfaatkan data dari tiga hari sebelumnya untuk memprediksi kebutuhan bahan baku pada hari keempat. Penggunaan metode *sliding window* memungkinkan model LSTM menangkap pola keterkaitan antar periode waktu sebelumnya, sehingga dapat mempelajari dependensi jangka pendek yang relevan dengan dinamika kebutuhan stok bahan baku.

Langkah terakhir pada tahap pra-pemrosesan adalah pembagian data menjadi data latih (80%) dan data uji (20%), dilakukan secara berurutan berdasarkan kronologi waktu [13]. Strategi ini penting untuk menjaga integritas hubungan temporal antar data, sekaligus mencegah kebocoran data (*data leakage*) yang dapat mengganggu validitas evaluasi model.

Untuk memperjelas proses ini, kode pra-pemrosesan data disajikan pada Gambar 6.

```

from sklearn.model_selection import train_test_split
from sklearn.preprocessing import MinMaxScaler
import numpy as np

# Split data
train, test = train_test_split(daily_sales, test_size=0.2, shuffle=False)

# Scaling
scaler = MinMaxScaler()
train_scaled = scaler.fit_transform(train[['jumlah_keluar']])
test_scaled = scaler.transform(test[['jumlah_keluar']])

scale_min = scaler.data_min_[0]
scale_max = scaler.data_max_[0]

train_scaled = np.array(train_scaled)
test_scaled = np.array(test_scaled)

# Window size untuk dataset time series
window_size = 3

def create_dataset(dataset, window_size):
    X, y = [], []
    for i in range(len(dataset) - window_size):
        a = dataset[i:(i + window_size), 0]
        X.append(a)
        y.append(dataset[i + window_size, 0])
    return np.array(X), np.array(y)

# Membuat dataset training dan testing
X_train, y_train = create_dataset(train_scaled, window_size)
X_test, y_test = create_dataset(test_scaled, window_size)

```

Gambar 6. Kode Pra-Pemrosesan Data

3.3. Pengembangan Model LSTM

Setelah tahap pra-pemrosesan data selesai, langkah berikutnya adalah membangun model prediksi berbasis algoritma *Long Short-Term Memory* (LSTM). LSTM merupakan varian dari *Recurrent Neural Network* (RNN) yang dirancang khusus untuk memproses data berurutan dan mempertahankan informasi dari periode waktu sebelumnya [14]. Keunggulan utama LSTM terletak pada kemampuannya mengatasi permasalahan *vanishing gradient* yang sering terjadi pada jaringan RNN konvensional, sehingga efektif dalam

mempelajari pola temporal jangka pendek maupun jangka panjang, termasuk dalam kasus prediksi kebutuhan stok bahan baku.

Model LSTM pada penelitian ini dirancang dengan arsitektur sederhana guna menjaga stabilitas pembelajaran dan menghindari risiko *overfitting*, mengingat volume data yang terbatas. Arsitektur model terdiri atas satu lapisan LSTM dengan 50 unit neuron menggunakan fungsi aktivasi *tanh*, diikuti oleh lapisan output *Dense layer* dengan satu neuron untuk menghasilkan nilai prediksi jumlah keluar. Proses optimasi parameter dilakukan menggunakan algoritma *Adam optimizer*, dengan fungsi kerugian *Mean Squared Error* (MSE) yang sesuai untuk permasalahan regresi deret waktu.

Model dikembangkan menggunakan *library Keras* pada framework *TensorFlow*. Proses pelatihan model dijalankan dengan batas maksimal 100 epoch menggunakan ukuran batch sebesar 16. Untuk mencegah terjadinya *overfitting*, diterapkan mekanisme *Early Stopping* dengan *patience* selama 5 epoch, yang secara otomatis menghentikan pelatihan apabila nilai validasi *loss* tidak menunjukkan perbaikan. Mekanisme ini penting mengingat fluktuasi data deret waktu yang cenderung menyebabkan variabilitas performa antar epoch, sehingga *monitoring* performa validasi secara dinamis diperlukan untuk memastikan generalisasi model tetap optimal.

Untuk memperjelas implementasi model, Gambar 7 berikut menampilkan kode program pengembangan model LSTM yang digunakan dalam penelitian ini.

```
from tensorflow.keras.models import Sequential
from tensorflow.keras.optimizers import Adam
from tensorflow.keras import layers
from tensorflow.keras.callbacks import EarlyStopping

# Membuat model LSTM
model = Sequential()
model.add(layers.LSTM(50, activation='tanh', input_shape=(window_size,
1)))
model.add(layers.Dense(1))

# Callback EarlyStopping
callbacks = [
    EarlyStopping(monitor='val_loss', patience=5,
restore_best_weights=True)
]

# Compile model
model.compile(optimizer='adam', loss='mse')

# Training model
model.fit(
    X_train, y_train,
    epochs=100,
    batch_size=16,
    validation_data=(X_test, y_test),
    callbacks=callbacks
)

# Evaluasi model
model.evaluate(X_test, y_test)

# Prediksi
y_pred = model.predict(X_test)

# Inverse transform hasil prediksi dan ground truth
y_pred = scaler.inverse_transform(y_pred.reshape(-1, 1))
y_test = scaler.inverse_transform(y_test.reshape(-1, 1))

# Mengambil tanggal aktual (untuk keperluan visualisasi nantinya)
tanggal_aktual = test['tanggal'].values[window_size:]
```

Gambar 7. Kode Model LSTM

3.4. Visualisasi Hasil Prediksi

Setelah model LSTM selesai dilatih dan menghasilkan prediksi terhadap data uji, dilakukan visualisasi hasil prediksi sebagai bagian dari evaluasi kinerja model secara kualitatif. Visualisasi ini bertujuan untuk mengevaluasi sejauh mana hasil prediksi mengikuti pola data aktual yang bersifat fluktuatif secara harian.

Gambar 8 memperlihatkan kode program yang digunakan untuk menghasilkan grafik perbandingan antara hasil prediksi dan data aktual dalam proses evaluasi kinerja model.

```

import matplotlib.pyplot as plt

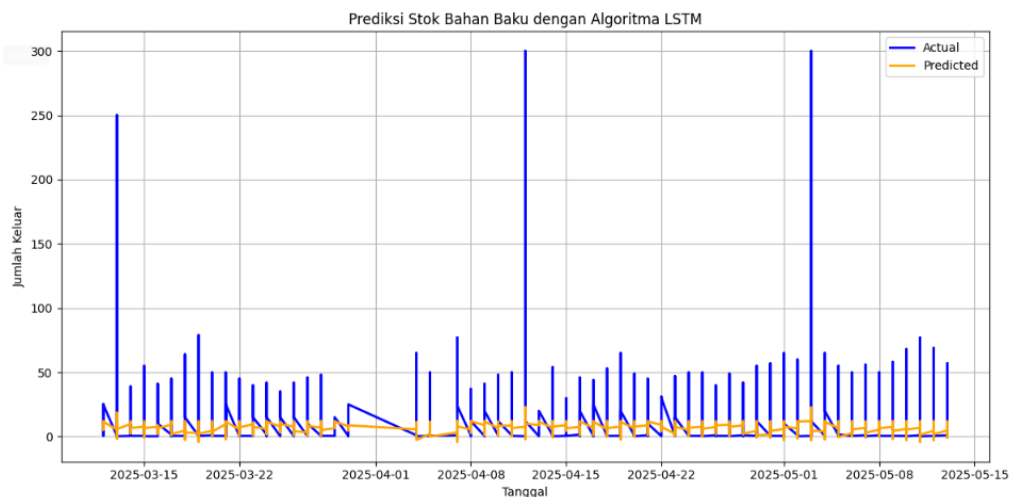
plt.figure(figsize=(12, 6))
plt.plot(tanggal_aktual, y_test.flatten(), label='Actual', color='blue',
linewidth=2)
plt.plot(tanggal_aktual, y_pred.flatten(), label='Predicted',
color='orange', linewidth=2)

plt.xlabel('Tanggal')
plt.ylabel('Jumlah Keluar')
plt.title('Prediksi Stok Bahan Baku dengan Algoritma LSTM')
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.show()

```

Gambar 8. Kode Visualisasi Hasil Prediksi

Visualisasi hasil prediksi disajikan pada Gambar 9. Pada grafik tersebut, garis berwarna biru merepresentasikan data aktual jumlah bahan baku yang keluar, sedangkan garis oranye menunjukkan hasil prediksi yang dihasilkan oleh model LSTM. Secara umum, model mampu mengikuti pola tren perubahan kebutuhan stok bahan baku dari waktu ke waktu, baik saat terjadi lonjakan maupun penurunan permintaan. Pola global yang dihasilkan model memperlihatkan kecenderungan yang cukup konsisten dengan pergerakan data aktual, yang mengindikasikan bahwa model berhasil mempelajari hubungan temporal pada data historis.



Gambar 9. Grafik Perbandingan Data Aktual dan Hasil Prediksi Model LSTM

Meskipun demikian, beberapa deviasi minor masih terlihat pada titik-titik tertentu, yang kemungkinan dipengaruhi oleh faktor eksternal yang tidak dimasukkan ke dalam model, seperti adanya promosi penjualan, fluktuasi pesanan mendadak, ataupun variasi pasokan logistik. Dengan demikian, visualisasi ini berperan sebagai indikator awal keberhasilan model dalam mempelajari dependensi temporal yang menjadi karakteristik utama data deret waktu pada sistem prediksi kebutuhan stok. Evaluasi kinerja model secara kuantitatif selanjutnya dibahas pada sub bab berikutnya.

3.5. Evaluasi Hasil Prediksi

Untuk mengukur kinerja model LSTM secara kuantitatif, dilakukan evaluasi menggunakan beberapa metrik regresi, yaitu *Mean Squared Error* (MSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE) [15]. Metrik-metrik ini dipilih karena mampu merepresentasikan besarnya kesalahan prediksi dari berbagai sudut pandang, baik dalam skala absolut, kuadrat kesalahan, maupun dalam bentuk persentase relatif terhadap data aktual.

Perhitungan nilai *error* dilakukan menggunakan *library Scikit-Learn*, yang menyediakan fungsi evaluasi regresi secara komprehensif. Kode perhitungan evaluasi kinerja model ditunjukkan pada Gambar 10 berikut:

```

from sklearn.metrics import mean_squared_error, mean_absolute_error,
mean_absolute_percentage_error

# Hitung nilai error menggunakan data yang sudah inverse scaling
mse = mean_squared_error(y_test, y_pred)
mae = mean_absolute_error(y_test, y_pred)
mape = mean_absolute_percentage_error(y_test, y_pred)

# Cetak hasil evaluasi
print('MSE :', mse)
print('MAE :', mae)
print('MAPE :', mape)

```

Gambar 10. Kode Evaluasi Hasil Prediksi

Berdasarkan hasil evaluasi, diperoleh nilai MSE sebesar 403.28, MAE sebesar 10.38, dan MAPE sebesar 10.79%. Nilai MSE menunjukkan bahwa rata-rata kuadrat kesalahan prediksi relatif kecil, yang menandakan bahwa model cukup berhasil meminimalisir deviasi besar antara hasil prediksi dan data aktual. Nilai MAE mengindikasikan bahwa rata-rata kesalahan absolut prediksi hanya sekitar ± 10 unit bahan baku per hari, baik dalam satuan kilogram maupun pcs, bergantung pada jenis bahan baku yang diprediksi.

Sementara itu, nilai MAPE sebesar 10.79% menunjukkan bahwa tingkat kesalahan relatif model tergolong rendah. Umumnya, dalam studi prediksi deret waktu operasional, MAPE di bawah 15% dapat dikategorikan sebagai prediksi dengan tingkat akurasi yang baik. Dengan capaian MAPE tersebut, model LSTM yang dikembangkan dalam penelitian ini dapat dikatakan cukup akurat dan stabil dalam memetakan pola kebutuhan stok bahan baku harian.

Gambar 11 menunjukkan kode penyusunan tabel evaluasi prediksi, meliputi data aktual, hasil prediksi, selisih prediksi, dan nilai MAPE.

```

import pandas as pd
import numpy as np

# Membuat DataFrame hasil prediksi
hasil_prediksi = pd.DataFrame({
    'Tanggal': tanggal_aktual,
    'Data Aktual': y_test.flatten(),
    'Data Prediksi': y_pred.flatten()
})

# Hitung Selisih Prediksi (Prediksi - Aktual)
hasil_prediksi['Selisih Prediksi'] = hasil_prediksi['Data Prediksi']
- hasil_prediksi['Data Aktual']

# Hitung MAPE per data
hasil_prediksi['MAPE'] = np.abs(hasil_prediksi['Selisih Prediksi'] /
hasil_prediksi['Data Aktual']) * 100

# Tampilkan tabel hasil
print(hasil_prediksi)

```

Gambar 11. Kode Tabel Evaluasi Hasil Prediksi

Tabel 3 menyajikan hasil prediksi secara kuantitatif. Hasil ini menunjukkan akurasi prediksi yang memadai untuk mendukung pengambilan keputusan pengadaan stok bahan baku secara efisien menghadapi dinamika permintaan.

Tabel 3. Hasil Prediksi

Tanggal	Data Aktual	Data Prediksi	Selisih Prediksi	MAPE (%)
2025-03-08	0.50	0.67	0.17	34.69
2025-03-08	0.50	0.67	0.17	34.69
2025-03-09	0.50	0.67	0.17	34.69
2025-03-09	0.50	0.67	0.17	34.69
2025-03-09	0.50	0.67	0.17	34.69
2025-03-10	0.50	0.67	0.17	34.69
2025-03-10	0.50	0.67	0.17	34.69
2025-03-11	1.00	0.67	-0.33	32.66

Tanggal	Data Aktual	Data Prediksi	Selisih Prediksi	MAPE (%)
2025-03-12	0.50	0.64	0.14	27.38
2025-03-12	0.50	0.67	0.17	34.07
2025-03-13	1.00	0.69	-0.31	30.72
2025-03-14	0.50	0.64	0.14	27.38
...
2025-05-13	0.25	0.33	0.08	32

Secara keseluruhan, hasil evaluasi kuantitatif konsisten dengan visualisasi prediksi sebelumnya, di mana model mampu mengikuti fluktuasi kebutuhan stok. Dengan performa prediksi yang diperoleh, model LSTM dapat diimplementasikan sebagai alat bantu dalam pengambilan keputusan pengadaan stok bahan baku secara terukur dan adaptif terhadap dinamika permintaan operasional.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, sistem prediksi kebutuhan stok bahan baku berbasis algoritma *Long Short-Term Memory* (LSTM) berhasil dikembangkan dengan pendekatan pengembangan sistem *Waterfall*. Melalui pengolahan data historis penggunaan bahan baku dari tujuh cabang produsen roti bakar selama periode sembilan bulan, sistem mampu mempelajari pola deret waktu kebutuhan bahan baku yang bersifat fluktuatif. Tahap pra-pemrosesan data meliputi normalisasi *Min-Max Scaling*, pembentukan data sekuensial menggunakan teknik *sliding window*, serta pembagian data latih dan data uji secara kronologis untuk menjaga integritas temporal.

Hasil evaluasi menunjukkan bahwa model LSTM yang dikembangkan memiliki kinerja prediksi yang cukup baik, dengan capaian nilai *Mean Squared Error* (MSE) sebesar 403.28, *Mean Absolute Error* (MAE) sebesar 10.38, dan *Mean Absolute Percentage Error* (MAPE) sebesar 10.79%. Nilai MAPE tersebut mengindikasikan tingkat akurasi prediksi yang tinggi dan cukup stabil dalam memetakan kebutuhan stok bahan baku harian. Keunggulan utama dari penelitian ini terletak pada keberhasilan penerapan model LSTM terhadap data operasional riil multi-cabang pada skala UMKM, serta pengembangan sistem berbasis web yang mempermudah pengelolaan stok secara digital dan terpusat.

Meskipun demikian, penelitian ini memiliki keterbatasan karena belum mempertimbangkan variabel eksternal yang dapat mempengaruhi fluktuasi permintaan bahan baku, seperti promosi penjualan, perubahan tren musiman, atau gangguan distribusi pasokan. Untuk pengembangan lebih lanjut, integrasi variabel eksternal dan pengujian pada data jangka panjang diharapkan dapat meningkatkan ketahanan dan akurasi model dalam menghadapi dinamika permintaan yang lebih kompleks. Hasil penelitian ini menunjukkan potensi pemanfaatan algoritma LSTM sebagai alat bantu pengambilan keputusan yang adaptif dalam pengelolaan logistik bahan baku pada skala operasional UMKM secara efektif dan berbasis data historis.

UCAPAN TERIMAKASIH

Penulis mengucapkan terima kasih kepada produsen roti bakar “Mizan dan Sunan” atas dukungan, pemberian data, serta kesempatan yang telah diberikan selama pelaksanaan penelitian ini. Bantuan dan kerja sama yang diberikan sangat mendukung kelancaran proses penelitian dan pengembangan sistem prediksi ini.

REFERENSI

- [1] S. D. Hasibuan, *Analisis Pengendalian Persediaan Bahan Baku Bolu Salak Menggunakan Metode Economic Order Quantity (EOQ) pada UD Bolu Salak Kenanga Kota Padang Sidempuan*, Disertasi, Universitas Malikussaleh, 2025.
- [2] Alfanny, Sungkono, and D. Mulyadi, "Analisis Persediaan Bahan Baku Pada UMKM di Rengasdengklok," *PENG: Jurnal Ekonomi dan Manajemen*, vol. 1, no. 2, pp. 399–406, Jul. 2024. [Online]. Tersedia: <https://teewanjurnal.com/index.php/peng/article/view/882/126>
- [3] N. M. E. Raysha, S. A. N. Aziza, and F. Sidik, "Analisis Manajemen Risiko pada Usaha 'Kue Kering Caisy Cookies' Bandung," *Jurnal Serambi Ekonomi dan Bisnis*, vol. 8, no. 1, pp. 381–388, 2024. [Online]. Tersedia: <https://ojs.serambimekkah.ac.id/serambi-ekonomi-dan-bisnis/>
- [4] A. Rahmani, "Analisis Persediaan Bahan Baku pada UMKM 'Chicken Fighter' dengan Metode Just In Time," *Skripsi*, Universitas Islam Indonesia, Yogyakarta, 2020. [Online]. Tersedia: <https://dspace.uui.ac.id/bitstream/handle/123456789/23916/16311052%20Adina%20Rahmani.pdf?isAllowed=y&sequence=1>
- [5] E. S. Putri and S. Mujiono, "Prediksi Penjualan Produk untuk Mengestimasi Kebutuhan Bahan Baku Menggunakan Perbandingan Algoritma LSTM dan ARIMA," *FORMAT: Jurnal Ilmiah Komputer dan Informatika*, vol. 10, no. 2, pp. 162–171, 2021. [Online]. Tersedia: <https://doi.org/10.22441/format.2021.v10.i2.007>

- [6] J. L. Pramudita, B. Rahayudi, and N. Y. Setiawan, "Analisis Perbandingan ARIMA dan Long-Short Term Memory dalam Prediksi Penjualan (Studi Kasus: PT XYZ)," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 8, no. 13, 2024. [Online]. Tersedia: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/13472>
- [7] D. Putra, "Implementasi Algoritma LSTM untuk Prediksi Harga Saham pada PT. Telkom Indonesia," *Jurnal Teknologi dan Sistem Informasi*, vol. 10, no. 2, pp. 45–52, 2023. [Online]. Tersedia: <https://eprints.ums.ac.id/124206/1/Naskah%20Publikasi.pdf>
- [8] A. Innayah, I. Nuraini, and S. K. Putra, "Peran data primer dalam penelitian kualitatif," *Jurnal Tawadhu*, vol. 7, no. 1, pp. 12–20, 2023. [Online]. Tersedia: <https://ejournal.tawadhu.ac.id/index.php/tawadhu/article/view/1234>
- [9] B. Santoso and R. Wulandari, "Data sekunder dalam kajian pendidikan dasar," *Pendas: Jurnal Ilmiah Pendidikan Dasar*, vol. 9, no. 1, pp. 33–41, Mar. 2024.
- [10] I. F. Ramadhan, R. Nugroho, and M. A. Fadhilah, "Penerapan Metode Waterfall dalam Pengembangan Sistem Informasi Pemesanan Online Berbasis Web," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 8, no. 2, pp. 123–130, 2023. [Online]. Tersedia: <https://ejournal.upi.edu/index.php/jtiik/article/view/18234>
- [11] S. Zhou, S. Guo, B. Du, S. Huang, and J. Guo, "A Hybrid Framework for Multivariate Time Series Forecasting of Daily Urban Water Demand Using Attention-Based Convolutional Neural Network and Long Short-Term Memory Network," *Sustainability*, vol. 14, no. 17, p. 11086, 2022. doi: 10.3390/su141711086.
- [12] F. Yanti, B. N. Sari, and S. Defiyanti, "Implementasi algoritma LSTM pada peramalan stok obat," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 4, pp. 6082–6089, 2024. [Online]. Tersedia: <https://mail.ejournal.itn.ac.id/index.php/jati/article/view/10068>
- [13] G. Maulana and N. Aini, "Prediksi harga Brent Crude Oil menggunakan algoritma Long Short-Term Memory (LSTM)," *Journal of Technology and Engineering*, vol. 3, no. 1, pp. 10–24, 2025. [Online]. Tersedia: <https://journal.institutemandalika.com/index.php/jte/article/view/184>
- [14] D. R. Mahendra and U. Azmi, "Prediksi return saham perbankan dengan metode LSTM dan estimasi Value at Risk dengan Copula Ali-Mikhail-Haq menggunakan korelasi Kendall's Tau," *Jurnal Sains dan Seni ITS*, vol. 14, no. 2, pp. D114–D121, 2025. [Online]. Tersedia: http://ejournal.its.ac.id/index.php/sains_seni/article/view/148669
- [15] S. A. Tussifah, *Analisis perbandingan kinerja model ARIMA, LSTM dan GRU pada stock price forecasting*, Bachelor's thesis, Fakultas Sains dan Teknologi, Universitas Islam Negeri Syarif Hidayatullah Jakarta, 2023. [Online]. Tersedia: <https://repository.uinjkt.ac.id/dspace/handle/123456789/68556>