

Prediksi Harga Saham Menggunakan Metode Long Short Term Memory Studi Kasus: Saham Intel Corporation

Indah Winarni^{1*}, Nunik Pratiwi¹

¹Program Studi Teknik Informatika, Universitas Muhammadiyah Prof. DR. HAMKA, Indonesia.

Artikel Info

Kata Kunci:

Deep Learning;
Intel Corporation;
Kecerdasan Buatan;
Long Short Term Memory (LSTM);
Prediksi Harga Saham.

Keywords:

Deep Learning;
Intel Corporation;
Artificial Intelligence;
Long Short-Term Memory (LSTM);
Stock Price Prediction.

Riwayat Artikel:

Submitted: 17 Mei 2025

Accepted: 17 Juli 2025

Published: 23 Juli 2025

Abstrak: Perkembangan dalam bidang teknologi kecerdasan buatan telah mendorong penerapan teknik *deep learning* dalam analisis pasar keuangan, khususnya dalam meramalkan harga saham. Penelitian ini bertujuan untuk membuat sebuah model yang bisa memperkirakan harga saham Intel Corporation menggunakan metode *Long Short-Term Memory (LSTM)* untuk mendukung pengambilan keputusan dalam investasi. Metode yang dilakukan mencakup pengumpulan data *historis* dari Kaggle, *preprocessing* data (*cleansing*, *scaling*, dan membagi data untuk pelatihan dan pengujian), merancang model LSTM, dan melakukan evaluasi dengan menggunakan *Root Mean Squared Error (RMSE)*. Model ini dilatih menggunakan 150 *epoch* dengan fungsi aktivasi *tanh* dan *optimizer Adam*. Hasil dari pengujian ini menunjukkan bahwa model LSTM mendapatkan nilai RMSE sebesar 0.0230 paling rendah, serta menunjukkan pola pergerakan harga yang sangat realistis. Hasil ini menunjukkan bahwa LSTM merupakan metode yang efisien untuk memodelkan data deret waktu dalam memprediksi harga saham, serta dapat berfungsi sebagai sumber informasi bagi investor dalam merancang strategi investasi yang didasarkan pada data.

Abstract: Developments in the field of artificial intelligence technology have encouraged the application of deep learning techniques in financial market analysis, especially in forecasting stock prices. This research aims to create a model that can forecast Intel Corporation stock prices using the Long Short-Term Memory (LSTM) method to support investment decision making. The method applied includes collecting historical data from Kaggle, preprocessing the data (cleansing, scaling, and dividing the data for training and testing), designing the LSTM model, and performing evaluation using Root Mean Squared Error (RMSE). The model was trained using 150 epochs with tanh activation function and Adam optimizer. The results of this test show that the LSTM model has the lowest RMSE value of 0.0198, and shows a very realistic price movement pattern. These results show that LSTM is an efficient method for modeling time series data in predicting stock prices, and can serve as a source of information for investors in designing investment strategies based on data.

Corresponding Author:

Nunik Pratiwi

Email: npratiwi@uhamka.ac.id

PENDAHULUAN

Dalam beberapa tahun terakhir, pasar modal dan dunia investasi di Indonesia telah mengalami perkembangan pesat dan menarik perhatian banyak kalangan. Investasi saham menjadi salah satu pilihan populer karena memberikan peluang keuntungan melalui kenaikan harga saham maupun dividen (Agusta et al., 2021). Namun, karena harga saham sangat sensitif terhadap berbagai faktor baik internal maupun eksternal seperti kondisi pasar keuangan, kebijakan industri, kinerja perusahaan, dan situasi ekonomi makro investasi saham dikategorikan sebagai investasi berisiko tinggi (Julian & Pribadi, 2021). Oleh karena itu, untuk memaksimalkan potensi keuntungan dan meminimalkan risiko, investor perlu memahami analisis fundamental dan teknikal serta menerapkan strategi yang tepat (Hamdani & Saputra, 2023). Dalam konteks ini, prediksi harga saham menjadi acuan penting ketika memilih waktu yang tepat untuk membeli atau menjual saham (Janastu & Wutsqa, 2024).

Investor umumnya menggunakan laporan keuangan perusahaan publik untuk menganalisis potensi investasi dengan melihat kinerja bisnis, efisiensi operasional, kapasitas pertumbuhan, serta rasio keuangan penting seperti laba bersih dan arus kas (Setiawan et al., 2023). Intel Corporation dipilih sebagai fokus penelitian karena perannya yang signifikan dalam industri semikonduktor, dengan produk seperti prosesor dan *chip* yang digunakan secara luas di berbagai perangkat elektronik (Ningrum & Seru, 2022). Inovasi teknologi, stabilitas perusahaan, serta pergerakan harga sahamnya yang dinamis menjadikan Intel sebagai objek yang menarik untuk dianalisis dari sisi investasi jangka panjang (Irawan, 2024).

Terdapat berbagai metode dalam memprediksi pergerakan harga saham, pendekatan berbasis kecerdasan buatan semakin banyak digunakan, terutama melalui teknik *machine learning* dan *deep learning* (Achyar et al., 2022). *Machine learning* memungkinkan model belajar dari data historis untuk menghasilkan prediksi yang lebih akurat. Salah satu cabangnya, *deep learning*, menawarkan kemampuan lebih dalam mengenali pola data yang kompleks dan berurutan (Sofi et al., 2021). Penelitian oleh (Gumelar et al., 2022) berhasil menggunakan LSTM untuk meramalkan harga saham dari empat bank BUMN di Indonesia. Hasilnya, akurasi dari model ini sangat baik, dengan MAPE hanya sekitar 3-4%. Teknologi ini terbukti efektif dalam mendukung keputusan investasi yang lebih cepat dan tepat (Riyantoko et al., 2020).

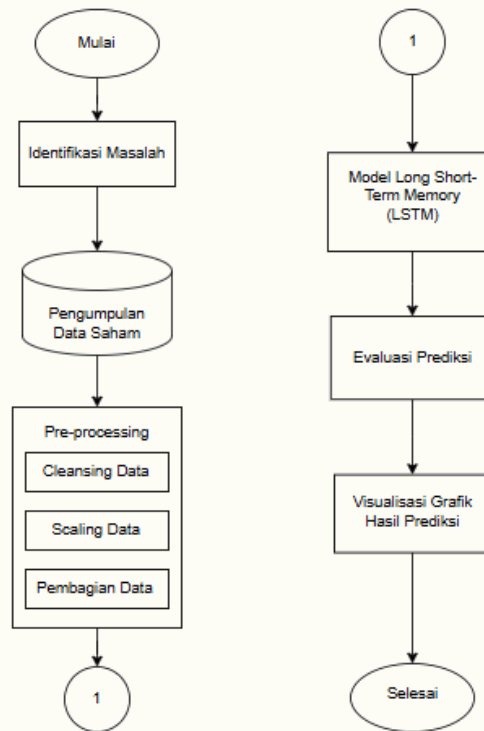
Long Short-Term Memory merupakan salah satu metode *deep learning* yang sering digunakan dengan data deret waktu, yaitu pengembangan dari arsitektur *Recurrent Neural Network* (RNN) yang dirancang untuk menyimpan informasi jangka panjang melalui *memory cell* (Pipin et al., 2023). LSTM dirancang oleh Hochreiter dan Schmidhuber (1997) untuk mengatasi masalah gradien yang hilang, yang sering terjadi pada RNN saat menangani data berurutan yang Panjang (Puteri, 2023). Arsitektur ini dinilai sangat sesuai dalam mengolah data pasar saham yang bersifat sekuensial dan memiliki ketergantungan historis yang kuat (Kiramy et al., 2024).

Berdasarkan permasalahan yang telah diidentifikasi dan mengacu pada studi sebelumnya, penelitian ini bertujuan untuk membangun model prediksi harga saham Intel Corporation menggunakan metode *Long Short-Term Memory* (LSTM) dengan data historis yang diperoleh dari situs Kaggle, yaitu "Harga saham Intel dari 2019-01-01 hingga 2024-09-27." Pemilihan metode LSTM didasarkan pada kemampuannya dalam mengenali pola jangka panjang secara akurat dan efisien. Diharapkan bahwa strategi ini akan menghasilkan model prediksi yang akan membantu menginformasikan pengambilan keputusan investasi berbasis data dan menawarkan wawasan tentang fluktuasi harga saham di masa yang akan datang. Penelitian ini diharapkan dapat memajukan secara signifikan penciptaan teknik prediksi harga saham yang lebih efektif dengan mempertimbangkan perubahan kondisi pasar.

METODE

Penelitian ini diawali dengan mengidentifikasi masalah yang terjadi, mengumpulkan data yang relevan, *pre-processing*, model *Long Short-Term Memory* (LSTM), sampai dengan evaluasi prediksi dan

visualisasi grafik. Metode penelitian ini dirancang untuk memberikan hasil prediksi yang akurat dengan pendekatan sistematis.



Gambar 1. Metode Penelitian

Pengumpulan Data

Data yang diterapkan dalam penelitian ini diperoleh dari *platform* Kaggle.com (Alex Khr, 2024). Proses pengumpulan data dimulai dengan eksplorasi dan pencarian dataset di Kaggle, menggunakan kata kunci seperti “Indonesian stock market”, “stock price forecasting”, atau “financial time series data”. Setelah menemukan dataset yang relevan, langkah selanjutnya adalah mengunduh data harga saham Intel Corp periode waktu 1 Januari 2019 sampai 27 September 2024. Dataset ini berisi 1445 data harian yang meliputi harga pembukaan (*open*), harga penutupan (*close*), harga tertinggi (*high*), harga terendah (*low*), dan volume perdagangan.

Tabel 1. Potongan Data Harga Saham

Date	Open	High	Low	Close	Adj Close	Volume
16/09/2024	2003	2106	1976	2090	2.090.999.984	14933700
17/09/2024	2170	2257	2123	2146	21.469.999.313	196249800
18/09/2024	2136	2173	2071	2077	20.770.000.457	118727900
19/09/2024	2128	2169	2103	2113	21.139.999.389	99829200
20/09/2024	2088	2313	2035	2184	2.184.000.015	260377900

Pada penelitian ini, data yang digunakan berjumlah 1445 dataset dari perubahan harga saham pada Intel Corp dan kolom yang akan digunakan adalah kolom *Close* untuk data *time series*, di mana *Close* akan digunakan sebagai kolom target.

Pre-processing

Sebelum data harga saham ditambahkan ke model prediksi LSTM, *pre-processing* dilakukan untuk mempersiapkannya. Tujuan dari langkah ini adalah untuk meningkatkan kualitas data dan menjamin bahwa data tersebut siap untuk evaluasi dan pelatihan model. Pada penelitian ini tahap *pre-processing* yang dilakukan adalah seperti *cleansing*, *scaling*, dan pembagian data.

a. Cleansing data

Cleansing data dilakukan untuk membersihkan data yang akan digunakan dari nilai-nilai yang tidak diperlukan. Di mana *cleansing* bertujuan untuk Mengurangi nilai yang hilang yang dapat mengakibatkan perhitungan dan klasifikasi yang tidak optimal adalah tujuan dari *Cleansing* data. (Riadi et al., 2024).

b. Scaling Data

Scaling Data merupakan sebuah teknik yang digunakan untuk menyelaraskan rentang dari variabel independen atau fitur dalam data. Dalam konteks pengolahan data, istilah ini juga dikenal sebagai normalisasi data dan biasanya dilaksanakan pada tahap pemrosesan data. Dalam penelitian ini, metode *Min-Max Scaling* akan diterapkan untuk melakukan skala data antara 0 hingga 1 (Rasyidi, 2023). Dibawah ini adalah rumus untuk normalisasi.

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

c. Pembagian Data

Data pelatihan dan pengujian adalah dua kategori yang memisahkan data penelitian. Model prediksi membagi data menjadi perbandingan, menggunakan sebagian dari keseluruhan data untuk pelatihan dan sisanya untuk pengujian. Model LSTM akan dilatih menggunakan data pelatihan, dan kinerjanya akan dievaluasi menggunakan data pengujian (Riatma et al., 2025).

Model Long Short-Term Memory

Metode LSTM dapat menganalisis data berurutan dan menyimpan informasi penting dalam jangka waktu yang lama, metode ini lebih efektif dalam mengidentifikasi pola dalam data deret waktu. Terdapat tiga jenis bobot yang digunakan dalam pengembangan LSTM, yaitu bobot dari lapisan input ke lapisan tersembunyi, bobot yang menghubungkan lapisan tersembunyi ke lapisan output, dan bobot dari lapisan konteks ke lapisan tersembunyi (Putra, 2024). Selanjutnya, parameter pembelajaran seperti laju pembelajaran, jumlah epoch, dan fungsi aktivasi ditentukan. Proses pembelajaran akan berhenti jika tingkat kesalahan mencapai tingkat target atau jika jumlah iterasi maksimum telah tercapai. (Damayanti et al., 2024).

Evaluasi Prediksi

Setelah memperoleh hasil prediksi harga saham dari model LSTM, evaluasi hasil perlu dilakukan untuk menilai tingkat ketepatan prediksi tersebut. Penelitian ini menggunakan evaluasi *Root Mean Squared Error* (RMSE) untuk menilai hasil tersebut (Sabar Sautomo & Hilman Ferdinandus Pardede, 2021). Grafik akan dihasilkan sebagai perbandingan antara prediksi dan data historis yang asli. Apabila hasil evaluasi menunjukkan performa yang kurang memuaskan, maka perancangan model akan dilakukan kembali .

Visualisasi Grafik Hasil Prediksi

Tahapan ini dilakukan untuk membantu para pembeli atau penjual saham dalam memahami hasil dari prediksi harga saham, di mana grafik tersebut akan menunjukkan harga yang diprediksi dan juga harga sebenarnya dari data harga saham dalam jangka waktu tertentu (Wijaya et al., 2021). Selain itu, grafik ini juga bisa dimanfaatkan untuk menilai sejauh mana model prediksi dapat mencerminkan pola pergerakan harga saham (Tauran, 2021). Apabila terdapat perbedaan yang signifikan antara harga yang diprediksi dan harga yang sebenarnya, maka perlu dilakukan analisis lebih mendalam untuk menemukan faktor-faktor yang memengaruhi kinerja model (Lestari et al., 2021).

HASIL DAN PEMBAHASAN

Pada bagian ini akan dijelaskan tentang prediksi Harga saham Intel Corporation dengan menggunakan metode *Long Short-Term Memory* (LSTM). Hal ini mencakup persiapan dataset, hasil pembersihan data, hasil normalisasi data, hasil pemisahan data, hasil penerapan model, dan hasil evaluasi model, serta visualisasi dari hasil prediksi data.

Pre-processing

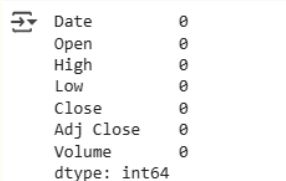
Tahap pertama penelitian ini menggunakan data harga saham PT Intel Corporation dari 02 Januari 2019 hingga 27 September 2024 dari kaggle.com. Gambar 2. menunjukkan data frame yang digunakan pada program, yang terdiri dari 6 kolom yaitu *Open*, *High*, *Low*, *Close*, *Adj Close*, *Volume*, dan satu *index*, *Date*. Terdapat juga 1445 records. Untuk memprediksi harga saham PT Intel Corporation, program ini menggunakan kolom "*Close*", yang menunjukkan harga penutupan pada hari tertentu.

	Date	Open	High	Low	Close	Adj Close	Volume
0	2019-01-02	45.959999	47.470001	45.770000	47.080002	40.518044	18774600
1	2019-01-03	46.150002	46.279999	44.389999	44.490002	38.289036	32267300
2	2019-01-04	45.840000	47.570000	45.540001	47.220001	40.638542	35447300
3	2019-01-07	47.099998	48.000000	46.750000	47.439999	40.827869	22736800
4	2019-01-08	47.799999	48.029999	46.779999	47.740002	41.086060	22749200
5	2019-01-09	47.959999	48.570000	47.779999	48.009998	41.318428	22554500
6	2019-01-10	47.750000	48.650002	47.410000	48.560001	41.791767	27202600
7	2019-01-11	48.099998	49.290001	48.049999	48.930000	42.110184	21751300
8	2019-01-14	48.459999	48.830002	48.299999	48.349998	41.611038	19193900
9	2019-01-15	48.709999	49.130001	48.439999	48.599998	41.826187	22480800

Gambar 2. Data frame Pada Program

Tahap kedua data yang digunakan dalam program ini sudah bersih, sehingga proses *cleansing* data selanjutnya merupakan proses mendeteksi nilai yang kosong atau tidak akurat pada dataset yang digunakan dalam program sebelum dataset digunakan untuk program. Berikut ini adalah sintaks program yang digunakan untuk menentukan apakah data memiliki nilai yang hilang:

```
[7] print(df.isnull().sum())
```



```

Date      0
Open      0
High      0
Low       0
Close     0
Adj Close 0
Volume    0
dtype: int64

```

Gambar 3. Hasil data *cleansing*

Setelah data dibersihkan, hasilnya ditampilkan pada Gambar 3., menunjukkan bahwa kolom *Open*, *High*, *Low*, *Close*, *Adj Close*, dan *Volume* memiliki hasil "0", yang menunjukkan bahwa tidak ada nilai yang hilang pada dataset. Dengan demikian, data dapat digunakan segera untuk proses pemodelan berikutnya.

Tahap ketiga *scaling* data dilakukan dengan tujuan untuk mengurangi kesalahan dalam program, dan dalam studi ini, proses *scaling* data menggunakan pendekatan Min-Max Scaling. Metode ini mampu mengubah ukuran data dari rentang aslinya menjadi nilai yang berada dalam interval antara 0 hingga 1.

```
[13] # Normalisasi data
      scaler = MinMaxScaler(feature_range=(0, 1))
      scaled_data = scaler.fit_transform(df[['Close']])

      print(scaled_data)
```

```
[[0.56857607]
 [0.51633726]
 [0.57139977]
 ...
 [0.09378784]
 [0.10145221]
 [0.10125051]]
```

Gambar 4. Hasil Normalisasi Data

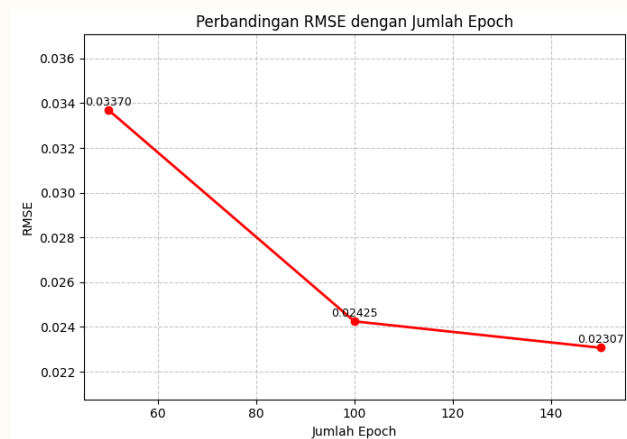
Setelah *scaling* data selesai, hasil ditampilkan pada Gambar 4., yang menunjukkan bahwa nilai data telah berhasil diubah menjadi rentang 0 hingga 1 sesuai dengan tujuan proses *scaling*.

Tahap keempat data akan dibagi untuk menghasilkan nilai prediksi yang mendekati nilai sebenarnya dan memiliki tingkat akurasi yang baik. Dalam pembagian data ini, data akan dipisahkan menjadi dua data uji dan data latih, digunakan untuk menghasilkan data prediksi dan mengukur performa model. Data *training* dilakukan dengan menggunakan tiga rasio perbandingan: 90%:10%, 80%:20%, dan 70%:30%.

Hasil Pengujian Model


Dalam proses pengujian model LSTM, terdapat tiga kategori utama yang digunakan selama pengembangannya, yaitu bobot jaringan, arsitektur model, dan parameter pelatihan. Parameter pelatihan LSTM mencakup pengaturan seperti *learning rate*, jumlah *epoch*, dan fungsi aktivasi yang digunakan. Proses pelatihan akan berakhir ketika tingkat kesalahan telah mencapai nilai yang ditargetkan atau jumlah iterasi maksimum telah terpenuhi. Berikut ini merupakan variasi parameter yang digunakan dalam proses *training*, yaitu nilai *learning rate*, jumlah *epoch*, dan fungsi aktivasi.

Pengujian *epoch* dilakukan dengan tiga parameter, yaitu 50, 100, dan 150. Hasil pengujian menunjukkan bahwa *epoch* 150 menghasilkan performa paling unggul dengan nilai RMSE terendah yang tercatat sebesar 0.02307.




Gambar 5. Perbandingan RMSE dengan jumlah Epoch

Pengujian *learning rate* dilakukan dengan tiga nilai: 0,001, 0,01, dan 0,05. Data yang diperoleh menunjukkan bahwa *learning rate* 0,01 memberikan hasil terbaik dengan nilai RMSE terendah yang tercatat sebesar 0.02240.



Gambar 6. Perbandingan RMSE dengan Learning Rate

Perbandingan nilai *Root Mean Square Error* (RMSE) yang dihasilkan dari tiga jenis fungsi aktivasi yang berbeda, yaitu *Relu*, *Tanh*, dan *Sigmoid*, dalam konteks model LSTM. Hasil yang didapat menunjukkan bahwa fungsi aktivasi *Tanh* memberikan hasil RMSE terendah yaitu 0.02932, yang menunjukkan kinerja prediksi paling baik di antara ketiga opsi tersebut.




Gambar 7. Perbandingan RMSE dengan Fungsi Aktivitas

Hasil Evaluasi Prediksi dan Visualisasi Hasil Prediksi


Evaluasi kinerja model LSTM dilakukan dengan membandingkan hasil prediksi yang dihasilkan dengan data yang sebenarnya menggunakan *Root Mean Square Error* (RMSE). RMSE berfungsi untuk menilai seberapa besar rata-rata ketidakepatan antara nilai yang diprediksi dan nilai nyata dalam satuan yang sebanding. Nilai RMSE yang lebih rendah menunjukkan bahwa hasil prediksi model lebih tepat. Dalam evaluasi model dilakukan pengujian dengan beberapa rasio diantaranya:

Pembagian data dengan rasio 90% : 10% menghasilkan 1291 data untuk pelatihan dan 144 data untuk pengujian. Dari pengolahan data tersebut, diperoleh nilai kesalahan RMSE sebesar 0.0234.




Gambar 8. Hasil Perbandingan Harga Aktual dan Prediksi 90:10

Pembagian data dengan rasio 80% : 20% menghasilkan 1148 data untuk pelatihan dan 287 data untuk pengujian. Dari pengolahan data tersebut, diperoleh nilai kesalahan RMSE sebesar 0.0243.



Gambar 9. Hasil Perbandingan Harga Aktual dan Prediksi 80:20

Pembagian data dengan rasio 70% : 30% menghasilkan 1004 data untuk pelatihan dan 431 data untuk pengujian. Dari pengolahan data tersebut, diperoleh nilai kesalahan RMSE sebesar 0.0230.



Gambar 10. Hasil Perbandingan Harga Aktual dan Prediksi 70:30

Berdasarkan tiga perbandingan tersebut, diperoleh bahwa pembagian data 70%:30% adalah yang paling efektif, karena menunjukkan nilai kesalahan RMSE sebesar 0.0230 dengan menggunakan parameter *epoch* 150, *learning rate* 0,01, *batch size* 32, serta optimasi adam. Di bawah ini adalah tabel yang menampilkan perbandingan antara nilai aktual dan nilai prediksi:

	Date	Actual Close	Predicted Close
0	2023-04-04	44.860001	44.630825
1	2023-04-05	45.240002	44.538095
2	2023-04-06	43.230000	45.129334
3	2023-04-10	42.750000	43.698033
4	2023-04-11	42.639999	42.629604
5	2023-04-12	42.709999	42.548365
6	2023-04-13	42.049999	42.776446
7	2023-04-14	42.200001	42.193380
8	2023-04-17	42.419998	42.145071
9	2023-04-18	42.570000	42.397147

RMSE (Train:Test = 70:30): 1.078093

Gambar 11. Hasil Perbandingan Nilai Aktual dan Nilai Prediksi 70:30

Selanjutnya, dengan mempertahankan proporsi pembagian data sebesar 70% untuk proses pelatihan dan 30% untuk evaluasi, model juga dimanfaatkan untuk meramalkan harga saham secara berurutan untuk satu bulan yang akan datang. Temuan ini menunjukkan bahwa model dapat mempertahankan kinerjanya dalam melakukan prediksi jangka pendek, sehingga dapat dijadikan acuan dalam pengambilan keputusan investasi.

	Date	Predicted Close	Date	Actual Close
0	2024-09-28	23.680565	2024-09-26	23.920000
1	2024-09-29	23.738554	2024-09-27	23.910000
2	2024-09-30	23.751247	2024-09-30	23.459999
3	2024-10-01	23.745182	2024-10-01	22.690001
4	2024-10-02	23.734383	2024-10-02	22.389999
5	2024-10-03	23.724983	2024-10-03	22.260000
6	2024-10-04	23.718834	2024-10-04	22.590000
7	2024-10-05	23.715744	2024-10-07	22.379999
8	2024-10-06	23.714760	2024-10-08	23.320000
9	2024-10-07	23.714834	2024-10-09	23.459999
10	2024-10-08	23.715128	2024-10-10	23.219999
11	2024-10-09	23.715080	2024-10-11	23.559999
12	2024-10-10	23.714396	2024-10-14	23.440001
13	2024-10-11	23.712980	2024-10-15	22.660000
14	2024-10-12	23.710878	2024-10-16	22.309999
15	2024-10-13	23.708208	2024-10-17	22.440001
16	2024-10-14	23.705114	2024-10-18	22.770000
17	2024-10-15	23.701736	2024-10-21	22.840000
18	2024-10-16	23.698208	2024-10-22	22.400000
19	2024-10-17	23.694630	2024-10-23	21.980000
20	2024-10-18	23.691074	2024-10-24	22.340000
21	2024-10-19	23.687593	2024-10-25	22.680000
22	2024-10-20	23.684221	2024-10-28	22.920000
23	2024-10-21	23.680975	2024-10-29	22.900000
24	2024-10-22	23.677860	2024-10-30	22.299999
25	2024-10-23	23.674877	2024-10-31	21.520000
26	2024-10-24	23.672022	2024-11-01	23.200001
27	2024-10-25	23.669281	2024-11-04	22.520000
28	2024-10-26	23.666651	2024-11-05	23.320000
29	2024-10-27	23.664118	2024-11-06	25.049999

Gambar 12. Hasil Perbandingan Nilai Prediksi dan Nilai Aktual

Tabel 2. Tabel Perbandingan Nilai Prediksi dan Aktual Harga Saham

Date	Predicted Close	Actual Close	Selisih
30/09/2024	23.751247	23.659999	0.291248
01/10/2024	23.745182	23.549999	1.055181
02/10/2024	23.734383	22.389999	1.353474
03/10/2024	23.724893	22.469999	1.464983
04/10/2024	23.718344	22.379999	1.128834

Pada perbandingan harga penutupan saham yang diprediksi dan harga penutupan yang sebenarnya dalam periode 30 September hingga 4 Oktober 2024. Analisis menunjukkan bahwa prediksi model yang paling akurat terjadi pada 30 September, dengan selisih hanya 0.291248. Sebaliknya, perbedaan terbesar terjadi pada 3 Oktober, mencapai 1.464983. Rata-rata selisih selama periode tersebut adalah sekitar 1.0587 USD, yang mencerminkan rata-rata perbedaan model dari data nyata.



Gambar 13. Grafik Prediksi Harga Close 30 Hari

Penelitian ini menggunakan LSTM untuk memprediksi harga saham Intel Corporation karena kemampuannya untuk menangani data berurutan dan melihat tren jangka panjang. Relatif terhadap data asli, kesalahan prediksi rata-rata model diukur dengan RMSE. Dengan tingkat kesalahan yang sangat rendah RMSE sebesar 0.0230, model ini menunjukkan bahwa model ini dapat secara akurat memprediksi nilai saham. Karena teknik alternatif seperti CNN dan regresi linier kurang baik dalam mengidentifikasi pola deret waktu, nilai RMSE yang diperoleh mungkin akan lebih besar.

KESIMPULAN

Berdasarkan temuan penelitian ini, dapat disimpulkan bahwa metode *Long Short-Term Memory* (LSTM) berhasil digunakan untuk memprediksi harga saham Intel Corporation. Penelitian ini menggunakan 1.445 data historis dari kaggle.com yang telah melalui proses pembersihan, dengan pembagian data yang terdiri dari 70% untuk proses pelatihan dan 30% untuk pengujian. Model ini dilatih melalui 150 *epoch*, dengan *learning rate* sebesar 0,01, menggunakan fungsi aktivitas *tanh* dan *optimizer* Adam. Hasil yang diperoleh menunjukkan evaluasi RMSE mendapatkan nilai 0.0230, yang merupakan hasil paling optimal. Selain itu, model yang telah dikembangkan juga digunakan untuk melakukan prediksi harga saham dalam periode satu bulan ke depan, dengan menggunakan data historis sebagai dasar prediksi. Hasil prediksi menunjukkan pola pergerakan harga yang cukup realistis, menggambarkan kemampuan model untuk memahami pergerakan pasar. Prediksi ini bisa dijadikan panduan awal bagi para investor dalam menyusun strategi jangka pendek, meskipun tidak sepenuhnya akurat. Namun, hasil tersebut tetap bermanfaat sebagai alat bantu dalam analisis untuk pengambilan keputusan investasi yang lebih didasarkan pada data. Sebagai panduan untuk penelitian yang akan datang, disarankan agar pendekatan LSTM ditingkatkan dengan mengevaluasi kemampuannya dibandingkan dengan algoritma lain seperti GRU untuk mencapai hasil prediksi yang lebih optimal. Percobaan juga harus dilakukan pada data saham dari sektor lain untuk menilai seberapa baik model dapat digeneralisasi. Dengan pendekatan yang lebih menyeluruh, hasil prediksi yang dihasilkan diharapkan tidak hanya akurat secara statistik, tetapi juga relevan terhadap dinamika pasar nyata dalam pengambilan keputusan investasi.

DAFTAR PUSTAKA

- Achyar, A. A., Olow, A. M., Perdana, M. R., Sundawijaya, A., & Goenawan, A. D. (2022). Identifikasi Ras Wajah Dengan Menggunakan Metode Deep Learning Model Keras. *Jurnal Teknik Mesin, Industri, Elektro Dan Informatika*, 1(1), 29-37. <https://doi.org/10.55606/jtmei.v1i1.779>
- Agusta, A., Ernawati, I., & Muliawati, A. (2021). Prediksi Pergerakan Harga Saham Pada Sektor Farmasi Menggunakan Algoritma Long Short-Term Memory. *Informatik : Jurnal Ilmu Komputer*, 17(2), 164-173. <https://doi.org/10.52958/iftk.v17i2.3651>
- Alex Khr. (2024). *INTEL stocks price from 2019-01-01 to 2024-09-27*. Kaggle. <https://www.kaggle.com/datasets/alexkhr/intel-stocks-price-from-2019-01-01-to-2024-09-27>
- Damayanti, E., Vitianingsih, A. V., Kacung, S., Suhartoyo, H., & Lidya Maukar, A. (2024). Sentiment Analysis of Alfagift Application User Reviews Using Long Short-Term Memory (LSTM) and Support Vector Machine (SVM) Methods. *Decode: Jurnal Pendidikan Teknologi Informasi*, 4(2), 509–521. <https://doi.org/10.51454/decode.v4i2.478>
- Gumelar, F., Adha, F. Z., Rafi, F. A., Pontoh, R. S. (2022). Peramalan Harga Saham Bank BUMN Indonesia Menggunakan Long Short-Term Memory (LSTM). *Seminar Nasional Statistika Aktuaria I*, 1(1), 1–8.
- Hamdani, A. F., & Saputra, A. J. (2023, January). Prediksi Harga Saham Tesla Menggunakan Algoritma Neural Prophet Berbasis Mobile. In *Seminar Nasional Teknologi & Sains* 2(1), 129-136.
- Janastu, I. N. C., & Wutsqa, D. U. (2024). Prediksi Harga Saham Pada Sektor Perbankan Menggunakan Algoritma Long Short-Term Memory. *Jurnal Statistika Dan Sains Data*, 1(2), 1–14.
- Julian, R., & Pribadi, M. R. (2021). Peramalan Harga Saham Pertambangan Pada Bursa Efek Indonesia (BEI) Menggunakan Long Short Term Memory (LSTM). *JATISI (Jurnal Teknik Informatika Dan Sistem Informasi)*, 8(3), 1570–1580. <https://doi.org/10.35957/jatisi.v8i3.1159>
- Kiramy, R. Al, Permana, I., & Marsal, A. (2024). Perbandingan Performa Algoritma RNN dan LSTM dalam Prediksi Jumlah Jamaah Umrah pada PT. Hajar Aswad, 4(4), 1224–1234. <https://doi.org/10.57152/malcom.v4i4.1373>

- Lestari, Y. D., Santoso, E., & Ridok, A. (2021). Prediksi Harga Saham Menggunakan Metode Extreme Learning Machine (ELM) (Studi Kasus : Saham PT Bank Rakyat Indonesia). *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 5(7), 2801–2808.
- Ningrum, A. R., & Seru, F. (2022). Penerapan gerak Brown geometrik untuk memprediksi harga saham PT. Astra International Tbk. pada masa pandemi COVID-19. *Jurnal Riset Dan Aplikasi Matematika (JRAM)*, 6(2), 93-104.
- Pipin, S. J., Purba, R., & Kurniawan, H. (2023). Prediksi Saham Menggunakan Recurrent Neural Network (RNN-LSTM) dengan Optimasi Adaptive Moment Estimation. *Journal of Computer System and Informatics (JoSYC)*, 4(4), 806–815. <https://doi.org/10.47065/josyc.v4i4.4014>
- Puteri, D. I. (2023). Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah. *Euler : Jurnal Ilmiah Matematika, Sains Dan Teknologi*, 11(1), 35–43. <https://doi.org/10.34312/euler.v11i1.19791>
- Putra. (2024). *Analisis Perbandingan Model Prediksi Harga Saham melalui Pendekatan Long-Short Term Memory (LSTM) Dan Autoregressive Integrated Moving Average (ARIMA) (Studi Kasus: Alfamart dan Alfamidi) TUGAS*.
- Rasyidi, M. A. (2023). Rancang Model Algoritma Long Short Term Memory Dengan Metode Rolling Windows Cross Validation: Studi Kasus Nilai Tukar Rupiah Terhadap Dollar Amerika. <https://repository.uinjkt.ac.id/dspace/handle/123456789/74144>
- Riadi, I., Umar, R., & Anggara, R. (2024). Prediksi Kelulusan Tepat Waktu Berdasarkan Riwayat Akademik Menggunakan Metode Naïve Bayes. *Decode: Jurnal Pendidikan Teknologi Informasi*, 4(1), 191-203. <https://doi.org/10.51454/decode.v4i1.308>
- Riatma, D. L., Rahman, Y. F., Roshinta, T. A., Sani, A. F., Khoirunisa, R., & Haqimi, N. A. (2025). *Model Prediksi Manajemen Stok Produk Berbasis Deep Learning Gated Recurrent Unit untuk Optimalisasi Rantai Pasok E-Commerce*. 5(1), 314–323.
- Riyantoko, P. A., Fahrudin, T. M., Hindrayani, K. M., & Safitri, E. M. (2020). Analisis Prediksi Harga Saham Sektor Perbankan Menggunakan Algoritma Long-Short Terms Memory (Lstm). *In Seminar Nasional Informatika (SEMNASIF)*, 1(1), 427–435.
- Sautomo, S., & Pardede, H. F. (2021). Prediksi belanja pemerintah Indonesia menggunakan long short-term memory (LSTM). *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, 5(1), 99-106. <https://doi.org/10.29207/resti.v5i1.2815>
- Setiawan, D., Stefani, K., Shandy, Y. J., & Patra, C. A. F. (2023). Sistem Analisa Harga Saham Menggunakan Algoritma Long Short Term Memory (LSTM). *Media Informatika*, 21(3), 264–279. <https://doi.org/10.37595/mediainfo.v21i3.159>
- Sofi, K., Sunge, A. S., Riady, S. R., & Kamalia, A. Z. (2021). Perbandingan algoritma linear regression, LSTM, dan GRU dalam memprediksi harga saham dengan model time series. *PROSIDING SEMINASTIKA*, 3(1), 39-46. <https://doi.org/10.47002/seminastika.v3i1.275>
- Tauran, E. R. (2021). Prediksi Harga Saham Pt Bank Central Asia Tbk Berdasarkan Data Dari Bursa Efek Indonesia Menggunakan Metode K-Nearest Neighbors (Knn). *TeIka*, 11(2), 123–129. <https://doi.org/10.36342/teika.v11i2.2609>
- Wijaya, E., Tarigan, F. A., & Michael. (2021). Aplikasi Prediksi Penentuan Kelancaran Pembayaran Koperasi Dengan Algoritma C5.0. *Jurnal TIMES*, 10(1), 31–38. <https://doi.org/10.51351/jtm.10.1.2021648>