



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 5 No. 2 (2026) pp: 13734-13742

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Analisis Kinerja Model Machine Learning untuk Memprediksi Data Deret Waktu: Sebuah Tinjaun

Irsan Hanafiah¹, Regiolina Hayami²

^{1,2} Fakultas Ilmu Komputer, Universitas Muhammadiyah Riau

¹220401219@student.umri.ac.id, ²regiolinahayami@umri.ac.id

Abstrak

Penelitian ini bertujuan untuk menganalisis kinerja model Machine Learning dan Deep Learning dalam memprediksi data deret waktu (time series) melalui pendekatan Systematic Literature Review (SLR). Kajian dilakukan terhadap 27 artikel ilmiah yang dipublikasikan pada periode 2020–2026 dan diperoleh dari berbagai basis data bereputasi, seperti Scopus, IEEE Xplore, ScienceDirect, MDPI, dan Google Scholar. Penelitian ini difokuskan pada identifikasi algoritma yang paling dominan digunakan, perbandingan kinerja antara model tunggal dan model hybrid, serta faktor-faktor yang memengaruhi peningkatan performa prediksi. Hasil kajian menunjukkan bahwa algoritma Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), dan Extreme Gradient Boosting (XGBoost) merupakan metode yang paling banyak digunakan karena mampu menangani pola temporal yang kompleks dan dinamis. LSTM unggul dalam menangkap ketergantungan jangka panjang, GRU menawarkan efisiensi komputasi yang lebih baik dengan tingkat akurasi yang sebanding, sedangkan XGBoost memiliki stabilitas tinggi dan kemampuan yang baik dalam mengatasi overfitting. Selain itu, model hybrid seperti CNN-LSTM, ARIMA-LSTM, Wavelet-GRU, dan Autoencoder-CNN-LSTM secara konsisten menunjukkan kinerja yang lebih unggul dibandingkan model tunggal berdasarkan metrik evaluasi RMSE, MAE, MAPE, dan SMAPE. Faktor-faktor seperti rekayasa fitur, pra-pemrosesan data, reduksi noise, optimasi hiperparameter, serta strategi ensemble dan hybrid terbukti berperan penting dalam meningkatkan akurasi prediksi. Dengan demikian, pendekatan hybrid dinilai lebih efektif dan andal dalam menangani karakteristik data deret waktu yang kompleks, nonlinier, volatil, dan mengandung ketidakpastian tinggi pada berbagai bidang aplikasi modern.

Kata Kunci: Data Deret Waktu, Machine Learning, Deep Learning, Model Hybrid, Prediksi.

1. Latar Belakang

Data time series merupakan bentuk data berurutan yang umumnya dihasilkan dan dikelola melalui sistem digital terdistribusi yang menjamin integritas serta keamanan informasi. Sistem tersebut menyimpan data dalam struktur blok yang saling terhubung dan terus bertambah, sehingga setiap perubahan dapat ditelusuri dan diverifikasi melalui mekanisme kriptografi untuk mencegah manipulasi data. Setiap blok merepresentasikan kumpulan data yang mencakup catatan transaksi, informasi waktu, serta nilai hash kriptografis dari blok sebelumnya sebagai penghubung antarblok (Javier et al., 2022). Proses pembentukan data dalam sistem ini melibatkan mekanisme validasi dan pembaruan berkelanjutan yang bertujuan memastikan konsistensi serta keandalan data historis. Memprediksi secara akurat perkembangan harga saham dan aset keuangan lainnya telah lama menjadi tujuan utama para pelaku investasi, baik sebagai sarana untuk memperoleh pendapatan tambahan maupun sebagai solusi jangka panjang dalam mengelola dan menyimpan nilai secara lebih produktif (Santos & Naranjo, 2024).

Pergerakan nilai pada data time series dapat dianalisis melalui dua pendekatan utama, yaitu analisis teknikal dan analisis fundamental (Rahmadayan, 2024). Analisis teknikal berfokus pada pola historis data dengan mengamati nilai masa lalu, seperti harga pembukaan, harga penutupan, volume, serta perubahan nilai pada setiap interval waktu, sedangkan analisis fundamental menitikberatkan pada identifikasi faktor eksternal dan internal yang memengaruhi perubahan nilai data tersebut. Pendekatan analisis teknikal secara khusus memanfaatkan karakteristik data time series untuk menangkap pola temporal dan tren yang berulang dalam rentang waktu tertentu (Singh & Shakya, 2020). Deep Learning merupakan salah satu pendekatan kecerdasan buatan yang memungkinkan sistem komputasi untuk memproses, mengelola, dan menganalisis data secara mendalam melalui pembelajaran berlapis. Pendekatan ini merupakan bagian dari Machine Learning yang memanfaatkan jaringan saraf tiruan sebagai dasar pemodelannya. Salah satu teknik Deep Learning, yaitu Long Short-Term Memory

(LSTM), dirancang untuk menangani ketergantungan jangka panjang pada data time series sehingga efektif digunakan dalam pemodelan dan prediksi data berurutan berbasis waktu

Oleh karena itu, berbagai teknik Kecerdasan Buatan (Artificial Intelligence/AI) telah dikembangkan untuk melakukan prediksi data time series secara otomatis. Penelitian awal mengenai prediksi otomatis berbasis pembelajaran mesin diperkirakan mulai dilakukan pada tahun 1994 melalui studi perbandingan berbagai model regresi dalam machine learning (Kristiyanti et al., 2024). Seiring perkembangan tersebut, banyak penelitian berupaya merancang strategi prediksi otomatis yang mampu menangkap pola kompleks pada data time series berskala besar, namun kinerja model sangat bergantung pada kualitas dan representasi data masukan (Dubey & Enke, 2025). Data time series umumnya memiliki karakteristik fluktuatif dan cenderung menyerupai pergerakan acak, sehingga proses ekstraksi dan pengolahan fitur menjadi lebih kompleks. Meskipun demikian, model Deep Learning mampu mempelajari pola langsung dari data mentah tanpa memerlukan rekayasa fitur secara terpisah, sehingga pendekatan ini banyak digunakan untuk memprediksi nilai dan tren data time series berdasarkan kumpulan data historis yang besar.

Penelitian ini bertujuan untuk melakukan tinjauan literatur sistematis studi Deep Learning ataupun Machine Learning mengenai prediksi data time series. Kajian ini mengidentifikasi perkembangan metode, perubahan pendekatan, keterbaruan model yang digunakan, serta potensi arah penelitian kedepan. Kontribusinya memperkaya literatur ilmiah dengan menyajikan analisis-analisis mengenai penggunaan Deep Learning dan Machine Learning di data time series.

2. Metode Penelitian

Metode yang digunakan dalam penelitian adalah Systematic Literature Review (SLR). Systematic Literature Review adalah metode penelitian yang dilakukan dengan cara mengidentifikasi, mengevaluasi, dan menginterpretasi semua penelitian yang tersedia dan relevan dengan pertanyaan penelitian tertentu (Sholeh et al., 2025). Tahapan Penelitian ini mengacu pada pedoman standar yang terdiri dari dua fase utama yaitu: Planning (Perencanaan) dan Search Strategy Literature (Strategi Pencarian Literatur).

Tahapan Perencanaan

Pada tahap ini dilakukan identifikasi kebutuhan tinjauan Pustaka dan perumusan pertanyaan penelitiann (Research Questions) untuk memandu proses pencarian literatur. Berdasarkan latar belakang masalah, ditetapkan tiga pertanyaan penelitian utama yang disajikan dalam tabel berikut:

Tabel 1 Pertanyaan Penelitian

Kode	Pertanya Penelitian
RQ1	Algoritma machine learning apa saja yang paling dominan dan sangat efektif digunakan dalam memprediksi data time series?
RQ2	Bagaimana perbandingan kinerja model tunggal seperti LSTM, GRU, atau XGBoost dibandingkan dengan model hybrid berdasarkan metrik akurasi?
RQ3	Faktor – faktor apa saja yang mempengaruhi dalam peningkatan kinerja suatu model?

Strategi Pencarian Literatur

Proses pengumpulan literatur dilakukan melalui pendekatan sistematis guna menjaring studi-studi relevan terkait prediksi data time series. Sebagai rujukan primer, penelusuran difokuskan pada database Internasional bereputasi tinggi di ranah ilmu komputer dan keungan, yakni Scopus, ScienceDirect, MDPI dan IEEE Xplore. Untuk memaksimalkan cakupan referensi, penelusuran sekunder turut dilakukan melalui Google Scholar guna mengakomodasi artikel signifikan yang mungkin tidak terindeks pada basis data utama.

Ekstraksi Data

Proses ekstraksi data dilakukan untuk mengumpulkan informasi dari artikel-artikel penelitian yang terpilih guna menjawab pertanyaan penelitian secara sistematis. Menyajikan ringkasan hasil pencarian literatur dari tahap awal hingga tahap akhir.

3. Hasil dan Diskusi

1. Hasil

Setelah menyelesaikan tahap perencanaan dan strategi pencarian literatur, ditemukan sebanyak 27 artikel untuk menjawab pertanyaan penelitian. Selanjutnya pertanyaan–pertanyaan kunci yang dianggap signifikan dalam artikel-artikel tersebut dicatat, termasuk poin-poin yang berkaitan dengan manfaat dan hasil penelitian.

Tabel ini merangkum 27 artikel yang digunakan sebagai sumber utama dalam penulisan artikel ini. Tabel tersebut menyajikan rincian mengenai model algoritma yang digunakan, objek serta jenis dataset yang digunakan, dan hasil evaluasi kinerja model tersebut. Analisa ini mencakup perbandingan efektivitas dan ketahanan antar model, memberikan gambaran komprehensif mengenai kemampuan masing-masing algoritma dalam menangani kasus data deret waktu, baik pada pasar mata uang digital maupun pada sektor lain dengan karakteristik serupa yang disajikan dalam tabel berikut.

Tabel 1 Ringkasan Artikel

No	Penulis	Algoritma	Objek	Hasil
1	(Riziq et al., 2025)	LSTM vs SVR	Bitcoin, Ethereum (Yahoo Finance)	LSTM memiliki kinerja terbaik dengan nilai <i>error</i> (MAE/MSE) terendah dibanding SVR dalam memprediksi harga kripto.
2	(Dubey & Enke, 2025)	CNN-LSTM, TCN	Bitcoin (<i>On-chain Data</i>)	Penggunaan fitur <i>on-chain</i> dikombinasikan dengan <i>feature selection</i> pada CNN-LSTM efektif memprediksi arah harga.
3	(Santos & Naranjo, 2024)	GRU, LSTM	Ethereum (Market Data)	Pengembangan strategi investasi berbasis prediksi GRU/LSTM yang hanya mengandalkan data historis dan 13736ndicator pasar.
4	(Li et al., 2026)	Bi-LSTM Wavelet	Saham (Data Time-Series)	Transformasi <i>Wavelet</i> sangat penting untuk mereduksi <i>noise</i> pada data keuangan, meningkatkan akurasi model Bi-LSTM secara signifikan.

5	(Kristiyanti et al., 2024)	LSTM	Saham Transportasi (Indonesia)	LSTM terbukti mampu memodelkan pergerakan harga saham sektor transportasi yang dipengaruhi inflasi.
6	(Singh & Shakya, 2020)	GRU vs LSTM vs RNN	Saham Perbankan (NEPSE)	GRU ditemukan lebih sukses dan efisien dalam prediksi harga saham dibandingkan LSTM dan RNN standar pada <i>look-back period</i> tertentu.
7	(Echabarri & Do, 2026)	XGBoost Hybrid Transformer-GRU	Energi (<i>Fuel Cells</i>)	XGBoost efektif untuk ekstraksi indikator kesehatan (<i>feature extraction</i>), sedangkan GRU menangani prediksi sisa umur (<i>time-series</i>) pada kondisi dinamis.
8	(Obra & Miwa, 2026)	Multi-step LSTM	Nuklir (Sistem Reaktor)	LSTM mampu menggantikan perhitungan fisika yang berat untuk prediksi <i>real-time</i> dengan akurasi tinggi pada sistem yang kompleks.
9	(Yang et al., 2025)	Hybrid KPCA-LSTM	Kesehatan (Sinyal EEG)	Kombinasi KPCA (reduksi dimensi) dan LSTM sangat handal menangkap fitur non-linear pada data sinyal otak yang rumit.
10	(Rajesh et al., 2023)	Deep Learning (ReLU + SGD)	Medis (Sel Tumor)	Penerapan fungsi aktivasi ReLU dengan optimasi SGD mempercepat konvergensi model <i>Deep Learning</i> pada klasifikasi data sel tunggal.
11	(Nadarajah et al., 2025)	XGBoost	Bitcoin (Volatilitas)	Optimasi <i>hyperparameter</i> menggunakan metode Bayesian pada XGBoost terbukti meningkatkan akurasi prediksi volatilitas Bitcoin secara signifikan.

12	(Alkayes & Sugihartono, 2025)	XGBoost vs LSTM	Saham (Tesla)	Membandingkan XGBoost yang unggul dalam kecepatan komputasi dengan LSTM yang lebih sensitif terhadap pola temporal jangka panjang pada saham volatil.
13	(Rahmadeyan, 2024)	GRU vs LSTM	Saham (BBRI - Perbankan)	Algoritma GRU terbukti menjadi model terbaik dengan <i>error</i> (MSE) terendah dan komputasi lebih efisien dibanding LSTM untuk saham perbankan.
15	(Tightiz et al., 2025)	XGBoost	Energi (Harga Listrik)	Model XGBoost yang dioptimalkan dengan fitur koreksi <i>error</i> mampu mengungguli model ARIMA-LSTM dalam memprediksi harga listrik yang fluktuatif.
16	(Xu et al., 2022)	GRU + Wavelet + Attention	Agrikultur (CO2 Time-series)	Integrasi Transformasi Wavelet dan mekanisme Attention pada GRU sangat efektif menangani akumulasi error pada prediksi jangka panjang
17	(Badar et al., 2025)	Hybrid CNN-LSTM dengan Autoencoder	Harga Cryptocurrency (Bitcoin, dkk.)	Penggunaan Autoencoder untuk mereduksi noise sebelum diproses oleh CNN-LSTM berhasil menurunkan nilai MAE hingga 0.008, lebih akurat dibanding LSTM standar.
19	(Hasanli, 2025)	XGBoost, Random Forest, LSTM, ANN	Bitcoin (BTC), Ethereum (ETH), Ripple (XRP)	Model Ensemble (Random Forest & XGBoost) dengan indikator teknikal berdimensi tinggi mencapai akurasi 95%, mengungguli model Deep Learning tunggal.
20	(Qureshi et al., 2024)	Hybrid ARIMA-LSTM, ETS-LSTM	Harga Harian Bitcoin	Model hibrida yang menggabungkan statistik linear

				(ARIMA) dan non-linear (LSTM) terbukti lebih unggul dalam menangani volatilitas ekstrim dibandingkan model tunggal.
22	(Chen, 2023)	Random Forest vs. LSTM	Harga Bitcoin (Data Harian)	Untuk prediksi jangka pendek (keesokan hari), Random Forest menghasilkan error (RMSE/MAPE) yang lebih rendah dibandingkan LSTM, membuktikan efisiensi model tree-based.
24	(Sebastião & Godinho, 2021)	Ensemble Learning (RF, SVM, Linear)	Bitcoin, Ethereum, Litecoin (2015–2019)	Strategi Ensemble (gabungan 5 model) menghasilkan Sharpe Ratio tertinggi dan risiko (drawdown) terendah saat kondisi pasar berubah dari bullish ke bearish.
25	(Jaquart et al., 2021)	RNN, LSTM, GRU, XGBoost	Bitcoin (Data frekuensi tinggi 1–60 menit)	Pada data high-frequency, XGBoost terbukti lebih stabil dan kompetitif dibandingkan jaringan saraf tiruan yang kompleks, terutama untuk validasi silang.
26	(Derbentsev, 2020)	Ensemble (Gradient Boosting, Random Forest)	Harga Cryptocurrency	Pendekatan Ensemble terbukti lebih tahan (robust) terhadap overfitting pada dataset terbatas dibandingkan model tunggal konvensional.

2. Pembahasan

Bagian ini menyajikan analisis kritis dan sintesis terhadap temuan dari literatur saat ini untuk menjawab tiga pertanyaan penelitian utama. Analisis didasarkan pada studi nyata yang dipublikasikan dalam waktu rentang lima tahun terakhir.

Algoritma Machine Learning yang dominan dan efektif (RQ1)

Algoritma berbasis Recurrent Neural Network (RNN), khususnya Long Short-Term Memory (LSTM), masih mendominasi penerapan metode prediksi data time series dalam penelitian terkini (Chen, 2023). Hasil penelitian menunjukkan bahwa LSTM secara konsisten mengungguli model statistik klasik seperti ARIMA serta model Machine Learning seperti Support Vector Machine dalam memprediksi nilai harian data time series. Keunggulan tersebut terutama disebabkan oleh mekanisme *forget gate* pada LSTM yang memungkinkan model

DOI: <https://doi.org/10.31004/riggs.v5i2.11037>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

menangkap ketergantungan jangka panjang dari data historis, sehingga efektif dalam mengidentifikasi pola tren jangka menengah yang bersifat kompleks. Selain LSTM, Gated Recurrent Unit (GRU) juga diidentifikasi sebagai algoritma yang memiliki performa tinggi dalam pemodelan data time series. GRU mampu menghasilkan tingkat akurasi yang sebanding dengan LSTM, ditunjukkan oleh nilai Root Mean Square Error (RMSE) yang hampir identik, namun dengan waktu pelatihan yang sekitar 30% lebih cepat akibat arsitekturnya yang lebih sederhana dan efisien.

Untuk skenario yang membutuhkan efisiensi tinggi, algoritma Extreme Gradient Boosting (XGBoost) muncul sebagai algoritma yang efektif (Jaquart et al., 2021). Penelitian tersebut menguji XGBoost pada data berfrekuensi tinggi dengan interval 1 hingga 60 menit dan menunjukkan bahwa algoritma ini memiliki stabilitas validasi yang lebih baik dibandingkan model Neural Network. Studi komparatif juga mengungkapkan bahwa algoritma berbasis ensemble, termasuk XGBoost, memiliki ketahanan yang lebih tinggi terhadap overfitting pada dataset berukuran terbatas dibandingkan dengan arsitektur Deep Learning yang kompleks (Derbentsev, 2020). Meskipun LSTM unggul dalam menangkap arah dan pola tren jangka panjang, XGBoost dinilai lebih praktis untuk implementasi prediksi data time series pada sistem transaksi karena keunggulannya dalam efisiensi waktu eksekusi dan stabilitas kinerja (Sebastião & Godinho, 2021).

Perbandingan Kinerja Berbasis Metrik Evaluasi (RQ2)

Pendekatan model hybrid secara konsisten menunjukkan kinerja prediksi yang lebih unggul dibandingkan model tunggal, ditunjukkan oleh nilai kesalahan yang lebih rendah pada metrik RMSE, MAE, dan MAPE. Kelemahan utama model tunggal terletak pada sensitivitasnya terhadap noise serta keterbatasannya dalam merepresentasikan pola kompleks secara menyeluruh pada data time series yang fluktuatif (Badar et al., 2025). Membuktikan hal ini melalui pengembangan model hybrid CNN-LSTM yang dilengkapi Autoencoder. Dalam pengujian ini, model tunggal LSTM cenderung mengalami overfitting pada data fluktuatif. Namun, dengan memanfaatkan Autoencoder untuk mengurangi noise dan CNN untuk mengekstraksi fitur sebelum diproses oleh LSTM, model hybrid ini berhasil menurunkan nilai Mean Absolute Error (MAE) secara signifikan yang membuktikan bahwa pra-pemrosesan fitur adalah kunci akurasi.

Evaluasi yang dilakukan menunjukkan bahwa model hybrid yang dibangun berdasarkan metode simple averaging dari model Machine Learning dan Time Series, mengungguli model tunggal dalam berbagai metrik kesalahan seperti RMSE, MAE, MAPE, dan SMAPE (Qureshi et al., 2024). Hasilnya, pendekatan hybrid ini mencatatkan tingkat akurasi prediksi yang jauh lebih tinggi dibandingkan jika model tersebut dijalankan secara terpisah. Model Machine Learning dengan indikator teknis berdimensi tinggi (High Dimensional Technical Indicators) dan diterapkan dalam kerangka kerja hybrid, mampu mengungguli model baseline standar dalam memprediksi arah pergerakan harga Bitcoin (Hasanli, 2025). Hal ini menegaskan bahwa kolaborasi antara arsitektur algoritma yang kuat dan fitur data yang kaya adalah faktor penentu dalam meminimalisir error prediksi.

Faktor Peningkatan Kinerja Model (RQ3)

Faktor pertama yang paling berpengaruh adalah rekayasa fitur (feature engineering). Menunjukkan bahwa pemilihan fitur yang relevan melalui proses feature selection secara signifikan meningkatkan kinerja model prediksi pada data deret waktu yang kompleks (Dubey & Enke, 2025). Dalam konteks time series, penggunaan fitur turunan seperti indikator statistik, lag variables, moving average, serta transformasi domain waktu dan frekuensi terbukti membantu model dalam menangkap pola tersembunyi yang tidak dapat dipelajari secara langsung dari data mentah. Temuan ini juga diperkuat oleh (Hasanli, 2025), yang menyatakan bahwa fitur berdimensi tinggi memberikan kontribusi besar terhadap peningkatan akurasi model Machine Learning, terutama pada algoritma berbasis ensemble.

Faktor kedua adalah pra-pemrosesan data, yang mencakup normalisasi, penanganan data hilang, serta reduksi noise. Data time series umumnya bersifat non-stasioner dan sangat dipengaruhi oleh fluktuasi acak. Membuktikan bahwa penerapan transformasi Wavelet sebelum pemodelan Bi-LSTM mampu mereduksi noise secara signifikan dan meningkatkan akurasi prediksi. Selain itu, (Badar et al., 2025) menunjukkan bahwa penggunaan Autoencoder sebagai tahap pra-pemrosesan dapat mengekstraksi representasi data yang lebih bersih sebelum diproses oleh model utama, sehingga mengurangi risiko overfitting dan meningkatkan kemampuan generalisasi model.

Faktor ketiga yang tidak kalah penting adalah strategi penggabungan model (hybrid dan ensemble). Model hybrid dirancang untuk mengombinasikan keunggulan dari beberapa pendekatan pemodelan dalam satu kerangka kerja. Menunjukkan bahwa penggabungan model statistik linear dan model non-linear berbasis Machine Learning mampu menghasilkan prediksi yang lebih akurat dibandingkan model Tunggal (Qureshi et al., 2024). Hal ini disebabkan oleh kemampuan model hybrid dalam membagi peran pemodelan, di mana komponen linear dan non-linear pada data time series dapat ditangani secara lebih optimal. Selain itu, model berbasis Machine Learning seperti XGBoost menunjukkan kinerja yang kompetitif dalam beberapa studi, meskipun dalam penelitian ini model hybrid berbasis averaging menghasilkan error yang lebih rendah dan konsistensi yang lebih baik dibanding model tunggal (Qureshi et al., 2024).

4. Kesimpulan

Studi literatur sistematis ini menunjukkan bahwa prediksi data time series dengan karakteristik nonlinier, volatil, dan mengandung noise tinggi memerlukan pendekatan pemodelan yang adaptif dan robust. Berdasarkan hasil penelitian dapat disimpulkan bahwa: Model tunggal berbasis Machine Learning dan Deep Learning, seperti LSTM, GRU, dan XGBoost, terbukti mampu memberikan kinerja prediksi yang kompetitif, namun masing-masing memiliki keterbatasan dalam menangani kompleksitas data secara menyeluruh. LSTM unggul dalam menangkap ketergantungan jangka panjang, GRU menawarkan efisiensi komputasi yang lebih baik. Model hybrid seperti CNN-LSTM, CNN-LSTM dengan Autoencoder, dan Wavelet-GRU secara konsisten mengungguli model tunggal berdasarkan metrik evaluasi seperti RMSE, MAE, dan MAPE. Keunggulan tersebut diperoleh melalui penggabungan mekanisme pemodelan linear dan nonlinier, pemanfaatan pra-pemrosesan untuk reduksi noise, serta penerapan rekayasa fitur yang lebih representatif. Selain itu, strategi ensemble dan hybrid terbukti meningkatkan kemampuan generalisasi model dalam menghadapi fluktuasi data time series yang ekstrem. Pendekatan model hybrid merupakan solusi yang lebih efektif dan andal untuk prediksi data time series dibandingkan penggunaan model tunggal. Studi ini diharapkan dapat menjadi referensi konseptual bagi peneliti selanjutnya dalam merancang arsitektur prediksi yang optimal serta mendorong pengembangan metode hybrid yang lebih inovatif dan efisien di masa mendatang

Referensi

1. Alkayes, A. F., & Sugihartono, T. (2025). *Perbandingan Algoritma XGBoost dan LSTM dalam Prediksi Harga Saham Tesla Menggunakan Data Tahun 2025* *Abstrak Comparison of XGBoost and LSTM Algorithms in Tesla Stock Price Prediction Using 2025 Data Abstract*. 5(6), 1563–1573.
2. Almeida, J., & Gaspar, R. M. (2021). *Accuracy of European Stock Target Prices* *†*.
3. Badar, W., Ramzan, S., Raza, A., Fitriyani, N. L., Syafrudin, M., & Lee, S. W. (2025). *Enhanced Interpretable Forecasting of Cryptocurrency Prices Using Autoencoder Features and a Hybrid CNN-LSTM Model*. 1–22.
4. Chen, J. (2023). *Analysis of Bitcoin Price Prediction Using Machine Learning*.
5. Derbentsev, V. (2020). *Forecasting Cryptocurrency Prices Using Ensembles-Based Machine Learning Approach*. 707–712.
6. Dubey, R., & Enke, D. (2025). *Machine Learning with Applications Bitcoin price direction prediction using on-chain data and feature selection. Machine Learning with Applications*, 20(May), 100674. <https://doi.org/10.1016/j.mlwa.2025.100674>
7. Echabbari, S., & Do, P. (2026). *AI-enhanced RUL prediction of PEMFCs under dynamic operating conditions using XGBoost-based HI extraction and hybrid transformer-GRU model. Reliability Engineering and System Safety*, 269(December 2025), 112042. <https://doi.org/10.1016/j.res.2025.112042>
8. Hasanli, R. (2025). *Integrating High-Dimensional Technical Indicators into Machine Learning Models for Predicting Cryptocurrency Price Movements and Trading Performance : Evidence from Bitcoin , Ethereum , and Ripple*. 1–29.
9. Jaquart, P., Dann, D., & Weinhardt, C. (2021). *ScienceDirect Short-term bitcoin market prediction via machine learning. The Journal of Finance and Data Science*, 7, 45–66. <https://doi.org/10.1016/j.jfds.2021.03.001>
10. Javier, F., Corral, G., Antonio, J., García, C., Valenciano, J. D. P., & Toril, J. U. (2022). *A bibliometric review of cryptocurrencies : how have they grown ? Financial Innovation*. <https://doi.org/10.1186/s40854-021-00306-5>
11. Kristiyanti, D. A., Bayu, W., Pramudya, N., & Sanjaya, S. A. (2024). *International Journal of Information How can we predict transportation stock prices using artificial intelligence ? Findings from experiments with Long Short-Term Memory based algorithms. International Journal of Information Management Data Insights*, 4(2), 100293. <https://doi.org/10.1016/j.jjimei.2024.100293>
12. Li, H., Marudhasalam, Y., & Huang, Z. (2026). *Engineering Applications of Artificial Intelligence The importance of data noise reduction – wavelet transformation in stock price forecasting with Bidirectional Long Short-Term Memory network. Engineering Applications of Artificial Intelligence*, 165(PA), 113390. <https://doi.org/10.1016/j.engappai.2025.113390>
13. Nadarajah, S., Mba, J. C., Manda, N., Ravonimanantsoa, V., Rakotomaroahy, P., & Ratolojanahary, H. T. J. E. (2025). *Empirical Calibration of XGBoost Model Hyperparameters Using the Bayesian Optimisation Method : The Case of Bitcoin Volatility*. 1–18.
14. Obra, J., & Miwa, S. (2026). *Progress in Nuclear Energy Real-time pipe break extent prediction for loss of coolant accidents in pressurized water reactors using a multi-step forecast-assisted long short-term memory model. Progress in Nuclear Energy*, 192(November 2025), 106148. <https://doi.org/10.1016/j.pnucene.2025.106148>
15. Paskaleva, M., & Vasenska, I. (2025). *The BTC Price Prediction Paradox Through Methodological Pluralism*. 1–43.
16. Qureshi, M., Iftikhar, H., Rodrigues, P. C., Rehman, M. Z., & Salar, S. A. A. (2024). *Statistical Modeling to Improve Time Series Forecasting Using Machine Learning , Time Series , and Hybrid Models : A Case Study of Bitcoin Price Forecasting*. 1–15.
17. Rahmadayan, A. (2024). *ScienceDirect ScienceDirect Long Short-Term Short-Term Memory Memory and and Gated Gated Recurrent Recurrent Unit Unit for for Stock Stock Price Prediction Prediction. Procedia Computer Science*, 234, 204–212. <https://doi.org/10.1016/j.procs.2024.02.167>

DOI: <https://doi.org/10.31004/riggs.v5i2.11037>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

18. Rajesh, M., Senapati, B., Das, R., Martha, S., & Martha, S. (2023). ScienceDirect Identifying Colorectal Tumor For Single Cell RNA Sequence Using Identifying Colorectal For Stochastic Single Cell RNA Sequence Rectified Linear Tumor Unit With Gradient Descent Using Rectified Linear Unit With Stochastic Gradient Descent. *Procedia Computer Science*, 218, 189–198. <https://doi.org/10.1016/j.procs.2023.01.001>
19. Riziq, I. F., Dzikrillah, A. R., & Informatika, T. (2025). *Impelementasi Algoritma LSTM Dan SVR Untuk Prediksi Harga Bitcoin Menggunakan Data Yahoo Finance*. 284–291. <https://doi.org/10.47002/metik.v9i2.1077>
20. Santos, M., & Naranjo, R. (2024). *Knowledge-Based Systems Machine learning Ethereum cryptocurrency prediction and knowledge-based investment strategies*. 299(March). <https://doi.org/10.1016/j.knosys.2024.112088>
21. Sebastião, H., & Godinho, P. (2021). Forecasting and trading cryptocurrencies with machine learning under changing market conditions. *Financial Innovation*. <https://doi.org/10.1186/s40854-020-00217-x>
22. Sholeh, M. B., Samodra, R. F., & Widodo, A. P. (2025). *Benefits and Challenges of ERP Implementation in Higher Education Institutions : A Systematic Literature Review*. 01, 126–138.
23. Singh, A., & Shakya, S. (2020). ScienceDirect ScienceDirect Analysis of look back period for stock price prediction with Analysis of look back period price prediction with RNN variants : A case study for on stock banking sector of NEPSE RNN variants : A case study on banking sector of NEPSE. *PROCS*, 167(2019), 788–798. <https://doi.org/10.1016/j.procs.2020.03.419>
24. Tightiz, L., Yoo, J., & Al-shibli, W. K. (2025). Results in Engineering Strategic enhancements in electricity price forecasting : The role of XGBoost and error correction features. *Results in Engineering*, 26(April), 105609. <https://doi.org/10.1016/j.rineng.2025.105609>
25. Xu, J., Gu, B., & Tian, G. (2022). Review of agricultural IoT technology. *Artificial Intelligence in Agriculture*, 6, 10–22. <https://doi.org/10.1016/j.aiia.2022.01.001>
26. Yang, B., Ding, Y., Cui, C., & Guo, T. (2025). Original article A hybrid kernel principal component analysis and long short-term memory approach for EEG signal-based fatigue evaluation. *Alexandria Engineering Journal*, 131(September), 209–217. <https://doi.org/10.1016/j.aej.2025.09.066>
27. Zhang, X., Guo, R., & Qian, Y. (2025). Smart Agricultural Technology Wavelet-decoupled GRU with adaptive attention for multi-step carbon dioxide concentration prediction in intelligent glass greenhouse. *Smart Agricultural Technology*, 12(September), 101653. <https://doi.org/10.1016/j.atech.2025.101653>