

Vector Autoregression, Long Short-Term Memory, dan Xgboost Dalam Kerangka Ensemble

Eddy Kurniawan^{1*)}, Budi Santoso²⁾, Elmayati³⁾

¹⁾²⁾³⁾Program Studi Teknik Informatika, Universitas Bina Insan

^{*)}Correspondence author: kurniawan.eddy.174@gmail.com, Indonesia

DOI: <https://doi.org/10.37012/jtik.v12i2.4028>

Abstract

Stock market volatility is a crucial indicator for risk assessment and investment decision-making, particularly for the S&P 500 index as a proxy for global financial markets. This study aims to forecast S&P 500 volatility by integrating macroeconomic and technical indicators using an ensemble approach. Daily data from March 18, 2015 to January 8, 2026 are employed. The input variables include macroeconomic indicators such as the Federal Funds Rate, Consumer Price Index, US Dollar Index, crude oil prices, and the Volatility Index (VIX), as well as technical indicators including log returns, realized volatility, moving averages, Relative Strength Index, and Moving Average Convergence Divergence. Realized volatility is computed using a 21-day rolling window and annualized. The proposed framework combines Vector Autoregression, Long Short-Term Memory networks, and XGBoost within an ensemble scheme. Empirical results indicate that the ensemble model produces more stable forecasts and outperforms classical econometric models. These findings highlight the effectiveness of combining macroeconomic and technical information for volatility forecasting and stock market risk management.

Keywords: S&P 500 volatility, Macroeconomic Indicators, Technical Indicators, Ensemble, XGBoost.

Abstrak

Volatilitas pasar saham merupakan indikator penting dalam pengukuran risiko dan pengambilan keputusan investasi, khususnya pada indeks S&P 500 sebagai representasi pasar global. Penelitian ini bertujuan untuk memprediksi volatilitas indeks S&P 500 berbasis indikator makroekonomi dan teknikal menggunakan pendekatan ensemble. Data yang digunakan berupa data harian periode 18 Maret 2015 hingga 8 Januari 2026. Variabel input mencakup indikator makroekonomi, yaitu Federal Funds Rate, Consumer Price Index, US Dollar Index, harga minyak mentah, dan indeks volatilitas (VIX), serta indikator teknikal seperti log return, realized volatility, moving average, Relative Strength Index, dan Moving Average Convergence Divergence. Volatilitas terealisasi dihitung menggunakan rolling window 21 hari dan dianualisasi. Metode yang digunakan mengombinasikan Vector Autoregression, Long Short-Term Memory, dan XGBoost dalam kerangka ensemble. Hasil pengujian menunjukkan bahwa model ensemble menghasilkan prediksi yang lebih stabil dan unggul dibandingkan model ekonometrika klasik. Temuan ini menunjukkan bahwa integrasi indikator makroekonomi dan teknikal efektif sebagai alat bantu peramalan volatilitas dan manajemen risiko pasar saham.

Kata Kunci: Volatilitas S&P 500, Indikator Makroekonomi, Indikator Teknikal, Ensemble, XGBoost.

PENDAHULUAN

Dalam beberapa tahun terakhir, dinamika pasar saham global semakin sulit diprediksi (Qiu et al., 2025). Pasca pandemi, kebijakan suku bunga agresif The Federal Reserve serta meningkatnya ketegangan geopolitik mendorong fluktuasi indeks seperti S&P 500 menjadi lebih tidak stabil (Merton et al., 2024). Kondisi ini menegaskan pentingnya analisis risiko, karena volatilitas merupakan indikator utama dalam penentuan harga derivatif, strategi lindung nilai, dan manajemen portofolio (Maingo et al., 2025). Pada kondisi sentimen negatif, pasar sering menunjukkan leverage effect, di mana berita buruk memicu lonjakan volatilitas yang lebih tajam dibandingkan berita baik (Qiu et al., 2025). Studi pada S&P 500 juga menunjukkan bahwa peramalan volatilitas yang akurat memiliki implikasi praktis dalam pengelolaan portofolio dan pengambilan keputusan investasi (Widiputra et al., 2021). Dengan demikian, pergerakan pasar tidak hanya dipengaruhi faktor ekonomi, tetapi juga ekspektasi dan persepsi investor (Roszyk & Ślepaczuk, 2024).

Penelitian terdahulu banyak menggunakan indikator makroekonomi seperti suku bunga, inflasi, harga minyak, dan nilai tukar untuk menjelaskan dinamika pasar (Qiu et al., 2025). Model Vector Autoregressive (VAR) menunjukkan bahwa hubungan antar variabel makro memiliki pengaruh signifikan terhadap pergerakan saham dalam jangka pendek maupun panjang (Hendajany & Wati, 2020). Namun, sebagian besar studi lebih berfokus pada return dibandingkan volatilitas, sehingga dimensi risiko belum dieksplorasi secara optimal. Di sisi lain, indikator teknikal seperti Moving Average dan RSI umum digunakan investor, tetapi cenderung bersifat reaktif dan kurang mampu menangkap pola nonlinier jangka panjang (Mostafavi & Hooman, 2025).

Model klasik seperti ARCH dan GARCH masih menjadi acuan dalam analisis volatilitas, meskipun memiliki keterbatasan dalam menghadapi perubahan struktur pasar saat krisis (Roszyk & Ślepaczuk, 2024). Perkembangan deep learning menawarkan alternatif yang lebih adaptif (Ghouse & Meharaz, 2025). LSTM terbukti mampu menangkap dependensi jangka panjang dan hubungan nonlinier dengan lebih baik dibandingkan model tradisional, dan kombinasi CNN-LSTM menunjukkan stabilitas prediksi yang lebih tinggi (Qiu et al., 2025), (Mochurad & Dereviannyi, 2024), (Widiputra et al., 2021), (Ma et al., 2024), (Widiputra et al., 2021). Selain itu, XGBoost dikenal efektif dalam memproses data berdimensi besar dengan interaksi fitur yang kompleks (Maingo et al., 2025), (Putratama et al., 2024), (Liwei et al., 2021). Meski demikian, penelitian yang mengintegrasikan indikator

makro dan teknikal dalam satu kerangka komprehensif untuk memprediksi volatilitas S&P 500 masih terbatas (Qiu et al., 2025).

Pendekatan ensemble menjadi solusi yang menjanjikan karena menggabungkan keunggulan model linier dan nonlinier (Widiputra et al., 2021), (Sari et al., 2025), (Kayit & Ismail, 2025). VAR mampu menjelaskan dinamika makro, LSTM menangkap pola temporal, dan XGBoost memodelkan hubungan kompleks antar fitur (Roszyk & Ślepaczuk, 2024), (Hendajany & Wati, 2020), (Hendajany & Wati, 2020), (Ghouse & Meharaz, 2025), (Mochurad & Dereviannyi, 2024), (Liwei et al., 2021), (Zhuo & Morimoto, 2024). Integrasi ini sejalan dengan pendekatan kuantitatif berbasis pengujian sistematis dalam pengambilan keputusan pasar (Simons, 2023), (Maulana, 2022). Oleh karena itu, penelitian ini mengusulkan model ensemble VAR-LSTM-XGBoost untuk meningkatkan akurasi dan stabilitas prediksi volatilitas S&P 500 dalam menghadapi kompleksitas pasar keuangan modern.

Volatilitas Pasar Saham

Volatilitas menggambarkan tingkat perubahan harga dalam periode tertentu dan menjadi indikator utama dalam pengukuran risiko pasar modal (Maulana, 2022). Dalam literatur keuangan, volatilitas berperan penting dalam penentuan harga derivatif, strategi lindung nilai, serta pengelolaan portofolio (Qiu et al., 2025). Pasar juga menunjukkan *leverage effect*, yaitu respons volatilitas yang lebih tajam terhadap berita buruk dibandingkan berita baik (Qiu et al., 2025). Pada indeks besar seperti S&P 500, karakteristik ini semakin relevan karena sensitivitasnya terhadap sentimen global dan kebijakan ekonomi (Roszyk & Ślepaczuk, 2024). Kajian terbaru menegaskan bahwa pemodelan volatilitas perlu mempertimbangkan *stylized facts* seperti *volatility clustering* dan *leverage effect*, serta perkembangan metode dari GARCH hingga LSTM dan Transformer (Ma et al., 2024). Artinya, pemilihan model tidak bisa dilepaskan dari sifat dasar volatilitas itu sendiri.

Model VAR-LSTM-XGBOOST

Vector Autoregressive (VAR) digunakan untuk menangkap hubungan dinamis antar variabel makroekonomi dan respons pasar terhadap shock ekonomi, termasuk kebijakan moneter (Hendajany & Wati, 2020). Namun, pendekatan linier saja sering kali belum cukup untuk menggambarkan pola nonlinier dalam data finansial. LSTM sebagai model *deep learning* mampu mengenali dependensi jangka panjang dan hubungan nonlinier dalam runtun waktu, sehingga relevan untuk memodelkan volatilitas yang memiliki pola kompleks (Widiputra et al., 2021). Di sisi lain, XGBoost dikenal efektif dalam mengolah data berdimensi tinggi dan

mampu mengungguli *Random Forest* maupun KNN dalam berbagai studi prediksi saham (Putratama et al., 2024). Kombinasi ketiga model ini membuka peluang integrasi antara dinamika linier, pola temporal, dan interaksi fitur yang kompleks.

Model *Ensemble/Hybrid*

Pendekatan *ensemble* bertujuan menggabungkan beberapa model untuk mengurangi error dan meningkatkan stabilitas prediksi (Mochurad & Dereviannyi, 2024). Bukti empiris pada indeks BEI menunjukkan bahwa kombinasi CNN-LSTM menghasilkan akurasi yang lebih baik dibanding model tunggal (Widiputra et al., 2021). Pendekatan GARCH-XGBoost juga terbukti mampu meningkatkan performa dengan memadukan dinamika linier dan nonlinier dalam satu kerangka terpadu (Maingo et al., 2025). Selain itu, penelitian lain menegaskan bahwa model *hybrid* antara neural network dan metode statistika cenderung lebih stabil saat pasar berada dalam kondisi tidak pasti (Zhuo & Morimoto, 2024). Temuan-temuan ini menguatkan bahwa integrasi model bukan sekadar tren metodologis, melainkan kebutuhan dalam menghadapi kompleksitas pasar modern.

Penelitian Terdahulu

Penelitian terdahulu merupakan kajian yang memiliki keterkaitan atau kemiripan dengan penelitian yang sedang dilakukan, baik dari segi topik, metode, maupun pendekatan yang digunakan. Dalam konteks penelitian ini, penelitian terdahulu mencakup berbagai studi sebelumnya yang membahas pemodelan volatilitas pasar saham, penggunaan metode ekonometrika seperti VAR, penerapan *deep learning* seperti LSTM dan CNN-LSTM, serta algoritma *machine learning* seperti XGBoost. Studi-studi tersebut memberikan landasan penting mengenai bagaimana model statistik, model berbasis urutan waktu, dan model *boosting* dapat digunakan untuk memahami dan memprediksi volatilitas di pasar keuangan. Beberapa tabel penelitian terdahulu antara lain sebagai berikut :

Tabel 1.
Penelitian Terdahulu


Peneliti	Hasil Utama
<i>“Prediksi indikator makro ekonomi Indonesia dengan model vector autoregressive periode 2019-2023”.</i> N. Hendajani & R. Reskatirini (2020)	IRF: return LQ45 negatif terhadap shock inflasi. FEVD: USD/IDR >20% kontribusi jangka panjang. Shock suku bunga signifikan negatif terhadap return.
<i>“On Stock Volatility Forecasting under -Mixed-Frequency Data Based on Hybrid RR-MIDAS and CNN-LSTM Models”.</i> W. Ma et al (2024)	Hybrid menurunkan RMSE 12,8% dibanding model tunggal dan unggul di seluruh horizon.
<i>“Multivariate CNN-LSTM Model for Multiple Parallel Financial Time-Series Prediction”.</i> H. Widiputra (2021)	Lebih stabil saat volatilitas tinggi (crash 2018). Meningkatkan akurasi melalui dependensi spasial-temporal.
<i>“A Fusion of Statistical and Machine Learning Methods: GARCH-XGBoost for Improved Volatility Modelling of the JSE Top40 Index”.</i> T. Maingo & W. Ndlovu (2025)	Hybrid menurunkan RMSE hingga 23,4% dan meningkatkan MAE, RMSE, MAPE.
<i>“Prediksi Harga Emas Menggunakan Jaringan Saraf Tiruan Algoritma Backpropagation”</i> Yupita Sari, Andri Anto Tri Susilo, Lukman Sunardi (2025)	MAE 8,22 pada prediksi harga emas (80:20 split). Mampu menangkap pola nonlinier.

METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif berbasis deret waktu untuk membangun model prediksi volatilitas indeks S&P 500. Model yang diusulkan mengintegrasikan pendekatan ekonometrika dan machine learning melalui skema ensemble VAR-LSTM-XGBoost. Tujuan utama penelitian adalah menghasilkan prediksi volatilitas yang lebih akurat dan stabil dengan memanfaatkan kombinasi indikator makroekonomi dan indikator teknikal.

Tahapan Penelitian

Proses penelitian mengikuti kerangka CRISP-DM yang diadaptasi untuk konteks peramalan volatilitas pasar saham. Tahapan utama meliputi:



Gambar 1. Kerangka Kerja CRISP-DM

Studi Literatur

Mengulas penelitian terdahulu terkait pemodelan volatilitas, VAR, LSTM, XGBoost, serta pendekatan ensemble dalam keuangan.

Pengumpulan Data

Data sekunder harian periode 18 Maret 2015 hingga 8 Januari 2026 sebanyak 2.722 observasi digunakan dalam penelitian ini. Dataset terdiri atas:

- Harga S&P 500 (OHLC dan volume)
- Indikator makro: FEDFUNDS, CPI, DXY, OIL, VIX
- Indikator teknikal: MA(10/20/50), RSI, MACD, ATR
- Data diperoleh dari Yahoo Finance, FRED, dan Investing.com.

Pra-pemrosesan Data

Harga penutupan ditransformasikan menjadi log-return. Volatilitas dihitung menggunakan squared log-return dengan pendekatan rolling 21 hari dan dianualisasi. Data distandardisasi menggunakan standarscaler untuk menjaga stabilitas numerik serta mencegah data leakage melalui pemisahan time-series split (80% training dan 20% testing).

Feature Engineering

Dibentuk fitur lag (1–30 hari) untuk return dan volatilitas. Untuk LSTM, data disusun dalam bentuk sequence window 30 hari. Seluruh fitur makro dan teknikal digabungkan dalam satu dataset terintegrasi.

Pemodelan

Model yang digunakan terdiri dari:

- VAR untuk menangkap hubungan linier antar variabel makro dan respons volatilitas terhadap shock.
- LSTM untuk mempelajari pola temporal non-linear jangka panjang.
- XGBoost untuk menangani interaksi fitur kompleks berbasis boosting.
- Prediksi dari masing-masing model digabungkan melalui weighted ensemble berbasis inverse-RMSE.

Evaluasi Model

Evaluasi dilakukan menggunakan RMSE, MAE, dan MAPE dengan pendekatan out-of-sample dan walk-forward validation guna memastikan reliabilitas hasil pada berbagai rezim volatilitas.

Arsitektur Sistem yang Diusulkan

Model dirancang dalam empat lapisan utama:

1. Input Layer
Data harga, indikator makroekonomi, dan indikator teknikal.
2. Preprocessing & Feature Engineering Layer
Transformasi log-return, perhitungan realized volatility (rolling 21 hari), standarisasi, pembentukan lag dan sequence window.
3. Modeling Layer
VAR (makro dynamics), LSTM (temporal learning), dan XGBoost (non-linear interaction).
4. Ensemble Layer
Penggabungan prediksi menggunakan weighted averaging untuk menghasilkan estimasi volatilitas akhir.

Struktur ini memungkinkan integrasi dinamika makro, pola temporal, dan hubungan non-linear secara simultan.

Formulasi Matematis Model

a. Realized Volatility

Log-return didefinisikan sebagai:

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

Realized volatility dengan jendela 21 hari dihitung sebagai:

$$RV_t = \sqrt{\frac{1}{n} \sum_{i=0}^{n-1} r_{t-i}^2} \times \sqrt{252}$$

dengan $n=21$ dan 252 sebagai faktor annualisasi.

b. Vector Autoregression (VAR)

$$Y_t = A_1 Y_{t-1} + A_2 Y_{t-2} + \dots + A_p Y_{t-p} + \varepsilon_t$$

di mana Y_t adalah vektor volatilitas dan variabel makro, A_i matriks koefisien, dan ε_t error term.

c. Long Short-Term Memory (LSTM)

Forget gate:

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

Cell state update:

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t$$

Output:

$$h_t = o_t \odot \tanh(C_t)$$

Struktur ini memungkinkan pemodelan dependensi jangka panjang dalam volatilitas.

d. XGBoost

$$\hat{y}_t = \sum_{k=1}^K f_k(x_t)$$

Fungsi objektif:

$$\mathcal{L} = \sum_t l(y_t, \hat{y}_t) + \sum_k \Omega(f_k)$$

e. Model Ensemble

$$w_i = \frac{1/RMSE_i}{\sum_{j=1}^3 (1/RMSE_j)}$$

dengan:

$$w_i = \frac{1/RMSE_i}{\sum_{j=1}^3 (1/RMS E_j)}$$

Model dengan error lebih kecil memperoleh bobot lebih besar.

Kontribusi Metodologis

Penelitian ini mengintegrasikan pendekatan ekonometrika dan machine learning dalam satu kerangka ensemble untuk prediksi volatilitas S&P 500. Berbeda dari studi yang menggunakan model tunggal atau kombinasi dua metode, pendekatan ini memadukan VAR untuk menjaga interpretabilitas makroekonomi, LSTM untuk menangkap dinamika temporal non-linear, dan XGBoost untuk mengelola interaksi fitur kompleks. Integrasi indikator makro dan teknikal dalam satu pipeline serta penggunaan weighted ensemble berbasis inverse-RMSE menghasilkan sistem prediksi yang lebih adaptif terhadap perubahan rezim pasar. Pendekatan ini memperkaya literatur peramalan volatilitas dengan menawarkan desain hybrid yang menggabungkan akurasi dan interpretabilitas secara simultan.

HASIL DAN PEMBAHASAN

Analisis Dataset dan Pra-Pemrosesan

Penelitian ini menggunakan data harian indeks S&P 500 periode 18 Maret 2015 hingga 8 Januari 2026 dengan total 2.722 observasi setelah proses pembersihan. Dataset mencakup 20 variabel utama yang terdiri atas harga (OHLC), volume, indikator makroekonomi (FEDFUNDS, CPI, DXY, OIL, VIX), serta indikator teknikal seperti MA, EMA, RSI, MACD, dan perubahan volume. Target prediksi adalah volatilitas satu langkah ke depan (*vol_target*).

Volatilitas dihitung dari *rolling* log-return 21 hari dan dianalisis menggunakan faktor $\sqrt{252}$. Baris awal yang mengandung nilai kosong akibat proses *rolling* dihapus untuk menjaga konsistensi data. Selain dataset utama, dibangun pula dataset khusus VAR yang memuat volatilitas dan variabel makro. Uji *Augmented Dickey-Fuller* memastikan stasioneritas, dengan pemilihan lag optimal berdasarkan AIC, BIC, FPE, dan HQIC. Residual VAR turut dimanfaatkan sebagai fitur untuk menangkap shock makro yang tidak dijelaskan secara linier.

```

Full df shape: (2722, 19)
date      Open      High      Low      Close      Adj Close \
2015-03-17 2080.590088 2080.590088 2065.080078 2074.200029 2074.200029
2015-03-18 2072.840088 2106.850098 2061.220088 2099.500000 2099.500000
2015-03-19 2098.689941 2098.689941 2085.560059 2089.270070 2089.270070
2015-03-20 2090.320068 2113.919922 2090.320068 2108.100098 2108.100098
2015-03-23 2107.989990 2114.860107 2104.419922 2104.419922 2104.419922

date      Volume      FEDFUNDS      CPI      DXY      OIL      VIX \
2015-03-17 3.221840e+09 0.11 234.747 99.599998 43.880001 15.61
2015-03-18 4.128210e+09 0.11 234.747 99.589996 43.459999 15.66
2015-03-19 3.385220e+09 0.11 234.747 98.550003 44.660000 13.97
2015-03-20 5.554120e+09 0.11 234.747 99.099998 43.959999 14.07
2015-03-23 3.267900e+09 0.11 234.747 97.910004 45.720001 13.02

date      log_return      realized_vol      ma_10      ma_20      ma_50 \
2015-03-17 -0.003326 0.114182 2070.947986 2089.815985 2060.034802
2015-03-18 0.012885 0.122134 2071.044083 2089.806989 2061.613203
2015-03-19 -0.004884 0.123204 2069.867981 2089.397992 2063.346404
2015-03-20 0.008972 0.127283 2073.551990 2089.287994 2064.990405
2015-03-23 -0.001747 0.125619 2076.850989 2089.025995 2065.836006

date      rsi_14      macd      macd_signal \
2015-03-17 39.784190 -0.492721 4.587930
2015-03-18 47.395975 1.527819 3.975908
2015-03-19 46.535642 2.277385 3.636203
2015-03-20 47.942457 4.340813 3.777125
2015-03-23 49.235714 5.614416 4.144583

Setelah tambah target: (2721, 20)
Train shape: (2177, 20)
Test shape: (544, 20)

Train periode: 2015-03-17 00:00:00 -> 2023-11-06 00:00:00
Test periode: 2023-11-07 00:00:00 -> 2026-01-08 00:00:00

```

Gambar 1. Ringkasan Struktur Data dan Periode *Train-Test*

Data dibagi 80% untuk pelatihan dan 20% untuk pengujian dengan skema *time-series split* guna menjaga validitas *out-of-sample*. Fitur dinormalisasi menggunakan *StandardScaler* berbasis data latih. Untuk LSTM, data dibentuk dalam *sequence* 30 hari, sedangkan XGBoost menggunakan format tabular dengan tambahan lag volatilitas. Integrasi makro dan teknikal dalam satu dataset menghasilkan representasi pasar yang lebih komprehensif.

Evaluasi Model

Kinerja model dibandingkan antara baseline (*Naive*, ARCH(1), GARCH(1,1), EGARCH(1,1)), LSTM, XGBoost, serta *ensemble* VAR-LSTM-XGBoost menggunakan RMSE, MAE, MAPE, dan QLIKE.

```

54/54 ————— 0s 6ms/step
13/13 ————— 0s 4ms/step
LSTM MSE Train: 0.001495 | MAE Train: 0.024393 | R2 Train: 0.8839
LSTM MSE Test : 0.015786 | MAE Test : 0.105332 | R2 Test : -2.3286

XGB MSE Train: 0.000026 | MAE Train: 0.003488 | R2 Train: 0.9980
XGB MSE Test : 0.000305 | MAE Test : 0.012133 | R2 Test : 0.9357

```

Gambar 2. Hasil Evaluasi MSE, MAE, dan R² Model LSTM dan XGBoost

Gambar 3 menunjukkan bahwa XGBoost non-tuning menjadi model individu terbaik dengan MSE $\approx 0,000305$, MAE 0,012133, dan R² 0,9357. LSTM mengalami *overfitting* dengan R² negatif pada data uji. Tuning hiperparameter XGBoost justru menurunkan performa sehingga konfigurasi awal dipertahankan.

Model ekonometrika klasik menghasilkan error lebih tinggi dan respons yang cenderung terlalu halus. LSTM mampu menekan error pada data latih namun gagal menjaga generalisasi. Karena itu, bobot *ensemble* ditentukan berbasis *inverse*-RMSE sehingga XGBoost memperoleh kontribusi lebih besar.

Hasil akhir menunjukkan bahwa *ensemble* menghasilkan RMSE dan MAE lebih rendah dibanding LSTM dan mendekati bahkan melampaui XGBoost pada metrik QLIKE. Distribusi residual lebih simetris di sekitar nol, mengindikasikan prediksi yang stabil tanpa bias sistematis.

Pembahasan

Validitas Data dan *Robustness*

Pendekatan analisis menggabungkan model statistik dan *machine learning* dengan integrasi indikator makro dan teknikal. Validitas dijaga melalui pembersihan data, standardisasi berbasis data latih, serta evaluasi out-of-sample.

Untuk menguji *robustness*, volatilitas diklasifikasikan ke dalam tiga rezim berdasarkan *threshold* historis ($\text{Vol} < 0,0918$; $0,0918 \leq \text{Vol} < 0,1847$; $\text{Vol} \geq 0,1847$).

2. VOLATILITY THRESHOLDS	
Low Volatility threshold:	$\text{Vol} < 0.0918$
Normal Volatility range:	$0.0918 \leq \text{Vol} < 0.1847$
High Volatility threshold:	$\text{Vol} \geq 0.1847$


Gambar 3. Klasifikasi Rezim Volatilitas (Low, Normal, High)

Gambar 4 memperlihatkan batas rezim tersebut. Evaluasi per rezim memperkuat validitas eksternal model karena kinerja diuji pada kondisi pasar yang berbeda.

Perbandingan Kinerja Model

	Model	RMSE	MAE	MAPE(%)	QLIKE
0	XGBoost (Tuned Feats)	0.018896	0.013039	6.365805	-2.472259
1	Ensemble (Weighted LSTM+XGB Tuned)	0.028002	0.020205	9.376124	-2.451426
2	Naive	0.094669	0.038162	4.222775	0.678341
3	EGARCH(1,1)	0.396715	0.235565	23.449600	0.869139
4	GARCH(1,1)	0.411606	0.236727	23.539860	0.874466
5	ARCH(1)	0.412979	0.284629	33.790836	0.887189
6	LSTM (Updated Feats)	0.125641	0.105332	54.718810	271.277226

Gambar 4. Perbandingan Kinerja Model Peramalan Volatilitas pada Data Uji




Gambar 5. Grafik *Actual vs Predicted Volatility* pada Periode Pengujian

Gambar 5-6 menunjukkan bahwa XGBoost dan *ensemble* unggul dibanding model klasik. *Naive* masih kompetitif pada kondisi normal namun gagal merespons lonjakan volatilitas. EGARCH menjadi terbaik di antara keluarga GARCH, tetapi tetap tertinggal dari model *machine learning*.


XGBoost Tuned mencatat RMSE 0,018896 dan QLIKE $-2,472259$, menurunkan error lebih dari 80% dibanding *Naive*. *Ensemble* berbobot LSTM-XGBoost berada sangat dekat dengan RMSE 0,028002 dan QLIKE $-2,451426$. Secara visual, kurva *ensemble* lebih stabil dan mengikuti pola aktual dengan baik.

Analisis Perilaku Model




Gambar 6. Kurva *Training* dan *Validation* MAE Model LSTM


Kurva training dan validation LSTM pada Gambar 7 menunjukkan gejala *overfitting*. Error latih turun tajam, tetapi error validasi stagnan. Hal ini menjelaskan mengapa LSTM tunggal kurang stabil pada data uji.



Gambar 7. Grafik *Volatility Prediction: Actual vs LSTM vs XGBoost*



Gambar 8. Scatter Plot *Actual vs Predicted XGBoost Ensemble* + garis perfect fit




Gambar 9. Histogram Distribusi *Error Ensemble*


Visualisasi pada Gambar 8 memperlihatkan bahwa XGBoost lebih adaptif terhadap lonjakan volatilitas dibanding LSTM yang cenderung bias *downward*. *Scatter* plot kalibrasi (Gambar 9) menunjukkan titik prediksi *ensemble* terkonsentrasi di sekitar garis diagonal, menandakan kalibrasi yang baik. Histogram residual (Gambar 10) memperlihatkan distribusi simetris dengan error ekstrem yang terbatas.

Rezim Pasar dan Implikasi Praktis

Analisis rezim menunjukkan sekitar 50% observasi berada pada kondisi normal, sedangkan low dan high masing-masing sekitar 25%.




Gambar 10. Matriks Transisi Rezim Volatilitas




Gambar 11. Visualisasi Rezim Volatilitas Historis S&P 500

Gambar 11 dan 12 menampilkan transisi rezim dengan persistensi tinggi (94–96%). Transisi normal ke *high volatility* hanya sekitar 2%, sehingga ketika model memproyeksikan dominasi rezim high selama 30 hari ke depan, hal tersebut dapat menjadi sinyal risiko signifikan bagi manajemen portofolio.



Gambar 12. Perbandingan Volatilitas Historis dan Proyeksi Ensemble 60 Hari ke Depan. Kinerja *ensemble* paling baik pada rezim normal ($RMSE \approx 0,4463$), cukup stabil pada high ($\approx 0,5503$), dan relatif lemah pada low karena level volatilitas sangat kecil. Proyeksi 30 hari menunjukkan kecenderungan menuju *high volatility* dengan estimasi kenaikan bertahap ke kisaran 0,10–0,11. Implikasinya jelas, strategi risiko perlu lebih konservatif dalam horizon jangka pendek.

Analisis Pengaruh Faktor Makro dan Teknikal



Gambar 13. Kontribusi Variabel Makro dan Teknikal terhadap Prediksi Volatilitas. Hasil *feature importance* XGBoost (Gambar 14) menunjukkan bahwa VIX menjadi variabel paling dominan dengan kontribusi sekitar 0,66. Temuan ini konsisten dengan teori bahwa VIX merepresentasikan ekspektasi risiko pasar dan sering disebut sebagai *fear index*. Dominasi VIX menegaskan bahwa volatilitas S&P 500 sangat dipengaruhi oleh persepsi risiko investor.

Indikator teknikal seperti MACD Signal ($\approx 0,13$) dan MA turut memberikan kontribusi signifikan. Hal ini menunjukkan bahwa momentum harga dan perubahan tren jangka pendek memiliki peran dalam pembentukan volatilitas. Temuan ini memperkuat literatur yang menyatakan bahwa volatilitas tidak hanya ditentukan faktor fundamental, tetapi juga dinamika teknikal pasar. Variabel makro seperti OIL, FEDFUNDS, dan CPI tetap berkontribusi meskipun dalam proporsi lebih kecil. Peran OIL mengindikasikan keterkaitan antara harga energi dan risiko pasar saham. Sementara itu, suku bunga dan inflasi berperan melalui mekanisme transmisi kebijakan moneter terhadap ekspektasi pasar.

Dari sisi model VAR, analisis *impulse response* menunjukkan bahwa shock pada suku bunga dan inflasi memicu respons volatilitas dalam beberapa periode berikutnya. Ini menunjukkan bahwa faktor makro bekerja lebih lambat namun memiliki efek struktural. Dengan demikian, hasil penelitian mengonfirmasi bahwa volatilitas S&P 500 terbentuk melalui kombinasi ekspektasi risiko jangka pendek, momentum teknikal, dan dinamika makroekonomi yang bersifat struktural.

KESIMPULAN DAN REKOMENDASI

Berdasarkan penelitian yang telah dilakukan mengenai *Prediksi Volatilitas Bursa Saham AS (S&P 500) Menggunakan Ensemble VAR-LSTM-XGBoost Berbasis Indikator Makro dan Indikator Teknikal*, dapat dirumuskan beberapa kesimpulan utama sebagai berikut:

1. Validitas Desain Eksperimen

Penggunaan 2.722 observasi harian S&P 500 periode 2015–2026 dengan integrasi indikator makro dan teknikal, serta evaluasi berbasis *time-series split* 80:20, menghasilkan pengujian *out-of-sample* yang realistis dan mencerminkan kondisi pasar aktual.

2. Keterbatasan Model Ekonometrika Klasik

ARCH(1), GARCH(1,1), dan EGARCH(1,1) masih mampu merepresentasikan dinamika dasar volatilitas, dengan EGARCH sebagai yang terbaik (RMSE 0,396715). Namun, model klasik menunjukkan keterlambatan dalam merespons lonjakan ekstrem dan menghasilkan error yang konsisten lebih tinggi dibanding pendekatan *machine learning*.

3. Evaluasi Model Deep Learning

LSTM mampu menangkap pola temporal jangka panjang, tetapi mengalami *overfitting* dan ketidakstabilan generalisasi. Walaupun terjadi perbaikan performa setelah optimasi fitur, nilai MAPE yang tinggi dan QLIKE ekstrem menunjukkan bahwa LSTM tunggal belum cukup robust untuk peramalan volatilitas.

4. Dominasi XGBoost dalam Akurasi Prediksi

XGBoost (*Tuned Feats*) menjadi model paling akurat dengan RMSE 0,018896 dan QLIKE -2,472259, menurunkan error lebih dari 80% dibanding model *Naive*. Temuan ini menegaskan bahwa hubungan non-linear dan interaksi fitur kompleks memainkan peran signifikan dalam pembentukan volatilitas pasar.

5. Keunggulan Struktural Model *Ensemble*

Ensemble berbobot LSTM-XGBoost menghasilkan RMSE 0,028002 dengan distribusi error yang lebih stabil dan residual yang simetris. Meskipun sedikit di bawah XGBoost murni dalam beberapa metrik, *ensemble* memberikan stabilitas prediksi yang lebih konsisten pada berbagai rezim volatilitas. Ini menunjukkan bahwa kombinasi model linier, temporal, dan *boosting* memberikan keseimbangan antara presisi dan *robustness*.

6. Analisis Rezim sebagai Validasi Eksternal

Dominasi rezim normal sekitar 50% dengan persistensi 94–96% memperkuat karakteristik *clustering* volatilitas. Proyeksi 60 hari ke depan yang mengarah pada *high volatility* mengindikasikan peningkatan risiko sistemik jangka pendek dan relevansi praktis model dalam konteks manajemen risiko.

7. Kontribusi Metodologis dan Novelty

Penelitian ini menawarkan integrasi simultan antara VAR untuk dinamika makro, LSTM untuk pembelajaran temporal, dan XGBoost untuk interaksi non-linear dalam satu kerangka *ensemble* berbobot berbasis *inverse*-RMSE. Pendekatan ini tidak hanya meningkatkan akurasi, tetapi juga mempertahankan interpretabilitas struktural pada level makroekonomi. Kombinasi ini memperluas literatur peramalan volatilitas dengan menghadirkan desain *hybrid* yang adaptif terhadap perubahan rezim pasar.

8. Keterbatasan dan Arah Pengembangan

Model masih bergantung pada data historis dan belum mengintegrasikan sentimen berita, faktor geopolitik real-time, maupun pendekatan *attention-based deep learning*.

Penelitian lanjutan dapat mengembangkan arsitektur berbasis Transformer atau menambahkan variabel sentimen untuk meningkatkan sensitivitas terhadap *shock* eksternal.

Secara keseluruhan, model *hybrid Ensemble* VAR-LSTM-XGBoost menunjukkan performa superior, stabilitas tinggi, dan relevansi praktis untuk mendukung pengambilan keputusan investasi dan pengelolaan risiko di pasar saham yang kompleks.

Saran

Untuk meningkatkan kualitas dan cakupan penelitian di masa mendatang, beberapa arah pengembangan dapat dipertimbangkan sebagai berikut:

1. Penambahan Variabel Eksternal

Integrasi variabel sentimen berita, indeks ketidakpastian ekonomi global, atau indikator geopolitik berpotensi meningkatkan sensitivitas model terhadap *shock* eksternal yang tidak sepenuhnya tercermin dalam data harga dan makro konvensional.

2. Eksplorasi Arsitektur *Deep Learning* Lanjutan

Penggunaan arsitektur seperti *Bidirectional* LSTM, GRU, atau mekanisme attention dapat dieksplorasi untuk meningkatkan kemampuan model dalam menangkap dependensi temporal yang lebih kompleks serta dinamika non-linear yang berubah cepat.

3. Integrasi dengan Ukuran Risiko Finansial

Output prediksi volatilitas dapat dikaitkan langsung dengan ukuran risiko seperti *Value at Risk* (VaR) dan *Expected Shortfall* agar hasil penelitian lebih aplikatif dalam konteks manajemen risiko dan regulasi keuangan.

4. Uji Generalisasi pada Aset dan Horizon Berbeda

Pengujian model pada indeks lain, komoditas, atau saham individual serta pada horizon prediksi berbeda akan membantu mengevaluasi kemampuan generalisasi dan ketahanan model di berbagai kondisi pasar.

5. Pendekatan Rezim yang Lebih Lanjut

Analisis rezim volatilitas dapat diperkaya menggunakan pendekatan *Markov Switching* atau teknik *clustering* berbasis data untuk menangkap perubahan struktur pasar secara lebih adaptif.

6. Implementasi Sistem Monitoring Praktis

Pengembangan dashboard pemantauan volatilitas berbasis model *ensemble* akan menjembatani hasil akademik dengan kebutuhan praktis industri, khususnya dalam pengelolaan risiko portofolio dan pengambilan keputusan investasi secara real-time.

REFERENSI

1. Ghouse, M. S., & Meharaz, I. S. (2025). Deep statistical fusion of LSTM and ARIMA for ESG-based financial risk and volatility forecasting. <https://doi.org/10.33425/3066-1226.1081>
2. Hendajany, N., & Wati, R. (2020). Prediksi indikator makro ekonomi Indonesia dengan model vector autoregressive periode 2019–2023. *Jurnal Ekonomi dan Bisnis*, 23(1), 189–202. <https://doi.org/10.24914/jeb.v23i1.2878>
3. Kayit, A. D., & Ismail, M. T. (2025). Leveraging hybrid ensemble models in stock market prediction: A data-driven approach. *Data Science in Finance and Economics*, 5(3), 355–386. <https://doi.org/10.3934/DSFE.2025015>
4. Liwei, T., Li, F., Yu, S., & Yuankai, G. (2021). Forecast of LSTM-XGBoost in stock price based on Bayesian optimization. *Intelligent Automation and Soft Computing*, 29(3), 855–868. <https://doi.org/10.32604/iasc.2021.016805>
5. Ma, W., Hong, Y., & Song, Y. (2024). On stock volatility forecasting under mixed-frequency data based on hybrid RR-MIDAS and CNN-LSTM models. *Mathematics*, 12(10). <https://doi.org/10.3390/math12101538>
6. Maingo, I., Ravele, T., & Sigauke, C. (2025). A fusion of statistical and machine learning methods: GARCH-XGBoost for improved volatility modelling of the JSE Top40 Index. *International Journal of Financial Studies*, 13(3). <https://doi.org/10.3390/ijfs13030155>
7. Maulana, Y. (2022). Pemodelan volatilitas indeks harga saham sektoral di Indonesia. *Jurnal Penelitian Universitas Kuningan*, 13. <https://doi.org/10.25134/logika.v13i01.5688>
8. Merton, R. C., Dai, W., & Pellerin, M. (2024). Forecasting and managing volatility: An S&P 500 case study. *Journal of Investment Management*. <https://ssrn.com/abstract=5013407>

9. Mochurad, L., & Dereviannyi, A. (2024). An ensemble approach integrating LSTM and ARIMA models for enhanced financial market predictions. *Royal Society Open Science*, 11(9), 240699. <https://doi.org/10.1098/rsos.240699>
10. Mostafavi, S. M., & Hooman, A. R. (2025). Key technical indicators for stock market prediction. *Machine Learning with Applications*, 20, 100631. <https://doi.org/10.1016/j.mlwa.2025.100631>
11. Putratama, G. A., Fahreza, S. M., & Ramandhani, Y. R. (2024). Comparative evaluation of machine learning methods for predicting stock price changes. *Antivirus: Jurnal Ilmiah Teknik Informatika*, 17(2), 278–285. <https://doi.org/10.35457/antivirus.v17i2.2871>
12. Qiu, Z., Kownatzki, C., Scalzo, F., & Cha, E. S. (2025). Historical perspectives in volatility forecasting methods with machine learning. *Risks*, 13(5). <https://doi.org/10.3390/risks13050098>
13. Roszyk, N., & Ślepaczuk, R. (2024). The hybrid forecast of S&P 500 volatility ensembled from VIX, GARCH and LSTM models. *arXiv*. <https://doi.org/10.48550/arXiv.2407.16780>
14. Sari, Y., Susilo, A. A. T., & Sunardi, L. (2025). Prediksi harga emas menggunakan jaringan saraf tiruan algoritma backpropagation. *Bulletin of Computer Science Research*, 5(4), 831–840. <https://doi.org/10.47065/bulletincsr.v5i4.566>
15. Simons, J. H. (2023). The masters series investment consulting. *A Reprinted Article from Journal of Investment Management*, 22(1). <https://ssrn.com/abstract=4668072>
16. Widiputra, H., Mailangkay, A., & Gautama, E. (2021a). Multivariate CNN-LSTM model for multiple parallel financial time-series prediction. *Complexity*, 2021, 9903518. <https://doi.org/10.1155/2021/9903518>
17. Widiputra, H., Mailangkay, A., & Gautama, E. (2021b). Prediksi indeks BEI dengan ensemble convolutional neural network dan long short-term memory. *Jurnal RESTI*, 5(3), 456–465. <https://doi.org/10.29207/resti.v5i3.3111>
18. Zhuo, Y., & Morimoto, T. (2024). A hybrid model for forecasting realized volatility based on heterogeneous autoregressive model and support vector regression. *Risks*, 12(1). <https://doi.org/10.3390/risks12010012>