

---

## PREDIKSI PENJUALAN SUPERMARKET MENGGUNAKAN JARINGAN SYARAF TIRUAN LONG SHORT-TERM MEMORY (LSTM)

<sup>1</sup>Lima Hartimar Rambe, <sup>2</sup>Yuke Manza, <sup>3</sup>Kiki Putri Ani Siregar, <sup>4</sup>Roslina

Universitas Potensi Utama, Medan

e-mail: limahartimarrambe12345@gmail.com, manzayuke@gmail.com,  
putriani1@gmail.com, roslinanich@gmail.com

**Abstract:** Sales forecasting is a crucial aspect of supermarket operations, as it supports inventory management, production planning, and strategic decision-making. Sales data typically exhibit complex patterns such as trends, seasonality, and fluctuations, requiring modeling methods capable of handling nonlinear time-series characteristics. This study employs the Long Short-Term Memory (LSTM) model, an advanced form of Recurrent Neural Network (RNN) designed to capture long-term dependencies and overcome the vanishing gradient problem. The secondary dataset was obtained from the Kaggle platform, consisting of 20 features and a total of 1,000 records. The LSTM model was constructed using 50 neurons in the LSTM layer and a single dense output layer. Training was conducted for 100 epochs using the Adam optimizer and Mean Squared Error (MSE) as the loss function. The training process showed a consistent decrease in loss, reaching approximately 0.0193, while evaluation using Root Mean Squared Error (RMSE) indicated that the model effectively learned historical patterns. Visualization of predictions on the test dataset demonstrated that the model successfully followed sales trends, although it was less responsive to extreme fluctuations. Overall, the LSTM model proved effective for daily sales forecasting and can serve as a valuable tool for operational planning in supermarkets.

**Keywords:** LSTM, Sales Forecasting, Time Series, Deep Learning, RMSE, Supermarket.

**Abstrak:** Peramalan penjualan merupakan aspek penting dalam operasional supermarket karena berperan besar dalam pengelolaan inventaris, perencanaan produksi, serta pengambilan keputusan strategis. Data penjualan umumnya memiliki pola tren, musiman, dan fluktuasi yang kompleks sehingga memerlukan metode pemodelan yang mampu menangani karakteristik deret waktu nonlinear. Penelitian ini menggunakan model Long Short-Term Memory (LSTM), sebuah pengembangan Recurrent Neural Network (RNN) yang efektif dalam menangkap dependensi jangka panjang dan mengatasi masalah vanishing gradient. Data sekunder diperoleh dari platform Kaggle dengan 20 fitur dan total 1.000 record. Model LSTM dibangun menggunakan 50 unit neuron pada lapisan LSTM dan satu lapisan dense sebagai output. Model dilatih selama 100 epoch menggunakan optimizer Adam dan fungsi loss MSE. Hasil pelatihan menunjukkan penurunan loss yang stabil hingga mencapai nilai sekitar 0,0193, sedangkan evaluasi menggunakan Root Mean Squared Error (RMSE) menunjukkan bahwa model mampu mempelajari pola historis dengan baik. Visualisasi prediksi pada data pengujian memperlihatkan bahwa model mampu mengikuti tren pergerakan penjualan meskipun masih kurang responsif terhadap fluktuasi ekstrem. Secara keseluruhan, model LSTM terbukti efektif dalam memprediksi penjualan harian dan dapat digunakan sebagai dasar pengambilan keputusan dalam perencanaan operasional supermarket.

**Kata Kunci:** LSTM, Peramalan Penjualan, Deret Waktu, Deep Learning, RMSE, Supermarket.

## PENDAHULUAN

Peramalan penjualan merupakan aspek penting dalam bisnis ritel karena secara langsung memengaruhi pengelolaan inventaris, perencanaan produksi, dan pengambilan keputusan strategis. Akurasi prediksi penjualan memungkinkan perusahaan meminimalkan risiko kelebihan atau kekurangan stok serta mengoptimalkan penggunaan sumber daya dan biaya operasional [1]. Tantangan ini semakin signifikan pada era big data, ketika volume dan kompleksitas data historis meningkat, sehingga diperlukan metode analisis yang mampu mengidentifikasi pola temporal dan nonlinear pada data deret waktu [2].

Long Short-Term Memory (LSTM), salah satu teknik pembelajaran mesin yang banyak digunakan dalam pemodelan deret waktu, merupakan varian jaringan saraf tiruan yang mampu menangkap dependensi jangka panjang pada data sekuensial. LSTM efektif dalam mengatasi isu vanishing gradient dan mengenali pola tren serta musiman pada data penjualan yang kompleks. LSTM menunjukkan MAPE 10,76% lebih rendah dibanding ARIMA 11,23% dan GRU 11,47%, menandakan kemampuan LSTM dalam menangkap pola kompleks pada data penjualan [3]. Kondisi ini menjadi tantangan serius dalam menjamin kualitas produk akhir. Oleh karena itu, LSTM sering digunakan sebagai alternatif atau pelengkap metode statistik tradisional seperti ARIMA. Studi komparatif menunjukkan bahwa model LSTM kerap menghasilkan prediksi yang lebih akurat dibandingkan metode statistik konvensional dalam berbagai aplikasi penjualan dan permintaan ritel [4].

[5] melakukan penelitian menggunakan LSTM untuk memprediksi cuaca berupa curah hujan dan suhu dengan data dari tahun 2013-2020. Penelitian ini secara khusus menguji pengaruh dua parameter utama, yaitu *epoch* dan *batch size*, terhadap akurasi

hasil prakiraan. Berdasarkan hasil pengujian dengan berbagai konfigurasi, ditemukan bahwa model paling optimal diperoleh dengan menggunakan *batch size* 50 dan *epoch* 100. Konfigurasi tersebut menghasilkan nilai error terkecil dengan skor RMSE sebesar 1.7444 dan MAPE sebesar 1.9499%. Meskipun model mampu mengikuti pola suhu dengan sangat baik, peneliti mencatat bahwa prediksi curah hujan memiliki tantangan tersendiri karena sifat datanya yang fluktuatif dan tidak stabil dari hari ke hari.

Selain itu [6] melakukan prediksi data *time series* saham Bank BRI (BBRI) dengan memanfaatkan metode *machine learning* berbasis *Long Short-Term Memory* (LSTM). Tujuan utama dari studi ini adalah untuk mengukur tingkat ketelitian prediksi serta menentukan jumlah *epoch* yang optimal guna menghasilkan nilai *Root Mean Square Error* (RMSE) yang paling kecil. Arsitektur model yang digunakan terdiri dari empat *hidden layer*, di mana setiap *layer* memiliki 50 *node* dan tingkat *dropout* sebesar 0,2. Hasil penelitian menunjukkan bahwa terdapat variasi yang tinggi antara nilai RMSE terhadap jumlah *epoch* yang digunakan, sehingga iterasi diperlukan untuk menemukan titik akurasi terbaik.

Penelitian-penelitian tersebut memberikan landasan teoritis dan empiris untuk peramalan penjualan di supermarket. Bisa disimpulkan bahwa LSTM bisa di implementasi dalam peramalan penjualan dengan hasil yang optimal. Berdasarkan tinjauan tersebut, peneliti tertarik untuk Prediksi penjualan supermarket menggunakan jaringan syaraf tiruan *long short-term memory* (LSTM).

## TINJAUAN PUSTAKA

Penjualan merupakan komponen utama dalam aktivitas operasional supermarket, di mana data penjualan biasanya dipengaruhi oleh berbagai faktor

seperti waktu, promosi, musim, dan perilaku konsumen [7]. Prediksi penjualan supermarket merupakan proses penting untuk membantu manajemen dalam mengelola stok, merencanakan strategi penjualan, dan meningkatkan keuntungan. Dengan memanfaatkan data transaksi penjualan yang tercatat setiap hari, supermarket dapat mengenali pola pembelian pelanggan, tren penjualan, serta fluktuasi permintaan pasar [8].

Jaringan Saraf Tiruan (JST) merupakan metode kecerdasan buatan yang meniru cara kerja otak manusia dalam mempelajari pola dari data. JST mampu belajar dari data historis dan mengenali hubungan yang kompleks tanpa memerlukan rumus matematis yang rumit [9]. Long Short-Term Memory (LSTM) adalah salah satu jenis jaringan saraf tiruan yang dirancang untuk mempelajari pola data berurutan, seperti data waktu ke waktu. LSTM mampu mengingat informasi penting dari data masa lalu dan mengabaikan informasi yang tidak relevan, sehingga lebih akurat dalam melakukan prediksi. Kemampuan ini membuat LSTM sangat efektif digunakan pada peramalan penjualan, keuangan, dan data deret waktu lainnya yang memiliki pola kompleks dan fluktuatif [10].

LSTM banyak digunakan karena kemampuannya dalam menangkap pola jangka panjang pada data sekuensial, mengatasi masalah vanishing gradient, serta memodelkan hubungan nonlinear yang kompleks pada deret waktu. Selain itu, LSTM mampu mempertahankan informasi penting melalui mekanisme cell state dan gates, sehingga menghasilkan prediksi yang lebih stabil dan akurat dibandingkan metode tradisional. Evaluasi performa LSTM digunakan untuk mengukur tingkat akurasi dan efektivitas model dalam mempelajari pola historis serta menghasilkan prediksi yang mendekati nilai aktual. Proses evaluasi biasanya menggunakan metrik seperti Root Mean Squared Error (RMSE), Mean Squared Error (MSE), dan Mean Absolute

Error (MAE), yang mampu menunjukkan seberapa besar kesalahan prediksi model [11].

Hasil penelitian sebelumnya menunjukkan bahwa LSTM merupakan model prediksi deret waktu yang paling efektif, dengan kesalahan yang lebih kecil dan akurasi yang lebih tinggi dalam prediksinya, menggunakan jaringan saraf tiruan (Artificial Neural Networks, ANN), jaringan saraf berulang (Recurrent Neural Networks, RNN), dan Long Short-Term Memory (LSTM), yang merupakan jenis khusus dari RNN, dibandingkan dengan metode Autoregressive Integrated Moving Average (ARIMA) yang umum digunakan. Hasil evaluasi diukur menggunakan metode Root Mean Square Error (RMSE). Hasil perbandingan menunjukkan bahwa metode LSTM lebih akurat dibandingkan ARIMA.

## METODE

Penelitian ini menggunakan metode peramalan untuk menganalisis data penjualan pada supermarket yang diunduh dari *Kaggle*. Metode penelitian ini dijelaskan melalui tahapan berikut:

### Dataset

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari platform *Kaggle*. Dataset tersebut terdiri dari 20 fitur yang merepresentasikan berbagai karakteristik variabel penelitian, dengan total 1.000 *record* data.

### Tahapan Penelitian

Penelitian ini dilakukan dalam beberapa tahap dimulai dari:

#### *Pre-processing Data*

Tahap ini mencakup proses pembersihan dan normalisasi data untuk memastikan kualitas serta kelengkapan dataset. Langkah-langkah yang dilakukan meliputi identifikasi dan penanganan nilai hilang (*missing value*), serta penerapan metode normalisasi *Min-Max* untuk mengonversi nilai setiap fitur ke dalam rentang tertentu. Proses ini bertujuan

untuk meningkatkan konsistensi data dan mempermudah tahapan pelatihan model dengan persamaan:

$$x^i = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Keterangan:

$x_i$  = Hasil Normalisasi

$x_i$  = Data Ke I

$x_{min}$  = Data Dengan Nilai Minimum

$x_{max}$  = Data Dengan Nilai Maksimum.

Selain itu, dilakukan beberapa tahapan praproses data, yaitu konversi tipe data pada kolom 'date' menjadi `datetime64[ns]` dan kolom 'time' menjadi objek `datetime.time`, agregasi transaksi menjadi total penjualan harian yang menghasilkan 89 entri untuk periode 1 Januari hingga 30 Maret 2019, serta penanganan tanggal hilang dengan mengisi tanggal yang tidak muncul menggunakan nilai 0 agar deret waktu tetap lengkap dan berkelanjutan.

### Long Short-Term Memory (LSTM)

Sequential Long Short-Term Memory (LSTM) berhasil dikembangkan dengan arsitektur yang terdiri atas satu lapisan lstm berjumlah 50 unit neuron dan satu lapisan dense sebagai lapisan keluaran. Model ini dikompilasi menggunakan optimizer adam dan fungsi *loss mean squared error* (MSE). Proses pelatihan dilakukan selama 100 *epoch* dengan ukuran batch sebesar 1, di mana hasil pelatihan menunjukkan penurunan nilai loss yang konsisten hingga mencapai sekitar 0,0193 pada *epoch* terakhir, yang mengindikasikan bahwa model mampu mempelajari pola dan karakteristik data deret waktu secara efektif.

### Evaluasi dan Prediksi

Model yang dihasilkan dari proses pelatihan menggunakan metode LSTM dievaluasi dengan metrik *Root Mean Squared Error* (RMSE) untuk mengukur tingkat kesalahan prediksi model terhadap data aktual.

$$RMSE = \sqrt{\sum (Aktual - Prediksi)^2 / n} \quad (2)$$

(2)

Keterangan:

N = ukuran sampel

Prediksi model LSTM untuk tahun 2019 memperkirakan produktivitas penjualan product di supermarket berdasarkan pola data historis. Hasil ini dapat digunakan sebagai acuan dalam perencanaan produksi dan pengelolaan penjualan secara efektif, dengan harapan tingkat akurasi yang baik untuk proyeksi jangka panjang.

Berikut komponen yang digunakan untuk mengidentifikasi hasil prediksi menggunakan *matrix*:

1. Metrik Evaluasi (RMSE): Metrik ini digunakan untuk mengukur tingkat kesalahan prediksi model terhadap data aktual dengan memberikan penalti yang lebih besar pada kesalahan yang ekstrem.
2. Nilai Loss (MSE): Selama proses pelatihan, model menggunakan *Mean Squared Error* (MSE) sebagai fungsi *loss* untuk mengoptimalkan bobot jaringan.
3. Visualisasi Perbandingan: Komponen penting lainnya adalah grafik visual yang membandingkan antara data penjualan harian aktual dengan hasil prediksi model LSTM pada data pengujian (*test set*).
4. Analisis Tren Temporal: Hasil ditentukan berdasarkan kemampuan model dalam mengikuti tren umum pergerakan penjualan, meskipun terdapat keterbatasan dalam memprediksi fluktuasi yang sangat tajam atau ekstrem.

## HASIL DAN PEMBAHASAN

### Analisis Dataset

Dataset awal terdiri dari 1.000 data yang setelah proses agregasi menghasilkan 89 baris data penjualan harian. Dataset ini memiliki 3 fitur utama, yaitu date (tanggal transaksi), time (waktu transaksi), dan daily sales (total penjualan

harian). Data penjualan harian tersebut selanjutnya digunakan sebagai deret waktu dalam pemodelan peramalan menggunakan algoritma long short-term memory.

```

RangeIndex: 1000 entries, 0 to 999
Data columns (total 20 columns):
 #   Column              Non-Null Count  Dtype
---  -
 0   Invoice ID          1000 non-null   object
 1   Branch             1000 non-null   object
 2   City               1000 non-null   object
 3   Customer type     1000 non-null   object
 4   Gender            1000 non-null   object
 5   Product line      1000 non-null   object
 6   Unit price        1000 non-null   float64
 7   Quantity          1000 non-null   int64
 8   Tax 5%           1000 non-null   float64
 9   Total             1000 non-null   float64
10   Date              1000 non-null   datetime64[ns]
11   Time             1000 non-null   object
12   Payment          1000 non-null   object
13   cogs             1000 non-null   float64
14   gross margin percentage 1000 non-null   float64
15   gross income     1000 non-null   float64
16   Rating           1000 non-null   float64
17   Day              1000 non-null   int64
18   Month            1000 non-null   int64
19   Year             1000 non-null   int64
dtypes: datetime64[ns](1), float64(7), int64(4), object(8)
    
```

**Gambar 1 Data Penjualan**

Data transaksi individual kemudian diagregasi menjadi total penjualan harian berdasarkan tanggal transaksi. Agregasi ini menghasilkan sebuah *dataframe* baru bernama `daily_sales` yang merepresentasikan jumlah penjualan per hari. Hasil agregasi mencakup 89 entri data harian, dengan rentang waktu dari 1 januari hingga 30 maret 2019. Langkah ini dilakukan untuk mengubah data transaksi granular menjadi bentuk deret waktu (*time series*) yang sesuai untuk pemodelan peramalan.

Daily_Sales	
Date	
2019-01-01	4745.1810
2019-01-02	1945.5030
2019-01-03	2078.1285
2019-01-04	1623.6885
2019-01-05	3536.6835

**Gambar 2. Hasil Agregasi**

Nilai penjualan harian selanjutnya dinormalisasi menggunakan metode min-max scaling, sehingga seluruh nilai dipetakan ke dalam rentang [0, 1]. Normalisasi ini dilakukan dengan tujuan untuk mempercepat proses konvergensi

model serta menghindari dominasi nilai berskala besar terhadap proses pembelajaran jaringan saraf. Hasil normalisasi disimpan dalam kolom baru bernama `daily_sales_normalized`, yang digunakan sebagai input utama dalam proses pelatihan model.

Date	Daily_Sales	Daily_Sales_Normalized
2019-01-01	4745.1810	0.582730
2019-01-02	1945.5030	0.154632
2019-01-03	2078.1285	0.174912
2019-01-04	1623.6885	0.105424
2019-01-05	3536.6835	0.397939

**Gambar 3 Hasil Normalisasi**

Setelah normalisasi, selanjutnya dilakukan pembentukan urutan input (*input sequences*) dan output (*target values*) menggunakan pendekatan *sliding window*. Periode look-back ditetapkan selama 7 hari, yang berarti nilai penjualan selama tujuh hari sebelumnya digunakan untuk memprediksi nilai penjualan pada hari berikutnya. Data deret waktu kemudian dibagi secara kronologis menjadi data pelatihan dan data pengujian, dengan proporsi 80% untuk pelatihan dan 20% untuk pengujian. Pembagian dilakukan tanpa pengacakan (*no shuffling*) guna menjaga urutan temporal data dan menghindari *data leakage*. Hasil pembagian menghasilkan data pelatihan `x_train` berdimensi (65, 7) dan `y_train` berdimensi (65, 1), serta data pengujian `x_test` berdimensi (17, 7) dan `y_test` berdimensi (17, 1).

### Long Short-Term Memory (LSTM)

Pembuatan arsitektur model LSTM, yang bertujuan untuk membangun jaringan saraf tiruan yang mampu menangkap pola dalam data deret waktu. Pada tahap ini, model lstm dirancang dengan beberapa lapisan, seperti lapisan input, lapisan lstm, dan lapisan output.

Model: "sequential"

Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, 50)	10,400
dense (Dense)	(None, 1)	51

Total params: 10,451 (40.82 KB)  
 Trainable params: 10,451 (40.82 KB)  
 Non-trainable params: 0 (0.00 B)

Gambar 4 Struktur LSTM


Model yang digunakan adalah sequential neural network yang terdiri dari dua lapisan utama, yaitu lstm dan dense. Lapisan pertama merupakan lstm dengan 50 unit neuron, yang berfungsi untuk mempelajari pola dan ketergantungan temporal pada data deret waktu penjualan. Output dari lapisan ini memiliki bentuk (none, 50), di mana *none* menunjukkan ukuran batch yang fleksibel, sedangkan angka 50 merepresentasikan jumlah unit lstm.

Lapisan berikutnya adalah dense layer dengan 1 neuron output, yang berfungsi untuk menghasilkan nilai prediksi penjualan pada periode berikutnya. Lapisan lstm memiliki 10.400 parameter, sedangkan lapisan dense memiliki 51 parameter, sehingga total parameter dalam model adalah 10.451 parameter, seluruhnya bersifat trainable. Tidak terdapat parameter non-trainable dalam model, yang menunjukkan bahwa seluruh bobot dioptimalkan selama proses pelatihan.

Arsitektur ini dirancang sederhana namun efektif untuk tugas peramalan time series satu variabel, dengan fokus pada kemampuan lstm dalam menangkap pola historis data penjualan harian.


### Evaluasi Hasil

Parameter evaluasi yang digunakan adalah root mean squared error (rmse) dan visualisasi perbandingan antara data aktual dan hasil prediksi. Dengan evaluasi ini, dapat dinilai efektivitas model dalam mengolah *data time series* dan memprediksi variabel target dengan tingkat kesalahan yang minimal. Hasil evaluasi model LSTM selama pelatihan disajikan dalam bentuk tabel dan grafik, yang menampilkan urutan epoch dan nilai RMSE.



Gambar 5 Grafik LSTM Model Training

Grafik menunjukkan perubahan nilai RMSE selama proses pelatihan model lstm pada 100 epoch. Terlihat bahwa nilai RMSE menurun secara bertahap dari epoch awal hingga akhir pelatihan, yang mengindikasikan bahwa model semakin mampu meminimalkan kesalahan prediksi. Meskipun terdapat fluktuasi kecil pada beberapa epoch, tren penurunan yang konsisten menunjukkan bahwa proses pelatihan berjalan stabil dan model berhasil mempelajari pola data tanpa indikasi overfitting yang signifikan.



Gambar 6 Grafik Aktual Dan Prediksi

Grafik menunjukkan perbandingan penjualan harian aktual dan hasil prediksi model lstm pada data pengujian. Model lstm mampu mengikuti tren umum penjualan, yang terlihat dari kesesuaian arah pergerakan antara nilai aktual dan prediksi. Namun, pada beberapa periode dengan perubahan penjualan yang tajam, masih terdapat selisih antara nilai aktual dan prediksi, di mana model cenderung menghasilkan prediksi yang lebih halus. Hal ini menunjukkan bahwa model cukup efektif dalam menangkap pola historis, tetapi masih memiliki keterbatasan dalam memprediksi fluktuasi ekstrem.

### SIMPULAN

Model LSTM yang dikembangkan terbukti mampu mempelajari pola dan

karakteristik data deret waktu secara efektif. Hal ini ditunjukkan dengan penurunan nilai *loss* yang konsisten selama 100 epoch hingga mencapai angka 0,0193. Selain itu, tren penurunan *Root Mean Squared Error* (RMSE) selama pelatihan menunjukkan bahwa proses berjalan stabil tanpa indikasi *overfitting* yang signifikan. Secara visual, model mampu mengikuti tren umum pergerakan penjualan harian pada data pengujian. Namun, model masih memiliki keterbatasan dalam memprediksi fluktuasi yang sangat ekstrem atau perubahan tajam, di mana hasil prediksi cenderung lebih halus dibandingkan data aktual. Hasil prediksi ini dapat digunakan sebagai acuan strategis bagi manajemen supermarket dalam perencanaan produksi dan pengelolaan inventaris secara lebih efisien dan efektif untuk jangka panjang.

#### DAFTAR PUSTAKA

- Y. Wang and C. Cui, “Forecasting superstore fruit and vegetable sales based on ARIMA-LSTM,” 2024. [Online]. Available: <https://cumcm.cnki.net/>
- X. Kong *et al.*, “Deep learning for time series forecasting: a survey,” *International Journal of Machine Learning and Cybernetics*, vol. 16, no. 7–8, pp. 5079–5112, Aug. 2025, doi: 10.1007/s13042-025-02560-w.
- N. Sunendar and Y. Rianto, “COMPARISON OF ARIMA, LSTM, AND GRU MODELS FOR FORECASTING SALES OF HIT AEROSOL PRODUCTS,” *Jurnal Pilar Nusa Mandiri*, vol. 21, no. 2, pp. 153–159, Sep. 2025, doi: 10.33480/pilar.v21i2.6412.
- D. Suganthi, “From ARIMA to LSTM: Evaluating Traditional and AI-Based Models for Accurate Retail Sales Forecasting,” *Int. J. Res. Appl. Sci. Eng. Technol.*, vol. 13, no. 10, pp. 1756–1760, Oct. 2025
- T. Lattifia, P. Wira Buana, N. Kadek, and D. Rusjyanthi, “Model Prediksi Cuaca Menggunakan Metode LSTM,” 2022.
- A. Satyo Bayangkari Karno, J. K. Noer Ali, and K. Bekasi, “Prediksi Data Time Series Saham Bank BRI Dengan Mesin Belajar LSTM (Long ShortTerm Memory),” *Journal of Information and Information Security (JIFORTY)*, vol. 1, no. 1, pp. 1–8, 2020, [Online]. Available: <http://ejurnal.ubharajaya.ac.id/index.php/jiforty>
- Y. Tri Utomo, Abdi Mujahidin Rahim, and Hery Sasono, “Faktor-Faktor yang Mempengaruhi Konsumen Belanja di Pamella Yogyakarta,” *Journal of Trends Economics and Accounting Research*, vol. 3, no. 3, pp. 238–242, Mar. 2023, doi: 10.47065/jtear.v3i3.576.
- M. Husban, A. Mir, and I. Yustiana, “Predicting Big Mart Sales with Machine Learning,” MDPI AG, Sep. 2025, p. 95. doi: 10.3390/engproc2025107095.
- A. Nevrisa and M. Nasir, “Penerapan Metode Backpropagation untuk Mengidentifikasi Penyakit ISPA pada Balita (Studi Kasus RSUD Pasaman Barat),” *Jurnal Teknologi Rekayasa Informasi dan Komputer*, vol. 6, no. 1, 2022.
- E. Novfuja, L. Efrizoni, E. Ali, and S. Susanti, “Prediksi Dukungan Publik Terhadap Program Makan Bergizi Gratis (MBG) Menggunakan Analisis Sentimen Berbasis Long Short-Term Memory (LSTM),” *Jurnal Algoritma*, vol. 22, no. 2, Nov. 2025, doi: 10.33364/algoritma/v.22-2.2690.
- M. Elsaraiti and A. Merabet, “A comparative analysis of the arima and lstm predictive models and their effectiveness for predicting wind speed,” *Energies (Basel)*, vol. 14, no. 20, Oct. 2021, doi: 10.3390/en14206782.