

Model *Transformer* untuk Prediksi Volatilitas Pasar Saham Jangka Panjang

<http://dx.doi.org/10.28932/jutisi.v12i1.13684>

Riwayat Artikel

Received: 3 November 2025 | Final Revision: 03 Agustus 2026 | 03 Agustus 2026

Creative Commons License 4.0 (CC BY – NC)



Christ Bastian Waruwu^{✉#1}, Dani Saepuloh^{#2}, Muhammad Mukhlis Khoirudin^{#3}, Budi Nurhidayatullah^{#4}

[#] Program Studi Magister Ilmu Komputer, Institut Pertanian Bogor University
Jalan Meranti, Kampus IPB Dramaga, Bogor 16680, Indonesia

¹christbastian@gmail.com

²danisaepuloh@apps.ipb.ac.id

³mukhliskhoirudin@apps.ipb.ac.id

⁴20budinurhidayatullah@apps.ipb.ac.id

[✉]Corresponding author: christbastian@gmail.com

Abstrak – Memprediksi volatilitas pasar saham jangka panjang di pasar saham berkembang, merupakan tantangan signifikan akibat data yang non-linear dan kompleks. Penelitian ini merancang dan mengevaluasi arsitektur *deep learning* berbasis *Transformer* untuk meningkatkan akurasi prediksi volatilitas jangka panjang di Indeks Harga Saham Gabungan (IHSG). Metode yang diusulkan mengintegrasikan data deret waktu *multi-modal*, mencakup data historis pasar (IHSG, saham *blue-chip*), indikator makroekonomi (suku bunga, inflasi), dan data lintas-aset (USD/IDR). Arsitektur *Transformer* dengan mekanisme *self-attention* digunakan untuk menangkap dependensi temporal jangka panjang dalam data. Model dilatih untuk memprediksi *future realized volatility* pada horizon 21 hari. Kinerja mode dievaluasi dan dibandingkan dengan arsitektur *baseline* populer, yaitu *Long Short-Term Memory* (LSTM) dan GARCH(1,1), menggunakan metrik *Root Mean Square Error* (RMSE) dan *Mean Absolute Error* (MAE). Hasil evaluasi pada data uji menunjukkan bahwa model *Transformer* yang diusulkan secara konsisten mengungguli model LSTM dan GARCH, yang ditandai dengan nilai RMSE dan MAE yang lebih rendah. Temuan ini menyoroti kemampuan superior arsitektur *Transformer* dalam memodelkan hubungan non-linear yang kompleks dan dependensi jangka panjang dari data keuangan *multi-modal*. Simpulannya, arsitektur *Transformer* terbukti menjadi kerangka kerja yang kuat dan efektif untuk prediksi volatilitas jangka panjang. Arsitektur ini menawarkan solusi yang menjanjikan untuk analisis risiko dan pengambilan keputusan investasi strategis di pasar berkembang.

Kata kunci – arsitektur *transformer*; *deep learning*; deret waktu keuangan; pasar saham berkembang; prediksi volatilitas.

Transformer Model for Long-Term Stock Market Volatility Prediction

Abstract – Predicting long-term stock market volatility in emerging stock markets is a significant challenge due to the data's inherent non-linear and complex nature. This study aims to design and evaluate a Transformer-based deep learning architecture to enhance the accuracy of long-term volatility prediction, with a case study on the Indonesia Stock Exchange Composite Index (IDX Composite). The proposed method integrates multi-modal time-series data, including historical market data (IDX Composite, blue-chip stocks), key macroeconomic indicators (interest rates, inflation), and cross-asset data (USD/IDR). The Transformer architecture, leveraging its self-attention mechanism, is employed to capture complex long-range temporal dependencies within the data. The model was trained to predict future realized volatility over a 21-day horizon. Its performance was rigorously evaluated against popular baseline architectures, namely Long Short-Term Memory (LSTM) and GARCH(1,1), using Root Mean Square Error (RMSE) and Mean Absolute Error (MAE) metrics. The evaluation results on the test set demonstrate that the proposed Transformer model consistently

outperforms both LSTM and GARCH models, indicated by lower RMSE and MAE values. This finding highlights the superior capability of the Transformer architecture in modeling complex non-linear relationships and long-term dependencies from multi-modal financial data. In conclusion, the Transformer architecture proves to be a robust and effective framework for long-term volatility prediction, offering a promising solution for risk analysis and strategic investment decision-making in emerging markets.

Keywords – deep learning; emerging stock markets; financial time series; transformer architecture; volatility prediction.

I. PENDAHULUAN

Pasar saham merupakan salah satu pilar utama dalam perekonomian modern, yang berfungsi sebagai barometer kesehatan ekonomi suatu negara dan sebagai wadah vital bagi investor untuk melakukan alokasi modal. Terutama di pasar saham berkembang (*emerging stock markets*) seperti Indonesia, pasar saham memainkan peran krusial dalam mendorong pertumbuhan ekonomi dan menawarkan peluang investasi yang signifikan. Karakteristik fundamental dari pasar saham, khususnya di negara berkembang, adalah tingkat volatilitasnya yang tinggi. Volatilitas, yang merefleksikan derajat ketidakpastian atau risiko dari perubahan harga sekuritas, bersifat kompleks, non-linear, dan stokastik [1], [2]. Fenomena ini dipengaruhi oleh interaksi dinamis dari berbagai faktor, mulai dari data ekonomi makro, sentimen investor, kebijakan moneter, hingga peristiwa geopolitik yang tidak terduga. Kemampuan untuk memprediksi volatilitas secara akurat, terutama dalam jangka panjang, telah menjadi tantangan fundamental namun sangat penting dalam bidang keuangan kuantitatif. Prediksi volatilitas jangka panjang yang andal menjadi faktor krusial bagi investor institusional dalam manajemen risiko dan optimalisasi portofolio. Selain itu, prediksi ini juga penting bagi para pembuat kebijakan untuk menjaga stabilitas sistem keuangan [3].

Seiring berjalannya waktu, berbagai pendekatan telah dikembangkan untuk memodelkan dan memprediksi volatilitas pasar saham. Model statistik tradisional seperti *Autoregressive Integrated Moving Average* (ARIMA) dan variannya, serta model ekonometrik seperti *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH), telah lama menjadi standar dalam analisis deret waktu keuangan [4]. Model-model ini, meskipun kuat dalam menangkap korelasi linear dan klusterisasi volatilitas, sering kali menghadapi kesulitan dalam memodelkan dependensi non-linear yang kompleks dan hubungan jangka panjang yang melekat pada data pasar saham. Keterbatasan ini menjadi semakin nyata dalam konteks pasar berkembang yang sering kali menunjukkan perilaku non-stasioner dan lebih rentan terhadap guncangan eksternal [5]. Untuk mengatasi kelemahan model statistik, penelitian beralih ke metode *machine learning* dan *deep learning*. Arsitektur seperti *Recurrent Neural Networks* (RNN), dan secara khusus *Long Short-Term Memory* (LSTM), menunjukkan kemajuan signifikan karena kemampuannya dalam memodelkan dependensi temporal dalam data sekuensial [6]. Jaringan LSTM terbukti lebih unggul dibandingkan dengan model tradisional dalam berbagai tugas prediksi keuangan karena dapat menangani masalah *vanishing gradient* dan menyimpan informasi dalam jangka waktu yang lebih panjang. Arsitektur RNN/LSTM memiliki keterbatasan inheren, yakni sifat pemrosesannya yang sekuensial telah menghambat paralelisasi dan membuatnya menjadi kurang efisien dalam menangkap dependensi yang sangat jauh (*very long-range dependencies*) dalam deret waktu yang panjang [7].

Kemunculan arsitektur *Transformer*, yang pertama kali diperkenalkan dalam bidang *Natural Language Processing* (NLP) oleh Vaswani dkk. [8], telah membuat revolusi pemodelan data sekuensial. Mekanisme inti dari *Transformer*, yaitu *self-attention*, memungkinkan model untuk menimbang pentingnya setiap elemen dalam urutan *input* secara dinamis dan paralel, tanpa bergantung pada jarak antar elemen. Kemampuan ini dilihat secara fundamental mampu mengatasi keterbatasan pemrosesan sekuensial pada RNN dan sangat efektif dalam menangkap pola dependensi jangka panjang yang kompleks. Keunggulan ini membuat arsitektur *Transformer* menjadi kandidat yang sangat menjanjikan untuk diterapkan dalam prediksi deret waktu keuangan [9], [10]; peristiwa pasar di masa lalu yang jauh dapat memiliki dampak signifikan pada kondisi pasar di masa depan. Beberapa penelitian telah mulai menerapkan model *Transformer* untuk prediksi harga saham dan menunjukkan hasil yang memuaskan, sering kali justru mengungguli arsitektur berbasis LSTM [11], terutama pada horizon prediksi yang lebih panjang. Sebagian besar studi tersebut cenderung berfokus pada prediksi harga jangka pendek atau pada pasar saham di negara maju yang lebih stabil dan efisien. Terdapat celah penelitian yang signifikan dalam penerapan arsitektur *Transformer* untuk tugas spesifik prediksi volatilitas jangka panjang di lingkungan pasar berkembang yang secara inheren lebih volatil dan dipengaruhi oleh beragam faktor eksternal.


Berdasarkan kajian literatur di atas, terdapat dua celah penelitian yang belum terjawab secara komprehensif. Pertama, penerapan arsitektur *Transformer* untuk prediksi *volatility* jangka panjang di pasar berkembang masih sangat terbatas; sebagian besar studi berfokus pada prediksi harga jangka pendek di pasar maju yang lebih stabil dan efisien. Kedua, model-model yang ada jarang mengintegrasikan indikator makroekonomi lokal sebagai fitur prediktor secara eksplisit, padahal volatilitas jangka panjang di pasar seperti Indonesia sangat dipengaruhi oleh kondisi fundamental makro seperti suku bunga, inflasi, dan nilai tukar. Penelitian ini hadir untuk mengisi kedua celah tersebut secara bersamaan.

Penelitian ini bertujuan untuk mengisi celah tersebut dengan mengusulkan, mengimplementasikan, dan mengevaluasi arsitektur berbasis *Transformer* yang dirancang khusus untuk prediksi volatilitas pasar saham jangka panjang, dengan studi

kasus di pasar saham Indonesia (IHSG). Kontribusi utama penelitian ini adalah sebagai berikut. *Pertama*, model *Transformer encoder-only* dirancang khusus untuk prediksi *realized volatility* pada horizon 21 hari di pasar saham berkembang Indonesia, sebuah tugas yang belum banyak dieksplorasi dalam literatur keuangan. *Kedua*, model mengintegrasikan data multi-modal yang mencakup data historis pasar (IHSG, JLQ45, saham *blue-chip*), lintas aset (USD/IDR), dan indikator makroekonomi Indonesia (suku bunga BI, inflasi, PDB, cadangan devisa), didasarkan pada hipotesis bahwa volatilitas jangka panjang sangat dipengaruhi oleh kondisi fundamental makro yang sering diabaikan model berbasis teknikal murni. *Ketiga*, dilakukan evaluasi komparatif yang ketat antara *Transformer*, LSTM, dan GARCH(1,1) pada data pasar berkembang, memberikan bukti empiris yang solid mengenai keunggulan relatif masing-masing pendekatan. Hasil penelitian ini diharapkan memberikan kontribusi signifikan secara teoretis maupun praktis sebagai kerangka kerja yang lebih andal untuk analisis dan manajemen risiko di pasar modal yang dinamis.

II. METODE PENELITIAN

Metodologi penelitian ini disusun secara sistematis untuk membangun dan mengevaluasi sebuah model prediksi volatilitas jangka panjang menggunakan arsitektur *Transformer*. Proses penelitian ini dibagi menjadi lima tahapan utama: (1) pengumpulan dan pra-pemrosesan data mentah dari berbagai sumber; (2) rekayasa fitur (*feature engineering*) untuk mengekstrak informasi prediktif dan mendefinisikan variabel target; (3) perancangan arsitektur model *Transformer* serta model pembanding; (4) prosedur eksperimen yang mencakup persiapan data, pelatihan model, dan pengujian; serta (5) evaluasi kinerja model menggunakan metrik statistik yang relevan. Keseluruhan alur kerja penelitian ini diilustrasikan secara visual pada Gambar 1.



Gambar 1. Diagram Alur Metodologi Penelitian

A. Pengumpulan dan Pra-pemrosesan Data

Tahap awal penelitian ini berfokus pada pengumpulan dan integrasi data deret waktu dari berbagai sumber untuk menciptakan sebuah dataset multi-modal yang komprehensif. Dataset penelitian ini dibangun dari data historis yang mencakup periode dari 1 Januari 2010 hingga 30 September 2025. Rentang waktu yang ekstensif ini (lebih dari 15 tahun) dipilih secara strategis untuk memastikan model dapat mempelajari berbagai rezim dan kondisi pasar, termasuk periode pemulihan pasca-krisis finansial global, pandemi COVID-19, hingga dinamika ekonomi dan geopolitik terkini. Sumber dan jenis data yang digunakan dirangkum pada Tabel 1.

TABEL 1
SUMBER DAN DESKRIPSI DATA PENELITIAN

Jenis Data	Detail	Sumber	Deskripsi Variabel	Frekuensi
Indeks Pasar	IHSG, JLQ45	Investing.com	Open, High, Low, Close (OHLC), Volume	Harian
Saham	Saham <i>Blue-Chip</i>	Yahoo Finance	OHLC, Volume untuk BBKA, ASII, TLKM, ADRO, PGAS, dan ICBP	Harian
Lintas Aset	Kurs Valuta Asing	Investing.com	OHLC untuk USD/IDR	Harian
	Suku Bunga Acuan	Investing.com	BI Rate (Bank Indonesia Rate)	Bulanan
	Inflasi	Investing.com	Tingkat Inflasi Tahunan (Year-over-Year)	Bulanan
	Pertumbuhan Ekonomi	Investing.com	Pertumbuhan PDB Tahunan (Year-over-Year)	Triwulanan
	Cadangan Devisa	Investing.com	Total Cadangan Devisa dalam Miliar USD	Bulanan
Ketidakpastian	<i>World Uncertainty Index</i>	FRED	Indeks Ketidakpastian Ekonomi untuk Indonesia	Triwulanan

Proses pra-pemrosesan data dilakukan untuk mengatasi perbedaan format, frekuensi, dan nilai yang hilang. Data dari situs Investing.com yang menggunakan format angka non-standar (pemisah ribuan titik, desimal koma) dan volume dengan sufiks ('M' untuk juta, 'B' untuk miliar) dibersihkan dan dikonversi menjadi format numerik standar. Data makroekonomi yang memiliki frekuensi bulanan atau triwulanan di-*resample* menjadi frekuensi harian menggunakan metode *forward fill* (*ffill*). Metode ini dipilih untuk mensimulasikan kondisi nyata karena data makro hanya dirilis secara periodik dan nilainya tetap berlaku hingga rilis berikutnya. Setelah semua data dibersihkan dan disesuaikan frekuensinya, data-data tersebut digabungkan menjadi satu *DataFrame* tunggal berdasarkan indeks tanggal. Baris yang merepresentasikan hari libur bursa, yaitu hari ketika data IHSG tidak tersedia, dihapus. Nilai kosong (*missing values*) yang mungkin masih ada, misalnya akibat perbedaan tanggal mulai data atau hari libur antara negara, diatasi dengan metode *forward fill* diikuti oleh *backward fill* (*bfill*) untuk memastikan tidak ada data yang hilang dalam deret waktu.

B. Rekayasa Fitur dan Definisi Variabel Target

Tahap ini bertujuan untuk mengekstrak fitur-fitur prediktif (*predictor*) dari data yang telah bersih dan mendefinisikan variabel target (*target*) secara akurat.

- 1) Variabel Target (*Future Realized Volatility*): Variabel dependen yang ingin diprediksi adalah volatilitas pasar di masa depan. Variabel ini didefinisikan sebagai *future realized volatility*, yang dihitung sebagai standar deviasi dari *log returns* harian IHSG selama periode horizon prediksi di masa depan. *Log return* (r_t) dihitung menggunakan Persamaan (1), dengan P_t adalah harga penutupan IHSG pada hari t .

$$r_t = \ln \ln \left(\frac{P_t}{P_{t-1}} \right) \quad (1)$$

Selanjutnya, *future realized volatility* (RV_H) untuk horizon H hari dihitung dan diannualisasi (dikalikan $\sqrt{252}$) sesuai Persamaan (2). Proses ini melibatkan penggeseran (*shifting*) hasil perhitungan ke belakang, sehingga nilai pada hari t merepresentasikan volatilitas aktual yang terjadi dari hari $t + 1$ hingga $t + H$.

$$RV_H(t) = StDev(r_{t+1}, r_{t+2}, \dots, r_{t+H}) \times \sqrt{252} \quad (2)$$


Dalam penelitian ini, tiga horizon prediksi jangka panjang didefinisikan, yakni 21 hari (~1 bulan), 63 hari (~3 bulan), dan 126 hari (~6 bulan). Namun, pelaporan hasil eksperimen pada penelitian ini difokuskan pada horizon 21 hari sebagai horizon yang paling relevan secara praktis untuk keputusan manajemen risiko jangka pendek-menengah, serta sebagai representasi awal yang memadai untuk memvalidasi keunggulan arsitektur yang diusulkan. Evaluasi pada horizon 63 dan 126 hari diidentifikasi sebagai arah penelitian lanjutan yang menjanjikan.

- 2) Fitur-fitur Prediktor (Variabel Independen): Serangkaian fitur direkayasa untuk menangkap berbagai aspek dinamika pasar:
 - Fitur Volatilitas Historis: Volatilitas masa lalu yang dihitung dengan cara yang sama seperti variabel target tetapi untuk periode masa lalu (misal, 5, 21, dan 63 hari sebelumnya).
 - Fitur Indikator Teknis: Indikator momentum dan tren seperti *Relative Strength Indeks* (RSI-14), *Moving Average Convergence Divergence* (MACD), dan *Exponential Moving Average* (EMA-50) pada IHSG.
 - Fitur Lintas Aset: *Log returns* harian dari indeks JLQ45, kurs USD/IDR, dan saham-saham *blue-chip*.
 - Fitur Makroekonomi: Data makroekonomi mentah dan fitur turunan seperti suku bunga riil (suku bunga BI – inflasi YoY).

C. Arsitektur Model

Penelitian ini mengusulkan model berbasis arsitektur *Transformer* dan membandingkannya dengan dua model *baseline*.

- 1) Model *Transformer* (Usulan): Model utama yang diusulkan dalam penelitian ini didasarkan pada arsitektur *Transformer* yang hanya menggunakan tumpukan *encoder*, sebuah adaptasi dari model asli yang diperkenalkan oleh Vaswani dkk. [8]. Seperti diilustrasikan pada Gambar 2, unit fundamental dari arsitektur ini adalah blok *encoder*. Setiap blok terdiri dari komponen kunci yaitu mekanisme *Multi-Head Self-Attention* dan sebuah *Feed-Forward Network*, yang keduanya dihubungkan melalui koneksi residual dan normalisasi lapisan. Dalam model final, beberapa blok *encoder* ini ditumpuk secara berurutan untuk memungkinkan pembelajaran representasi data yang semakin kompleks dan mendalam.



Gambar 2. Arsitektur Blok *Transformer Encoder* yang Digunakan

- *Positional Encoding*: Sebuah lapisan *positional encoding* sinusoidal ditambahkan pada sekuens *input* untuk menyuntikkan informasi urutan temporal ke dalam model.
- *Multi-Head Self-Attention*: Inti dari *Transformer* yang memungkinkan model menangkap dependensi jangka panjang secara paralel.

- *Feed-Forward Network*: Jaringan *feed-forward* yang diterapkan pada setiap posisi untuk transformasi non-linear.
- Tumpukan dan Kepala Regresi: Beberapa blok *encoder* ditumpuk. *Output*-nya kemudian dirata-ratakan melalui *Global Average Pooling* dan dilewatkan ke beberapa lapisan *Dense* (MLP) untuk menghasilkan prediksi volatilitas tunggal.

Hyperparameter utama dari model *Transformer* yang digunakan dalam penelitian ini dirangkum dalam Tabel 2.

TABEL 2
KONFIGURASI *HYPERPARAMETER* MODEL *TRANSFORMER*

<i>Hyperparameter</i>	Nilai
Panjang Sekuens <i>Input</i>	60 hari
Jumlah Blok <i>Transformer</i>	4
Jumlah <i>Heads</i> (<i>Attention</i>)	4
Ukuran <i>Head</i> (<i>Key Dimension</i>)	256
<i>Dropout Rate</i>	0.2 – 0.3
<i>Optimizer</i>	Adam (<i>learning rate</i> = $1e-4$)

Konfigurasi *hyperparameter* pada Tabel 2 ditentukan berdasarkan kombinasi kajian literatur dan eksperimen awal (*preliminary experiments*) dengan pemantauan *validation loss*. Panjang sekuens 60 hari dipilih karena mencakup sekitar tiga bulan kalender perdagangan, yang secara empiris cukup untuk menangkap pola siklus jangka pendek hingga menengah dalam data volatilitas keuangan. Jumlah 4 blok *encoder* dan 4 *attention heads* ditentukan mengacu pada arsitektur *Transformer* skala menengah yang terbukti efektif untuk deret waktu multivariat [8], [9], sekaligus menyeimbangkan kapasitas model dengan ukuran dataset yang tersedia guna menghindari *overfitting*. Proses penentuan *hyperparameter* dilakukan secara manual (*manual tuning*) dengan mengevaluasi kombinasi nilai pada data validasi. Nilai yang lebih besar (misalnya 8 blok atau 8 *heads*) tidak memberikan perbaikan signifikan pada *validation loss* namun meningkatkan waktu komputasi secara substansial, sehingga konfigurasi pada Tabel 2 dipilih sebagai titik keseimbangan optimal antara performa dan efisiensi.

2) Model Pembanding (*Baseline*):

- *LSTM*: Sebuah model *Long Short-Term Memory* (*LSTM*) digunakan sebagai *baseline deep learning*. Meskipun arsitektur yang lebih baru seperti *Transformer* telah muncul, *LSTM* masih menjadi pembanding yang kuat dan relevan dalam prediksi deret waktu keuangan [6], [7]. Arsitekturnya terdiri dari dua lapisan *LSTM* yang ditumpuk, diikuti oleh lapisan *Dropout* dan lapisan *Dense* untuk prediksi akhir.
- *GARCH*: Model *GARCH*(1,1) [4] dipilih sebagai *baseline* ekonometrik standar. Model ini dilatih pada *log returns* harian data latih untuk memprediksi varians harian pada data uji, yang kemudian diintegrasikan untuk menghasilkan prediksi volatilitas jangka panjang.

D. Prosedur Eksperimen dan Evaluasi

- Pembagian dan Normalisasi Data: Dataset dibagi secara kronologis menjadi data latih sekitar 70% dari tahun 2010 hingga 2021, validasi sekitar 15% dari 2021 hingga 2023), dan uji sekitar 15% dari 2024 hingga 2025. Semua fitur dinormalisasi menggunakan *StandardScaler* yang hanya dilatih pada data latih.
- Pembuatan Sekuens: Data diubah menjadi format sekuensial dengan panjang jendela geser (*sliding window*) 60 hari kerja untuk membuat sampel *input* (*x*) dan target (*y*).
- Pelatihan Model: Model dilatih menggunakan data latih dengan *loss function* *mean_squared_error*. Mekanisme *Early Stopping* dengan *patience* 15 *epoch* digunakan untuk mencegah terjadinya *overfitting* dan menyimpan bobot model terbaik berdasarkan performa pada data validasi.
- Metrik Evaluasi: Kinerja model dievaluasi pada data uji menggunakan metrik:
 - *Root Mean Square Error* (RMSE): Mengukur magnitudo rata-rata kesalahan.
 - *Mean Absolute Error* (MAE): Mengukur rata-rata kesalahan absolut, lebih mudah diinterpretasikan.

III. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil eksperimen dari model-model yang telah dilatih dan dievaluasi, diikuti dengan pembahasan mendalam mengenai temuan yang diperoleh. Analisis difokuskan pada perbandingan kinerja antara model *Transformer* yang diusulkan dengan model *baseline* *LSTM* dan *GARCH* dalam memprediksi volatilitas jangka panjang *IHSG* pada data uji.

Horizon prediksi yang dianalisis dalam bagian ini adalah untuk 21 hari perdagangan (~1 bulan), yang mewakili prediksi jangka menengah.

A. Hasil Eksperimen Kuantitatif

Kinerja dari ketiga model (Transformer, LSTM, dan GARCH) dievaluasi pada set data uji, yang mencakup periode dari awal tahun 2024 hingga 30 September 2025. Metrik evaluasi utama yang digunakan adalah *Root Mean Square Error* (RMSE) dan *Mean Absolute Error* (MAE). Nilai yang lebih rendah pada kedua metrik ini mengindikasikan kinerja prediksi yang lebih baik. Hasil evaluasi kuantitatif dirangkum secara lengkap pada Tabel 3.

TABEL 3
PERBANDINGAN KINERJA PREDIKSI MODEL PADA DATA UJI (HORIZON 21 HARI)

Model	RMSE	MAE
GARCH(1,1)	0,1446	0,1283
LSTM	0,0871	0,0769
Transformer (Usulan)	0,0686	0,0490

Tabel 3 menunjukkan bahwa model *Transformer* yang diusulkan memiliki kinerja paling unggul. Model ini berhasil mencapai nilai RMSE dan MAE terendah dibandingkan dengan model LSTM dan GARCH(1,1). Secara spesifik, model *Transformer* mencapai RMSE sebesar 0,0686, yang menunjukkan penurunan kesalahan prediksi yang signifikan dibandingkan dengan LSTM sebesar 0,0871 dan GARCH(1,1) sebesar 0,1446. Pola yang sama juga terlihat pada metrik MAE, sementara model *Transformer* mencatatkan nilai 0,0490, mengindikasikan bahwa rata-rata simpangan absolut prediksinya terhadap nilai aktual adalah yang terkecil di antara ketiga model.


Penurunan RMSE model *Transformer* terhadap LSTM sebesar -21,2% (dari 0,0871 menjadi 0,0686) dan terhadap GARCH sebesar -52,6% (dari 0,1446 menjadi 0,0686) merupakan selisih yang substansial dan bukan sekadar perbaikan marginal. Dari perspektif teoritis, keunggulan ini dapat dijelaskan melalui kemampuan mekanisme *self-attention* yang memungkinkan mode menghubungkan secara langsung setiap titik dalam sekuens 60 hari tanpa degradasi informasi, berbeda dengan LSTM yang memproses data secara sekuensial sehingga informasi dari awal sekuens berisiko melemah sebelum mencapai lapisan akhir [7]. Keunggulan terhadap GARCH lebih besar lagi karena GARCH secara fundamental bersifat univariat dan *mean-reverting*, sehingga tidak menginkorporasikan sinyal dari data lintas-aset dan makroekonomi yang menjadi kekuatan utama mode yang diusulkan.

Meskipun uji signifikansi formal tidak dilakukan dalam penelitian ini, konsistensi keunggulan *Transformer* pada kedua metrik (RMSE dan MAE) sekaligus pada seluruh periode data uji (2024-2025) memberikan indikasi yang kuat bahwa perbedaan performa yang diamati bersifat sistematis, bukan fluktuasi acak. Penelitian lanjutan disarankan untuk melengkapi analisis ini dengan uji Diebold-Mariano atau uji statistik sejenis.

Pelaporan hasil pada penelitian ini difokuskan pada horizon 21 hari sebagai representasi prediksi volatilitas jangka menengah yang paling relevan secara praktis dan memiliki volume sampel uji yang memadai. Evaluasi pada horizon 63 hari (~ 3 bulan) dan 126 hari (~ 6 bulan) tidak diikutsertakan dalam laporan ini karena keterbatasan jumlah sampel *non-overlapping* pada periode data uji yang tersedia (2024-2025), yang dapat menghasilkan estimasi metrik yang kurang stabil. Eksplorasi horizon yang lebih panjang dengan rentang data yang lebih luas merupakan arah penelitian lanjutan yang penting.

B. Analisis Visual Kinerja Prediksi

Untuk memberikan pemahaman yang lebih intuitif mengenai kinerja model, dilakukan visualisasi perbandingan antara nilai volatilitas aktual (*ground truth*) dengan nilai yang diprediksi oleh masing-masing model pada data uji. Gambar 3 menyajikan plot deret waktu dari hasil prediksi ketiga model tersebut.



Gambar 3. Perbandingan Visual Prediksi Volatilitas Model pada Data

Gambar 3 mengilustrasikan secara visual bahwa kurva prediksi yang dihasilkan oleh model *Transformer* (garis merah putus-putus) secara umum paling mendekati dan paling mampu mengikuti pola pergerakan kurva volatilitas aktual (garis hitam tebal). Terlihat bahwa model *Transformer* lebih responsif dalam menangkap puncak (*peak*) dan lembah (*trough*) dari volatilitas pasar, meskipun masih terdapat beberapa penyimpangan. Sebaliknya, prediksi dari model LSTM (garis hijau titik-titik) menunjukkan kemampuan mengikuti tren umum tetapi cenderung lebih *smooth* dan terkadang melambat dalam merespons perubahan volatilitas yang tajam. Sementara itu, model GARCH (garis ungu strip-strip), meskipun mampu menangkap beberapa klusterisasi volatilitas, terlihat memiliki kesulitan dalam memprediksi magnitudo perubahan secara akurat, sering kali menghasilkan prediksi yang lebih rendah (*underestimate*) pada periode volatilitas tinggi.

C. Pembahasan Hasil

Hasil eksperimen, baik secara kuantitatif maupun kualitatif, secara konsisten menunjukkan superioritas arsitektur *Transformer* dibandingkan dengan LSTM dan GARCH untuk tugas prediksi volatilitas pasar saham jangka panjang di pasar berkembang. Terdapat beberapa alasan mendasar yang dapat menjelaskan temuan ini.

Pertama, kemampuan mekanisme *self-attention* pada model *Transformer* menjadi faktor pembeda utama. Model LSTM memproses data secara sekuensial sehingga rentan terhadap pelemahan informasi dari masa lalu yang jauh. Sebaliknya, mekanisme *self-attention* pada model *Transformer* memungkinkan model untuk secara langsung menghubungkan dan menimbang pentingnya setiap hari perdagangan dalam sekuens *input* (60 hari) [7]. Hal ini sangat krusial dalam konteks keuangan, karena sebuah peristiwa ekonomi atau rilis data makro di awal periode sekuens bisa memiliki dampak signifikan terhadap volatilitas di masa depan. Kemampuan untuk “melihat” seluruh sekuens secara bersamaan memungkinkan *Transformer* menangkap dependensi temporal yang kompleks dan non-linear, yang gagal dimodelkan secara efektif oleh arsitektur sekuensial seperti LSTM atau model statistik seperti GARCH(1,1) [10], [11].

Kedua, integrasi data multi-modal (pasar, makroekonomi, lintas-aset) memberikan keuntungan signifikan bagi model *Transformer*. Arsitektur *deep learning* seperti *Transformer* dan LSTM memiliki kapasitas yang lebih besar untuk mengekstraksi sinyal prediktif dari dataset berdimensi tinggi dibandingkan GARCH, yang pada merupakan model univariat. Model *Transformer*, dengan kemampuannya untuk mempelajari interaksi antar-fitur melalui lapisan-lapisan *encoder*-nya, terbukti lebih efektif dalam mensintesis informasi dari berbagai sumber data ini. Misalnya, model dapat belajar bahwa perubahan mendadak pada kurs USD/IDR atau rilis data inflasi yang tidak terduga memiliki bobot atensi yang lebih tinggi dalam memprediksi lonjakan volatilitas di masa depan, sebuah hubungan yang sulit dimodelkan oleh GARCH.

Temuan ini secara konsisten mendukung dan memperluas hasil dari studi-studi *Transformer* terdahulu di bidang keuangan. Tiantian [11] menunjukkan bahwa arsitektur hibrida CNN-*Transformer* mengungguli LSTM terutama pada horizon prediksi yang lebih panjang, sejalan dengan hasil penelitian ini yang membuktikan keunggulan serupa pada horizon 21 hari di pasar berkembang. Lebih jauh, Li dkk. [9] dalam model MASTER mendemonstrasikan bahwa *Transformer* mampu mengekstraksi sinyal lintas-aset secara efektif, yang mendukung pendekatan integrasi multi-modal yang digunakan dalam penelitian ini. Berbeda dari sebagian studi tersebut yang beroperasi di pasar maju (AS, China), penelitian ini memberikan bukti bahwa keunggulan *Transformer* tetap bertahan di lingkungan pasar berkembang yang lebih non-linear dan rentan terhadap guncangan eksternal, kontribusi yang belum banyak didokumentasikan dalam literatur yang ada. Adapun Liu dkk. [12] menunjukkan bahwa penambahan analisis sentimen ke dalam model *deep learning* berbasis *Transformer* dapat meningkatkan performa lebih lanjut, yang mengindikasikan bahwa hasil penelitian ini masih berpotensi untuk ditingkatkan dengan menginkorporasikan dimensi sentimen pasar.

Ketiga, keterbatasan mode *baseline* juga menjadi jelas. Model GARCH, meskipun baik dalam menangkap klusterisasi volatilitas (periode volatilitas tinggi diikuti oleh volatilitas tinggi), pada dasarnya bersifat *mean-reverting* dan terbatas dalam menangkap non-linearitas. Model ini kesulitan beradaptasi dengan perubahan rezim pasar yang drastis dan tidak dapat secara langsung menginkorporasikan informasi eksternal. Model LSTM, meskipun lebih baik dari GARCH, masih dibatasi oleh “leher botol” informasi (*information bottleneck*) dari pemrosesan sekuensialnya. Informasi dari awal sekuens harus melewati banyak langkah komputasi sebelum mencapai akhir, yang berisiko menyebabkan hilangnya detail-detail penting.

Dari perspektif praktis, hasil penelitian ini memiliki implikasi langsung bagi dua kelompok pengguna utama. *Pertama*, bagi manajer portofolio institusional, prediksi volatilitas 21 hari ke depan yang lebih akurat dapat digunakan sebagai input dinamis dalam model *Value-at-Risk* (VaR) untuk penetapan batas risiko harian, serta sebagai sinyal *rebalancing* dalam strategi *risk-parity* yang mengalokasikan bobot aset berdasarkan kontribusi volatilitas masing-masing. Kemampuan model mengidentifikasi periode volatilitas tinggi secara lebih dini memberikan keunggulan waktu bagi manajer investasi untuk melakukan lindung nilai (*hedging*) sebelum lonjakan terjadi. *Kedua*, bagi pembuat kebijakan dan regulator pasar modal, model ini dapat berfungsi sebagai sistem peringatan dini (*early warning system*) terhadap periode tekanan pasar yang berpotensi sistemik, mengingat model mengintegrasikan indikator makroekonomi yang mencerminkan kondisi fundamental perekonomian Indonesia.

Meskipun model *Transformer* menunjukkan kinerja terbaik, penelitian ini memiliki beberapa keterbatasan yang perlu diakui. *Pertama*, prediksi masih menunjukkan deviasi dari nilai aktual terutama selama periode guncangan pasar yang ekstrem dan tidak terduga (*black swan events*), seperti pengumuman kebijakan moneter mendadak atau krisis geopolitik. Hal ini mengindikasikan bahwa model belum sepenuhnya mampu mengantisipasi perubahan rezim pasar yang bersifat diskontinyu. *Kedua*, dan yang paling signifikan, model ini belum menginkorporasikan data sentimen pasar dari sumber seperti berita keuangan, laporan analis, atau media sosial. Di pasar berkembang seperti Indonesia, karena proporsi investor ritel masih relatif besar dan pasar cenderung reaktif terhadap narasi media, sentimen dapat berfungsi sebagai *leading indicator* yang mendahului pergerakan harga dan lonjakan volatilitas sebelum tercermin dalam data fundamental. Penelitian Liu dkk. [12] mendemonstrasikan bahwa integrasi analisis sentimen ke dalam kerangka *deep learning* secara konsisten meningkatkan akurasi prediksi volatilitas. Ketiadaan dimensi sentimen ini kemungkinan menjadi faktor utama yang membatasi performa model pada periode *black swan*, karena perubahan sentimen pasar sering kali mendahului dan memicu pergerakan harga yang ekstrem. *Ketiga*, evaluasi terbatas pada satu pasar (IHSG Indonesia) sehingga generalisasi temuan ke pasar berkembang lain masih memerlukan validasi empiris lebih lanjut.

IV. SIMPULAN

Penelitian ini mengusulkan dan mengevaluasi sebuah arsitektur *Transformer encoder-only* yang diintegrasikan dengan data multi-modal, mencakup data historis pasar saham, lintas aset (USD/IDR), dan indikator makroekonomi Indonesia, untuk memprediksi *realized volatility* jangka panjang pada Indeks Harga Saham Gabungan (IHSG). Kebaruan utama penelitian ini terletak pada penerapan arsitektur *Transformer* secara spesifik untuk tugas prediksi volatilitas jangka panjang di pasar berkembang yang belum banyak dieksplorasi dalam literatur, serta pada integrasi dimensi makroekonomi lokal yang selama ini sering diabaikan oleh model prediksi berbasis teknikal murni.

Hasil eksperimen pada data uji periode 2024-2025 menunjukkan bahwa model *Transformer* yang diusulkan secara konsisten mengungguli kedua model *baseline* pada horizon prediksi 21 hari. Model *Transformer* mencapai RMSE sebesar 0,0686 dan MAE sebesar 0,0490, lebih rendah ~21,2% dan ~36,3% dibandingkan LSTM, serta ~52,6% dan ~61,8% dibandingkan GARCH(1,1). Keunggulan ini dikonfirmasi secara kualitatif melalui visualisasi deret waktu yang menunjukkan kemampuan *Transformer* dalam mengikuti puncak dan lembah volatilitas aktual secara lebih responsif. Temuan ini menegaskan bahwa mekanisme *self-attention* yang memproses seluruh sekuens secara paralel memberikan keunggulan struktural yang signifikan dibandingkan pemrosesan sekuensial LSTM maupun model ekonometrik GARCH dalam menangkap dependensi non-linear jangka panjang dari data keuangan multi-modal.

Dari perspektif praktis, model ini menawarkan potensi aplikasi nyata dalam sistem manajemen risiko portofolio institusional, khususnya sebagai input dinamis untuk model *Value-at-Risk* dan strategi *risk hedging* di pasar modal Indonesia. Meskipun demikian, penelitian ini memiliki keterbatasan utama berupa belum diinkorporasikannya data sentimen pasar, yang diidentifikasi sebagai faktor yang dapat meningkatkan akurasi prediksi pada periode guncangan ekstrem. Oleh karena itu, penelitian lanjutan disarankan untuk mengeksplorasi model hibrida *Transformer* yang menggabungkan analisis sentimen berita keuangan, serta melakukan validasi lintas-pasar pada bursa berkembang lain seperti Bursa Malaysia atau Bursa Efek Vietnam untuk menguji generalisabilitas kerangka kerja yang diusulkan.

DAFTAR PUSTAKA

- [1] W. Ge, P. Lalbakhsh, L. Isai, A. Lensky, and H. Suominen, "Comparing Deep Learning Models for the Task of Volatility Prediction Using Multivariate Data," 2023. [Online]. Available: <https://arxiv.org/abs/2306.12446>
- [2] R. R. Khansama, R. Priyadarshini, S. K. Nanda, R. K. Barik, and M. J. Saikia, "SGR-Net: A Synergistic Attention Network for Robust Stock Market Forecasting," *Forecasting*, vol. 7, no. 3, p. 50, 2025.
- [3] A. A. Salisu, R. Gupta, and A. E. Ogbonna, "Point and Density Forecasting of Macroeconomic and Financial Uncertainties of the United States," *J. Forecast.*, vol. 40, pp. 700–707, 2021.
- [4] H. T. Araya, J. Aduda, and T. Berhane, "A Hybrid GARCH and Deep Learning Method for Volatility Prediction," *J. Appl. Math.*, vol. 2024, no. 1, p. 6305525, 2024.
- [5] S. S. Calik, A. Akyuz, Z. H. Kilimci, and K. Colak, "Explainable-AI powered stock price prediction using time series transformers: A Case Study on BIST100," 2025. [Online]. Available: <https://arxiv.org/abs/2506.06345>
- [6] 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.
- [7] L. Berti and G. Kasneci, "TLOB: A Novel Transformer Model with Dual Attention for Price Trend Prediction with Limit Order Book Data," 2025. [Online]. Available: <https://arxiv.org/abs/2502.15757>
- [8] A. Vaswani *et al.*, "Attention is All You Need," in *31st Conference on Neural Information Processing Systems (NIPS 2017)*, 2017, pp. 5998–6008.
- [9] T. Li, Z. Liu, Y. Shen, X. Wang, H. Chen, and S. Huang, "Market-Guided Stock Transformer for Stock Price Forecasting," in *The Thirty-Eighth AAAI Conference on Artificial Intelligence (AAAI-24)*, 2024, pp. 162–170.
- [10] X. Li, "A Market Information Prediction Model Based on the Transformer Architecture," in *SECA '25: Proceedings of the 2025 International Conference on Software Engineering and Computer Applications*, 2025, pp. 116–121.
- [11] T. Tu, "Bridging Short- and Long-Term Dependencies: A CNN-Transformer Hybrid for Financial Time Series Forecasting," 2025, [Online]. Available: <https://arxiv.org/abs/2504.19309>
- [12] Y. Liu *et al.*, "Revolutionising Financial Portfolio Management: The Non-Stationary Transformer's Fusion of Macroeconomic Indicators and Sentiment Analysis in a Deep Reinforcement Learning Framework," *Applied Sciences*, vol. 14, no. 1, 2024.