



IMPLEMENTASI DATA MINING DALAM PREDIKSI HARGA SAHAM BBNI DENGAN PEMODELAN MATEMATIKA MENGGUNAKAN METODE LSTM DENGAN OPTIMASI ADAM

Alrafiqul Rahman¹, Lucia Sri Istiyowati², Valentinus³, Ivan⁴, Zainal Azis⁵

^{1,2,3} Fakultas Teknologi Informasi, Institute Perbanas, Jakarta, Indonesia

^{4,5} Matematika, Universitas Muhammadiyah Sumatra Utara, Medan, Indonesia

email: alrafiqul.rahman@perbanas.id¹, lucia.istiyowati@perbanas.id², valentinus13@perbanas.id³, irvan@umsu.ac.id⁴, zainalazis@umsu.ac.id⁵

Informasi Artikel	ABSTRACT
<p>Riwayat artikel : Disubmit : 28 November 2024 Direvisi : 13 Desember 2024 Diterima : 15 Desember 2024 Dipublikasi : 20 Desember 2024</p> <p>Keywords: Stock Price Prediction, Long Short-Term Memory (LSTM), Adam Optimization, Data Mining</p>	<p><i>Stock price prediction plays a crucial role in investment decision-making, allowing investors to maximize profits and minimize risks. This study implements the Long Short-Term Memory (LSTM) method with Adam optimization to predict the stock price of Bank Negara Indonesia (BBNI) based on historical stock price data from the Indonesia Stock Exchange (2001-2023). LSTM is chosen for its ability to handle sequential data and identify long-term patterns in time series. Meanwhile, the Adam optimization algorithm is used to accelerate model convergence and improve prediction accuracy. The data used includes daily stock prices (closing prices), and the research process involves data collection, preprocessing, LSTM model creation, Adam optimization, training, evaluation, and prediction. The experimental results show that the model with a batch size of 64 and 100 epochs yields an R² of 0.9928 and a MAPE of 1.53%, indicating a very high prediction accuracy. With an accuracy of 98.46%, the LSTM model with Adam optimization proves to be effective in predicting stock prices, providing excellent results for applications in investment strategies. This study demonstrates the great potential of applying data mining and machine learning techniques in more informed and data-driven stock market analysis.</i></p>
	ABSTRAK
<p>Kata Kunci: Prediksi Harga Saham, Long Short-Term Memory (LSTM), Optimasi Adam, Data Mining.</p>	<p>Prediksi harga saham memainkan peran penting dalam pengambilan keputusan investasi, memungkinkan investor untuk memaksimalkan keuntungan dan meminimalkan risiko. Penelitian ini mengimplementasikan metode Long Short-Term Memory (LSTM) dengan optimasi Adam untuk memprediksi harga saham Bank Negara Indonesia (BBNI) berdasarkan data historis harga saham dari Bursa Efek Indonesia (2001-2023). LSTM dipilih karena kemampuannya dalam menangani data berurutan dan mengidentifikasi pola jangka panjang dalam time series. Sementara itu, algoritma optimasi Adam digunakan untuk mempercepat konvergensi model dan meningkatkan akurasi prediksi. Data yang digunakan mencakup harga saham harian (harga penutupan), dan proses penelitian meliputi pengumpulan data, preprocessing, pembuatan model LSTM, optimasi dengan Adam, pelatihan, evaluasi, dan prediksi. Hasil eksperimen menunjukkan bahwa model dengan <i>batch size</i> 64 dan <i>epoch</i> 100 menghasilkan R² sebesar 0.9928 dan MAPE sebesar 1.53%, yang menunjukkan tingkat akurasi prediksi yang sangat tinggi. Dengan akurasi mencapai 98.46%, model LSTM dengan optimasi Adam terbukti efektif dalam memprediksi harga saham, memberikan hasil yang sangat baik untuk aplikasi dalam strategi investasi. Penelitian ini menunjukkan potensi besar penerapan teknik data mining dan machine learning dalam analisis pasar saham yang lebih terinformasi dan berbasis data.</p>





PENDAHULUAN

Prediksi harga saham memainkan peran krusial dalam pengambilan keputusan investasi. Dengan memproyeksikan pergerakan harga saham di masa depan, investor dapat menentukan waktu yang tepat untuk membeli atau menjual saham, sehingga memaksimalkan keuntungan dan meminimalkan risiko. Analisis prediktif ini membantu investor dalam mengidentifikasi tren pasar, memahami volatilitas, dan membuat strategi investasi yang lebih terinformasi.

Namun, mencapai prediksi harga saham yang akurat merupakan tantangan tersendiri. Fluktuasi harga saham yang tidak menentu menciptakan tantangan dalam meramalkan pergerakan pasar. Faktor-faktor seperti kondisi ekonomi global, peristiwa politik, dan sentimen pasar dapat mempengaruhi harga saham secara signifikan, membuat prediksi menjadi kompleks dan sering kali tidak pasti. Selain itu, noise dalam data historis harga saham dan ketergantungan temporal antara harga sebelumnya dan harga saat ini menyulitkan pengenalan pola pergerakan harga. Dalam lingkungan pasar yang dinamis, kemampuan model dalam menghasilkan prediksi yang akurat memiliki implikasi penting bagi pengambilan keputusan investasi yang lebih terinformasi (Pipin et.al, 2023)

Data mining sebagai salah satu pendekatan dalam analisis data, telah menunjukkan potensi besar dalam mengolah data historis untuk memprediksi tren harga saham. Dengan memanfaatkan data mining, pola tersembunyi dalam data dapat diungkapkan dan digunakan untuk melakukan prediksi yang lebih akurat. Salah satu metode data mining yang populer dalam prediksi data waktu adalah Long Short Term Memory (LSTM), jenis jaringan saraf tiruan (RNN) yang memiliki kemampuan untuk mempertahankan informasi jangka panjang. LSTM efektif dalam menangani data berurutan dan mengatasi masalah vanishing gradient, menjadikannya metode yang sesuai untuk prediksi harga saham (Siswanto et.al, 2024; Bao et.al, 2024).

Namun, untuk meningkatkan kinerja prediksi model LSTM, diperlukan teknik optimasi yang tepat. Salah satu algoritma optimasi yang digunakan secara luas adalah Adam Optimizer. Algoritma ini menggabungkan dua teknik optimasi, yaitu momentum dan adaptive learning rate, sehingga dapat meningkatkan konvergensi model secara lebih efisien (Kingma & Ba, 2015) . Implementasi Adam dalam pelatihan model LSTM bertujuan untuk memaksimalkan akurasi prediksi dan stabilitas model dalam memprediksi harga saham.

Penelitian-penelitian sebelumnya menunjukkan bahwa penggunaan LSTM dengan Adam Optimizer dalam prediksi harga saham memberikan hasil yang menjanjikan (Faridah & Sugiantoro, 2023). Berbagai studi juga mengungkapkan bahwa metode ini mampu mengakomodasi dinamika pasar saham yang sangat fluktuatif, sehingga investor dapat memiliki gambaran yang lebih jelas dalam menentukan strategi investasi mereka (Wathani & Kusnawi, 2023; Puteri,2023).





Tujuan dari penelitian ini ialah Implementasi Data Mining dalam Prediksi Harga Saham Bank Negara Indonesia (Persero) Tbk dengan Pemodelan Matematika Menggunakan Metode *Long Short Term Memory* (LSTM) dengan Optimasi Adam.

METODE PENELITIAN

2.1. Sumber Data

Pada penelitian ini, sumber data yang digunakan yaitu menggunakan data dari (*Indonesia Stock Exchange, 2024*) yang bersifat *time series*, adapun data ini merupakan data histori harga-harga saham yang didapat bersifat *open source*. Dataset yang digunakan terdapat 5670 data saham Bank Negara Indonesia (Persero) Tbk dari Tahun 2001 sampai 2023. Harga saham didapat dari proses pengumpulan data harga dari *Indonesia Stock Exchange* (Bursa Efek Indonesia) yang diambil adalah data harga saham Bank Negara Indonesia (Persero) Tbk. Berikut detail dataset yang digunakan.

Tabel 1. Dataset Saham BBNI Lima Data Awal

Date	Open	Low	High	Close	Volume
2001-04-16	1232	1232	1327	1232	0
2001-04-17	1232	1232	1327	1232	0
2001-04-18	1232	1232	1327	1232	0
2001-04-19	1232	1232	1327	1232	0

2.2. Metode Penelitian

Pada penelitian ini, peneliti menggunakan salah satu metodologi dalam data mining menggunakan metode *Long Short Term Memory* (LSTM) dengan Optimasi Adam dengan tahapan yang dilakukan dimulai pada pengumpulan data, lalu *preprocessing* kemudian membangun model LSTM dengan optimasi Adam kemudian pelatihan dan evaluasi diakhiri dengan tahapan prediksi. Gambar 1 yang menunjukkan proses tahapan yang dilakukan pada penelitian ini.

Pada Gambar 1 memperlihatkan alur tahapan pada metode penelitian yang dilakukan diantaranya :

1. *Data Collection* (Pengumpulan Data)

Mengumpulkan data historis untuk variabel yang akan diprediksi, seperti harga saham, volume perdagangan, atau indikator pasar lainnya. Data ini biasanya berbentuk *time series* dan menjadi dasar analisis.

2. *Preprocessing* (Pra-pemrosesan)

Data dipersiapkan agar siap diolah oleh model. Tahap ini meliputi:

- a. *Normalisasi*: Mengubah data ke skala tertentu (misalnya 0 hingga 1) agar lebih mudah diolah oleh model LSTM.





- b. Penanganan Data Hilang: Membersihkan data dari nilai yang hilang atau *outlier* yang dapat mengganggu hasil analisis.

Data kemudian disusun dalam bentuk sekuensial agar sesuai dengan kebutuhan LSTM.



Gambar 1. Tahapan Metode Penelitian

3. Membangun Model LSTM

Mendesain struktur model LSTM, termasuk jumlah layer dan unit pada tiap layer. LSTM dipilih karena kemampuannya untuk menangani data berurutan dan mempertahankan pola dalam data untuk jangka panjang.

4. Optimization (Optimasi Adam)

Menggunakan algoritma optimasi Adam untuk meningkatkan performa model. Adam menggabungkan keunggulan metode momentum dan RMSProp, yang membuat proses pelatihan lebih cepat dan stabil.

5. *Training and Evaluation* (Pelatihan dan Evaluasi)



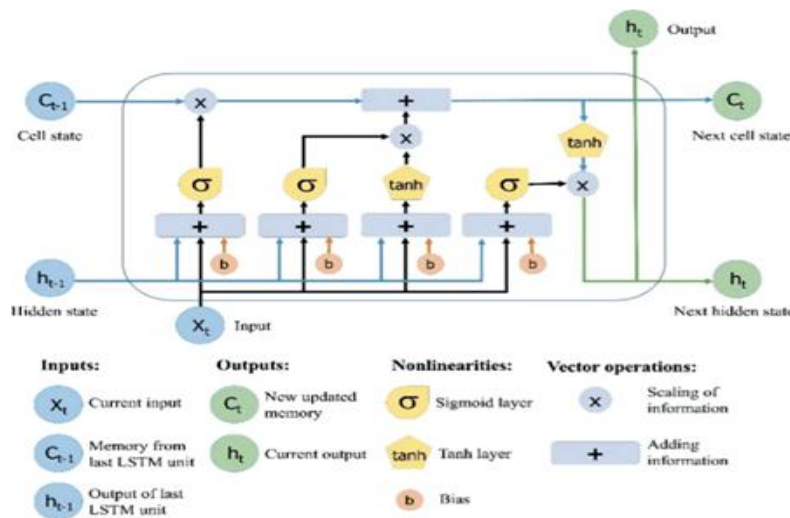
Melatih model LSTM menggunakan data pelatihan. Model belajar dari pola-pola dalam data historis untuk memperkirakan hasil di masa depan. Setelah pelatihan, model dievaluasi menggunakan metrik seperti *Mean Squared Error* (MSE) atau *Root Mean Squared Error* (RMSE) untuk mengukur akurasi dan efektivitas model.

6. *Prediction* (Prediksi)

Model yang sudah terlatih digunakan untuk membuat prediksi harga saham di masa depan. Hasil prediksi ini kemudian dapat digunakan untuk analisis atau pengambilan keputusan lebih lanjut.

2.3. Metode Pengujian Dataset

Penelitian ini melakukan pemodelan matematika menggunakan metode *Long Short Term Memory* (LSTM) dengan optimasi Adam. Adapun *flowchart* sistem pada riset ini dapat diamati pada Gambar 2 (Dineshkumar & Subramani, 2024).



Gambar 2. Flowchart Architecture LSTM Optimasi Adam

Setiap algoritma memiliki langkah-langkah dan fungsi yang diterapkan untuk melaksanakan prediksi harga saham menerapkan metode LSTM memiliki tiga gerbang utama yang mengontrol aliran informasi (Kingma & Ba, 2015):

- a. *Forget Gate*: menentukan informasi dari cell state sebelumnya (C_{t-1}) yang perlu dihapus atau disimpan. Persamaannya adalah:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \dots \dots \dots (1)$$

f_t adalah vektor forget gate pada waktu t .
 W_f adalah bobot untuk forget gate.





h_{t-1} adalah *hidden state* dari waktu sebelumnya.

x_t adalah input pada waktu t .

b_f adalah bias untuk *forget gate*.

σ adalah fungsi aktivasi sigmoid yang membatasi nilai antara 0 dan 1 (0 berarti melupakan, 1 berarti menyimpan).

- b. *Input gate* mengontrol informasi baru yang akan ditambahkan ke *cell state* saat ini. Terdapat dua langkah di sini (Fischer & Krauss, 2018):

- 1. Pertama, menentukan kandidat *cell state* baru (\tilde{C}_t) [10]:

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \dots \dots \dots (2)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \dots \dots \dots (3)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \dots \dots \dots (4)$$

\tilde{C}_t adalah kandidat *cell state* baru, sementara i_t adalah *input gate*.

W_c dan b_c adalah bobot dan bias untuk kandidat *cell state*.

* adalah operasi perkalian elemen-wisely.

- c. *Output Gate* mengontrol bagian mana dari *cell state* yang akan digunakan untuk menghasilkan *output* (Siami et.al, 2018)

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \dots \dots \dots (5)$$

Output hidden state diperoleh dengan mengalikan *output gate* o_t dengan \tanh dari *cell state* saat ini:

$$h_t = o_t * \tanh(C_t) \dots \dots \dots (6)$$

o_t adalah *output gate*.

h_t adalah *hidden state* atau *output* yang digunakan untuk langkah selanjutnya dalam jaringan atau untuk prediksi.

2.4. Evaluasi Model

Pengujian dilakukan pada data latih dan data uji. Pengujian dilakukan dengan menerapkan model LSTM yang belum dilakukan optimasi dengan menggunakan Adam dan pengujian terhadap model LSTM yang telah dioptimasi dengan Adam dalam meningkatkan hasil akurasi dalam model yang digunakan. Kemudian akan dilakukan perbandingan akurasi dari varian Adam dengan menggunakan model LSTM.

Dengan pemodelan matematika ini, LSTM dengan Adam sebagai algoritma optimasi untuk memperbarui bobot agar model dapat meminimalkan loss. LSTM dapat mengenali pola jangka panjang dalam data sekuensial (Zhao, 2023), sementara optimasi Adam membantu mempercepat konvergensi dan menyesuaikan laju pembelajaran secara adaptif selama proses pelatihan.

Terdapat *loss function* yang digunakan sebagai kriteria dalam mengevaluasi kinerja prediksi kualitas udara termasuk *Root Mean Square Error* (RMSE), *R-square* (R^2), dan *Mean Absolute Error* (MAE) (Gunawan & Wibowo, 2023). Pada metode yang diterapkan dapat dikatakan bekerja dengan baik saat nilai loss function memiliki nilai yang kecil. Akurasi model untuk menentukan performa yang baik dari Adam menggunakan metode *Mean Absolute Percentage Error* (MAPE) dengan menemukan nilai





kesalahan absolut dari setiap periode yang telah dibagi dengan nilai aktual dari periode tersebut dan dibuat rata-rata *absolute percentage error*.

Perhitungan matematis MAE yang dijelaskan dalam persamaan berikut (Emanuella et.al, 2022):

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

Dimana \hat{y}_i merupakan nilai prediksi dan y_i merupakan nilai benar. Semakin kecil nilai dari MAE maka semakin baik kinerja model prediksinya.

Perhitungan matematis RMSE yang dijelaskan dalam persamaan berikut (Wathani et.al, 2023):

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

Dimana \hat{y}_i merupakan nilai prediksi dan y_i merupakan nilai benar. Semakin kecil nilai dari RMSE maka semakin baik kinerja model prediksinya.

Perhitungan matematis MSE yang dijelaskan dalam persamaan berikut (Pipin et.al, 2023; Rosyd et.al, 2024):

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \dots\dots\dots(3)$$

Dimana $\frac{1}{n} \sum_{i=1}^n$ merupakan nilai *mean* dan $(Y_i - \hat{Y}_i)^2$ merupakan nilai *error* dan *squared*. MSE dihitung dengan mengambil rata-rata dari selisih kuadrat tersebut. Nilai MSE yang lebih rendah mengindikasikan bahwa prediksi model lebih mendekati harga aktual, mencerminkan kinerja yang lebih baik (Pipin et.al, 2023).

Perhitungan matematis R^2 yang dijelaskan dalam persamaan berikut (Emanuella et.al, 2022):

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

Dimana \hat{y}_i merupakan nilai prediksi dan y_i merupakan nilai benar, \bar{y} merupakan nilai rata-rata. Rentang nilai dari R^2 adalah (0,1).

Perhitungan matematis *MAPE* yang dijelaskan dalam persamaan berikut (Arkadia et.al, 2022):

$$MAPE (p) = \frac{1}{n} \sum_{i=1}^n \frac{|y_t - \hat{y}_t|}{y_t} \times 100\% \dots\dots\dots(5)$$

Tabel 2. Akurasi MAPE

Nilai MAPE	Akurasi
$p \leq 10\%$	Sangat Akurat
$10\% < p \leq 20\%$	Akurat
$20\% < p \leq 50\%$	Cukup Akurat
$p > 50\%$	Tidak Akurat





Mean Absolute Percentage Error (MAPE) adalah nilai rata – rata perbedaan absolut yang ada diantara nilai dari prediksi dan nilai realisasi yang disebutkan sebagai hasil persenan dari nilai realisasi. Penggunaan *Mean Absolute Percentage Error* (MAPE) pada evaluasi dari hasil peramalan dapat melihat tingkat akurasi terhadap angka peramalan dan angka realisasi (Nabillah & Ranggadara, 2020).

HASIL DAN PEMBAHASAN

3.1. Hasil Pengumpulan dan *Pre-processing* Data

Pada tahap awal penelitian, dilakukan pengumpulan data historis harga saham dari data pergerakan harga saham tiap harinya di Bursa Efek Indonesia sejak 16 April 2001 sampai 6 Januari 2023 dengan melakukan pembagian data latih 80% dan data pengujian 20% dengan menekankan pada data saham kolom harga *close*. Data yang diperoleh mencakup rentang waktu tertentu yang relevan dengan tujuan analisis. Proses pengumpulan data ini memastikan bahwa dataset yang digunakan dalam penelitian memiliki integritas dan kualitas yang tinggi. Selanjutnya, tahapan *pre-processing* data dilakukan untuk mempersiapkan data sebelum diolah oleh model LSTM dengan Optimasi Adam. Penelitian ini menggunakan data history saham dengan kode perusahaan BBNI Bank Negara Indonesia (Persero) Tbk dengan tiap dataset saham berisi rangkaian variabel seperti tanggal (*Time frame*), harga pembukaan (*Open*), penutupan (*Close*), harga terendah (*Low*), harga tertinggi (*High*), volume perdagangan. Adapun jumlah keseluruhan yaitu 5670 data. Pada proses menjalankan algoritma LSTM dibagi menjadi beberapa proses diantara penggunaan *optimizer Adam epoch* 25, 50, 75 serta 100. Berikut lima data terakhir yang akan ditampilkan.

Hasil penelitian dapat dilengkapi dengan tabel, grafik (gambar), dan/atau bagan. Bagian pembahasan memaparkan hasil pengolahan data, menginterpretasikan penemuan secara logis, mengaitkan dengan sumber rujukan yang relevan.

Tabel 3. Dataset Saham BBNI Lima Data Terakhir

Date	Open	Low	High	Close	Volume
1/2/2023	9225	9100	9225	9225	6699200
1/3/2023	9200	9150	9300	9275	13231500
1/4/2023	9275	9150	9300	9175	24059200
1/5/2023	9150	8825	9150	9000	45567500
1/6/2023	8975	8875	9050	8900	23537500
1/2/2023	9225	9100	9225	9225	6699200

Exchange (Bursa Efek Indonesia), meliputi data saham BNI. Data saham yang diambil meliputi kolom date, open, close, high, low, adj close, volume. Date merupakan data tanggal, bulan, dan tahun untuk data saham yang diterbitkan dalam waktu sesuai pembukaan pasar saham. *Open* merupakan data harga





saham pertama kali melakukan transaksi pada hari itu. *High* dan *Low* merupakan pergerakan harga harian untuk melakukan posisi jual atau beli saham secara rasionalitas. *Close* merupakan harga saham pada saat semua perdagangan di bursa saham berakhir. *Adj Close* merupakan harga pada saat penutupan harga saham yang mempengaruhi pembagian *dividen* dan *stock split*. Volume merupakan seluruh jumlah lembar atau lot saham pada periode tertentu. Pada penelitian ini, difokuskan pada harga saham *close* atau penutupan harga saham harian sebagai acuan atau data input yang akan diolah untuk data pelatihan dan data pengujian.

3.2. Membandingkan Hasil variasi *batch size* dan *epochs* terhadap MSE, RMSE, MAE, R², dan MAPE Percobaan pada Tabel 4 menggunakan data saham BBNI dengan melakukan analisis pada model optimasi Adam variasi *epoch* dan *batch size*. Dari data saham close hasil yang terbaik didapat pada *batch size* 64 *epoch* 100 dengan mendapat R² sebesar 0.9928 dan MAPE sebesar 1.53% yang dimana hasil tersebut mendekati 0% artinya mendekati hasil yang sangat baik. Hal ini sedikit banyak mempengaruhi tingkat akurasi model optimasi. Tetapi apabila dilihat dari data percobaan di kolom akurasi dari saham BBNI model optimasi menghasilkan data akurasi yang berbeda.

Tabel 4. Optimasi Adam dengan Variasi *Batch size* dan *Epoch*


<i>Batch size</i>	<i>Epoch</i>	MSE	RMSE	MAE	R ²	MAPE
32	25	24974.34	158.03	120.54	0.9910	1.83%
	50	21129.79	145.36	106.73	0.9924	1.60%
	100	23097.74	151.97	114.43	0.9917	1.69%
64	25	32713.50	180.86	135.06	0.9882	2.08%
	50	21181.23	145.53	106.10	0.9923	1.60%
	100	19804.51	140.72	101.30	0.9928	1.53%
128	25	60910.89	246.80	186.53	0.9781	2.79%
	50	29646.93	172.18	130.77	0.9893	2.01%
	100	21965.51	148.20	109.39	0.9921	1.64%

Tabel 5. Accuracy LSTM Optimasi Adam dengan Variasi *Batch size* dan *Epoch*


<i>Batch size</i>	<i>Epoch</i>	Accuracy
32	25	98.17%
	50	98.39%
	100	98.31%
64	25	97.92%
	50	98.39%
	100	98.46%
128	25	97.21%
	50	97.99%
	100	98.36%




Pada data Tabel 5, dapat dilihat saat percobaan menggunakan model optimasi Adam dengan nilai *epoch* 25, 50, dan 100. Dari ke empat grafik tersebut, antara data pengujian dan data prediksi dengan menggunakan algoritma LSTM sangat tidak jauh berbeda. Dimana untuk data dengan *batch size* 64 *epoch* 100 nilai *accuracy* sebesar 98,46%. Sehingga dapat dikatakan bahwa model optimasi Adam semakin tinggi nilai *epoch*, semakin tinggi juga tingkat akurasinya.




Gambar 3. Data BBNI *batch size* 32 dan *epoch* 25



Gambar 4. Data BBNI *batch size* 32 dan *epoch* 50




Gambar 5. Data BBNI *batch size* 32 dan *epoch* 100




Gambar 6. Data BBNI *batch size* 64 dan *epoch* 25







Gambar 7. Data BBNI *batch size* 64 dan *epoch* 50




Gambar 8. Data BBNI *batch size* 64 dan *epoch* 100



Gambar 9. Data BBNI *batch size* 128 dan *epoch* 25



Gambar 10. Data BBNI *batch size* 128 dan *epoch* 50



Gambar 11. Data BBNI *batch size* 128 dan *epoch* 100





SIMPULAN

Metode LSTM yang dioptimasi dengan Adam dapat digunakan untuk memprediksi harga saham dengan akurasi yang sangat baik, terutama ketika menggunakan pengaturan *batch size* 64 dan *epoch* 100. Model ini mampu menangani volatilitas pasar yang tinggi dan memberikan hasil prediksi yang dapat diandalkan bagi investor. Oleh karena itu, penelitian ini menunjukkan potensi besar penggunaan LSTM dalam analisis prediktif pasar saham untuk pengambilan keputusan investasi yang lebih informasional dan terukur.

Secara keseluruhan, penelitian ini menunjukkan bahwa penggunaan LSTM yang dioptimasi dengan Adam adalah pendekatan yang efektif dalam prediksi harga saham. Model ini memberikan hasil yang sangat akurat dan dapat diandalkan untuk membantu investor dalam mengambil keputusan investasi. Dengan akurasi prediksi yang mencapai 98.46% untuk *batch size* 64 dan *epoch* 100, model ini dapat dianggap sebagai alat yang bermanfaat dalam analisis pasar saham. Penerapan model ini dapat memberikan keuntungan kompetitif dalam dunia investasi dengan memanfaatkan teknik data mining dan machine learning untuk membuat prediksi yang lebih terinformasi. Dengan pengembangan lebih lanjut, model ini berpotensi menjadi alat yang sangat berguna dalam dunia keuangan dan pasar saham global.

DAFTAR RUJUKAN

- Arkadia, B., Hananto, B., & Prasvita, D. S. (2022). Optimasi long short-term memory dengan Adam menggunakan data udara kota DKI Jakarta. In *Seminar Nasional Mahasiswa Ilmu Komputer dan Aplikasinya (SENAMIKA)* (pp. 92–101).
- Bao, W., Cao, Y., Yang, Y., Che, H., Huang, J., & Wen, S. (2024). Data-driven stock forecasting models based on neural networks: A review. *Information Fusion*, 113, Article 102616. <https://doi.org/10.1016/j.inffus.2024.102616>
- Dineshkumar, P., & Subramani, D. B. (2024). Foresight in finance: Elevating predictions with enhanced RNN-LSTM and Adam optimizer. *Educational Administration: Theory and Practice*, 30(5), 13637–13646. <https://doi.org/10.53555/kuvey.v30i5.5931>
- Emanuella, T., Lawi, A., & Hendra. (2022). Model prediksi harga saham Apple Inc pada beberapa bursa efek menggunakan metode multivariate gated recurrent unit. In *Prosiding Seminar Nasional Teknik Elektro dan Informatika (SNTEI)* (pp. 298–303).
- Faridah, N., & Sugiantoro, B. (2023). Analisis optimasi pada algoritma long short-term memory untuk memprediksi harga saham. *Jurnal Media Informasi Budidarma*, 7(1), 575. <https://doi.org/10.30865/mib.v7i1.5421>
- Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654–669. <https://doi.org/10.1016/j.ejor.2017.11.054>





- Gudelek, M. U., Boluk, S. A., & Ozbayoglu, A. M. (2017). A deep learning based stock trading model with 2-D CNN trend detection. In *2017 IEEE Symposium Series on Computational Intelligence (SSCI)* (pp. 1–8). <https://doi.org/10.1109/SSCI.2017.8285188>
- Gunawan, E. K., & Wibowo, A. (2023). Stock price movement classification using ensembled model of long short-term memory (LSTM) and random forest (RF). *JOIV: International Journal of Informatics and Visualization*, 7(4), 2255. <https://doi.org/10.30630/joiv.7.4.01640>
- Indonesia Stock Exchange. (2024, November 13). *Stock index*. Retrieved from <https://www.idx.co.id/en/market-data/stocks-data/stock-index/>
- Kingma, D. P., & Ba, J. L. (2015). Adam: A method for stochastic optimization. In *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings* (pp. 1–15).
- Nabillah, & Ranggadara, I. (2020). Mean absolute percentage error untuk evaluasi hasil prediksi komoditas laut. *JOINS: Journal of Information Systems*, 5(2), 250–255. <https://doi.org/10.33633/joins.v5i2.3900>
- Pipin, S. J., Purba, R., & Kurniawan, H. (2023). Prediksi Saham Menggunakan Recurrent Neural Network (RNN-LSTM) Dengan Optimasi Adaptive Moment Estimation. *Journal of Computational System Informatics*, 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>
- Rosyd, A., Purnamasari, I., & Ali, I. (2024). Penerapan metode long short-term memory (LSTM) dalam memprediksi harga saham PT Bank Central Asia. *JATI: Jurnal Mahasiswa Teknik Informatika*, 8(1), 501–506. <https://doi.org/10.36040/jati.v8i1.8440>
- Siami-Namini, S., Tavakoli, N., & Siami Namin, A. (2018). A comparison of ARIMA and LSTM in forecasting time series. In *Proceedings - 17th IEEE International Conference on Machine Learning and Applications (ICMLA)* (pp. 1394–1401). <https://doi.org/10.1109/ICMLA.2018.00227>
- Siswanto, J., Manongga, D., Sembiring, I., & Wijono, S. (2024). Deep learning based LSTM model for predicting the number of passengers for public transport bus operators. *Journal of Online Informatics*, 9(1), 18–28. <https://doi.org/10.15575/join.v9i1.1245>
- Wathani, M. N., Kusriani, K., & Kusnawi, K. (2023). Prediksi tren pergerakan harga saham PT Bank Central Asia Tbk, dengan menggunakan algoritma long short-term memory (LSTM). *Infotek: Jurnal Informatika dan Teknologi*, 6(2), 502–512. <https://doi.org/10.29408/jit.v6i2.19824>
- Zhao, Y. (2023). Stock prediction based on LSTM neural network. *Highlights in Business, Economics and Management*, 3, 19–23.

