

## PERAMALAN PENJUALAN SAHAM NIKEL MENGGUNAKAN ALGORITMA *LONG SHORT TERM MEMORY* (LSTM)

Firhan Abdillah Mahbubi<sup>1\*</sup>, Teguh Iman Hermanto<sup>2</sup>, Chandra Dewi Lestari<sup>3</sup>

<sup>1,2,3</sup>Teknik Informatika, Sekolah Tinggi Teknologi Wastukencana, Purwakarta, Jawa Barat

Email: <sup>1\*</sup>[firhanabdillah32@wastukencana.ac.id](mailto:firhanabdillah32@wastukencana.ac.id), <sup>2</sup>[teguhiman@wastukencana.ac.id](mailto:teguhiman@wastukencana.ac.id), <sup>3</sup>[chandra@stt-wastukencana.ac.id](mailto:chandra@stt-wastukencana.ac.id)

(\*: coresponding author)

**Abstrak**-Indonesia memiliki sumber daya nikel terbesar di dunia, dengan produksi 1,6 juta ton dari total global 328 juta ton pada 2022. Kebijakan larangan ekspor bijih nikel mentah 2020 bertujuan meningkatkan pemrosesan dalam negeri dan menarik investasi. Pasokan nikel mencapai 26 miliar ton dengan cadangan 11.887 juta ton. Investasi mineral dan batu bara pada 2021 mencapai US\$35 miliar. Pemerintah merencanakan 53 *smelter* hingga 2024, dengan 19 beroperasi pada 2021. PT. Resource Alam Indonesia Tbk aktif dalam industri, menghadapi fluktuasi harga saham nikel yang memiliki masalah yaitu ketidakpastian bagi investor dalam membuat keputusan investasi akibat fluktuasi harga nikel di pasar dunia. Sehingga diperlukan peramalan harga saham yang efektif menggunakan analisis data deret waktu. Penelitian ini menggunakan pendekatan algoritma deep learning yaitu *Long Short Term Memory* (LSTM). Metode penelitian menggunakan CRISP-DM meliputi pemahaman bisnis, pemahaman data, persiapan data, pembuatan model, evaluasi model, dan deployment. Eksperimen menggunakan *Python* dan visualisasi menggunakan *Framework Streamlit*. Penelitian ini bertujuan untuk mengevaluasi efektivitas model LSTM dalam memprediksi harga saham Nikel pada PT. Resource Alam Indonesia Tbk dengan menggunakan parameter teknis optimal. Hasil penelitian menunjukkan bahwa model *Long Short Term Memory* (LSTM), mampu memprediksi penjualan saham Nikel pada PT. Resource Alam Indonesia Tbk (kata sandi: KKGLJK) dengan baik, dengan nilai MAE sebesar 33.15, nilai RMSE 48.14, nilai MSE 2317.33, dan nilai MAPE 7.39. Dari berbagai kombinasi parameter yang diuji, kombinasi terbaik adalah dengan *batch size* 32, *epochs* 150, dan *optimizer Adam*. Temuan ini memberikan pandangan yang berharga bagi investor dalam mengambil keputusan investasi yang lebih informatif dan efektif.

**Kata kunci:** *Long Short Term Memory* (LSTM), Peramalan, Penjualan Saham Nikel, PT. Resource Alam Indonesia Tbk.

**Abstract-** Indonesia has the world's largest nickel resources, with production of 1.6 million tons out of a global total of 328 million tons by 2022. In 2020, the Indonesian government imposed a ban on nickel ore exports to increase domestic processing and attract investment. Nickel supply reached 26 billion tons with reserves of 11,887 million tons. Mineral and coal investment in 2021 reached US\$35 billion. The government plans 53 *smelters* until 2024, with 19 operating in 2021. PT Resource Alam Indonesia Tbk is active in the industry and faces fluctuations in nickel stock prices, which create problems, namely uncertainty for investors in making investment decisions due to fluctuations in nickel prices on the world market. So, effective stock price forecasting is needed using time series data analysis. This research uses a deep learning algorithm approach: *Long Short Term Memory* (LSTM). The research method uses CRISP-DM, which includes business understanding, data understanding, data preparation, model building, model evaluation, and deployment. Experimentation uses *Python*, and visualization uses the *Streamlit Framework*. This study uses optimal technical parameters to evaluate the LSTM model's effectiveness in predicting Nickel stock prices at PT Resource Alam Indonesia Tbk. The results showed that the *Long Short Term Memory* (LSTM) model could predict the sale of Nickel shares at PT. Resource Alam Indonesia Tbk (password: KKGLJK) well, with an MAE value of 33.15, RMSE value of 48.14, MSE value of 2317.33, and MAPE value of 7.39. The best combination of the parameter combinations tested is with *batch size* 32, *epochs* 150, and *optimizer Adam*. The findings provide valuable insights for investors in making more informative and effective investment decisions.

**Keywords:** Forecasting, *Long Short Term Memory* (LSTM), Nickel Stock Sales, PT. Resource Alam Indonesia Tbk.

### 1. PENDAHULUAN

Indonesia, sebagai negara dengan sumber daya mineral yang besar, memiliki peran penting dalam pasar nikel dunia, dengan pasokan nikel terbesar di dunia. Untuk meningkatkan nilai tambah nikel domestik, pemerintah Indonesia memberlakukan larangan ekspor bijih nikel mentah pada tahun 2020, yang bertujuan untuk menarik investasi di sektor hilir dan memperkuat industri nikel nasional [1]. Data menunjukkan bahwa Indonesia memproduksi 1,6 juta ton nikel dari total produksi dunia sebesar 328 juta ton pada tahun 2022, dengan cadangan bijih nikel yang melimpah [2]. Pemerintah berencana membangun 53 *smelter* hingga tahun 2024, di mana 19 sudah beroperasi pada tahun 2021. PT. Resource Alam Indonesia Tbk adalah salah satu perusahaan yang aktif dalam sektor ini [3].

Masalah utama yang dihadapi adalah ketidakpastian bagi investor dalam membuat keputusan investasi akibat fluktuasi harga nikel di pasar dunia. Fluktuasi harga saham perusahaan di sektor nikel, seperti PT. Resource Alam Indonesia Tbk, menjadi perhatian penting bagi para investor. Peramalan harga saham adalah kegiatan yang kompleks namun krusial dalam investasi. *Long Short-Term Memory* (LSTM), sebuah jenis *Recurrent Neural*

Network (RNN), telah terbukti efektif dalam menganalisis data deret waktu. LSTM memiliki kemampuan untuk menangkap pola dan ketergantungan temporal dalam data, sehingga sangat cocok digunakan untuk peramalan harga saham[4]. Keunggulan LSTM, seperti kemampuannya mengatasi masalah *vanishing gradient* dan fleksibilitas dalam memodelkan ketergantungan *non-linear*, menjadikannya metode yang tepat untuk peramalan harga saham[5].

Penelitian ini bertujuan untuk mengevaluasi efektivitas model LSTM dalam memprediksi harga saham PT. Resource Alam Indonesia Tbk dengan menggunakan parameter teknis optimal. Hasil penelitian ini dapat membantu investor dalam membuat keputusan investasi yang lebih baik dan memberikan kontribusi signifikan dalam peningkatan kemampuan prediksi harga saham di sektor nikel. Selain itu, penelitian ini akan menggunakan web *Streamlit* untuk menyajikan prediksi harga saham dan grafik yang mempermudah keputusan investasi.

Model LSTM, pertama kali diperkenalkan oleh Hochreiter dan Schmidhuber pada tahun 1997, dirancang untuk mengatasi keterbatasan RNN dalam menangani masalah ketergantungan jangka panjang. LSTM menggunakan struktur sel yang terdiri dari gate input, gate output, dan gate forget, yang memungkinkan model untuk menyimpan informasi yang relevan dalam jangka panjang dan membuang informasi yang tidak relevan. Keunggulan ini menjadikan LSTM sebagai pilihan yang tepat untuk prediksi harga saham yang bersifat non-linear dan memiliki pola temporal yang kompleks [6]

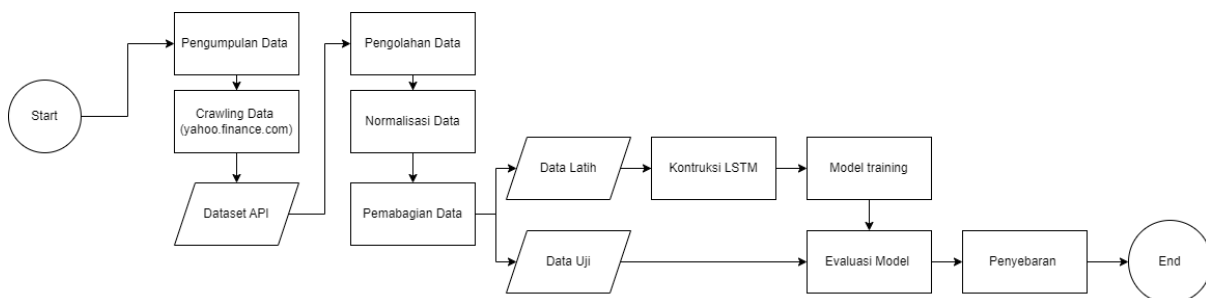
Beberapa penelitian sebelumnya telah menggunakan LSTM untuk prediksi harga saham dengan hasil yang cukup baik. Misalnya, sebuah studi menggunakan model LSTM untuk memprediksi harga saham PT Erajaya Swasembada Tbk (ERAA) dengan data dari Desember 2011 sampai Desember 2021 [7]. Model ini menerapkan parameter optimal seperti 4 *hidden layer*, 50 *neuron per hidden layer*, *batch size* 4, maksimum *epoch* 100, *optimizer adam*, serta fungsi aktivasi tanh dan sigmoid, dan menghasilkan nilai RMSE 12,07 dan MAPE 1,86% . Penelitian oleh Fischer dan Krauss menggunakan LSTM untuk prediksi harga saham di pasar AS menunjukkan bahwa LSTM dapat mengungguli model tradisional seperti ARIMA dan SVM dalam hal akurasi prediksi [8]. Selain itu, penelitian oleh Bao, Yue, dan Rao juga menunjukkan bahwa LSTM dapat memberikan hasil prediksi yang lebih baik dibandingkan dengan model deep learning lainnya seperti CNN dalam memprediksi harga saham [9].

Dengan mempertimbangkan kelebihan metode LSTM dan hasil penelitian sebelumnya, penelitian ini bertujuan untuk mengaplikasikan LSTM dalam prediksi harga saham PT. Resource Alam Indonesia Tbk dengan menggunakan parameter teknis yang optimal untuk meningkatkan akurasi dan efektivitas model prediksi. Penelitian ini akan diterapkan dalam sebuah web *Streamlit* yang menyajikan halaman prediksi untuk satu tahun ke depan serta grafik yang mempermudah investor dalam menentukan investasi saham.

## 2. METODE PENELITIAN

### 1. Kerangka Penelitian

Penelitian menggunakan pendekatan kuantitatif dengan metode eksperimental untuk memprediksi harga saham PT. Resource Alam Indonesia Tbk. Penelitian ini mencakup tahapan pengumpulan data dengan teknik *crawling* data dari *Application Programming Interface* (API) yang disediakan oleh *Finance.Yahoo.com* untuk mengumpulkan informasi awal mengenai saham PT Resource Alam Indonesia Tbk (kode saham: KKGJ.JK) yang berbentuk *dataset*. *Crawling data* adalah proses otomatis untuk mengunduh informasi dari internet, tahapan pengolahan data yaitu melakukan *preprocessing*, normalisasi data dan pembagian data, tahapan pembuatan model menggunakan algoritma *Long Short-Term Memory* (LSTM), tahapan evaluasi model menggunakan data uji dengan MAPE, MAE, MSE, RMSE dan tahapan penyebaran *Web* interaktif *streamlit* untuk informasi dan pengetahuan.



Gambar 1. Kerangka Penelitian

Berikut ini adalah detail dari tiap tahapan pada Gambar 1.

**a. Pengumpulan Data**

Data yang digunakan dalam penelitian, merupakan data yang dicrawling dari situs Yahoo Finance yang berisi riwayat harga saham PT. Resource Alam Indonesia Tbk dari tahun 2021 hingga 2024. Data ini memiliki beberapa atribut yaitu *open*, *close*, *high*, *low*, dan *volume* perdagangan harian. Pada Tabel 1 menampilkan contoh data mentah yang merupakan dataset penelitian.

**Tabel 1.** Hasil Crawling pada Situs Yahoo Finance khusus pada PT. Resource Alam Indonesia Tbk

Date	Open	High	Low	Close	Adj Close	Volume	company_name
01/01/2021	256	308	245	308	259	111162	KKGLJK
02/01/2021	308	308	287	301	252	95104	KKGLJK
03/01/2021	299	301	281	295	247	88370	KKGLJK
04/01/2021	281	299	277	295	247	61227	KKGLJK
05/01/2021	293	293	276	276	231	776171	KKGLJK
06/01/2021	272	295	270	295	247	122869	KKGLJK

**b. Pengolahan Data**

1) *Preprocessing*

Pada tahap ini kami melakukan pembersihan dataset serta melakukan beberapa tahap pra-pemrosesan, seperti pengisian nilai yang hilang pada dataset.

2) Normalisasi Data:

Data akan dinormalisasi ke dalam rentang [0, 1] menggunakan rumus pada persamaan (1).

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{1}$$

Keterangan:

x': Nilai data yang telah dinormalisasi

x: Nilai asli data sebelum dinormalisasi

x min : Nilai minimum dari *dataset*

x max : Nilai maksimum dari *dataset*

3) Pembagian Data (SPLIT)

Data akan dibagi dengan 80% data latih dan 20% data uji. Data latih digunakan untuk membangun model *Long Short Term Memory*, sedangkan data uji digunakan sebagai mengevaluasi kinerja model [10]. Pada Tabel 2 menampilkan contoh data mentah yang merupakan dataset penelitian.

**Tabel 2.** Hasil Pengolahan data mentah

Date	Close	Company_Name
01/01/2021	308	KKGLJK
02/01/2021	301	KKGLJK
03/01/2021	295	KKGLJK
04/01/2021	295	KKGLJK
05/01/2021	276	KKGLJK
06/01/2021	295	KKGLJK

**c. Pembuatan Model**

1) Pemilihan Algoritma.

Algoritma yang digunakan pada penelitian ini adalah *Long Short Term Memory* (LSTM), jenis khusus dari *Recurrent Neural Network* (RNN). LSTM dirancang untuk mengatasi masalah vanishing gradient yang sering terjadi pada RNN tradisional dan sangat efektif untuk analisis data deret waktu. Dengan menggunakan unit memori dan gerbang (*input*, *forget*, dan *output*), LSTM dapat menyimpan dan mengontrol informasi penting dari data historis, memungkinkan pemodelan ketergantungan jangka panjang yang lebih baik [11].

2) Arsitektur Model:

Model akan dibangun dengan beberapa lapisan, termasuk lapisan *input*, beberapa lapisan *Long Short-Term Memory*, dan lapisan *output*. Fungsi aktivasi yang diterapkan adalah *Rectified Linear Unit* untuk lapisan tersembunyi, sementara lapisan *output* menggunakan fungsi *linear* [12].

3) Pelatihan Model:

Model akan dilatih menggunakan data latih dengan optimizer Adam dan fungsi MSE. Pelatihan dilakukan dalam beberapa epoch hingga model mencapai konvergensi [13].

4) *Optimizer*:

Optimizer ini digunakan untuk mengupdate bobot-bobot dalam jaringan LSTM selama pelatihan, dengan parameter standar [14].

**d. Evaluasi Model**

Kinerja model akan dievaluasi menggunakan data uji dengan metrik berikut:

1) *Mean Absolute Percentage Error (MAPE)*

MAPE adalah menghitung *mean* kesalahan absolut dengan persentase [15]. Rumus MAPE terdapat pada persamaan (2).

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (2)$$

Keterangan:

n: Jumlah sampel dalam data

$y_i$ : Nilai aktual

$\hat{y}_i$ : Nilai prediksi

$|\cdot|$ : Nilai absolut dari kesalahan prediksi

2) *Mean Absolute Error (MAE)*

MAE berfungsi untuk Menghitung *mean* kesalahan absolut dengan hasil prediksi dan data aktual [16].

Rumus MAE terdapat pada persamaan (3).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

Keterangan:

n: Jumlah sampel dalam data

$y_i$ : Nilai aktual

$\hat{y}_i$ : Nilai prediksi

$|\cdot|$ : Nilai absolut dari kesalahan prediksi

3) *Mean Squared Error (MSE)*

MSE berfungsi untuk Menghitung *mean* kesalahan kuadrat dengan nilai prediksi dan nilai aktual [17].

Rumus MAE terdapat pada persamaan (4).

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

Keterangan:

n: Jumlah sampel dalam data

$y_i$ : Nilai aktual

$\hat{y}_i$ : Nilai prediksi

$(\cdot)^2$ : Kuadrat dari kesalahan prediksi

4) *Root Mean Squared Error (RMSE)*:

RMSE untuk Menghitung akar kuadrat dari rata-rata kesalahan kuadrat [14]. Rumus MAE terdapat pada persamaan (5).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

Keterangan:

n: Jumlah sampel dalam data

$y_i$ : Nilai aktual

$\hat{y}_i$ : Nilai prediksi

$\sqrt{\cdot}$ : Akar kuadrat dari rata-rata kesalahan kuadrat

**e. Penyebaran**

Pada fase akhir, yakni penyebaran penyampaian hasil dari seluruh rangkaian proses penelitian yang telah dilakukan. Langkah ini mencakup pembuatan laporan presentasi yang menampilkan hasil yang diperoleh dari proses pemodelan dan evaluasi dan *Web* interaktif streamlit untuk informasi dan pengetahuan yang diinginkan.

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Pengolahan Data

Proses *Crawling Dataset*, dilakukan *crawling* data saham nikel dari PT. *Resource Alam Indonesia Tbk* (kode saham: *KKGI.JK*) menggunakan modul *yfinance* dalam *Python*. Data diambil dari *Yahoo Finance* mencakup periode 2021 hingga saat ini, terdiri dari 819 baris yang meliputi harga pembukaan, tertinggi, terendah, penutupan, penutupan yang disesuaikan, dan volume perdagangan. Proses *crawling* data ini bertujuan untuk memperoleh dataset yang diperlukan untuk analisis dan pengembangan model prediksi pergerakan harga saham nikel PT. *Resource Alam Indonesia Tbk*. Proses *Crawling* pada penelitian ini dapat dilihat kode program pada Gambar 2.

```
1 # Import modul yang diperlukan
2 import yfinance as yf
3 from datetime import datetime
4 import matplotlib.pyplot as plt
5 from mplfinance.original_flavor import candlestick_ohlc
6 import matplotlib.dates as mdates
7
8 # Menentukan kode saham yang akan diambil datanya
9 stock_symbol = 'KKGI.JK'
10
11 # Set up End dan Start times untuk pengambilan data
12 end_date = datetime.now()
13 start_date = datetime(2021, 1, 1) # Tanggal awal pengambilan data
14
15 # Menggunakan yfinance untuk mengambil data dari Yahoo Finance
16 data = yf.download(stock_symbol, start=start_date, end=end_date)
```

Gambar 2. *Crawling Dataset*

#### 3.2 Normalisasi Data

Peneliti menggunakan *forward fill* (*fillna* (*method='ffill'*)) untuk mengisi nilai hilang, memastikan data tetap kontinu. Data kemudian diubah menjadi *array* dua dimensi dengan satu kolom. Normalisasi dilakukan menggunakan *MinMaxScaler* dari *sklearn.preprocessing*, mengubah nilai ke rentang 0 hingga 1. Normalisasi ini memudahkan model dalam memahami pola data tanpa terpengaruh perbedaan skala antar fitur [18]. Pada normalisasi data yang akan dilakukan terdapat pada gambar 3.

```
1 import tensorflow as tf
2 from tensorflow.keras.models import Sequential
3 from tensorflow.keras.layers import Dense, LSTM
4 import yfinance as yf
5 from datetime import datetime, date
6 import numpy as np
7 from sklearn.preprocessing import MinMaxScaler
8 import matplotlib.pyplot as plt
9 import pandas as pd
10 # download the data
11 df = yf.download(tickers=['KKGI.JK'], period='3y')
12 y = df['Close'].fillna(method='ffill')
13 y = y.values.reshape(-1, 1)
14
15 # scale the data
16 scaler = MinMaxScaler(feature_range=(0, 1))
17 scaler = scaler.fit(y)
18 y = scaler.transform(y)
```

Gambar 3. Normalisasi

#### 3.3 Pembagian Data

Dataset Penelitian sebanyak 819 baris yang kemudian dilakukan *SPLIT* dengan pembagian data uji dan data latih yang digunakan memiliki 819 data. Pertama, *indeks* pembagian dihitung dengan mengalikan panjang *dataset* (819) dengan 0.8, menghasilkan 655 (80% dari 819) untuk data latih. Fungsi *int()* memastikan hasilnya bilangan



bulat. *Dataset* X dan Y kemudian dibagi menjadi dua: *X\_train* dan *Y\_train* berisi 655 data pertama, sementara *X\_test* dan *Y\_test* berisi 164 data sisanya. Pembagian ini dilakukan dengan *slicing array*, yaitu *X[:655]* dan *Y[:655]* untuk data latih, serta *X[164:]* dan *Y[164:]* untuk data uji. Langkah ini memastikan model dilatih pada satu subset data dan diuji pada *subset* lain, membantu mengevaluasi kemampuan generalisasi model terhadap proses pembagian data uji dan data latih pada gambar 4.

```
1 # Membagi data menjadi set pelatihan dan set uji (misalnya, 80% pelatihan, 20% uji)
2 train_size = int(len(X) * 0.8)
3 X_train, X_test = X[:train_size], X[train_size:]
4 Y_train, Y_test = Y[:train_size], Y[train_size:]
```

Gambar 4. Pembagian Data Uji dan Latih

### 3.4 Pembuatan Model

Dalam pembuatan model ini, penentuan model LSTM yang akan dibentuk berdasarkan parameter yang telah diperlukan. Parameter yang diperlukan adalah:

- a. *Hidden Layer*: 2
- b. *Neuron Hidden*: 50
- c. *Batch size*: 32
- d. *Epoch maximum*: 50, 100, 150
- e. *Optimizer*: Adam, Adamax, Sgd dan Rmspo

Parameter tersebut mengacu pada penelitian sebelumnya oleh [7] dan juga pengembangan dari penulis. Parameter dalam penelitian sebelumnya digunakan sebagai acuan karena mereka dianggap optimal dalam penelitian tersebut, dengan beberapa penyesuaian Parameter dalam penelitian ini tidak memiliki aturan baku, sehingga dapat diubah sesuai dengan kebutuhan dan preferensi peneliti. Jumlah input dan arsitektur memengaruhi model. LSTM yang dibuat berdasarkan parameter-parameter di atas. Model *Sequential* dari Keras digunakan untuk membangun arsitektur LSTM. Model dilengkapi dengan dua lapisan LSTM dengan 50 unit dan satu lapisan *Dense*. Model dikompilasi dengan menggunakan *Adam* dan *loss function* *'mean\_squared\_error'*. Pelatihan model dilakukan dengan set pelatihan (*X\_train* dan *Y\_train*) dengan jumlah *epoch* yang berbeda-beda (50, 100, dan 150), serta *batch size* sebanyak 32. Pada *optimizer* yang akan digunakan sebagai perbandingan yaitu ada 4 *Adam*, *AdaMax*, *SGD* dan *RMSProp* seperti yang terlihat pada gambar 5 dan 6.

```
1 n_lookback = 164 # panjang urutan input (periode melihat ke belakang)
2 n_forecast = 365 # panjang urutan output (periode perkiraan)
3
4 X = []
5 Y = []
6
7 for i in range(n_lookback, len(y_scaled) - n_forecast + 1):
8     X.append(y_scaled[i - n_lookback: i])
9     Y.append(y_scaled[i: i + n_forecast])
10
11 X = np.array(X)
12 Y = np.array(Y)
```

Gambar 5. Kontruksi Model Long Short-Term Memory (LSTM)

```
1 eval_data = []
2
3 for epoch in [50, 100, 150]:
4     # Melatih model
5     model = Sequential()
6     model.add(LSTM(units=50, return_sequences=True, input_shape=(n_lookback, 1)))
7     model.add(LSTM(units=50))
8     model.add(Dense(n_forecast))
9     model.compile(loss='mean_squared_error', optimizer='adam')
10
11 model.fit(X_train, Y_train, epochs=epoch, batch_size=32, verbose=0)
12
13 # Menghasilkan perkiraan pada set uji
14 Y_test_pred = model.predict(X_test)
15
16 # Mengembalikan skala prediksi ke skala asli
17 Y_test_pred_rescaled = scaler.inverse_transform(Y_test_pred.flatten().reshape(-1, 1)).reshape(Y_test_pred.shape)
18 Y_test_rescaled = scaler.inverse_transform(Y_test.flatten().reshape(-1, 1)).reshape(Y_test.shape)
19
```

Gambar 6. Model Sequential Keras

### 3.5 Evaluasi Model

Hasil Evaluasi dilakukan berbagai pengujian untuk menentukan kombinasi parameter terbaik dalam model peramalan. Variasi parameter meliputi *batch size*, *epochs*, dan *optimizer*. Pada Tabel 3 menampilkan Evaluasi performa menggunakan RMSE, MAE, MSE, dan MAPE.

**Tabel 3.** Hasil Evaluasi Kinerja LSTM menggunakan Beberapa Parameter

<i>Bacth</i>	<i>Epochs</i>	<i>Optimizer</i>	RMSE	MAE	MSE	MAPE
32	50	adam	62,04	46,00	3849,22	10,38
32	100	adam	63,23	45,80	3997,77	10,36
32	150	adam	<b>48,14</b>	<b>33,15</b>	<b>2317,33</b>	<b>7,39</b>
32	50	adamax	69,80	55,32	4872,16	12,56
32	100	adamax	63,29	46,99	4005,12	10,60
32	150	adamax	54,94	38,08	3018,55	8,46
32	50	SGD	250,99	232,31	62997,29	48,12
32	100	SGD	243,66	224,19	59371,57	46,30
32	150	SGD	235,19	214,53	55315,45	44,15
32	50	RMSprop	68,41	54,35	4679,55	12,24
32	100	RMSprop	56,36	40,56	3176,45	9,04
32	150	RMSprop	50,89	35,54	2590,01	7,88

Angka yang ditebalkan memiliki performa terbaik

Berdasarkan pada hasil evaluasi kinerja model LSTM pada Tabel 3, maka kombinasi optima terdapat pada batch size 32, epochs 150, optimizer adam. RMSE bernilai 48,14, MAE bernilai 33,15, MSE bernilai 2317,33, dan MAPE bernilai 7,39. nilai terendah menunjukkan performa peramalan yang superior. Optimizer adam unggul dibandingkan AdaMax, SGD, dan RMSProp dalam stabilitas dan efisiensi pelatihan model. Pada Gambar 7 menampilkan grafik peramalan (*forecasting*) selama satu tahun ke depan.



**Gambar 7.** Grafik Hasil Peramalan (*Forecasting*) tahun 2025 menggunakan Long Short-Term Memory (LSTM)

### 3.6 Penyebaran

Pada tahap ini akan menampilkan tampilan layar dari aplikasi untuk prediksi analisis harga saham dengan algoritma Long Short-Term Memory (LSTM) pada Saham PT. Resource Alam Indonesia Tbk.

a. Tampilan Halaman Menu “Home”

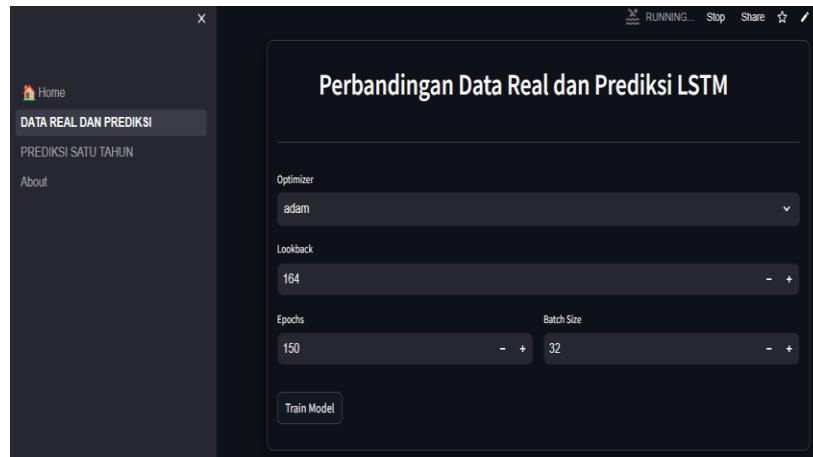
Pada Gambar 8 menampilkan layar Halaman "Home" yang berfungsi sebagai dasbor halaman utama yang memberikan ringkasan prediksi dan metrik penting terkait harga saham nikel pada PT. Resource Alam Indonesia Tbk (kode saham: KKGI.JK) menggunakan model LSTM.



**Gambar 8.** Tampilan Layar Halaman menu “Home” pada Aplikasi

b. Tampilan Halaman Data Real dan Prediksi

Pada Tampilan layar di Gambar 9, pengguna dapat mengatur parameter penting untuk melatih model LSTM. Optimizer algoritma yang mengubah bobot dan bias jaringan saraf. Pilihan optimizer meliputi optimizer Adaptive Moment Estimation (Adam), AdaMax, SGD, dan RMSProp, dengan Adam disarankan karena performanya yang konsisten [19]. Lookback ditetapkan pada 164 untuk menentukan seberapa jauh mundur model menggunakan data historis. Epochs diatur ke 150, menunjukkan berapa kali seluruh dataset dilalui selama proses pelatihan.



**Gambar 9.** Tampilan Layar Halaman Menu “Data Real dan Prediksi” pada Aplikasi



**Gambar 10.** Contoh Tampilan Layar Grafik Hasil Peramalan Menggunakan Pengaturan *Adaptive Moment Estimation* (Adam) Dan Epochs 150

Pada Gambar 10 menampilkan contoh hasil peramalan pada aplikasi sesuai dengan parameter yang telah diatur pada halaman di Gambar 9. Gambar 10 menunjukkan bahwa Grafik dapat menampilkan kemampuan model dalam memprediksi harga saham KKGI.JK berdasarkan data historis. Sehingga berdasarkan hasil penelitian ini, Model LSTM secara akurat dapat mengikuti tren data aktual, mencerminkan kemampuan PT. Resource Alam Indonesia Tbk (KKGI.JK) dalam memprediksi pola waktu dan mengolah data deret waktu. Hasil ini menunjukkan bahwa model LSTM dapat membuat prediksi valid dengan mengidentifikasi pola dan tren dari data sebelumnya.

c. Tampilan Halaman Prediksi Satu Tahun

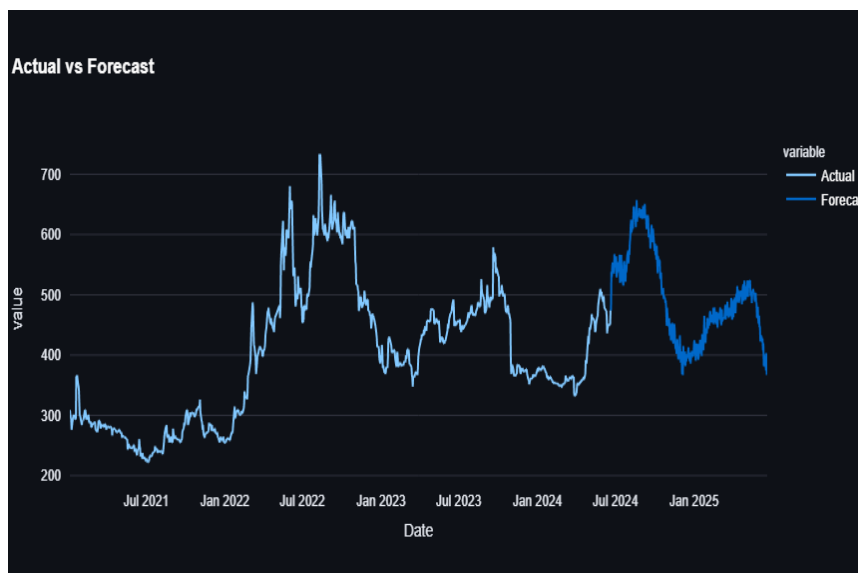
Pada Gambar 11 menampilkan halaman pengaturan pada aplikasi untuk melakukan peramalan atau prediksi satu tahun dengan melakukan *input* sebuah parameter yang ditentukan yaitu *optimizer adam*, *Lookback 164*, *Forecast 365*, *Epochs 150* dan *batch size 32*.





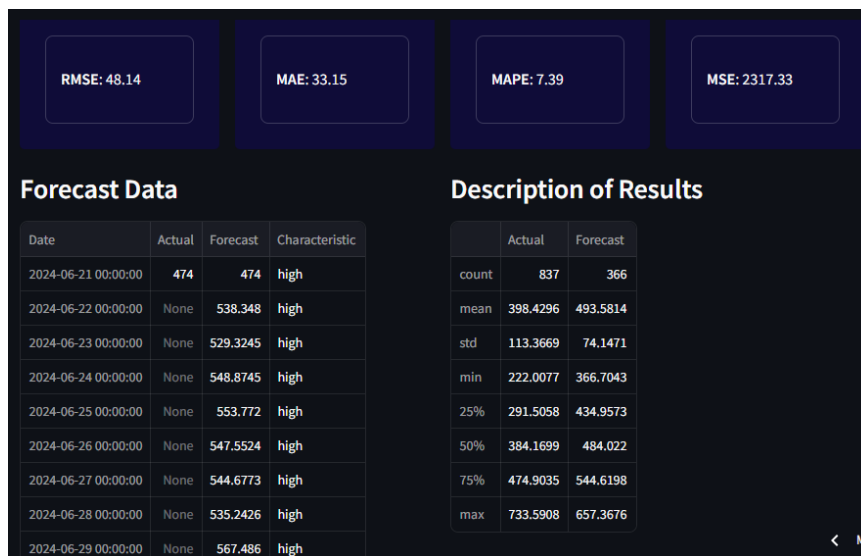
**Gambar 11.** Tampilan Layar Halaman Pengaturan Algoritma LSTM untuk Prediksi Peramalan Harga Saham Satu Tahun

Setelah proses pelatihan model selesai, hasil prediksi untuk satu tahun ke depan akan ditampilkan dalam bentuk grafik dan tabel. Grafik "Actual vs Forecast" memperlihatkan persamaan antara data yang diprediksi dan data yang sebenarnya oleh model. Garis biru pada grafik mewakili data aktual, sementara garis biru muda menunjukkan prediksi yang dihasilkan oleh model. Pada Gambar 12 merupakan tampilan layar dari aplikasi berupa grafik pergerakan harga saham dengan nilai aktual dan peramalan (*forecast*), sehingga pengguna dapat mengidentifikasi kesamaan dan perbedaan antara nilai aktual dan prediksi dengan mudah.



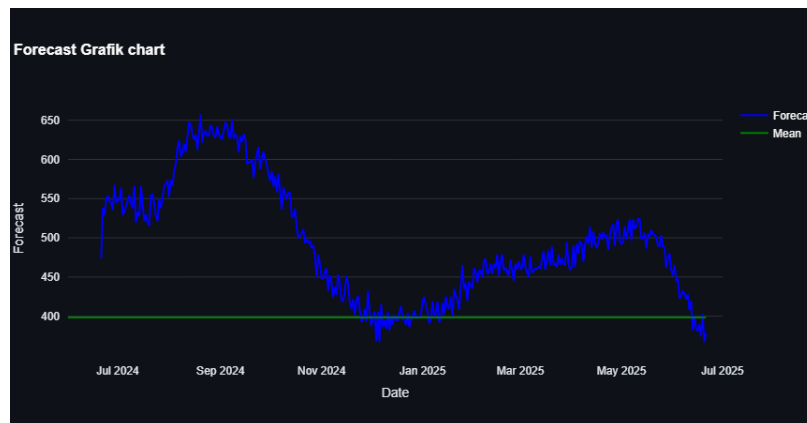
**Gambar 12.** Tampilan Layar Aplikasi yang menampilkan Grafik Hasil Prediksi Satu Tahun (2025) dan Data Real Menggunakan LSTM

Mengevaluasi model menggunakan metrik RMSE, MAE, MAPE, dan MSE. RMSE mengukur kesalahan prediksi dalam satuan data asli, MAE menunjukkan rata-rata kesalahan absolut, MAPE memberikan persentase kesalahan relatif, dan MSE menghitung rata-rata kesalahan kuadrat antara prediksi dan nilai aktual. Nilai-nilai ini menunjukkan performa dan akurasi model. Pada "Forecast Data" menyajikan prediksi model dari tanggal tertentu, detail nilai prediksi, karakteristik, dan perbandingan dengan nilai aktual. Tabel "Description of Results" memberikan statistik deskriptif untuk nilai aktual dan prediksi, seperti mean, standar deviasi, nilai min dan max, serta kuartil. Statistik ini membantu evaluasi akurasi dan konsistensi model. Gambar 13 merupakan tampilan layar dari aplikasi yang menunjukkan analisis "Forecast Data" dan "Description of Results" sehingga memungkinkan pengguna untuk memahami performa model dan mengidentifikasi area yang memerlukan peningkatan.



**Gambar 13.** Tampilan Layar Halaman Hasil Evaluasi Model LSTM untuk Prediksi Satu Tahun

Setelah "Forecast Data" dan "Description of Results" yang menyediakan statistik deskriptif untuk nilai aktual dan prediksi, terdapat grafik hasil Peramalan (*forecasting*). Grafik ini adalah grafik garis yang menggambarkan karakteristik prediksi selama satu tahun, dari Juli 2024 hingga Juli 2025. Pada Gambar 14 menunjukkan garis biru mewakili nilai prediksi, sedangkan garis hijau menunjukkan rata-rata dari nilai prediksi.



**Gambar 14.** Tampilan Layar Halaman Grafik Hasil Peramalan (Prediksi) Satu Tahun Kedepan Menggunakan Algoritma LSTM

Secara umum, grafik menunjukkan bahwa nilai prediksi (garis biru) berfluktuasi secara signifikan di sekitar garis rata-rata (garis hijau). Nilai prediksi yang kondisi kurang dari nilai *mean* "low", sedangkan jika berada di atas nilai *mean* menunjukkan kondisi "high". Fluktuasi yang sering dan tidak beraturan menandakan bahwa data yang diprediksi memiliki tingkat variabilitas yang tinggi sepanjang tahun. Garis hijau yang stabil membantu memberikan gambaran umum tentang kecenderungan sentral dari data prediksi ini.

### 3.7 Diskusi

Proses penelitian dimulai dengan pengumpulan data historis harga saham dari *Yahoo Finance*, yang mencakup periode Januari 2021 hingga Mei 2024. Data tersebut kemudian dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian model, memungkinkan evaluasi generalisasi model LSTM. Model ini dirancang dengan dua lapisan LSTM yang masing-masing memiliki 50-unit neuron, dan satu lapisan Dense. Selama pemrosesan data, dilakukan normalisasi untuk memastikan konsistensi dan efektivitas pelatihan model. Model LSTM kemudian dilatih menggunakan optimizer Adam dan 150 epochs, yang memberikan hasil terbaik berdasarkan metrik evaluasi seperti RMSE, MAE, MSE, dan MAPE.

Simulasi dan validasi model menunjukkan bahwa model LSTM dapat menangkap pola harga saham secara efektif, dengan prediksi yang signifikan untuk periode mendatang. Peningkatan harga yang diprediksi dari Juli hingga September 2024, diikuti oleh penurunan tajam, mencerminkan tren pasar yang dapat dimanfaatkan untuk

strategi investasi. Fluktuasi yang diprediksi hingga Mei 2025 menunjukkan variabilitas pasar yang harus diperhatikan oleh investor. Secara keseluruhan, proses ini menunjukkan bahwa model LSTM adalah alat yang berguna dalam analisis prediktif harga saham. Namun, penelitian ini juga mengungkapkan batasan terkait dengan ukuran dataset dan periode waktu, yang memerlukan penelitian lebih lanjut dengan model lebih kompleks dan data eksternal untuk hasil yang lebih akurat.

#### 4. KESIMPULAN

Penelitian ini menggunakan model LSTM untuk melakukan peramalan atau prediksi harga saham nikel pada PT. Resource Alam Indonesia Tbk (KKGI.JK) dengan data dari Januari 2021 hingga Mei 2024. Dengan pembagian dataset 80% data latih dan 20% data uji, menggunakan algoritma *Long Short-Term Memory* (LSTM). Penelitian ini melakukan beberapa hiperparameter tuning pada model LSTM untuk mendapatkan kinerja yang terbaik dan menemukan bahwa menggunakan pengaturan parameter optimizer Adam dan 150 epochs, model LSTM bekerja secara optimal dengan nilai MAE sebesar 33.15, nilai RMSE 48.14, nilai MSE 2317.33, dan nilai MAPE 7.39.

Hasil penelitian ini menemukan bahwa berdasarkan hasil eksperimen menggunakan metode LSTM dapat memprediksi terjadinya indikasi peningkatan harga saham nikel dari Juli hingga September 2024, penurunan hingga Oktober 2024, dan fluktuasi hingga Mei 2025. Hasil penelitian ini dapat membantu pengambilan keputusan investor saham nikel dengan pendekatan penambangan data menggunakan model peramalan, namun memiliki batasan terkait dataset dan periode waktu. Penelitian selanjutnya disarankan untuk mengeksplorasi model lebih kompleks dan data eksternal yang dapat membantu meningkatkan akurasi.

#### DAFTAR PUSTAKA

- [1] M. Agung and E. A. W. Adi, "Peningkatan Investasi Dan Hilirisasi Nikel Di Indonesia," *JISIP (Jurnal Ilmu Sos. dan Pendidikan)*, vol. 6, no. 2, pp. 4009–4020, 2022, doi: 10.58258/jisip.v6i2.3085.
- [2] T. Bastian Sianturi, I. Cholissodin, and N. Yudistira, "Penerapan Algoritma Long Short-Term Memory (LSTM) berbasis Multi Fungsi Aktivasi Terbobot dalam Prediksi Harga Ethereum," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 7, no. 3, pp. 1101–1107, 2023, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [3] ESDM Ministry, "Investment Opportunities in Nickel in Indonesia," The Ministry of Energy and Mineral Resources of the Republic of Indonesia. pp. 1–40, 2020. [Online]. Available: <https://www.esdm.go.id/id/booklet/booklet-tambang-nikel-2020>
- [4] G. Budiprasetyo, M. Hani'ah, and D. Z. Afiah, "Prediksi Harga Saham Syariah Menggunakan Algoritma Long Short-Term Memory (LSTM)," *J. Nas. Teknol. dan Sist. Inf.*, vol. 8, no. 3, pp. 164–172, 2023, doi: 10.25077/teknosi.v8i3.2022.164-172.
- [5] P. H. Gunawan, D. Munandar, and A. Z. Farabiba, "Long Short-Term Memory Approach for Predicting Air Temperature In Indonesia," *J. Online Inform.*, vol. 5, no. 2, p. 161, 2020, doi: 10.15575/join.v5i2.551.
- [6] N. Faridah and B. Sugiantoro, "Analisis Optimasi Pada Algoritma Long Short Term Memory Untuk Memprediksi Harga Saham," *J. Media Inform. Budidarma*, vol. 7, no. 1, pp. 575–582, 2023, doi: 10.30865/mib.v7i1.5421.
- [7] F. Qotrunnada, "Implementasi Long Short Term Memory Pada Optimalisasi Prediksi Harga Saham Menggunakan Parameter Analisis Teknikal," UIN Maulana Malik Ibrahim Malang, Malang, Jun. 2022. Available: <http://etheses.uin-malang.ac.id/37135/1/15610115.pdf>.
- [8] D. Diandra, F. Atsila, R. Hanif, S. Akhdan, and N. Yudistira, "Prediksi Perubahan Iklim di Indonesia pada Tahun 2013-2014 Menggunakan LSTM," *J. Litbang Edusaintech*, vol. 3, no. 2, pp. 101–106, 2022, [Online]. Available: <http://dx.doi.org/10.51402/jle.v3i2.49>
- [9] D. A. Manalu and G. Gunadi, "Implementasi Metode Data Mining K-Means Clustering Terhadap Data Pembayaran Transaksi Menggunakan Bahasa Pemrograman Python Pada Cv Digital Dimensi," *Infotech J. Technol. Inf.*, vol. 8, no. 1, pp. 43–54, 2022, doi: 10.37365/jti.v8i1.131.
- [10] F. Husaini, I. Permana, and M. Afdal, "Application of Long Short-Term Memory Algorithm for Palm Oil Production Prediction P," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 2, pp. 366–374, 2024.
- [11] Namora and Jan Everhard Riwurohi, "Prediction of Water Levels on Peatland using Deep Learning," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 6, no. 2, pp. 234–239, 2022, doi: 10.29207/resti.v6i2.3919.
- [12] M. Owen, V. Vincent, R. Br Ambarita, and E. Indra, "Implementasi Metode Long Short Term Memory Untuk Memprediksi Pergerakan Nilai Harga Emas," *J. Tek. Inf. dan Komput.*, vol. 5, no. 1, p. 96, 2022, doi: 10.37600/tekinkom.v5i1.507.
- [13] D. D. Pramesti, D. C. R. Novitasari, F. Setiawan, and H. Khaulasari, "Long-Short Term Memory (Lstm) for Predicting Velocity and Direction Sea Surface Current on Bali Strait," *BAREKENG J. Ilmu Mat. dan Terap.*, vol. 16, no. 2, pp. 451–462, 2022, doi: 10.30598/barekengvol16iss2pp451-462.
- [14] A. Rasikha, M. H. Fatihurrahman, and A. Munandar, "Teknik Long Short-Term Memory Untuk Analisa Mengatasi Fenomena Pump and Dump," *J. Investasi*, vol. 8, no. 3, pp. 13–18, 2022, doi: 10.31943/investasi.v8i3.211.
- [15] A. Rosyd, A. I. Purnamasari, and I. Ali, "Penerapan Metode Long Short Term Memory (LSTM) Dalam Memprediksi Harga Saham Pt Bank Central Asia," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 1, pp. 501–506, 2024.
- [16] D. P. Sari, L. Karlitasari, and F. D. Wihartiko, "Clean Water Demand Prediction Model Using The Long Short Term Memory (LSTM) Method," *Komputasi J. Ilm. Ilmu Komput. dan Mat.*, vol. 20, no. 2, pp. 160–168, 2023, doi:

- 10.33751/komputasi.v20i2.8060.
- [17] Z. S. C. Viqri, E. Kurniati, and Respitawulan, “Perbandingan Penerapan Metode Fuzzy Time Series Model Chen-Hsu dan Model Lee dalam Memprediksi Kurs Rupiah terhadap Dolar Amerika,” *DataMath J. Stat. Math.*, vol. 1, no. 1, pp. 19–26, 2023.
- [18] C. Chandra and S. Budi, “Analisis Komparatif ARIMA dan Prophet dengan Studi Kasus Dataset Pendaftaran Mahasiswa Baru,” *J. Tek. Inform. dan Sist. Inf.*, vol. 6, no. 2, pp. 278–287, 2020, doi: 10.28932/jutisi.v6i2.2676.
- [19] Moch Farryz Rizkilloh and Sri Widiyanesti, “Prediksi Harga Cryptocurrency Menggunakan Algoritma Long Short Term Memory (LSTM),” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 6, no. 1, pp. 25–31, 2022