

Komparasi Model Transformer dan LSTM dalam Prediksi Harga Saham *Blue Chip* di BEI

Ricky Andre Ferdiansyah^{*1} dan Ema Utami²

1-2 Universitas AMIKOM Yogyakarta

Jl. Ring Road Utara, Condongcatur, Sleman, Yogyakarta 55283

ricky.ferdiansyah@students.amikom.ac.id; ema.u@amikom.ac.id

Abstrak

Kompleksitas prediksi harga saham berakar dari sifat data runtun waktu keuangan yang fluktuatif dan non-linear. Studi ini menyelidiki bagaimana *Long Short-Term Memory* (LSTM) dan *Transformer* merespons variasi panjang sekuens historis dalam meramalkan harga penutupan saham PT Bank Central Asia Tbk (BBCA), saham *blue-chip* dengan kapitalisasi pasar terbesar di Bursa Efek Indonesia. Data historis OHLCV dikumpulkan dari Yahoo Finance mencakup periode Januari 2018 hingga Desember 2024. Panjang sekuens divariasikan pada 3, 5, 7, 10, dan 14 hari. Evaluasi menggunakan MAE, RMSE, MAPE, serta Uji Diebold-Mariano untuk mengonfirmasi signifikansi statistik perbedaan kinerja. Hasil eksperimen menunjukkan LSTM mencapai kinerja terbaik pada panjang sekuens 14 hari dengan MAPE 1,23%, sementara *Transformer* mencapai titik optimal pada panjang sekuens 3 hari dengan MAPE 1,40%. *Transformer* mengalami penurunan performa yang tajam seiring bertambahnya panjang sekuens, mencapai MAPE 5,26% pada 14 hari. Sebaliknya, LSTM menunjukkan performa yang stabil di seluruh variasi panjang sekuens. Perbedaan ini berkaitan dengan cara kerja masing-masing model dalam mengolah data historis. LSTM yang membaca data secara bertahap cenderung dapat mengumpulkan informasi dari sekuens panjang, sedangkan *Transformer* yang membandingkan semua data sekaligus justru tidak menunjukkan hal yang sama saat jumlah data bertambah. Temuan ini menegaskan bahwa pada dataset finansial dengan ukuran terbatas, pemilihan model dan panjang data historis harus disesuaikan secara hati-hati karena tidak semua arsitektur diuntungkan oleh penambahan data.

Kata Kunci Deep Learning, Transformer, LSTM, Prediksi Saham, Bursa Efek Indonesia

Digital Object Identifier 10.36802/jnanaloka.2026.v7-no1-51-59

1 Pendahuluan

Pasar saham Indonesia, terutama saham-saham *blue-chip* yang tercatat di Bursa Efek Indonesia (BEI), telah menjadi salah satu instrumen investasi paling populer bagi masyarakat. Saham-saham ini dikenal karena potensi keuntungannya yang tinggi dan likuiditas yang baik. Namun di saat yang sama, volatilitas harga yang tinggi seringkali menciptakan ketidakpastian bagi investor ketika mereka perlu mengambil keputusan [1]. Situasi menjadi semakin rumit ketika faktor-faktor eksternal ikut berperan, seperti kondisi ekonomi global, kebijakan pemerintah, dan sentimen pasar, yang semuanya sulit diprediksi secara akurat [2]. Inilah mengapa prediksi harga saham terus menjadi topik penting baik di bidang keuangan maupun teknologi.

Banyak penelitian telah dilakukan mengenai prediksi harga saham menggunakan metode statistik dan kecerdasan buatan. Model *Long Short-Term Memory* (LSTM) telah banyak digunakan untuk tugas ini karena kemampuannya yang baik dalam menangkap pola-pola

* Corresponding author.



kompleks dalam data runtun waktu [3]. Belakangan ini, model *Transformer*, yang awalnya dibangun untuk tugas pemrosesan bahasa alami, mulai diadaptasi untuk prediksi runtun waktu, termasuk harga saham, berkat keunggulannya dalam menangani ketergantungan jangka panjang [4]. Studi lain menunjukkan bahwa model *deep learning* umumnya memberikan hasil prediksi yang lebih baik daripada metode tradisional [5]. Namun, akurasi prediksi ini sangat bergantung pada pemilihan model yang tepat dan parameter yang sesuai.

Meskipun banyak studi telah membandingkan berbagai model prediksi, karya yang secara spesifik menempatkan *Transformer* dan LSTM berdampingan untuk saham *blue-chip* di BEI masih sulit ditemukan. Sebagian besar penelitian yang tersedia berfokus pada satu model saja atau membandingkan *deep learning* dengan pendekatan konvensional seperti ARIMA [6,7]. Selain itu, belum ada studi yang secara khusus meneliti saham BBCA menggunakan pengaturan multivariat OHLCV.

Kesenjangan inilah yang coba diisi oleh penelitian ini. Studi ini bertujuan membandingkan model *Transformer* dan LSTM dalam memprediksi harga penutupan BBCA menggunakan pendekatan multivariat OHLCV, sekaligus melihat seberapa sensitif kedua model terhadap perubahan panjang sekuens. Temuan dari studi ini diharapkan dapat memberikan gambaran awal mengenai pemilihan model dan konfigurasi yang lebih sesuai untuk data pasar Indonesia, serta menjadi referensi bagi peneliti dan praktisi yang tertarik pada penerapan *deep learning* untuk prediksi saham di BEI.

2 Metodologi

2.1 Data

Studi ini menggunakan data historis harga saham PT Bank Central Asia Tbk (BBCA) yang diperoleh dari Yahoo Finance melalui API *yfinance*. Dataset mencakup periode dari 1 Januari 2018 hingga 31 Desember 2024, yang terdiri dari 1730 hari perdagangan. Lima fitur digunakan dalam penelitian ini: *Open*, *High*, *Low*, *Close*, dan *Volume* (OHLCV).

BBCA dipilih sebagai objek studi dengan beberapa pertimbangan. Pertama, BBCA merupakan saham dengan kapitalisasi pasar terbesar di BEI dan termasuk dalam kategori *blue-chip* dengan likuiditas tinggi, sehingga data perdagangannya tersedia secara lengkap dan konsisten. Kedua, pergerakan harga BBCA menunjukkan karakteristik non-stasioner dengan tren naik jangka panjang yang diselingi periode koreksi, mencerminkan dinamika khas pasar berkembang yang cenderung lebih volatil dibandingkan pasar maju. Karakteristik ini relevan dengan tujuan studi karena menguji bagaimana model merespons data yang mengandung fluktuasi dan derau cukup tinggi.

Dataset dibagi secara kronologis menjadi tiga subset untuk menjaga struktur temporal data runtun waktu. Data pelatihan mencakup periode dari Januari 2018 hingga Desember 2022, data validasi mencakup Januari 2023 hingga Desember 2023, dan data pengujian mencakup Januari 2024 hingga Desember 2024. Strategi pembagian ini menghasilkan 1254 sampel pelatihan, 239 sampel validasi, dan 237 sampel pengujian.

2.2 Pra-pemrosesan Data

Pra-pemrosesan data terdiri dari tahapan pemilihan fitur dan normalisasi. Fitur OHLCV dipilih karena memberikan informasi komprehensif mengenai pergerakan harga saham dan aktivitas perdagangan. Setelah pemilihan fitur, normalisasi *MinMaxScaler* diterapkan untuk mentransformasi semua nilai fitur ke dalam rentang 0 hingga 1. Normalisasi membantu

mengurangi perbedaan skala antar fitur dan meningkatkan stabilitas pelatihan selama optimasi *deep learning*.

Data yang telah dinormalisasi kemudian ditransformasi menjadi sampel runtun waktu sekuensial menggunakan pendekatan *sliding window*. Untuk menyelidiki pengaruh panjang sekuens terhadap kinerja peramalan, variasi panjang sekuens 3, 5, 7, 10, dan 14 hari dievaluasi pada kedua model.

2.3 Arsitektur Model LSTM

Model LSTM yang digunakan dalam studi ini terdiri dari satu lapisan tersembunyi LSTM dengan 50 unit yang diikuti oleh lapisan *output dense*. Konfigurasi model diadaptasi dari Fischer dan Krauss [8] dengan beberapa modifikasi untuk menyesuaikan dengan tugas regresi dalam peramalan harga saham. Jumlah neuron ditingkatkan menjadi 50 untuk memberikan kapasitas lebih dalam memprediksi nilai kontinu. *Optimizer* Adam dipilih karena lebih umum digunakan dalam tugas regresi, dan *loss function* MSE menggantikan *cross-entropy*. Parameter lain seperti *batch size* 32 dan maksimum *epoch* 100 dipilih berdasarkan praktik umum dalam penelitian serupa.

Early stopping dengan *patience* 10 *epoch* diterapkan untuk mencegah *overfitting*. Proses pelatihan dihentikan ketika kerugian validasi gagal membaik selama 10 *epoch* berturut-turut.

2.4 Arsitektur Model Transformer

Model *Transformer* yang digunakan dalam studi ini mengadopsi arsitektur *encoder-only* yang terinspirasi oleh Vaswani et al. [9]. Model terdiri dari enam blok *Transformer encoder* dengan delapan *attention head* dan dimensi ukuran *head* 512. Dimensi jaringan *feed-forward* diatur ke 2048. *Positional encoding* sinusoidal diterapkan untuk mempertahankan informasi sekuensial dalam data masukan.

Model *Transformer* menggunakan *optimizer* Adam dengan *learning rate* 5×10^{-5} . MSE digunakan sebagai *loss function*, sementara tingkat *dropout* 0,1 dan 0,2 diterapkan masing-masing untuk lapisan *attention* dan *dense*. Serupa dengan model LSTM, pelatihan dilakukan menggunakan ukuran *batch* 32 dan maksimum 100 *epoch*.

Untuk meningkatkan stabilitas pelatihan, diterapkan dua mekanisme tambahan. Pertama, *gradient clipping* dengan nilai maksimum 1,0 diterapkan untuk mencegah gradien membesar secara tidak terkendali atau *exploding gradient* yang dapat mengganggu proses pembelajaran. Kedua, *learning rate reduction* dengan faktor 0,5 diterapkan jika *validation loss* tidak membaik selama 5 *epoch* berturut-turut. Mekanisme ini mengurangi *learning rate* sebesar setengahnya untuk membantu model keluar dari area stagnan atau *plateau* dan mencapai konvergensi yang lebih baik.

2.5 Metrik Evaluasi

Kinerja model dievaluasi menggunakan MAE, RMSE, dan MAPE. MAE mengukur rata-rata kesalahan prediksi absolut, RMSE menekankan kesalahan prediksi yang lebih besar, dan MAPE mengukur kesalahan prediksi dalam bentuk persentase, memungkinkan interpretasi yang lebih mudah di berbagai skala harga.

Formulasi matematis dari metrik evaluasi diberikan sebagai berikut.

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

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

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (3)$$

Dengan y_i sebagai nilai aktual pada pengamatan ke- i , \hat{y}_i sebagai nilai prediksi pada pengamatan ke- i , dan n sebagai jumlah data pengamatan.

Selain metrik evaluasi standar, Uji Diebold-Mariano (DM) digunakan untuk memeriksa apakah perbedaan kinerja antara model LSTM dan *Transformer* signifikan secara statistik. Hipotesis nol dari Uji DM menyatakan bahwa kedua model memiliki akurasi prediktif yang sama. Tingkat signifikansi $\alpha = 0,05$ digunakan dalam studi ini. Jika nilai p yang dihasilkan kurang dari 0,05, hipotesis nol ditolak, yang menunjukkan perbedaan yang signifikan secara statistik antara kedua model peramalan.

$$\text{DM} = \frac{\bar{d}}{\sqrt{\text{Var}(\bar{d})}} \quad (4)$$

dengan \bar{d} adalah rata-rata selisih kesalahan dan $\text{Var}(\bar{d})$ adalah varians dari rata-rata selisih.

3 Hasil dan Pembahasan

3.1 Hasil Eksperimen Panjang Sekuens

Eksperimen dilakukan menggunakan panjang sekuens 3, 5, 7, 10, dan 14 hari. Setiap panjang sekuens dievaluasi pada model LSTM dan *Transformer*. Kinerja model dinilai pada dataset pengujian 2024 menggunakan MAE, RMSE, dan MAPE. Signifikansi statistik antara kinerja model dievaluasi menggunakan Uji Diebold-Mariano (DM) dengan tingkat signifikansi $\alpha = 0,05$.

■ **Tabel 1** Hasil eksperimen panjang sekuens

Panjang Sekuens (hari)	LSTM			Transformer			DM Test	
	MAE (Rp)	RMSE (Rp)	MAPE (%)	MAE (Rp)	RMSE (Rp)	MAPE (%)	p-value	Signifikan?
3	145,25	175,41	1,58	127,99	161,13	1,40	$1,65 \times 10^{-2}$	Ya, Transformer
5	177,32	210,22	1,92	208,81	252,18	2,27	$1,56 \times 10^{-5}$	Ya, LSTM
7	148,32	181,61	1,62	260,51	300,84	2,81	$2,86 \times 10^{-28}$	Ya, LSTM
10	194,99	233,17	2,11	187,77	226,79	2,03	$1,07 \times 10^{-1}$	Tidak (Transformer unggul tipis)
14	111,70	141,65	1,23	480,61	532,79	5,26	$6,46 \times 10^{-44}$	Ya, LSTM

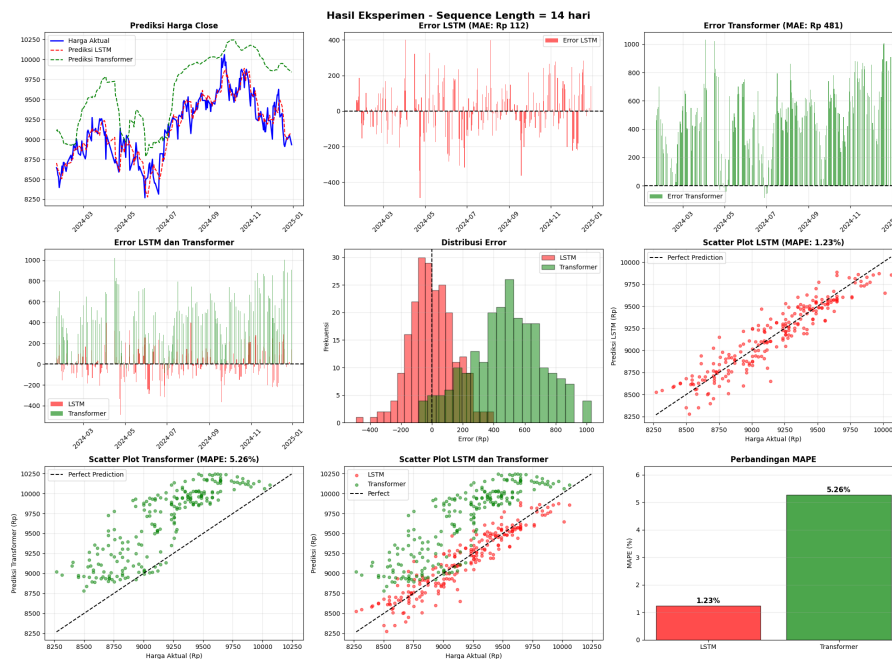
Dari Tabel 1, terdapat beberapa temuan yang dapat diamati. LSTM unggul di tiga panjang sekuens, yaitu 5, 7, dan 14 hari, dengan selisih yang dikonfirmasi signifikan oleh uji statistik. *Transformer* unggul di dua panjang sekuens lainnya, yaitu 3 dan 10 hari. Namun, keunggulan *Transformer* di sekuens 10 hari sangat tipis dengan selisih MAPE hanya 0,08% dan hasil uji statistik menunjukkan selisih ini tidak cukup kuat untuk disebut meyakinkan. Dengan kata lain, hanya pada sekuens 3 hari *Transformer* benar-benar menunjukkan performa yang lebih baik secara meyakinkan. Menurut interpretasi penulis, ini menarik karena menunjukkan bahwa pada dataset BBCE, *Transformer* cenderung bekerja lebih baik

ketika diberi data historis yang sangat pendek. Begitu sekuens bertambah panjang, LSTM justru lebih mampu memanfaatkan tambahan informasi tersebut. Adapun performa terbaik secara keseluruhan dicapai oleh LSTM di sekuens 14 hari dengan MAPE 1,23%. Pola ini memberi petunjuk bahwa LSTM lebih mampu menjaga performanya di berbagai panjang sekuens, sementara keunggulan *Transformer* terbatas pada konfigurasi dengan data historis minimal.

3.2 Analisis Kinerja pada Panjang Sekuens Optimal

Tabel 1 menunjukkan bahwa LSTM mencapai kinerja terbaik pada panjang sekuens 14 hari dengan MAPE 1,23%, MAE Rp111,70, dan RMSE Rp141,65. Sementara itu, *Transformer* mencapai kinerja terbaik pada panjang sekuens 3 hari dengan MAPE 1,40%, MAE Rp127,99, dan RMSE Rp161,13. Temuan ini menunjukkan bahwa masing-masing model memiliki panjang sekuens optimal yang berbeda.

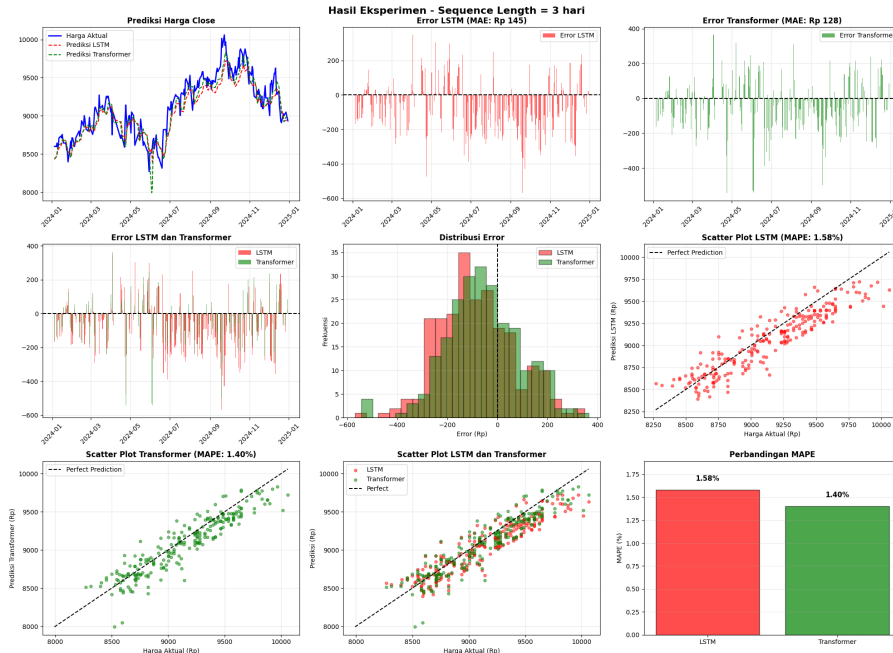
Pada sekuens 14 hari, LSTM memperoleh keuntungan dari cara kerjanya yang membaca data secara bertahap. Dalam dua minggu perdagangan, model dapat mengumpulkan informasi sedikit demi sedikit dan menyaring mana yang relevan dan mana yang tidak. Hasilnya, rata-rata kesalahan prediksi LSTM hanya 1,23% dari harga aktual. Angka ini lebih rendah dibandingkan studi Chaudhary [10] yang melaporkan MAPE terbaik 2,72% menggunakan LSTM. Sebaliknya, pada sekuens 3 dan 5 hari, LSTM mencatat MAPE masing-masing 1,58% dan 1,92%. Angka ini lebih tinggi dibandingkan sekuens 14 hari, yang menunjukkan bahwa data historis yang terlalu pendek belum cukup bagi LSTM untuk menangkap pola pergerakan harga secara optimal.



Gambar 1 Perbandingan prediksi pada panjang sekuens 14

Sementara itu, *Transformer* pada sekuens yang sama mencatat MAPE 5,26%, MAE Rp480,61, dan RMSE Rp532,79. Secara visual, Gambar 1 menunjukkan bahwa kurva prediksi LSTM mengikuti pergerakan harga aktual dengan cukup rapat, sedangkan prediksi *Transformer* meleset terutama pada periode volatilitas tinggi.

Transformer menunjukkan pola yang berkebalikan. Model ini bekerja dengan membandingkan semua hari sekaligus. Pada sekuens pendek 3 hari, *Transformer* hanya perlu menghitung tiga perbandingan sehingga dapat memberikan bobot yang lebih terarah dan menghasilkan MAPE 1,40%. Pada konfigurasi yang sama, LSTM mencatat MAPE 1,58%.



■ **Gambar 2** Perbandingan prediksi pada panjang sekuens 3

Pada Gambar 2, terlihat bahwa prediksi *Transformer* pada sekuens 3 hari lebih terkendali dibanding LSTM. Ini menjadi satu-satunya konfigurasi di mana *Transformer* unggul secara meyakinkan.

Ketika sekuens diperpanjang, performa *Transformer* justru menurun. Pada sekuens 14 hari, jumlah perbandingan antarhari melonjak menjadi 196. Perhatian model tersebar ke terlalu banyak titik dan informasi penting tenggelam. Ditambah lagi, perubahan harga saham dari hari ke hari seringkali kecil dan sulit dibedakan apakah perubahan tersebut benar-benar bermakna untuk prediksi atau sekadar fluktuasi acak. Akibatnya, MAPE *Transformer* meningkat tajam ke 5,26%.

Menurut penulis, pola ini memberi pelajaran bahwa menambah panjang data historis tidak selalu menguntungkan semua model. LSTM diuntungkan oleh data yang lebih panjang, sementara *Transformer* justru terbebani. Pemilihan model perlu disesuaikan dengan karakteristik data dan panjang sekuens yang akan digunakan.

3.3 Analisis Statistik Error

Tabel 2 menyajikan ringkasan statistik *error* yang meliputi rata-rata, standar deviasi, *skewness*, dan *kurtosis* untuk setiap variasi panjang sekuens.

Dari Tabel 2, terlihat pola bias prediksi yang menarik dari kedua model. Sebagian besar nilai rata-rata *error* bernilai negatif, menunjukkan bahwa LSTM dan *Transformer* sama-sama cenderung memprediksi harga di bawah nilai sebenarnya. Kecenderungan ini wajar dalam konteks prediksi saham, di mana model cenderung berhati-hati dan tidak terlalu

■ **Tabel 2** Statistik error LSTM dan Transformer

Panjang Sekuens	Model	Mean (Rp)	Std (Rp)	Skewness	Kurtosis
3	LSTM	-85	153	0,21	0,03
	Transformer	-56	151	-0,14	0,69
5	LSTM	-133	163	0,25	0,03
	Transformer	-184	173	-0,32	1,01
7	LSTM	-95	155	0,08	0,08
	Transformer	-240	181	0,22	0,09
10	LSTM	-164	166	0,12	-0,14
	Transformer	-136	182	0,18	-0,20
14	LSTM	2	142	0,01	0,36
	Transformer	478	235	-0,16	-0,30

berani memproyeksikan kenaikan. Namun, ada satu pengecualian yang cukup mencolok. *Transformer* pada sekuens 14 hari justru mencatat rata-rata *error* positif sebesar Rp478. Angka ini cukup besar dan menunjukkan bahwa model tidak sekadar meleset, melainkan secara sistematis memprediksi harga terlalu tinggi. Menurut penulis, ini menarik karena terjadi justru pada konfigurasi terburuk *Transformer*. Artinya, ketika model kehilangan akurasi, ia tidak hanya menghasilkan *error* yang besar tetapi juga kehilangan keseimbangan arah prediksinya. Sebaliknya, LSTM pada sekuens 14 hari mencatat rata-rata *error* hanya Rp2. Pada konfigurasi terbaiknya, LSTM nyaris tidak memiliki bias sistematis.

Dari sisi kestabilan, LSTM juga menunjukkan keunggulan. Standar deviasi *error* LSTM selalu lebih kecil dibandingkan *Transformer* di semua panjang sekuens. Pada sekuens 14 hari, standar deviasi LSTM sebesar Rp142 sedangkan *Transformer* mencapai Rp235. Selisih ini cukup berarti. Penulis melihat bahwa *Transformer* tidak hanya menghasilkan *error* rata-rata yang lebih besar, tetapi juga variasi *error* yang lebih lebar. Kombinasi keduanya membuat prediksi *Transformer* sulit diandalkan pada sekuens panjang.

Nilai *skewness* di sebagian besar konfigurasi mendekati nol, menunjukkan bahwa distribusi *error* kedua model umumnya seimbang antara kesalahan positif dan negatif. *Skewness* paling mendekati nol dicatat oleh LSTM pada sekuens 14 hari sebesar 0,01. Angka ini melengkapi temuan sebelumnya: pada konfigurasi optimalnya, LSTM tidak hanya akurat dan stabil, tetapi juga sangat seimbang dalam arah kesalahannya.

3.4 Diskusi

Perbedaan performa antara LSTM dan *Transformer* dalam studi ini tidak sekadar soal satu model lebih baik dari yang lain. LSTM mampu menjaga MAPE di bawah 2,11% pada semua konfigurasi, sementara *Transformer* melonjak hingga 5,26% saat sekuens diperpanjang menjadi 14 hari. Menurut penulis, perbedaan ini berakar pada kecocokan antara cara kerja model dan sifat data. LSTM yang membaca data secara bertahap cocok untuk data harga saham yang perubahannya akumulatif. Semakin banyak data historis yang diberikan, semakin kaya informasi yang bisa dikumpulkan. Sebaliknya, *Transformer* yang membandingkan semua hari sekaligus justru terbebani saat data terlalu panjang karena perhatiannya tersebar ke banyak titik yang kurang relevan. Temuan ini sejalan dengan Zeng et al. [11] yang mencatat bahwa model sederhana bisa mengungguli *Transformer* pada tugas peramalan runtun

waktu tertentu. Pola penurunan performa *Transformer* pada sekuens panjang juga teramati dalam studi lain. Jang et al. [12] melaporkan bahwa pada peramalan PM2.5, peningkatan panjang input dari 7 menjadi 15 hari menyebabkan peningkatan MAE sebesar 10 hingga 15 persen untuk prediksi 72 jam, yang dihubungkan dengan masuknya pola historis redundan ke dalam mekanisme *attention*.

Pengaruh panjang sekuens terhadap performa juga tidak bisa disamaratakan. Hasil studi ini memperkuat temuan Azlan et al. [13] bahwa pemilihan panjang jendela historis bersifat krusial, sekaligus menambah catatan bahwa setiap arsitektur memiliki titik optimalnya sendiri. LSTM membaik pada sekuens panjang, *Transformer* justru menurun. Penulis melihat ini sebagai pengingat bahwa strategi pemilihan panjang data harus disesuaikan dengan model yang dipakai.

Studi ini memiliki keterbatasan yang perlu dicatat. Dataset hanya mencakup satu saham sehingga generalisasi hasil masih perlu diuji lebih lanjut. Arsitektur *Transformer* yang digunakan juga tergolong besar untuk ukuran data yang tersedia. Ada kemungkinan performa *Transformer* dapat berbeda jika arsitekturnya disederhanakan. Meskipun demikian, hasil ini memberikan gambaran awal bahwa pada dataset finansial dengan ukuran terbatas, LSTM menawarkan keseimbangan antara akurasi dan kestabilan, sementara *Transformer* memerlukan kehati-hatian lebih dalam pemilihan panjang sekuens.

4 Kesimpulan dan Saran

Studi ini menguji bagaimana LSTM dan *Transformer* merespons variasi panjang data historis pada prediksi harga saham BBCA di BEI. Hasil eksperimen menunjukkan bahwa kedua model memiliki titik optimal yang sangat berbeda. LSTM mencapai performa terbaik pada sekuens 14 hari dengan MAPE 1,23%, sedangkan *Transformer* hanya optimal pada sekuens 3 hari dengan MAPE 1,40% dan menurun tajam pada sekuens yang lebih panjang. Kesenjangan performa ini semakin terlihat pada sekuens 14 hari, di mana *Transformer* mencatat MAPE 5,26% dengan rata-rata *error* Rp478 dan standar deviasi Rp235, sementara LSTM hampir tanpa bias dengan rata-rata *error* Rp2 dan standar deviasi Rp142.

Implikasi dari temuan ini adalah bahwa penambahan panjang data historis tidak selalu menguntungkan semua arsitektur. LSTM yang memproses data secara bertahap mampu memanfaatkan informasi dari sekuens panjang, sedangkan *Transformer* yang mengolah seluruh data sekaligus justru kehilangan akurasi. Kontribusi utama studi ini terletak pada bukti empiris bahwa pemilihan panjang sekuens perlu disesuaikan dengan arsitektur model, terutama pada dataset finansial dengan ukuran terbatas. Tanpa penyesuaian ini, model yang lebih kompleks seperti *Transformer* dapat bekerja jauh di bawah potensinya.

Untuk penelitian selanjutnya, disarankan eksplorasi *hyperparameter* yang lebih menyeluruh mengingat arsitektur *Transformer* dalam studi ini tergolong besar untuk data yang tersedia. Penyederhanaan arsitektur atau penambahan data melalui fitur eksternal seperti sentimen berita dan indikator makroekonomi dapat dipertimbangkan. Pengujian pada saham lain di BEI juga diperlukan untuk melihat konsistensi pola yang ditemukan.

Pustaka

- 1 M. S. Larasati, T. Astuti, dan S. Ambarwati, "Determinan volatilitas harga saham," *Relevan: Jurnal Riset Akuntansi*, vol. 1, no. 2, pp. 73–82, 2021.
- 2 Z. S. Qatrunnada, "Faktor yang mempengaruhi volatilitas return saham di Indonesia: perusahaan lq45," *Owner*, vol. 8, no. 3, pp. 2441–2451, 2024.

- 3 M. Marwondo dan T. Hidayah, "Perbandingan algoritma long short-term memory (lstm) dan gated recurrent unit (gru) untuk prediksi harga emas dunia," *In Search*, vol. 21, no. 2, pp. 230–239, 2023.
- 4 N. M. F. Hazsanah, "Analisis perbandingan model long short term memory dan transformer untuk prediksi saham bri," 2024.
- 5 D. K. H. Putra, "Analisis perbandingan model prediksi harga saham melalui pendekatan long-short term memory (lstm) dan autoregressive integrated moving average (arima) (studi kasus: Alfamart dan alfamidi)," Sekolah Tinggi Teknologi Terpadu Nurul Fikri, 2024.
- 6 J. Li, "A comparative study of lstm variants in prediction for tesla's stock price," *BCP Business & Management*, vol. 34, pp. 30–38, 2022.
- 7 Y. C. Tjen, "Peramalan ihsg dengan metode arima-garch dan lstm pada periode sebelum, masa, dan sesudah covid-19," Universitas Islam Indonesia, 2025.
- 8 T. Fischer dan C. Krauss, "Deep learning with long short-term memory networks for financial market predictions," *European Journal of Operational Research*, vol. 270, no. 2, pp. 654–669, 2018.
- 9 A. Vaswani *et al.*, "Attention is all you need," 2023.
- 10 R. Chaudhary, "Advanced stock market prediction using long short-term memory networks: a comprehensive deep learning framework," 2025.
- 11 A. Zeng, M. Chen, L. Zhang, dan Q. Xu, "Are transformers effective for time series forecasting?" 2023.
- 12 K. Jang, S. Han, K. Wang, dan H. Yun, "Sensitivity of transformer-based pm2.5 forecasting to input sequence length," pp. 4–5, 2026.
- 13 A. Azlan, Y. Yusof, M. Farhan, dan M. Mohsin, "Determining the impact of window length on time series forecasting using deep learning," *International Journal of Advanced Computer Research*, vol. 9, no. 44, 2019.