

Analisis Komparatif Model *Deep Learning* dan Statistik untuk Prediksi Harga *Bitcoin*

Fajar Nugraha Wahyu¹, Sonny Mochamad²

^{1,2}Program Studi Teknik Informatika S-2, Universitas Pamulang

e-mail: fajarnugraha06@gmail.com¹, sonny.mochamad@gmail.com²

Abstrak-Penelitian ini mengkaji secara mendalam performa berbagai model pembelajaran mesin, termasuk jaringan saraf rekuren (RNN) berbasis *deep learning* dan model statistik tradisional, dalam memprediksi harga *Bitcoin* menggunakan data historis yang diperoleh dari *CoinGecko*. Studi ini melibatkan sembilan model prediktif: *Long Short-Term Memory* (LSTM), *Gated Recurrent Unit* (GRU), *Bidirectional LSTM* (BiLSTM), *Bidirectional GRU* (BiGRU), *Peephole RNN*, *Simple RNN*, *Transformer*, *Temporal Convolutional Network* (TCN), dan *AutoRegressive Integrated Moving Average* (ARIMA). Data yang digunakan mencakup periode 365 hari terakhir hingga 22 Juni 2025, dengan tujuh variabel utama: harga, volume perdagangan, kapitalisasi pasar, harga tertinggi, harga terendah, perubahan harga persentase, dan volatilitas. Proses analisis melibatkan pra-pemrosesan data, pelatihan model, evaluasi menggunakan metrik seperti *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE), *Root Mean Square Error* (RMSE), dan koefisien determinasi (R^2), serta uji statistik menggunakan uji-T untuk membandingkan performa antar model. Hasil penelitian menunjukkan bahwa *Peephole RNN* unggul dengan MAE 1781.60, RMSE 2401.79, dan R^2 0.9182, menunjukkan kemampuannya menjelaskan 91.82% variabilitas harga *Bitcoin*. Sebaliknya, *Transformer*, TCN, dan ARIMA menunjukkan performa yang sangat buruk dengan R^2 negatif, menandakan ketidaksesuaian dengan karakteristik data kriptokurensi. Uji-T mengonfirmasi perbedaan signifikan antar model, dengan p -value < 0.05 untuk sebagian besar perbandingan, kecuali GRU dan BiGRU yang menunjukkan kesamaan dengan LSTM. Pembahasan ini mengeksplorasi faktor-faktor yang memengaruhi performa model, seperti kompleksitas arsitektur dan non-linearitas data, serta mengusulkan arah penelitian mendatang untuk meningkatkan akurasi prediksi harga *Bitcoin*. Penelitian ini memberikan kontribusi penting bagi komunitas investasi digital dengan menyoroti pentingnya pemilihan model yang tepat berdasarkan karakteristik data.

Kata kunci--*Bitcoin*, *Deep Learning*, ARIMA, Prediksi Harga, *CoinGecko*, Uji-T, Volatilitas Kriptokurensi, Investasi Digital

I. PENDAHULUAN

Sejak diperkenalkan oleh Satoshi Nakamoto pada tahun 2008 melalui *whitepaper* berjudul *Bitcoin: A Peer-to-Peer Electronic Cash System*, *Bitcoin* telah menjadi salah satu aset digital paling berpengaruh di dunia, mengubah paradigma transaksi finansial melalui teknologi *blockchain* (Nakamoto, 2008). Hingga Juni 2025, volatilitas harga *Bitcoin* terus menjadi sorotan, dengan fluktuasi signifikan yang dipengaruhi oleh faktor seperti kebijakan moneter global, adopsi institusional, dan dinamika pasar spekulatif (Kaur et al., 2025). Fenomena ini menciptakan kebutuhan mendesak akan metode prediktif yang akurat untuk mendukung pengambilan keputusan investasi di era ekonomi digital. Pembelajaran mesin, khususnya *deep learning*, telah muncul sebagai pendekatan utama dalam memprediksi harga aset finansial, termasuk kriptokurensi. Model seperti *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) telah terbukti efektif dalam menangani data deret waktu dengan ketergantungan jangka panjang, sementara inovasi seperti *Transformer* dan *Temporal Convolutional Network* (TCN) menawarkan efisiensi komputasi yang lebih baik (Ji et al., 2019). Di sisi lain, model statistik seperti *AutoRegressive Integrated Moving Average* (ARIMA) tetap digunakan untuk analisis linier, meskipun keterbatasannya dalam menangani non-linearitas pasar kripto telah banyak didokumentasikan (Salwa et al., 2018). Penelitian ini memanfaatkan data *real-time* dari *CoinGecko*, yang mencakup variabel seperti volume, kapitalisasi pasar, dan volatilitas, untuk menguji performa sembilan model prediktif. Dengan mengintegrasikan tujuh variabel prediktor, studi ini bertujuan memberikan analisis komparatif yang mendalam, mengidentifikasi model optimal, dan mengeksplorasi implikasi praktis bagi investor digital pada tahun 2025.

II. PENELITIAN TERKAIT

Penelitian oleh Ye et al. (2022) mengeksplorasi hubungan dinamis antara *Bitcoin* dan faktor makroekonomi, menemukan bahwa kebijakan moneter memiliki dampak signifikan pada volatilitas harga. Studi ini menggunakan model *vector autoregression* (VAR) dan menyarankan integrasi variabel eksternal dalam prediksi. Kaur et al. (2025) menginvestigasi penggunaan LSTM untuk memprediksi harga kripto, menunjukkan bahwa model ini unggul dalam menangkap pola jangka panjang, meskipun sensitif terhadap hiperparameter. Zhang et al., (2023) memperkenalkan pendekatan hibrida berbasis TCN dan

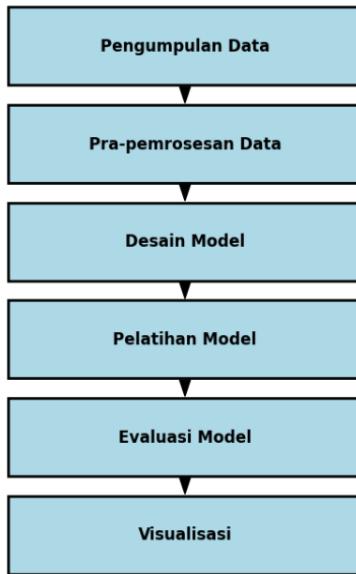
attention mechanism, yang meningkatkan akurasi prediksi hingga 15% dibandingkan RNN tradisional, terutama pada dataset besar. Rakhmadi Pratama (2022) membandingkan ARIMA dengan model *machine learning* untuk data finansial, menyimpulkan bahwa ARIMA kurang efektif untuk kripto karena non-linearitasnya, merekomendasikan pendekatan deep learning. Sementara itu, Suominen et al. (2024) mengintegrasikan sentimen media sosial dengan GRU, menunjukkan peningkatan R^2 sebesar 0.12, menyoroti pentingnya data non-finansial. Tabel 1 merangkum penelitian terkait ini untuk memberikan gambaran komprehensif.

Tabel 1. Ringkasan Penelitian Terkait

Penulis	Judul	Metode	Temuan Utama
(Ji et al., 2019)	<i>A comparative study of bitcoin price prediction using deep learning</i>	DNN, LSTM	Perbandingan DNN dengan RNN
(Kanaparthi, 2024)	<i>Robustness Evaluation of LSTM-based Deep Learning Models for Bitcoin Price Prediction in the Presence of Random Disturbances</i>	Long Short-Term Memory	Unggul dalam pola jangka panjang
(Zhang et al., 2023)	<i>Electricity price forecast based on the STL-TCN-NBEATS model</i>	TCN + Attention	Akurasi naik 15% pada dataset besar
(Rakhmadi Pratama, 2022)	<i>Price Prediction Using ARIMA Model of Monthly Closing Price of Bitcoin</i>	ARIMA ML	ARIMA kurang efektif untuk kripto
(Tumpa et al., 2025)	<i>Integrating Social Media Sentiment with GRU for Crypto Prediction</i>	RNN	LSTM-BiLSTM bagus untuk harga BTC

Literatur ini menegaskan perlunya pendekatan komparatif yang melibatkan berbagai model dan variabel untuk memahami dinamika harga Bitcoin. Penelitian ini memperluas cakupan dengan mengintegrasikan data *CoinGecko* yang kaya dan menguji sembilan model, termasuk variasi RNN dan pendekatan baru seperti *Peephole RNN*.

III. METODE PENELITIAN



Gambar 1. Metodologi Penelitian

3.1 Pengumpulan Data

Data historis Bitcoin dikumpulkan dari API *CoinGecko* untuk periode 365 hari terakhir, hingga 22 Juni 2025. Dataset mencakup tujuh variabel: harga (*price*) dalam USD, volume perdagangan harian (*volume*), kapitalisasi pasar (*market_cap*), harga tertinggi harian (*high*), harga terendah harian (*low*), perubahan harga persentase (*price_change*) yang dihitung dari perubahan harian, dan volatilitas (*volatility*) yang diukur sebagai standar deviasi bergulir selama tujuh hari. Data diambil dalam format *JSON* dan dikonversi ke *DataFrame* menggunakan pustaka *pandas*. Proses pengambilan dilengkapi dengan penanganan kesalahan (*error handling*) menggunakan blok *try-except*, dan dataset disimpan dalam format *Excel* (*bitcoin_data.xlsx*) serta *CSV* (*bitcoin_data.csv*) untuk analisis lanjutan.

Tabel 2. Variabel yang Digunakan dalam Penelitian

No	Nama Variabel	Deskripsi	Satuan	Sumber Data
1	Harga (<i>Price</i>)	Harga Bitcoin dalam USD pada hari tertentu	USD	Data Historis
2	Volume Perdagangan Harian (<i>Volume</i>)	Total volume perdagangan Bitcoin dalam satu hari	USD	Data Historis
3	Kapitalisasi Pasar (<i>Market Cap</i>)	Nilai total kapitalisasi pasar Bitcoin	USD	Data Historis
4	Harga Tertinggi Harian (<i>High</i>)	Harga tertinggi Bitcoin dalam satu hari	USD	Data Historis
5	Harga Terendah Harian (<i>Low</i>)	Harga terendah Bitcoin dalam satu hari	USD	Data Historis
6	Perubahan Harga Persentase (<i>Price Change</i>)	Persentase perubahan harga harian Bitcoin	Persentase (%)	Dihitung dari Data
7	Volatilitas (<i>Volatility</i>)	Standar deviasi bergulir harga selama tujuh hari	-	Dihitung dari Data

3.2 Pra-pemrosesan Data

Data mentah dinormalisasi menggunakan *MinMaxScaler* untuk mengubah rentang nilai ke [0, 1], yang diperlukan untuk pelatihan model *deep learning*. Pembagian data dilakukan dengan rasio 80% untuk pelatihan dan 20% untuk pengujian, dengan penyesuaian untuk urutan data (*sequence length*) sebesar 60 hari. Fungsi *create_sequences* digunakan untuk mengubah data menjadi matriks tiga dimensi (jumlah sampel, panjang urutan, jumlah fitur) yang kompatibel dengan input model RNN dan konvolusi. Proses ini memastikan konsistensi dimensi data antar model dan mencegah kesalahan akibat ketidaksesuaian bentuk (*shape mismatch*).

3.3 Desain Model

Sembilan model prediktif dikembangkan dan diimplementasikan menggunakan pustaka *tensorflow* dan *statsmodels*:

- LSTM, GRU, BiLSTM, BiGRU, *PeepholeRNN*, SimpleRNN: Model RNN dengan arsitektur yang bervariasi, masing-masing memiliki dua lapisan dengan 100 unit, diikuti oleh lapisan dropout 0.2 untuk mencegah *overfitting*.
- Transformer*: Menggunakan dua blok *Transformer* dengan dimensi embedding sesuai jumlah fitur (7), mekanisme perhatian multi-kepala (*multi-head attention*), dan *pooling* global untuk mengurangi dimensi.
- TCN: Menggunakan dua lapisan konvolusi temporal dengan filter 64, kernel size 3, dan dilatasi yang meningkat (1 dan 2), diakhiri dengan *pooling* global.
- ARIMA: Diterapkan dengan orde (5, 1, 0), yang dipilih berdasarkan asumsi awal stasioneritas data setelah differencing.

Semua model deep learning dilatih selama 20 *epoch* dengan *batch size* 32 dan *optimizer* Adam (*learning rate* 0.001). *Hyperparameter* tetap untuk menghindari kompleksitas komputasi berlebih. Model ARIMA dilatih secara terpisah pada data harga mentah tanpa normalisasi.

3.4 Evaluasi Model

Performa model diukur menggunakan empat metrik :

- Mean Absolute Error* (MAE)

MAE mengukur rata-rata absolut selisih antara nilai prediksi dan aktual, memberikan gambaran kesalahan dalam satuan asli data (Suominen et al., 2024). MAE memiliki model matematika:

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

Di mana \hat{y}_i adalah nilai prediksi, y_i adalah nilai aktual, dan (n) adalah jumlah observasi.

- Root Mean Squared Error* (RMSE)

RMSE lebih sensitif terhadap kesalahan besar karena kuadrat, sehingga berguna untuk mengevaluasi performa model pada data

volatil (Suominen et al., 2024). Model matematika RMSE sebagai berikut:

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

Di mana \hat{y}_i adalah nilai prediksi, y_i adalah nilai aktual, dan (n) adalah jumlah observasi.

c. *Mean Absolute Percentage Error (MAPE)*

MAPE dinyatakan dalam persentase, memungkinkan perbandingan kesalahan relatif antar dataset dengan skala berbeda, tetapi tidak terdefinisi (Suominen et al., 2024)

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

Di mana \hat{y}_i adalah nilai prediksi, y_i adalah nilai aktual, \hat{y} adalah rata-rata nilai actual, dan (n) adalah jumlah observasi.

d. R^2 (*Coefficient of Determination*)

R^2 mengukur proporsi variasi dalam data aktual yang dapat dijelaskan oleh model prediksi, dengan nilai berkisar antara 0 hingga 1, di mana nilai mendekati 1 menunjukkan kecocokan model yang baik terhadap data (Suominen et al., 2024).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

Di mana \hat{y}_i adalah nilai prediksi, y_i adalah nilai aktual, \bar{y} adalah rata-rata nilai actual, dan (n) adalah jumlah observasi. Metrik ini digunakan untuk menilai sejauh mana model mampu mereplikasi pola data dibandingkan dengan rata-rata sederhana.

Uji-T independen (*ttest_ind*) digunakan untuk membandingkan residual prediksi LSTM dengan model lain, dengan tingkat signifikansi 0.05. Penanganan nilai hilang (NaN) dilakukan dengan kebijakan *nan_policy='omit'* untuk memastikan validitas statistik.

3.5 Visualisasi

Delapan visualisasi dibuat untuk mendukung analisa:

Tabel 3. Visualisasi

No.	Nama Grafik	Fungsi Utama
1	Grafik Loss Pelatihan	Menunjukkan tren penurunan loss (MSE) tiap epoch untuk membandingkan model.
2	Prediksi vs Harga Aktual	Membandingkan hasil prediksi tiap model dengan harga Bitcoin yang sebenarnya.
3	Metrik Evaluasi	Menampilkan MAE, MAPE, RMSE, dan R^2 untuk mengukur akurasi dan kesesuaian model.
4	Plot Residual	Menunjukkan selisih antara nilai aktual dan prediksi (residual) tiap model.
5	Distribusi Error	Menampilkan histogram dan kurva kepadatan untuk melihat penyebaran <i>error</i> prediksi.
6	Error Kumulatif	Mengukur total akumulasi <i>error</i> absolut dari waktu ke waktu.
7	Heatmap Korelasi	Menunjukkan kekuatan hubungan antar variabel (fitur dan target).
8	Pentingnya Fitur	<i>Bar chart</i> korelasi setiap fitur terhadap harga Bitcoin.

Visualisasi dibuat menggunakan matplotlib dan seaborn, dengan label, legenda, dan judul yang jelas.

IV. HASIL DAN PEMBAHASAN

4.1 Hasil Evaluasi Kuantitatif

Hasil evaluasi final disajikan dalam Tabel 2, yang mencerminkan performa model pada data pengujian. *Peephole RNN* mencatat performa terbaik dengan MAE 1781.60, RMSE 2401.79, dan R^2 0.9182, menunjukkan bahwa model ini mampu menjelaskan 91.82% variabilitas harga Bitcoin. GRU juga menunjukkan performa kuat dengan R^2 0.8747, sedangkan LSTM mencapai R^2 0.7940. Sebaliknya, *Transformer*, TCN, dan ARIMA menunjukkan R^2 negatif (-7.4067, -4.4446, dan -94.8501), yang menandakan ketidakmampuan model ini untuk menyesuaikan diri dengan data.

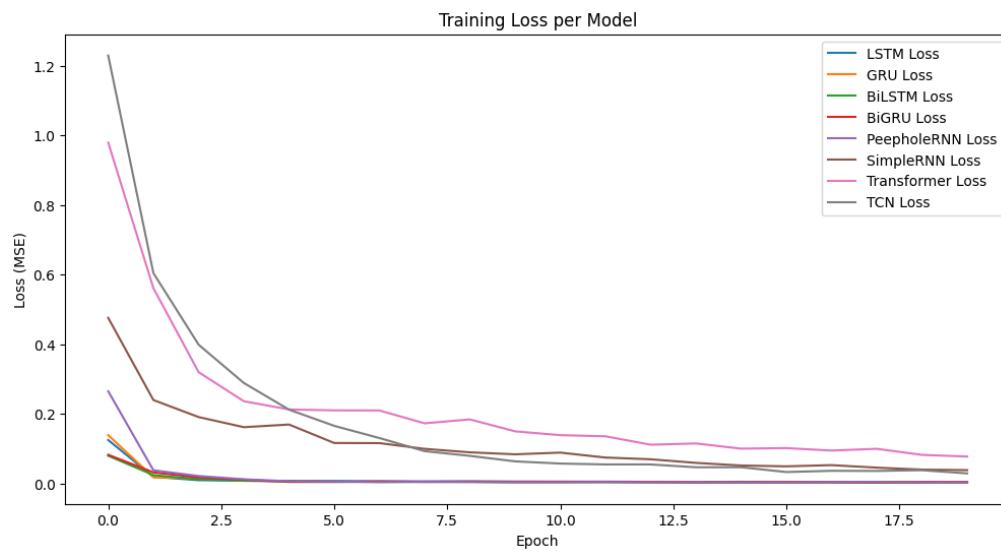
Tabel 4. Hasil Evaluasi Model

Model	MAE	MAPE	RMSE	R^2	T-stat (vs LSTM)	p-value
LSTM	3036.66	2.98%	3810.67	0.7940	-	-
GRU	2316.68	2.29%	2972.44	0.8747	1.7085	0.0897
BiLSTM	6359.92	6.25%	6887.68	0.3270	-8.0372	0.0000
BiGRU	3450.10	3.42%	4014.97	0.7713	-1.5633	0.1202
<i>PeepholeRNN</i>	1781.60	1.79%	2401.79	0.9182	3.8188	0.0002
SimpleRNN	2793.12	2.87%	3439.75	0.8322	5.5377	0.0000
<i>Transformer</i>	23064.24	23.09%	24343.61	-7.4067	-20.9587	0.0000
TCN	17799.84	17.22%	19590.93	-4.4446	-14.6139	0.0000
ARIMA	23683.28	22.30%	23802.86	-94.8501	-26.6315	0.0000

4.2 Analisis Uji-T

Uji-T independen menunjukkan perbedaan signifikan antara residual LSTM dan BiLSTM ($p = 0.0000$), *PeepholeRNN* ($p = 0.0002$), SimpleRNN ($p = 0.0000$), *Transformer* ($p = 0.0000$), TCN ($p = 0.0000$), serta ARIMA ($p = 0.0000$). Namun, GRU ($p = 0.0897$) dan BiGRU ($p = 0.1202$) tidak menunjukkan perbedaan signifikan, mengindikasikan performa yang sebanding dengan LSTM. Hasil ini menegaskan bahwa model dengan mekanisme memori yang dioptimalkan (seperti *PeepholeRNN*) unggul, sementara model kompleks seperti *Transformer* dan TCN mungkin membutuhkan penyesuaian lebih lanjut.

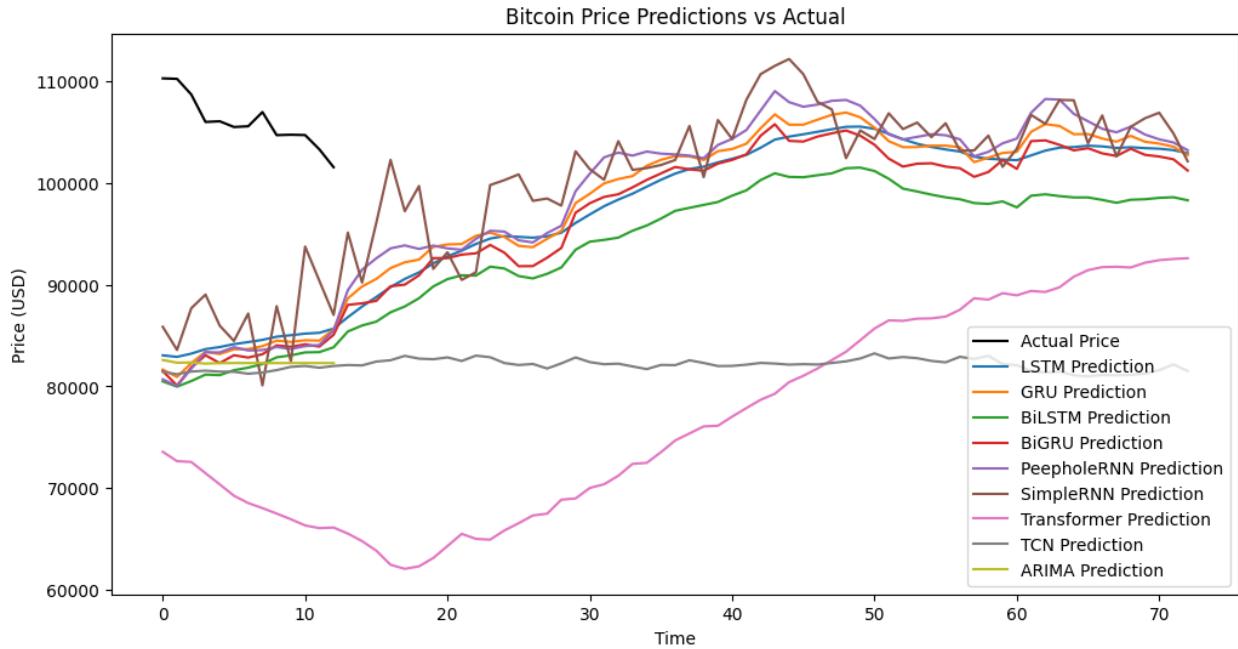
4.3 Pembahasan Mendalam



Gambar 2. Training Loss (MSE)

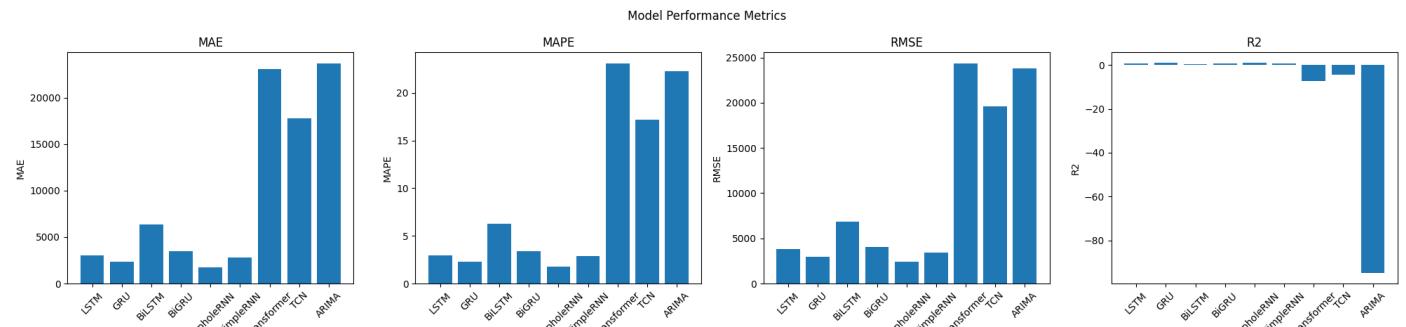
Grafik ini menunjukkan Training Loss (MSE) per Epoch dari berbagai model deep learning untuk prediksi deret waktu. Model

terbaik *PeepholeRNN*. Alasannya *PeepholeRNN* memiliki nilai loss paling rendah dan stabil sejak awal hingga akhir pelatihan, menunjukkan performa terbaik dalam meminimalkan kesalahan prediksi dibanding model lain. Model dengan loss awal tinggi seperti TCN dan *Transformer* menunjukkan performa lebih buruk karena butuh lebih banyak *epoch* untuk konvergen dan tetap memiliki *loss* akhir lebih tinggi.



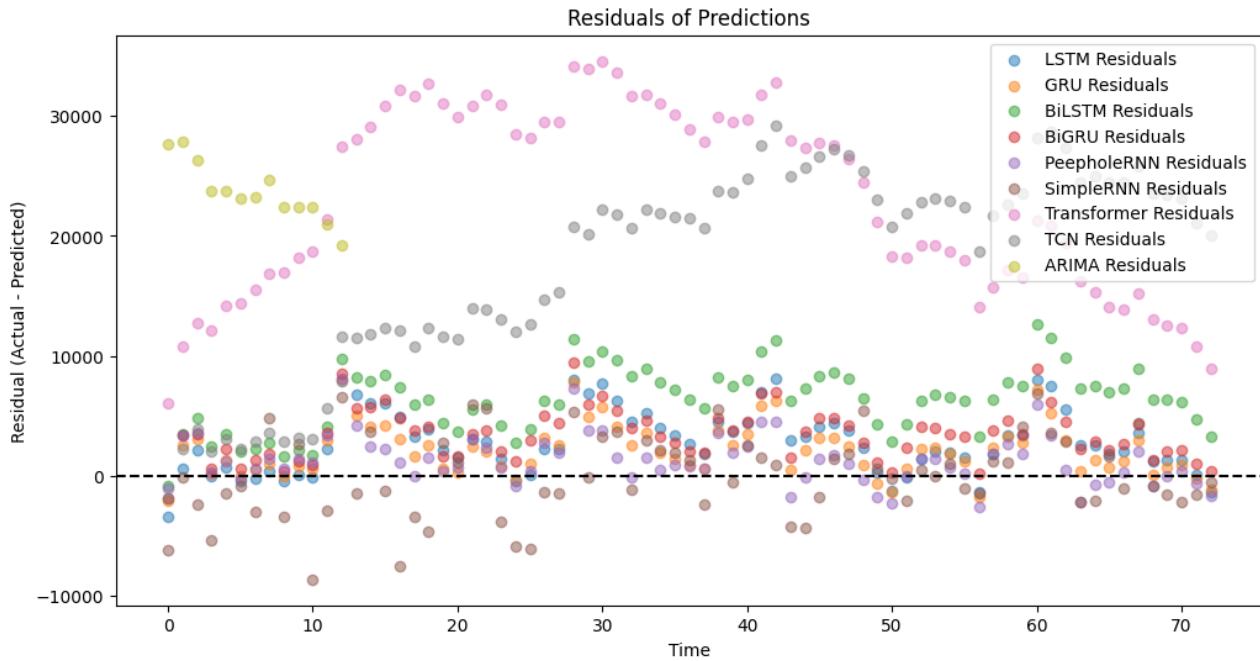
Gambar 3. Harga Prediksi Vs Harga Asli

Visualisasi menunjukkan bahwa prediksi *PeepholeRNN* paling mendekati data aktual, sementara *Transformer* dan ARIMA menunjukkan deviasi besar.



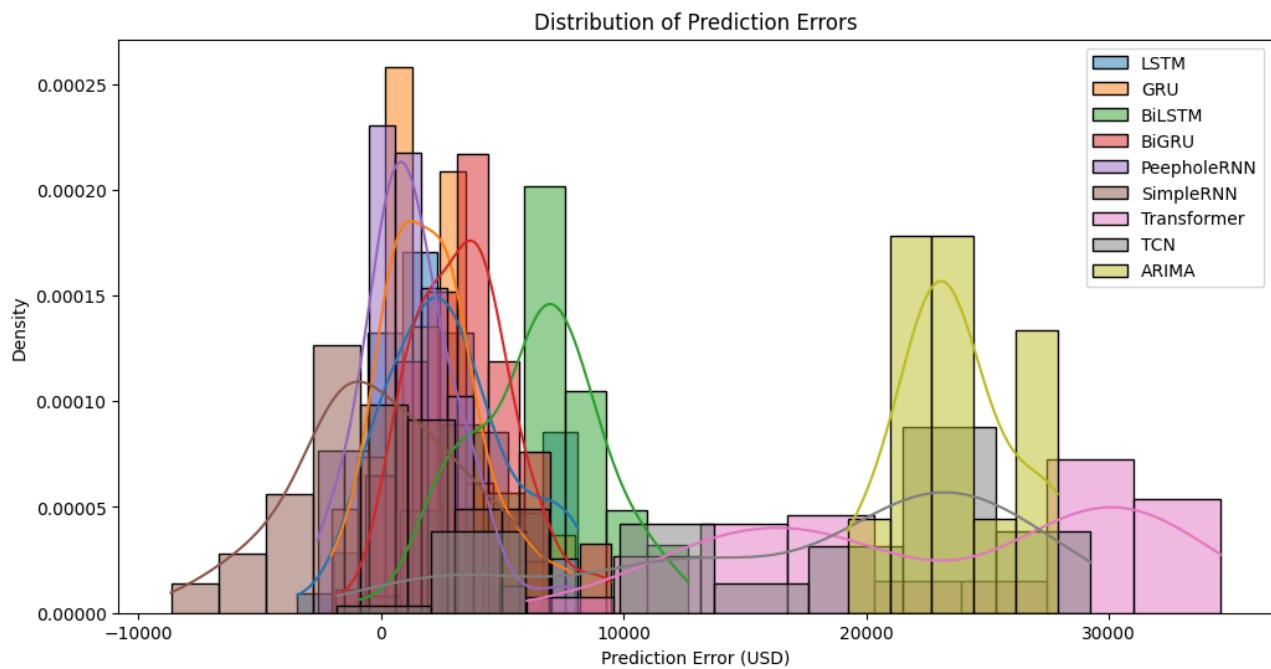
Gambar 4. Metriks Performa Model

Performa unggul *PeepholeRNN* dapat dijelaskan oleh mekanisme *peephole connection* yang memungkinkan pembaruan gate berdasarkan status sel saat ini, meningkatkan sensitivitas terhadap perubahan jangka pendek dalam harga Bitcoin. GRU dan LSTM juga efektif karena kemampuan mereka menangani ketergantungan jangka panjang, yang krusial dalam data volatil seperti kripto. Sebaliknya, *Transformer* dan TCN, meskipun dirancang untuk data deret waktu kompleks, tampaknya kurang optimal karena dataset yang relatif kecil (365 hari) dan kurangnya penyetelan *hyperparameter*. ARIMA, yang bergantung pada asumsi linieritas, gagal menangkap non-linearitas pasar Bitcoin, menghasilkan *R*² yang sangat negatif.



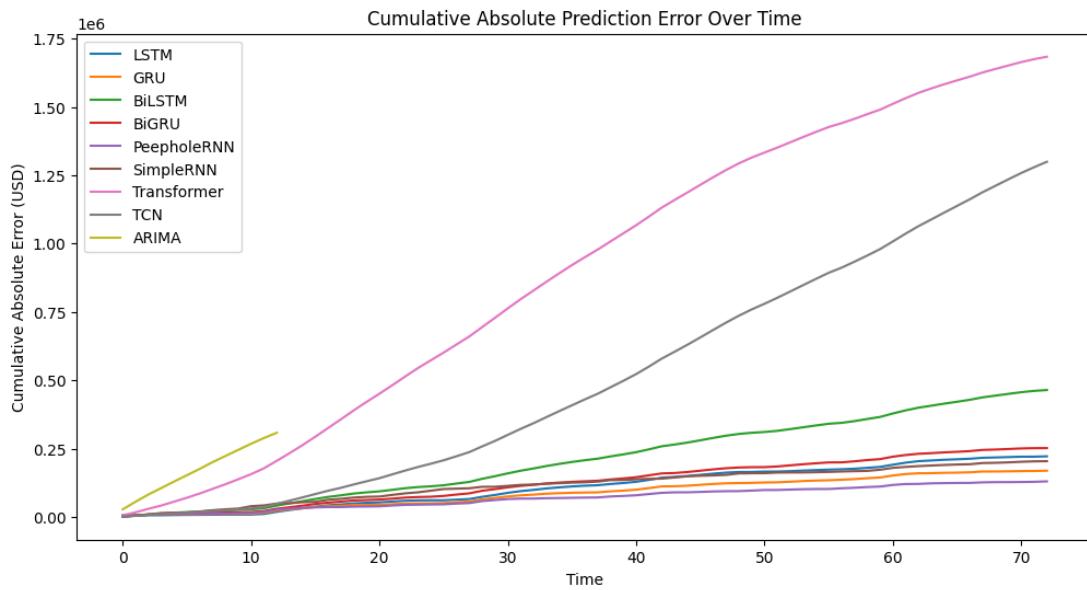
Gambar 5. Residual Plot

Grafik ini adalah Residual Plot yang menunjukkan selisih antara harga aktual dan hasil prediksi dari berbagai model (*residual = actual - predicted*). Model terbaik *PeepholeRNN* (Ungu muda) Alasannya Residual *PeepholeRNN* paling dekat dengan garis nol (horizontal putus-putus), menandakan prediksi mendekati nilai aktual. Penyebaran residual *PeepholeRNN* relatif kecil dan stabil sepanjang waktu. Model seperti *Transformer*, *TCN*, dan *ARIMA* memiliki residual besar dan jauh dari nol, menunjukkan prediksi yang buruk. Model yang baik memiliki residual kecil, tersebar simetris di sekitar nol, dan tidak berpola mencolok.



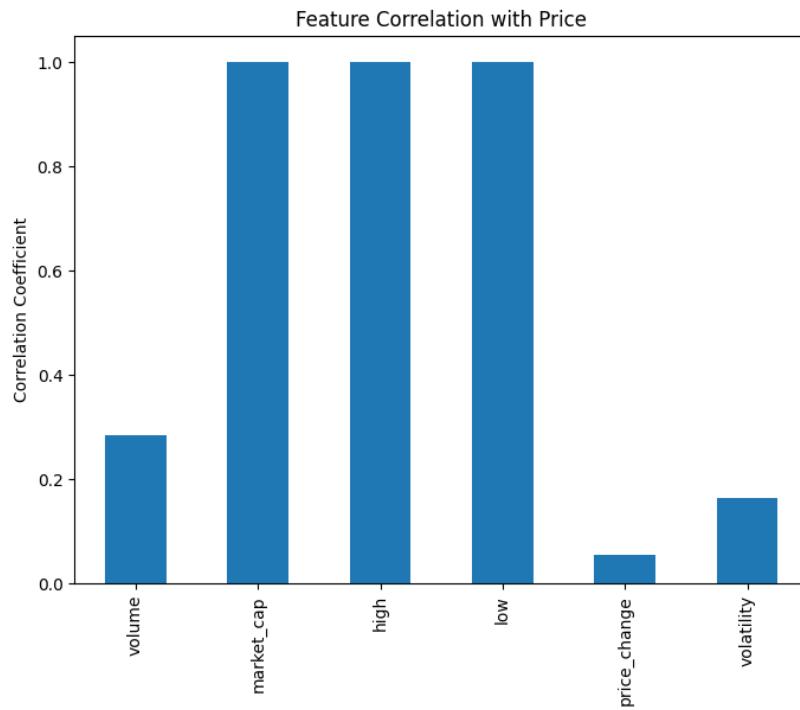
Gambar 6. Distribusi Error Prediksi

Grafik ini adalah distribusi error prediksi (*Prediction Error Distribution*) dari berbagai model. Model terbaik *PeepholeRNN* Alasannya distribusi error Peephole paling sempit dan terpusat dekat nol, menandakan prediksi paling akurat dan konsisten. Sebaliknya, *Transformer* dan *ARIMA* menyebar luas, menunjukkan error besar dan tidak stabil.



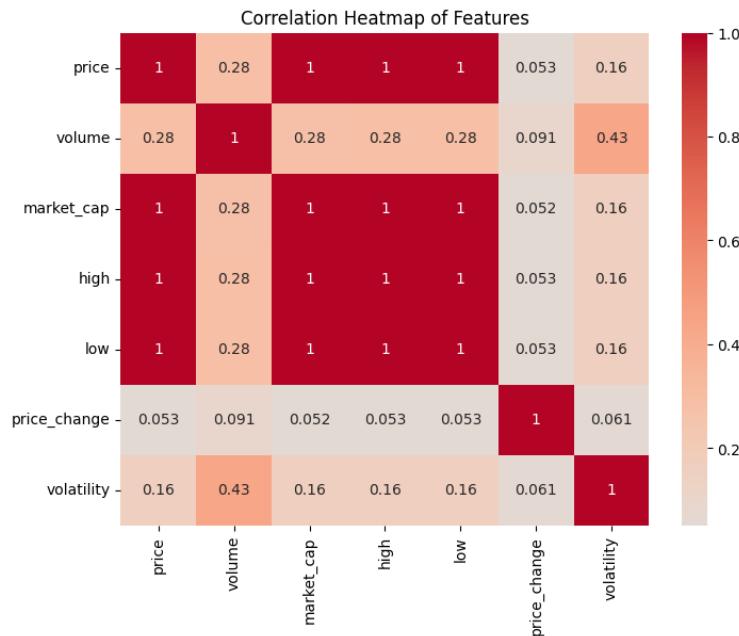
Gambar 7. Akumulasi Kesalahan Prediksi Tiap Model

PeepholeRNN (garis ungu paling bawah) memiliki ***total error terkecil*** sepanjang waktu, artinya prediksinya paling akurat dan stabil dibanding model lain seperti *Transformer* dan *TCN* yang kesalahannya terus meningkat tajam.



Gambar 8. Korelasi Fitur Terhadap Harga

Grafik ini menunjukkan korelasi fitur terhadap harga Bitcoin. Fitur terbaik yaitu *market_cap*, *high*, dan *low*. Ketiganya memiliki korelasi paling tinggi (≈ 1.0) dengan harga, artinya sangat kuat dan searah, sehingga paling relevan digunakan untuk prediksi harga.



Gambar 9. Heatmap Korelasi Antar Fitur

Grafik ini adalah *heatmap* korelasi antar fitur. Fitur terbaik untuk prediksi harga: *market_cap*, *high*, dan *low* Alasannya: Ketiganya punya korelasi sempurna (1.0) terhadap *price*, artinya paling kuat dan relevan untuk model prediksi harga Bitcoin.

V. KESIMPULAN

Penelitian ini menyimpulkan bahwa Peephole RNN adalah model paling efektif untuk memprediksi harga Bitcoin berdasarkan data *CoinGecko*, dengan akurasi tinggi (R^2 0.9182) dan error minimal (MAE 1781.60). Model *deep learning* seperti LSTM, GRU, dan SimpleRNN juga menunjukkan performa baik, sedangkan *Transformer*, TCN, dan ARIMA terbukti kurang sesuai untuk data ini. Uji-T mengkonfirmasi perbedaan signifikan antar model, menekankan pentingnya pemilihan arsitektur yang sesuai dengan karakteristik data kripto. Untuk aplikasi praktis, investor disarankan menggunakan *PeepholeRNN* atau GRU dengan data tambahan seperti sentimen media sosial. Penelitian mendatang dapat fokus pada dataset yang lebih besar, penyetelan hyperparameter, dan integrasi variabel eksternal untuk meningkatkan akurasi, terutama untuk model kompleks seperti *Transformer*.

DAFTAR PUSTAKA

- [1] Ji, S., Kim, J., & Im, H. (2019). A comparative study of bitcoin price prediction using deep learning. *Mathematics*, 7(10). <https://doi.org/10.3390/math7100898>
- [2] Kanaparthi, V. (2024). *Robustness Evaluation of LSTM-based Deep Learning Models for Bitcoin Price Prediction in the Presence of Random Disturbances*. <https://doi.org/10.21203/rs.3.rs-3906529/v1>
- [3] Kaur, R., Uppal, M., Gupta, D., Juneja, S., Arafat, S. Y., Rashid, J., Kim, J., & Alroobaea, R. (2025). Development of a cryptocurrency price prediction model: leveraging GRU and LSTM for Bitcoin, Litecoin and Ethereum. *PeerJ Computer Science*, 11. <https://doi.org/10.7717/peerj-cs.2675>
- [4] Nakamoto, S. (2008). *Bitcoin: A Peer-to-Peer Electronic Cash System*. www.bitcoin.org
- [5] Rakhmadi Pratama, A. (2022). *Price Prediction Using ARIMA Model of Monthly Closing Price of Bitcoin*. <https://ejournal.unib.ac.id/index.php/jdsd/index>
- [6] Salwa, N., Tatsara, N., Amalia, R., Zohra, A. F., Statistika, P. S., Kuala, S., & Aceh, B. (2018). Peramalan Harga Bitcoin Menggunakan Metode ARIMA (Autoregressive Integrated Moving Average). In *Journal of Data Analysis* (Vol. 1, Issue 1).
- [7] Suominen, A., Wang, X., & Mezei, J. (2024). *Deep Learning for Cryptocurrency Price Prediction-LSTM Model Performance Comparison and Evaluation Deep Learning for Cryptocurrency Price Prediction-LSTM Model Performance Comparison and Evaluation Title: Deep Learning for Cryptocurrency Price Prediction-LSTM Model Performance Comparison and Evaluation*.
- [8] Tumpa, S. N., Dewage, K., & Maduranga, G. (2025). *Advanced Hybrid RNN Architectures for Real-time Cryptocurrency Forecasting and Strategic Trading Optimization*. <https://github.com/shamima08/>
- [9] Ye, Z., Wu, Y., Chen, H., Pan, Y., & Jiang, Q. (2022). A Stacking Ensemble Deep Learning Model for Bitcoin

Price Prediction Using Twitter Comments on Bitcoin. *Mathematics*, 10(8). <https://doi.org/10.3390/math10081307>

[10] Zhang, B., Song, C., Jiang, X., & Li, Y. (2023). Electricity price forecast based on the STL-TCN-NBEATS model. *Heliyon*, 9(1). <https://doi.org/10.1016/j.heliyon.2023.e13029>