



## Peramalan Harga Cabai Rawit Merah Menggunakan Attention Mechanism Berbasis Long Short-Term Memory

Setyo Arie Anggara<sup>1</sup>, Wina Witanti<sup>2</sup>, Melina<sup>3</sup>

<sup>1,2,3</sup>Jurusan Informatika, Fakultas Sains & Informatika, Universitas Jenderal Achmad Yani, Cimahi, Indonesia

<sup>1</sup>setyoariaea20@if.unjani.ac.id, <sup>2</sup>witanti@gmail.com\*, <sup>3</sup>melina@lecture.unjani.ac.id

### Abstract

Red cayenne pepper is a commodity that has important economic value in Indonesia, especially in West Java Province. Cayenne pepper often experiences significant price fluctuations which can cause inflation. In 2022 there will be the highest inflation in West Java in the last eight years due to increased commodity prices, including cayenne pepper. There needs to be an effort to maintain the stability of the price of red cayenne pepper in West Java. This research aims to create a price forecasting system for red cayenne peppers in West Java by comparing two deep learning approaches, namely Long-Short Term Memory (LSTM) and Long-Short Term Memory with Attention Mechanism (LSTM-Attention-LSTM) to obtain high accuracy in predicting the price of red cayenne pepper. The results of this research show that the LSTM model using 3 hidden layers, 100 neurons, 128 dense, 1 dense, and 32 batch sizes, produces Mean Absolute Error (MAE) values of 0.023, Root Mean Square Error (RMSE) of 0.152, and Mean Absolute Percentage Error (MAPE) is 3.68%. Meanwhile, the LSTM-Attention-LSTM model with the same configuration produces an MAE value of 0.017, RMSE of 0.130, and MAPE of 2.74%. The results of this research can be a reference for the community and government in maintaining price stability for cayenne pepper in West Java.

Keywords: attention mechanisms, LSTM, forecasting, price, red cayenne pepper.

### Abstrak

Cabai rawit merah merupakan komoditas yang memiliki nilai ekonomi penting di Indonesia terutama di Provinsi Jawa Barat. Cabai rawit sering mengalami fluktuasi harga yang signifikan sehingga dapat menimbulkan inflasi. Pada tahun 2022 terjadi inflasi tertinggi di Jawa Barat dalam delapan tahun terakhir yang disebabkan karena adanya kenaikan harga komoditas, antara lain cabai rawit. Perlu adanya suatu upaya untuk menjaga stabilitas harga cabai rawit merah di Jawa Barat. Penelitian ini bertujuan untuk membuat sistem peramalan harga cabai rawit merah di Jawa Barat dengan membandingkan dua pendekatan *deep learning* yaitu *Long-Short Term Memory* (LSTM) dan *Long-Short Term Memory* dengan *Attention Mechanism* (LSTM-Attention-LSTM) untuk memperoleh akurasi yang tinggi dalam meramalkan harga cabai rawit merah. Hasil penelitian ini menunjukkan bahwa model LSTM dengan menggunakan 3 *hidden layer*, 100 *neuron*, 128 *dense*, dan 1 *dense*, serta 32 *batch size*, menghasilkan nilai *Mean Absolute Error* (MAE) sebesar 0.023, *Root Mean Square Error* (RMSE) sebesar 0.152, dan *Mean Absolute Percentage Error* (MAPE) sebesar 3.68%. Sedangkan model LSTM-Attention-LSTM dengan konfigurasi yang sama menghasilkan nilai MAE sebesar 0.017, RMSE sebesar 0.130, dan MAPE sebesar 2.74%. Hasil dari penelitian ini dapat menjadi referensi bagi masyarakat dan pemerintah dalam menjaga stabilitas harga cabai rawit di Jawa Barat.

Kata kunci: attention mechanisms, cabai rawit merah, LSTM, peramalan, harga.

### 1. Pendahuluan

Cabai rawit merah merupakan komoditas penting di provinsi Jawa Barat dengan konsumsi rata-rata mencapai 2,19 kg/kapita/tahun pada tahun 2023 [1]. Namun, fluktuasi harga cabai rawit merah di Jawa Barat kerap mengalami lonjakan yang signifikan, seperti yang terjadi pada Maret 2021, harga cabai rawit merah mencapai Rp 120.000 per kilogram sebagaimana yang ditunjukkan pada Gambar 1. Harga cabai rawit yang berfluktuasi dapat menyebabkan kerugian bagi para petani [2]. Selain itu, lonjakan dan tren harga cabai rawit merah yang tinggi merupakan salah satu faktor pemicu terjadinya inflasi [3]. Data dari Badan Pusat Statistik

(BPS) Jawa Barat menunjukkan tingkat inflasi tahunan sebesar 6,04% *year-on-year* (yoy) pada bulan Desember 2022 [4], lihat Gambar 1.



Gambar 1. Pergerakan Indeks Harga Cabai Rawit Merah



Lisensi

Lisensi Internasional Creative Commons Attribution-ShareAlike 4.0.

Inflasi dapat menurunkan daya beli masyarakat yang berdampak pada penurunan pendapatan negara dan menghambat pertumbuhan ekonomi [5], untuk mengatasi ketidakpastian harga cabai rawit dan risikonya, diperlukan suatu metode yang mampu memperkirakan harga dari komoditas cabai rawit [2].

Peramalan adalah suatu metode untuk memperkirakan suatu nilai dimasa depan dengan menggunakan data masa lalu [6]. Model *Long Short-Term Memory* (LSTM) merupakan salah satu model peramalan yang paling banyak dikembangkan saat ini, karena termasuk model berbasis *Machine Learning* [7]. Model ini lebih adaptif terhadap perubahan tren dan dapat menangani data *non-linear* dengan lebih baik dibandingkan metode tradisional seperti ARIMA [8]. Sebagai model proses linier, ARIMA yang memiliki keterbatasan pada data yang *non-stasioner* [9]. Meskipun model LSTM telah menunjukkan kinerja yang baik, tetapi masih memiliki kekurangan dalam hal akurasi yang perlu ditingkatkan [10].

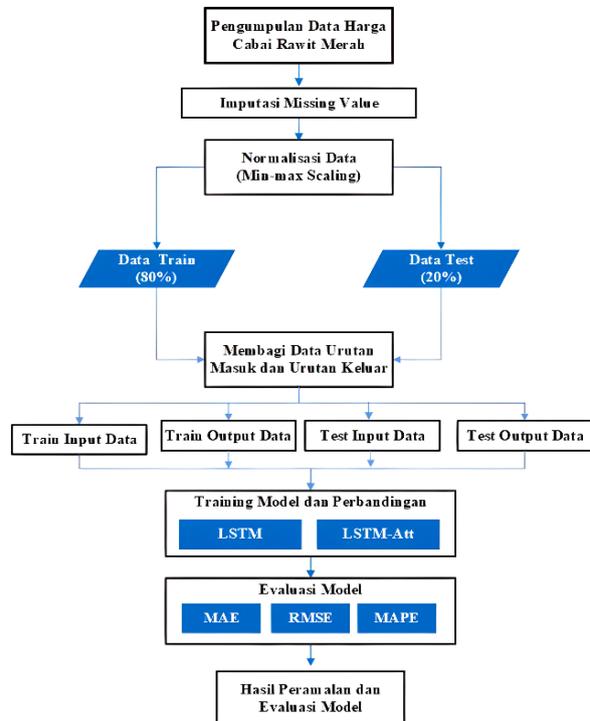
*Attention mechanism* adalah teknik yang mampu meningkatkan akurasi peramalan secara selektif pada data yang relevan, dapat menangkap dependensi jangka panjang, beradaptasi dengan perubahan pola, dan menyediakan interpretasi yang lebih jelas, sehingga menghasilkan prediksi yang lebih andal dibanding metode LSTM standar [11]. LSTM-Attention-LSTM mempunyai kemampuan generalisasi yang lebih baik sehingga memungkinkan LSTM-Attention-LSTM menangani variabilitas tinggi dalam harga komoditas pertanian [12]. Kombinasi beberapa model menunjukkan kinerja yang lebih baik dibandingkan model tunggal dan merupakan arah utama dalam peramalan [13].

Penelitian terkait yang mengkaji peramalan harga komoditas pangan menggunakan metode LSTM telah dilakukan oleh penelitian terdahulu, diantaranya yaitu penelitian oleh Sudianto dkk menggunakan metode LSTM untuk memprediksi harga beras medium di kota Banyumas menghasilkan RMSE sebesar 79.17% [14]. Penelitian oleh Avianto dkk yang memprediksi harga cabai merah keriting di Yogyakarta menunjukkan hasil penelitiannya memperoleh akurasi terbaik dengan menggunakan rasio split data sebesar 70%:30% dengan parameter *epoch* 150, *batch size* 48, *learning rate* 0.001, jumlah *neuron* 30, fungsi aktivasi ReLU, dan fungsi optimasinya Adam. Jumlah atribut yang digunakan pada data *training* dan *testing* adalah 10. Model dengan parameter tersebut mendapatkan nilai MAPE sebesar 3.6995% [15]. Penelitian oleh David dkk menggunakan algoritma LSTM untuk memprediksi harga cabai di Kota Malang yang menghasilkan tingkat kesalahan terendah dengan *Mean Square Error* (MSE) pada pengujian nilai parameter. Parameter yang digunakan yaitu data *training* dan data *testing* sebesar 70%:30% dengan nilai *sequence data* sebanyak 21, *hidden unit* sebanyak 128, dan jumlah *epoch* 150 dengan nilai MSE sebesar 0,0155 [16].

Berdasarkan penelitian terdahulu, terdapat gap yang menunjukkan bahwa masih kurangnya penelitian yang mengkaji tentang sistem peramalan harga cabai rawit merah di Jawa Barat. Penelitian ini bertujuan mengembangkan sistem peramalan harga cabai rawit merah di Jawa Barat dengan membandingkan hasil akurasi terbaik antara metode LSTM dan LSTM-Attention-LSTM. Perbandingan ini dilakukan untuk mengisi kesenjangan penelitian dalam sistem peramalan harga cabai rawit merah di Jawa Barat, sekaligus meningkatkan akurasi peramalan. Selain itu, dengan membandingkan kedua metode ini dapat dievaluasi efektivitas penambahan *attention mechanism* pada model LSTM untuk peramalan harga komoditas pertanian yang memiliki dampak signifikan terhadap ekonomi dan inflasi di Jawa Barat khususnya, dan di Indonesia pada umumnya. Hasil perbandingan ini tidak hanya berkontribusi pada pengembangan model peramalan yang lebih akurat, tetapi juga memberikan rekomendasi bagi pelaku pasar dalam mengantisipasi fluktuasi harga cabai rawit merah.

## 2. Metode Penelitian

Dalam penelitian ini, sistem peramalan harga cabai rawit merah di provinsi Jawa Barat dikembangkan dengan menggunakan metode LSTM dan LSTM-Attention-LSTM berdasarkan akurasi tingkat *error* yang paling minimal sebagai rekomendasi metode yang tepat. Alur metode penelitian dapat dilihat pada Gambar 2.



Gambar 2. Metode Penelitian Peramalan

Tahapan dari penelitian ini meliputi pengumpulan data dan *pre-processing* data harga cabai rawit merah.

Metode LSTM digunakan untuk mempelajari pola jangka panjang dan dependensi temporal dari data harga cabai rawit merah. Model LSTM akan mengambil *vector* konteks dari histori harga cabai sebagai *input* [17]. Kemudian, dengan bantuan layer LSTM dan layer tambahan seperti *layer dropout* atau *layer dense*, model akan melakukan proses informasi temporal dan pola-pola tersembunyi dalam data *time series* harga cabai rawit merah, dan menghasilkan probabilitas atau nilai prediksi harga cabai untuk periode waktu yang akan datang. Selain itu, metode *attention mechanism* digunakan untuk memberikan penekanan pada pola dalam data *time series* harga cabai yang paling relevan untuk peramalan sehingga menghasilkan peramalan yang lebih akurat.

### 2.1. Pengumpulan Data

Pengumpulan data merupakan langkah krusial yang mempengaruhi kualitas dan validitas hasil akhir. Data yang digunakan adalah data harga cabai rawit merah yang terletak di provinsi Jawa Barat dari tanggal 1 Maret 2021 hingga 31 Mei 2024. Data diperoleh dari situs resmi Badan Pangan Nasional (BPN) dengan total data berjumlah 1.189 records yang dapat diakses pada tautan berikut <https://panelharga.badanpangan.go.id/>. Dalam dataset ini terdapat dua atribut utama yaitu tanggal dan harga cabai rawit merah/kg. Tanggal menyatakan kapan harga cabai rawit merah diobservasi, sedangkan harga menyatakan nilai harga/kg dari cabai rawit merah di provinsi Jawa Barat pada tanggal tertentu. Contoh data harga cabai rawit merah dapat dilihat pada Tabel 1.

Tabel 1. Data Harga Cabai Rawit Merah

No.	Tanggal	Harga
1	3/1/2021	91071
2	3/2/2021	93348
3	3/3/2021	95626
...	...	...
1187	5/29/2024	36450
1188	5/30/2024	36880
1189	5/31/2024	37620

### 2.2. Pre-processing

*Pre-processing* bertujuan untuk mengubah data mentah menjadi data yang bersih dan konsisten sebelum dilakukan pelatihan model peramalan menggunakan metode LSTM dan LSTM-Attention-LSTM. Proses pengolahan data ini melalui beberapa tahapan, seperti data *cleaning*, normalisasi data dan *splitting data*.

Data *cleaning* dilakukan identifikasi dan penghapusan data yang tidak valid. Data yang tidak valid termasuk data yang memiliki *missing value* dan data yang tidak konsisten. Penelitian ini menggunakan metode imputasi *linier interpolate* dalam menanggulangi masalah tersebut. *Linear interpolate* adalah teknik untuk memperkirakan nilai di antara dua titik data yang diketahui pada garis lurus [18]. *Linear interpolate* mengisi celah antara data yang sudah ada dengan menarik garis lurus antara dua titik data terdekat dan

memperkirakan nilai pada titik tertentu di sepanjang garis tersebut. Berikut merupakan algoritma dari proses linier interpolate.

#### Algorithm Imputasi Linier Interpolate

```

Input: hargacabai
Output: hargacabai_clean
hargacabai_clean <- []
Initialization i, j, k
for j in range(length of hargacabai):
  if hargacabai[i] is empty:
    j <- i - 1
    while j >= 0 and hargacabai[j] is empty:
      j <- j - 1
    endwhile
    prev_value <- hargacabai[j]

    k <- i + 1
    while k < length of hargacabai and
    hargacabai[k] is empty:
      k <- k + 1
    endwhile
    next_value <- hargacabai[k]

    interpolated_value <- prev_value +
    (next_value - prev_value) * ((i - j) / (k - j))
    hargacabai_clean.append(interpolated_value)
  else:
    hargacabai_clean.append(hargacabai[i])
  endelse
endfor
return hargacabai_clean

```

Normalisasi data bertujuan untuk mengubah nilai data ke dalam rentang yang sama. Dalam penelitian ini, digunakan metode normalisasi *min-max scaling* untuk mengubah nilai data ke dalam rentang 0 hingga 1. Hal ini membantu untuk mencegah dominasi fitur dengan rentang nilai yang jauh lebih besar dibandingkan fitur lainnya, serta meningkatkan kinerja dan kestabilan selama pelatihan model. *Min-max scaling* dapat dihitung dengan menggunakan persamaan (1) [15].

$$X_i = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (1)$$

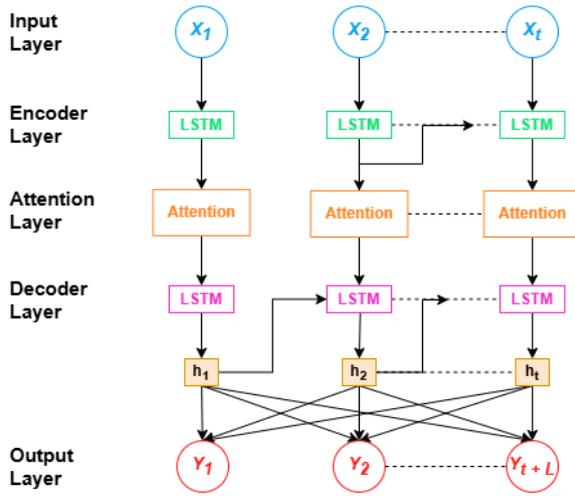
$X_i$  mewakili titik data ke- $i$  dalam *time series* dari  $[0, n]$ ,  $X_{min}$  dan  $X_{max}$  mewakili minimum dan titik data maksimum dalam *time series* tersebut.

Data dibagi menjadi *train set* dan *test set* dengan proporsi 80% dan 20%. Kumpulan data *train* berisi 892 baris dan data *test* berisi 297 baris. Kedua *train set* dan *test set* diproses menggunakan algoritma *moving window* untuk mendapatkan urutan *input* dan *output*. *Input* berisi dua atribut yaitu tanggal dan harga.

### 2.3. Training Model

Model peramalan yang dibangun dengan menggunakan metode LSTM-Attention-LSTM mampu memahami dan menangkap kompleksitas serta dinamika dalam data *time series* harga cabai rawit merah secara menyeluruh. Kemampuan ini meliputi memahami dependensi jangka panjang, sehingga model dapat menangkap pola dan tren jangka panjang dalam data berdasarkan atribut yang telah ditentukan sebelumnya, seperti tanggal dan harga [19]. Dalam model arsitektur LSTM-Attention-LSTM

ini terdapat beberapa proses yang dapat dilihat pada Gambar 3.



Gambar 3. Arsitektur LSTM-Attention-LSTM

Berdasarkan pada Gambar 3 arsitektur LSTM-Attention-LSTM dibagi menjadi lima layer, seperti *input layer*, *encoder layer*, *attention layer*, *decoder layer* dan *output layer*. Pada tahap *input layer*, data *time series* 3D berbentuk [sample, time step, feature] yang telah diproses sebelumnya  $X = (X_1, X_2, X_3 \dots X_t)$  mengenai harga cabai rawit merah diterima sebagai masukan. *Input layer* ini mengonversi data menjadi bentuk *vector* yang kemudian siap diproses oleh *layer* LSTM yang berada di *encoder layer*.

*Encoder layer* berfungsi untuk melakukan proses *data input* menggunakan LSTM, dengan tujuan menangkap pola dan ketergantungan temporal dalam data. *Encoder layer* menerima *input* yang dihasilkan oleh *input layer*. Data tersebut kemudian disandikan oleh *encoder layer* dengan menggunakan persamaan (2) berikut:

$$h_i = f(X_i, h_i - 1) \quad 1 \leq i \leq t \quad (2)$$

Dimana  $h_i$  menyatakan *hidden state* pada waktu ke- $i$  yang dihitung oleh *encoder layer*,  $h_i - 1$  menyatakan *hidden state* pada waktu ke- $(i-1)$ ,  $t$  menyatakan *time step*, dan  $f$  merupakan fungsi perhitungan *input gate*, *forget gate*, dan *output gate* pada model LSTM.

LSTM berperan dalam mengingat informasi penting dari urutan data sebelumnya sambil mengabaikan informasi yang kurang relevan.

*Attention layer* berfungsi untuk mengidentifikasi bagian data *input* yang lebih relevan untuk prediksi. *Layer* ini menghitung skor perhatian untuk *output* dari setiap unit LSTM pada *encoder layer* dengan menggunakan persamaan (3), (4) dan (5) berikut:

$$e_{ij} = a(h_i - 1, h_j) \quad (3)$$

$$\alpha_{ij} = \frac{\exp(e_{ij})}{\sum_{k=1}^T \exp(e_{ik})} = \text{softmax}(e_{ij}) \quad (4)$$

$$C_i' = \sum_{j=1}^t \alpha_{ij} h_j \quad (5)$$

Dimana  $\alpha_{ij}$  menunjukkan bobot perhatian (*attention weight*) dan  $e_{ij}$  menunjukkan skor korelasi perhatian (*attention correlation score*) dari waktu ke- $j$  terhadap waktu ke- $i$ .  $C_i'$  adalah *vector output* dari *attention layer* pada saat  $i$ ,  $h_j$  adalah *hidden state* pada saat  $j$ . Skor-skor ini kemudian digunakan untuk membentuk *vector* konteks, yang merupakan kombinasi tertimbang dari semua *output encoder*, dengan memberikan perhatian lebih pada langkah-langkah waktu yang lebih signifikan untuk prediksi.

*Decoder layer* berfungsi untuk menghasilkan representasi prediktif menggunakan informasi dari *attention layer*.  $C_i'$  yang diperoleh oleh *attention layer* akan dimasukkan ke *decoder layer* sebagai urutan *input*, dan  $y_i$  akan dihitung oleh *decoder layer* dengan menggunakan persamaan (6), (7), (8), (9), (10) dan (11) berikut:

$$f_i = \delta(W_f[y_{i-1}, h_i, C_i'] + b_f) \quad (6)$$

$$i_i = \delta(W_i[y_{i-1}, h_i, C_i'] + b_i) \quad (7)$$

$$L_i = \tanh(W_c[y_{i-1}, h_i, C_i'] + b_c) \quad (8)$$

$$C_i = f_i \times C_{i-1} + i_i \times L_i \quad (9)$$

$$O_i = \delta(W_o[y_{i-1}, h_i, C_i'] + b_o) \quad (10)$$

$$y_i = O_i \times \tanh(C_i) \quad (11)$$

Dimana  $f_i$ ,  $i_i$ , dan  $O_i$  masing-masing menyatakan *forget gate*, *input gate*, dan *output gate*.  $L_i$  dan  $C_i$  merupakan pembaruan *cell state*.  $C_{i-1}$  adalah *cell state* pada waktu ke- $(i-1)$ .  $\delta$  adalah fungsi aktivasi sigmoid.  $W_f$ ,  $W_i$ ,  $W_c$ , dan  $W_o$  adalah bobot dari input, sedangkan  $b_f$ ,  $b_i$ ,  $b_c$ , dan  $b_o$  masing-masing menunjukkan bias dari *input*.  $y_{i-1}$  adalah nilai output yang diprediksi pada waktu ke- $(i-1)$  di *decoder*.  $h_i$  adalah *hidden state* pada waktu ke- $i$  di *decoder*, dan  $C_i'$  adalah *vector output* dari *attention layer* pada waktu ke- $i$ . Nilai *output* yang diprediksi  $y_i$  pada waktu ke- $i$  diperoleh dari keluaran *decoder*, dan  $y_i$  kemudian dihitung dengan fungsi aktivasi ReLU dari lapisan *fully connected* untuk mendapatkan urutan prediksi akhir  $Y = (Y_1, Y_2, Y_3 \dots Y_t)$ . Setiap unit LSTM di *decoder layer* menerima *vector* konteks yang telah difokuskan oleh *attention layer* dan memprosesnya bersama dengan informasi temporal sebelumnya. *Output* dari LSTM di *decoder layer* adalah representasi internal yang digunakan untuk membuat prediksi harga pada setiap langkah waktu.

*Output layer* menghasilkan nilai prediksi akhir  $Y = (Y_1, Y_2, Y_3 \dots Y_t)$  untuk harga cabai rawit merah di masa depan. *Layer* ini menerima *input* dari LSTM di *decoder layer* dan mengeluarkan nilai prediksi. Prediksi ini adalah perkiraan harga cabai di masa depan, yang didasarkan pada informasi yang telah diproses dan difokuskan melalui *layer encoder*, *attention*, dan

decoder [20]. Berikut merupakan algoritma dari model LSTM-Attention-LSTM:

**Algorithm LSTM-Attention-LSTM**

```

Input: Time-series  $X = (X_1, X_2, X_3 \dots X_t)$ , Time-step  $L$ , Train-epoch  $n$ 
Output: Predict time-series  $Y = (Y_1, Y_2, Y_3 \dots Y_t)$ , mean absolute error MAE, root mean square error RMSE, mean absolute percentage error MAPE
for  $i$  to  $n$  do:
  for  $j$  to  $L$  do:
    for  $k$  to  $L$  do:
      encoder layer calculate encoding
      vector  $h_1 \leftarrow X_t$ 
       $f_i = \delta(W_f[y_{i-1}, h_i, C'_i] + b_f)$ 
       $i_i = \delta(W_i[y_{i-1}, h_i, C'_i] + b_i)$ 
       $L_i = \tanh(W_c[y_{i-1}, h_i, C'_i] + b_c)$ 
       $C_i = f_i \times C_{i-1} + i_i \times L_i$ 
       $O_i = \delta(W_o[y_{i-1}, h_i, C'_i] + b_o)$ 
       $y_i = O_i \times \tanh(C_i)$ 
    Dropout layer
    BatchNormal Layer
    Attention layer calculate  $C'_i \leftarrow h_1$ 
     $e_{ij} = a(h_i - 1, h_i)$ 
     $\alpha_{ij} = \frac{\exp(e_{ij})}{\sum_{k=1}^x \exp(e_{ik})} = \text{softmax}(e_{ij})$ 
     $C'_i = \sum_{j=1}^x \alpha_{ij} h_j$ 
    Decoder layer calculate decoding
    vector  $y_i \leftarrow C'_i$ 
    Dropout layer
    BatchNormal layer
    Fully connected layer  $Y = \text{relu}(y_i)$ 
  endfor
endfor
endfor
Calculate MAE RMSE MAPE
return  $Y$  MAE RMSE MAPE
  
```

**2.4. Evaluasi Model**

Pengujian model pada penelitian ini dievaluasi menggunakan beberapa *evaluation metrics*, seperti MAE, RMSE dan MAPE. Tujuan dari tahapan ini adalah untuk mengukur kinerja sistem peramalan secara menyeluruh dan memastikan bahwa model tersebut dapat memberikan hasil yang akurat dan dapat diandalkan dalam peramalan.

MAE merupakan sebuah metode yang digunakan untuk mengukur tingkat keakuratan model peramalan. Nilai MAE menunjukkan rata-rata kesalahan (*error*) absolut antara hasil peramalan/prediksi dengan nilai sebenarnya [21]. Nilai MAE dapat dihitung dengan menggunakan persamaan (12) berikut [22]:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}| \tag{12}$$

Dimana  $y_i$  adalah nilai aktual,  $\hat{y}$  adalah nilai peramalan dan  $n$  adalah jumlah pengamatan/baris.

RMSE merupakan nilai rata-rata dari jumlah kuadrat kesalahan yang dapat menyatakan ukuran besarnya kesalahan yang dihasilkan oleh suatu model prakiraan. Nilai RMSE yang rendah menunjukkan bahwa variasi nilai yang dihasilkan oleh suatu model prakiraan mendekati variasi nilai aslinya, sedangkan apabila nilai RMSE semakin besar, maka keakuratan suatu nilai yang dihasilkan semakin sedikit atau tidak akurat [23]. Nilai

RMSE dapat dihitung dengan menggunakan persamaan (13) berikut [22]:

$$RMSE = \sqrt{\frac{\sum (y_i - \hat{y})^2}{n}} \tag{13}$$

Dimana  $y_i$  adalah nilai aktual,  $\hat{y}$  adalah nilai peramalan dan  $n$  adalah jumlah pengamatan/baris.

MAPE merupakan nilai rata-rata perbedaan absolut yang ada diantara nilai dari prediksi dan nilai realisasi yang disebutkan sebagai hasil persenan dari nilai realisasi. Penggunaan MAPE pada evaluasi dari hasil peramalan dapat melihat tingkat akurasi terhadap angka peramalan dan angka aktual [24]. Nilai MAPE dapat dihitung dengan menggunakan persamaan (14) berikut [22]:

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \tag{14}$$

Dimana  $F_t$  adalah hasil prediksi pada periode ke- $t$ ,  $A_t$  adalah nilai aktual pada periode ke- $t$  dan  $n$  adalah jumlah pengamatan/baris.

**2.5. Peramalan**

Setelah melakukan pelatihan dan evaluasi model LSTM dan LSTM-Attention-LSTM, model terbaik yang mampu memberikan performa peramalan paling akurat kemudian dipilih. Model terbaik ini selanjutnya akan digunakan untuk meramalkan harga cabai rawit merah di Jawa Barat periode waktu ke depan untuk mendapatkan nilai harga cabai rawit merah yang sebenarnya dan dapat diinterpretasikan, diperlukan proses denormalisasi atau *invers min-max scaling*.

Dalam proses ini, nilai peramalan yang dihasilkan model akan ditransformasi kembali ke rentang nilai asli dengan menggunakan parameter minimum dan maksimum dari data harga yang digunakan selama pelatihan. Persamaan denormalisasi dinyatakan pada (15) berikut:

$$y_i = Y'_i (X_{max} - X_{min}) + X_{min} \tag{15}$$

Dimana  $y_i$  adalah sebuah output,  $Y'_i$  adalah sebuah output setelah dilakukan denormalisasi,  $X_{max}$  adalah nilai terbesar data,  $X_{min}$  adalah nilai terkecil data.

**3. Hasil dan Pembahasan**

Setelah melakukan serangkaian proses pelatihan dan evaluasi model, diperoleh sejumlah hasil yang menggambarkan performa dari metode LSTM dan LSTM-Attention-LSTM dalam meramalkan harga cabai rawit merah di Jawa Barat.

**3.1. Pemodelan**

Inisialisasi parameter pada penelitian ini menggunakan pendekatan *trial* dan *error* untuk mendapatkan hasil yang optimal. Pada penelitian ini menggunakan enam parameter, yaitu jumlah *neuron*, jumlah *hidden layer*, *optimizer*, *learning rate*, *batch size* dan *epoch*. Parameter yang digunakan dapat dilihat pada Tabel 2.

Tabel 2. Batasan Parameter Harga Cabai Rawit Merah

Parameter	Batasan	
	LSTM	LSTM-Att
Jumlah Neuron	50, 100	50, 100
Jumlah Hidden Layer	3	3
Optimizer	Adam	Adam
Learning Rate	0,001	0,001
Batch Size	32, 64, 128	32, 64, 128

Pada proses ini menggunakan sintaks *EarlyStopping*, dimana proses pelatihan akan terhenti ketika performa arsitektur tidak terjadi peningkatan yang signifikan dalam performa model [25]. Ketika proses pelatihan berhenti dari model yang digunakan. Selanjutnya, dilakukan evaluasi dengan melihat nilai MAE, RMSE dan MAPE dari setiap arsitektur yang telah dibuat.

### 3.2. Evaluasi Model

Penelitian ini membuat dua model yaitu model LSTM dan LSTM-Attention-LSTM. Pengujian model pada penelitian ini dievaluasi menggunakan beberapa *evaluation metrics*, seperti MAE, RMSE dan MAPE yang dapat dilihat pada Tabel 3.

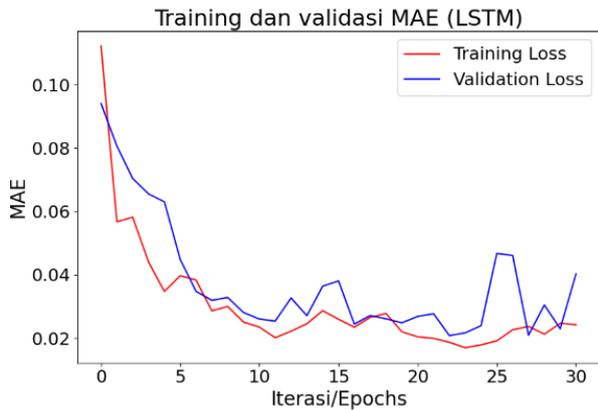
Tabel 3. Evaluation Metrics

Model	Neuron	Batch Size	MAE	RMSE	MAPE
LSTM	50	32	0.027	0.164	4.60%
	50	64	0.027	0.164	4.59%
	50	128	0.039	0.197	6.31%
	100	32	0.023	0.152	3.68%
	100	64	0.025	0.158	4.16%
	100	128	0.040	0.200	6.32%
LSTM+Att	50	32	0.018	0.134	2.81%
	50	64	0.025	0.158	4.33%
	50	128	0.043	0.207	7.11%
	100	32	0.017	0.130	2.74%
	100	64	0.043	0.207	7.19%
	100	128	0.053	0.230	8.36%

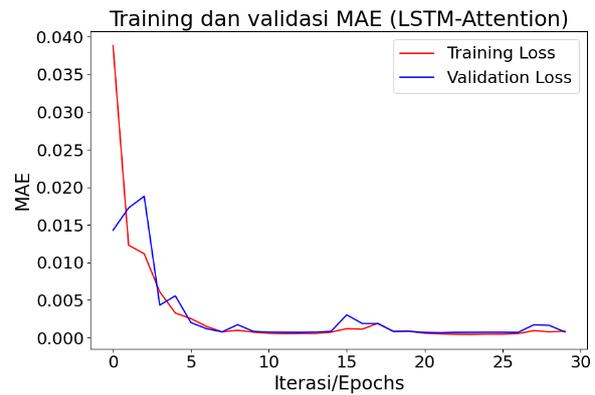
Berdasarkan pada *evaluation metrics* yang ditunjukkan pada Tabel 3 menunjukkan bahwa hasil percobaan parameter yang beragam. Percobaan ini diperoleh satu nilai evaluasi terbaik dengan nilai MAPE terendah. Nilai MAPE yang paling rendah adalah model LSTM-Attention-LSTM sebesar 2.74% dan nilai MAPE untuk model LSTM sebesar 3.68%, sehingga dapat disimpulkan model LSTM-Attention-LSTM merupakan arsitektur terbaik untuk melakukan peramalan harga cabai rawit merah untuk 30 hari ke depan. Parameter yang digunakan untuk melakukan peramalan ditunjukkan pada Tabel 4.

Tabel 4. Parameter Terbaik untuk Peramalan

Parameter	Batasan	
	LSTM	LSTM-Att
Jumlah Neuron	100	100
Jumlah Hidden Layer	3	3
Optimizer	Adam	Adam
Learning Rate	0,001	0,001
Batch Size	32	32



Gambar 4. Grafik Loss Function Model LSTM



Gambar 5. Grafik Loss Function Model LSTM-Attention-LSTM

Gambar 3 dan Gambar 4 menunjukkan grafik perubahan nilai loss function selama proses *training* model LSTM dan LSTM-Attention-LSTM untuk peramalan harga cabai rawit merah. Garis berwarna merah mewakili nilai *loss* pada data pelatihan, sedangkan garis berwarna biru merepresentasikan nilai *loss* pada data validasi (*val\_loss*). Sumbu horizontal pada grafik menunjukkan jumlah *epoch* atau iterasi pelatihan yang dilakukan, sementara sumbu vertikal mencatat nilai *loss* yang dihitung berdasarkan selisih antara nilai prediksi model dengan nilai aktualnya. Semakin kecil nilai *loss*, semakin akurat prediksi model tersebut. Berdasarkan pada grafik tersebut, dapat diamati bahwa baik nilai *loss* pada data pelatihan maupun *val\_loss* pada data validasi cenderung menurun seiring bertambahnya *epoch* pelatihan. Penurunan nilai *loss* menunjukkan bahwa model semakin mampu mempelajari data dengan baik, menghasilkan prediksi akurat, dan kinerja yang seimbang antara data pelatihan dan validasi. Hal ini menandakan model tidak mengalami *overfitting* atau *underfitting*, sehingga mampu melakukan generalisasi dengan baik pada data baru. Grafik *loss function* ini mengindikasikan bahwa model telah dilatih dengan baik dan dapat memberikan prediksi yang akurat.

Hasil penelitian ini dapat menjadi aplikasi potensial yang signifikan dalam manajemen risiko dan perencanaan strategis di sektor agribisnis terkait harga cabai rawit merah. Prediksi yang akurat dapat membantu

optimalisasi rantai pasokan, memungkinkan pelaku pasar untuk mengelola inventori dan distribusi secara lebih efisien, serta mengurangi risiko kelebihan atau kekurangan stok. Dalam hal manajemen risiko harga, petani dan pedagang dapat memanfaatkan model ini untuk mengantisipasi fluktuasi, menentukan kapan waktu tanam, panen, dan penjualan yang optimal sehingga perencanaan keuangan dapat ditingkatkan, berdasarkan prediksi harga. Model ini dapat menjadi pendukung keputusan bagi pemerintah dalam merancang dan mengimplementasikan kebijakan stabilisasi harga yang lebih efektif. Lebih lanjut, integrasi model ke dalam sistem peringatan dini dapat membantu mengantisipasi gejala harga ekstrem, memungkinkan respons cepat dari berbagai pemangku kepentingan. Oleh karena itu, penelitian ini berkontribusi dalam peningkatan efisiensi pasar, pengurangan risiko, dan peningkatan ketahanan sektor agribisnis cabai rawit merah tidak hanya di Jawa Barat, tetapi memungkinkan diterapkan di daerah-daerah lain di Indonesia.

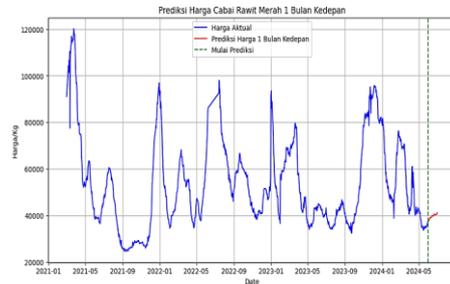
### 3.3. Hasil Peramalan

Akurasi suatu metode peramalan sangat bergantung pada seberapa minimal tingkat kesalahan atau *error* yang dihasilkan dalam memprediksi nilai di masa depan [26]. Metode dengan tingkat *error* terendah dipilih sebagai metode terbaik karena mampu memberikan prediksi harga cabai rawit merah yang paling akurat dan terpercaya. Penelitian ini menggunakan model LSTM-Attention-LSTM dengan nilai MAE 0.017, RMSE 0.130, dan MAPE 2.74% untuk harga cabai rawit merah di provinsi Jawa Barat. Hal ini menunjukkan peningkatan akurasi yang signifikan dengan penambahan *attention mechanism*. Selain itu Model LSTM-Attention-LSTM menunjukkan kemampuan yang lebih baik dalam menangkap dan memprediksi fluktuasi harga yang tajam. Hal ini terlihat dari nilai MAPE yang lebih rendah, mengindikasikan bahwa model ini lebih akurat dalam memprediksi perubahan persentase harga, termasuk saat terjadi fluktuasi yang signifikan, ditandai dengan penurunan nilai *loss* yang konsisten selama pelatihan dan tidak adanya tanda-tanda *overfitting* atau *underfitting* yang signifikan seperti yang ditunjukkan pada Gambar 5. Grafik *loss function* menunjukkan bahwa model dapat melakukan generalisasi dengan baik pada data baru, mengindikasikan kemampuannya dalam menangkap pola fluktuasi harga cabai rawit merah secara akurat. Selanjutnya dilakukan peramalan data harga cabai rawit merah selama 30 hari kedepan pada tanggal 1 Juni 2024 hingga 30 Juni 2024 seperti yang ditunjukkan pada Tabel 5.

Tabel 5. Prediksi Harga Cabai Rawit 1 Juni 2024 – 30 Juni 2024

Tanggal	Harga/Kg	Tanggal	Harga/Kg
01 Juni 2024	37.466,78	16 Juni 2024	39.813,18
02 Juni 2024	37.723,16	17 Juni 2024	39.768,38
03 Juni 2024	37.932,09	18 Juni 2024	39.872,11
04 Juni 2024	38.213,49	19 Juni 2024	40.114,63

05 Juni 2024	38.549,29	20 Juni 2024	40.530,92
06 Juni 2024	38.954,82	21 Juni 2024	40.577,36
07 Juni 2024	39.071,64	22 Juni 2024	40.441,90
08 Juni 2024	39.063,52	23 Juni 2024	40.319,30
09 Juni 2024	39.023,51	24 Juni 2024	40.252,09
10 Juni 2024	39.063,79	25 Juni 2024	40.331,38
11 Juni 2024	39.214,58	26 Juni 2024	40.352,70
12 Juni 2024	39.468,41	27 Juni 2024	40.363,98
13 Juni 2024	39.868,54	28 Juni 2024	40.487,39
14 Juni 2024	39.967,04	29 Juni 2024	40.722,82
15 Juni 2024	39.882,59	30 Juni 2024	41.090,98



Gambar 6. Plot Prediksi Harga Cabai Rawit Merah 1 Bulan ke depan

Berdasarkan pada Tabel 5 hasil peramalan harga cabai rawit merah berada direntang harga Rp 37.000/kg – Rp 41.000/kg. Dilihat dari rentang harga tersebut diperkirakan akan terjadi kenaikan harga cabai rawit merah di provinsi Jawa Barat pada bulan Juni seperti yang ditunjukkan pada Gambar 6.

## 4. Kesimpulan

Berdasarkan pada hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa peramalan harga cabai rawit merah, dengan menggunakan LSTM-Attention-LSTM menunjukkan bahwa model tersebut memiliki arsitektur terbaik untuk melakukan peramalan harga cabai rawit merah untuk masa yang akan datang dibandingkan dengan model LSTM. Pada konfigurasi 3 *hidden layer*, 100 *neuron*, 128 *dense*, 1 *dense*, dan 32 *batch size*, model LSTM-Attention-LSTM menghasilkan nilai evaluasi yang lebih baik dengan nilai MAE 0.017, RMSE 0.130, dan MAPE 2.74%, sedangkan model LSTM standar menghasilkan MAE 0.023, RMSE 0.152, dan MAPE 3.68%. Hal ini menunjukkan, dengan adanya penambahan *attention mechanism* pada model LSTM dapat meningkatkan akurasi peramalan secara signifikan, dengan penurunan MAPE sebesar 25.54%. Peramalan harga cabai rawit merah dengan model LSTM-Attention-LSTM menunjukkan bahwa harga cabai rawit merah di Jawa Barat diperkirakan akan berada dalam rentang Rp 37.000/kg hingga Rp 41.000/kg. Rentang harga tersebut mengindikasikan kemungkinan terjadinya kenaikan harga cabai rawit merah di Jawa Barat pada bulan Juni 2024.

## Daftar Rujukan

- [1] S. S. Mas'ud, SE, M.Si, Sri Wahyuningsih, *STATISTIK KONSUMSI PANGAN 2023*. Badan Pusat Statistik (BPS), 2023.
- [2] Y. J. Siregar, R. Hartono, and A. E. Hardana, "Peramalan Harga Cabai Rawit Di Kota Malang Dengan Metode Holt-Winters

- Exponential Smoothing,” *Agricore J. Agribisnis dan Sos. Ekon. Pertan. Unpad*, vol. 6, no. 2, 2022, doi: 10.24198/agricore.v6i2.34778.
- [3] I. Marina, D. Sukmawati, E. Juliana, and Z. N. Safa, “Dinamika Pasar Komoditas Pangan Strategis: Analisis Fluktuasi Harga Dan Produksi,” *Paspalum J. Ilm. Pertan.*, vol. 12, no. 1, p. 160, 2024, doi: 10.35138/paspalum.v12i1.700.
- [4] S. Kasus *et al.*, “Peramalan Harga Aneka Cabai Menggunakan Metode Long Short Term Memory (LSTM),” *Semin. Nas. Stat. Aktuaria Ji*, 2023, [Online]. Available: <https://prosidingsnsa.statistics.unpad.ac.id/>
- [5] P. S. Agribisnis and U. J. Soedirman, “Pengaruh Fluktuasi Harga Cabai Rawit Merah Terhadap Inflasi di Kabupaten Banyumas,” vol. 10, no. 2020, pp. 1866–1877, 2024.
- [6] H. Ihsan, R. Syam, and F. Ahmad, “Peramalan Penjualan dengan Metode Exponential Smoothing (Studi Kasus : Penjualan Bakso Kemasaan/Kiloan Rumah Bakso Bang Ipul),” *J. Math. Comput. Stat.*, vol. 1, no. 1, p. 1, 2019, doi: 10.35580/jmathcos.v1i1.9168.
- [7] M. Melina, Sukono, H. Napitupulu, and N. Mohamed, “Modeling of Machine Learning-Based Extreme Value Theory in Stock Investment Risk Prediction: A Systematic Literature Review,” *Big Data*, Jan. 2024, doi: 10.1089/big.2023.0004.
- [8] P. G. Zhang, “Time series forecasting using a hybrid ARIMA and neural network model,” *Neurocomputing*, vol. 50, pp. 159–175, 2003, doi: 10.1016/S0925-2312(01)00702-0.
- [9] G. Zhang, B. Eddy Patuwu, and M. Y. Hu, “Forecasting with artificial neural networks: The state of the art,” *Int. J. Forecast.*, vol. 14, no. 1, pp. 35–62, 1998, doi: 10.1016/S0169-2070(97)00044-7.
- [10] C. K. Poetra, S. F. Pane, and N. S. Fatolah, “Meningkatkan Akurasi Long-Short Term Memory (LSTM) pada Analisis Sentimen Vaksin Covid-19 di Twitter dengan Glove,” *J. Telemat.*, vol. 16, no. 2, pp. 85–90, 2022, doi: 10.61769/telematika.v16i2.400.
- [11] M. Mukhlis, A. Kustiyo, and A. Suharso, “Peramalan Produksi Pertanian Menggunakan Model Long Short-Term Memory,” *Bina Insa. Ict J.*, vol. 8, no. 1, p. 22, 2021, doi: 10.51211/biict.v8i1.1492.
- [12] R. Wen, K. Torkkola, B. Narayanaswamy, and D. Madeka, “A Multi-Horizon Quantile Recurrent Forecaster,” no. Nips 2017, 2017, [Online]. Available: <http://arxiv.org/abs/1711.11053>
- [13] Melina, Sukono, H. Napitupulu, and N. Mohamed, “A Conceptual Model of Investment-Risk Prediction in the Stock Market Using Extreme Value Theory with Machine Learning: A Semisystematic Literature Review,” *Risks*, vol. 11, no. 3, 2023, doi: 10.3390/risks11030060.
- [14] R. M. S. Adi and S. Sudianto, “Prediksi Harga Komoditas Pangan Menggunakan Algoritma Long Short-Term Memory (LSTM),” *Buld. Informatics, Technol. Sci.*, vol. 4, no. 2, pp. 1137–1145, 2022, doi: 10.47065/bits.v4i2.2229.
- A. Restu, H. Dwika, and D. Avianto, “Implementasi Algoritma LSTM untuk Prediksi Harga Cabai Merah Keriting di Yogyakarta,” vol. 5, no. 1, pp. 635–648, 2024.
- [16] M. David, I. Cholissodin, and N. Yulistira, “Prediksi Harga Cabai menggunakan Metode Long-Short Term Memory (Case Study : Kota Malang),” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 7, no. 3, pp. 1214–1219, 2023, [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/12406>
- [17] Fahmi Yusron Fiddin, A. Komarudin, and M. Melina, “Chatbot Informasi Penerimaan Mahasiswa Baru Menggunakan Metode FastText dan LSTM,” *J. Appl. Comput. Sci. Technol.*, vol. 5, no. 1, pp. 33–39, 2024, doi: 10.52158/jacost.v5i1.648.
- [18] I. Alexander, M. Khairani, and others, “Penerapan Metode Interpolasi Linear dan Geometric Mean Filter Pada Citra Resolusi Rendah Hasil Resampling,” *J. Ilmu Komput. dan Sist. Inf.*, vol. 3, no. 1, pp. 72–86, 2024.
- [19] M. A. R. Suleman and S. Shridevi, “Short-Term Weather Forecasting Using Spatial Feature Attention Based LSTM Model,” *IEEE Access*, vol. 10, no. August, pp. 82456–82468, 2022, doi: 10.1109/ACCESS.2022.3196381.
- [20] X. Wen and W. Li, “Time Series Prediction Based on LSTM-Attention-LSTM Model,” *IEEE Access*, vol. 11, no. April, pp. 48322–48331, 2023, doi: 10.1109/ACCESS.2023.3276628.
- [21] I. Indriyanti, N. Ichsan, H. Fatah, T. Wahyuni, and E. Ermawati, “Implementasi Orange Data Mining Untuk Prediksi Harga Bitcoin,” *J. Responsif Ris. Sains dan Inform.*, vol. 4, no. 2, pp. 118–125, 2022, doi: 10.51977/jti.v4i2.762.
- [22] Y. Dai, Q. Zhou, M. Leng, X. Yang, and Y. Wang, “Improving the Bi-LSTM model with XGBoost and attention mechanism: A combined approach for short-term power load prediction,” *Appl. Soft Comput.*, vol. 130, p. 109632, 2022, doi: 10.1016/j.asoc.2022.109632.
- [23] H. W. Herwanto, T. Widiyaningtyas, and P. Indriana, “Penerapan Algoritma Linear Regression untuk Prediksi Hasil Panen Tanaman Padi,” *J. Nas. Tek. Elektro dan Technol. Inf.*, vol. 8, no. 4, p. 364, 2019, doi: 10.22146/jnteti.v8i4.537.
- [24] I. Nabillah and I. Ranggadara, “Mean Absolute Percentage Error untuk Evaluasi Hasil Prediksi Komoditas Laut,” *JOINS (Journal Inf. Syst.*, vol. 5, no. 2, pp. 250–255, 2020, doi: 10.33633/joins.v5i2.3900.
- Y. Bai *et al.*, “Understanding and Improving Early Stopping for Learning with Noisy Labels,” *Adv. Neural Inf. Process. Syst.*, vol. 29, no. NeurIPS, pp. 24392–24403, 2021.
- L. Wiranda and M. Sadikin, “Penerapan Long Short Term Memory pada Data Time Series untuk Memprediksi Penjualan Produk PT. Metiska Farma,” *J. Nas. Pendidik. Tek. Inform.*, vol. 8, no. 3, pp. 184–196, 2019.