

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian yang Relevan

Dalam penelitian ini, terdapat sejumlah studi terdahulu yang relevan dan dapat dijadikan acuan dalam pengembangan model peramalan harga *Bitcoin* menggunakan metode *deep learning*, khususnya *Hybrid LSTM–GRU*. Penelitian-penelitian tersebut membahas berbagai pendekatan untuk meningkatkan akurasi prediksi harga *cryptocurrency* yang sangat volatil, termasuk melalui perbandingan model, pengembangan arsitektur *hybrid*, integrasi variabel tambahan, serta optimasi *hyperparameter*.

Dengan melakukan kajian terhadap penelitian sebelumnya, penelitian ini bertujuan untuk mengembangkan model prediksi harga *Bitcoin* yang lebih akurat dengan menggabungkan antara LSTM dan GRU menjadi *Hybrid LSTM–GRU* serta memanfaatkan optimasi *hyperparameter*. Berikut ini disajikan beberapa penelitian yang relevan:

1. (Omole & Enke, 2024) dalam artikel *Deep Learning for Bitcoin Price Direction Prediction* meneliti berbagai model deep learning seperti CNN–LSTM, LSTNet, dan Temporal Convolutional Network (TCN) untuk memprediksi arah harga Bitcoin menggunakan data *on-chain*. Hasil penelitian menunjukkan bahwa CNN–LSTM dengan metode *feature selection* Boruta mampu mencapai akurasi 82.44% dalam memprediksi arah harga, sekaligus menghasilkan strategi *trading* yang sangat menguntungkan. Keterbatasan penelitian ini adalah fokus pada arah harga (klasifikasi), bukan prediksi nilai harga aktual (regresi).
2. (Seabe et al., 2023) dalam *Sentiment-driven Cryptocurrency Forecasting* mengintegrasikan data harga Bitcoin dengan analisis sentimen Twitter menggunakan VADER dan RoBERTa. Model Bi-LSTM berbasis RoBERTa menghasilkan performa terbaik dengan nilai MAPE 2.01%. Penelitian ini menunjukkan pentingnya faktor eksternal berupa sentimen pasar dalam

meningkatkan akurasi prediksi, meski membutuhkan sumber daya komputasi besar.

3. (X. Zhang et al., 2025) melakukan studi *LSTM-Conformal Forecasting* mengombinasikan LSTM dengan metode conformal prediction untuk menghasilkan prediksi harga *Bitcoin* yang tidak hanya berupa titik estimasi, tetapi juga interval prediksi. Pendekatan ini meningkatkan reliabilitas model dengan memberikan batas keyakinan pada hasil peramalan, meski lebih kompleks secara implementasi.
4. (Seabe et al., 2023) dalam *Forecasting Cryptocurrency Prices Using LSTM, GRU, and Bi-LSTM* membandingkan tiga arsitektur RNN pada prediksi BTC, ETH, dan LTC. Hasil penelitian menunjukkan bahwa *Bi-LSTM* memberikan performa paling akurat dengan MAPE lebih rendah dibanding LSTM maupun GRU. Namun, penelitian ini belum mengeksplorasi integrasi data non-harga.
5. (Badar et al., 2025) mengusulkan *Hybrid CNN-LSTM* dengan *variational autoencoder* (VAE) untuk ekstraksi fitur serta SHAP untuk *interpretabilitas*. Model ini menghasilkan R^2 sebesar 0.99 dan error prediksi yang sangat rendah (MSE 0.0002), membuktikan kombinasi arsitektur mampu meningkatkan kinerja. Tantangan penelitian ini adalah kompleksitas arsitektur yang cukup tinggi untuk aplikasi *real-time*.
6. (ALDI & Nathasia, 2025) dalam penelitian *Prediksi Harga dan Kinerja Aset Bitcoin Menggunakan LSTM* membandingkan LSTM *Single Layer* dan *Double Layer*. Model *Double Layer* memberikan hasil lebih baik dengan MSE 0.00044 dan R^2 0.98. Penelitian ini juga menghitung kinerja aset menggunakan *Sharpe Ratio* (1.003), tetapi belum memanfaatkan arsitektur GRU.
7. (Ramadhan et al., 2024) melakukan prediksi harga *Bitcoin* menggunakan LSTM dengan horizon 7 hari dan 30 hari. Hasil penelitian menunjukkan bahwa horizon 7 hari lebih akurat dengan RMSE lebih rendah. Keterbatasannya adalah penelitian hanya menggunakan satu arsitektur (LSTM) tanpa perbandingan dengan GRU atau *hybrid*.
8. (Kervanci et al., 2024) dalam *Bitcoin Price Prediction Using LSTM, GRU, and Hybrid LSTM-GRU with Hyperparameter Optimization* membandingkan tiga

teknik optimasi *hyperparameter*: *grid search*, *random search*, dan *Bayesian optimization*. Hasil penelitian menunjukkan bahwa *Bayesian optimization* paling efektif menurunkan *error* prediksi. Namun, penelitian ini belum menguji integrasi variabel volume perdagangan.

9. (Bouteska et al., 2024) meneliti *Sistem Prediksi Harga Bitcoin di Market Cryptocurrency Menggunakan Algoritma Long Short-Term Memory*. Hasil menunjukkan bahwa LSTM cukup efektif untuk data pasar Indonesia, dengan tingkat *error* relatif rendah. Namun penelitian ini terbatas pada model LSTM tanpa membandingkan dengan GRU atau *hybrid*.
10. (Wijaya et al., 2025) melalui *Perbandingan Kinerja LSTM dan GRU* menemukan bahwa GRU lebih unggul dibanding LSTM dalam prediksi harga *close cryptocurrency* (BTC dan ETH) dengan MAPE lebih rendah. Penelitian ini menegaskan efisiensi GRU, meski belum mengintegrasikan *hybrid* model.

Tabel 2. 1 Penelitian Terdahulu

No	Peneliti (Tahun)	Metode yang Digunakan	Hasil Utama	Keterbatasan
1	Omole & Enke (2024)	CNN–LSTM, LSTNet, TCN vs ARIMA (<i>on-chain</i> data)	CNN–LSTM + <i>Boruta feature</i> <i>selection</i> mencapai akurasi 82.44% dalam prediksi arah harga; strategi <i>trading</i> menghasilkan return sangat tinggi	Fokus klasifikasi arah harga, belum regresi nilai aktual
2	Seabe, Moutsinga, & Pindza (2025)	LSTM, GRU, Bi- LSTM, TAM + Twitter <i>sentiment</i>	<i>Bi-LSTM</i> + <i>RoBERTa MAPE</i> 2.01%, terbukti <i>efektif integrasi</i> <i>sentimen</i>	Komputasi berat karena <i>transformer-based</i> <i>embedding</i>

No	Peneliti (Tahun)	Metode yang Digunakan (VADER, RoBERTa)	Hasil Utama	Keterbatasan
3	Zhang et al. (2025)	LSTM + <i>Conformal Forecasting</i>	Memberikan interval prediksi dengan reliabilitas lebih baik dibanding LSTM standar	<i>Implementasi lebih kompleks dan butuh data besar</i>
4	Seabe, Moutsinga, & Pindza (2023)	<i>LSTM, GRU, Bi- LSTM</i>	<i>Bi-LSTM terbaik dengan MAPE BTC 0.036; LSTM (0.041); GRU (0.124)</i>	Hanya data harga, tanpa variabel eksternal
5	Badar et al. (2025)	<i>Hybrid CNN– LSTM + VAE + SHAP</i>	$R^2 = 0.99$, MSE 0.0002 ; <i>akurasi tinggi & interpretabel</i>	Arsitektur kompleks, sulit untuk <i>real-time</i>
6	Chourasia et al. (2023)	<i>LSTM, GRU, Hybrid LSTM– GRU + optimasi (grid, random, Bayesian)</i>	<i>Bayesian optimization paling efektif menurunkan error prediksi</i>	Tidak uji variabel eksternal (volume/sentimen)
7	Aprianto & Ramadhan (2025)	LSTM	Efektif untuk data pasar Indonesia dengan <i>error</i> rendah	Tidak membandingkan dengan GRU/ <i>hybrid</i>

No	Peneliti (Tahun)	Metode yang Digunakan	Hasil Utama	Keterbatasan
8	Ramadhan & Nathasia (2025)	<i>Single vs Double Layer LSTM</i>	<i>Double Layer</i> unggul (<i>MSE</i> <i>0.00044, R² 0.98</i>); <i>Sharpe Ratio</i> <i>1.003</i>	Tidak menggunakan GRU/ <i>hybrid</i>
9	Wijaya (2023)	LSTM vs GRU	GRU lebih efisien & akurat (MAPE lebih rendah) dibanding LSTM	Belum mengembangkan model <i>hybrid</i>
10	Nirraca & Hartati (2024)	<i>LSTM (horizon 7 vs 30 hari)</i>	Horizon 7 hari lebih akurat dengan RMSE & MAE lebih rendah	Hanya uji LSTM, tanpa GRU atau <i>hybrid</i>

Tabel di atas menunjukkan perkembangan dalam penelitian yang berkaitan dengan penerapan model *Hybrid* LSTM-GRU untuk prediksi *cryptocurrency*. Dengan RMSE yang menurun dan akurasi yang meningkat, terlihat tren yang menunjukkan peningkatan dari tahun ke tahun dalam kinerja model. Namun demikian, ada beberapa masalah umum yang dihadapi oleh penelitian terdahulu, seperti keterbatasan dalam optimasi *hyperparameter*, kompleksitas model yang tinggi, dan kurangnya interpretasi model.

Penelitian ini bertujuan untuk mengatasi beberapa masalah ini dengan berfokus pada optimasi *hyperparameter* yang komprehensif, melakukan perbandingan sistematis antara berbagai arsitektur, dan melakukan analisis menyeluruh tentang komponen yang mempengaruhi performa model.

2.2 Landasan Teori

2.2.1 *Bitcoin*

Bitcoin adalah salah satu jenis mata uang digital atau *cryptocurrency* yang diperkenalkan pada tahun 2009 oleh seseorang atau sekelompok orang dengan nama samaran Satoshi Nakamoto. Berbeda dengan sistem keuangan tradisional yang bersifat terpusat, *Bitcoin* beroperasi berdasarkan teknologi *blockchain*, sebuah buku besar digital yang mencatat seluruh transaksi secara berurutan, terbuka, dan susah untuk diubah. Dengan mekanisme ini, setiap transaksi yang dilakukan divalidasi oleh jaringan komputer global sehingga keamanan dan transparansi terjaga tanpa memerlukan lembaga pusat seperti bank sentral (Chohan, 2017).

Jumlah *Bitcoin* yang dapat diakses juga dibatasi, dan totalnya diprediksi akan mencapai 21 juta unit pada tahun 2140. Berbeda dengan mata uang fiat yang lembaga moneter dapat mencetak secara tak terbatas, sifat deflasi *Bitcoin* diciptakan oleh sistem ini. Untuk mengesahkan transaksi dan menghasilkan koin baru, proses penambangan yang menggunakan algoritma *proof-of-work* yang membutuhkan banyak daya komputasi menciptakan keterbatasan jumlah tersebut. Proses penambangan juga berfungsi sebagai sistem keamanan jaringan dan memengaruhi harga *Bitcoin*.

Karakteristik terdesentralisasi, transparan, dan terbatas *Bitcoin* sering dianggap sebagai "emas digital" dan dianggap sebagai aset yang melindungi nilainya. Namun, nilai *Bitcoin* sangat tidak stabil karena pasar, adopsi, regulasi, dan spekulasi investor. Sifat-sifat ini membuat *Bitcoin* menarik untuk diteliti dari sudut pandang teknologi dan kemungkinan menjadi instrumen investasi di era keuangan digital. Mekanisme pasar, atau keseimbangan penawaran dan permintaan, menentukan harga *Bitcoin*. Meskipun demikian, sejumlah variabel memengaruhi pergerakan harga *Bitcoin*, beberapa di antaranya:

1. Sentimen pasar berita positif seperti adopsi institusional atau regulasi yang mendukung dapat mendorong harga naik, sementara berita

negatif seperti peretasan bursa atau larangan pemerintah dapat menurunkannya.

2. Regulasi pemerintah kebijakan di negara-negara besar seperti Amerika Serikat, Uni Eropa, atau Tiongkok sangat memengaruhi harga *Bitcoin* secara global.
3. Faktor makroekonomi kondisi global seperti inflasi, krisis keuangan, hingga kebijakan moneter turut memengaruhi minat investor pada aset *kripto*.
4. Adopsi teknologi semakin banyak perusahaan yang menerima *Bitcoin* sebagai metode pembayaran, semakin tinggi pula legitimasi dan nilainya.

Volatilitas harga *Bitcoin* yang tinggi menjadi salah satu alasan mengapa penelitian terkait peramalan harga (*price forecasting*) sangat penting, baik bagi investor individu maupun institusi keuangan.



Gambar 2. 1 Bitcoin

2.2.2 Time Series Forecasting

Time Series Forecasting adalah data yang menggunakan data historis yang disusun secara berurutan berdasarkan waktu, prediksi seri waktu adalah proses memprediksi nilai pada periode mendatang. Metode ini memiliki tujuan utama untuk menemukan pola, tren, dan perubahan musiman dalam data sehingga model dapat membuat perkiraan yang lebih sesuai dengan keadaan saat ini (Liu & Wang, 2024). Metode ini sangat penting dalam bidang keuangan, misalnya untuk memperkirakan harga saham, kurs mata uang, volume perdagangan, dan harga aset *kripto* seperti *Bitcoin*, yang sangat

tidak stabil. Karena kesalahan prediksi dapat berdampak langsung pada keputusan investasi, manajemen risiko, dan strategi perdagangan, diperlukan akurasi dalam peramalan deret waktu. Oleh karena itu, metode prediksi seri waktu terus berkembang. Ada inovasi dari pendekatan statistik konvensional seperti ARIMA hingga penggunaan algoritme pengajaran mesin dan pengajaran mendalam yang dapat mendeteksi pola non-linier dan kompleksitas data keuangan kontemporer. Karakteristik utama dari data *time series* adalah adanya dependensi temporal, artinya nilai pada suatu waktu dipengaruhi oleh nilai pada waktu sebelumnya. Oleh karena itu, metode *forecasting* berusaha menangkap pola seperti:

1. *Tren* arah pergerakan data dalam jangka panjang yang menunjukkan kecenderungan naik atau turun. Sebagai contoh, dengan keterbatasan suplai hanya 21 juta unit, harga *Bitcoin* cenderung meningkat dalam jangka panjang.
2. *Seasonality* pola yang terjadi secara berkala dalam jangka waktu tertentu. Misalnya, peningkatan aktivitas transaksi atau lonjakan harga yang dipengaruhi oleh siklus pasar dapat dianggap sebagai contoh *seasonality*.
3. *Noise* fluktuasi acak yang tidak dapat dijelaskan secara *deterministik*. Karena sifatnya yang spekulatif, *noise* ini sering muncul di pasar *kripto* dan sangat dipengaruhi oleh faktor eksternal seperti berita, kebijakan regulasi, dan perasaan investor. Untuk membangun model prediksi seri waktu, penting untuk memahami ketiga elemen ini. Model ini harus mampu membedakan pola teratur dari ketidakpastian, sehingga prediksi yang dihasilkan lebih akurat dan dapat diandalkan.


Forecasting dalam bidang keuangan sangat penting untuk:

Tabel 2. 2 Forecasting dalam bidang keuangan

Manajemen risiko	Membantu investor mengantisipasi potensi kerugian.
------------------	--

Strategi investasi	Memberikan dasar bagi pengambilan keputusan jual atau beli.
Perencanaan bisnis	Bagi perusahaan yang berhubungan dengan aset digital, prediksi harga membantu dalam perhitungan biaya dan pendapatan.

Autoregressive Integrated Moving Average (ARIMA), *Exponential Smoothing*, dan *Vector Autoregression (VAR)* adalah metode prediksi tradisional yang sering digunakan. ARIMA banyak digunakan untuk memodelkan data deret waktu dengan sifat stasioner, sedangkan *Exponential Smoothing* efektif dalam mengakomodasi pola dan tren musiman dengan memberikan bobot yang lebih besar pada data terbaru. Sebaliknya, VAR memungkinkan analisis simultan terhadap beberapa variabel yang saling memengaruhi. Meskipun teknik-teknik ini telah terbukti berguna untuk data linier dan relatif stabil, masalah muncul ketika digunakan pada data keuangan kontemporer yang bersifat non-linear, dinamis, dan penuh dengan ketidakpastian, seperti harga aset *kripto*. Model tradisional cenderung menghasilkan prediksi yang tidak cukup akurat karena kompleksitas hubungan antar variabel, pengaruh faktor eksternal yang berubah dengan cepat, dan tingkat *noise* yang tinggi. Kondisi inilah yang mendorong pengembangan metode berbasis *machine learning* dan *deep learning*. Metode-metode ini lebih cocok untuk menangani fluktuasi jangka panjang dan jangka pendek serta pola non-linear (Ahmad et al., 2025).



Gambar 2. 2 Forecasting Time Series

2.2.3 Long Short Term Memory (LSTM)

Long Short-Term Memory (LSTM) adalah bentuk pengembangan dari *Recurrent Neural Network* (RNN) yang dibangun untuk mengatasi keterbatasan RNN konvensional, khususnya masalah *vanishing gradient* saat memproses data *sekuens* dengan urutan yang panjang. Pada RNN biasa, informasi dari waktu sebelumnya cenderung semakin melemah ketika diteruskan ke langkah berikutnya, sehingga model sering kesulitan menangkap keterkaitan jangka panjang. Untuk mengatasi hal tersebut, LSTM menggunakan komponen memori internal yang dikenal sebagai *cell state*, yaitu jalur penyimpanan informasi yang memungkinkan konteks penting tetap dipertahankan dalam rentang waktu yang lebih panjang. Selain itu, LSTM memiliki tiga mekanisme gerbang, yaitu *forget gate*, *input gate*, dan *output gate*, yang berfungsi mengatur aliran informasi secara selektif pada setiap langkah waktu.

Secara umum, *forget gate* bertugas menyeleksi informasi lama yang masih relevan untuk dipertahankan, *input gate* mengatur informasi baru yang akan dimasukkan ke memori, sedangkan *output gate* menentukan bagian informasi yang akan digunakan sebagai keluaran model. Sinergi ketiga gerbang tersebut membuat LSTM mampu mempelajari pola temporal yang kompleks, termasuk hubungan *nonlinier* pada data deret

waktu (*time series*) yang mengandung tren, pola berulang, dan fluktuasi (Wen & Li, 2023).

Dalam prediksi harga aset seperti *Bitcoin*, kemampuan ini menjadi penting karena perubahan harga tidak hanya dipengaruhi oleh kondisi jangka pendek, tetapi juga oleh pola historis yang terbentuk dalam periode sebelumnya. Oleh sebab itu, LSTM dinilai sesuai untuk memodelkan data yang bersifat dinamis dan memiliki keterkaitan antar kurun waktu .

Keunggulan utama LSTM terletak pada kemampuannya menjaga informasi jangka panjang dengan lebih stabil dibandingkan RNN standar. Adanya mekanisme gerbang membuat proses pembelajaran menjadi lebih terarah, sehingga informasi penting dari urutan data sebelumnya tidak mudah hilang. Kondisi ini menjadikan LSTM efektif untuk mengenali tren jangka panjang, pola musiman, maupun perubahan bertahap yang sering ditemukan pada data keuangan. Di samping itu, LSTM juga cukup fleksibel karena dapat diterapkan pada data sekuens univariat maupun multivariat, serta memungkinkan integrasi dengan variabel atau indikator teknikal lain untuk meningkatkan performa prediksi (K. Djunaidi, M. Y. D. Sudirman, 2025).

Walaupun demikian, LSTM tetap memiliki keterbatasan. Struktur arsitekturnya yang relatif kompleks menyebabkan jumlah parameter model menjadi lebih banyak, sehingga proses pelatihan membutuhkan waktu komputasi lebih lama dan sumber daya perangkat keras yang lebih besar. Kompleksitas tersebut juga dapat meningkatkan risiko *overfitting* jika data pelatihan kurang representatif atau regularisasi tidak diterapkan secara tepat. Dalam konteks sistem prediksi real-time atau lingkungan komputasi yang terbatas, penggunaan LSTM sebagai model tunggal terkadang kurang efisien. Oleh karena itu, meskipun LSTM unggul dalam menangkap pola jangka panjang, penentuan arsitektur dan strategi optimasi tetap perlu diperhatikan agar model menghasilkan kinerja yang optimal.

Rumus LSTM :

Rumus ini menggambarkan bagaimana LSTM mengatur *input*, memori, dan *output* pada setiap langkah waktu. Adapun rumus-rumusnya, yaitu:

- *Forget gate* f_t :

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.4)$$

- *Input gate* i_t :

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.5)$$

- *Cell state* C_t :

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (2.6)$$

- *Output gate* o_t :

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2.7)$$

- *Hidden state* h_t :

$$h_t = o_t \cdot \tanh(C_t) \quad (2.8)$$

2.2.4 Gated Recurrent Unit (GRU)

Gated Recurrent Unit (GRU) merupakan salah satu varian dari *Recurrent Neural Network* (RNN) yang dikembangkan dengan struktur lebih sederhana dibandingkan *Long Short-Term Memory* (LSTM), namun tetap mempertahankan mekanisme pengendalian aliran informasi melalui sistem gerbang. Berbeda dengan LSTM yang menggunakan tiga gerbang serta memisahkan *cell state* dan *hidden state*, GRU hanya menggunakan

dua gerbang utama, yaitu *update gate* dan *reset gate*, serta menggabungkan representasi memori ke dalam satu *hidden state*. *Update gate* berfungsi mengatur proporsi informasi lama yang dipertahankan dan informasi baru yang dimasukkan, sedangkan *reset gate* berperan dalam menentukan sejauh mana informasi masa lalu perlu diabaikan ketika model memproses *input* terbaru. Penyederhanaan arsitektur ini membuat GRU lebih ringkas secara struktur, tetapi tetap mampu mempelajari pola temporal pada data *sekuens* secara efektif.

Dalam pemodelan data deret waktu (*time series*), GRU dikenal memiliki kemampuan yang baik dalam menangkap pola perubahan data dengan beban komputasi yang lebih rendah dibandingkan LSTM. Karakteristik tersebut menjadikan GRU sering digunakan pada penelitian prediksi *sekuens*, terutama ketika efisiensi proses pelatihan menjadi pertimbangan penting. Pada data keuangan seperti harga *Bitcoin* yang bersifat fluktuatif dan cepat berubah, GRU memiliki keunggulan dalam merespons dinamika jangka pendek secara adaptif. Dengan jumlah parameter yang lebih sedikit, GRU dapat melakukan proses pelatihan lebih cepat tanpa kehilangan kemampuan dasar dalam memahami hubungan antar data pada urutan waktu tertentu (Y. Zhang et al., 2024).

Kelebihan utama GRU terletak pada efisiensi komputasi dan waktu pelatihan yang relatif lebih singkat karena struktur modelnya lebih sederhana. Hal ini membuat GRU lebih ringan untuk diimplementasikan, termasuk pada perangkat dengan sumber daya komputasi terbatas. Selain itu, performa GRU pada berbagai kasus prediksi deret waktu juga sering kali kompetitif, bahkan pada kondisi tertentu dapat mendekati atau menyamai LSTM. Oleh karena itu, GRU menjadi pilihan yang cukup baik ketika penelitian membutuhkan keseimbangan antara akurasi prediksi dan efisiensi proses komputasi.

Meskipun demikian, GRU memiliki keterbatasan dalam menangkap dependensi jangka sangat panjang pada beberapa jenis data. Karena arsitekturnya lebih sederhana, kapasitas memorinya dalam menyimpan

konteks historis yang kompleks dapat lebih terbatas dibandingkan LSTM. Akibatnya, pada data yang sangat bergantung pada pola jangka panjang, LSTM sering menunjukkan performa yang lebih stabil. Dengan demikian, pemilihan GRU perlu disesuaikan dengan karakteristik data dan tujuan pemodelan. Dalam konteks prediksi harga aset, GRU sangat bermanfaat untuk memodelkan perubahan jangka pendek secara efisien, tetapi tetap perlu dipertimbangkan kombinasi dengan pendekatan lain apabila diperlukan representasi pola jangka panjang yang lebih kuat (Adamu, 2024).

Adapun rumus-rumus dasar dari GRU adalah:

- *Update gate* z_t :

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (2.9)$$

- *Reset gate* r_t :

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (2.10)$$

- *Candidate hidden state* $\tilde{h}_t$:

$$\tilde{h}_t = \tanh(W_h \cdot [h_{t-1}, x_t] + b_h) \quad (2.11)$$

- *Final hidden state* h_t :

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t \quad (2.12)$$

2.2.5 Hybrid LSTM–GRU

Dalam arsitektur model *deep learning Hybrid LSTM-GRU*, dua jenis jaringan saraf *Recurrent Neural Network* (RNN) LSTM dan GRU digabungkan untuk menggabungkan keunggulan masing-masing dalam

menangani data deret waktu yang sangat kompleks (Satria Andromeda & Anisa Sri Winarsih, 2025). Tujuan dari metode ini adalah untuk memaksimalkan kemampuan LSTM untuk menangkap dependensi jangka panjang dan kekuatan GRU saat menangani ketergantungan jangka pendek (Kervanci et al., 2024).

Model yang digunakan dalam penelitian ini adalah arsitektur *Hybrid LSTM-GRU* paralel. Pada arsitektur ini, data *input* yang sama diproses secara bersamaan oleh dua cabang jaringan, yaitu *Long Short Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). *Output* dari kedua cabang tersebut kemudian digabungkan menggunakan operasi *concatenation* dan diteruskan ke lapisan *Dense* untuk menghasilkan prediksi akhir. Adapun yang dimaksud dengan pendekatan Paralel adalah :

Pendekatan Paralel: Dalam pendekatan ini, LSTM dan GRU bekerja secara paralel dengan menerima *input* yang sama. Setiap model akan memproses data sesuai dengan kekuatannya masing-masing, dan hasil dari kedua model tersebut kemudian digabungkan untuk menghasilkan *output* akhir. Pendekatan ini memungkinkan kedua model untuk menangkap informasi yang berbeda dari data yang sama, sehingga memberikan prediksi yang lebih kaya dan lebih akurat.

Rumus Penggabungan *Output*:

$$h_{\text{final}} = \text{concat}(h_{\text{LSTM}}, h_{\text{GRU}}) \quad (2.1)$$


atau

$$h_{\text{final}} = \frac{1}{2}(h_{\text{LSTM}} + h_{\text{GRU}}) \quad (2.2)$$

Dengan menggunakan arsitektur *hybrid* ini, model dapat menggunakan LSTM untuk mengumpulkan informasi jangka panjang dan menggunakan GRU untuk menangani fluktuasi data yang cepat, yang sangat membantu dalam memprediksi harga aset

digital yang sangat berubah seperti *Bitcoin* (Ilham Caniago et al., 2021). Keuntungan utama dari arsitektur *hybrid* ini adalah kemampuan untuk memberikan prediksi yang lebih akurat dan fleksibel karena dapat menangani berbagai pola data (Widiasari & Efendi, 2024).

Arsitektur Hybrid LSTM- GRU digambarkan sebagai berikut :



Gambar 2. 3 Hybrid LSTM-GRU

2.2.6 Mean Absolut Error (MAE)

Salah satu metrik evaluasi yang paling sederhana dan paling umum digunakan dalam analisis prediksi adalah *Mean Absolute Error* (MAE). MAE mengukur kesalahan rata-rata antara nilai prediksi dan nilai aktual dengan menghitung selisih absolut antara keduanya, lalu merata-ratakan hasilnya. MAE memberikan gambaran yang jelas tentang besarnya kesalahan prediksi tanpa mempertimbangkan arah kesalahan (apakah nilai yang sebenarnya lebih tinggi atau lebih rendah).

Secara matematis, MAE dihitung dengan rumus:

$$MAE = \frac{1}{n} \sum_{i=1}^n | y_i - \hat{y}_i | \quad (2.13)$$

Keterangan :

- n adalah jumlah data,
- y_i adalah nilai aktual,

- $\hat{y}_i$ adalah nilai prediksi.

MAE sering digunakan untuk menilai ketepatan prediksi model secara keseluruhan karena metriknya mudah dipahami dan memberikan wawasan langsung tentang seberapa besar kesalahan rata-rata model dalam satuan data asli yang diprediksi. Karena kesalahan besar dan kecil dihitung dengan cara yang sama, MAE tidak memperhatikan kesalahan besar. Hal ini membuat MAE kurang peka terhadap nilai *ekstrem*, atau *outliers*, dalam data. Ini dapat menjadi komponen penting dalam beberapa aplikasi prediksi.

2.2.7 Root Mean Square Error (RMSE)

Sebuah metrik yang dikenal sebagai *Root Mean Square Error* (RMSE) digunakan untuk menentukan seberapa jauh prediksi model menyimpang dari nilai sebenarnya. RMSE sangat sensitif terhadap kesalahan besar karena setiap kesalahan dikuadratkan sebelum dihitung rata-ratanya, yang dihitung dengan mengambil akar kuadrat dari rata-rata kuadrat kesalahan antara nilai aktual dan yang diprediksi. Akibatnya, RMSE memberikan hukuman yang lebih berat untuk kesalahan prediksi yang signifikan.

Secara matematis, RMSE dihitung dengan rumus:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.14)$$

RMSE sering digunakan ketika ingin memberikan perhatian lebih pada kesalahan besar, yang penting dalam aplikasi di mana kesalahan besar dapat berisiko, seperti dalam peramalan harga saham atau aset *kripto*. Keunggulan RMSE adalah kemampuannya untuk memberikan gambaran yang lebih sensitif terhadap kesalahan besar dibandingkan dengan MAE, tetapi juga menjadikannya lebih rentan terhadap *outliers*.

2.2.8 Mean Absolute Percentage Error (MAPE)

MAPE dihitung dengan mengambil selisih absolut antara nilai yang diprediksi dan nilai aktual, membaginya dengan nilai aktual, dan mengalikannya dengan 100 untuk mendapatkan persentase. Ini menunjukkan seberapa jauh prediksi model dari nilai aktual dalam persentase.

Secara matematis, MAPE dihitung dengan rumus:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (2.15)$$

Keterangan :

- n adalah jumlah data,
- y_i adalah nilai aktual,
- $\hat{y}_i$ adalah nilai prediksi.

MAPE memiliki kelebihan dalam hal kemudahan interpretasi karena memberikan hasil dalam bentuk persentase yang mudah dipahami. MAPE memungkinkan perbandingan performa antar model bahkan ketika skala data yang diprediksi sangat berbeda. Namun, MAPE memiliki kelemahan utama, yaitu tidak dapat menangani nilai aktual yang sangat kecil atau hampir nol, yang dapat menghasilkan nilai kesalahan yang sangat besar atau tak terhingga. Oleh karena itu, MAPE harus digunakan dengan hati-hati, terutama pada *dataset* yang memiliki nilai sangat kecil atau hampir nol.

2.2.9 Cross Industry Process Standart for Data Mining (CRISP-DM)

CRISP-DM (*Cross-Industry Standard Process for Data Mining*) adalah metodologi standar yang dikembangkan untuk memberikan kerangka kerja sistematis dalam pelaksanaan proyek data *mining*. CRISP-DM dirancang agar dapat diterapkan di berbagai bidang, baik industri maupun

penelitian, sehingga proses pengolahan dan analisis data dapat dilakukan secara terstruktur dan efisien. Metodologi ini menekankan pentingnya pemahaman yang jelas tentang tujuan sejak tahap awal serta keterkaitan antar tahapan dalam siklus data *mining* yang bersifat *iteratif* dan adaptif terhadap kebutuhan proyek (Rifai et al., 2019).

Sebagai suatu metodologi standar, CRISP-DM memandang proses data *mining* sebagai sebuah siklus yang terdiri dari beberapa fase yang saling berkaitan. Setiap fase dalam siklus ini tidak berdiri sendiri, melainkan memungkinkan adanya umpan balik yang saling terintegrasi. Proses ini memungkinkan pengulangan tahap-tahap tertentu apabila hasil yang diperoleh belum sesuai dengan tujuan yang telah ditetapkan pada tahap awal. Pendekatan berbasis siklus ini memberikan fleksibilitas yang memungkinkan peneliti untuk melakukan penyesuaian terhadap data, metode, serta model yang dikembangkan berdasarkan hasil evaluasi yang dilakukan di setiap tahap (Karmila & Rezki, 2020).

Pendekatan ini juga memfasilitasi penyesuaian berkelanjutan selama siklus berlangsung, yang memberikan ruang bagi proses analisis data yang lebih adaptif dan responsif terhadap perubahan dan perkembangan baru dalam proyek. Hal ini menjadikan CRISP-DM sebagai salah satu metodologi yang efektif dan efisien dalam pengolahan data yang sangat dinamis, seperti pada proyek data *mining* di berbagai bidang industri maupun penelitian.

Dalam praktiknya, CRISP-DM banyak digunakan sebagai pendekatan sistematis yang bertujuan untuk meningkatkan kualitas hasil analisis data. Dengan mengikuti tahapan-tahapan yang telah ditetapkan dalam CRISP-DM, proses data *mining* menjadi lebih terkontrol dan terarah, mulai dari pemahaman permasalahan hingga penerapan hasil analisis. Pendekatan ini juga membantu memastikan bahwa hasil data *mining* tidak hanya akurat secara teknis, tetapi juga relevan dan dapat dimanfaatkan sesuai dengan tujuan awal penelitian atau kebutuhan organisasi (Puji Catur Siswipratini, Ahmad Saputra Fadiatora, 2023).

Metodologi CRISP-DM terdiri dari enam tahapan utama yang membentuk satu siklus proses data *mining*, yang antara lain adalah sebagai berikut:

1. *Business Understanding* (Pemahaman Bisnis)

Tahap pertama dalam CRISP-DM adalah pemahaman bisnis atau tujuan penelitian yang jelas. Pada tahap ini, fokus utama adalah memahami konteks permasalahan yang ingin diselesaikan, baik dari sisi bisnis maupun penelitian. Aktivitas utama dalam tahap ini mencakup identifikasi masalah yang perlu dipecahkan, penentuan sasaran yang ingin dicapai, serta perumusan kebutuhan yang ingin tercapai melalui proses data *mining*. Dengan pemahaman yang jelas tentang tujuan bisnis, seluruh proses selanjutnya dalam data *mining* akan lebih terarah dan relevan.

2. *Data Understanding* (Pemahaman Data)

Setelah memahami tujuan bisnis, tahap berikutnya adalah pemahaman mendalam terhadap data yang akan digunakan. Pada tahap ini, dilakukan serangkaian kegiatan yang meliputi pengumpulan data awal, deskripsi data untuk memahami struktur dan karakteristiknya, eksplorasi data untuk menemukan pola atau informasi yang relevan, serta identifikasi kualitas data guna mendeteksi masalah yang mungkin muncul, seperti data yang tidak lengkap atau tidak konsisten. Pemahaman yang baik terhadap data merupakan langkah penting untuk memastikan proses analisis yang lebih efektif dan efisien.

3. *Data Preparation* (Persiapan Data)

Setelah data dipahami, langkah selanjutnya adalah mempersiapkan data agar siap digunakan dalam tahap pemodelan. Proses ini melibatkan beberapa langkah, seperti seleksi data, di mana data yang relevan dengan tujuan analisis

dipilih; pembersihan data, yang mencakup penghapusan atau perbaikan data yang tidak konsisten atau hilang; integrasi data, yang menyatukan data dari berbagai sumber; serta transformasi data untuk memastikan bahwa data berada dalam format yang sesuai dengan teknik analisis yang akan digunakan. Persiapan data ini sangat krusial untuk memastikan kualitas dan ketepatan analisis yang dilakukan pada tahap selanjutnya.

4. Modeling (Pemodelan)

Pada tahap ini, teknik atau algoritma data *mining* yang sesuai dengan karakteristik data dan tujuan penelitian akan dipilih dan diterapkan. Proses ini melibatkan penggunaan berbagai metode dan algoritma yang dapat menghasilkan model yang optimal untuk memecahkan masalah yang diidentifikasi pada tahap pertama. Pemodelan sering kali dilakukan secara *iteratif*, artinya proses ini bisa diulang-ulang dengan pengaturan parameter atau pemilihan metode yang berbeda untuk mendapatkan model dengan kinerja terbaik. Dalam proses ini, peneliti harus memilih teknik yang paling tepat, apakah itu regresi, klasifikasi, *clustering*, atau metode lainnya.


5. *Evaluation* (Evaluasi)

Setelah model dibangun, tahap selanjutnya adalah evaluasi untuk menilai kesesuaian model yang dihasilkan dengan tujuan yang telah ditetapkan pada tahap awal. Evaluasi tidak hanya dilihat dari performa teknis model, tetapi juga dari sisi relevansi hasil yang dihasilkan terhadap kebutuhan penelitian atau bisnis. Dalam tahap ini, dilakukan analisis terhadap kualitas model, apakah model tersebut dapat memberikan hasil yang akurat dan bermanfaat sesuai dengan harapan. Jika hasil evaluasi tidak memuaskan, maka mungkin diperlukan perbaikan model atau iterasi lebih lanjut pada tahap modeling.

6. *Deployment* (Penerapan)

Tahap terakhir dalam CRISP-DM adalah penerapan hasil data *mining*. Pada tahap ini, model atau pengetahuan yang dihasilkan dari analisis data dapat diimplementasikan dalam berbagai bentuk. Hasilnya dapat diterapkan dalam sistem, digunakan untuk membuat laporan atau rekomendasi, atau bahkan diintegrasikan ke dalam proses bisnis yang lebih besar. Penerapan ini bertujuan untuk memastikan bahwa hasil yang diperoleh dari proses data mining dapat memberikan manfaat yang nyata bagi organisasi atau tujuan penelitian yang lebih besar.

2.2.10 Kerangka Berpikir



Gambar 2. 4 Kerangka Berpikir

Kerangka berpikir adalah dasar konseptual yang menjelaskan bagaimana suatu penelitian akan berjalan. Pada dasarnya, kerangka berpikir menjelaskan bagaimana variabel yang diteliti, metode yang digunakan, dan tujuan yang ingin dicapai berhubungan satu sama lain. Peneliti dapat melihat bagaimana proses penelitian dilakukan secara sistematis, mulai dari pengumpulan data hingga tahap analisis dan pengujian hasil. Dengan menggunakan kerangka berpikir, penelitian menjadi lebih terarah dan memiliki kejelasan metodologis untuk menyelesaikan masalah.

Dengan menggunakan pendekatan *deep learning*, penelitian ini sebagian besar berkonsentrasi pada prediksi harga *Bitcoin* dengan *Hybrid Long Short-Term Memory–Gated Recurrent Unit* (LSTM–GRU). Model-model ini termasuk dalam keluarga *Recurrent Neural Network* (RNN), yang

dirancang untuk memproses data deret waktu (*time series data*) dengan mempertimbangkan keterkaitan antar waktu.

Sebagaimana ditunjukkan pada Gambar 2.4 berikut, kerangka berpikir penelitian ini terdiri dari empat elemen utama: indikator (*data input*), metode (pemodelan prediksi), tujuan (analisis perbandingan hasil prediksi), dan pengujian (evaluasi performa model). Keempat komponen ini saling berhubungan dan membentuk alur penelitian yang logis. Adapun penjelasan dari keempat komponen tersebut adalah sebagai berikut :

1. Indikator

Penentuan indikator penelitian data harga *Bitcoin* adalah langkah pertama dalam kerangka berpikir ini. Data ini dipilih karena *Bitcoin* adalah aset digital yang sangat berfluktuasi, dengan perubahan harga yang besar dapat terjadi dalam waktu yang sangat singkat. Banyak variabel, termasuk kebijakan regulasi, sentimen publik, permintaan pasar, dan aktivitas spekulatif investor, sangat memengaruhi fluktuasi tersebut.

Data harga *Bitcoin* yang digunakan diperoleh dari sumber terpercaya seperti Yahoo Finance. Informasi tentang harga pembukaan (*open*), harga penutupan (*close*), harga tertinggi (*high*), harga terendah (*low*), dan jumlah transaksi yang terjadi setiap hari termasuk dalam data ini. Sebelum digunakan sebagai *input* model, data akan melalui proses *preprocessing*, yang mencakup:

- Data *cleaning* adalah proses menghapus nilai kosong atau anomali dari data.
- Normalisasi data, dengan Min-Max *Scaler* memastikan bahwa skala seluruh fitur berada dalam rentang yang sama. Ini mempercepat proses pelatihan model.

- Pembagian Data yaitu sebagian besar data digunakan untuk melatih model, dan sebagian lagi digunakan untuk menguji kemampuan generalisasi model.

2. Metode

Pemilihan dan penerapan metode prediksi berbasis pembelajaran mendalam adalah langkah berikutnya dalam kerangka berpikir. Dua model utama yang digunakan dalam penelitian ini adalah *Hybrid Long Short-Term Memory-Gated Recurrent Unit* (LSTM–GRU).

Metode hybrid LSTM–GRU: Metode ini menggabungkan kekuatan dari dua arsitektur populer, LSTM dan GRU. LSTM memiliki mekanisme *state cell* dan tiga gerbang utama (*input*, *output*, dan *forget gate*), tetapi GRU memiliki mekanisme pembelajaran yang lebih sederhana dan lebih cepat dalam konvergensi.

Diharapkan kelemahan masing-masing model dapat diatasi dengan kombinasi LSTM dan GRU. GRU mempercepat proses pelatihan dan meningkatkan efisiensi komputasi, sedangkan LSTM menangkap pola jangka panjang dan kompleks pada data harga *Bitcoin*. Dalam penelitian terbaru, metode *hybrid* ini telah banyak digunakan untuk meningkatkan akurasi prediksi data deret waktu yang kompleks seperti harga saham, cuaca, dan aset *kripto*.

3. Tujuan

Peneliti ingin mengetahui seberapa akurat model *Hybrid* LSTM-GRU dibandingkan dengan model prediksi lainnya dengan melakukan perbandingan hasil prediksi dalam konteks peramalan harga *Bitcoin*. Model *Hybrid* LSTM-GRU menggabungkan kekuatan dari LSTM untuk menangkap pola

jangka panjang dan GRU untuk menangani fluktuasi jangka pendek, yang memberikan keuntungan dalam meningkatkan akurasi dan efisiensi prediksi.

Perbandingan ini sangat penting karena model *Hybrid LSTM-GRU* memiliki karakteristik dan kemampuan unik dalam menangkap pola data, diharapkan dengan pendekatan *hybrid* dapat mencapai keseimbangan antara akurasi dan efisiensi, yang akan menghasilkan model prediksi yang optimal. Dengan menggunakan model ini, diharapkan dapat meningkatkan kemampuan dalam meramalkan harga *Bitcoin* secara lebih akurat.

Selain itu, tujuan lain dari penelitian ini adalah untuk memberikan kontribusi ilmiah dalam pengembangan model prediksi harga aset digital berbasis *deep learning*. Hasil perbandingan yang diperoleh nantinya dapat digunakan sebagai referensi bagi peneliti atau praktisi di bidang keuangan digital untuk memilih model prediksi yang paling sesuai dengan fitur data *kripto* yang dinamis.

4. Penilaian

Setelah model menghasilkan hasil prediksi, langkah selanjutnya adalah menguji dan mengevaluasi kinerjanya. Tiga metrik evaluasi kesalahan yang umum digunakan dalam penelitian peramalan deret waktu adalah *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE), dan *Root Mean Square Error* (RMSE). Pengujian ini dilakukan.

Untuk menghitung rata-rata selisih absolut antara nilai aktual dan hasil prediksi, *mean absolute error* (MAE) digunakan. Metrik ini menunjukkan seberapa besar kesalahan

prediksi secara umum tanpa memperhatikan arah kesalahan. Performa model lebih baik dengan nilai MAE yang lebih rendah.

Menghitung rata-rata persentase kesalahan antara nilai aktual dan nilai prediksi, *Mean Absolute Percentage Error* (MAPE) memberikan gambaran yang mudah diinterpretasikan karena hasilnya berupa persentase kesalahan relatif terhadap nilai sebenarnya.

Root Mean Square Error (RMSE) adalah dasar dari rata-rata kuadrat kesalahan antara nilai aktual dan hasil prediksi. RMSE menekankan penalti yang lebih besar untuk kesalahan yang besar, sehingga cocok digunakan untuk menilai kestabilan model dalam memprediksi data fluktuatif seperti harga *Bitcoin*.