

Analisis Pola *Candlestick* Cryptocurrency menggunakan Gramian Angular Field dan Deep Learning Hibrid

Analysis of Cryptocurrency Candlestick Patterns using Gramian Angular Field and Hybrid Deep Learning

¹Hasriadi*, ²Mashur Razak, ³Abdul Jalil

^{1,2,3}Pascasarjana Magister Sistem Komputer, Universitas Handayani Makassar
^{1,2,3}Jl. Adhiyaksa Baru No. 1, Pandang, Kec. Panakukang, Kota Makassar, Sulawesi Selatan,
Indonesia

*e-mail: hasriadihakka@gmail.com

(received: 9 January 2026, revised: 22 January 2026, accepted: 25 January 2026)

Abstrak

Pasar *cryptocurrency* seperti *Bitcoin*, *Ethereum*, dan *Solana* memiliki tingkat volatilitas yang tinggi sehingga menyulitkan proses prediksi harga apabila hanya mengandalkan analisis teknikal konvensional. Penelitian ini bertujuan untuk menganalisis pola *candlestick cryptocurrency* dengan memanfaatkan representasi *Gramian Angular Field* (GAF) serta mengevaluasi kinerja model *deep learning* hibrid *CNN-LSTM-Transformer* dalam mendukung pengambilan keputusan investasi. Metode yang digunakan meliputi pengolahan data historis harian *Open*, *High*, *Low*, dan *Close* (OHLC) dari tiga aset *cryptocurrency* utama, yaitu *Bitcoin* (BTC-USD), *Ethereum* (ETH-USD), dan *Solana* (SOL-USD) periode 1 Januari 2020 hingga 30 September 2024 yang diperoleh dari *Yahoo Finance*. Data deret waktu tersebut dikonversi menjadi citra GAF berukuran 64×64 piksel dan digunakan untuk melatih model *CNN* baseline serta model hibrid *CNN-LSTM-Transformer*. Evaluasi dilakukan pada berbagai horizon prediksi, yaitu satu hari, tujuh hari, tiga puluh hari, seratus delapan puluh hari, dan satu tahun, serta dilengkapi dengan pengujian *real-time* menggunakan *API CoinGecko* pada Maret 2025. Hasil penelitian menunjukkan bahwa model hibrid memberikan kinerja terbaik pada horizon yang berbeda untuk setiap aset, yaitu BTC-USD pada horizon tiga puluh hari dengan nilai R^2 sebesar 0,971 dan SMAPE 0,77%, ETH-USD pada horizon satu tahun dengan R^2 sebesar 0,948 dan SMAPE 0,81%, serta SOL-USD pada horizon satu tahun dengan R^2 sebesar 0,910 dan SMAPE 4,72%. Pengujian *real-time* menunjukkan bahwa model mampu menangkap tren umum pergerakan harga secara konsisten meskipun terjadi volatilitas yang tinggi. Dapat disimpulkan bahwa pemanfaatan representasi GAF dan model hibrid *CNN-LSTM-Transformer* berpotensi meningkatkan kualitas analisis *candlestick cryptocurrency* dan dapat dimanfaatkan sebagai komponen Sistem Pendukung Keputusan dalam investasi aset digital.

Kata kunci: *cryptocurrency*, *deep learning*, gramian angular field, pola *candlestick*, prediksi harga

Abstract

Cryptocurrency markets such as *Bitcoin*, *Ethereum*, and *Solana* exhibit high volatility, making price forecasting difficult when relying solely on conventional technical analysis. This study aims to analyze *cryptocurrency candlestick* patterns by utilizing *Gramian Angular Field* (GAF) representations and to evaluate the performance of a hybrid *deep learning* model combining *CNN-LSTM-Transformer* to support investment decision-making. The proposed method involves processing daily historical *Open*, *High*, *Low*, and *Close* (OHLC) data from three major *cryptocurrency* assets: *Bitcoin* (BTC-USD), *Ethereum* (ETH-USD), and *Solana* (SOL-USD), covering the period from January 1, 2020, to September 30, 2024, obtained from *Yahoo Finance*. The time-series data were transformed into 64×64 pixel GAF images and used to train a baseline *CNN* model as well as a hybrid *CNN-LSTM-Transformer* model. Model evaluation was conducted across multiple forecasting horizons, including 1 day, 7 days, 30 days, 180 days, and 1 year, and was further complemented by *real-time* testing using the *CoinGecko API* in March 2025. The results indicate that the hybrid model achieved the best performance at different horizons for each asset: BTC-USD at the 30-day horizon with an R^2 of 0.971 and an SMAPE of 0.77%, ETH-USD at the 1-year horizon with an R^2 of 0.948 and

<http://sistemasi.ftik.unisi.ac.id>

an SMAPE of 0.81%, and SOL-USD at the 1-year horizon with an R^2 of 0.910 and an SMAPE of 4.72%. Real-time testing demonstrated that the model consistently captured the overall price movement trends despite high market volatility. It can be concluded that the integration of GAF representations and the hybrid CNN–LSTM–Transformer model has strong potential to enhance cryptocurrency candlestick analysis and can be utilized as a component of a Decision Support System for digital asset investment.

Keywords: candlestick patterns, cryptocurrency, deep learning, gramian angular field, price prediction

1 Pendahuluan

Pasar *cryptocurrency* merupakan bagian dari ekosistem sistem keuangan digital yang berkembang pesat sejak diperkenalkannya Bitcoin pada tahun 2009 berbasis teknologi blockchain terdesentralisasi [1]. Perkembangan ini ditandai dengan meningkatnya jumlah aset digital serta partisipasi investor, trader, dan analis di berbagai negara [2]. Di Indonesia, *cryptocurrency* telah diakui secara resmi sebagai komoditas sejak tahun 2018 oleh Badan Pengawas Perdagangan Berjangka Komoditi (Bappebti), yang mendorong peningkatan aktivitas investasi aset digital secara signifikan [3]. Namun demikian, tingginya volatilitas dan dinamika pasar *cryptocurrency* menyebabkan proses analisis dan pengambilan keputusan investasi menjadi kompleks dan berisiko tinggi, sehingga memerlukan dukungan Sistem Informasi yang mampu menyajikan informasi prediktif secara akurat, adaptif, dan berbasis data [4].

Dalam praktiknya, analisis teknikal masih menjadi pendekatan yang umum digunakan untuk memprediksi pergerakan harga aset keuangan, salah satunya melalui identifikasi pola *candlestick* [5], [6]. Pendekatan ini relatif efektif pada pasar keuangan konvensional, tetapi menghadapi berbagai keterbatasan ketika diterapkan pada pasar *cryptocurrency*. Pasar *cryptocurrency* beroperasi tanpa henti selama 24 jam, memiliki fluktuasi harga yang ekstrem, serta sangat dipengaruhi oleh sentimen global yang berubah dengan cepat. Kondisi tersebut menyebabkan metode analisis teknikal konvensional sering kali kurang adaptif dan belum mampu merepresentasikan kompleksitas pola pergerakan harga secara optimal sebagai dasar pengambilan keputusan investasi.

Perkembangan teknik pembelajaran mendalam (*deep learning*) membuka peluang baru dalam pengembangan Sistem Informasi prediktif di bidang keuangan digital. *Convolutional Neural Network* (CNN) telah banyak dimanfaatkan untuk mengenali pola *candlestick* karena kemampuannya dalam mengekstraksi fitur spasial dari data visual [7], [8]. Namun, CNN memiliki keterbatasan dalam memodelkan ketergantungan temporal jangka panjang pada data deret waktu. Sebaliknya, *Long Short-Term Memory* (LSTM) lebih efektif dalam menangkap dinamika temporal, sementara mekanisme *attention* pada Transformer mampu memodelkan hubungan jangka panjang secara lebih fleksibel [9]. Selain itu, pendekatan *Gramian Angular Field* (GAF) dikembangkan untuk mentransformasikan data deret waktu menjadi representasi citra dua dimensi yang kaya informasi *temporal* dan *geometris*, sehingga lebih sesuai untuk diproses oleh CNN dan berpotensi meningkatkan akurasi prediksi [10]. Meskipun demikian, integrasi representasi GAF dengan arsitektur *deep learning* hibrid serta pemanfaatannya sebagai komponen dalam Sistem Pendukung Keputusan investasi *cryptocurrency* masih relatif terbatas dalam literatur.

Berdasarkan permasalahan tersebut, penelitian ini mengusulkan pendekatan analisis *candlestick* *cryptocurrency* menggunakan representasi *Gramian Angular Field* (GAF) dan model *deep learning* hibrid CNN–LSTM–Transformer. Penelitian difokuskan pada tiga aset *cryptocurrency* utama, yaitu Bitcoin (BTC-USD), *Ethereum* (ETH-USD), dan *Solana* (SOL-USD), dengan memanfaatkan data historis harian *Open*, *High*, *Low*, dan *Close* (OHLC) periode Januari 2020 hingga September 2024 yang diperoleh dari Yahoo Finance. Evaluasi model dilakukan pada berbagai horizon prediksi, meliputi satu hari, tujuh hari, tiga puluh hari, seratus delapan puluh hari, dan satu tahun, serta dilengkapi dengan pengujian real-time menggunakan API CoinGecko pada Maret 2025 untuk menilai ketahanan model pada kondisi pasar aktual.

Penelitian ini dirancang untuk menjawab dua pertanyaan penelitian utama, yaitu: (1) sejauh mana representasi citra *candlestick* berbasis *Gramian Angular Field* (GAF) mampu meningkatkan kualitas ekstraksi pola pergerakan harga *cryptocurrency* sebagai dasar analisis prediktif dalam Sistem

Pendukung Keputusan investasi; dan (2) bagaimana kinerja model hibrid CNN–LSTM–Transformer dalam memprediksi harga *cryptocurrency* pada berbagai horizon waktu jika dibandingkan dengan pendekatan konvensional berbasis data numerik.

Tujuan penelitian ini adalah menganalisis efektivitas *Gramian Angular Field* dalam merepresentasikan pola candlestick *cryptocurrency* serta mengevaluasi kinerja model hibrid CNN–LSTM–Transformer dalam mendukung proses analisis dan prediksi harga. Hasil penelitian ini diharapkan dapat memberikan kontribusi akademik dalam pengembangan Sistem Informasi prediktif berbasis deep learning, memperkaya kajian pada bidang Sistem Informasi dan Sistem Pendukung Keputusan, serta menyediakan informasi prediktif multi-horizon yang lebih terstruktur sebagai pendukung pengambilan keputusan bagi trader, analis, dan investor di pasar *cryptocurrency*.

2 Tinjauan Literatur

Penelitian terkait prediksi harga *cryptocurrency* dengan pendekatan pembelajaran mendalam terus berkembang seiring meningkatnya volatilitas pasar aset digital. Berbagai studi menunjukkan bahwa model berbasis deret waktu, seperti *Long Short-Term Memory* (LSTM), memiliki kemampuan yang baik dalam menangkap ketergantungan temporal jangka pendek pada data harga *cryptocurrency*, namun cenderung mengalami penurunan performa ketika dihadapkan pada noise tinggi dan perubahan tren yang abrupt. Di sisi lain, *Convolutional Neural Network* (CNN) telah banyak dimanfaatkan untuk mengekstraksi fitur spasial dari representasi visual data harga, termasuk pola candlestick, tetapi memiliki keterbatasan dalam memodelkan dinamika temporal jangka panjang secara eksplisit. Temuan ini mendorong munculnya pendekatan hibrid CNN–LSTM, yang berupaya mengombinasikan keunggulan ekstraksi fitur visual dan pemodelan urutan waktu. Meskipun demikian, sebagian besar penelitian hibrid masih mengandalkan representasi deret waktu konvensional atau citra candlestick sederhana, sehingga potensi informasi geometris dan temporal yang lebih kaya belum dimanfaatkan secara optimal.

Dalam konteks representasi data, *Gramian Angular Field* (GAF) telah diperkenalkan sebagai teknik transformasi deret waktu ke dalam bentuk citra dua dimensi yang mempertahankan hubungan temporal melalui pemetaan sudut dan korelasi antar titik waktu. Pendekatan ini terbukti efektif dalam tugas klasifikasi pola candlestick, dengan tingkat akurasi yang relatif tinggi pada berbagai pola teknikal penting. Namun, fokus penelitian yang ada masih terbatas pada klasifikasi pola atau prediksi tren jangka sangat pendek, tanpa pengujian komprehensif pada skenario prediksi harga multi-horizon yang lebih relevan bagi pengambilan keputusan investasi. Selain itu, sebagian besar studi yang memanfaatkan GAF masih menggunakan CNN sebagai satu-satunya arsitektur utama, sehingga kemampuan model dalam menangkap dependensi temporal jangka panjang tetap terbatas.

Seiring berkembangnya arsitektur pembelajaran mendalam, mekanisme attention pada Transformer mulai diadopsi dalam analisis deret waktu keuangan karena kemampuannya dalam memodelkan hubungan jangka panjang secara lebih *fleksibel* dibandingkan LSTM. Beberapa penelitian telah mengintegrasikan attention mechanism ke dalam model hibrid untuk meningkatkan akurasi prediksi pasar keuangan. Namun, penerapannya pada data *cryptocurrency* berbasis citra candlestick masih bersifat parsial, baik karena penggunaan representasi input yang belum optimal maupun karena Transformer hanya digunakan sebagai komponen tambahan tanpa integrasi penuh dalam arsitektur end-to-end. Selain itu, penelitian yang mengombinasikan CNN, LSTM, dan Transformer secara simultan masih relatif terbatas, terutama yang mengevaluasi kontribusi masing-masing komponen terhadap performa prediksi pada berbagai horizon waktu.

Keterbatasan lain yang muncul dalam literatur adalah ruang lingkup evaluasi yang sempit, baik dari sisi aset maupun horizon prediksi. Sebagian besar penelitian hanya menguji satu atau dua aset *cryptocurrency* utama, seperti Bitcoin dan Ethereum, serta membatasi horizon prediksi pada jangka pendek hingga menengah. Pendekatan ini kurang merepresentasikan kebutuhan praktis pengguna akhir, seperti trader dan investor, yang memerlukan informasi prediktif pada berbagai horizon waktu untuk mendukung strategi pengambilan keputusan yang berbeda. Selain itu, pengujian berbasis data historis saja belum sepenuhnya mencerminkan kondisi pasar aktual yang terus berubah, sehingga validasi real-time masih jarang dilakukan secara eksplisit.


Berdasarkan analisis terhadap penelitian-penelitian tersebut, dapat disimpulkan bahwa masih terdapat celah penelitian yang signifikan. Hingga saat ini, belum banyak studi yang mengintegrasikan

secara penuh representasi Gramian Angular Field multi-channel dengan arsitektur pembelajaran mendalam hibrid CNN–LSTM–Transformer untuk prediksi harga *cryptocurrency* berbasis pola *candlestick*. Selain itu, evaluasi kinerja model pada berbagai horizon prediksi secara simultan, mulai dari jangka sangat pendek hingga jangka panjang, serta pengujian real-time untuk menilai ketahanan model dalam kondisi pasar aktual, masih belum banyak dilakukan. Oleh karena itu, penelitian ini difokuskan pada pengembangan dan evaluasi model hibrid CNN–LSTM–Transformer berbasis citra *Gramian Angular Field multi-channel* untuk prediksi harga *cryptocurrency* pada berbagai horizon waktu, dengan tujuan mengisi celah penelitian tersebut dan memberikan kontribusi yang relevan bagi pengembangan Sistem Informasi dan Sistem Pendukung Keputusan di bidang investasi aset digital.

3 Metode Penelitian

3.1 Alur Penelitian

Penelitian ini merupakan penelitian eksperimental berbasis pendekatan kuantitatif yang bertujuan mengembangkan dan mengevaluasi efektivitas model hybrid CNN–LSTM–Transformer dalam menganalisis pola *candlestick* dan memprediksi pergerakan harga *cryptocurrency* menggunakan representasi citra *Gramian Angular Field* (GAF). Alur penelitian dirancang secara sistematis untuk memastikan setiap tahapan pemrosesan data dan pemodelan dilakukan secara terstruktur, mulai dari pengumpulan data hingga evaluasi hasil prediksi. Alur penelitian disajikan pada Gambar 1 dibawah ini:



Gambar 1 Alur penelitian

Tahap awal penelitian diawali dengan pengumpulan data historis harian Open, High, Low, dan Close (OHLC) dari tiga aset cryptocurrency utama, yaitu Bitcoin (BTC-USD), *Ethereum* (ETH-USD), dan Solana (SOL-USD), yang diperoleh melalui pustaka *yfinance* pada rentang waktu 1 Januari 2020 hingga 30 September 2024. Data historis ini kemudian diproses melalui tahap normalisasi menggunakan metode *Min-Max Scaling* untuk menyamakan skala nilai dan mengurangi bias akibat perbedaan rentang harga antar aset.

Selanjutnya, data time-series OHLC dikonversi menjadi citra *Gramian Angular Field* (GAF) multi-channel berukuran 64×64 piksel dengan window size 64 hari. Transformasi ini bertujuan mengubah pola numerik pergerakan harga menjadi representasi visual dua dimensi yang mampu menangkap hubungan temporal dan spasial antar komponen *candlestick* secara lebih komprehensif. Representasi GAF ini menjadi input utama bagi model deep learning yang dikembangkan.

Dataset kemudian dibagi menggunakan skema time-series split untuk menghindari data leakage, dengan proporsi 80% data latih (periode 2020–2023) dan 20% data uji (periode 2024). Data latih digunakan untuk proses pembelajaran model, sedangkan data uji dimanfaatkan untuk mengevaluasi kemampuan generalisasi model pada data yang belum pernah dilihat sebelumnya.

Model hybrid CNN–LSTM–Transformer dilatih menggunakan data citra GAF sebagai masukan. Pada tahap ini, CNN berfungsi mengekstraksi fitur spasial dari pola candlestick, Bidirectional LSTM memodelkan ketergantungan temporal dua arah, dan Transformer memperkuat representasi fitur melalui mekanisme attention untuk menangkap hubungan jangka panjang yang kompleks. Proses pelatihan dilengkapi dengan hyperparameter tuning untuk memperoleh konfigurasi model terbaik.

Evaluasi kinerja model dilakukan menggunakan berbagai metrik kuantitatif untuk mengukur akurasi prediksi dan kemampuan model dalam menangkap pola pergerakan harga pada beberapa horizon waktu, yaitu satu hari, tujuh hari, tiga puluh hari, seratus delapan puluh hari, dan satu tahun. Selain itu, pengujian dilakukan pada data real-time menggunakan API CoinGecko untuk mengamati performa model pada kondisi pasar aktual.

Alur penelitian ini dirancang sebagai kerangka analitis dalam Sistem Pendukung Keputusan (*Decision Support System*) perdagangan *cryptocurrency*. Hasil prediksi harga pada berbagai horizon waktu tidak hanya diperlakukan sebagai keluaran numerik, tetapi sebagai informasi pendukung keputusan yang dapat dimanfaatkan oleh trader, analis, dan investor dalam mengevaluasi risiko, mengidentifikasi tren pasar, serta merencanakan strategi transaksi yang lebih rasional dan berbasis data.

3.2 Pengumpulan Data

Data yang digunakan dalam penelitian ini berupa data historis harian *Open, High, Low, dan Close* (OHLC) dari tiga aset *cryptocurrency* utama, yaitu *Bitcoin* (BTC-USD), *Ethereum* (ETH-USD), dan *Solana* (SOL-USD). Data diperoleh melalui pustaka *yfinance* pada bahasa pemrograman Python dengan fungsi `download()`, dengan rentang waktu pengamatan dari 1 Januari 2020 hingga 30 September 2024 disajikan pada Tabel 1 di bawah ini:

Table 1 Jumlah data cryptocurrency

No.	Cryptocurrency	Jumlah baris data
1.	BTC-USD	1735
2.	ETH-USD	1735
3.	SOL-USD	1735

Pemilihan ketiga aset *cryptocurrency* tersebut didasarkan pada pertimbangan karakteristik pasar yang berbeda sehingga relevan untuk analisis komparatif dalam konteks Sistem Informasi dan Sistem Pendukung Keputusan. *Bitcoin* (BTC) merepresentasikan aset *cryptocurrency* dengan kapitalisasi pasar terbesar dan tingkat adopsi tertinggi, sehingga mencerminkan kondisi pasar yang relatif lebih stabil. *Ethereum* (ETH) dipilih karena perannya sebagai platform smart contract utama yang sangat dipengaruhi oleh aktivitas ekosistem aplikasi terdesentralisasi (DeFi). Sementara itu, *Solana* (SOL) dipilih sebagai representasi aset dengan volatilitas tinggi berbasis teknologi generasi baru. Pemilihan ini bertujuan untuk menguji kemampuan model dalam menangani variasi pola pergerakan harga pada kondisi pasar yang beragam. Periode waktu pengamatan dipilih untuk mencakup berbagai fase penting pasar *cryptocurrency*, termasuk fase pertumbuhan pesat, periode koreksi ekstrem, serta fase pemulihan pasca volatilitas tinggi. Dengan demikian, data yang digunakan diharapkan mampu merepresentasikan dinamika pasar yang kompleks dan relevan untuk pengembangan model prediktif berbasis data historis. Data yang mengandung nilai kosong (*missing values*) ditangani menggunakan metode *forward fill* dan *backward fill*. Baris data yang masih mengandung nilai kosong setelah proses tersebut dihapus untuk memastikan kualitas data. Hasil akhir menghasilkan sebanyak 1.735 baris data lengkap untuk masing-masing aset *cryptocurrency*.


3.3 Pra-pemrosesan

Tahap pra-pemrosesan diawali dengan proses normalisasi data OHLC menggunakan metode *Min-Max Scaling* ke dalam rentang nilai [0,1]. Normalisasi ini bertujuan untuk menyamakan skala data dan meningkatkan stabilitas proses pelatihan model *deep learning*.

Tabel 2 Hasil konversi data ke GAF

No.	Cryptocurrency	Jumlah baris data OHLC+V	Jumlah Konversi GAF yang dihasilkan	Jumlah baris yang tidak digunakan
1.	BTC-USD	1735	1672	63

2.	ETH-USD	1735	1672	63
3.	SOL-USD	1735	1672	63




Gambar 2 GAF multi channel

Tabel 2 menunjukkan Hasil Konversi Data ke GAF dan Gambar 2 menunjukkan representasi visual data BTC-USD sebagai sampel yang menggabungkan OHLC menggunakan teknik GAF Multi-Channel. Selanjutnya, data deret waktu OHLC dikonversi menjadi citra *Gramian Angular Field* (GAF) multi-channel berukuran 64×64 piksel dengan window size 64 hari, mengikuti pendekatan yang diusulkan oleh Jun-Hao dan Yun-Cheng (2021). Setiap kanal GAF merepresentasikan satu komponen OHLC sehingga pola candlestick dapat divisualisasikan secara komprehensif dalam bentuk citra dua dimensi. Representasi GAF *multi-channel* memungkinkan transformasi data numerik OHLC menjadi pola visual yang kaya informasi, sehingga lebih mudah diekstraksi oleh model deep learning berbasis citra. Selain meningkatkan kemampuan model dalam mengenali pola kompleks, pendekatan ini juga mendukung Sistem Pendukung Keputusan berbasis visual dengan menyajikan pola tren pasar dalam bentuk yang lebih intuitif dan terstruktur. Karena penggunaan window size 64 hari, dari total 1.735 baris data historis dihasilkan sebanyak 1.672 citra GAF untuk masing-masing aset cryptocurrency, sementara 63 baris data awal tidak digunakan dalam proses konversi.

3.4 Pelatihan dan Arsitektur Model

Model yang dikembangkan dalam penelitian ini merupakan arsitektur hybrid yang mengintegrasikan *Convolutional Neural Network* (CNN), *Bidirectional Long Short-Term Memory* (BiLSTM), dan Transformer. Arsitektur ini dirancang untuk menggabungkan kemampuan ekstraksi fitur visual, pemodelan ketergantungan temporal, serta mekanisme *attention* dalam satu kerangka pemodelan yang terpadu.



Gambar 3 Arsitektur model *hybrid* CNN-LSTM-transformer

Gambar 3 menunjukkan arsitektur *model hybrid* CNN-LSTM-Transformer yang dirancang khusus untuk menangani kompleksitas pola candlestick pada data cryptocurrency yang sangat volatil.

Proses pelatihan model hybrid ini melibatkan pengolahan data OHLC *candlestick* sebagai input, di mana CNN digunakan untuk mengekstrak fitur lokal, dilanjutkan dengan LSTM untuk memodelkan dinamika temporal, dan Transformer untuk menyempurnakan hubungan global antar fitur. Citra GAF multi-channel digunakan sebagai input ke dalam blok CNN untuk mengekstraksi fitur spasial dari pola *candlestick*. Fitur hasil ekstraksi CNN kemudian diteruskan ke lapisan *Bidirectional* LSTM untuk memodelkan dinamika temporal dua arah, sehingga ketergantungan jangka pendek dan jangka panjang dapat ditangkap secara lebih efektif. Selanjutnya, fitur temporal diproses oleh blok Transformer yang memanfaatkan mekanisme multi-head attention untuk memperkuat hubungan global antar fitur penting.

Berikut ini merupakan tabel pelatihan model terbaik dari setiap cryptocurrency yang kami sajikan pada penelitian ini, terlihat pada Tabel 3 di bawah ini:

Tabel 3 Hasil Pelatihan model terbaik dari *cryptocurrency* setiap horizon waktu

No.	Cryptocurrency	Horizon	MSE	RMSE	MAE	SMAPE	R ²	Accuracy
1.	BTC-USD	next_day	0.012	0.113	0.088	0.88	0.967	0.964
		7_days	0.011	0.109	0.077	0.76	0.970	0.945
		30_days	0.011	0.107	0.078	0.77	0.971	0.955
		180_days	0.018	0.136	0.093	0.91	0.927	0.915
		1_year	0.011	0.108	0.077	0.74	0.932	0.943
2.	ETH-USD	next_day	0.032	0.179	0.133	1.91	0.960	0.897
		7_days	0.039	0.199	0.152	2.16	0.951	0.888
		30_days	0.043	0.209	0.148	2.08	0.943	0.888
		180_days	0.024	0.156	0.114	1.53	0.930	0.869
		1_year	0.006	0.080	0.062	0.81	0.948	0.939
3.	SOL-USD	next_day	0.050	0.224	0.1737	8.05	0.975	0.947
		7_days	0.074	0.272	0.2107	8.00	0.962	0.950
		30_days	0.092	0.304	0.2391	10.11	0.951	0.912
		180_days	0.051	0.227	0.1618	5.52	0.960	0.941
		1_year	0.062	0.250	0.1865	4.72	0.910	0.908

Tabel 3 Menunjukkan hasil pelatihan dan pengujian model hybrid CNN-LSTM-Transformer menunjukkan performa yang sangat baik pada ketiga aset cryptocurrency dengan berbagai tingkat volatilitas. Tabel 3 menyajikan metrik evaluasi terbaik untuk lima horizon prediksi pada BTC-USD, ETH-USD, dan SOL-USD.

Hasil pemodelan kemudian diteruskan ke lapisan fully connected (Dense) untuk menghasilkan satu nilai keluaran berupa prediksi harga pada horizon waktu tertentu. Proses pelatihan model dilakukan menggunakan data latih dengan skema time-series split dan dioptimasi melalui hyperparameter tuning untuk memperoleh konfigurasi terbaik. Evaluasi kinerja model dilakukan menggunakan beberapa metrik kuantitatif, yaitu *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), *Symmetric Mean Absolute Percentage Error* (SMAPE), koefisien determinasi (R²), serta akurasi arah tren. Seluruh hasil evaluasi dan analisis performa model disajikan secara rinci pada bagian Hasil dan Pembahasan.

Penelitian ini memiliki beberapa keterbatasan metodologis yang perlu diperhatikan. Pertama, data yang digunakan berupa data historis harian sehingga belum mencakup dinamika pergerakan harga intraday yang dapat memengaruhi keputusan perdagangan jangka pendek. Kedua, jumlah aset cryptocurrency yang dianalisis masih terbatas pada tiga aset utama, sehingga generalisasi hasil penelitian ke seluruh pasar cryptocurrency perlu dilakukan secara hati-hati. Ketiga, model prediksi sangat bergantung pada pola historis, sehingga perubahan ekstrem akibat faktor eksternal seperti regulasi, kebijakan pemerintah, atau sentimen global dapat memengaruhi akurasi prediksi.

4 Hasil dan Pembahasan

4.1 Hasil Evaluasi Model Terbaik

Berdasarkan hasil evaluasi terhadap seluruh skenario pengujian, model terbaik untuk masing-masing cryptocurrency dipilih berdasarkan kombinasi metrik kesalahan terendah (*Mean Squared Error*, *Root Mean Squared Error*, *Mean Absolute Error*, dan *Symmetric Mean Absolute Percentage Error*), koefisien determinasi (R^2), serta tingkat akurasi arah pergerakan harga (*directional accuracy*). Ringkasan hasil pemilihan model terbaik disajikan pada Tabel 4.

Tabel 4 Hasil Pelatihan model terbaik dari cryptocurrency

No.	Cryptocurrency	Horizon	MSE	RMSE	MAE	SMAPE	R^2	Accuracy
1.	BTC-USD	30_days	0.011	0.107	0.078	0.77	0.971	0.955
2.	ETH-USD	1_year	0.006	0.080	0.062	0.81	0.948	0.939
3.	SOL-USD	1_year	0.062	0.250	0.1865	4.72	0.910	0.908


Hasil pada Tabel 4 menunjukkan bahwa horizon prediksi optimal berbeda untuk setiap aset cryptocurrency. Pada BTC-USD, horizon 30 hari menghasilkan kinerja terbaik dengan nilai R^2 sebesar 0,971 dan SMAPE sebesar 0,77%. Sementara itu, pada ETH-USD dan SOL-USD, horizon prediksi 1 tahun justru memberikan performa paling optimal, masing-masing dengan nilai R^2 sebesar 0,948 dan 0,910.

4.2 Hasil Evaluasi Model Terbaik

Perbedaan horizon prediksi optimal antar aset menunjukkan bahwa karakteristik pasar dan tingkat kematangan cryptocurrency berpengaruh signifikan terhadap efektivitas prediksi. BTC-USD, sebagai aset dengan likuiditas tinggi dan struktur pasar yang relatif stabil, lebih mudah diprediksi pada horizon jangka menengah. Hal ini mengindikasikan bahwa pola candlestick harian BTC-USD memiliki konsistensi yang cukup kuat sehingga dapat ditangkap secara efektif oleh representasi GAF multi-channel dan arsitektur model hibrid.


Sebaliknya, ETH-USD dan SOL-USD menunjukkan performa terbaik pada horizon jangka panjang. Kondisi ini mengindikasikan bahwa kedua aset tersebut lebih dipengaruhi oleh tren makro, siklus pasar, dan faktor fundamental jangka panjang. Mekanisme multi-head attention pada Transformer berperan penting dalam menangkap ketergantungan temporal jangka panjang tersebut, sehingga model mampu menyaring fluktuasi jangka pendek dan memfokuskan prediksi pada arah tren utama.

4.3 Analisis Kurva Pelatihan dan Visualisasi Prediksi




Gambar 4 Training vs validasi loss dan Harga aktual vs prediksi BTC_USD 30_days

Gambar 4 menyajikan kurva training loss dan validation loss serta perbandingan antara harga aktual dan harga hasil prediksi untuk BTC-USD pada horizon 30 hari. Kurva pelatihan menunjukkan tren penurunan yang stabil tanpa indikasi overfitting yang signifikan, yang mencerminkan efektivitas penerapan *Early Stopping* dan *ReduceLROnPlateau*. Visualisasi harga aktual dan prediksi memperlihatkan bahwa model mampu mengikuti pola pergerakan harga secara konsisten pada berbagai kondisi pasar, sejalan dengan nilai SMAPE yang sangat rendah.



Gambar 5 Training vs validasi loss dan harga aktual vs prediksi ETH_USD 1_year


Pada ETH-USD horizon 1 tahun (Gambar 5), model menunjukkan kemampuan yang baik dalam menangkap tren jangka panjang meskipun terdapat deviasi pada periode volatilitas tinggi. Nilai SMAPE sebesar 0,81% menunjukkan bahwa kesalahan prediksi tetap berada pada tingkat rendah untuk horizon panjang, yang mengonfirmasi peran Bidirectional LSTM dan Transformer dalam memodelkan ketergantungan temporal jangka panjang secara efektif.



Gambar 6 Training vs validasi loss dan harga aktual vs prediksi SOL_USD 1_year

Untuk SOL-USD horizon 1 tahun (Gambar 6), kurva *validation loss* menunjukkan fluktuasi yang lebih besar dibandingkan dua aset lainnya. Hal ini mencerminkan tingkat volatilitas SOL-USD yang lebih tinggi. Meskipun demikian, model tetap mampu mempertahankan arah tren utama dengan nilai R^2 sebesar 0,910 dan *directional accuracy* sebesar 90,8%, yang menunjukkan ketahanan model terhadap fluktuasi ekstrem.

4.4 Analisis Representasi GAF dan Dampaknya terhadap Prediksi



Gambar 7 Sampel GAF SOL-USD Periode 1 Januari – 4 Maret 2020

Analisis visual terhadap citra GAF SOL-USD pada periode awal pengamatan Gambar 7 menunjukkan bahwa nilai piksel yang relatif homogen akibat harga awal yang sangat rendah menyebabkan berkurangnya variasi informasi visual. Kondisi ini membatasi kemampuan CNN dalam mengekstraksi fitur spasial yang kaya, sehingga berkontribusi terhadap nilai kesalahan prediksi yang relatif lebih tinggi pada SOL-USD dibandingkan BTC-USD dan ETH-USD, khususnya pada horizon jangka menengah. Temuan ini menunjukkan bahwa kualitas representasi GAF sangat dipengaruhi oleh karakteristik distribusi harga aset. Meskipun demikian, pada horizon jangka panjang, integrasi LSTM dan Transformer mampu mengompensasi keterbatasan tersebut dengan memanfaatkan informasi temporal yang lebih luas.

4.5 Implikasi terhadap Sistem Informasi dan Sistem Pendukung Keputusan

Hasil penelitian ini menunjukkan bahwa integrasi Gramian Angular Field dengan arsitektur hybrid CNN–LSTM–Transformer mampu memberikan kinerja prediksi yang unggul dibandingkan pendekatan konvensional berbasis deret waktu atau model CNN tunggal. Pengujian model secara real-time sebagaimana ditunjukkan pada Gambar 8 memperlihatkan bahwa sistem mampu mengintegrasikan data harga *cryptocurrency* yang diperoleh langsung dari API CoinGecko dengan mekanisme pencadangan data lokal dalam format CSV. Arsitektur ini mencerminkan prinsip keandalan (*reliability*) dalam Sistem Informasi, di mana ketersediaan data tetap terjaga meskipun terjadi gangguan koneksi jaringan atau kendala teknis pada proses pengambilan data real-time.



Gambar 8 Pengujian *real-time*

Hasil prediksi harga pada berbagai horizon waktu, khususnya horizon 30 hari dan 1 tahun, menunjukkan nilai tambah yang signifikan bagi Sistem Pendukung Keputusan (SPK) dalam konteks perdagangan *cryptocurrency*. Informasi prediktif multi-horizon ini memungkinkan pengguna, seperti trader dan analis, untuk mengevaluasi risiko, mengidentifikasi arah tren pasar jangka menengah hingga jangka panjang, serta menyusun strategi perdagangan yang lebih terukur dan berbasis data. Penyajian hasil prediksi secara visual melalui antarmuka Streamlit, sebagaimana ditunjukkan pada pengujian real-time, meningkatkan aspek usability dan mempermudah interpretasi perbandingan antara harga aktual dan hasil prediksi. Selain itu, konsistensi performa model pada pengujian real-time selama periode Maret 2025 menunjukkan bahwa integrasi *Gramian Angular Field* dengan arsitektur hybrid CNN–LSTM–Transformer memiliki stabilitas yang baik dalam menangkap tren umum pergerakan harga meskipun pasar bersifat volatil. Dengan demikian, sistem yang dikembangkan tidak hanya berfungsi sebagai alat prediksi harga, tetapi juga sebagai modul analitik dalam Sistem Informasi perdagangan *cryptocurrency* yang adaptif dan mendukung proses pengambilan keputusan secara berkelanjutan.

4.6 Keterbatasan dan Diskusi Lanjutan

Meskipun memberikan hasil yang menjanjikan, penelitian ini memiliki beberapa keterbatasan. Ruang lingkup data terbatas pada tiga aset *cryptocurrency* utama dengan periode data historis hingga 30 September 2024, sehingga generalisasi hasil ke aset lain perlu dilakukan dengan kehati-hatian. Selain itu, pada aset dengan harga awal yang sangat rendah, proses normalisasi Min-Max pada representasi GAF dapat mengurangi variasi informasi visual dan memengaruhi kemampuan ekstraksi fitur spasial. Dari sisi implementasi, model hybrid CNN–LSTM–Transformer memiliki kompleksitas komputasi yang tinggi dan memerlukan proses hyperparameter tuning yang intensif, sehingga berpotensi menjadi kendala dalam penerapan real-time atau pada skala aset yang lebih luas. Perubahan dinamika pasar setelah periode pelatihan, khususnya pada akhir 2024 hingga awal 2025, juga dapat memengaruhi konsistensi performa model pada pengujian real-time.

Selain itu, penelitian ini hanya memanfaatkan data historis OHLC tanpa mempertimbangkan variabel eksternal seperti sentimen pasar, faktor makroekonomi, atau data on-chain. Integrasi sumber data tambahan tersebut menjadi peluang pengembangan penelitian selanjutnya untuk meningkatkan

ketahanan, generalisasi, dan nilai praktis model dalam konteks Sistem Informasi dan Sistem Pendukung Keputusan investasi cryptocurrency.

5 Kesimpulan

Penelitian ini menyimpulkan bahwa pendekatan *Gramian Angular Field multi-channel* efektif dalam mentransformasikan data candlestick cryptocurrency menjadi representasi citra yang kaya informasi dan relevan untuk pemodelan berbasis deep learning. Hasil pengujian menunjukkan bahwa model hibrid CNN–LSTM–Transformer secara konsisten memberikan kinerja yang lebih unggul dibandingkan pendekatan konvensional pada ketiga aset *cryptocurrency* yang diteliti. Kinerja terbaik diperoleh pada *Bitcoin* (BTC-USD) dengan nilai R^2 sebesar 0,971 pada horizon prediksi tiga puluh hari, *Ethereum* (ETH-USD) dengan nilai R^2 sebesar 0,948 pada horizon satu tahun, serta *Solana* (SOL-USD) dengan nilai R^2 sebesar 0,975 pada horizon satu hari, yang menunjukkan kemampuan model dalam menangkap dinamika pergerakan harga pada berbagai skala waktu. Pengujian real-time menggunakan API CoinGecko pada Maret 2025 menunjukkan bahwa model mampu merepresentasikan tren umum pergerakan harga pasar aktual secara konsisten. Temuan ini mengindikasikan bahwa integrasi representasi *Gramian Angular Field* dengan arsitektur hibrid CNN–LSTM–Transformer memiliki potensi yang kuat untuk digunakan dalam analisis prediktif pasar *cryptocurrency* yang bersifat dinamis dan berfluktuasi tinggi.

Dalam konteks Sistem Informasi, hasil penelitian ini menunjukkan bahwa model yang diusulkan berpotensi diimplementasikan sebagai komponen model base dalam Sistem Pendukung Keputusan investasi cryptocurrency. Informasi prediktif multi-horizon yang dihasilkan dapat dimanfaatkan oleh trader, analis, dan investor dalam mengevaluasi tren pasar, mendukung pengelolaan risiko, serta merumuskan strategi investasi secara lebih rasional.

Meskipun demikian, penelitian ini masih memiliki keterbatasan yang berkaitan dengan ruang lingkup data, karakteristik aset yang dianalisis, serta kompleksitas model yang digunakan. Keterbatasan tersebut diharapkan dapat menjadi dasar bagi pengembangan penelitian selanjutnya untuk meningkatkan robustnes dan generalisasi model pada pasar *cryptocurrency* yang lebih luas.

Referensi

- [1] S. Nakamoto, “*Bitcoin: A Peer-to-Peer Electronic Cash System*,” 2008.
- [2] T. Nahdi and E. B. Sili, “Legalitas Penggunaan *Cryptocurrency* sebagai Alat Investasi Jangka Panjang di Indonesia,” *Commerce Law*, Vol. 3, No. 1, pp. 1–13, 2023.
- [3] T. B. S. Timothy, I. Cahya, and N. Y. Novanto, “Penerapan Algoritma *Long Short-Term Memory* (LSTM) berbasis Multi Fungsi Aktivasi terbobot dalam Prediksi Harga *Ethereum*,” *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, Vol. 7, No. 3, pp. 1101–1107, 2023.
- [4] M. F. Rizkilloh and S. Widiyanesti, “Prediksi Harga *Cryptocurrency* menggunakan Algoritma *Long Short Term Memory* (LSTM),” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, Vol. 6, No. 1, pp. 25–31, 2022.
- [5] Jun-Hao Chen and Yun-Cheng Tsai, “*Encoding Candlesticks as Images for Pattern Classification using Convolutional Neural Networks*,” *Financial Innovation*, Vol. 6, No. 26, pp. 1–20, 2021.
- [6] I. Uzun, M. Lobachev, V. Kharchenko, T. Schöler, and I. Lobachev, “*Candlestick Pattern Recognition in Cryptocurrency Price Time-Series Data using Rule-based Data Analysis Methods*,” *Computation*, Vol. 12, No. 7, p. 132, 2024.
- [7] S. W. Ng and L. S. Ling, “*Evaluation of Cryptocurrency Price Prediction using LSTM and CNNs Models*,” *International Journal on Informatics Visualization*, Vol. 7, No. 3-2, pp. 2016–2024, 2023.
- [8] R. Zhang, C. Zhao, and G. Lin, “*Interpretable Image-based Deep Learning for Price Trend Prediction in ETF Markets*,” *The European Journal of Finance*, Vol. 29, No. 5, pp. 521–549, 2023.
- [9] A. L. Armin, H. M. Hendra, and S. A. Supri, “*Implementation of Long Short-Term Memory and Gated Recurrent Units on Grouped Time-Series Data to Predict Stock Prices Accurately*,” *Journal of Big Data*, Vol. 9, No. 89, 2022.
- [10] Y. K. Chuen and P. L. Chin, “*Cryptocurrency Price Prediction with Convolutional Neural Network and Stacked Gated Recurrent Unit*,” *Data*, Vol. 7, No. 11, p. 149, 2022.

- [11] K. Jearanaitanakij and B. Passaya, “Predicting Short Trend of Stocks by using Convolutional Neural Network and Candlestick Patterns,” in *Proc. 2019 4th International Conference on Information Technology (InCIT)*, Bangkok, Thailand, 2019, pp. 159–162.
- [12] M. L. P. Muhammad and U. Hastari, “Pendekatan *Deep Learning* menggunakan Metode LSTM untuk Prediksi Harga *Bitcoin*,” *IJCSR: The Indonesian Journal of Computer Science Research*, Vol. 2, No. 2, pp. 43–50, 2023.
- [13] A. F. P. Andree, T. B. K. Tri, Misinem, and D. A. D. Deshinta, “Implementasi Analisis Sentimen dan Model *Deep Learning* untuk Prediksi Harga *Bitcoin*,” *Jurnal Jupiter*, Vol. 15, No. 1, pp. 403–412, 2023.
- [14] A. Imsyar, E. Christopher, A. Dithi, A. N. Khan, and S. Maulana, “The Challenge of Cryptocurrency in the Era of the Digital Revolution: A Review of Systematic Literature,” *Aptisi Transactions on Technopreneurship (ATT)*, Vol. 2, No. 2, pp. 153–162, 2020.
- [15] A. Nurhopipah and N. A. Larasati, “CNN Hyperparameter Optimization using Random Grid Coarse-to-Fine Search for Face Classification,” *Kinetik: Game Technology, Information System, Computer Network, Computing, Electronics, and Control*, Vol. 6, No. 1, pp. 47–56, 2021.
- [16] W. Gazali, H. Soeparno, and J. Ohliati, “Penerapan Metode Konvolusi dalam Pengolahan Citra Digital,” *Jurnal Mat Stat*, Vol. 12, No. 2, pp. 103–113, 2012.