

INVESTASI DI ERA AI: ANALISIS TREN HARGA CRYPTOCURRENCY BERBASIS KECERDASAN BUATAN (AI) DAN KORELASI DENGAN SAHAM NVIDIA

Akmal Kherudin Rachman¹, N. Neni Triana², Thomas Nadaek³

^{1, 2, 3}Universitas Buana Perjuangan Karawang, Jl. HS. Ronggo Waluyo, Karawang, Jawa Barat, Indonesia
Email: mn19.akmalrachman@mhs.ubpkarawang.ac.id

Article History

Received: 03-08-2026

Revision: 22-08-2026

Accepted: 25-08-2026

Published: 28-08-2026

Abstract. The advancement of artificial intelligence (AI) has driven growth in the technology sector and the emergence of AI-based crypto assets, making the relationships between these assets a subject worthy of study. This research analyzes the price relationships between Nvidia (NVDA) stock and Bitcoin (BTC), Bittensor (TAO), NEAR Protocol (NEAR), and Internet Computer (ICP), while comparing the performance of Prophet and Long Short-Term Memory (LSTM) models. A quantitative approach utilizing time-series analysis was employed. Daily closing price and volume data were obtained from CoinMarketCap for the crypto assets and Investing.com for NVDA, covering the period from January 16, 2025, to February 18, 2026—comprising 273 observations aligned with NVDA's trading days. The analysis encompassed descriptive statistics, Pearson correlation, the Augmented Dickey-Fuller (ADF) stationarity test, Prophet and LSTM modeling, and Mean Absolute Percentage Error (MAPE) evaluation. The results reveal varying strengths in inter-asset relationships and differing stationarity characteristics across the price series. LSTM tended to project price increases for the crypto assets and a decline for NVDA, whereas Prophet yielded more conservative projections. Based on MAPE, Prophet exhibited an average prediction error 12.9% lower than that of LSTM, indicating superior predictive performance during the study period.

Keywords: AI-Based Cryptocurrency; Investment Strategy; LSTM; Nvidia Stock; Portfolio Diversification; Price Prediction; Prophet.

Abstrak. Perkembangan kecerdasan buatan (AI) mendorong pertumbuhan sektor teknologi dan munculnya aset kripto berbasis AI, sehingga hubungan antar-aset tersebut penting dikaji. Penelitian ini menganalisis hubungan harga saham Nvidia (NVDA) dengan Bitcoin (BTC), Bittensor (TAO), NEAR Protocol (NEAR), dan Internet Computer (ICP), serta membandingkan kinerja model Prophet dan Long Short-Term Memory (LSTM). Penelitian menggunakan pendekatan kuantitatif dengan analisis *time series*. Data harga penutupan dan volume harian diperoleh dari CoinMarketCap untuk aset kripto dan Investing.com untuk NVDA selama 16 Januari 2025 hingga 18 Februari 2026, mencakup 273 pengamatan yang disesuaikan dengan hari perdagangan NVDA. Analisis meliputi statistik deskriptif, korelasi Pearson, uji stasioneritas Augmented Dickey-Fuller (ADF), pemodelan Prophet dan LSTM, serta evaluasi Mean Absolute Percentage Error (MAPE). Hasil menunjukkan variasi kekuatan hubungan antar-aset dan karakteristik stasioneritas pada setiap deret harga. LSTM cenderung memproyeksikan kenaikan harga aset kripto dan penurunan NVDA, sedangkan Prophet menghasilkan proyeksi lebih konservatif. Berdasarkan MAPE, Prophet memiliki kesalahan prediksi rata-rata 12,9% lebih rendah daripada LSTM, sehingga menunjukkan kinerja prediksi lebih baik pada periode penelitian.

Kata Kunci: Cryptocurrency Berbasis AI; Diversifikasi Portofolio; LSTM; Prediksi Harga; Prophet; Saham Nvidia; Strategi Investasi.

How to Cite: Rachman, A. K., Triana, N. N., & Nadaek, T. (2026). Investasi di Era AI: Analisis Tren Harga Cryptocurrency Berbasis Kecerdasan Buatan (AI) dan Korelasi dengan Saham NVIDIA. *HORIZON: Indonesian Journal of Multidisciplinary*, 4 (4), 5603-5616. <http://doi.org/10.54373/hijm.v4i4.7315>

PENDAHULUAN

Perkembangan teknologi kecerdasan buatan (*artificial intelligence/AI*) telah mendorong transformasi pada sektor teknologi dan keuangan, termasuk munculnya aset kripto yang dikembangkan untuk mendukung ekosistem AI. Kondisi tersebut menciptakan ruang investasi yang mempertemukan pasar modal konvensional dengan aset digital berbasis teknologi. Oleh karena itu, hubungan antara saham perusahaan yang menjadi infrastruktur utama pengembangan AI dan aset kripto yang merepresentasikan penerapan AI dalam ekosistem *blockchain* menjadi penting untuk dikaji, terutama karena kedua kelompok aset memiliki karakteristik pasar, tingkat volatilitas, dan mekanisme perdagangan yang berbeda.

Penelitian ini menggunakan Nvidia (NVDA), Bitcoin (BTC), Bittensor (TAO), *NEAR Protocol* (NEAR), dan Internet Computer (ICP) sebagai objek penelitian. NVDA dipilih sebagai representasi pasar saham karena perusahaan tersebut memiliki posisi penting dalam penyediaan GPU dan infrastruktur komputasi untuk pengembangan AI. Sementara itu, BTC digunakan sebagai representasi utama pasar kripto karena memiliki posisi dominan dan dapat menjadi indikator umum pergerakan pasar aset digital. TAO, NEAR, dan ICP dipilih untuk merepresentasikan aset kripto yang memiliki keterkaitan dengan perkembangan teknologi AI dan infrastruktur *blockchain*. Dengan demikian, kelima aset tersebut tidak sekadar dibandingkan berdasarkan popularitas atau kapitalisasi pasar, tetapi digunakan untuk membentuk perbandingan antara representasi AI di pasar saham, kondisi umum pasar kripto, dan aset kripto yang memiliki keterkaitan dengan ekosistem AI. Pemilihan kelompok aset tersebut memungkinkan penelitian mengamati apakah pergerakan harga aset dalam ekosistem teknologi yang saling berkaitan menunjukkan pola hubungan yang serupa atau justru berbeda.

Perbedaan karakteristik tersebut juga penting dalam konteks prediksi harga. Pasar saham NVDA mengikuti mekanisme perdagangan bursa dengan jadwal tertentu, sedangkan pasar kripto berlangsung selama 24 jam dan cenderung memiliki volatilitas yang lebih tinggi. Kondisi ini menjadikan pemodelan *time series* relevan untuk mengidentifikasi pola historis dan mengevaluasi kemampuan model dalam menghasilkan prediksi. Selain itu, perbandingan antar-aset dapat memberikan gambaran apakah model prediksi yang memiliki karakteristik berbeda mampu mempertahankan kinerja yang konsisten pada aset saham dan aset kripto.

Sejumlah penelitian terdahulu menunjukkan bahwa kinerja *Prophet* dan LSTM pada data keuangan dapat berbeda. Cheng et al. (2024) menemukan bahwa LSTM mengungguli *Prophet* dalam memprediksi harga dan volatilitas Bitcoin berdasarkan MSE dan MAE, meskipun *Prophet* tetap mampu menangkap pola tren dan musiman. McNally et al. (2018) juga menunjukkan bahwa LSTM dapat memprediksi arah harga Bitcoin, tetapi memerlukan data

dan proses pelatihan yang lebih kompleks. Sebaliknya, *Prophet* memiliki struktur yang lebih sederhana dan interpretatif dalam memodelkan tren, musiman, serta perubahan pola (Taylor dan Letham, 2018).

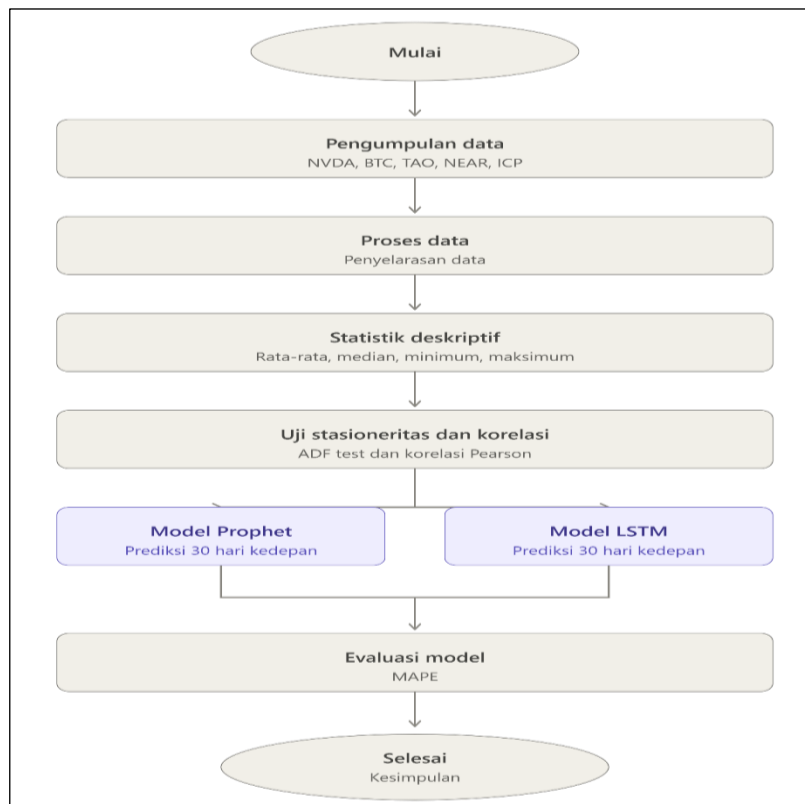
Kinerja kedua model sangat dipengaruhi oleh karakteristik aset, periode pengamatan, konfigurasi model, dan tujuan prediksi. Makridakis et al. (2020) menegaskan bahwa model *machine learning* tidak selalu mengungguli metode statistik pada seluruh data *time series*. Pada aset kripto, Awan et al. (2021) menunjukkan bahwa kinerja LSTM bergantung pada arsitektur, fitur, dan periode pelatihan. Sementara itu, penelitian pada pasar saham menunjukkan bahwa LSTM mampu menangkap hubungan temporal yang kompleks, tetapi hasilnya tetap dipengaruhi oleh karakteristik data dan metode evaluasi (Fischer dan Krauss, 2018; Sezer et al., 2020). Dengan demikian, belum terdapat model yang secara konsisten unggul pada seluruh aset dan kondisi pasar.

Penelitian yang membandingkan *Prophet* dan LSTM pada saham teknologi, Bitcoin, serta aset kripto yang berkaitan dengan ekosistem AI masih terbatas. Oleh karena itu, penelitian ini menguji kedua model pada NVDA, BTC, TAO, NEAR, dan ICP yang memiliki karakteristik pasar dan tingkat volatilitas berbeda. Evaluasi menggunakan metrik yang sama pada seluruh aset untuk membandingkan kinerja model secara konsisten. Hasil penelitian diharapkan dapat memperluas kajian prediksi harga berbasis *time series*, khususnya pada aset dalam ekosistem teknologi AI. Penelitian ini bertujuan untuk menganalisis karakteristik harga, hubungan antar-aset, dan stasioneritas NVDA, BTC, TAO, NEAR, dan ICP, serta membandingkan kinerja *Prophet* dan LSTM dalam memprediksi harga 30 hari ke depan. Analisis dilakukan menggunakan statistik deskriptif, korelasi Pearson, uji *Augmented Dickey-Fuller* (ADF), serta evaluasi model berdasarkan *Mean Absolute Percentage Error* (MAPE). Dengan membandingkan kelima aset dalam satu kerangka analisis, penelitian ini diharapkan memberikan kontribusi empiris terhadap kajian prediksi *time series* pada aset keuangan yang berada dalam ekosistem teknologi AI tetapi memiliki karakteristik pasar yang berbeda.

METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan metode analisis *time series* untuk memahami pola pergerakan harga dan memprediksi harga di masa depan. Pendekatan ini dipilih karena data harga aset keuangan bersifat berurutan (*time series*) dan sangat dipengaruhi oleh pergerakan waktu, sehingga analisis statistik konvensional saja tidak cukup. Dalam penelitian ini, penulis menggabungkan beberapa teknik analisis mulai dari statistik deskriptif, uji korelasi, uji stasioneritas, hingga pemodelan prediksi menggunakan *Prophet* dan

LSTM. Data harga harian (*close price* dan *volume*) diambil dari *Coin Market Cap* untuk *cryptocurrency* dan *Investing.com* untuk saham Nvidia. Periode pengamatan adalah 16 Januari 2025 hingga 18 Februari 2026 dengan total 273 hari trading untuk menyesuaikan dengan hari pasar saham NVDA yang tidak buka di akhir pekan dan hari libur. Data kemudian digabungkan menjadi satu tabel besar agar memudahkan analisis korelasi dan perbandingan antar aset.



Gambar 1. Flow chart metode penelitian

Statistik Deskriptif

Statistik deskriptif digunakan untuk memberikan gambaran awal mengenai karakteristik data harga masing-masing aset. Melalui statistik ini, peneliti dapat melihat rata-rata harga, tingkat penyebaran data (standar deviasi), nilai terendah, nilai tengah (median), dan nilai tertinggi selama periode pengamatan. Metode ini sangat penting karena memberikan pemahaman dasar tentang seberapa besar fluktuasi harga yang terjadi pada setiap aset sebelum dilakukan analisis yang lebih mendalam (Evans, 1996). Statistik deskriptif sangat cocok untuk data harga aset kripto dan saham karena data ini bersifat volatil dan memiliki rentang nilai yang sangat lebar. Dengan mengetahui tingkat volatilitas melalui standar deviasi, investor dapat langsung memahami tingkat risiko masing-masing aset. Dalam penelitian ini, statistik deskriptif juga menjadi dasar untuk menghubungkan dengan hasil uji stasioneritas, sehingga

peneliti dapat menjelaskan mengapa beberapa aset memiliki pola harga yang lebih stabil dibandingkan yang lain (Brooks, 2019).

Uji Korelasi *Pearson*

Uji korelasi *Pearson* digunakan untuk mengukur kekuatan dan arah hubungan linier antara harga saham NVDA dengan harga *cryptocurrency* serta antar sesama aset kripto. Metode ini menghasilkan nilai korelasi yang berkisar antara -1 hingga +1, di mana nilai mendekati +1 menunjukkan hubungan positif yang kuat, mendekati -1 menunjukkan hubungan negatif yang kuat, dan mendekati 0 menunjukkan hubungan yang sangat lemah (Evans, 1996). Uji korelasi *Pearson* dipilih karena sederhana, mudah diinterpretasikan, dan sangat sesuai untuk data harga aset keuangan yang bersifat kontinu (Stock & Watson, 2019). Dalam konteks investasi, hasil korelasi ini sangat berguna untuk melihat apakah aset-aset ini bergerak bersama atau berlawanan arah, sehingga dapat membantu investor dalam menyusun strategi diversifikasi portofolio. Penelitian ini menggunakan *Pearson* karena data harga relatif normal dan tidak mengandung banyak data ekstrem.

Uji Stasioneritas *Augmented Dickey-Fuller* (ADF)

Uji stasioneritas menggunakan *Augmented Dickey-Fuller* (ADF) dilakukan untuk mengetahui apakah suatu deret waktu memiliki akar unit (*unit root*) atau tidak. Deret waktu dikatakan stasioner apabila karakteristik statistiknya, seperti rata-rata dan varians, relatif tidak berubah sepanjang waktu. Dalam uji ADF, hipotesis nol (H_0) menyatakan bahwa deret waktu mengandung akar unit atau bersifat tidak stasioner, sedangkan hipotesis alternatif (H_1) menyatakan bahwa deret waktu tidak mengandung akar unit atau bersifat stasioner (Brooks, 2019).

Keputusan pengujian didasarkan pada nilai *p-value*. Jika *p-value* < 0,05, maka H_0 ditolak sehingga data dinyatakan stasioner. Sebaliknya, jika *p-value* ≥ 0,05, maka H_0 tidak ditolak sehingga terdapat bukti bahwa data masih mengandung akar unit dan belum stasioner (Stock & Watson, 2019). Pengujian ini penting dalam analisis *time series* karena penggunaan data yang tidak stasioner dalam analisis hubungan atau pemodelan tertentu dapat menghasilkan hubungan yang bersifat semu (*spurious relationship*). Dalam penelitian ini, uji ADF digunakan untuk mengidentifikasi karakteristik stasioneritas harga harian NVDA, BTC, TAO, NEAR, dan ICP sebelum dilakukan analisis lebih lanjut. Hasil pengujian menjadi dasar untuk memahami karakteristik deret waktu masing-masing aset dan memastikan bahwa interpretasi hubungan antarvariabel dilakukan dengan mempertimbangkan sifat statistik datanya. Stasioneritas tidak

digunakan sebagai ukuran volatilitas, karena keduanya merupakan karakteristik deret waktu yang berbeda.

Model Forecasting

Model forecasting adalah metode untuk memprediksi nilai di masa depan berdasarkan data historis. Dalam penelitian ini, digunakan dua model forecasting yaitu *Facebook Prophet* dan *Long Short-Term Memory* (LSTM). Kedua model ini dipilih karena mampu menangani data harga yang kompleks, volatil, dan memiliki pola yang tidak selalu linear.

Facebook Prophet

Facebook Prophet adalah model forecasting yang dikembangkan oleh tim Facebook untuk memprediksi data *time series* dengan mudah dan akurat. Model ini bekerja dengan memecah data menjadi tiga komponen utama yaitu tren, seasonalitas (pola musiman), dan hari libur (Taylor & Letham, 2018). Prophet sangat cocok untuk data harga aset keuangan karena dapat menangani data yang memiliki tren naik atau turun secara otomatis tanpa perlu banyak penyesuaian rumit. Dalam penelitian ini, Prophet dipilih karena kemampuannya memberikan prediksi yang stabil dan mudah diinterpretasikan oleh investor bisnis.

Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) adalah jenis model *deep learning* yang termasuk dalam kelompok *neural network*. Model ini dirancang khusus untuk memproses data berurutan dan mampu “mengingat” pola dari periode sebelumnya dalam jangka waktu yang panjang. LSTM sangat cocok untuk data harga *cryptocurrency* yang sangat volatil dan memiliki pola naik-turun yang sulit diprediksi dengan model sederhana (PyTorch, 2025). Meskipun lebih kompleks, LSTM sering memberikan hasil yang lebih akurat pada data dengan pergerakan tidak teratur, sehingga menjadi pilihan yang baik untuk membandingkan performa dengan *Prophet* dalam penelitian ini.

Metrik Evaluasi Model

Penelitian ini menggunakan *Mean Absolute Percentage Error* (MAPE) sebagai metrik utama untuk mengevaluasi kesalahan prediksi dari model *Prophet* dan *Long Short-Term Memory* (LSTM). MAPE menunjukkan rata-rata persentase kesalahan antara nilai aktual dan nilai hasil prediksi. Nilai MAPE yang lebih kecil menunjukkan bahwa hasil prediksi model memiliki kesalahan relatif yang lebih rendah dibandingkan nilai aktual (Scikit-learn, 2020).

Penggunaan MAPE memungkinkan perbandingan kinerja kedua model pada lima aset yang memiliki rentang harga berbeda. Dalam penelitian ini, MAPE digunakan untuk menentukan model yang menghasilkan kinerja prediksi relatif lebih baik pada masing-masing aset selama periode pengujian. Nilai MAPE yang diperoleh tidak diinterpretasikan sebagai ukuran risiko investasi maupun sebagai dasar langsung untuk menentukan keputusan membeli atau menjual aset. Demikian pula, kinerja prediksi yang lebih baik tidak secara otomatis menunjukkan bahwa suatu aset lebih sesuai untuk strategi diversifikasi. Oleh karena itu, hasil MAPE diposisikan sebagai indikator evaluasi performa model dalam menghasilkan prediksi harga, sedangkan keputusan investasi memerlukan pertimbangan terhadap faktor lain di luar cakupan penelitian.

HASIL DAN DISKUSI

Statistik Deskriptif

Data yang telah dikumpulkan kemudian diproses menggunakan aplikasi *AI-Coin* sehingga menyajikan ringkasan statistik deskriptif harga penutupan harian (dalam USD) untuk lima aset yang diteliti selama periode 16 Januari 2025 hingga 18 Februari 2026, sebagaimana disajikan pada Tabel 1.

Tabel 1. Data Harga Penutupan Harian (dalam USD) Periode 16 Januari 2025 -18 Februari 2026

Statistik	Nvidia (NVDA)	Bittensor (TAO)	NEAR Project (NEAR)	Internet Protocol (ICP)	Bitcoin (BTC)
Rata-rata Harga (USD)	158,13	331,47	2,47	4,97	99.762,53
Persebaran Harga (USD)	30,10	75,86	0,75	1,50	13.423,59
Minimum (USD)	94,31	145,63	0,96	2,23	62.702,10
Median (USD)	172,41	338,16	2,51	4,99	101.663,19
Maksimum (USD)	207,04	485,38	5,75	11,36	124.752,53

Sumber: Coinmarketcap

Bitcoin (BTC) memiliki rata-rata harga tertinggi yaitu US\$ 99.762,53 dengan median US\$ 101.663,19. Bittensor (TAO) berada di posisi kedua dengan rata-rata US\$ 331,47 dengan standar deviasi (persebaran harga) tertinggi sebesar US\$ 75,86 (sekitar 22,9% dari rata-ratanya). Tingkat volatilitas yang sangat tinggi ini menunjukkan bahwa Bittensor merupakan aset yang paling berisiko di antara kelima aset yang diteliti. Saham Nvidia (NVDA) memiliki rata-rata harga US\$ 158,13 dengan standar deviasi US\$ 30,10 (sekitar 19% dari rata-rata), menunjukkan volatilitas yang jauh lebih rendah dibandingkan aset kripto. Rentang harga NVDA juga relatif sempit (US\$ 94,31 – US\$ 207,04), yang mencerminkan karakteristik saham


blue-chip teknologi yang lebih stabil meskipun tetap dipengaruhi oleh tren AI global (Investing.com, 2026). *NEAR Protocol* dan *Internet Computer* memiliki rata-rata harga rendah yaitu US\$ 2,47 dan US\$ 4,97 dengan volatilitas yang relatif terkendali (std US\$ 0,75 dan US\$ 1,50).

Hasil standar deviasi yang tinggi pada TAO dan BTC selaras dengan hasil uji stasioneritas *Augmented Dickey-Fuller* (ADF) yang menunjukkan bahwa kedua aset ini tidak stasioner ($p\text{-value} > 0,05$), sehingga pola harganya cenderung mengandung tren jangka panjang atau fluktuasi yang tidak stabil. Sebaliknya, NEAR dan ICP yang memiliki standar deviasi rendah juga terkonfirmasi stasioner ($p\text{-value} < 0,05$), menandakan pola harga yang lebih terkontrol dan tidak memiliki tren permanen yang kuat (Brooks, 2019).

Uji Korelasi

Untuk menguji kolerasi kita menggunakan korelasi *Pearson* dibantu aplikasi *AI-Coin* dan telah didapatkan data yang tertera pada Tabel 2. Pada Tabel 2 menyajikan matriks korelasi *Pearson* antar harga penutupan harian lima aset yang diteliti. Korelasi tertinggi terdapat antara NEAR dan ICP sebesar 0,90, menunjukkan hubungan linier yang sangat kuat dan positif. Kedua aset ini sama-sama termasuk dalam kategori altcoin layer-1 yang berfokus pada skalabilitas *blockchain* dan aplikasi terdesentralisasi, sehingga pergerakan harganya cenderung mengikuti pola serupa akibat faktor pasar yang sama (CoinMarketCap, 2026). Korelasi yang cukup tinggi juga terlihat antara TAO dan BTC (0,73) serta TAO dan NEAR (0,64). Bittensor (TAO) tampaknya memiliki ketergantungan yang signifikan terhadap pergerakan Bitcoin sebagai aset acuan pasar *cryptocurrency* secara keseluruhan (Chandra et al., 2024).

Tabel 2. Korelasi Harga NVDA, BTC, TAO, NEAR, ICP



Saham Nvidia (NVDA) menunjukkan korelasi yang relatif lemah dengan BTC (0,28) dan bahkan negatif dengan TAO (-0,06), NEAR (-0,41), serta ICP (-0,51). Korelasi yang lemah ini mengindikasikan bahwa pergerakan harga NVDA sebagai saham *blue-chip* teknologi tidak selalu sejalan dengan aset *cryptocurrency*, meskipun NVDA merupakan penyedia GPU utama yang mendukung infrastruktur AI (Investing.com, 2026). Temuan ini memperkuat bahwa investor dapat memanfaatkan NVDA sebagai aset stabil untuk mengimbangi risiko volatilitas pada aset kripto berbasis AI dan mengelompokkan portofolio *AI-Coin* dengan BTC.

Uji Stasioneritas

Uji *Augmented Dickey-Fuller* (ADF) digunakan untuk mengidentifikasi keberadaan akar unit pada deret harga selama periode pengamatan 16 Januari 2025 hingga 18 Februari 2026. Hasil pengujian menunjukkan bahwa NEAR ($p\text{-value} = 0,0252$) dan ICP ($p\text{-value} = 0,0009$) memiliki $p\text{-value} < 0,05$, sehingga hipotesis nol yang menyatakan adanya akar unit ditolak. Dengan demikian, deret harga kedua aset tersebut dinyatakan stasioner berdasarkan spesifikasi pengujian yang digunakan. Sebaliknya, NVDA ($p\text{-value} = 0,8535$), TAO ($p\text{-value} = 0,1392$), dan BTC ($p\text{-value} = 0,8725$) memiliki $p\text{-value} \geq 0,05$, sehingga hipotesis nol tidak dapat ditolak dan deret harga ketiganya belum menunjukkan bukti yang cukup untuk dinyatakan stasioner.

Temuan tersebut menunjukkan bahwa karakteristik deret waktu kelima aset tidak sepenuhnya sama. Perbedaan hasil ADF mengindikasikan bahwa pola statistik harga selama periode pengamatan memiliki karakteristik yang berbeda, sehingga analisis dan pemodelan perlu mempertimbangkan sifat masing-masing deret. Kondisi ini sejalan dengan Brooks (2019) yang menjelaskan bahwa harga aset keuangan pada umumnya dapat mengandung akar unit, terutama ketika pergerakan harga mengikuti proses yang bersifat nonstasioner. Oleh karena itu, hasil ADF dalam penelitian ini lebih tepat dipahami sebagai informasi mengenai sifat statistik deret harga, bukan sebagai ukuran tingkat volatilitas suatu aset.

Hasil tersebut juga memiliki implikasi terhadap interpretasi hubungan antar-aset dan pemodelan *time series*. Deret harga yang tidak stasioner dapat menghasilkan hubungan yang bersifat semu apabila dianalisis secara langsung menggunakan metode tertentu tanpa mempertimbangkan karakteristik deretnya (Stock & Watson, 2019). Dengan demikian, pengujian ADF memberikan dasar diagnostik untuk memahami data sebelum hasil korelasi dan prediksi diinterpretasikan. Perbedaan stasioneritas antara aset saham dan kripto juga memperlihatkan bahwa penerapan satu model prediksi pada berbagai aset perlu dievaluasi secara empiris, bukan diasumsikan memiliki kinerja yang sama.

Hasil Uji ADF (Stasioneritas):
 Harga NVDA: p-value = 0,85345 → Tidak Stasioner
 Harga TAO: p-value = 0,13923 → Tidak Stasioner
 Harga DEKAT: nilai p = 0,02519 → Stasioner
 Harga ICP: nilai p = 0,00086 → Stasioner
 Harga BTC: p-value = 0,87253 → Tidak Stasioner

Gambar 1. Hasil Perhitungan Uji Stasioner ADF

Metrik Evaluasi Model

Tabel 3. Nilai Presentase MAPE

Saham/Kripto	MAPE Prophet	MAPE LSTM	Selisih	Interpretasi Selisih
NVDA	2,26%	2,47%	+0,21%	LSTM sedikit lebih buruk, tapi masih sangat dekat
BTC	3,64%	8,77%	+5,13%	LSTM jauh lebih tinggi kesalahannya (> 2 kali lipat)
TAO	6,99%	34,59%	+27,60%	LSTM sangat jauh lebih buruk (~ 5 kali lipat)
NEAR	11,57%	25,92%	+14,35%	LSTM > 2 kali lebih tinggi kesalahannya
ICP	10,86%	28,45%	+17,59%	LSTM > 2 kali lebih tinggi kesalahannya

Sumber: Perhitungan menggunakan Aplikasi AI-Coin

Hasil evaluasi menunjukkan bahwa *Prophet* menghasilkan MAPE yang lebih rendah daripada LSTM pada seluruh aset yang diteliti. Namun, perbedaan kinerja tersebut perlu dipahami sebagai hasil interaksi antara karakteristik data, struktur model, dan konfigurasi pemodelan, bukan semata-mata sebagai bukti bahwa *Prophet* selalu lebih unggul daripada LSTM. Pada NVDA, misalnya, perbedaan MAPE kedua model relatif kecil, yaitu 0,21 poin persentase. Sebaliknya, perbedaan semakin besar pada aset kripto, terutama TAO, NEAR, dan ICP. Pola ini menunjukkan bahwa kinerja model dapat berubah ketika diterapkan pada aset dengan karakteristik deret waktu yang berbeda.

Keunggulan relatif *Prophet* dalam penelitian ini dapat dikaitkan dengan karakteristik struktur modelnya yang secara eksplisit memodelkan tren dan komponen musiman serta dirancang untuk menangani perubahan pola dalam deret waktu (Taylor & Letham, 2018). Struktur tersebut memungkinkan model menghasilkan prediksi yang relatif stabil tanpa membutuhkan arsitektur pembelajaran yang kompleks. Sebaliknya, LSTM merupakan model *deep learning* yang dirancang untuk mempelajari dependensi temporal melalui jaringan berulang. Kemampuan tersebut dapat menjadi keunggulan ketika pola temporal kompleks dapat dipelajari dengan baik, tetapi performanya sangat bergantung pada konfigurasi model, panjang *sequence*, jumlah data pelatihan, serta karakteristik data yang digunakan (Fischer & Krauss, 2018; Sezer et al., 2020).

Temuan penelitian ini berbeda dengan sebagian hasil penelitian terdahulu yang menunjukkan keunggulan LSTM pada prediksi aset kripto. McNally et al. (2018), misalnya, menunjukkan bahwa LSTM dapat digunakan untuk memprediksi arah harga Bitcoin, sedangkan Cheng et al. (2024) melaporkan bahwa kinerja LSTM dapat mengungguli *Prophet* dalam konteks prediksi harga dan volatilitas Bitcoin berdasarkan metrik tertentu. Perbedaan tersebut memperlihatkan bahwa tidak terdapat model yang secara universal memberikan kinerja terbaik pada seluruh kondisi data. Makridakis et al. (2020) juga menunjukkan bahwa metode *machine learning* tidak selalu mengungguli metode statistik pada seluruh karakteristik deret waktu. Dalam konteks penelitian ini, MAPE yang lebih rendah pada *Prophet* menunjukkan bahwa model tersebut menghasilkan kesalahan relatif yang lebih kecil pada periode pengujian dibandingkan LSTM. Namun, hasil tersebut tidak dapat langsung diartikan bahwa *Prophet* lebih baik untuk seluruh aset kripto atau untuk periode yang berbeda. Besarnya selisih MAPE pada TAO, NEAR, dan ICP menunjukkan adanya perbedaan kemampuan kedua model dalam merepresentasikan pola data pada periode penelitian. Kemungkinan adanya *overfitting* pada LSTM juga perlu dipertimbangkan, tetapi kesimpulan tersebut tidak dapat dipastikan hanya berdasarkan nilai MAPE karena diperlukan pemeriksaan tambahan terhadap proses pelatihan, *validation loss*, konfigurasi hiperparameter, dan pola kesalahan prediksi.

Pada NVDA, kedekatan nilai MAPE antara *Prophet* dan LSTM menunjukkan bahwa kedua model memberikan kinerja yang relatif serupa pada periode pengujian. Sementara itu, pada BTC, TAO, NEAR, dan ICP, selisih MAPE yang lebih besar menunjukkan bahwa pemilihan model memberikan perbedaan hasil prediksi yang lebih nyata. Temuan ini memperkuat pandangan bahwa evaluasi model *time series* perlu dilakukan secara empiris pada masing-masing karakteristik aset. Dengan demikian, penelitian ini tidak menyimpulkan bahwa satu model selalu unggul, tetapi menunjukkan bahwa *Prophet* memberikan kinerja prediksi relatif lebih baik daripada LSTM pada lima aset dan periode pengamatan yang digunakan dalam penelitian ini.

Secara akademis, hasil tersebut memperluas penelitian terdahulu dengan menempatkan saham NVDA, BTC, dan tiga aset kripto yang berkaitan dengan ekosistem AI dalam satu kerangka perbandingan. Kajian sebelumnya lebih banyak membandingkan model pada satu jenis aset atau fokus pada Bitcoin, sedangkan penelitian ini memperlihatkan bagaimana kinerja dua model yang sama dapat berbeda ketika diterapkan pada aset dengan karakteristik pasar yang berbeda. Oleh karena itu, kontribusi utama penelitian terletak pada bukti empiris mengenai perbandingan kinerja *Prophet* dan LSTM pada lintas aset dalam ekosistem teknologi

AI, bukan pada klaim bahwa hasil prediksi tersebut secara langsung menentukan keputusan investasi.

KESIMPULAN

Penelitian ini menganalisis karakteristik harga, hubungan antar-aset, stasioneritas, serta perbandingan kinerja model *Prophet* dan LSTM pada NVDA, BTC, TAO, NEAR, dan ICP selama periode 16 Januari 2025 hingga 18 Februari 2026. Hasil analisis menunjukkan bahwa karakteristik pergerakan harga kelima aset berbeda, dengan TAO dan BTC menunjukkan penyebaran harga yang relatif tinggi dibandingkan NVDA. Uji ADF menunjukkan bahwa NEAR dan ICP memenuhi kriteria stasioner pada tingkat signifikansi 5%, sedangkan NVDA, BTC, dan TAO belum menunjukkan bukti yang cukup untuk dinyatakan stasioner. Hasil korelasi Pearson menunjukkan bahwa hubungan NVDA dengan aset kripto relatif lemah, sedangkan beberapa pasangan aset kripto memiliki hubungan yang lebih kuat, terutama NEAR dan ICP ($r = 0,90$) serta TAO dan BTC ($r = 0,73$). Temuan ini menunjukkan adanya perbedaan pola hubungan antara saham teknologi dan aset kripto serta hubungan yang lebih erat di antara sebagian aset dalam pasar kripto.

Perbandingan kinerja model menunjukkan bahwa *Prophet* menghasilkan MAPE lebih rendah daripada LSTM pada seluruh aset yang diuji. Perbedaan terbesar terdapat pada TAO, NEAR, dan ICP, sedangkan kinerja kedua model pada NVDA relatif berdekatan. Dengan demikian, pada periode dan data penelitian ini, *Prophet* memberikan kinerja prediksi yang lebih baik berdasarkan MAPE dibandingkan LSTM. Sementara itu, hasil prediksi 30 hari menunjukkan adanya perbedaan pola proyeksi antara kedua model, sehingga hasil prediksi perlu dipahami sebagai estimasi berdasarkan pola historis dan bukan sebagai kepastian pergerakan harga di masa mendatang. Secara keseluruhan, penelitian ini menunjukkan bahwa karakteristik deret waktu dan hubungan antar-aset berbeda antara NVDA dan aset kripto yang diteliti, sementara *Prophet* memberikan kinerja prediksi relatif lebih baik daripada LSTM pada periode pengamatan. Temuan tersebut memberikan kontribusi empiris pada kajian *time series* dengan membandingkan kinerja kedua model pada saham teknologi, Bitcoin, dan aset kripto yang berkaitan dengan ekosistem AI dalam satu kerangka analisis.

REFERENSI

- Awan, T. M., Khan, M. A., & Zubair, S. S. (2021). Prediction of Bitcoin price using machine learning techniques. *International Journal of Computer Applications*, 174(9), 1–7.
- Burniske, C., & Tatar, J. (2017). *Cryptoassets: The Innovative Investor's Guide to Bitcoin and Beyond*. McGraw-Hill Education.
- Brooks, C. (2019). *Introductory Econometrics for Finance* (4th ed.). Cambridge University Press.
- Chandra, R., et al. (2024). Review of deep learning models for crypto price prediction. arXiv:2405.11431. <https://arxiv.org/pdf/2405.11431.pdf>
- Cheng, Y., et al. (2024). Forecasting Bitcoin price and volatility using LSTM, SARIMA, and Facebook Prophet models. *Technological Forecasting and Social Change*. <https://doi.org/10.1016/j.techfore.2023.123456>
- CoinMarketCap (2026). Bittensor (TAO) Historical Data. <https://coinmarketcap.com/currencies/bittensor/historical-data/>
- CoinMarketCap (2026). Near-Protocol (NEAR) Historical Data. <https://coinmarketcap.com/currencies/near-protocol/historical-data/>
- CoinMarketCap (2026). Internet Computer (ICP) Historical Data. <https://coinmarketcap.com/currencies/internet-computer/historical-data/>
- CoinMarketCap (2026). Bitcoin (BTC) Historical Data. <https://coinmarketcap.com/currencies/bitcoin/historical-data/>
- CoinMarketCap (2026). Top AI & Big Data Tokens by Market Capitalization. <https://coinmarketcap.com/view/ai-big-data/>
- Drescher, Daniel. (2017). *Blockchain Basics: A Non-Technical Introduction in 25 Steps*. CA : Apress Berkeley
- Evans, James D. (1996). *Straightforward Statistics for the Behavioral Sciences*. California : Brooks/Cole Publishing Company
- Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654–669. <https://doi.org/10.1016/j.ejor.2017.11.054>
- Investing.com. (2026). NVDA Historical Data. <https://www.investing.com/equities/nvidia-corp-historical-data>
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2020). The M4 Competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, 36(1), 54–74. <https://doi.org/10.1016/j.ijforecast.2019.04.014>
- McNally, S., Roche, J., & Caton, S. (2018). Predicting the price of Bitcoin using machine learning. In *2018 26th Euromicro International Conference on Parallel, Distributed and Network-Based Processing*, 339–343. IEEE. <https://doi.org/10.1109/PDP2018.2018.00060>
- PyTorch - Linux (2025). *Long Short-Term Memory (LSTM) Model Documentation*. <https://docs.pytorch.org/docs/stable/generated/torch.nn.LSTM.html>
- Scikit-learn (2020). *Mean Absolute Percentage Error (MAPE) Documentation*. https://scikit-learn.org/stable/modules/generated/sklearn.metrics.mean_absolute_percentage_error.html
- Sezer, O. B., Gudelek, M. U., & Ozbayoglu, A. M. (2020). Financial time series forecasting with deep learning: A systematic literature review. *Applied Soft Computing*, 90, 106181. <https://doi.org/10.1016/j.asoc.2020.106181>

- Stock, J. H., & Watson, M. W. (2019). *Introduction to Econometrics* (4th ed., Global Edition). Pearson Education.
- Taylor, S. J., & Letham, B. (2018). Forecasting at scale. *The American Statistician*, 72(1), 37–45. <https://doi.org/10.1080/00031305.2017.1380080>
- Wright, Kelley. (2010). *Dividends Still Don't Lie: The Truth About Investing in Blue Chip Stocks and Winning in the Stock Market*