Indonesian Journal of Multidisciplinary on Social and Technology
Homepage: https://journal.ilmudata.co.id/index.php/ijmst
Vol. 5 No. 1 (2026) pp: 1236-1246
P-ISSN: 2986-6790, e-ISSN: 2986-6782

Perbandingan Akurasi Algoritma *Long Short Term Memory* dan *Transformer* Peramalan Harga Saham Volatilitas Tinggi

Arief Rahman, Yulian Ansori*, Febriyanti Darni, Czidni Sika Azkia
Informatika, Fakultas Teknik, Universitas Sultan Ageng Tirtayasa
arief.rahman@untirta.ac.id, yulian.ansori@untirta.ac.id, febriyanti.darnis@untirta.ac.id, czidni.sika@untirta.ac.id

Abstrak

Penelitian membandingkan akurasi algoritma Long Short-Term Memory (LSTM) dan Transformer dalam meramalkan harga saham dengan volatilitas tinggi, khususnya saham PT Paragon Karya Perkasa Tbk (PKPK). Data yang digunakan merupakan harga penutupan (close price) saham PKPK dari Yahoo Finance periode 23 September 2021 hingga 30 September 2026 sebanyak 1.024 data. Data melalui tahap normalisasi min-max, kemudian dibagi menjadi data latih dan data uji untuk dilatih menggunakan model LSTM dan Transformer. Evaluasi kinerja model dilakukan menggunakan metrik Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE). Hasil penelitian menunjukkan bahwa model LSTM terbaik diperoleh dengan konfigurasi 150 hidden layer, dropout 0,01, dan 100 epoch, menghasilkan akurasi 96,99%. Sementara itu, model Transformer terbaik diperoleh dengan self-attention mechanism 10, multi-head attention 100, dan 5 hidden layer, dengan akurasi 95,69%. Pada pengujian peramalan lima hari ke depan, Transformer menghasilkan akurasi 92,84%, sedikit lebih tinggi dibandingkan LSTM yang mencapai 92,79%. Temuan ini menunjukkan bahwa Transformer lebih baik dalam meramalkan harga saham dengan volatilitas tinggi pada periode validasi, meskipun LSTM memiliki akurasi pelatihan yang lebih tinggi. Namun, kedua model mengalami penurunan performa ketika harga saham mencapai all-time high, sehingga diperlukan pengembangan model yang lebih adaptif terhadap perubahan harga ekstrem, seperti penambahan sentimen analisis.

Kata kunci: LSTM, Transformer, Harga Saham, Volitalitas Tinggi

Abstract

This study compares the accuracy of Long Short-Term Memory (LSTM) and Transformer algorithms in forecasting highly volatile stock prices, particularly the shares of PT Paragon Karya Perkasa Tbk (PKPK). The dataset consists of 1,024 closing price observations obtained from Yahoo Finance, covering the period from September 23, 2021, to September 30, 2026. The data were preprocessed using min-max normalization and subsequently divided into training and testing datasets for developing the LSTM and Transformer models. Model performance was evaluated using Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and Mean Absolute Percentage Error (MAPE). The results indicate that the best LSTM model, configured with a hidden-layer size of 150, a dropout rate of 0.01, and 100 epochs, achieved an accuracy of 96.99%. Meanwhile, the optimal Transformer model, configured with 10 self-attention mechanisms, 100 multi-head attention units, and five hidden layers, achieved an accuracy of 95.69%. In the five-day forecasting evaluation, the Transformer demonstrated an accuracy of 92.84%, slightly outperforming the LSTM model, which achieved 92.79%. These findings suggest that the Transformer provides better forecasting performance for highly volatile stock prices during the validation period, although LSTM demonstrates higher training accuracy. However, both models experienced performance degradation when stock prices reached all-time highs. Therefore, further development of more adaptive forecasting models is necessary, particularly through the integration of sentiment analysis to improve predictions under extreme market fluctuations.

Keywords: LSTM; Transformer; Stock Prices; High Volatility

1. Pendahuluan

Dewasa ini pasar saham merupakan salah satu instrumen dalam sistem keuangan modern yang dapat berfungsi memobilisasi modal dan menjadi indikator kondisi ekonomi dari suatu negara. Pergerakan harga saham dipengaruhi oleh banyak faktor, mulai dari kinerja fundamental perusahaan, kebijakan moneter, kondisi geopolitik, hingga sentimen dari investor (Xu dan Zhao, 2022), untuk itu, kemampuan memperkirakan arah dan besaran harga saham menjadi kebutuhan yang sangat penting bagi para investor, manajer portofolio, dan regulator dalam mengambil keputusan serta pengelolaan resiko keuangan.

Dalam meramlakan harga saham bukan perkara yang mudah. Deret waktu keuangan memiliki karakteristik dan perilaku nonlinear. Salah satu yang menjadi tantangan adalah saham dengan volatilitas tinggi, dengan fluktuasi harga yang tajam dan tidak menentu membuat pola historis semakin sulit untuk diramalkan. Beberapa model dari statistik yang konvensional terkadang tidak mampu untuk meramalkannya juga.

Keterbatasan tersebut dapat mendorong untuk pemanfaatan *deep learning*, yang mampu mempelajari pola nonlinear dan dependensi temporal secara otomatis dari data. Dari sekian banyak *deep learning*, arsitektur yang paling banyak digunakan adalah *Long Short-Term Memory* (LSTM), jaringan saraf berulang yang dirancang dengan mekanisme gerbang untuk mengatasi masalah *vanishing gradient* dan menangkap ketergantungan jangka panjang (Hochreiter dan Schmidhuber, 1997), beberapa penelitian menghasilkan bahwa peramalan dan prediksi pergerakan pasar saham dapat diprediksi dengan baik (Bhandari et al., 2022; Bathla et al., 2023; Fischer dan Krauss, 2018; Sezer et al., 2019; Ozbayoglu et al., 2020; Jiang 2021)

Dalam perkembangan yang terbaru, arsitektur *transformer* yang berbasis mekanisme *self-attention* yang diperkenalkan oleh (Vaswani et al, 2017), yang dimulai di adaptasi untuk peramalan deret waktu. Berbeda dengan LSTM yang memproses data secara sekeunsial, *Transfomer* memproses seluruh urutan secara paralel dan menimbang kontribusi setiap titik waktu secara langsung (Liam dan Zohren, 2021). Berbagai varian *Transformer* telah dikembangkan untuk deret waktu (Wen et al., 2023; Zhou et al., 2021., Wu et al., 2021; Lim et al., 2021; Nie et al., 2023), dalam beberapa penelitian efektivitas *Transformer* masih dalam perdebatan. Pada suatu penelitian, bahwa model linear sederhana dapat mengungguli beberapa *Transformer* pada tugas tertentu, sehingga keunggulan dari arsitektur ini tidak dapat diasumsikan lebih baik secara umum (Zeng et al., 2023).

Untuk itu ada kesenjangan penelitian, yaitu perbandingan LSTM dan *Transfomer* untuk memprediksi nilai saham, sudah banyak penelitian yang menyatakan bahwa LSTM mampu memprediksi harga saham dengan baik (Zhang et al., 2022; Ding et al., 2020; Kim dan Won, 2018). Untuk itu pada penelitian ini, peneliti akan melakukan penelitian dengan saham dengan volatilitas yang tinggi, saham dengan volatilitas tinggi adalah kondisi ketika harga saham bergerak naik dan turun secara drastis, cepat dan dalam rentang yang lebar dalam waktu yang singkat (TradingView, 2026). Salah satu saham dengan volatilitas yang tinggi adalah PT Paragon Karya Perkasa Tbk (kode:PKPK) (Yahoo Finance, 2026), PKPK merupakan perusahaan yang bergerak di bidang jasa konstruksi penunjang minyak dan gas di Indonesia. Berdasarkan data dari TradingView, saham ini tergolong memiliki volatilitas yang tinggi. Dari harga yang berfluktuasi tinggi beberapa kali Bursa Efek Indonesia menghentikan sementara perdagangan saham ini, antara lain 4 Oktober 2021, 23 September 2024.

Berdasarkan hal tersebut, penelitian ini akan membandingkan akurasi algoritma LSTM dan Transformer dalam meramalkan harga saham dengan volatilitas yang tinggi. Penelitian ini menggunakan Root Means Square Error (RMSE), Maen Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), untuk evaluasi matriks akurasi. Penelitian ini juga membandingkan dari masing-masing algoritma dengan model terbaik untuk memprediksi harga saham PKPK 5 hari ke depan.

2. Metode Penelitian

2.1. Jenis dan Sumber Data

Penelitian ini data yang dikumpulkan berasal dari yahoo finance, data yang menjadi bahan penelitian adalah harga nilai saham PT Paragon Karya Perkasa Tbk (kode:PKPK), dari tanggal 23 September 2021 sampai tanggal 30 September 2026. Dengan jumlah 1204 data. Tabel 1 merupakan contoh dari harga saham PKPK.

Tabel 1. Contoh Harga Saham

Date	*Close*	*High*	*Low*	*Open*	*Volume*
9/23/2021	99	112	85	86	500842200
9/24/2021	108	121	96	100	455673500
9/27/2021	145	145	108	109	575062900

DOI: https://doi.org/10.69693/ijmst.v5i1.14725
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

9/28/2021	152	191	141	157	670366600
9/29/2021	152	152	152	152	0
9/24/2026	5500	5700	5000	5175	5965300
9/25/2026	5575	6050	5575	5725	5734900
9/28/2026	5900	6100	5400	5450	5197000
9/29/2026	6150	6350	5950	5950	3962400
9/30/2026	6025	6325	6025	6150	2667400

Tabel 1 menunjukan data harga saham, pada penelitian ini harga yang dipilih untuk mengukur akurasinya adalah data *close*, *close price* adalah harga dari transaksi terakhir suatu saham sebelum pasar ditutup, *close price* merupakan harga yang sering kali dianggap sebagai valuasi yang paling akurat dari suatu saham (Bhandari et al., 2022), *close price* bukanlah angka sembarangan, *close price* adalah hasil dari ”pertarungan” antara kekuatan permintaan (*buyer*) dan penawaran (*seller*) sepanjang hari penjualan, yang akhirnya menemui titik kesepakatan di detik-detik penutupan pasar inilah salah satu sebab banyak dari *trader* dan *investor* menunggu *close price* untuk mengonfirmasi arah pergerakan saham. Tabel 2 merupakan contoh harga saham yang menjadi data pada penelitian ini.

Tabel 2. Contoh Data Harga Saham

Date	*Close*
9/23/2021	99
9/24/2021	108
9/27/2021	145
9/28/2021	152
9/29/2021	152
9/24/2026	5500
9/25/2026	5575
9/28/2026	5900
9/29/2026	6150
9/30/2026	6025

2.2. Praproses

Data yang sebelumnya sudah didapatkan, lalu dilakukan proses normalisasi, tahapan ini penting dilakukan agar data yang ada sebelumnya tidak terlampau jauh jarak antara yang terbesar dan terkecilnya. Dengan tahapan praproses ini terbukti mampu meningkatkan akurasi yang didapatkan (Pranolo et al., 2024; Singh dan Singh et al., 2020). Metode yang sering digunakan untuk melakukan normalisasi adalah dengan menggunakan Persamaan 1. Tabel 3 adalah hasil normalisasi harga saham PKPK dengan menggunakan Persamaan 1.

$$x_i \text{ normalisasi} = (x_i - min\,(x)) / (max\,(x) - min\,(x)) \quad (1)$$

DOI: https://doi.org/10.69693/ijmst.v5i1.14725
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

Dimana :

x_i normalisasi : Hasil normalisasi terhadap data x ke-i
x_i : Data x ke-i
min (x) : Data minimum yang terdapat pada x
max (x) : Data maksimum yang terdapat pada data x

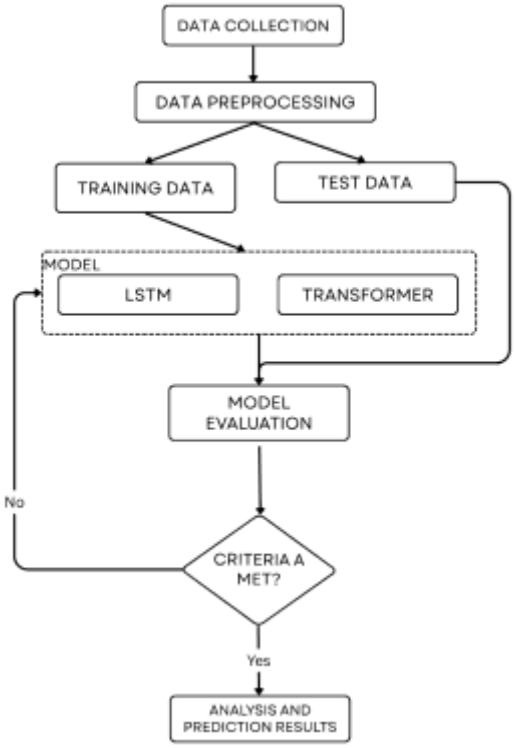
Tabel 3. Contoh Harga Saham Setelah Dinormalisasi

Date	*Close*
9/23/2021	0
9/24/2021	0.001487
9/27/2021	0.007602
9/28/2021	0.008759
9/29/2021	0.008759
9/24/2026	0.89258
9/25/2026	0.904974
9/28/2026	0.958685
9/29/2026	1
9/30/2026	0.979342

2.3. Diagram Alir Penelitian

Penelitian ini dilaksanakan melalui beberapa tahapan dengan diawali dengan pengumpulan data, berupa data saham PKPK. Data yang telah didapatkan dan dikumpulkan lalu melalui tahap praproses untuk memastikan kualitas dan kesiapan datanya. Normalisasi diperlukan agar skala antarvariabel dapat seragam. Selanjutnya, data hasil praproses tadi dibagi menjadi dua bagian, yaitu data latih dan data uji. Data latih kemudian dimasukkan kedalam tahap pemodelan dua arsitektur deep learning, yaitu LSTM dan Transformer, untuk dibandingkan kinerjanya dalam meramalkan harga saham. Hasil pelatihan kedua model di evaluasi menggunakan data uji dengan matriks kesalahan prediksi yang sudah sering digunakan, yaitu, RMSE, MAE dan MAPE, jika hasil evaluasi belum memenuhi apa yang diharapkan, maka prosesnya akan kembali lagi ke tahap pemodelan untuk dilakukan penyesuaian, seperti penyetelan hyperparameter atau perubahan dari konfigurasi arsitektur. Sebaliknya, apabila hasil evaluasi sudah sesuai, tahap terakhir adalah menganalisis dari hasil prediksi, yang akan mencakup perbandingan akurasi antara STM dan Transformer dalam memprediksi harga saham dengan volatilitas tinggi. Untuk lebih jelasnya dapat dilihat pada Gambar 1.

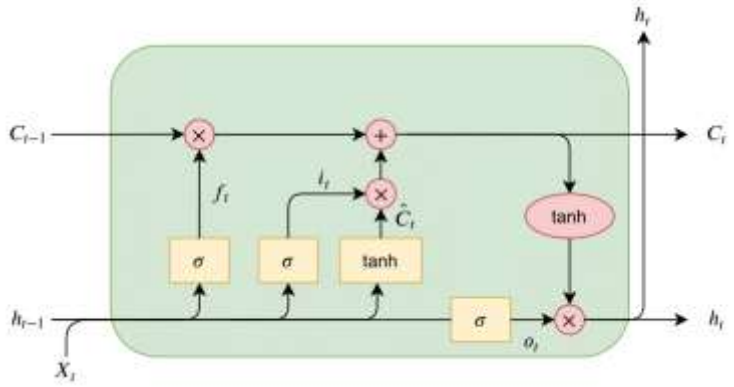
DOI: https://doi.org/10.69693/ijmst.v5i1.14725
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)



Gambar 1. Diagram Alur Penelitian

2.4. LSTM

Long Short-Term Memory (LSTM) adalah salah satu varian dari *Recurrent Neural Network* (RNN) yang umum dipakai untuk memprediksi data deret waktu (Hewamalage et al., 2021; Greff et al 2017). Pada dasarnya, RNN rentan mengalami masalah pada proses perambatan gradien, yaitu gradien dapat menghilang atau meledak sehingga akumulasi nilai hilang dan informasi menjadi kabur (Bengio et al., 1994). Untuk mengatasi masalah tersebut, LSTM dikembangkan sebagai solusinya. LSTM tersusun dari sejumlah sel memori yang menggantikan neuron pada lapisan tersembunyi RNN. Melalui struktur gerbang (*gates*), model ini mampu menyaring informasi yang masuk, sehingga informasi penting dapat dipertahankan dan diteruskan ke dalam sel memori (Hochreiter dan Schmidhuber, 1997). Arsitektur LSTM ditunjukkan pada Gambar 2.



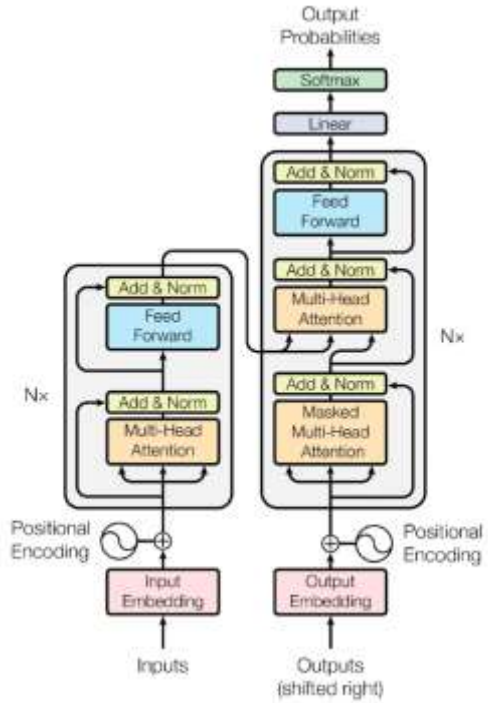
Gambar 2. Arsitektur LSTM

2.5. Transformer

Transformer adalah arsitektur *deep learning* yang dikemukakan oleh vaswani (Vaswani et al, 2017), Transformer ini awalnya digunakan untuk pemrosesan bahasa alami. Tidak seperti RNN dan LSTM yang mengolah data secara

DOI: https://doi.org/10.69693/ijmst.v5i1.14725
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

sekuensial, Transformer memproses seluruh urutan sekaligus melalui mekanisme *self-attention*. Mekanisme ini dapat menilai seberapa erat hubungan setiap elemen dengan elemen lainnya dalam urutan, sehingga ketergantungan jangka panjang dapat ditangkap tanpa dipengaruhi jarak antar posisi. Karena tidak bersifat rekuren, *Transformer* memerlukan *positional encoding* untuk menyisipkan informasi urutan waktu ke dalam data masukan. Secara umum, arsitekturnya terdiri dari *encoder* dan *decoder* yang masing-masing disusun oleh lapisan *multi-head attention* da *feed-forward network*, serta ditopang *residual connection* dan *layer normalization* agar pelatihan lebih stabil. Berkat keunggulan yang sudah dijelaskan tadi. *Transformer* kini semakin banyak digunakan untuk peramalan deret waktu, termasuk data harga saham. Arsitektur *Transformer* ditampilkan pada Gambar 3.



Gambar 3. Arsitektur Transformer

2.6. Pengujian Data

Pada penelitian ini pengujian data dilakukan dengan menggunakan *Root Means Square Error*, *Maen Absolute Error*, *Mean Absolute Percentage Error* (Rahman et al., 2022; Hodson 2022), metode-metode tersebut sudah sering digunakan untuk mengukur tingkat akurasi dari sebuah model. Pengujian data yang dilakukan pada penelitian ini adalah dengan melakukan perbandingan data yang sebelumnya sudah dipisahkan pada data testing, yaitu sebanyak. Persamaan RMSE MAE dan MAPE, dapat ditunjukkan pada Persamaan 2, Persamaan 3, dan Persamaan 4.

$$RMSE = \sqrt{\frac{\sum_{t=1}^{n}(X_t - F_t)^2}{n}} \quad (2)$$

$$MSE = \frac{\sum_{t=1}^{n}(X_t - F_t)^2}{n} \quad (3)$$

$$MAPE = \frac{\sum_{t=1}^{n}\left|\frac{X_t - F_t}{X_t}\right|}{n}\ x\ 100\% \quad (4)$$

Keterangan:

n= Jumlah pengamatan atau periode waktu.
X_t= Nilai aktual data periode t.
F_t= Nilai peramalan pada periode t.

DOI: https://doi.org/10.69693/ijmst.v5i1.14725
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

3. Hasil dan Pembahasan

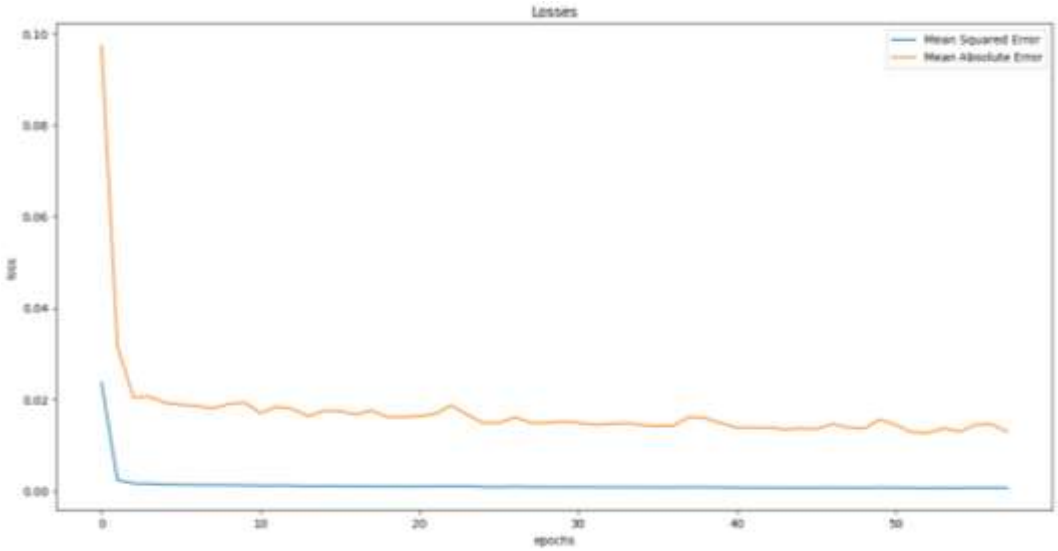
3.1. Evaluasi Model

Pada penelitian ini, data yang dikumpulkan sebanyak 1204 data dibagi menjadi 2, data latih sebanyak 80% (963 data), data uji sebanyak 20% (241 data), selanjutnya dilakukan *trail* dan *error* untuk menemukan model yang terbaik, untuk pemilihan model terbaik, peneliti melakukan 46 skenario untuk algoritma LSTM berupa jumlah *hidden layer* (50, 100, 150), *epoch* (50, 100, 150), dropout (0.01, 0.1, 0.2), dari ke 46 skenario, Tabel 4 merupakan 5 skenario dengan akurasi yang terbaik.

Tabel 4. 5 Model Terbaik LSTM

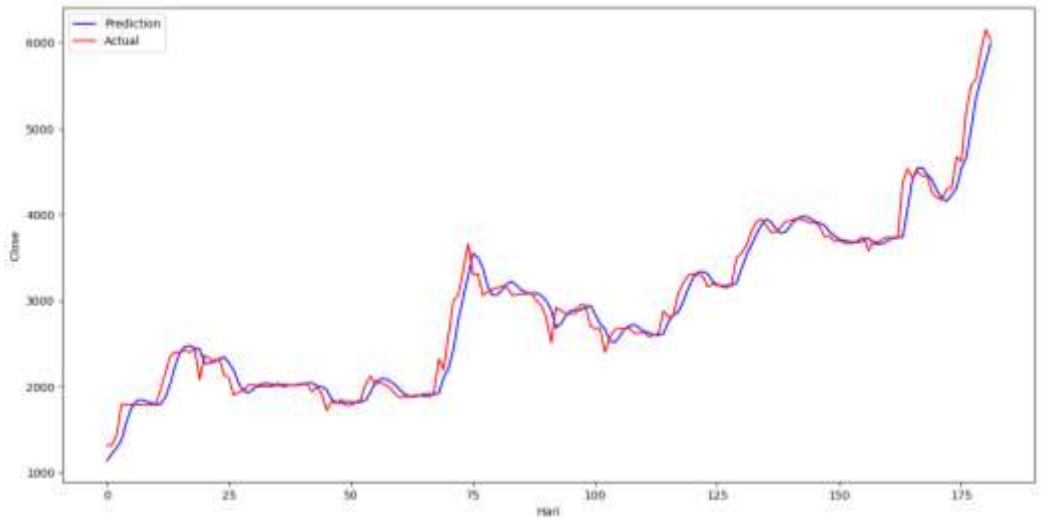
Hidden Layer	Drop out	epoch	Akurasi (%)	MSE	RMSE
50	0.01	150	95.56	42089	205
100	0.01	150	96.17	27461	165
150	0.01	50	95.18	41200	203
150	0.01	100	96.99	28337	168
150	0.01	150	95.56	28224	168

Setelah melakukan beberapa kali *trial* dan *error*, skenario dengan untuk algoritma LSTM menghasilkan akurasi yang tertinggi, dengan model jumlah *hidden layer* 150, *dropout* 0.01 dan jumlah *epoch* 100, dan akurasi yang didapatkan sebesar 96.99%, maka dari itu model tersebut dianggap menjadi model yang terbaik, dari Gambar 4, merupakan hasil pelatihan untuk MSE dan MAE, dari gambar tersebut proses pelatihan model berlangsung dengan baik, kedua *loss* tersebut mengalami penurunan yang stabil pada beberapa awal *epoch*. Setelah mendapatkan hasil MSE dan MAE yang baik, dilakukan proses perbandingan nilai prediksi dan aktual. Dari Gambar 5 bisa dilihat antara hasil prediksi dan aktual grafik untuk algoritma LSTM didapatkan hampir menyerupai satu dengan lainnya, dengan demikian algoritma LSTM berhasil belajar dengan baik dan tidak terjadi *overfitting* dalam proses pembelajarannya.



Gambar 4. Grafik MSE dan MAE Pelatihan LSTM

DOI: https://doi.org/10.69693/ijmst.v5i1.14725
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

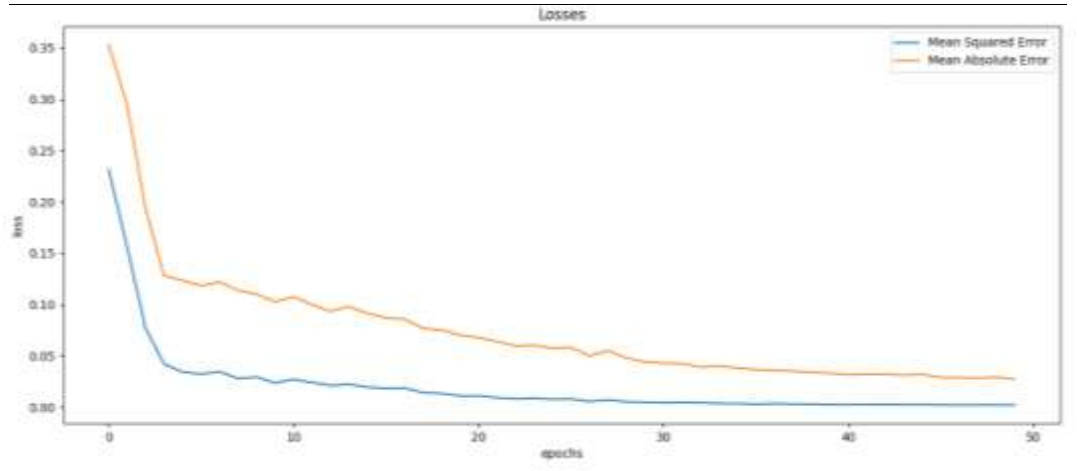


Gambar 5. Grafik Perbandingan Nilai Prediksi dan Aktual LSTM

Tabel merupakan 5 skenario terbaik untuk algoritma *Transformer*, pada penelitian ini terdapat 50 skenario yang dijalankan, dari 50 model tersebut, *multi-layer perceptron* berada di 50 unit, *multi-layer perceptron dropout* 0.1, dan *dropout* 0.1, pada penelitian ini juga peneliti melakukan perubahan nilai untuk masing-masing *multi-layer perceptron, multi-layer perceptron dropout*, dan *dropout* tetapi hasil yang terbaik tetap didapatkan dengan nilai yang sudah dijelaskan sebelumnya. model terbaik diambil dengan akurasi yang terbesar. Model yang terbaik adalah dengan *self-attention mechanism* 10, *multi-head attention* 100, *hidden layer* 5, dengan akurasi 95.69%.

Tabel 5. 5 Model Terbaik Transformer

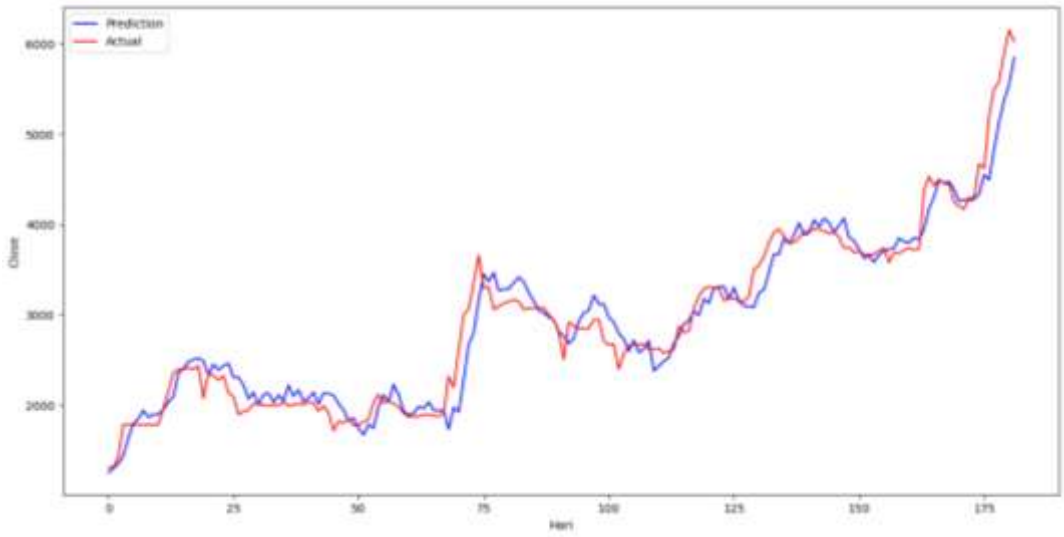
Self-Attention Mechanism	Multi-Head Attention	Hidden Layer	Akurasi (%)	MSE	RMSE
10	100	5	95.69	30666	175
10	100	30	94.77	25239	158
50	10	5	95.32	27526	166
50	50	5	95.06	30485	175
50	50	30	95.17	29441	172



Gambar 6. Grafik MSE dan MAE Pelatihan Transformer

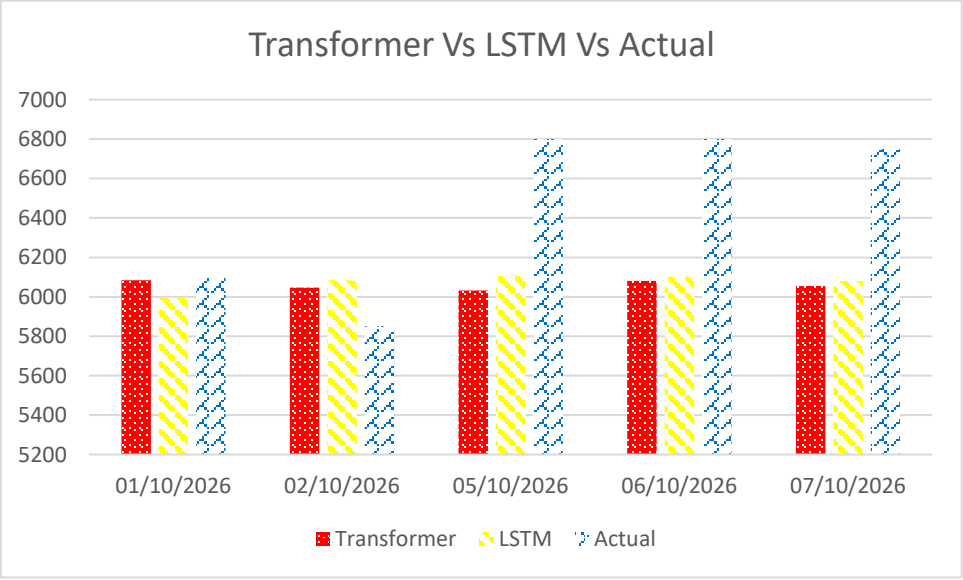
DOI: https://doi.org/10.69693/ijmst.v5i1.14725
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

Gambar 6 merupakan hasil pelatihan yang didapatkan dari model yang terbaik, dapat dilihat dari gambar tersebut MSE dan MAE mengalami loss penurunan yang stabil pada beberapa epoch awal. Pada Gambar 7 bisa dilihat grafik akurasi dan prediksi dari algoritma *Transformer* dengan model yang terbaik yang sudah didapatkan sebelumnya menghasilkan grafik yang baik. Dengan demikian algoritma Transformer juga mampu menghasilkan model yang baik untuk memprediksi nilai harga saham.



Gambar 7. Grafik Perbandingan Nilai Prediksi dan Aktual Transformer

Setelah masing-masing model terbaik dari algoritma LSTM dan Transformer didapatkan, dilakukan validasi dengan cara memprediksi 5 hari ke depan setelah tanggal terakhir data set, Gambar 8 merupakan harga saham yang dihasilkan dari masing-masing model terbaik algoritma Transformer dan LSTM yang dibandingkan dengan nilai aktual. Dari gambar tersebut didapatkan bahwa baik algoritma Transformer dan LSTM kurang mampu untuk memprediksi jika harga yang diprediksi *all time high*.



Gambar 8. Grafik Perbandingan Harga LSTM, Transformer dan Aktual

DOI: https://doi.org/10.69693/ijmst.v5i1.14725
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

Pada penelitian ini berlangsung saham PKPK ternyata didapatkan harga *all time high* bertepatan dengan harga yang akan diprediksi oleh masing-masing algoritma. Tabel 6 merupakan harga prediksi dari algoritma Transformer, LSTM dan aktual. Dari tabel tersebut didapatkan bahwa algoritma Transformer lebih baik dalam memprediksi harga saham yang bervolitalitas tinggi dibandingkan dengan algoritma LSTM walaupun dalam proses pembelajarannya algoritma LSTM lebih baik akurasinya dibandingkan dengan algoritma transformer

Tabel 6. Perbandingan Harga, MSE, RMSE dan MAPE, LSTM, Transformer dan Aktual,

Date	Transformer	LSTM	Actual
01/10/2026	6083.686523	5995.876	6100
02/10/2026	6047.022461	6083.526	5850
05/10/2026	6032.431152	6109.167	6800
06/10/2026	6080.376953	6102.023	6800
07/10/2026	6054.029785	6079.872	6750
MSE	326095.6	295774.1	
RMSE	571.0478	543.8512	
Akurasi	92.84%	92.79%	

4. Kesimpulan

Algoritma Transformer dan LSTM telah berhasil melakukan prediksi untuk harga saham PKPK, algoritma Transformer lebih baik untuk memprediksi harga saham dengan volatilitas tinggi dibandingkan dengan algoritma LSTM. Model terbaik yang didapatkan untuk algoritma Transformer adalah dengan model *self-attention mechanism* 10, *multi-head attention* 100, *hidden layer* 5, *multi-layer perceptron* 50 unit, *multi-layer perceptron dropout* 0.1, dan *dropout* 0.1 dengan akurasi yang didapatkan adalah 95.69%. sedangkan untuk algoritma LSTM model yang terbaik adalah jumlah *hidden layer* 150, *dropout* 0.01 dan jumlah *epoch* 100, dan akurasi yang didapatkan sebesar 96.99% dari akurasi yang didapatkan model yang terbaik. Algoritma yang memiliki akurasi yang tertinggi adalah LSTM, dari masing-masing model terbaik tersebut selanjutnya dilakukan validasi dengan memprediksi harga saham 5 hari ke depan, didapatkan hasil yang terbaik dengan akurasi yang tertinggi adalah algoritma Transformer dengan akurasi 92.84% dibandingkan dengan algoritma LSTM 92.79%, algoritma Transformer menjadi yang terbaik untuk memprediksi 5 hari ke depan walaupun perbedaannya relatif kecil. Hasil akurasi yang didapatkan untuk memvalidasi 5 hari ke depan mengalami penurunan performa yang signifikan ketika mendapatkan harga saham mencapai *all time high*, yang artinya masing-masing algoritma belum mampu memprediksi dengan baik jika harga saham yang diprediksi ke depannya mendapatkan nilai *all time high*. sehingga diperlukan pengembangan model yang lebih adaptif terhadap perubahan harga ekstrem, seperti penambahan sentimen analisis (Jiang et al., 2021).

Reference

1. Y. Xu and J. Zhao, “Can sentiments on macroeconomic news explain stock returns? Evidence from social network data,” Int. J. Finance Econ., vol. 27, no. 2, pp. 2073–2088, 2022.
2. S. Hochreiter and J. Schmidhuber, “Long short-term memory,” Neural Comput., vol. 9, no. 8, pp. 1735–1780, 1997, doi: 10.1162/neco.1997.9.8.1735.
3. H. N. Bhandari, B. Rimal, N. R. Pokhrel, R. Rimal, K. R. Dahal, and R. K. C. Khatri, “Predicting stock market index using LSTM,” Mach. Learn. Appl., vol. 9, Art. no. 100320, 2022, doi: 10.1016/j.mlwa.2022.100320.
4. 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.
5. T. Fischer and C. Krauss, “Deep learning with long short-term memory networks for financial market predictions,” Eur. J. Oper. Res., vol. 270, no. 2, pp. 654–669, 2018, doi: 10.1016/j.ejor.2017.11.054.
6. O. B. Sezer, M. U. Gudelek, and A. M. Ozbayoglu, “Financial time series forecasting with deep learning: A systematic literature review: 2005–2019,” Appl. Soft Comput., vol. 90, Art. no. 106181, 2020, doi: 10.1016/j.asoc.2020.106181.
7. A. M. Ozbayoglu, M. U. Gudelek, and O. B. Sezer, “Deep learning for financial applications: A survey,” Appl. Soft Comput., vol. 93, Art. no. 106384, 2020, doi: 10.1016/j.asoc.2020.106384.

DOI: https://doi.org/10.69693/ijmst.v5i1.14725
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

8. W. Jiang, "Applications of deep learning in stock market prediction: Recent progress," Expert Syst. Appl., vol. 184, Art. no. 115537, 2021, doi: 10.1016/j.eswa.2021.115537.
9. A. Vaswani et al., "Attention is all you need," in Proc. Adv. Neural Inf. Process. Syst. (NIPS), vol. 30, 2017, pp. 5998–6008.
10. B. Lim and S. Zohren, "Time-series forecasting with deep learning: A survey," Philos. Trans. R. Soc. A, vol. 379, no. 2194, Art. no. 20200209, 2021, doi: 10.1098/rsta.2020.0209.
11. Q. Wen et al., "Transformers in time series: A survey," in Proc. 32nd Int. Joint Conf. Artif. Intell. (IJCAI), 2023, pp. 6778–6786, doi: 10.24963/ijcai.2023/759.
12. H. Zhou et al., "Informer: Beyond efficient transformer for long sequence time-series forecasting," in Proc. AAAI Conf. Artif. Intell., 2021, vol. 35, no. 12, pp. 11106–11115, doi: 10.1609/aaai.v35i12.17325.
13. H. Wu, J. Xu, J. Wang, and M. Long, "Autoformer: Decomposition transformers with auto-correlation for long-term series forecasting," in Proc. Adv. Neural Inf. Process. Syst. (NeurIPS), vol. 34, 2021, pp. 22419–22430.
14. B. Lim, S. Ö. Arık, N. Loeff, and T. Pfister, "Temporal Fusion Transformers for interpretable multi-horizon time series forecasting," Int. J. Forecast., vol. 37, no. 4, pp. 1748–1764, 2021, doi: 10.1016/j.ijforecast.2021.03.012.
15. Y. Nie, N. H. Nguyen, P. Sinthong, and J. Kalagnanam, "A time series is worth 64 words: Long-term forecasting with Transformers," in Proc. Int. Conf. Learn. Represent. (ICLR), 2023.
16. A. Zeng, M. Chen, L. Zhang, and Q. Xu, "Are Transformers effective for time series forecasting?," in Proc. AAAI Conf. Artif. Intell., 2023, vol. 37, no. 9, pp. 11121–11128, doi: 10.1609/aaai.v37i9.26317.
17. Q. Zhang, C. Qin, Y. Zhang, F. Bao, C. Zhang, and P. Liu, "Transformer-based attention network for stock movement prediction," Expert Syst. Appl., vol. 202, Art. no. 117239, 2022, doi: 10.1016/j.eswa.2022.117239.
18. Q. Ding, S. Wu, H. Sun, J. Guo, and J. Guo, "Hierarchical multi-scale Gaussian Transformer for stock movement prediction," in Proc. 29th Int. Joint Conf. Artif. Intell. (IJCAI), 2020, pp. 4640–4646, doi: 10.24963/ijcai.2020/640.
19. H. Y. Kim and C. H. Won, "Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple GARCH-type models," Expert Syst. Appl., vol. 103, pp. 25–37, 2018, doi: 10.1016/j.eswa.2018.03.002.
20. S.-H. Poon and C. W. J. Granger, "Forecasting volatility in financial markets: A review," J. Econ. Lit., vol. 41, no. 2, pp. 478–539, 2003.
21. TradingView, "Most volatile Indonesian stocks," TradingView. Accessed: Oct. 1, 2026. [Online]. Available: https://id.tradingview.com/markets/stocks-indonesia/market-movers-most-volatile/
22. Yahoo Finance, "PT Paragon Karya Perkasa Tbk (PKPK.JK) stock price, news, quote & history," Yahoo Finance. Accessed: Oct. 1, 2026. [Online]. Available: https://finance.yahoo.com/quote/PKPK.JK/
23. A. Pranolo et al., "Enhanced multivariate time series analysis using LSTM: A comparative study of min-max and z-score normalization techniques," ILKOM J. Ilm., vol. 16, no. 2, pp. 210–220, 2024, doi: 10.33096/ilkom.v16i2.2333.210-220.
24. D. Singh and B. Singh, "Investigating the impact of data normalization on classification performance," Appl. Soft Comput., vol. 97, Art. no. 105524, 2020, doi: 10.1016/j.asoc.2019.105524.
25. H. Hewamalage, C. Bergmeir, and K. Bandara, "Recurrent neural networks for time series forecasting: Current status and future directions," Int. J. Forecast., vol. 37, no. 1, pp. 388–427, 2021, doi: 10.1016/j.ijforecast.2020.06.008.
26. K. Greff, R. K. Srivastava, J. Koutník, B. R. Steunebrink, and J. Schmidhuber, "LSTM: A search space odyssey," IEEE Trans. Neural Netw. Learn. Syst., vol. 28, no. 10, pp. 2222–2232, 2017, doi: 10.1109/TNNLS.2016.2582924.
27. Y. Bengio, P. Simard, and P. Frasconi, "Learning long-term dependencies with gradient descent is difficult," IEEE Trans. Neural Netw., vol. 5, no. 2, pp. 157–166, 1994, doi: 10.1109/72.279181.
28. A. Rahman, S. Wahjuni, and K. Priandana, "The development of hydroponic nutrient solutions control using fuzzy and BPNN for celery plant," Int. J. Adv. Sci. Eng. Inf. Technol., vol. 12, pp. 431–436, 2022.
29. T. O. Hodson, "Root mean square error (RMSE) or mean absolute error (MAE): When to use them or not," Geosci. Model Dev., vol. 15, no. 14, pp. 5481–5487, 2022, doi: 10.5194/gmd-15-5481-2022.
30. N. Jing, Z. Wu, and H. Wang, "A hybrid model integrating deep learning with investor sentiment analysis for stock price prediction," Expert Syst. Appl., vol. 178, Art. no. 115019, 2021, doi: 10.1016/j.eswa.2021.115019.

DOI: https://doi.org/10.69693/ijmst.v5i1.14725
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)