



Analisis Komparatif XGBoost dan Temporal Fusion Transformer (TFT) pada Time Series Forecasting Harga Solana

M. Zikry Sahendra Chan¹, Qatrunnada Athirah Herdiyanto², Juhraini Helfiana Lexa³

¹⁻³Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Medan

Korespondensi penulis: qatrunn.2006@gmail.com

Abstract. Cryptocurrency price prediction, particularly for highly volatile assets like Solana (SOL), is a crucial challenge in time series data analysis in digital finance. This study aims to compare the performance of the XGBoost machine learning algorithm with the Temporal Fusion Transformer (TFT) deep learning model in predicting Solana's daily closing price. The dataset used consists of historical Solana price data and network fundamentals data in the form of Total Value Locked (TVL). The research process includes data preprocessing, dividing training and test data, model training, and evaluation using the Root Mean Squared Error (RMSE) metric. The results show that using the same-day price feature has the potential to cause target leakage, resulting in invalid prediction accuracy. In testing using pure historical data without data leakage, the XGBoost model performed better than TFT with an RMSE of 4.27, while TFT produced an RMSE of 18.59. Furthermore, the integration of network fundamentals data in the form of TVL did not improve prediction accuracy and even caused a decrease in performance for the XGBoost model with an RMSE of 7.10. The results of this study show that the use of historical price action features is more effective than fundamental network indicators for short-term daily Solana price predictions.

Keywords: Solana; XGBoost; Temporal Fusion Transformer (TFT); On-Chain Data; Machine Learning

Abstrak. Prediksi harga cryptocurrency, khususnya aset dengan volatilitas tinggi seperti Solana (SOL), merupakan tantangan penting dalam analisis data time series di bidang keuangan digital. Penelitian ini bertujuan untuk membandingkan performa algoritma machine learning XGBoost dengan model deep learning Temporal Fusion Transformer (TFT) dalam memprediksi harga penutupan harian Solana. Dataset yang digunakan berupa data historis harga Solana serta data fundamental jaringan berupa Total Value Locked (TVL). Proses penelitian meliputi tahap preprocessing data, pembagian data latih dan data uji, pelatihan model, serta evaluasi menggunakan metrik Root Mean Squared Error (RMSE). Hasil penelitian menunjukkan bahwa penggunaan fitur harga pada hari yang sama berpotensi menyebabkan target leakage yang menghasilkan akurasi prediksi yang tidak valid. Pada pengujian menggunakan data historis murni tanpa kebocoran data, model XGBoost menunjukkan performa yang lebih baik dibandingkan TFT dengan nilai RMSE sebesar 4.27, sedangkan TFT menghasilkan RMSE sebesar 18.59. Selain itu, integrasi data fundamental jaringan berupa TVL tidak meningkatkan akurasi prediksi, bahkan menyebabkan penurunan performa pada model XGBoost dengan RMSE sebesar 7.10. Hasil penelitian ini menunjukkan bahwa penggunaan fitur price action historis lebih efektif dibandingkan indikator fundamental jaringan untuk prediksi harga harian Solana dalam jangka pendek.

Kata Kunci: Solana; XGBoost; Temporal Fusion Transformer (TFT); On-Chain Data; Machine Learning

1. LATAR BELAKANG

Cryptocurrency merupakan salah satu instrumen keuangan digital yang mengalami perkembangan pesat dalam beberapa tahun terakhir (Alfarizi & Lestarini, 2025). Aset kripto seperti Bitcoin, Ethereum, dan Solana memiliki tingkat ketidakstabilan harga yang tinggi sehingga menarik perhatian investor sekaligus menimbulkan tantangan dalam proses prediksi harga secara akurat. Tingkat fluktuasi harga yang ekstrem menyebabkan proses prediksi harga cryptocurrency menjadi lebih kompleks dibandingkan dengan

instrumen keuangan konvensional sehingga diperlukan pendekatan analisis berbasis *machine learning* dan *deep learning* untuk meningkatkan akurasi peramalan harga pada data deret waktu (*time series*) keuangan digital (Bao, Yue, & Rao, 2017), sehingga diperlukan pendekatan berbasis *machine learning* dan *deep learning* untuk meningkatkan akurasi peramalan harga cryptocurrency (Xiao, Wang, Xu, Wang, & Zhang, 2025).

Solana merupakan salah satu cryptocurrency yang berkembang pesat karena memiliki keunggulan dalam kecepatan transaksi dan biaya yang relatif rendah dibandingkan blockchain lainnya. Sama halnya dengan aset kripto lain, fluktuasi harga Solana sangat bergantung pada dinamika pasar, sentimen para investor, hingga kondisi fundamental jaringannya sendiri. Kompleksitas inilah yang membuat prediksi harga Solana menjadi topik yang krusial untuk dikaji, terutama melalui pendekatan analisis *time series* yang memanfaatkan data historis.

Dalam beberapa tahun terakhir, algoritma berbasis *machine learning* seperti XGBoost banyak digunakan dalam prediksi data keuangan karena kemampuannya dalam menangkap hubungan non-linear pada dataset serta kemampuannya dalam menangani data berdimensi tinggi secara efisien. Selain itu, XGBoost juga memiliki sistem optimasi yang mampu meningkatkan skalabilitas dan performa model dalam berbagai permasalahan prediksi berbasis data besar. Seiring meningkatnya adopsi aset kripto, keterkaitan antara pasar cryptocurrency dan sistem keuangan tradisional mulai menunjukkan peningkatan meskipun tingkat integrasinya masih relatif terbatas (Akbar, n.d.-a; Vidal-Tomás & Aste, 2025).

Beberapa penelitian sebelumnya telah menggunakan metode *machine learning* dan *deep learning* untuk memprediksi harga cryptocurrency. Penelitian oleh Nugraha et al. (2025) membandingkan algoritma Temporal Fusion Transformer, N-BEATS, dan DeepAR dalam memprediksi harga Bitcoin, Ethereum, dan Solana dan menunjukkan bahwa model *deep learning* mampu menangkap pola kompleks pada data *time series* cryptocurrency. Selain itu, penelitian lain menunjukkan bahwa algoritma XGBoost memiliki performa yang baik dalam prediksi harga cryptocurrency karena mampu menangani hubungan non-linear secara efektif. Penelitian lainnya juga menunjukkan bahwa model Transformer memberikan hasil prediksi yang kompetitif dibandingkan metode tradisional seperti ARIMA dan LSTM. Namun demikian, penelitian yang secara

khusus membandingkan performa XGBoost dan Temporal Fusion Transformer pada prediksi harga Solana masih terbatas sehingga diperlukan penelitian lebih lanjut.

Berdasarkan penelitian sebelumnya, sebagian besar studi berfokus pada penggunaan model deep learning atau machine learning secara terpisah dalam prediksi harga cryptocurrency (Pratama & Utama, 2023). Namun, penelitian yang secara langsung membandingkan performa XGBoost dan Temporal Fusion Transformer pada prediksi harga Solana masih terbatas. Selain itu, penggunaan fitur fundamental jaringan seperti Total Value Locked (TVL) dalam proses prediksi harga harian cryptocurrency masih jarang dianalisis secara komprehensif (Agoi, Agoi, & Syakirunni'am, 2026; Lee, 2025). Oleh karena itu, penelitian ini dilakukan untuk mengisi kesenjangan penelitian tersebut dengan melakukan analisis komparatif kedua metode serta mengevaluasi pengaruh integrasi data fundamental jaringan terhadap akurasi prediksi.

Penelitian ini bertujuan untuk membandingkan performa algoritma XGBoost dan Temporal Fusion Transformer dalam memprediksi harga penutupan harian Solana menggunakan pendekatan time series forecasting. Selain itu, penelitian ini juga bertujuan untuk menganalisis pengaruh penggunaan fitur fundamental jaringan berupa Total Value Locked terhadap akurasi prediksi model. Hasil penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan metode prediksi harga cryptocurrency serta menjadi referensi bagi penelitian selanjutnya di bidang analisis data time series berbasis machine learning dan deep learning.

2. KAJIAN TEORITIS

Cryptocurrency adalah aset digital berbasis blockchain yang memungkinkan transaksi tanpa perantara, sehingga lebih transparan dan efisien dibanding sistem keuangan tradisional. Perkembangannya dimulai sejak munculnya Bitcoin pada tahun 2009 dan terus berkembang dengan hadirnya aset lain seperti Ethereum dan Solana (Bryan Lim). Dalam penelitian ini, digunakan pendekatan time series forecasting, yaitu metode untuk memprediksi nilai di masa depan berdasarkan data historis. Metode ini penting dalam keuangan karena digunakan untuk pengambilan keputusan investasi, meskipun data finansial cenderung kompleks, tidak stabil, dan penuh noise sehingga sulit diprediksi (Sezer, Gudelek, & Ozbayoglu, 2019)

Untuk mengatasi hal tersebut, Machine Learning digunakan karena mampu menangkap pola yang rumit dan non-linear. Salah satu algoritma yang sering digunakan

adalah XGBoost, yang dikenal cepat dan akurat karena bekerja dengan memperbaiki kesalahan model secara bertahap (Chen & Guestrin, 2016). Selain itu, Deep Learning seperti Temporal Fusion Transformer (TFT) juga banyak digunakan karena mampu memahami pola jangka panjang dan menghasilkan prediksi yang lebih stabil, terutama pada data kripto yang volatil (Lim, Arik, Loeff, & Pfister, 2021).

Agar model semakin optimal, dilakukan feature engineering dengan menambahkan fitur seperti lag, moving average, return, dan volume, serta menggabungkan data on-chain seperti TVL dan aktivitas pengguna untuk menangkap perilaku pasar (Lee, 2025). Dalam prosesnya juga perlu menghindari target leakage agar hasil model tetap valid. Evaluasi model dilakukan menggunakan metrik seperti MAE, RMSE, dan MAPE (Nugraha Wahyu & Anggai, 2025). Beberapa penelitian menunjukkan bahwa model deep learning dan XGBoost sama-sama efektif, sehingga penelitian ini menggabungkan keduanya untuk membandingkan performa dan meningkatkan akurasi prediksi harga kripto (Akbar, n.d.-b)

3. METODE PENELITIAN

Dataset Penelitian

Implementasi model peramalan dalam penelitian ini didasarkan pada perbandingan dua arsitektur yang berbeda secara fundamental, yaitu algoritma *machine learning* berbasis *tree boosting* (XGBoost) dan model *deep learning* berbasis arsitektur Transformer modern (*Temporal Fusion Transformer / TFT*). Kedua model tersebut dipilih karena memiliki karakteristik yang berbeda dalam menangkap pola temporal pada data deret waktu, di mana XGBoost dikenal efektif dalam memodelkan hubungan non-linear pada data finansial, sedangkan TFT dirancang untuk menangani dependensi temporal jangka pendek maupun jangka panjang melalui mekanisme *attention* dan seleksi variabel yang adaptif (Chen & Guestrin, 2016; Lim et al., 2021)

Sumber dan Periode Dataset Penelitian

Data historis yang digunakan bersumber dari penyedia data pasar finansial (untuk data harga) dan API publik DeFiLlama (untuk data fundamental jaringan), mencakup periode pengamatan dari Januari 2024 hingga Februari 2026. Dari dataset tersebut, diekstraksi beberapa fitur utama yang merepresentasikan dinamika pasar dan aktivitas *blockchain*. Fitur-fitur ini meliputi harga pembukaan (*open*), penutupan (*close*), tertinggi (*high*), terendah (*low*), dan volume perdagangan. Selain itu, dilakukan rekayasa fitur

(*feature engineering*) untuk menghasilkan variabel *Moving Average* (SMA 7 dan 14), *Lag Features* (memori harga masa lalu), persentase *Daily Return*, serta metrik *On-Chain Total Value Locked* (TVL) yang berfungsi sebagai proksi aktivitas desentralisasi di jaringan Solana (Nugraha Wahyu & Anggai, 2025).

Tahapan Pengolahan Data dan Implementasi

Setelah kebutuhan data dijabarkan, penelitian dilanjutkan dengan perancangan tahapan sistematis yang terdiri dari beberapa proses utama, yaitu pengumpulan dataset, tahap *preprocessing*, proses *feature engineering*, pembagian dataset secara kronologis (*chronological data splitting*), pelatihan model, serta evaluasi performa model prediksi. Tahap *preprocessing* dilakukan melalui pembentukan variabel *lag features* dan *moving average* serta proses penggabungan antara data harga historis dengan data indikator *on-chain* berupa TVL. Proses ini bertujuan untuk meningkatkan kualitas representasi data sehingga model mampu menangkap hubungan temporal yang lebih kompleks dalam data deret waktu cryptocurrency (Nugraha Wahyu & Anggai, 2025).


Selanjutnya, dataset dibagi secara kronologis menjadi data latih (*training*), data validasi (*validation*), dan data uji (*testing*) untuk menjaga integritas struktur data *time series* serta menghindari terjadinya *data leakage* yang dapat mempengaruhi hasil prediksi model. Pendekatan pembagian data secara kronologis merupakan prosedur standar dalam penelitian *time series forecasting* karena mempertahankan urutan temporal data historis yang menjadi dasar pembelajaran model prediktif (Sezer et al., 2019).

Pelatihan model dilakukan menggunakan dua pendekatan berbeda, yaitu model XGBoost sebagai representasi algoritma *machine learning* berbasis *gradient boosting* dan model TFT sebagai representasi arsitektur *deep learning* berbasis Transformer. XGBoost memiliki kemampuan tinggi dalam menangani dataset berdimensi besar serta hubungan non-linear antar variabel, sedangkan TFT dirancang untuk meningkatkan akurasi prediksi melalui mekanisme seleksi fitur dinamis dan interpretasi dependensi temporal multivariat (Chen & Guestrin, 2016; Lim et al., 2021).

Selain itu, eksperimen dilakukan dengan dua skenario pelatihan model, yaitu menggunakan fitur harga lengkap serta menggunakan fitur yang telah diseleksi tanpa variabel *high* dan *low* untuk menguji potensi terjadinya *target leakage* dalam proses prediksi harga harian. Tahap akhir penelitian dilakukan melalui evaluasi performa model menggunakan metrik *Root Mean Squared Error* (RMSE) dan *Mean Absolute Error*

(MAE). Kedua metrik tersebut merupakan indikator evaluasi yang umum digunakan dalam penelitian prediksi harga cryptocurrency karena mampu mengukur tingkat kesalahan prediksi secara kuantitatif serta memberikan gambaran tingkat akurasi model secara objektif (Brownlee Disclaimer, 2018; Nugraha Wahyu & Anggai, 2025).

Seluruh tahapan penelitian dirancang untuk menghasilkan analisis komparatif yang sistematis terkait efektivitas algoritma XGBoost dan TFT dalam memprediksi harga penutupan harian Solana serta mengevaluasi kontribusi indikator *on-chain* dalam meningkatkan performa model prediksi jangka pendek pada data cryptocurrency.



Gambar 1. Flowchart alur Preprocessing

Gambar 1 menunjukkan alur tahapan penelitian yang dilakukan dalam proses prediksi harga penutupan harian Solana menggunakan algoritma XGBoost dan Temporal Fusion Transformer. Tahapan penelitian diawali dengan proses pengumpulan data harga historis dan data fundamental jaringan berupa *Total Value Locked (TVL)*, yang digunakan sebagai indikator aktivitas jaringan blockchain dalam analisis prediksi cryptocurrency berbasis data multivariat (Lee, 2025). Selanjutnya dilakukan tahap *preprocessing* dan *feature engineering* untuk menghasilkan variabel turunan seperti *moving average*, *lag features*, dan *daily return* yang berperan dalam membantu model mengenali pola

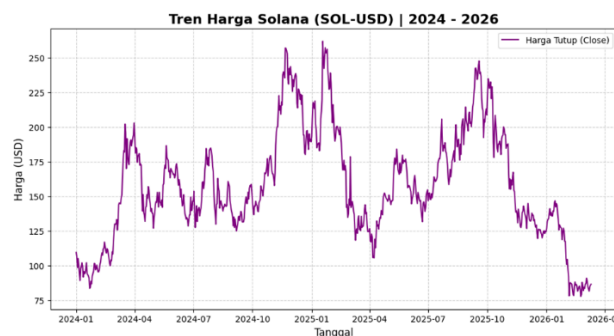
temporal pada data deret waktu (Nugraha Wahyu & Anggai, 2025). Dataset kemudian dibagi secara kronologis menjadi data latih, validasi, dan data uji untuk menjaga integritas struktur *time series* serta menghindari terjadinya *data leakage* dalam proses pelatihan model prediksi (Sezer et al., 2019). Tahap berikutnya adalah pelatihan model menggunakan dua pendekatan yang berbeda, yaitu algoritma *machine learning* berbasis *gradient boosting* (XGBoost) dan model *deep learning* berbasis arsitektur Transformer (Temporal Fusion Transformer) yang dirancang untuk menangkap dependensi temporal jangka panjang melalui mekanisme *attention* dan seleksi variabel dinamis (Chen & Guestrin, 2016; Farooq et al., 2024; Lim et al., 2021). Terakhir, performa model dievaluasi menggunakan metrik *Root Mean Squared Error* (RMSE) dan *Mean Absolute Error* (MAE) yang umum digunakan dalam penelitian prediksi harga cryptocurrency untuk mengukur tingkat kesalahan prediksi secara kuantitatif dan objektif (Nugraha Wahyu & Anggai, 2025).

4. HASIL DAN PEMBAHASAN

Hasil

Analisis Model

Hasil pengujian model berdasarkan dataset harga historis Solana dan tiga skenario eksperimen yang telah dirancang. Sebagai gambaran awal, fluktuasi harga penutupan harian Solana (SOL) selama periode penelitian (2024–2026) dapat dilihat pada Gambar 2 berikut.



Gambar 2. Tren Harga Historis Solana (SOL) Periode 2024 - 2026.


Hasil Skenario Prediksi Awal (Termasuk Fitur High dan Low)

Pada tahap pertama, model XGBoost dan TFT dilatih menggunakan seluruh fitur yang diekstraksi dari dataset, termasuk harga tertinggi (*High*) dan terendah (*Low*) harian. Hasil peramalan menunjukkan grafik prediksi (garis merah) yang nyaris menempel

sempurna dengan harga aktual (garis biru) untuk kedua model tersebut, seperti yang divisualisasikan pada Gambar 3 dan Gambar 4.



Gambar 3. Grafik Prediksi XGBoost Skenario Awal (Dengan Fitur *High* dan *Low*)



Gambar 4. Grafik Prediksi TFT Skenario Awal (Dengan Fitur *High* dan *Low*)

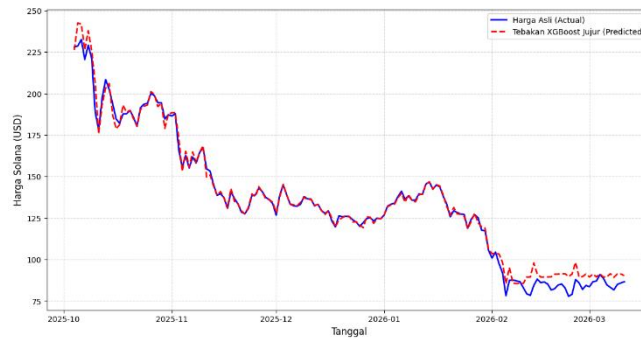
Hasil Evaluasi XGBoost vs TFT (Tanpa Fitur *High* dan *Low*)

Pada skenario kedua, fitur *High* dan *Low* dihapus dari dataset. Model kemudian dilatih murni menggunakan data historis (*Lag Features*, *Moving Average*, dll). Hasil komparasi performa kedua model berdasarkan metrik *Root Mean Squared Error* (RMSE) dan *Mean Absolute Error* (MAE) pada data uji disajikan pada Tabel 1.


| MODEL | RMSE | MAE |
|---------|---------|---------|
| XGBoost | \$4.27 | \$2.67 |
| TFT | \$18.59 | \$14.79 |

Tabel 1. Perbandingan Metrik Evaluasi Model (Tanpa Fitur High/Low)

Visualisasi hasil prediksi model XGBoost dan TFT pada skenario "jujur" ini dapat dilihat pada Gambar 5 dan Gambar 6. Terlihat bahwa XGBoost lebih baik dalam mengikuti tren harga dibandingkan TFT.



Gambar 5. Grafik Prediksi XGBoost Mode Jujur (Tanpa Fitur High dan Low)



Gambar 6. Grafik Prediksi TFT Mode Jujur (Tanpa Fitur *High* dan *Low*)

Hasil Integrasi Data Fundamental On-Chain

Skenario ketiga menguji dampak penambahan variabel Total Value Locked (TVL) terhadap performa model XGBoost terbaik. Hasil evaluasi menunjukkan adanya penurunan akurasi setelah data TVL diintegrasikan, seperti yang ditunjukkan pada Tabel 2.

| MODEL | RMSE | MAE |
|-----------------------------------|--------|--------|
| XGBoost (Tanpa TVL) | \$4.27 | \$2.67 |
| XGBoost + TVL (<i>On-Chain</i>) | \$7.10 | \$4.46 |

Tabel 2. Perbandingan Performa Sebelum dan Sesudah Integrasi Data TVL

Visualisasi prediksi model XGBoost setelah ditambahkan data fundamental *On-Chain* dapat dilihat pada Gambar 7.

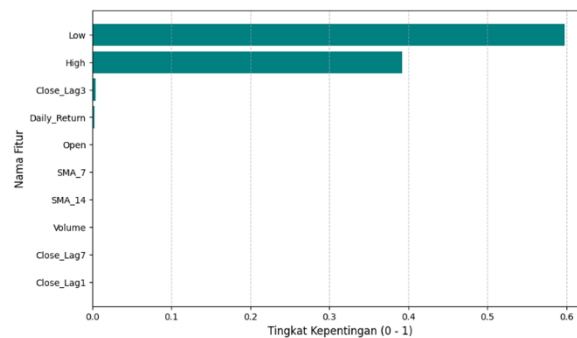


Gambar 7. Grafik Prediksi XGBoost dengan Integrasi Data On-Chain (TVL)

B. Pembahasan

Identifikasi dan Bahaya Target Leakage

Akurasi yang nyaris sempurna pada skenario awal (Gambar 3 dan 4) bukanlah indikasi model yang cerdas, melainkan gejala kebocoran data (*Target Leakage*). Untuk membuktikan hal ini, dilakukan analisis *Feature Importance* pada model XGBoost skenario awal (Gambar 8).



Gambar 8. Fitur Penting XGBoost Saat Mengetahui High dan Low

Grafik di atas mengonfirmasi bahwa model mendasarkan prediksinya hampir secara eksklusif pada fitur *Low* dan *High*. Dalam dunia nyata, harga tertinggi dan terendah baru diketahui saat hari perdagangan usai. Menggunakan data ini menyebabkan model hanya mengkalkulasi selisih harga hari ini, bukan memprediksi masa depan berdasarkan tren masa lalu. Penghapusan fitur ini pada skenario kedua terbukti mengembalikan model ke kondisi prediktif yang valid.


Keunggulan Machine Learning atas Deep Learning pada Data Terbatas

Berdasarkan Tabel 4.1 dan visualisasi Gambar 4.4, XGBoost secara signifikan mengungguli model Deep Learning TFT. Secara teoritis, TFT sangat tangguh untuk data berskala masif. Namun, dengan dataset harian yang ukurannya relatif kecil (ratusan hingga ribuan baris), model neural network yang kompleks (TFT) gagal melakukan konvergensi optimal dan kesulitan menangkap pola tren (seperti terlihat pada Gambar 4.5 yang sangat landai). Sebaliknya, algoritma berbasis pohon keputusan (decision tree) seperti XGBoost terbukti sangat efisien dan lincah dalam memetakan pola harga pada data tabular menengah.

Analisis Noise pada Data Fundamental On-Chain

Temuan menarik terjadi pada skenario ketiga, di mana penambahan data fundamental TVL justru memperburuk nilai RMSE (Tabel 4.2). Analisis *Feature*

Importance pada model yang menggunakan data *On-Chain* ini (Gambar 4.8) memberikan jawaban empiris atas anomali tersebut.



Gambar 9. Fitur Penting Prediksi XGBoost dengan Data On-Chain

Gambar 9 menunjukkan bahwa memori harga masa lalu (**Close_Lag1**, **SMA_7**) tetap menjadi prediktor paling diandalkan oleh model, sementara variabel **TVL_OnChain** berada di urutan bawah dengan kontribusi minim. Hal ini menyimpulkan bahwa pergerakan harga Solana dalam jangka pendek (harian) didorong oleh sentimen pasar, spekulasi, dan pola teknikal. Data fundamental TVL yang bergerak secara makro cenderung bertindak sebagai *noise* (kebisingan) yang mendistraksi fokus model dari fluktuasi harga harian yang cepat.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian dan eksperimen yang telah dilakukan terhadap prediksi harga aset kripto Solana (SOL), maka kesimpulan yang dapat diambil adalah Model XGBoost maupun Temporal Fusion Transformer (TFT) dapat menghasilkan prediksi yang nyaris sempurna (dengan error mendekati nol) ketika diberikan akses ke fitur harga tertinggi (High) dan terendah (Low) harian. Namun, hasil evaluasi menunjukkan bahwa ini adalah ilusi dari kebocoran data (Target Leakage), sehingga fitur masa depan tersebut tidak valid untuk digunakan dalam prediksi dunia nyata. Model XGBoost terbukti memberikan performa terbaik dalam memprediksi harga Solana pada skenario data historis murni. XGBoost menghasilkan nilai RMSE (\$4.27) dan MAE (\$2.67) terendah, sehingga lebih tanggap dan efektif dalam menangkap pola tren pergerakan harga harian. Untuk Model Deep Learning Temporal Fusion Transformer (TFT) menunjukkan performa yang kurang optimal dalam prediksi harga harian ini (dengan RMSE mencapai \$18.59). Arsitektur yang kompleks pada TFT mengalami kesulitan konvergensi (overfitting) ketika dihadapkan pada dataset berskala kecil (kurang dari 1.000 baris), sehingga kurang direkomendasikan untuk skenario data terbatas. Integrasi data

fundamental On-Chain berupa Total Value Locked (TVL) justru menurunkan akurasi model XGBoost (RMSE memburuk menjadi \$7.10). Hal ini menegaskan bahwa untuk kerangka waktu jangka pendek (harian), pergerakan harga aset kripto lebih didominasi oleh pola teknikal dan sentimen spekulatif, sementara data fundamental lambat seperti TVL justru bertindak sebagai noise (kebisingan) yang mengganggu model. Berdasarkan perbandingan seluruh skenario, implementasi model XGBoost menggunakan data teknikal historis murni merupakan pendekatan yang paling akurat dan fungsional. Implementasi ini membuktikan bahwa algoritma Machine Learning konvensional dengan rekayasa fitur (Lag dan Moving Average) yang tepat dapat memberikan hasil peramalan yang mendekati nilai aktual, sehingga sangat relevan untuk membantu pengambilan keputusan investasi jangka pendek di pasar kripto.

DAFTAR REFERENSI

- Agoi, M. A., Agoi, A. E., & Syakirunni'am, L. (2026). Page| 56 Decentralized Finance, Smart Contracts, and Financial Stability in Nigeria's Halal Industry Article Info. *Jurnal Halal Center*, 1(1), 56–71. <https://doi.org/10.28918/jhc.v1i1.14502>
- Akbar, M. (n.d.-a). *Sistemasi: Jurnal Sistem Informasi Bitcoin Price Forecasting using Seasonal Log-Differenced XGBoost with 2014-2025 Data*. Retrieved from <http://sistemasi.ftik.unisi.ac.id>
- Akbar, M. (n.d.-b). *Sistemasi: Jurnal Sistem Informasi Bitcoin Price Forecasting using Seasonal Log-Differenced XGBoost with 2014-2025 Data*. Retrieved from <http://sistemasi.ftik.unisi.ac.id>
- Alfarizi, M., & Lestarini, D. (2025). Predicting Cryptocurrency Prices Using Machine Learning: A Case Study on Bitcoin. In *Journal of Applied Informatics and Computing (JAIC)* (Vol. 9). Retrieved from <http://jurnal.polibatam.ac.id/index.php/JAIC>
- Bao, W., Yue, J., & Rao, Y. (2017). A deep learning framework for financial time series using stacked autoencoders and long-short term memory. *PLoS ONE*, 12(7). <https://doi.org/10.1371/journal.pone.0180944>
- Brownlee Disclaimer, J. (2018). *Deep Learning for Time Series Forecasting Predict the Future with MLPs, CNNs and LSTMs in Python Acknowledgements Copyright Deep Learning for Time Series Forecasting*.
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 13-17-August-2016*, 785–794. Association for Computing Machinery. <https://doi.org/10.1145/2939672.2939785>
- Farooq, A., Irfan Uddin, M., Adnan, M., Alarood, A. A., Alsolami, E., & Habibullah, S. (2024). Interpretable multi-horizon time series forecasting of cryptocurrencies by leverage temporal fusion transformer. *Heliyon*, 10(22). <https://doi.org/10.1016/j.heliyon.2024.e40142>

- Lee, M. C. (2025). Temporal Fusion Transformer-Based Trading Strategy for Multi-Crypto Assets Using On-Chain and Technical Indicators. *Systems*, 13(6). <https://doi.org/10.3390/systems13060474>
- Lim, B., Arik, S., Loeff, N., & Pfister, T. (2021). Temporal Fusion Transformers for interpretable multi-horizon time series forecasting. *International Journal of Forecasting*, 37(4), 1748–1764. <https://doi.org/10.1016/j.ijforecast.2021.03.012>
- Nugraha Wahyu, F., & Anggai, S. (2025). Prediksi Harga Cryptocurrency Menggunakan Algoritma Temporal Fusion Transformer, N-Beats dan Deepar. *R2J*, 8(1). <https://doi.org/10.38035/rrj.v8i1>
- Pratama, M. L., & Utama, H. (2023). PENDEKATAN DEEP LEARNING MENGGUNAKAN METODE LSTM UNTUK PREDIKSI HARGA BITCOIN. *IJCSR: The Indonesian Journal of Computer Science Research*, 2(2). <https://doi.org/10.37905>
- Sezer, O. B., Gudelek, M. U., & Ozbayoglu, A. M. (2019). *Financial Time Series Forecasting with Deep Learning: A Systematic Literature Review: 2005-2019*. Retrieved from <http://arxiv.org/abs/1911.13288>
- Vidal-Tomás, D., & Aste, T. (2025). Integration or separation? Examining the dynamic relationship between crypto and traditional finance. *Finance Research Letters*, 86. <https://doi.org/10.1016/j.frl.2025.108927>
- Xiao, X., Wang, F., Xu, H., Wang, D., & Zhang, Y. (2025, July 24). *Applying XGBoost for Time Series Prediction in Financial Market Data*. <https://doi.org/10.21203/rs.3.rs-7017751/v1>
- Wikipedia contributors. (n.d.). *Data science and predictive analytics*. Retrieved March 30, 2026, from https://en.wikipedia.org/wiki/Data_Science_and_Predictive_Analytics
- Solana Foundation. (n.d.). *Pasar modal untuk setiap aset di bumi*. Retrieved March 30, 2026, from <https://solana.com/id>
- Wikipedia contributors. (n.d.). *Time series*. Retrieved March 30, 2026, from https://en.wikipedia.org/wiki/Time_series
- Raharjo, B. (2022). *Deep learning dengan Python*. Semarang, Indonesia: Yayasan Prima Agus Teknik.
- Kim, J., Kim, H., Kim, H., Lee, D., & Yoon, S. (2025). A comprehensive survey of deep learning for time series forecasting: Architectural diversity and open challenges. *Artificial Intelligence Review*, 58(216), 1-95 . doi:10.1007/s10462-025-11223-9