

BAB II

LANDASAN TEORI

2.1 Penelitian Terdahulu

No	JUDUL PENELITIAN	PENULIS DAN TAHUN	METODE	HASIL PEMBAHASAN
1	Predicting Cryptocurrency Price Using RNN and LSTM Method	Gunarto, D.M., Sa'adah, S., & Utama, D.Q. (2023)	<i>RNN dan LSTM</i>	LSTM lebih unggul dibandingkan RNN dengan tingkat akurasi prediksi 94,34% pada Bitcoin dan 95,42% pada Ethereum.
2	Prediksi Harga Mata Uang Virtual (Cryptocurrency) dengan Metode LSTM	Kholifah, F.N. (2024)	LSTM	Akurasi model mencapai 93% berdasarkan nilai MAPE untuk Ethereum
3	Implementasi Deep Learning Menggunakan Long Short-Term Memory dalam Peramalan Harga Cryptocurrency	Putra, I.G.S. (2025)	LSTM dan Stacked LSTM	Model mencapai akurasi 96,06% (Bitcoin), 96,91% (Ethereum)

Tabel 2. 1 Tabel Penelitian Terdahulu

Berdasarkan Tabel 2.1 Penelitian Terdahulu, terdapat beberapa studi yang relevan terkait prediksi harga cryptocurrency menggunakan metode deep learning. Penelitian yang dilakukan oleh Gunarto et al. membandingkan kinerja metode RNN dan LSTM dalam memprediksi harga Bitcoin dan Ethereum. Hasilnya menunjukkan bahwa LSTM lebih unggul dibandingkan RNN dengan tingkat akurasi prediksi 94,34% pada Bitcoin dan 95,42% pada Ethereum karena mampu memberikan akurasi prediksi yang lebih baik [2].

Selanjutnya, penelitian oleh Kholifah menggunakan metode LSTM untuk memprediksi harga Ethereum. Model yang dikembangkan berhasil mencapai tingkat akurasi hingga 93% berdasarkan nilai Mean Absolute Percentage Error (MAPE), yang menunjukkan efektivitas LSTM dalam mengenali tren harga mata uang kripto [1].

Penelitian Putra [5] memperlihatkan keunggulan signifikan metode Stacked LSTM dibandingkan LSTM standar. Berdasarkan hasil pengujian, arsitektur Stacked LSTM terbukti lebih robust dengan tingkat kesalahan yang minim, menghasilkan akurasi prediksi mencapai 96% untuk Bitcoin. Capaian ini mengindikasikan bahwa penambahan kedalaman lapisan (stacking layers) mampu meningkatkan presisi model secara substansial dalam menghadapi fluktuasi harga aset kripto.

Dengan merujuk pada ketiga penelitian di atas, dapat disimpulkan bahwa LSTM dan variannya memiliki potensi besar dalam memprediksi harga cryptocurrency. Penelitian ini mencoba melangkah lebih jauh dengan mengombinasikan pendekatan jangka pendek dan jangka panjang, sehingga dapat memberikan informasi prediktif yang lebih aplikatif dan relevan bagi pelaku pasar. Pemilihan Stacked LSTM dibandingkan turunan LSTM lainnya didasarkan pada keunggulannya dalam mengekstraksi pola data secara lebih mendalam melalui arsitektur berlapis, sehingga mampu meningkatkan akurasi dan stabilitas prediksi pada data yang sangat volatil. Selain itu, Stacked LSTM lebih fleksibel dalam menangani horizon waktu jangka pendek maupun jangka panjang. Dengan demikian, Stacked LSTM dinilai sebagai metode yang paling tepat untuk mencapai hasil prediksi yang akurat dan bermanfaat dalam mendukung pengambilan keputusan investasi di pasar kripto.

2.2 Landasan Teori

2.2.1 Cryptocurrency

Cryptocurrency merupakan aset digital yang menggunakan teknologi kriptografi untuk mengamankan transaksi dan mengatur penciptaan unit baru secara terdesentralisasi. Bitcoin dan Ethereum adalah dua cryptocurrency paling populer yang banyak digunakan dalam investasi dan perdagangan global. Karena tidak berada di bawah pengawasan otoritas pusat seperti bank sentral, harga cryptocurrency sangat dipengaruhi oleh permintaan pasar dan berita global, sehingga menyebabkan volatilitas harga yang tinggi dan fluktuatif [11].

Di Indonesia, meskipun cryptocurrency tidak diakui sebagai alat pembayaran yang sah, pemerintah mengatur perdagangan aset kripto sebagai komoditas yang dapat diperdagangkan di pasar berjangka melalui pengawasan Badan Pengawas Perdagangan Berjangka Komoditi (Bappebti). Regulasi ini memberikan landasan hukum yang jelas dan pengawasan yang ketat untuk mengurangi risiko penyalahgunaan dan meningkatkan kepercayaan investor (Sujjada, Sembiring, & Febriansyah (2025); Anam et al. (2024)). Selain itu, dengan disahkannya Undang-Undang Nomor 4 Tahun 2023, pengawasan terhadap aset kripto di Indonesia kini juga melibatkan Otoritas Jasa Keuangan (OJK), yang bertanggung jawab mengatur dan mengawasi sektor teknologi informasi dan aset digital [13].

Volatilitas harga Bitcoin dan Ethereum yang tinggi disebabkan oleh berbagai faktor, termasuk sentimen pasar, regulasi yang berubah-ubah, dan perkembangan teknologi blockchain. Kondisi ini menimbulkan risiko investasi yang besar dan menuntut penggunaan metode prediksi harga yang akurat untuk membantu pengambilan keputusan investasi [14].

2.2.2 Analisis Time Series

Analisis deret waktu bertujuan untuk memahami pola data yang berurutan berdasarkan waktu, seperti tren, musiman, dan fluktuasi. Model konvensional seperti ARIMA masih banyak digunakan dalam memprediksi data keuangan. Namun, model ini sering kali kurang efektif dalam menangani data yang bersifat non-linier dan sangat dinamis seperti harga cryptocurrency. Oleh karena itu, pendekatan berbasis machine learning dan deep learning menjadi pilihan yang lebih unggul karena kemampuannya dalam mengelola kompleksitas data yang tinggi [15].

Penelitian terdahulu umumnya lebih berfokus pada prediksi jangka pendek. Misalnya, Gunarto et al. (2023) menggunakan metode RNN dan LSTM untuk memprediksi harga Bitcoin dan Ethereum harian, dengan hasil bahwa LSTM lebih unggul dibandingkan RNN berdasarkan nilai RMSE. Kholifah (2024) juga menggunakan LSTM untuk memprediksi harga Ethereum dengan akurasi 93% berdasarkan MAPE, namun masih terbatas pada horizon jangka pendek. Putra (2025) menambahkan arsitektur Stacked LSTM yang lebih kompleks dan terbukti menghasilkan prediksi yang lebih stabil dengan MAE lebih rendah, tetapi penelitian ini juga berfokus pada horizon harian.

Berdasarkan temuan tersebut, penelitian ini mengusulkan pendekatan multi-horizon (jangka pendek dan jangka panjang) untuk memberikan kontribusi baru dalam analisis prediksi cryptocurrency.

2.2.3 Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) adalah jenis jaringan saraf tiruan (artificial neural network) yang termasuk dalam arsitektur Recurrent Neural Network (RNN). LSTM dirancang secara khusus untuk mengatasi permasalahan vanishing gradient yang sering terjadi pada RNN konvensional, terutama saat mempelajari ketergantungan jangka panjang dalam data deret waktu (*time series*) [18].

Berbeda dengan RNN biasa yang hanya memiliki struktur sel tunggal yang terus diperbarui seiring waktu, LSTM memiliki memori internal yang disebut cell state dan tiga gerbang utama: forget gate, input gate, dan output gate. Ketiga komponen ini memungkinkan LSTM untuk mempertahankan informasi penting dalam jangka panjang dan mengabaikan informasi yang tidak relevan [19].

Secara matematis, LSTM memproses informasi melalui beberapa gerbang utama, dengan persamaan sebagai berikut:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (\text{Forget gate}) \quad (2.1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (\text{Input gate}) \quad (2.2)$$

$$\bar{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (\text{Candidate cell state}) \quad (2.3)$$

$$C_t = f_t * C_{t-1} + i_t * \bar{C}_t \quad (\text{Cell state update}) \quad (2.4)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (\text{Output gate}) \quad (2.5)$$

$$h_t = o_t * \tanh(C_t) \quad (\text{Hidden state}) \quad (2.6)$$

Di mana:

x_t adalah input pada waktu t

h_{t-1} adalah *hidden state* dari waktu sebelumnya

C_t adalah *cell state*


σ adalah fungsi aktivasi sigmoid

\tanh adalah fungsi aktivasi tanh

W dan b adalah bobot dan bias pada masing-masing gerbang

Dengan struktur ini, LSTM memiliki keunggulan dalam menjaga dan memanipulasi informasi penting selama periode waktu yang panjang.





Legend: Layer Componentwise Copy Concatenate

↕
↳

Gambar 2.1 *Architecture LSTM*

Penelitian menunjukkan bahwa LSTM efektif digunakan untuk prediksi jangka pendek, dengan error prediksi Bitcoin dan Ethereum relatif kecil (RMSE 0.0032 dan 0.0041). Namun penelitian ini hanya terbatas pada horizon jangka pendek, sehingga kurang relevan untuk strategi investasi jangka panjang[2].

Model	Karakteristik Utama	Kelebihan	Kekurangan	Contoh Penggunaan	Referensi
LSTM (Long Short-Term Memory)	Menambahkan cell state dan tiga gerbang (forget, input, output) untuk	Mampu menangkap pola jangka pendek & panjang; lebih stabil	Lebih kompleks dan membutuhkan waktu	Prediksi harga sederhana, teks berurutan.	(Gunarto et al., 2023)

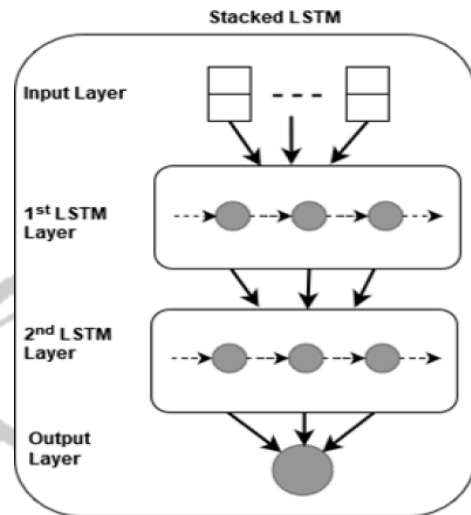
	mengontrol aliran informasi.	dibanding RNN standar.	komputasi lebih lama.		
Stacked LSTM	Beberapa lapisan LSTM ditumpuk (deep architecture).	Menangkap pola kompleks lebih baik, akurasi & stabilitas lebih tinggi.	Lebih lama dilatih, risiko overfitting jika data sedikit.	Prediksi harga kripto, saham, iklim.	Putra (2025)
Bi-LSTM (Bidirectional LSTM)	Memproses data dari dua arah: forward dan backward.	Memanfaatkan informasi masa lalu dan masa depan secara bersamaan; sangat baik untuk NLP.	Kurang relevan untuk prediksi harga kripto/saham karena masa depan tidak diketahui.	NLP, speech recognition, analisis teks.	(Qureshi et al., 2025)
Peephole LSTM	Cell state langsung terhubung dengan gates.	Lebih presisi dalam menangkap ketergantungan waktu.	Lebih kompleks, butuh komputasi lebih tinggi.	Prediksi cuaca, sinyal biologis.	Goodfellow et al. (2016)
Coupled LSTM	Input gate & forget gate digabung.	Lebih sederhana, lebih efisien dibanding LSTM standar.	Kurang fleksibel dalam pengaturan memori.	Aplikasi real-time dengan keterbatasan komputasi.	Goodfellow et al. (2016)
Residual LSTM	Menambahkan <i>residual connection</i> antar layer.	Mengurangi vanishing gradient, lebih stabil pada jaringan dalam.	Implementasi lebih rumit, butuh tuning ekstra.	Deep LSTM untuk prediksi kompleks.	Goodfellow et al. (2016)
ConvLSTM	Menggabungkan CNN & LSTM (untuk data	Cocok untuk data dengan pola spasial	Butuh data besar & GPU	Prediksi cuaca, video, citra medis.	Kang et al. (2022)

	spasial-temporal).	& temporal sekaligus.	kuat, lebih berat dilatih.		
Attention LSTM	Mengintegrasikan mekanisme <i>attention</i> agar fokus pada bagian penting dalam sekuensial.	Meningkatkan interpretabilitas & akurasi pada data panjang.	Lebih kompleks, pelatihan lebih berat dibanding LSTM biasa.	NLP, machine translation, analisis sentimen.	Goldberg (2016)
Hybrid LSTM	LSTM digabung dengan model lain (CNN-LSTM, GRU-LSTM, Transformer-LSTM).	Fleksibel, mampu menangani data dengan variasi karakteristik.	Sangat kompleks, tuning sulit, butuh sumber daya besar.	Prediksi harga kompleks, multimodal data.	Kang et al. (2022)

Tabel 2. 2 Perbandingan LSTM dan Turunan LSTM

Berdasarkan Tabel 2.2 Perbandingan LSTM dan Turunannya, dapat dilihat bahwa setiap varian LSTM memiliki karakteristik, kelebihan, dan kekurangan yang berbeda sesuai dengan kebutuhan prediksi. LSTM (Long Short-Term Memory) memiliki mekanisme *cell state* dan tiga gerbang utama yang membuatnya mampu menangkap pola jangka pendek maupun panjang, meskipun membutuhkan waktu komputasi lebih lama [2].

Stacked LSTM menumpuk beberapa lapisan LSTM untuk membangun arsitektur yang lebih dalam, sehingga lebih akurat dalam menangkap pola kompleks, meskipun berisiko *overfitting* jika data yang digunakan terbatas [5]. Bidirectional LSTM (Bi-LSTM) memproses data dua arah sehingga unggul dalam pemrosesan bahasa alami, tetapi kurang relevan untuk prediksi harga kripto atau saham karena masa depan tidak tersedia [4].



Gambar 2.2 *Architecture Stacked LSTM [20]*

Penelitian ini menggunakan Stacked LSTM karena arsitektur berlapisnya mampu menangkap pola jangka pendek dan panjang secara lebih efektif dibandingkan LSTM tunggal. Hal ini penting mengingat harga cryptocurrency sangat fluktuatif dan bersifat non-linear. Dengan menumpuk beberapa lapisan, Stacked LSTM dapat mengekstraksi representasi data pada tingkat kedalaman yang berbeda, sehingga lebih mampu mengenali dinamika pasar [6].

Hasil penelitian terdahulu juga menunjukkan bahwa Stacked LSTM menghasilkan prediksi yang lebih akurat dengan nilai *Mean Absolute Error (MAE)* lebih rendah dibandingkan LSTM standar, khususnya pada prediksi jangka pendek. Dibandingkan varian lain seperti Bi-LSTM yang mengandalkan informasi dua arah, Stacked LSTM lebih relevan untuk prediksi harga aset keuangan karena hanya menggunakan data historis tanpa memerlukan informasi dari masa depan [4].

Dengan keunggulan tersebut, Stacked LSTM dipilih karena dinilai paling sesuai untuk menghasilkan prediksi arah harga Bitcoin dan Ethereum yang lebih stabil dan akurat dan bermanfaat dalam mendukung pengambilan keputusan investasi di pasar kripto.

Berbeda dengan itu, penelitian Putra membuktikan bahwa Stacked LSTM mampu memberikan hasil lebih stabil, dengan MAE lebih rendah baik dalam horizon jangka pendek maupun jangka panjang. Hal ini memperlihatkan bahwa arsitektur berlapis lebih unggul untuk memodelkan volatilitas kripto dalam dua cakupan waktu sekaligus[5].

2.2.5 Persentase Perubahan Harga

Persentase perubahan harga (price percentage change) mengukur seberapa besar harga suatu aset mengalami kenaikan atau penurunan relatif terhadap nilai sebelumnya dalam bentuk persentase. Pendekatan ini digunakan untuk menormalkan data harga sehingga lebih representatif dalam menunjukkan arah pergerakan pasar dibandingkan menggunakan nilai absolut. Teknik ini sangat penting dalam preprocessing data untuk model prediksi harga, terutama pada aset dengan volatilitas tinggi seperti cryptocurrency.

Menurut Maliki, Cholissodin, dan Yudistira (2022), penambahan fitur perubahan harga dalam persen pada model prediksi harga Bitcoin dapat membantu mengurangi tingkat error dan meningkatkan akurasi prediksi. Hal ini karena volatilitas harga cryptocurrency yang tinggi menyebabkan perubahan harga yang cepat dan signifikan, sehingga penggunaan persentase perubahan harga memungkinkan model untuk lebih sensitif terhadap dinamika pasar. Dengan demikian, persentase perubahan harga menjadi variabel penting dalam analisis dan prediksi harga aset kripto [17].

2.2.6 Hasil dan Evaluasi Model

Hasil eksperimen menunjukkan bahwa model Stacked LSTM mampu menangkap pola kompleks dalam data time series harga cryptocurrency dengan baik. Sebagai contoh, Gunarto et al. (2023) melaporkan bahwa LSTM memiliki performa lebih baik dibandingkan RNN dengan nilai RMSE sebesar 0,061 untuk Bitcoin dan 0,036 untuk Ethereum, serta MAPE yang lebih rendah, menandakan prediksi yang lebih akurat. Selain itu, Putra (2025) menemukan bahwa model Stacked LSTM memberikan hasil prediksi yang lebih stabil dan memiliki Mean Absolute Error (MAE) yang lebih rendah dibandingkan LSTM tunggal, khususnya dalam memprediksi fluktuasi harga jangka pendek [5].

Lebih lanjut, penelitian Putra (2025) yang menggunakan dataset dari Januari 2019 hingga Januari 2024 menunjukkan bahwa model LSTM dapat memprediksi harga Bitcoin, Ethereum, dan Binance Coin (BNB) dengan tingkat kesalahan yang rendah, yakni MAPE masing-masing sebesar 3,94%, 3,09%, dan 2,17%, yang termasuk

kategori sangat akurat. Hal ini menegaskan bahwa metode LSTM, termasuk varian Stacked LSTM, sangat efektif untuk memodelkan volatilitas tinggi pada pasar cryptocurrency [5].

Untuk mengukur akurasi model secara objektif, evaluasi dilakukan dengan membandingkan hasil prediksi terhadap data aktual. Pemilihan metrik evaluasi dalam penelitian ini didasarkan pada prinsip fundamental *deep learning*. Merujuk pada Goodfellow et al. (2016), evaluasi kinerja model regresi harus berfokus pada pengukuran kuantitatif kesalahan prediksi serta kemampuan model dalam melakukan generalisasi terhadap data baru[19]. Berdasarkan landasan tersebut, digunakan tiga metrik statistik utama:

Mean Absolute Error (MAE)

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (2.10)$$

R-squared (R²)

$$R^2 = 1 - \frac{\sum_{n=1}^n (y_t - \hat{y}_t)^2}{\sum_{n=1}^n (y_t - \bar{y}_t)^2} \quad (2.11)$$

Root Mean Squared Error (RMSE)

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (2.12)$$

Secara keseluruhan, temuan ini mengindikasikan bahwa pendekatan Stacked LSTM sangat potensial dalam membantu investor