

Optimization of stock price prediction of PT Aneka Tambang Tbk (ANTM) using Long Short-Term Memory

Optimasi Prediksi harga saham PT. Aneka Tambang Tbk (ANTM) Menggunakan Long Short-Term Memory

Ilham Maulana¹, Mellisa², Jumanto³

^{1,2,3} Teknik Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Semarang, Indonesia.

¹ilhammaulana05303005@students.unnes.ac.id, ²mellisalisa@students.unnes.ac.id,

³jumanto@mail.unnes.ac.id

*: Penulis korespondensi (corresponding author)

Informasi Artikel

Received: October 2023

Revised: May 2024

Accepted: December 2024

Published: February 2025

Abstract

Purpose: The purpose of this study is to develop a machine learning model to predict stock market activity by finding the Root Mean Squared Error (RMSE) value.

Design/methodology/approach: The research process begins with searching for PT Aneka Tambang stock datasets taken from the kaggle website. Furthermore, data preprocessing is carried out in order to prepare data for the next stage. Data that is ready for the next stage is normalized first. Next, the training and testing data is separated. The next stage of detection is carried out using the LSTM (Long Short-Term Memory) model. The last stage evaluates the model.

Findings/result: The prediction model for the share price of PT Aneka Tambang Tbk produces a Root Mean Squared Error (RMSE) value of 44.07.

Originality/value/state of the art: This research obtained a smaller RMSE value with previous research.

Abstrak

Tujuan: Tujuan dari penelitian ini adalah untuk melakukan pengembangan model pembelajaran mesin untuk memprediksi aktivitas pasar saham dengan mencari nilai Root Mean Squared Error (RMSE).

Perancangan/metode/pendekatan: Proses penelitian dimulai dengan mencari dataset saham PT Aneka Tambang yang diambil dari website kaggle. Selanjutnya dilakukan preprocessing data guna untuk menyiapkan data untuk ke

Keywords: LSTM; ANTM; Stock; RMSE.

Kata kunci: LSTM; ANTM; Stock; RMSE.

tahap selanjutnya. Data yang siap untuk tahap selanjutnya dilakukan normalisasi data terlebih dahulu. Selanjutnya dilakukan pemisahan data training dan testing. Tahap selanjutnya prediksi harga saham PT. Aneka Tambang Tbk dilakukan menggunakan model LSTM (Long Short-Term Memory). Tahap terakhir melakukan evaluasi model. Hasil: Model prediksi harga saham PT. Aneka Tambang Tbk menghasilkan nilai Root Mean Squared Error (RMSE) Sebesar 44,07.

Keaslian/ state of the art: Penelitian ini mendapatkan nilai RMSE lebih kecil dengan penelitian sebelumnya.

1. Pendahuluan

Perdagangan saham adalah jenis investasi yang populer di seluruh dunia dimana investor membeli saham dengan harapan mendapatkan keuntungan yang signifikan di masa mendatang [1]. Perdagangan saham juga merupakan salah satu faktor yang dapat menggambarkan suatu kondisi sebuah perekonomian dari suatu negara [2], [3]. Namun, investasi saham memiliki risiko yang tinggi karena harga saham dipengaruhi oleh banyak faktor, seperti situasi ekonomi global, kondisi politik, serta performa keuangan dan operasional perusahaan [4], [5]. Oleh karena itu, prediksi harga saham menjadi hal yang sangat penting bagi para investor dan perusahaan untuk membuat keputusan investasi yang tepat [6]. Berbagai metode prediksi harga saham sudah dikembangkan, salah satunya adalah menggunakan teknologi *Artificial Intelligence* (AI). AI adalah sebuah teknologi yang memudahkan kehidupan sehari-hari hingga masa mendatang. Penelitian ini menggunakan salah satu bagian algoritma dari AI, yaitu dengan arsitektur *Recurrent Neural Network* (RNN) [7], [8]. Salah satu perusahaan yang menjadi fokus penelitian ini adalah PT Aneka Tambang Tbk (ANTM), perusahaan yang bergerak di bidang pertambangan dan mempunyai pengaruh yang signifikan terhadap industri pertambangan Indonesia, dengan mendeteksi pergerakan saham PT Aneka Tambang Tbk, sehingga dapat memudahkan investor dan perusahaan dalam melakukan prediksi harga saham di masa depan [9], [10], dan [11].

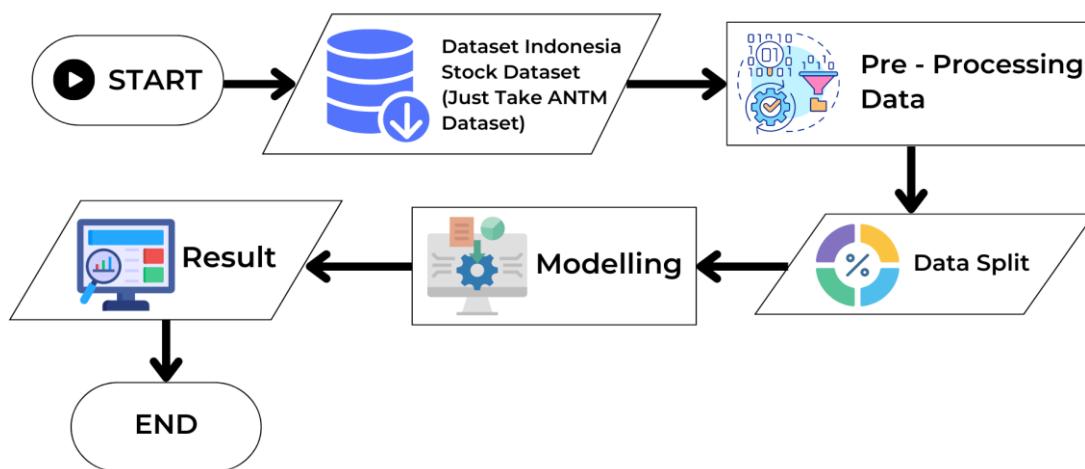
RNN merupakan sebuah algoritma *deep learning* yang digunakan untuk mengenali pola dan memprediksi data yang berbentuk time series [12]. RNN memiliki beberapa arsitektur. Pada penelitian ini, arsitektur RNN yang digunakan adalah varian LSTM [13]. Pada penelitian [4] yang menggunakan dataset dari perusahaan Bursa Efek Indonesia (BEI) pada sektor pertambangan dengan metode LSTM yang dapat melakukan pengolahan permasalahan data dengan tipe *time series*. Penelitian tersebut menggunakan saham ANTM, TINS, dan INCO dengan data tercatat dari tanggal 1 Januari 2016 sampai 31 Desember 2020 [4]. Pada percobaan 50 epoch dan berdasarkan nilai RMSE menghasilkan 54,84 memakan waktu komputasi selama 20,13 detik [4]. Penelitian [10] menghasilkan RSME yang cukup besar dan memakan waktu yang cukup lama.

Berdasarkan latar belakang tersebut, penelitian ini dilakukan dengan bertujuan untuk membuat sebuah model baru untuk mengukur nilai RMSE lebih kecil dalam memprediksi harga saham dengan menggunakan RNN. Dengan menggunakan data saham dari PT Aneka Tambang Tbk

(ANTM), penelitian ini memberikan beberapa kontribusi yaitu sebagai berikut: Merancang model prediksi baru dengan menggunakan LSTM untuk membuat nilai RMSE lebih kecil. Dengan melakukan evaluasi model agar menghasilkan tingkat akurasi yang lebih baik dalam memprediksi harga saham. Dalam penelitian ini menggunakan dataset yang diambil dari kaggle yaitu dataset Saham Indonesia / Indonesia Stock Dataset [14].

2. Metode

Alur dari metode yang diusulkan pada penelitian ini yaitu dengan membangun sebuah model - *machine learning* dengan algoritma LSTM untuk memprediksi harga saham mendatang. Dapat dilihat pada Gambar 1 merupakan langkah-langkah penelitian, yang merupakan langkah-langkah dari tujuan penelitian dan akan dijelaskan pada bagian selanjutnya.



Gambar 1. Flowchart dari metode yang diusulkan (Sumber: dokumen pribadi)

2.1. Pengumpulan Data

Penelitian ini menggunakan dataset yang terdapat pada website kaggle, dengan judul “Indonesia Stock Dataset” [14]. Pada dataset tersebut terdapat macam-macam saham yang di Indonesia, akan tetapi pada penelitian ini hanya akan menggunakan saham ANTM milik PT Aneka Tambang. Dataset tersebut dipisahkan dengan beberapa kurun waktu yaitu per-hari dapat dilihat pada gambar 2 deskripsi data, per-jam dapat dilihat pada gambar 3 deskripsi data, per-menit dapat dilihat pada gambar 4 deskripsi data. Pada data Per-hari mulai dari tahun 2001 hingga 2023, Per-jam mulai dari tahun 2020 hingga 2023, dan Per-menit mulai dari tahun 2021 hingga 2023. Dataset tersebut mencakup data *timestamp, open, low, high, close, and volume*.

| Daily | | | | | |
|-------|-------------|-------------|-------------|-------------|--------------|
| | open | low | high | close | volume |
| count | 5670.000000 | 5670.000000 | 5670.000000 | 5670.000000 | 5.670000e+03 |
| mean | 1147.170547 | 1122.435273 | 1167.470194 | 1145.959083 | 5.842432e+07 |
| std | 738.496408 | 725.853779 | 753.857710 | 737.559545 | 1.242240e+08 |
| min | 290.000000 | 285.000000 | 294.000000 | 287.000000 | 0.000000e+00 |
| 25% | 500.000000 | 491.000000 | 510.000000 | 499.250000 | 0.000000e+00 |
| 50% | 895.000000 | 881.000000 | 910.000000 | 895.000000 | 2.258961e+07 |
| 75% | 1679.000000 | 1654.000000 | 1700.000000 | 1679.000000 | 6.600675e+07 |
| max | 4409.000000 | 4115.000000 | 4451.000000 | 4241.000000 | 2.186653e+09 |

Gambar 2. Deskripsi dataset dalam kurun waktu per-hari

| Hourly | | | | | |
|--------|-------------|-------------|-------------|-------------|--------------|
| | open | low | high | close | volume |
| count | 5682.00000 | 5682.00000 | 5682.00000 | 5682.00000 | 5.682000e+03 |
| mean | 1900.249384 | 1888.733897 | 1910.956177 | 1898.960577 | 2.282031e+07 |
| std | 708.406271 | 704.952439 | 712.859556 | 709.026145 | 5.763197e+07 |
| min | 0.00000 | 0.00000 | 0.00000 | 0.00000 | 0.000000e+00 |
| 25% | 1570.00000 | 1560.00000 | 1580.00000 | 1565.00000 | 0.000000e+00 |
| 50% | 2135.00000 | 2120.00000 | 2150.00000 | 2130.00000 | 6.579600e+06 |
| 75% | 2390.00000 | 2370.00000 | 2400.00000 | 2390.00000 | 2.025052e+07 |
| max | 3390.00000 | 3330.00000 | 3440.00000 | 3390.00000 | 9.544058e+08 |

Gambar 3. Deskripsi dataset dalam kurun waktu per-jam

| Minutes | | | | | |
|---------|--------------|--------------|--------------|--------------|--------|
| | open | low | high | close | volume |
| count | 130221.00000 | 130221.00000 | 130221.00000 | 130221.00000 | |
| mean | 2093.678669 | 2090.042075 | 2096.788997 | 2092.969060 | |
| std | 454.137406 | 455.115711 | 454.841284 | 455.832074 | |
| min | 0.00000 | 0.00000 | 0.00000 | 0.00000 | |
| 25% | 1915.00000 | 1915.00000 | 1920.00000 | 1915.00000 | |
| 50% | 2070.00000 | 2060.00000 | 2070.00000 | 2070.00000 | |
| 75% | 2360.00000 | 2350.00000 | 2360.00000 | 2360.00000 | |
| max | 3120.00000 | 3090.00000 | 3170.00000 | 3120.00000 | |

Gambar 4. Deskripsi dataset dalam kurun waktu per-menit

| | volume |
|-------|--------------|
| count | 1.302210e+05 |
| mean | 3.178010e+05 |
| std | 2.995927e+06 |
| min | 0.000000e+00 |
| 25% | 0.000000e+00 |
| 50% | 1.030000e+04 |
| 75% | 1.229000e+05 |
| max | 3.688481e+08 |

Gambar 5. Deskripsi volume seluruh data

2.2. Pemrosesan Data

Pada tahap pemrosesan data, kolom *timestamp* diubah ke format *datetime* untuk memungkinkan manipulasi data waktu seperti hari, bulan, atau tahun. Setelah itu, data *timestamp* dipisahkan menjadi kolom baru bernama *day*, *month*, dan *year*, yang bertujuan untuk mempermudah analisis berdasarkan waktu. Selain itu, kolom baru bernama *is_quarter_end* ditambahkan. Kolom ini menunjukkan apakah bulan berada pada akhir kuartal (kelipatan 3), di mana nilai 1 diberikan jika memenuhi kriteria tersebut. Kolom baru lainnya adalah *open-close*, yang diperoleh dari selisih antara nilai *open* dan *close*, serta *low-high*, yang merupakan selisih antara nilai *low* dan *high*. Kolom tambahan berikutnya adalah *target*, yang bernilai 1 jika nilai pada kolom *close* di periode berikutnya lebih tinggi, dan bernilai 0 jika tidak. Tahap akhir pemrosesan melibatkan normalisasi fitur *open-close*, *low-high*, dan *is_quarter_end* menggunakan *StandardScaler*. Langkah ini bertujuan untuk membuat distribusi nilai fitur lebih seragam, sehingga dapat mendukung analisis atau model prediktif secara optimal. Pada proses ini tidak ada data yang duplikat, dan total data yang digunakan adalah 5670 dataset.

2.3. Data Split

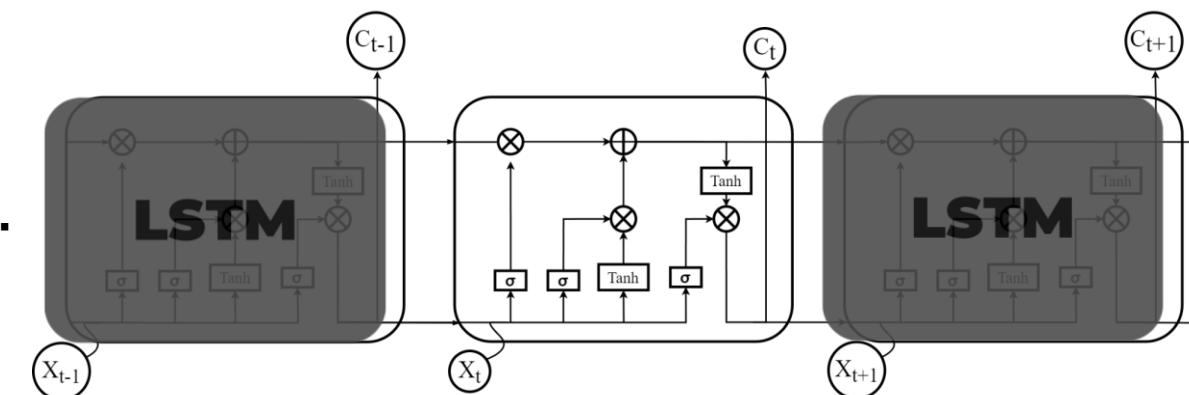
Pada tahap ini dilakukan setelah *cleaning* data dan *preprocessing* data. *Split* data dilakukan untuk menentukan perbandingan berapa persen untuk data train dan untuk data validasi. Pada penelitian ini melakukan split data dengan perbandingan 80% untuk data train dan 20 % untuk data validasi dengan *random_state* sebesar 2022. Data yang telah dilakukan pembagian dapat dilihat pada Tabel 1.

Tabel 1. Pembagian Dataset

| No. | Pembagian Data | Jumlah |
|-----|----------------|--------|
| 1. | Data Latih | 4536 |
| 2. | Data Validasi | 1134 |
| | Total Dataset | 5670 |

2.4. Model Prediksi

Dalam perancangan model, arsitektur dari algoritma *Long Short-Term Memory* (LSTM) dapat dilihat pada Gambar 6 Dan akan dijelaskan pada bagian selanjutnya.



Gambar 6. Arsitektur Algoritma LSTM [15], [16]

Model LSTM (yang telah diberi warna abu-abu) mempunyai pemrosesan yang berbeda dengan model RNN biasa. Model tersebut memiliki tambahan sinyal dengan memberikan satu langkah waktu ke langkah waktu berikutnya, yang didefinisikan dengan simbol C_t [15], [16]. Jalur tersebut menghubungkan dari $C_{(t-1)}$ menuju *Memory Cell* baru C_t , jalur yang terdapat pada bagian atas LSTM [15], [16].

2.4.1. Membangun Model

Membangun model neural network secara berurutan, membuat objek `model_rnn` menggunakan kelas Sequential dan pustaka LSTM [17]. Kemudian, menambahkan layer LSTM dengan 50 unit menggunakan metode `add()` pada `model_rnn`. Layer LSTM digunakan untuk memodelkan data urutan dan mempertahankan informasi jangka panjang dan pendek. Selanjutnya, menambahkan layer dense dengan 1-unit setelah layer LSTM [18]. Layer dense ini bertindak sebagai layer output yang menghasilkan prediksi [19]. Pada Diagram 2 terdapat contoh summary epoch 50.

| Model: "sequential_1" | | |
|--------------------------|--------------|---------|
| Layer (type) | Output Shape | Param # |
| lstm_1 (LSTM) | (None, 50) | 10400 |
| dense_1 (Dense) | (None, 1) | 51 |
| Total params: 10,451 | | |
| Trainable params: 10,451 | | |
| Non-trainable params: 0 | | |
| None | | |

2.4.2. Mengkompilasi Model

Mengkompilasi model dengan menggunakan sebuah metode *compile()* pada *model_rnn*. Pada metode ini, kita mengatur fungsi *loss='mean_squared_error'* [20], yang merupakan metrik yang digunakan untuk mengukur kesalahan antara prediksi dan nilai sebenarnya. Selain itu, mengatur *optimizer='Adam'*, yang merupakan algoritma optimasi yang digunakan untuk memperbarui bobot model selama proses pelatihan [21].

2.4.3. Melatih Model

Melatih model dengan data *X_train_rnn* dan *Y Train*, kita menggunakan metode *fit()* pada *model_rnn*. Pada metode ini, mengatur jumlah *epoch=50*. yang menentukan berapa kali model akan melalui seluruh dataset pelatihan dalam proses pembelajaran. Selain itu, mengatur jumlah *batch_size=32*, yaitu jumlah sampel yang akan dievaluasi sebelum bobot model diperbarui.

2.4.4. Menampilkan Prediksi

Menampilkan hasil prediksi pada data pelatihan (*X_train_rnn*) dan data validasi (*X_valid_rnn*), kita menggunakan metode *predict()* pada *model_rnn*. Hasil prediksi akan disimpan dalam variabel *y_train_pred* untuk data pelatihan dan *y_valid_pred* untuk data validasi.

2.4.5. Menghitung RMSE dan Epoch

Menghitung nilai dari *Mean Squared Error* (MSE) antara nilai sebenarnya (*Y_train*, *Y_valid*) dan prediksi (*y_train_pred*, *y_valid_pred*), kita menggunakan fungsi *mean_squared_error* dari library *sklearn*. Selanjutnya, kita menggunakan *np.sqrt()* untuk menghitung akar kuadrat dari MSE, sehingga menghasilkan *Root Mean Squared Error* (RMSE) [22]. Rumus untuk menghitung MSE dapat dilihat pada Equation 1 dan untuk menghitung RMSE dapat dilihat pada Equation 2:

$$MSE = \frac{1}{2} \sum (xy - x'y)^2 \quad (1)$$

$$RMSE = \sqrt{(mean_squared_error)} \quad (2)$$

Keterangan:

1. n adalah jumlah sampel yang ada pada dataset
2. xy adalah nilai target pada sampel y
3. $x'y$ adalah nilai prediksi dari model pada sampel y
4. Σ adalah penjumlahan dari perbedaan kuadrat antara nilai sebenarnya dengan nilai prediksi pada setiap sampel.

3. Hasil dan Pembahasan Pemrosesan Data

3.1. Pelabelan berdasarkan Hari, Bulan, Tahun

Terdapat kolom bernama “*timestamp*” yang berisikan data tanggal, bulan, dan tahun. Pada Proses ini dilakukan pemisahan untuk hari, bulan, dan tahun. Dengan membuat kolom “Hari” dengan rentang 1-31 untuk setiap tanggal yang berada pada “*timestamp*”. Membuat kolom “Bulan” dengan mengambil atribut dari “*Month*” dengan rentang 1-12 untuk setiap tanggal yang berada pada “*timestamp*”. Membuat kolom “Tahun” dengan mengambil atribut dari “*Year*” dengan mengembalikan nilai tahun untuk setiap tanggal yang berada pada “*timestamp*”. Dapat dilihat pada Gambar 7.

| | timestamp | open | low | high | close | volume | day | month | year |
|------|------------------|------|------|------|-------|-----------|-----|-------|------|
| 0 | 2001-04-16 | 432 | 407 | 436 | 432 | 0 | 16 | 4 | 2001 |
| 1 | 2001-04-17 | 432 | 407 | 436 | 432 | 0 | 17 | 4 | 2001 |
| 2 | 2001-04-18 | 432 | 407 | 436 | 432 | 0 | 18 | 4 | 2001 |
| 3 | 2001-04-19 | 432 | 407 | 436 | 432 | 0 | 19 | 4 | 2001 |
| 4 | 2001-04-20 | 432 | 407 | 436 | 432 | 0 | 20 | 4 | 2001 |
| ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| 5665 | 2023-01-02 | 1990 | 1975 | 2010 | 1980 | 15045200 | 2 | 1 | 2023 |
| 5666 | 2023-01-03 | 1980 | 1975 | 2020 | 2000 | 45001200 | 3 | 1 | 2023 |
| 5667 | 2023-01-04 | 2020 | 2010 | 2100 | 2050 | 142169900 | 4 | 1 | 2023 |
| 5668 | 2023-01-05 | 2020 | 1935 | 2050 | 1965 | 130118600 | 5 | 1 | 2023 |
| 5669 | 2023-01-06 | 1950 | 1930 | 1985 | 1985 | 55673400 | 6 | 1 | 2023 |
| 5670 | rows × 9 columns | | | | | | | | |

Gambar 7. Pelabelan Tanggal

3.2. Fitur yang akan digunakan

Pada tahap ini dilakukan pembuatan fitur dan target yang akan digunakan untuk model. Fitur yang akan dibuat yaitu “*is_quarter_end*”, “*open-close*”, dan “*low-high*”. Untuk target akan dibuat dengan nama “target”. Kolom yang sudah dibuat dapat dilihat pada Gambar 8.

Keterangan:

1. *is_quarter_end* = Akhir kuartal pada kolom “*month*” (1 untuk akhir kuartal dan 0 bukan)
2. *open_close* = selisih nilai antara kolom “*open*” dengan “*close*”.
3. *low-high* = selisih nilai antara kolom “*low*” dengan “*high*”.
4. *target* = perbandingan nilai pada kolom “*close*” dengan nilai “*close*” pada baris berikutnya.

| | timestamp | open | low | high | close | volume | day | month | year | is_quarter_end | open-close | low-high | target |
|------|------------|------|------|------|-------|-----------|-----|-------|------|----------------|------------|----------|--------|
| 0 | 2001-04-16 | 432 | 407 | 436 | 432 | 0 | 16 | 4 | 2001 | 0 | 0 | -29 | 0 |
| 1 | 2001-04-17 | 432 | 407 | 436 | 432 | 0 | 17 | 4 | 2001 | 0 | 0 | -29 | 0 |
| 2 | 2001-04-18 | 432 | 407 | 436 | 432 | 0 | 18 | 4 | 2001 | 0 | 0 | -29 | 0 |
| 3 | 2001-04-19 | 432 | 407 | 436 | 432 | 0 | 19 | 4 | 2001 | 0 | 0 | -29 | 0 |
| 4 | 2001-04-20 | 432 | 407 | 436 | 432 | 0 | 20 | 4 | 2001 | 0 | 0 | -29 | 0 |
| ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| 5665 | 2023-01-02 | 1990 | 1975 | 2010 | 1980 | 15045200 | 2 | 1 | 2023 | 0 | 10 | -35 | 1 |
| 5666 | 2023-01-03 | 1980 | 1975 | 2020 | 2000 | 45001200 | 3 | 1 | 2023 | 0 | -20 | -45 | 1 |
| 5667 | 2023-01-04 | 2020 | 2010 | 2100 | 2050 | 142169900 | 4 | 1 | 2023 | 0 | -30 | -90 | 0 |
| 5668 | 2023-01-05 | 2020 | 1935 | 2050 | 1965 | 130118600 | 5 | 1 | 2023 | 0 | 55 | -115 | 1 |
| 5669 | 2023-01-06 | 1950 | 1930 | 1985 | 1985 | 55673400 | 6 | 1 | 2023 | 0 | -35 | -55 | 0 |

Gambar 8. Fitur yang telah dibuat

3.3. Grafik Pergerakan Harga Saham

Pada Gambar 9 menunjukkan sebuah grafik *Candlestick Chart* menggunakan *Plotly*. Grafik ini menampilkan pergerakan dari harga saham dengan rentang waktu tertentu berdasarkan data yang tersimpan di dalam *DataFrame* ‘df_daily’.

1. *Candlestick* berwarna hijau menunjukkan bahwa nilai *close* lebih tinggi dari pada nilai *open*.
2. *Candlestick* berwarna merah menunjukkan bahwa nilai *close* lebih rendah dari pada nilai *open*.



Gambar 9. Grafik Pergerakan Harga Saham

3.4. Analisis dan Hasil Eksperimen

Pada penelitian ini telah dilakukan pelatihan dengan dilakukan epoch 50. Hasil dari epoch dapat dilihat pada Tabel 2.

Tabel 2. Hasil Penelitian

| Data Latih | | Data Validasi | |
|------------|-----------------|---------------|-----------------|
| RMSE | Waktu Komputasi | RMSE | Waktu Komputasi |
| 43,75 | 77,58 | 44,07 | 1,042 |

3.5. Perbandingan Dengan Penelitian

Pada beberapa penelitian sebelumnya [4], [23], dan [24] mencari nilai RMSE terkecil. Perbandingan hasil dapat dilihat pada Tabel 3.

Tabel 3. Perbandingan hasil dengan penelitian sebelumnya

| Penelitian | Metode | RMSE |
|-----------------------|--------|-------------------|
| | | Hasil Penelitian |
| [23] | TFGRU | 553,3277 |
| [24] | LSTM | 96,92 |
| [4] | LSTM | 54,84999664170528 |
| Metode yang diusulkan | LSTM | 44,07 |

Pada Tabel 2. menunjukkan perbandingan hasil penelitian berdasarkan nilai Root Mean Square Error (RMSE) dari beberapa metode. Penelitian [23] menggunakan metode TFLSTM dengan RMSE sebesar 638,0830, sementara penelitian [24] dengan LSTM memperoleh RMSE sebesar 96,92. Penelitian [4] juga menggunakan LSTM dan menghasilkan RMSE sebesar 54,85. Penelitian ini, yang menggunakan metode LSTM, berhasil mencapai RMSE sebesar 44,07, menunjukkan hasil yang lebih optimal. sehingga penelitian ini menunjukkan keunggulan dalam mengurangi kesalahan prediksi dan menghasilkan model yang lebih tepat.

4. Kesimpulan dan Saran

Angka Root Mean Square Error (RMSE) telah jauh menurun dibandingkan dengan publikasi sebelumnya dalam hal prediksi data, demikian disimpulkan. Dengan mencapai penurunan RMSE sebesar 44,07, penelitian ini menunjukkan bahwa pendekatan LSTM efektif dalam mengoptimalkan prediksi. Seperti yang ditunjukkan oleh [4], yang memiliki RMSE sebesar 54,85, hal ini menunjukkan bahwa model yang digunakan dalam investigasi ini lebih tepat dan mampu mengurangi kesalahan prediksi dibandingkan dengan model yang digunakan dalam penelitian sebelumnya. Hasilnya, penelitian ini secara efektif menggambarkan bagaimana memilih pendekatan yang tepat dan memodifikasi parameter model dapat meningkatkan kinerja dalam hal prediksi data yang lebih tepat.

Untuk penelitian selanjutnya bisa melakukan penambahan dataset yang jauh lebih besar, untuk lebih meningkatkan model dan menurunkan RMSE, lebih banyak perubahan dapat dilakukan pada hiperparameter seperti ukuran batch, laju pembelajaran, atau lapisan LSTM, dan melakukan peningkatan dalam pemrosesan data seperti augmentasi data dan normalisasi data yang lebih baik.

5. Daftar Pustaka

- [1] M. Abdul Dwiyanto Suyudi, E. C. Djamal, A. Maspupah Jurusan Informatika, and F. Sains dan Informatika Universitas Jenderal Achmad Yani Cimahi, “Prediksi Harga Saham menggunakan Metode Recurrent Neural Network,” *Semin. Nas. Apl. Teknol. Inf.*, pp. 1907–5022, 2019.
- [2] S. Masriyah, H. Hariyanto, and N. Wahyuningsih, “Prediksi Indeks Harga Saham Menggunakan Model Hibrida Recurrent Neural Network Dan Genetic Algorithm,” *J. Sains dan Seni ITS*, vol. 11, no. 2, 2022, doi: 10.12962/j23373520.v11i2.78431.
- [3] M. Diqi, M. E. Hiswati, and A. S. Nur, “StockGAN: robust stock price prediction using GAN algorithm,” *Int. J. Inf. Technol.*, vol. 14, no. 5, pp. 2309–2315, 2022, doi: 10.1007/s41870-022-00929-6.
- [4] R. Julian and M. R. Pribadi, “Peramalan Harga Saham Pertambangan Pada Bursa Efek Indonesia (BEI) Menggunakan Long Short Term Memory (LSTM),” *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 8, no. 3, pp. 1570–1580, 2021, doi: 10.35957/jatisi.v8i3.1159.
- [5] A. Mahmoodi, L. Hashemi, M. Jasemi, S. Mehraban, J. Laliberté, and R. C. Millar, “A developed stock price forecasting model using support vector machine combined with metaheuristic algorithms,” *OPSEARCH*, vol. 60, no. 1, pp. 59–86, 2023, doi:

- 10.1007/s12597-022-00608-x.
- [6] Y. Shi, Y. Wang, Y. Qu, and Z. Chen, “Integrated GCN-LSTM stock prices movement prediction based on knowledge-incorporated graphs construction,” *Int. J. Mach. Learn. Cybern.*, pp. 1–16, Apr. 2023, doi: 10.1007/s13042-023-01817-6.
 - [7] J. Zhao, D. Zeng, S. Liang, H. Kang, and Q. Liu, “Prediction model for stock price trend based on recurrent neural network,” *J. Ambient Intell. Humaniz. Comput.*, vol. 12, no. 1, pp. 745–753, 2021, doi: 10.1007/s12652-020-02057-0.
 - [8] R. Kumar, “Cerebral LSTM: A Better Alternative for Single- and Multi-Stacked LSTM Cell-Based RNNs,” *SN Comput. Sci.*, vol. 1, no. 2, p. 85, 2020, doi: 10.1007/s42979-020-0101-1.
 - [9] Y. Ramdhani and A. Mubarok, “Analisis Time Series Prediksi Penutupan Harga Saham Antm.Jk Dengan Algoritma SVM Model Regresi,” *J. Responsif Ris. Sains dan Inform.*, vol. 1, no. 1, pp. 77–82, 2019.
 - [10] L. Alfat, H. Hermawan, A. Rustandiputri, R. Inzhagi, and R. Tandjilal, “Prediksi Saham PT. Aneka Tambang Tbk. dengan K-Nearest Neighbors,” *JSAI (Journal Sci. Appl. Informatics)*, vol. 5, no. 3, pp. 236–243, 2022, doi: 10.36085/jsai.v5i3.3975.
 - [11] K. Kumar and M. T. U. Haider, “Enhanced Prediction of Intra-day Stock Market Using Metaheuristic Optimization on RNN–LSTM Network,” *New Gener. Comput.*, vol. 39, no. 1, pp. 231–272, 2021, doi: 10.1007/s00354-020-00104-0.
 - [12] H. Putra and N. Ulfa Walmi, “Penerapan Prediksi Produksi Padi Menggunakan Artificial Neural Network Algoritma Backpropagation,” *J. Nas. Teknol. dan Sist. Inf.*, vol. 6, no. 2, pp. 100–107, 2020, doi: 10.25077/teknosi.v6i2.2020.100-107.
 - [13] N. Yudistira, P. Studi, T. Informatika, F. I. Komputer, U. Brawijaya, and P. Korespondensi, “Prediksi harga saham indosat menggunakan algoritma lstm,” pp. 1–6, 2021.
 - [14] M. KHADAFI, “Dataset Saham Indonesia / Indonesia Stock Dataset,” 2023. <https://www.kaggle.com/datasets/muamkh/ihsgstockdata> (accessed Apr. 29, 2023).
 - [15] B. Prijono, “Pengenalan Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU) – RNN Bagian 2,” 2018. <https://indoml.com/2018/04/13/pengenalan-long-short-term-memory-lstm-dan-gated-recurrent-unit-gru-rnn-bagian-2/> (accessed Jun. 14, 2023).
 - [16] 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. JANAPATI*, vol. 8, no. 3, pp. 184–196, 2020, doi: 10.23887/janapati.v8i3.19139.
 - [17] T. L. Nikmah, M. Z. Ammar, and Y. R. Allatif, “Comparison of LSTM, SVM, and naive bayes for classifying sexual harassment tweets,” *J. Soft Comput. Explor.*, vol. 3, no. 2, pp. 131–137, 2022, doi: 10.52465/joscex.v3i2.85.
 - [18] E. M. C. Wattimena, A. Annisa, and I. S. Sitanggang, “CO and PM10 Prediction Model based on Air Quality Index Considering Meteorological Factors in DKI Jakarta using LSTM,” *Sci. J. Informatics*, vol. 9, no. 2, pp. 123–132, 2022, doi:

- 10.15294/sji.v9i2.33791.
- [19] G. Bathla, R. Rani, and H. Aggarwal, “Stocks of year 2020: prediction of high variations in stock prices using LSTM,” *Multimed. Tools Appl.*, vol. 82, no. 7, pp. 9727–9743, 2023, doi: 10.1007/s11042-022-12390-5.
 - [20] R. Wulandari, B. Surarso, Irawanto, and F. Farikhin., “The Forecasting of Palm Oil Based on Fuzzy Time Series-Two Factor,” *J. Soft Comput. Explor.* 2, vol. 1, pp. 11–16, 2021.
 - [21] L. Setiyani and W. H. Utomo, “Arabica Coffee Price Prediction Using the Long Short Term Memory Network (LSTM) Algorithm,” vol. 10, no. 3, pp. 287–296, 2024, doi: 10.15294/sji.v10i3.44162.
 - [22] A. Purwanto and L. P. Manik, “Software Effort Estimation Using Logarithmic Fuzzy Preference Programming and Least Squares Support Vector Machines,” *Sci. J. Informatics*, vol. 10, no. 1, pp. 1–12, 2022, doi: 10.15294/sji.v10i1.39865.
 - [23] Haryono, A. T., Sarno, R., & Sungkono, K. R. (2024). Stock price forecasting in Indonesia stock exchange using deep learning: A comparative study. International Journal of Electrical and Computer Engineering (IJECE), 14(1), 861.
 - [24] Wathani, M. N., Kusrini, K., & Kusnawi, K. (2023). Prediksi Tren Pergerakan Harga Saham PT Bank Central Asia Tbk, Dengan Menggunakan Algoritma Long Shot Term Memory (LSTM). Infotek: Jurnal Informatika dan Teknologi, 6(2), 502-512.