

**TESIS**  
**PREDIKSI HARGA BITCOIN MENGGUNAKAN MODEL**  
**HIBRIDA TRANSFORMER DAN LONG SHORT-TERM**  
**MEMORY**



disusun oleh

**Rio Irawan**

**23.51.2491**

**Konsentrasi : Digital Transformation Intelligence**

**FAKULTAS ILMU KOMPUTER**  
**UNIVERSITAS AMIKOM YOGYAKARTA**  
**YOGYAKARTA**  
**2025**

**TESIS**  
**PREDIKSI HARGA BITCOIN MENGGUNAKAN MODEL**  
**HIBRIDA TRANSFORMER DAN LONG SHORT-TERM**  
**MEMORY**

**BITCOIN PRICE PREDICTION USING A HYBRID**  
**TRANSFORMER AND LONG SHORT-TERM MEMORY**  
**MODEL**

Diajukan untuk memenuhi salah satu syarat mencapai derajat Pascasarjana  
Program Studi S2 Informatika



disusun oleh

**Rlo Irawan**

**23.51.2491**

**Konsentrasi : Digital Transformation Intelligence**

**FAKULTAS ILMU KOMPUTER**  
**UNIVERSITAS AMIKOM YOGYAKARTA**  
**YOGYAKARTA**

**2025**

**HALAMAN PERSETUJUAN**

**PREDIKSI HARGA BITCOIN MENGGUNAKAN MODEL HIBRIDA  
TRANSFORMER DAN LONG SHORT-TERM MEMORY**

**BITCOIN PRICE PREDICTION USING A HYBRID TRANSFORMER  
AND LONG SHORT-TERM MEMORY MODEL**

yang disusun dan diajukan oleh

**Rlo Irawan**

**23.51.2491**

telah disetujui oleh Dosen Pembimbing Tesis  
pada hari Rabu, 1 Oktober 2025

Dosen Pembimbing,

  
Prof. Dr. Ema Uharti, S.Si., M.Kom.  
NIK: 190302037

**HALAMAN PENGESAHAN**

**PREDIKSI HARGA BITCOIN MENGGUNAKAN MODEL HIBRIDA  
TRANSFORMER DAN LONG SHORT-TERM MEMORY**

**BITCOIN PRICE PREDICTION USING A HYBRID TRANSFORMER  
AND LONG SHORT-TERM MEMORY MODEL**

yang disusun dan diajukan oleh

**Rio Irawan**

**23.51.2491**

Telah dipertahankan di depan Dewan Penguji  
pada tanggal 1 Oktober 2025

**Susunan Dewan Penguji**

**Nama Penguji**

**Tanda Tangan**

**Dr. Andi Sunvoto, M.Kom.**  
**NIK. 190302052**

**Hanif Al Fatta, S.Kom., M.Kom., Ph.D**  
**NIK. 190302096**

**Prof. Dr. Ema Utami, S.Si., M.Kom.**  
**NIK. 190302037**

Tesis ini telah diterima sebagai salah satu persyaratan  
untuk memperoleh gelar Magister Komputer  
Tanggal 1 Oktober 2025

**DEKAN FAKULTAS ILMU KOMPUTER**



**Prof. Dr. Kusriani, M.Kom.**  
**NIK. 190302106**

## HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : Rio Irawan  
NIM : 23.51.2491

Menyatakan bahwa Tesis dengan judul berikut:

### **PREDIKSI HARGA BITCOIN MENGGUNAKAN MODEL HIBRIDA TRANSFORMER DAN LONG SHORT-TERM MEMORY**

Dosen Pembimbing : Prof. Dr. Ema Utami, S.Si., M.Kom.

1. Karya tulis ini adalah benar-benar **ASLI** dan **BELUM PERNAH** diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya.
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian **SAYA** sendiri, tanpa bantuan pihak lain kecuali arahan dari Dosen Pembimbing.
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini.
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab **SAYA**, bukan tanggung jawab Universitas AMIKOM Yogyakarta.
5. Pernyataan ini **SAYA** buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka **SAYA** bersedia menerima **SANKSI AKADEMIK** dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi.

Yogyakarta, 1 Oktober 2025

Yang Menyatakan,



Rio Irawan

## HALAMAN PERSEMBAHAN

Pertama dan paling utama, saya ucapkan puji syukur kepada Allah SWT yang telah memberikan kemudahan dan kelancaran dalam proses pembuatan tesis ini. Tesis ini saya persembahkan untuk:


1. Orang tua saya Bpk. Suranto, Ibu Kasiyem yang tidak pernah lelah memberikan doa, dukungan, kasih sayang, dan semangat dalam setiap langkah hidup saya. Terima kasih atas segala pengorbanan dan cinta yang tak ternilai.
2. Ibu Prof. Dr. Ema Utami, S. Si., m. Kom yang memberikan bimbingan aktif selama pelaksanaan penelitian, semoga mendapatkan banyak keberkahan dan dilancarkan segala urusannya.
3. Teman-teman seperjuangan, yang telah menjadi bagian

## MOTTO

ولا تمش في الأرض مرحاً لئن تخرق الأرض لئن تبلى الجبال طولا

“Sesungguhnya engkau tidak akan dapat menembus bumi dan tidak akan mampu menjulang setinggi gunung.”

(QS. Al-Isra' : 37)



## KATA PENGANTAR

Puji syukur penulis panjatkan ke hadirat Allah SWT atas segala rahmat dan kemudahan yang diberikan hingga tesis ini dengan judul “Prediksi Harga Bitcoin Menggunakan Model Hibrida Transformer dan Long Short-Term Memory” dapat terselesaikan. Penelitian ini menjadi perjalanan belajar yang penuh tantangan, kesabaran, dan pembelajaran baru tentang ketekunan serta makna proses. Penulis menyampaikan terima kasih yang tulus kepada Ibu Prof. Dr. Ema Utami, S.Si., M.Kom. selaku dosen pembimbing utama atas bimbingan, arahan, dan kesabarannya selama penelitian ini berlangsung. Ucapan terima kasih juga penulis sampaikan kepada seluruh dosen dan staf Program Pascasarjana Universitas AMIKOM Yogyakarta atas ilmu dan dukungan yang telah diberikan.

Rasa terima kasih yang terdalam penulis persembahkan kepada kedua orang tua tercinta, Bapak Suranto dan Ibu Kasiyem, atas doa, kasih sayang, dan pengorbanan yang menjadi sumber semangat dalam setiap langkah. Terima kasih juga kepada teman-teman seperjuangan yang senantiasa memberi dukungan dan semangat selama proses penyusunan tesis ini. Penulis menyadari bahwa karya ini masih jauh dari sempurna. Semoga penelitian ini dapat memberikan manfaat dan menjadi bagian kecil dari upaya pengembangan ilmu pengetahuan di bidang teknologi dan pembelajaran mesin.

Yogyakarta, 1 Oktober 2025




Rio irawan

## DAFTAR ISI

HALAMAN JUDUL.....	i
Halaman persetujuan.....	ii
halaman pengesahan.....	iii
halaman pernyataan keaslian penelitian.....	iv
HALAMAN PERSEMBAHAN .....	v
MOTTO .....	vi
KATA PENGANTAR .....	vii
DAFTAR ISI.....	viii
DAFTAR TABEL .....	xi
DAFTAR GAMBAR .....	xii
INTISARI.....	xiii
<i>ABSTRACT</i> .....	xiv
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang Masalah .....	1
1.2. Rumusan Masalah.....	6
1.3. Batasan Masalah .....	6
1.4. Tujuan Penelitian .....	7
1.5. Manfaat Penelitian .....	7
BAB II TINJAUAN PUSTAKA.....	9
2.1. Tinjauan Pustaka .....	9


2.2. Keaslian Penelitian.....	15
2.3. Landasan Teori.....	23
2.3.1. Bitcoin.....	23
2.3.2. <i>Machine Learning</i> .....	23
2.3.3. Deep Learning.....	25
2.3.4. <i>Long Short Term Memory</i> .....	26
2.3.5. <i>Transformer</i> .....	27
2.3.6. <i>Time series forecasting</i> .....	32
2.3.7. Evaluation matrix.....	33
<b>BAB III METODE PENELITIAN</b> .....	<b>35</b>
3.1. Jenis, Sifat, dan Pendekatan Penelitian.....	35
3.2. Metode Pengumpulan Data.....	35
3.3. Metode Analisis Data.....	36
3.4. Alur Penelitian.....	37
3.5. Skenario.....	48
<b>BAB IV HASIL PENELITIAN DAN PEMBAHASAN</b> .....	<b>50</b>
4.1. Pendahuluan.....	50
4.2. Konfigurasi parameter.....	50
4.3. Hasil Pengujian.....	53
4.3.1 Hasil Pengujian Skenario 1 (LSTM).....	53
4.3.2 Skenario 2: LSTM-Transformer.....	54
4.4. Visualisasi Hasil.....	55

4.5 Analisis hasil dan Perbandingan.....	64
4.6 Pembahasan .....	67
<b>BAB V PENUTUP.....</b>	<b>71</b>
5.1. Kesimpulan .....	71
5.2. Saran .....	72
<b>DAFTAR PUSTAKA.....</b>	<b>74</b>



## DAFTAR TABEL

Tabel 2.1 prediksi harga bitcoin menggunakan model hibrida Transformer - Long Short Term Memory .....	15
Tabel 3.1 Konfigurasi Skenario Pengujian Model.....	48
Tabel 4.1 Konfigurasi Parameter Penelitian .....	52
Tabel 4.2 Hasil Pengujian Skenario 1 LSTM.....	53
Tabel 4.3 Hasil Pengujian Skenario 2 (LSTM-Transformer).....	54
Tabel 4. 4 Perbandingan Hasil dengan Penelitian Terdahulu .....	65



## DAFTAR GAMBAR

Gambar 2.1	Arsitektur LSTM.....	27
Gambar 2.2	Arsitektur Transformer model.....	28
Gambar 3.1	Alur Penelitian.....	38
Gambar 3.2	Dataset BTC.....	40
Gambar 3.3	Arsitektur model.....	46
Gambar 4.1	Visualisasi Pembagian Dataset Latih dan Uji.....	51
Gambar 4.2	grafik loss LSTM batch size 32.....	56
Gambar 4.3	grafik loss LSTM batch size 64.....	56
Gambar 4.4	grafik loss LSTM batch size 128.....	57
Gambar 4.5	grafik prediksi LSTM batch size 32.....	58
Gambar 4.6	grafik prediksi LSTM batch size 64.....	58
Gambar 4.7	grafik prediksi LSTM batch size 128.....	59
Gambar 4.8	grafik loss LSTM-transformer batch size 32.....	60
Gambar 4.9	Grafik loss LSTM-transformer batch size 64.....	61
Gambar 4.10	grafik loss LSTM-transformer batch size 128.....	62
Gambar 4.11	Grafik prediksi LSTM-transformer batch size 32.....	62
Gambar 4.12	grafik prediksi LSTM-transformer batch size 64.....	63
Gambar 4.13	Grafik prediksi LSTM-transformer batch size 128.....	64

## INTISARI

Peramalan harga Bitcoin merupakan tantangan signifikan akibat fluktuasi pasar yang tinggi, di mana model deret waktu konvensional seringkali gagal menangkap dependensi data jangka pendek dan panjang secara bersamaan. Untuk mengatasi masalah tersebut, penelitian ini bertujuan mengembangkan dan mengevaluasi model deep learning hibrida guna meningkatkan presisi peramalan harga Bitcoin. Model yang diusulkan mengintegrasikan arsitektur Long Short-Term Memory (LSTM), yang andal dalam memproses data sekuensial, dengan mekanisme atensi pada Transformer yang mampu mengidentifikasi hubungan data yang relevan.

Metode penelitian mencakup penggunaan data harga historis Bitcoin yang telah melalui tahap pra-pemrosesan dan normalisasi. Arsitektur model terdiri dari dua lapisan LSTM (30 unit), diikuti oleh lapisan Transformer dengan Multi-Head Attention (satu head, dimensi kunci empat), dan diakhiri dengan lapisan Global Average Pooling. Pelatihan model dilakukan menggunakan konfigurasi optimal selama 10 epoch dengan ukuran batch 128. Hasil evaluasi menunjukkan kinerja prediksi yang sangat akurat, dibuktikan dengan nilai Mean Absolute Percentage Error (MAPE) sebesar 0.000594 dan R-squared ( $R^2$ ) 0.999967. Temuan ini menegaskan bahwa pendekatan hibrida efektif dalam menangkap pola kompleks pada data harga Bitcoin, sehingga menawarkan alat yang lebih kuat untuk analisis keuangan di pasar cryptocurrency.

Kata kunci: Deep Learning, LSTM, Model Hibrida, Peramalan Harga Bitcoin, Transformer.

## ABSTRACT

Forecasting Bitcoin prices is a significant challenge due to high market volatility, where conventional time series models often fail to capture both short-term and long-term data dependencies. To address this issue, this study aims to develop and evaluate a hybrid deep learning model to improve the precision of Bitcoin price forecasting. The proposed model integrates the Long Short-Term Memory (LSTM) architecture, which excels at processing sequential data, with the attention mechanism of the Transformer, capable of identifying relevant data relationships. The methodology involves using historical Bitcoin price data that was preprocessed and normalized. The model architecture consists of two LSTM layers (30 units), a Transformer layer with Multi-Head Attention (one head, a key dimension of four), and a Global Average Pooling layer. The model was trained using an optimal configuration of 10 epochs and a batch size of 128. The evaluation results demonstrate highly accurate predictive performance, evidenced by a Mean Absolute Percentage Error (MAPE) of 0.000594 and an R-squared ( $R^2$ ) score of 0.999967. These findings confirm that the hybrid approach effectively captures complex patterns in Bitcoin price data, offering a more robust tool for financial analysis in the cryptocurrency market.

**Keyword:** Bitcoin Price Forecasting, Deep Learning, Hybrid Model, LSTM, Transformer

# BAB I

## PENDAHULUAN

### 1.1. Latar Belakang Masalah

Bitcoin merupakan mata uang digital yang dibuat melalui rangkaian code yang disebut dengan blockchain [1] bitcoin telah merevolusi dunia keuangan dengan menghadirkan transparansi dan konsep desentralisasi[2] yang dimana itu adalah kelebihan dibanding dengan mata uang konvensional karena dianggap lebih baik.

Bitcoin telah menjadi instrumen investasi yang sangat diminati saat ini. Hal ini terbukti dari data terbaru dari Badan Pengawas Perdagangan Berjangka Komoditi (Bappebti) yang menunjukkan peningkatan signifikan dalam jumlah investor kripto di Indonesia. Per April 2024, jumlah investor kripto di Indonesia telah mencapai lebih dari 20 juta orang. Angka ini menunjukkan peningkatan yang luar biasa, yakni 8 kali lipat dibandingkan dengan data pada Maret 2021 yang hanya tercatat 4,45 juta investor. Lonjakan jumlah investor kripto ini mengindikasikan bahwa aset kripto semakin diterima dan diminati oleh masyarakat Indonesia sebagai instrumen investasi yang menjanjikan.

Peramalan harga cryptocurrency menjadi menarik untuk diteliti, mengingat tingkat fluktuasi dan peminatnya yang tinggi. Namun, peramalan harga cryptocurrency umumnya rentan terhadap kesalahan yang besar karena sifat non-linier dan non-stasioner dari seri harga Bitcoin yang berfrekuensi tinggi. Karakteristik data harga cryptocurrency yang kompleks ini membuat prediksi

menjadi tantangan tersendiri. Volatilitas yang tinggi, pengaruh faktor-faktor eksternal, dan pola pergerakan harga yang tidak mudah diprediksi secara konvensional menjadi isu-isu utama yang harus dihadapi dalam melakukan peramalan.

Salah satu isu dalam melakukan peramalan harga cryptocurrency adalah karena sifat non-linier dan non-stasioner dari data harga yang menyebabkan kesulitan dalam melakukan peramalan, sejumlah besar penelitian berkonsentrasi pada elemen-elemen yang membentuk atau mempengaruhi harga. Secara khusus, banyak peneliti yang mencoba memprediksi harga Bitcoin dengan menggunakan pendekatan machine learning dan deep learning [3].

Salah satu deep learning yang digunakan adalah pemodelan LSTM seperti yang digunakan dalam penelitian [4] yang bertujuan untuk menemukan subset fitur internal Bitcoin yang paling optimal untuk prediksi harga bitcoin. Secara khusus, algoritma deep learning telah digunakan secara luas di berbagai sektor seperti manufaktur [5],[6], keuangan[7],[8], kedokteran, lingkungan maupun pertanian.

[1] Melakukan penelitian menggunakan metode LSTM untuk membangun pemodelan prediksi harga koin doge dengan menggunakan data time series. melakukan pengujian dengan Epoch masing-masing 1, 10, dan 20 pada tiap sesi. Hasil akhir pengujian menunjukkan performa prediksi terbaik terjadi pada saat melakukan pengujian terhadap jenis koin DOGE dengan jumlah Epoch 20 yang mendapatkan nilai RMSE sebesar 0,0630 namun dalam jenis koin BTC hasil RMSE masih cukup besar yaitu dengan epoch 1 2863 epoch 10 1991 epoch 20 2963.

[9] juga melakukan penelitian peramalan bitcoin menggunakan deep learning LSTM, di sini peneliti melakukan pengujian dengan 4 model dan diukur menggunakan RMSE dengan hasil model pertama Naïve model 351.7594, Drift model 344.8232, single feature LSTM 122.333 dan model terakhir Multi feature LSTM dengan hasil kesalahan paling rendah 90.136. Penelitian ini juga masih menghasilkan nilai RMSE yang cukup besar dan hanya menggunakan 1 model pembelajaran mesin.

Penelitian lain yang menggunakan algoritma LSTM adalah penelitian yang dilakukan oleh [10] Penelitian ini akan melakukan 2 percobaan menggunakan metode LSTM sederhana dan memanfaatkan multivariate time series dengan LSTM. Hasilnya diperoleh nilai terkecil prediksi menggunakan skenario pembagian alokasi data 80/20, inputan layer LSTM 360, Epoch 500 yang dilakukan yaitu koin Solana dengan RMSE 0.111, R2 0.9962. Akan tetapi kelemahan penelitian ini adalah hanya menggunakan 1 model pembelajaran mesin yaitu LSTM dan menggunakan jenis koin dengan harga yang relatif murah bukan menggunakan jenis koin dengan harga yang cukup tinggi seperti BTC.

Algoritma LSTM telah banyak digunakan untuk memprediksi pergerakan harga Cryptocurrency dan belum banyak algoritma hibrida yang dilakukan untuk prediksi harga bitcoin, selain menggunakan algoritma LSTM ada beberapa penelitian yang memanfaatkan penggunaan analisis transformasi wavelet. seperti yang dilakukan [11] menggunakan Transformasi wavelet untuk mengekstrak fitur dari dataset yang tersedia, kemudian diberikan ke jaringan Bi-LSTM untuk memprediksi koefisien transformasi wavelet untuk 16 hari ke depan. Transformasi

wavelet terbalik digunakan untuk mendapatkan harga cryptocurrency untuk 16 hari ke depan. Skema yang diusulkan menghasilkan Mean Square Error (MSE) 0.000000000001, Mean Absolute Error (MAE) 0.00000094 dan Root Mean Square Error (RMSE) 0.00000097.

Oleh karena itu, penelitian ini mengusulkan penggunaan model hibrida Transformer dan Long Short-Term Memory (LSTM) untuk prediksi harga Bitcoin. Alasan pemilihan model ini didasarkan pada keunggulan Transformer dalam menangkap hubungan temporal jangka panjang secara efektif serta kemampuan LSTM dalam memproses data sekuensial dengan memperhatikan pola waktu. Hingga saat ini, masih minim penelitian yang menggabungkan kedua algoritma ini dalam prediksi harga Bitcoin, sehingga penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam memperluas literatur serta menawarkan solusi yang lebih akurat untuk masalah prediksi harga Bitcoin.

Pendekatan hibrida yang menggabungkan kekuatan dari kedua arsitektur ini telah terbukti efektif dalam literatur terkini. LSTM unggul dalam menangkap dependensi jangka panjang dan pola dari data historis, sementara Transformer, dengan mekanisme

self-attention, mampu mengekstrak pola kompleks dan menyoroti fitur-fitur penting serta hubungan temporal dalam data. Penelitian oleh [12] menunjukkan bahwa penggabungan LSTM dan Transformer dalam satu model memungkinkan penangkapan konteks sekuensial yang robas dari LSTM, yang kemudian outputnya diproses oleh Transformer untuk mengidentifikasi hubungan antar fitur secara lebih mendalam. Model hibrida semacam ini secara efektif menangani kerumitan dan

volatilitas yang khas pada data deret waktu keuangan. Dengan demikian, sinergi antara kemampuan LSTM dalam memproses urutan dan kemampuan Transformer dalam memahami konteks global menjadi landasan kuat untuk pengembangan model prediksi yang lebih superior.

Oleh karena itu, penelitian ini mengusulkan penggunaan model hibrida Transformer dan Long Short-Term Memory (LSTM) untuk prediksi harga Bitcoin. Berdasarkan tinjauan terhadap penelitian-penelitian terkini, ditemukan bahwa pendekatan hibrida seringkali menunjukkan keunggulan dibandingkan model tunggal. Sebagai contoh, penelitian yang dilakukan oleh [13] menggunakan model hibrida CNN-LSTM dan menyoroti pentingnya membandingkan kinerja model hibrida dengan arsitektur tunggal serta menganalisis faktor-faktor yang memengaruhi akurasi prediksi. Mengacu pada kerangka berpikir tersebut, penelitian ini merumuskan beberapa pertanyaan kunci untuk mengevaluasi secara komprehensif efektivitas model hibrida Transformer-LSTM. Dengan demikian, rumusan masalah dalam penelitian ini adalah sebagai berikut:"

Penelitian ini akan membahas penggunaan algoritma hibrida Long Short Term Memory dengan algoritma Transformer untuk membangun model prediksi harga bitcoin. Tujuan dari penelitian ini adalah untuk mengetahui tingkat keakuratan model yang dibangun sehingga investor atau trader dapat mempertimbangkannya saat membuat keputusan investasi.

## 1.2. Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, perumusan masalah dalam penelitian ini adalah sebagai berikut:

- a. Bagaimana kinerja model hibrida yang menggabungkan arsitektur Transformer dan LSTM dalam memprediksi harga Bitcoin dibandingkan dengan model deep learning tunggal seperti LSTM atau CNN-LSTM?
- b. Sejauh mana model hibrida Transformer-LSTM mampu mengatasi permasalahan volatilitas dan non-linearitas data harga Bitcoin dibandingkan metode prediksi tradisional atau model deep learning lain?

## 1.3. Batasan Masalah

Selain perumusan masalah yang telah disebutkan, perlu ditetapkan pembatasan masalah agar pembahasan nantinya tidak meluas dan tetap fokus pada tujuan awal penelitian:

- a. Metode yang digunakan dalam prediksi harga bitcoin hanya menggunakan hibrida Transformer dan Long Short Term Memory.
- b. Dataset yang di gunakan hanya berupa data historis permenit BTC\_USD selama 2 tahun terakhir.
- c. Dataset bitcoin didapatkan dari Kaggle
- d. Pengujian evaluasi model prediksi menggunakan metode evaluation matrix MAPE dan R<sup>2</sup>
- e. Target penelitian ini berfokus pada evaluasi arsitektur model, bukan optimisasi untuk mencapai tingkat akurasi tertinggi.

- f. Target penelitian ini hanya berupa uji akurasi modelling dengan python dan tidak ke tahap pembuatan implementasi aplikasi.

#### **1.4. Tujuan Penelitian**

Berdasarkan latar belakang yang telah disebutkan tujuan dalam pembuatan penelitian ini adalah:


- a. Menganalisis keterbatasan performa model Long Short-Term Memory (LSTM) standar dalam menangkap pola kompleks pada data deret waktu harga Bitcoin yang memiliki volatilitas tinggi dengan granularitas per menit.
- b. Membangun dan mengevaluasi sebuah arsitektur model hibrida paralel yang mengintegrasikan kekuatan pemrosesan sekuensial dari LSTM dengan kemampuan pemrosesan kontekstual dari arsitektur Transformer.
- c. Membuktikan secara kuantitatif bahwa sinergi antara LSTM dan Transformer dalam model hibrida yang diusulkan mampu menghasilkan prediksi yang lebih akurat dan stabil secara signifikan, jika dibandingkan dengan model LSTM standar sebagai baseline serta hasil dari penelitian relevan sebelumnya.

#### **1.5. Manfaat Penelitian**

Bagian ini memuat penjelasan tentang:

- a. Memberikan kontribusi penelitian pada penerapan metode hibrida Transformer dan Long Short Term Memory
- b. Hasil rancangan model dapat digunakan untuk mengetahui prediksi harga bitcoin secara lebih akurat

- c. Dapat dijadikan sebagai referensi untuk penelitian selanjutnya dalam pengembangan prediksi harga bitcoin.



## **BAB II**

### **TINJAUAN PUSTAKA**

#### **2.1. Tinjauan Pustaka**

Dalam penelitian ini, penulis melakukan tinjauan pustaka untuk mencari informasi dari penelitian-penelitian sebelumnya. Tujuannya adalah sebagai bahan perbandingan, baik mengenai kekurangan maupun kelebihan dari penelitian yang sudah ada. Tinjauan pustaka juga dilakukan untuk mengkaji keterkaitan antara penelitian terdahulu dengan penelitian yang penulis lakukan, serta untuk menghindari terjadinya duplikasi. Oleh karena itu, penelitian sebelumnya yang sudah dilakukan menjadi sangat penting bagi penulis.

Selain itu, tinjauan pustaka bertujuan untuk menunjukkan bahwa penelitian yang penulis lakukan memiliki manfaat dan arti penting sebagai kontribusi terhadap ilmu pengetahuan. Dalam bagian ini, penulis akan menyajikan beberapa ulasan jurnal tentang penelitian terdahulu yang berkaitan dengan data dan metode yang digunakan sebagai acuan dalam penelitian ini.

Berdasarkan penelitian terdahulu terkait dengan tersedianya dataset historis bitcoin yang dapat diakses oleh publik sehingga penulis tertarik untuk melakukan penelitian terkait tentang ide memprediksi harga bitcoin menggunakan metode hibrida Transformer dan Long Short Term Memory (LSTM). Penulis menggunakan metode yang telah dikaji berdasarkan penelitian sebelumnya tentang penggunaan metode tersebut berikut beberapa kajian tentang penggunaan dengan menerapkan arsitektur Long Short Term Memory dan Transformer.

Pada penelitian yang dilakukan [11] menyatakan bahwa prediksi harga mata uang kripto merupakan salah satu tantangan terbesar bagi sistem prediksi manapun karena volatilitasnya dan ketergantungannya pada banyak faktor. Pada penelitian ini di usulkan penggunaan tranformasi wavelet yang dianggap sebagai metode yang efektif untuk memecah sinyal non stasioner menjadi komponen yang tidak berkorelasi. Penelitian ini berusaha untuk mengambil keuntungan dari wavelet untuk mengekstrak fitur dari kumpulan data yang tersedia dan memprediksi tren harga kripto untuk 16 hari kedepan menggunakan jaringan Bi-LSTM. Dataset dalam penelitian ini diambil dari yahoo.finance.com melalui API yFinance dengan kode python sebagai data utama. Hasil dari penelitian ini diukur menggunakan evaluation matrix dan mendapatkan hasil RMSE sebesar 0.00000097 MSE sebesar 0.000000000001 dan MAE sebesar 0.00000094 yang terbukti lebih unggul dari penelitian sebelumnya yang mendapat nilai MAE sebesar 0.02294 MSE sebesar 0.000196 dan rmse sebesar 0.014.

Penelitian selanjutnya yang dilakukan oleh [10] menyatakan bahwa Cryptocurrency merupakan mata uang virtual yang keamanannya dijamin menggunakan kriptografi dan teknologi distributed ledger. Kehadiran cryptocurrency telah menarik minat para peneliti untuk melakukan penelitian dalam memprediksi harga koin cryptocurrency, mengingat harga crypto yang cenderung tidak stabil. Salah satu faktor yang mempengaruhi harga cryptocurrency adalah meningkatnya volume transaksi. Penelitian sebelumnya telah menggunakan berbagai metode untuk memprediksi harga cryptocurrency, seperti metode LSTM (Long Short-Term Memory). Penggunaan metode, algoritma, dan jumlah data yang

berbeda dapat mempengaruhi hasil prediksi. Dalam penelitian ini, metode LSTM akan digunakan untuk pemodelan prediksi harga cryptocurrency, dengan membandingkan penggunaan LSTM sederhana dan LSTM multivariate time series. Selain itu, penelitian ini akan menggunakan data jangka pendek (short-term data) dalam pemodelan prediksi, karena penggunaan data jangka pendek menarik minat peneliti dengan kemungkinan dapat menghasilkan prediksi yang lebih akurat dibandingkan data jangka panjang. Namun, karakteristik dataset dan metodologi pemodelan yang tepat perlu diperhatikan saat menggunakan data jangka pendek. Hasil terbaik dalam penelitian ini diperoleh dengan menggunakan skenario alokasi data 80/20 dengan input layer LSTM 300 dan 500 epoch Untuk cryptocurrency Solana, pendekatan ini menghasilkan Root Mean Squared Error (RMSE) sebesar 0.111 dan nilai R-squared 0.9962.

Penelitian berikutnya dilakukan oleh [14] menyatakan bahwa Penelitian tentang prediksi harga cryptocurrency menggunakan algoritma Machine Learning (ML) dan Deep Learning (DL) telah banyak dilakukan dalam beberapa tahun terakhir. Hal ini dikarenakan pergerakan harga cryptocurrency yang sangat fluktuatif dan sulit diprediksi, sehingga mendorong para peneliti untuk memanfaatkan teknik-teknik prediksi berbasis pembelajaran mesin. Dalam penelitian ini, algoritma yang digunakan untuk membangun model prediksi adalah Long Short-Term Memory (LSTM), yang merupakan pengembangan dari Recurrent Neural Network (RNN). LSTM didesain untuk mengatasi kelemahan RNN dalam mengelola data time series jangka panjang, seperti data harga cryptocurrency. LSTM dianggap lebih unggul dibandingkan algoritma lain dalam

menangani karakteristik data yang bersifat non-linear dan highly volatile. Hasil penelitian menunjukkan bahwa model prediksi berbasis LSTM dapat memberikan performa prediksi yang cukup baik, dengan nilai RMSE terbaik sebesar 0,0630 pada pengujian untuk jenis koin DOGE dengan 20 epoch. Hal ini membuktikan efektivitas algoritma LSTM dalam memprediksi harga cryptocurrency yang sangat fluktuatif. Penelitian ini memberikan wawasan baru dalam pemanfaatan teknik Machine Learning dan Deep Learning untuk membangun model prediksi harga cryptocurrency yang akurat dan dapat diandalkan oleh para investor.

Penelitian lainnya dilakukan oleh [15] Penelitian ini bertujuan untuk mengidentifikasi subset fitur internal yang menghasilkan tingkat pengembalian tertinggi dalam memprediksi harga Bitcoin. Fitur-fitur internal Bitcoin dikategorikan menjadi empat kelompok: data mata uang, detail blok, informasi penambangan, dan kesulitan jaringan. Selanjutnya, jaringan saraf tiruan long short-term memory (LSTM) digunakan untuk memprediksi harga penutupan Bitcoin hari berikutnya dengan memanfaatkan berbagai kategorisasi subset fitur. Hasil penelitian menunjukkan bahwa laju kesalahan absolut rata-rata adalah 6,38% saat pemodelan dengan kategori fitur detail blok. Peningkatan kinerja ini terutama berasal dari hubungan positif antara harga Bitcoin dan rendahnya ambiguitas subset data ini. Hasil eksperimen menekankan bahwa, dibandingkan dengan subset fitur yang diselidiki, kategorisasi fitur detail blok memberikan prediksi harga Bitcoin paling akurat, yang menjadi landasan bagi penelitian masa depan di bidang ini. Penelitian ini memberikan kontribusi signifikan dengan mengembangkan teknik pemodelan prediktif novel untuk peramalan deret waktu, menggabungkan kerangka

kerja optimasi dan rekursi dalam pengaturan granular. Temuan ini dapat membantu investor dalam membuat keputusan investasi yang lebih baik di pasar Bitcoin yang volatil.

Penelitian lainnya yang menggunakan algoritma LSTM yaitu [16] Investasi saham merupakan salah satu aktivitas investasi yang cukup populer saat ini, namun memiliki risiko tinggi karena fluktuasi harga yang cepat dan sulit diprediksi. Banyak investor yang tidak memahami teknik dan analisis untuk membeli dan menjual saham, sehingga membuat mereka ragu untuk berinvestasi. Oleh karena itu, diperlukan teknik analitik yang dapat menentukan pergerakan harga saham agar dapat melakukan perencanaan, manajemen risiko, dan pengambilan keputusan. Saham perbankan merupakan salah satu sektor saham yang penting dan populer. Hal ini karena industri perbankan terus berkembang dari waktu ke waktu dan keberadaannya akan bertahan lama, serta memiliki posisi strategis untuk mendukung pembangunan ekonomi. Salah satu saham perbankan yang go-public di Bursa Efek Indonesia dengan kenaikan harga yang pesat adalah saham Bank Rakyat Indonesia. Penelitian ini menerapkan Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) untuk menghasilkan model yang dapat memprediksi harga saham Bank Rakyat Indonesia secara akurat. Berdasarkan implementasi, model GRU merupakan model terbaik dengan nilai MSE 4958,9168, RMSE 70,4195, dan MAPE 1,1699%. Model GRU memprediksi akan ada penurunan harga saham pada bulan berikutnya.

Penelitian lainnya yang berkaitan dengan prediksi cryptocurrency yaitu [17] Penelitian ini membandingkan dua algoritma, yaitu ARIMA dan Prophet, dalam

melakukan peramalan harga Bitcoin. Data yang digunakan adalah data historis harga Bitcoin selama dua tahun, dari Februari 2019 hingga 2021. Data tersebut dikelompokkan menjadi tiga kategori interval waktu, yaitu harian, mingguan, dan bulanan. Kedua algoritma dibangun menjadi model univariat yang hanya menerima 2 fitur untuk melatih model. Beberapa model ARIMA dikembangkan untuk setiap interval data. Parameter dari masing-masing model kemudian saling direferensikan untuk mendapatkan kombinasi parameter terbaik. Sementara itu, model Prophet dikembangkan menggunakan tuning otomatis dan manual. Lalu parameter nilai dari masing-masing model juga saling direferensikan untuk mendapatkan kombinasi parameter terbaik. Evaluasi model pelatihan dilakukan dengan menghitung Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), Mean Squared Error (MSE), dan Rooted Mean Squared Error (RMSE). Hasil penelitian menunjukkan bahwa model terbaik untuk kategori data harian dan mingguan adalah algoritma Prophet, sementara untuk kategori data bulanan adalah algoritma ARIMA. Temuan ini berkontribusi pada pemahaman tentang kinerja relatif dua algoritma populer dalam peramalan harga Bitcoin pada berbagai interval data. Hasil ini dapat membantu praktisi dan peneliti dalam memilih algoritma yang tepat untuk tugas peramalan harga cryptocurrency serupa.

## 2.2. Keaslian Penelitian

Tabel 2.1 prediksi harga bitcoin menggunakan model hibrida Transformer - Long Short Term Memory

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
1	Improved LSTM Method for Predicting Cryptocurrency Price Using Short-Term Data	Risna Sari , Kusrini Kusrini , Tonny Hidayat , Theofanis Orphanoudakis  JCCS (Indonesian Journal of Computing and Cybernetics Systems), 2023	Mengembangkan model prediksi harga mata uang kripto menggunakan metode LSTM dan data jangka pendek?	Penelitian ini berhasil menunjukkan bahwa metode LSTM dapat digunakan secara efektif untuk memprediksi harga cryptocurrency menggunakan data jangka pendek. Hasil terbaik diperoleh dengan skenario pembagian data 80/20, input layer LSTM sebanyak 360, dan 500 epoch pelatihan.	peneliti menekankan perlunya perhatian khusus terhadap karakteristik dataset dan metodologi pemodelan yang digunakan. Pemilihan parameter model dan pengolahan data yang tepat menjadi faktor penting dalam menghasilkan prediksi yang akurat.	Menerapkan Arsitektur LSTM pada prediksi harga bitcoin

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				Pada skenario tersebut, prediksi untuk koin Solana menghasilkan nilai RMSE terkecil yaitu 0,111 dan nilai R2 yang tinggi mencapai 0,9962. Hal ini menunjukkan kemampuan prediksi yang sangat baik menggunakan model LSTM dengan data jangka pendek.		
2	Prediksi Harga Cryptocurrency Menggunakan Algoritma Long Short Term Memory (LSTM)	Moch Farryz Rizkilloh , Sri Widiyanesti  Jurnal resti, 2022	Mengembangkan model prediksi harga cryptocurrency menggunakan algoritma LSTM, dengan	Penelitian ini menggunakan algoritma Long Short-Term Memory (LSTM) untuk membangun model prediksi	Secara keseluruhan, penelitian ini sudah cukup baik dalam membangun model prediksi harga cryptocurrency menggunakan	Menggunakan algoritma LSTM untuk memprediksi harga bitcoin

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			tujuan memberikan alat bagi investor untuk mengelola risiko yang terkait dengan pasar cryptocurrency yang fluktuatif.	harga cryptocurrency. LSTM terbukti efektif dalam mengelola data runtun waktu, menghasilkan prediksi terbaik pada koin DOGE dengan RMSE 0,0630. Kesimpulannya, LSTM unggul dibandingkan algoritma lain untuk meramalkan harga cryptocurrency.	LSTM. Namun masih terdapat beberapa aspek yang dapat dikembangkan lebih lanjut untuk meningkatkan akurasi dan kehandalan prediksi	
3	Crypto Trend Prediction Based on Wavelet Transform and Deep	Sumesh Eratt Parameswaran, Vidhyalavanya Ramachandran, Swati Shukla	Memprediksi tren harga cryptocurrency menggunakan kombinasi transformasi	Transformasi wavelet untuk mengekstrak fitur dari dataset yang tersedia, kemudian diberikan ke	Penelitian ini hanya menggunakan satu studi kasus, yaitu kripto SHIB. Menguji model pada beberapa	Melakukan metode wavelet tranform di dalam algoritma LSTM

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
	Learning Algorithm	Procedia computer, 2024	wavelet dan jaringan syaraf dalam pembelajaran mendalam (deep learning)	<p>jaringan Bi-LSTM untuk memprediksi koefisien transformasi wavelet untuk 16 hari ke depan. Transformasi wavelet terbalik digunakan untuk mendapatkan harga cryptocurrency untuk 16 hari ke depan</p> <p>Skema yang diusulkan menghasilkan Mean Square Error (MSE) 0.000000000001, Mean Absolute Error (MAE) 0.00000094 dan Root Mean Square Error (RMSE)</p>	kripto lain akan menguji keandalan metode yang diusulkan.	

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				0.00000097 yang lebih rendah dibandingkan dengan metode yang tersedia saat ini		
4	Comparative Analysis of ARIMA and Prophet Algorithms in Bitcoin Price Forecasting	Michael David Angeloa, Ilhas Fadhiilrahmana, Yudy Purnama  Procedia Computer, 2023	Perbandingan algoritma ARIMA dan Prophet untuk meramalkan harga bitcoin	ARIMA dan Prophet dibangun menjadi model univariat dengan 2 fitur, kemudian parameter masing-masing model dibandingkan untuk mendapatkan kombinasi terbaik. Evaluasi menggunakan MAE, MAPE, MSE, dan RMSE Algoritma Prophet terbukti lebih baik untuk data harian	Belum menjelaskan alasan mengapa ARIMA dan Prophet menunjukkan kinerja yang berbeda di seluruh interval harian, mingguan, dan bulanan. Memahami faktor-faktor mendasar dapat memberikan wawasan tentang kekuatan dan kelemahan masing-masing algoritma.	Melakukan peramalan harga bitcoin

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				dan mingguan, sedangkan ARIMA lebih baik untuk data bulanan		
5	Prediction of bitcoin stock price using feature subset optimization	Saurabh Singh , Anil Pise , Byungun Yoon Heliyon, 2024	Memprediksi harga Bitcoin menggunakan algoritma pembelajaran mesin dan Mengidentifikasi subset fitur internal Bitcoin yang menghasilkan prediksi terbaik	Hasil penelitian menunjukkan subset fitur detail blok memberikan tingkat kesalahan rata-rata 6,38%, yang lebih baik dibandingkan subset fitur lainnya. Hal ini karena hubungan positif antara harga Bitcoin dan subset data ini yang memiliki ambiguitas rendah	Penelitian ini tidak melakukan analisis perbandingan kinerja prediksi antara subset fitur yang berbeda, sehingga tidak dapat diketahui subset fitur mana yang paling berpengaruh secara kuantitatif.	menggunakan algoritma LSTM, sama seperti penelitian ini, tetapi dengan arsitektur yang berbeda
6	Forecasting cryptocurrency	Nehal N. AlMadany,	membandingkan ketepatan	Penelitian ini menggunakan	Mengkombinasikan metode klasik	menggunakan metode deep learning LSTM,

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
	returns using classical statistical and deep learning techniques	Omar Hujran, Ghazi Al Naymat, Aktham Maghyereh  International Journal of Information Management Data Insights, 2024	peramalan antara model statistik klasik (ARMA, GARCH, EGARCH) dan model deep learning (LSTM) dalam memproyeksikan tingkat pengembalian cryptocurrency.	model statistik klasik (ARMA, GARCH, EGARCH) dan deep learning (LSTM) untuk meramalkan imbal hasil 10 cryptocurrency terbesar. Hasilnya menunjukkan bahwa semua model memiliki akurasi tinggi, dengan model hybrid EGARCH-LSTM dan GARCH-LSTM sedikit lebih baik. Temuan ini berharga bagi berbagai pemangku kepentingan di	(ARMA, GARCH, EGARCH) dengan metode deep learning (LSTM) atau metode lain seperti wavelet transform untuk melihat perbandingannya.	namun penelitian "Forecasting cryptocurrency returns using classical statistical and deep learning techniques" juga menggunakan metode statistik klasik seperti ARMA dan GARCH

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
				pasar cryptocurrency dan mengisi kesenjangan dalam literatur sebelumnya.		

## **2.3. Landasan Teori**

### **2.3.1. Bitcoin**

Menurut [18] dalam buku *Bitcoin on the Go: The Basics of Bitcoins and Blockchains* bitcoin didefinisikan sebagai cryptocurrency, yaitu bentuk uang digital yang digunakan untuk pembayaran dan pertukaran secara online. Bitcoin dikembangkan pada tahun 2009 oleh Satoshi Nakamoto, seorang individu atau kelompok yang identitasnya masih belum diketahui. Bitcoin didasarkan pada teknologi blockchain, yang merupakan buku besar terdesentralisasi yang mencatat semua transaksi Bitcoin. Transaksi Bitcoin dilakukan secara peer-to-peer tanpa memerlukan otoritas pusat atau lembaga keuangan, memungkinkannya digunakan secara global tanpa batasan geografis. Bitcoin dihasilkan melalui proses "penambangan" (mining), di mana komputer-komputer menyelesaikan perhitungan matematika kompleks untuk memverifikasi dan mencatat transaksi dalam blockchain. Bitcoin memiliki sifat-sifat unik seperti sifat terbatas, tidak dapat dimanipulasi, dan memberikan anonimitas yang relatif bagi penggunanya, serta memungkinkan transfer dana dengan biaya rendah, kecepatan tinggi, dan tanpa batasan geografis, menjadikannya menarik bagi berbagai aplikasi keuangan dan perdagangan.

### **2.3.2. Machine Learning**

Menurut [19] dalam buku *Deep learning: a visual approach* Machine learning adalah bidang ilmu komputer yang memungkinkan sistem atau perangkat untuk belajar dan meningkatkan kinerjanya secara otomatis dari pengalaman, tanpa

harus diprogram secara eksplisit. Algoritma machine learning dilatih pada dataset, dan kemudian dapat digunakan untuk membuat prediksi atau keputusan pada data yang belum pernah dilihat sebelumnya.

Beberapa algoritma utama dalam machine learning antara lain:

- Regresi Linier (Linear Regression): Memprediksi nilai output kontinu berdasarkan satu atau lebih variabel input.
- Klasifikasi Naïve Bayes (Naïve Bayes Classification): Mengklasifikasikan data berdasarkan probabilitas.
- K-Nearest Neighbors (K-NN): Mengklasifikasikan data berdasarkan kedekatan dengan tetangga terdekat.
- Support Vector Machines (SVMs): Mengklasifikasikan data dengan menemukan hyperplane optimal pemisah kelas.
- Pohon Keputusan (Decision Trees): Membuat model prediksi dalam bentuk struktur pohon keputusan.

Terdapat beberapa skenario dalam pembelajaran machine learning, yaitu:

- Supervised learning  
Supervised learning adalah pendekatan pembelajaran di mana sistem diberikan data pelatihan yang terdiri dari pasangan input-output yang diharapkan. Algoritma pembelajaran kemudian berusaha mempelajari hubungan antara input dan output yang benar, sehingga dapat membuat prediksi yang akurat untuk data baru [20].
- Unsupervised learning

Unsupervised learning adalah pendekatan pembelajaran di mana sistem diberikan data input tanpa label atau output yang diharapkan. Algoritma pembelajaran berusaha menemukan pola, struktur, atau pengelompokan yang tersembunyi dalam data [20].

- R Reinforcement learning adalah pendekatan pembelajaran di mana agen (agent) mengambil tindakan dalam lingkungan tertentu dan menerima umpan balik berupa reward atau punishment. Tujuan agen adalah untuk mempelajari strategi yang memaksimalkan reward jangka panjang Reinforcement Learning [20].

### 2.3.3. Deep Learning

Menurut buku Deep learning: a visual approach [19] Deep learning adalah cabang dari machine learning yang menggunakan arsitektur jaringan saraf tiruan (artificial neural networks) yang terdiri dari banyak lapisan. Deep learning dapat secara otomatis belajar merepresentasikan fitur dari data mentah, tanpa memerlukan rekayasa fitur manual.

Beberapa algoritma utama dalam deep learning antara lain:

- Jaringan Syaraf Konvolusional (Convolutional Neural Networks/CNNs): Digunakan terutama untuk tugas-tugas visi komputer seperti pengenalan gambar.
- Jaringan Saraf Rekuren (Recurrent Neural Networks/RNNs): Digunakan terutama untuk tugas-tugas pemrosesan bahasa alami seperti penerjemahan, peringkasan, dan pemodelan bahasa.

- Autoencoder: Digunakan untuk belajar representasi data yang lebih ringkas dan efisien.
- Generative Adversarial Networks (GANs): Digunakan untuk menghasilkan data yang mirip dengan data asli, seperti gambar atau teks.
- Long Short-Term Memory (LSTM): Varian dari RNN yang dapat mempelajari dependensi jangka panjang dalam data sekuensial.

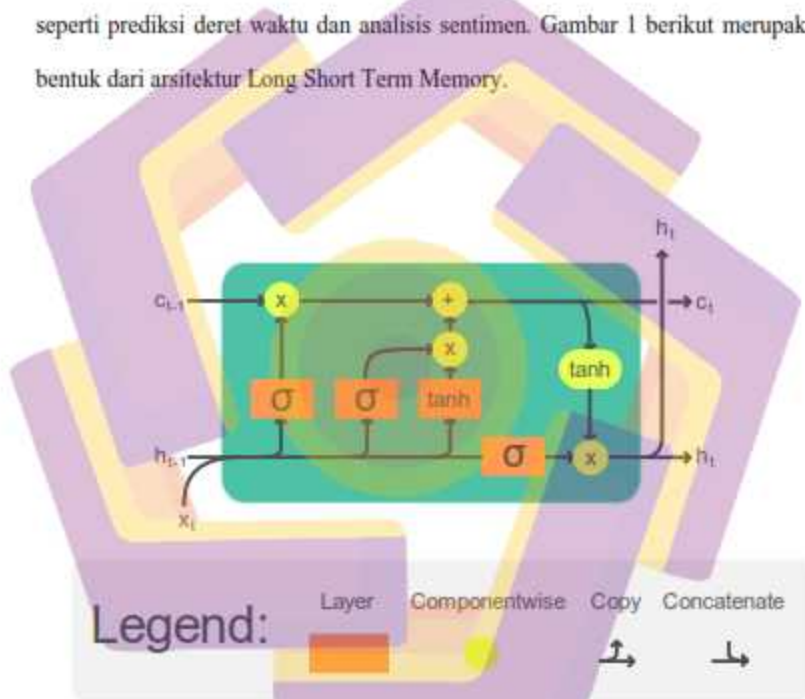
#### 2.3.4. Long Short Term Memory

Menurut [21] dalam buku yang berjudul Supervised Machine Learning for Text Analysis in R LSTM adalah salah satu jenis jaringan saraf rekuren (Recurrent Neural Network/RNN) yang dirancang untuk mengatasi masalah vanishing gradient pada RNN tradisional. LSTM mampu mempelajari dependensi jangka panjang dalam sekuens data, seperti teks atau suara. Kunci utama LSTM adalah sel memori (memory cell) yang dapat menyimpan informasi selama beberapa langkah waktu. Sel memori ini terdiri dari 3 gerbang (gate):

- Gerbang lupa (forget gate): Menentukan informasi mana yang akan disimpan atau dihapus dari sel memori.
- Gerbang input (input gate): Mengontrol informasi mana yang akan ditambahkan ke sel memori.
- Gerbang output (output gate): Mengontrol informasi mana yang akan dihasilkan sebagai output dari sel memori.

Dengan struktur gerbang ini, LSTM dapat mempelajari kapan harus menyimpan, kapan harus lupa, dan kapan harus menggunakan informasi dari urutan input

sebelumnya. Hal ini memungkinkan LSTM untuk menangkap dependensi jangka panjang dengan baik, yang menjadi kelemahan pada RNN tradisional. LSTM telah terbukti sangat efektif dalam berbagai tugas pemrosesan bahasa alami, seperti penerjemahan mesin, pengenalan ucapan, dan pemodelan bahasa. Algoritma ini juga dapat digunakan untuk tugas-tugas lain yang melibatkan data sekuensial, seperti prediksi deret waktu dan analisis sentimen. Gambar 1 berikut merupakan bentuk dari arsitektur Long Short Term Memory.



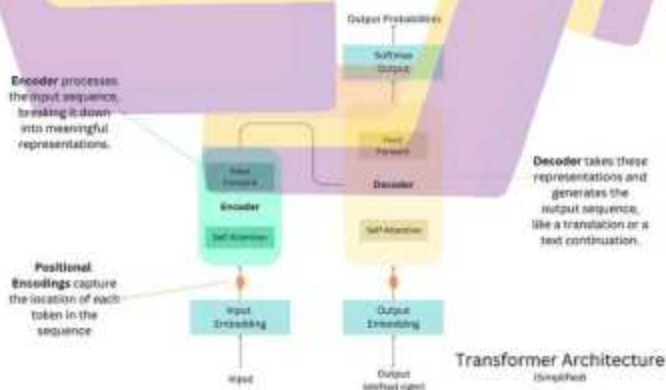
Gambar 2.1 Arsitektur LSTM

### 2.3.5. Transformer

Transformer adalah salah satu arsitektur deep learning yang dirancang untuk menangani data sekuensial dengan lebih efisien dibandingkan pendekatan

tradisional seperti Recurrent Neural Network (RNN) atau Long Short-Term Memory (LSTM). Transformer pertama kali diperkenalkan oleh [22]. Melalui penelitian berjudul "Attention is All You Need". Salah satu keunggulan utama Transformer terletak pada mekanisme self-attention, yang memungkinkan model untuk memperhatikan hubungan antara elemen-elemen dalam urutan data tanpa harus diproses secara berurutan.

Arsitektur Transformer pada gambar 1 terdiri dari dua komponen utama, yaitu encoder dan decoder. Encoder bertugas untuk menganalisis dan merepresentasikan informasi dari data input, sementara decoder digunakan untuk menghasilkan output berdasarkan representasi tersebut. Dalam konteks prediksi data seperti harga Bitcoin, biasanya hanya bagian encoder yang digunakan untuk memahami pola-pola kompleks dalam data historis.



Gambar 2.2 Arsitektur Transformer model

Keunggulan utama Transformer adalah kemampuannya untuk menangani hubungan jangka panjang secara efisien, karena model ini tidak bergantung pada propagasi informasi secara sekuensial seperti RNN atau LSTM. Dengan menggunakan mekanisme self-attention, Transformer dapat memberikan bobot lebih pada elemen-elemen penting dalam data, terlepas dari posisi mereka dalam urutan. Hal ini menjadikan Transformer sangat cocok untuk data bersifat non-linear dan volatil, seperti harga Bitcoin, di mana pola-pola penting dapat muncul di berbagai skala waktu.

Dengan arsitektur paralelisasinya, Transformer juga lebih cepat dan efisien dibandingkan model sekuensial tradisional, terutama saat bekerja dengan dataset yang besar. Kombinasi keunggulan tersebut membuat Transformer menjadi salah satu algoritma yang sangat diminati untuk berbagai aplikasi, termasuk pemrosesan bahasa alami, pengenalan pola, dan analisis data keuangan.

Berikut adalah penjelasan mengenai perhitungan dalam algoritma Transformer, meliputi mekanisme utama yang mendasarinya:

- **Embedding Layer**

Data input, seperti data harga Bitcoin, direpresentasikan sebagai vektor numerik melalui proses embedding. Proses ini mengubah setiap elemen data menjadi representasi berdimensi tinggi agar dapat diproses lebih lanjut oleh model. Selain itu, Transformer menggunakan positional encoding untuk menambahkan informasi posisi elemen dalam urutan, karena model ini tidak memiliki struktur sekuensial bawaan seperti RNN.

Positional Encoding Formula:

$$PE(pos, 2i) = \sin \left( \frac{pos}{10000^{\frac{2i}{D}}} \right) \quad (2.1)$$

$$PE(pos, 2i + 1) = \cos \left( \frac{pos}{10000^{\frac{2i}{D}}} \right) \quad (2.2)$$

Di sini

Pos : posisi elemen dalam urutan

I : indeks dimensi embedding

D : dimensi embedding

- Self-Attention Mechanism

Self-attention adalah inti dari Transformer yang memungkinkan model untuk memperhatikan hubungan antara elemen-elemen dalam data.

Langkah-langkah Perhitungan:

**Input Transformasi ke Query, Key, dan Value:**

Setiap elemen dalam data input ( $X$ ) diubah menjadi tiga vektor baru: Query ( $Q$ ), Key ( $K$ ), dan Value ( $V$ ), melalui matriks bobot:

$$Q = XW^Q, K = XW^K, V = XW^V \quad (2.3)$$

Disini  $W^Q$ ,  $W^K$  dan  $W^V$  adalah matriks bobot untuk query, key, dan value.

**Skor Kesamaan:**

Skor kesamaan antara elemen dihitung menggunakan produk titik antara  $Q$  dan  $K$ , kemudian dinormalisasi dengan akar dimensi  $d_k$  untuk menjaga stabilitas numerik:

$$Attention\ Score = \frac{QK^T}{\sqrt{d_k}} \quad (2.4)$$

**Multi-Head Attention:**

Untuk meningkatkan kemampuan model dalam menangkap berbagai pola, Transformer menggunakan beberapa "head" attention dengan parameter berbeda. Output dari semua head digabungkan dan diproyeksikan kembali menggunakan matriks bobot.

- Feedforward Neural Network (FFN)

Setelah self-attention, output dari mekanisme tersebut diteruskan ke jaringan feedforward untuk transformasi non-linear:

$$FFN(x) = ReLU(xW_1 + b_1)W_2 + b_2 \quad (2.5)$$

Di sini,  $W_1$ ,  $W_2$ ,  $b_1$ , dan  $b_2$  adalah parameter feedforward.

- Residual Connection dan Layer Normalization

Untuk mempermudah proses pelatihan, setiap sub-lapisan (self-attention dan feedforward) dilengkapi dengan residual connection, yang menjumlahkan input asli dengan output sub-lapisan, dan dilanjutkan dengan normalisasi:

$$Output = LayerNorm(x + SubLayer(x)) \quad (2.6)$$

- Decoder (Opsional untuk Prediksi Sekuens)

Pada tugas prediksi seperti harga Bitcoin, hanya encoder yang biasanya digunakan. Namun, jika diperlukan prediksi sekuens seperti urutan harga ke depan, decoder akan digunakan untuk menghasilkan data berdasarkan representasi dari encoder.

- Kompleksitas Perhitungan

Transformer memiliki kompleksitas perhitungan sekitar  $O(n^2 \cdot d)$  di mana  $n$  adalah panjang urutan dan  $d$  adalah dimensi vektor. Ini lebih efisien dibandingkan RNN/LSTM untuk urutan panjang karena memungkinkan komputasi paralel.

Perhitungan Transformer yang mengandalkan self-attention dan feedforward neural network memungkinkan model untuk menangkap hubungan kompleks dalam data dengan efisien. Hal ini membuatnya cocok untuk tugas prediksi harga Bitcoin yang memerlukan analisis pola dari data historis yang bersifat volatil dan non-linear.

### **2.3.6. Time series forecasting**

Time series forecasting menurut [23] dalam buku *Machine Learning for Time Series Forecasting with Python* menjelaskan bahwa peramalan deret waktu (time series forecasting) merupakan proses memprediksi nilai-nilai masa depan suatu variabel berdasarkan nilai-nilai historisnya dan informasi tambahan yang relevan. Tujuan utama peramalan deret waktu adalah untuk memperkirakan nilai-nilai di masa depan dengan akurasi yang tinggi. Peramalan deret waktu memainkan peran penting dalam berbagai bidang, seperti ekonomi, keuangan, pemasaran, dan produksi, karena memungkinkan pengambilan keputusan yang lebih baik dengan memperkirakan kondisi masa depan berdasarkan data historis. Buku ini berfokus pada penggunaan deep learning, khususnya model Long Short-Term Memory (LSTM), untuk peramalan deret waktu. LSTM mampu menangkap dependensi jangka panjang dalam data deret waktu, sehingga efektif untuk memprediksi nilai-

nilai masa depan. Buku ini juga mencakup contoh penggunaan LSTM untuk memprediksi harga cryptocurrency, termasuk harga Bitcoin, dan menjelaskan bagaimana data deret waktu harga Bitcoin dapat dimodelkan menggunakan LSTM untuk menghasilkan peramalan yang akurat.

### 2.3.7. Evaluation matrix

- **Mean Absolute Percentage Error (MAPE)**

MAPE adalah salah satu metrik evaluasi yang digunakan untuk mengukur tingkat kesalahan prediksi dalam bentuk persentase relatif terhadap nilai aktual. MAPE berguna karena hasilnya dinyatakan dalam persentase, yang memudahkan interpretasi dan perbandingan antar model.

Rumus MAPE

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - y'_i}{y_i} \right| \times 100 \quad (2.7)$$

Dimana

$n$ : jumlah data.

$y_i$ : nilai aktual pada data ke- $i$

$y'_i$ : nilai prediksi pada data ke- $i$

- **Coefficient of Determination ( $R^2$ )**

$R^2$  atau Koefisien Determinasi adalah metrik yang menunjukkan seberapa baik model menjelaskan variabilitas data target. Nilainya berkisar antara 0 hingga 1, di mana semakin mendekati 1, semakin baik model dalam menjelaskan data.

Rumus  $R^2$ :


$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y'_i)^2}{\sum_{i=1}^n (y_i - y^-)^2} \quad (2.8)$$

Di mana

$y_i$  : Nilai aktual pada data ke-i

$y'_i$  : Nilai prediksi pada data ke-i

$y^-$  : Rata-rata nilai aktual



## BAB III

### METODE PENELITIAN

#### 3.1. Jenis, Sifat, dan Pendekatan Penelitian

Jenis penelitian ini adalah penelitian eksperimental, yaitu melakukan pengujian terhadap data menggunakan metode tertentu dengan tujuan untuk mendapatkan kesimpulan berdasarkan data statistik. Eksperimen ini dilakukan menggunakan metode LSTM yang di gabung dengan transformer.

#### 3.2. Metode Pengumpulan Data

Dalam tahap pengumpulan data, penelitian ini akan menggunakan data historis harga Bitcoin yang bersumber dari dataset publik di platform Kaggle. Secara spesifik, data yang digunakan adalah "Bitcoin Historical Data" yang dapat diakses melalui tautan <https://www.kaggle.com/datasets/mczielinski/bitcoin-historical-data>. Dataset ini menyediakan rekaman data harga Bitcoin per menit yang komprehensif, mencakup berbagai informasi penting seperti harga pembukaan (Open), harga tertinggi (High), harga terendah (Low), harga penutupan (Close), volume perdagangan (Volume), serta harga rata-rata tertimbang (Weighted Price). Untuk memanfaatkannya, peneliti akan mengunduh file dataset yang tersedia dalam format .csv langsung dari platform Kaggle. Selanjutnya, file data tersebut akan dimuat ke dalam lingkungan analisis menggunakan library Pandas pada Python, yang memungkinkan data untuk diproses, dibersihkan, dan dianalisis lebih lanjut sesuai dengan kerangka metodologi penelitian yang telah ditetapkan.

### 3.3. Metode Analisis Data

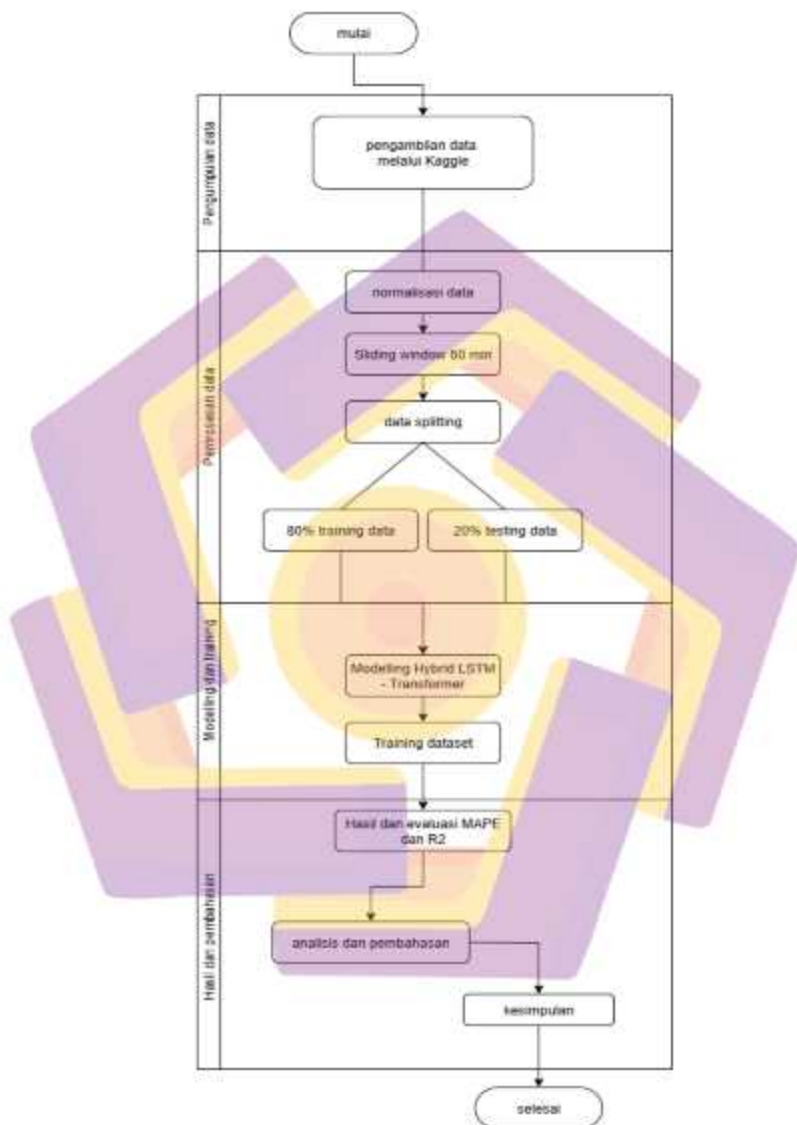
Metode analisis data yang diterapkan dalam penelitian ini merupakan sebuah kerangka kerja yang sistematis dan komprehensif, dirancang secara khusus untuk menjawab tantangan dalam memprediksi harga Bitcoin yang dikenal volatil dan bersifat non-linear. Tujuan utamanya adalah untuk membangun dan mengevaluasi secara cermat sebuah model prediksi inovatif yang mengintegrasikan dua arsitektur deep learning canggih: Transformer dan Long Short-Term Memory (LSTM). Pemilihan pendekatan hibrida ini didasarkan pada potensi sinergis keduanya; LSTM dikenal unggul dalam menangkap dependensi temporal dan pola sekuensial jangka panjang yang melekat pada data deret waktu, sementara arsitektur Transformer, melalui mekanisme self-attention, memiliki kemampuan superior untuk menimbang dan mengidentifikasi hubungan kontekstual yang kompleks antar titik data historis.

Secara metodologis, penggabungan ini didasarkan pada prinsip komplementer. LSTM berfungsi untuk menangkap urutan konteks dalam durasi yang panjang dengan ketahanan yang lebih tinggi terhadap noise dan data yang hilang [24]. Fitur yang diekstraksi oleh LSTM kemudian dapat dijadikan input bagi arsitektur Transformer. Di sisi lain, Transformer akan memanfaatkan mekanisme self-attention untuk secara simultan mempertimbangkan hubungan antara bagian spesifik dari fitur tersebut dengan semua bagian lainnya, sehingga model dapat berkonsentrasi pada aspek yang paling penting dari sekuens fitur. Dengan kata lain, model hibrida ini mengintegrasikan kekuatan dari paradigma

deep learning yang berbeda: lapisan LSTM mengidentifikasi dependensi jangka pendek dan panjang, sementara Transformer meningkatkan kemampuan model melalui mekanisme atensinya. Kombinasi ini memungkinkan model untuk secara efektif menangkap fluktuasi jangka pendek maupun tren jangka panjang dalam data harga Bitcoin, yang pada akhirnya mengarah pada prediksi yang lebih akurat. Proses analisis ini dijalankan sebagai sebuah alur kerja yang terstruktur, mencakup serangkaian tahapan yang saling terkait dan fundamental. Setiap tahap memiliki peran krusial dalam mencapai hasil akhir yang valid dan andal. Alur kerja ini dimulai dari akuisisi dan pra-pemrosesan data secara teliti untuk memastikan kualitas input, dilanjutkan dengan perancangan arsitektur model hibrida yang robust, kemudian masuk ke proses pelatihan dan optimisasi model, hingga tahap akhir yaitu pengujian dan evaluasi performa secara mendalam menggunakan berbagai metrik standar. Setiap langkah dalam metodologi ini dirancang untuk memastikan bahwa model yang dihasilkan tidak hanya akurat secara statistik, tetapi juga dapat dipertanggungjawabkan efektivitasnya. Berikut adalah rincian tahapan-tahapan yang akan dilakukan dalam analisis data ini:

#### **3.4. Alur Penelitian**

Bagian alur atau tahapan yang dilakukan dalam penelitian ini digambarkan melalui Gambar 3.1



Gambar 3.1 Alur Penelitian

Alur penelitian secara sistematis dapat dilihat pada Gambar dan akan dijelaskan sebagai berikut:

a. Pengumpulan Dataset

Langkah fundamental yang mengawali metodologi penelitian ini adalah tahap pengumpulan dataset, yang perannya krusial dalam menentukan kualitas dan keandalan model prediksi yang akan dibangun. Mengingat sifat penelitian ini adalah analisis deret waktu kuantitatif, pemilihan sumber data yang valid dan memiliki granularitas tinggi menjadi prioritas utama. Untuk memenuhi kebutuhan tersebut, penelitian ini memanfaatkan data sekunder yang bersumber dari repositori dataset publik terkemuka, Kaggle. Platform ini dipilih karena reputasinya dalam menyediakan dataset yang terverifikasi, mudah diakses, dan umum digunakan oleh komunitas riset global, sehingga menjamin transparansi dan reproduisibilitas penelitian. Dataset yang digunakan secara spesifik adalah "Bitcoin Historical Data", yang menyediakan catatan historis harga Bitcoin terhadap Dolar AS (BTC/USD) dengan interval waktu per menit. Granularitas data per menit ini menawarkan kekayaan informasi yang detail mengenai dinamika pasar dalam skala waktu yang singkat, meskipun nantinya akan diolah lebih lanjut sesuai kebutuhan model.

Dataset mentah yang diunduh dalam format .csv ini mencakup beberapa kolom atribut yang menjadi standar dalam analisis pasar keuangan. Atribut-atribut tersebut meliputi harga pembukaan (Open), harga

tertinggi (High), harga terendah (Low), harga penutupan (Close), serta total volume perdagangan (Volume) untuk setiap interval waktu satu menit. Setiap atribut ini memiliki peran penting; misalnya, harga penutupan (Close) seringkali menjadi target utama dalam peramalan, sementara volume (Volume) dapat memberikan indikasi mengenai kekuatan suatu tren pasar. Untuk memberikan gambaran visual yang konkret mengenai struktur dan cakupan data mentah yang menjadi fondasi penelitian ini, Gambar 3.2 disajikan untuk menampilkan lima baris data teratas dan lima baris data terbawah. Visualisasi ini secara efektif menunjukkan titik awal dan akhir dari periode data yang digunakan, serta memperlihatkan format asli data sebelum melalui tahap pra-pemrosesan lebih lanjut.

	Timestamp	Open	High	Low	Close	Volume
0	2012-01-01 10:01:00	4.58	4.58	4.58	4.58	0.0
1	2012-01-01 10:02:00	4.58	4.58	4.58	4.58	0.0
2	2012-01-01 10:03:00	4.58	4.58	4.58	4.58	0.0
3	2012-01-01 10:04:00	4.58	4.58	4.58	4.58	0.0
4	2012-01-01 10:05:00	4.58	4.58	4.58	4.58	0.0
	Timestamp	Open	High	Low	Close	Volume
6742275	2025-01-10 23:56:00	94725.0	94725.0	94690.0	94691.0	0.901410
6742276	2025-01-10 23:57:00	94691.0	94691.0	94672.0	94680.0	1.067209
6742277	2025-01-10 23:58:00	94680.0	94713.0	94680.0	94710.0	2.215471
6742278	2025-01-10 23:59:00	94710.0	94710.0	94700.0	94702.0	1.324348
6742279	2025-01-11 00:00:00	94702.0	94702.0	94678.0	94685.0	3.407287

Gambar 3.2 Dataset BTC

#### b. Pra-pemrosesan

Setelah dataset berhasil dikumpulkan, tahap selanjutnya adalah pemrosesan data. Tahap ini merupakan langkah krusial yang bertujuan untuk membersihkan, mentransformasi, dan menstrukturkan data mentah

agar sesuai dengan format yang dibutuhkan oleh arsitektur model hibrida Transformer-LSTM. Proses ini memastikan bahwa data yang digunakan untuk melatih model memiliki kualitas yang tinggi, bebas dari anomali, dan memiliki skala yang seragam, sehingga dapat meningkatkan stabilitas dan efektivasi proses pelatihan. Serangkaian langkah pemrosesan data yang dilakukan adalah sebagai berikut:

Pertama, dilakukan pembersihan data. Data mentah per menit yang diperoleh dari Kaggle diperiksa untuk menangani nilai yang hilang (missing values) yang mungkin muncul. Baris data yang tidak lengkap atau mengandung anomali akan dihapus untuk menjaga integritas dan kontinuitas dataset deret waktu. Berbeda dengan analisis jangka panjang, penelitian ini tidak melakukan agregasi ke interval waktu yang lebih besar (seperti harian) dan akan bekerja langsung pada data per menit untuk menangkap fluktuasi pasar dengan frekuensi tinggi.

Kedua, dilakukan normalisasi data. Atribut-atribut dalam dataset, terutama harga, memiliki skala nilai yang bervariasi. Untuk menyeragamkan skala ini dan mempercepat konvergensi model, diterapkan teknik normalisasi menggunakan MinMaxScaler. Metode ini mengubah semua nilai fitur ke dalam rentang antara 0 dan 1. Penting untuk dicatat bahwa objek scaler ini hanya "dilatih" (fitted) pada data latih. Parameter skala yang sama kemudian digunakan untuk mentransformasi data validasi dan data uji, untuk memastikan tidak ada informasi dari data masa depan yang bocor ke dalam proses pelatihan.

Langkah terakhir adalah pembentukan sekuens atau windowing. Model deep learning untuk deret waktu tidak memproses data secara satu per satu, melainkan dalam bentuk sekuens (jendela waktu). Masing-masing set data (latih, validasi, dan uji) yang telah dinormalisasi kemudian diubah menjadi sekuens-sekuens data dengan panjang yang telah ditentukan (misalnya, 60 menit terakhir). Setiap sekuens input ini akan dipasangkan dengan satu nilai target output, yaitu data pada menit berikutnya. Proses ini menghasilkan struktur data input-output yang siap untuk dimasukkan ke dalam model untuk tahap pelatihan, validasi, dan evaluasi.

#### c. Pembagian Data

Kedua, dilakukan pembagian dataset menjadi tiga bagian terpisah: data latih (training set), data validasi (validation set), dan data uji (testing set). Karena ini adalah data deret waktu, pembagian harus dilakukan secara kronologis untuk mencegah kebocoran data dari masa depan ke masa lalu (look-ahead bias). Keseluruhan dataset yang telah diurutkan berdasarkan waktu dibagi dengan proporsi 80% data terawal untuk pelatihan, 10% data berikutnya untuk validasi, dan 10% data terakhir untuk pengujian. Dengan demikian, model akan dilatih menggunakan sebagian besar data historis dan diuji kemampuannya untuk memprediksi data pada periode waktu yang lebih baru.

#### d. Model

Model yang diusulkan dalam penelitian ini adalah sebuah arsitektur *deep learning* hibrida yang dirancang untuk memanfaatkan keunggulan dari

dua pendekatan pemrosesan sekuens yang berbeda: Long Short-Term Memory (LSTM) dan Transformer. Tujuan utama dari desain hibrida ini adalah untuk menciptakan model yang mampu menangkap baik dependensi temporal berurutan (kekuatan LSTM) maupun hubungan kontekstual jangka panjang (kekuatan Transformer) yang ada dalam data harga Bitcoin.

Seperti yang diilustrasikan pada Gambar 3.3, arsitektur ini memiliki alur pemrosesan paralel di mana data input diproses secara bersamaan melalui dua cabang yang berbeda sebelum hasilnya digabungkan untuk prediksi akhir.

### **1. Input Layer**

Proses prediksi dimulai dengan mengambil data mentah dari 60 menit terakhir sebagai input. Sebagai contoh, untuk memprediksi harga pada pukul 23:00, model akan menganalisis 60 data harga penutupan (Close) dari pukul 22:00 hingga 22:59. Data ini berupa serangkaian harga riil dalam Dolar AS, misalnya dimulai dari 43.500,10 USD pada pukul 22:00 dan berakhir di 43.580,40 USD pada pukul 22:59, yang merepresentasikan pergerakan pasar dalam satu jam terakhir sebelum titik prediksi.

Sebelum dimasukkan ke dalam model, data mentah tersebut harus melalui tahap normalisasi menggunakan MinMaxScaler. Proses ini mengubah setiap nilai harga riil ke dalam skala  $[0, 1]$ , di mana nilai terendah dalam rentang data latih menjadi 0 dan nilai tertinggi menjadi 1. Hasilnya adalah sebuah matriks berukuran  $[60, 1]$  yang berisi harga ternormalisasi,

misalnya [0.45], [0.48], ..., [0.85]. Matriks inilah yang menjadi input sebenarnya untuk kedua cabang arsitektur hibrida, memastikan proses pelatihan berjalan lebih stabil dan efisien.

## 2. Cabang Pemrosesan Paralel

Setelah dari *Input Layer*, data dialirkan ke dua cabang pemrosesan secara simultan:

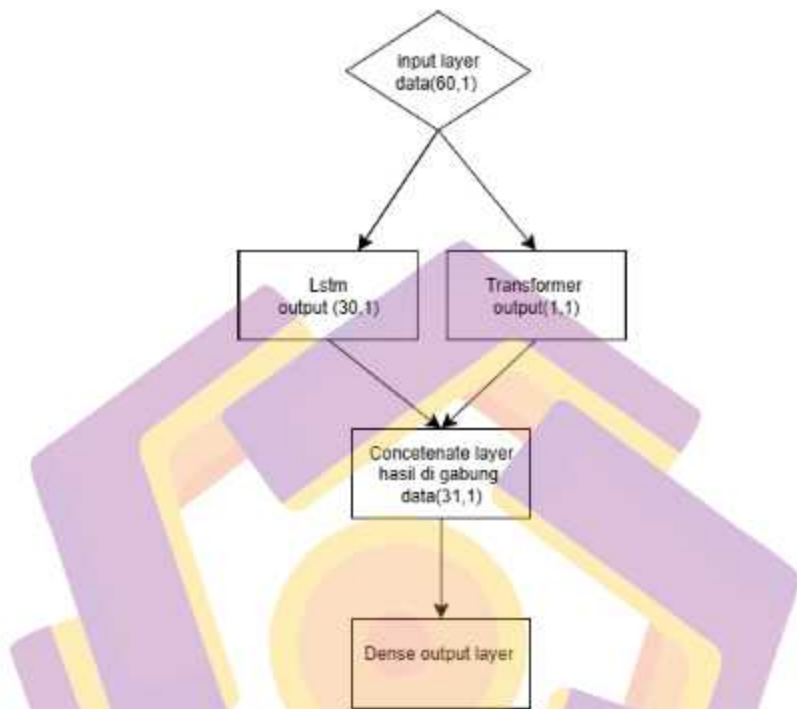
- **Cabang Stacked LSTM:** Setelah dinormalisasi, matriks input [60, 1] pertama kali diproses oleh cabang LSTM. Cabang ini, yang terdiri dari dua lapis LSTM, menganalisis data secara sekuensial dari menit ke-1 hingga ke-60 untuk menangkap pola-pola temporal seperti tren dan momentum. Proses ini menghasilkan sebuah vektor rangkuman akhir berukuran [30], misalnya [0.92, -0.31, ..., -0.11]. Setiap angka dalam vektor ini merupakan representasi fitur abstrak yang merangkum "alur cerita" dari pergerakan harga selama satu jam terakhir.
- **Cabang Transformer Block:** Secara bersamaan, matriks input [60, 1] yang sama juga dianalisis oleh cabang Transformer. Cabang ini bekerja secara holistik, di mana lapisan MultiHeadAttention mencari hubungan kontekstual yang signifikan di antara 60 titik data tanpa terikat oleh urutan. Hasil analisis yang kaya konteks ini kemudian diringkas oleh lapisan GlobalAveragePooling1D menjadi sebuah skalar tunggal berukuran [1], misalnya [0.65]. Nilai tunggal ini merepresentasikan kesimpulan numerik dari konteks pasar secara keseluruhan selama periode tersebut.

### 3. Penggabungan dan Lapisan Akhir

Di tahap ini, dua jenis pemahaman yang berbeda dari kedua cabang disatukan untuk menciptakan sebuah representasi data yang superior. Lapisan Concatenate menerima dua input: vektor [30] dari LSTM dan skalar [1] dari Transformer. Operasi ini secara harfiah "menempelkan" keduanya dari ujung ke ujung, menghasilkan sebuah vektor hibrida baru berukuran [31], misalnya [0.92, -0.31, ..., -0.11, 0.65]. Vektor ini adalah representasi data yang paling komprehensif, karena 30 fitur pertamanya mengandung pemahaman sekuensial dan 1 fitur terakhirnya mengandung pemahaman kontekstual.

### 4. Tahap prediksi akhir

Vektor hibrida [31] yang kaya informasi ini menjadi input untuk lapisan Dense(1) akhir, yang berfungsi sebagai "penerjemah" akhir. Lapisan ini melakukan operasi penjumlahan tertimbang (weighted sum): setiap dari 31 fitur dikalikan dengan bobot internalnya yang telah dipelajari, lalu dijumlahkan untuk menghasilkan satu nilai output. Hasilnya adalah sebuah nilai skalar (misalnya [0.88]) yang merupakan prediksi dalam skala ternormalisasi. Nilai ini kemudian dikembalikan ke skala Dolar AS menggunakan `scaler.inverse_transform()` untuk menghasilkan prediksi akhir yang dapat diinterpretasikan, misalnya 43.595,50 USD.



Gambar 3.3 Arsitektur model

#### e. Pelatihan Model

Tahap pelatihan model adalah proses inti di mana arsitektur hibrida yang telah dirancang akan mempelajari pola dari data latih. Untuk menemukan konfigurasi yang paling optimal, penelitian ini akan melakukan serangkaian eksperimen dengan memvariasikan parameter pelatihan.

Model akan dikompilasi dengan menggunakan optimizer Adam, yang merupakan algoritma optimasi yang efisien karena kemampuannya dalam menyesuaikan learning rate secara adaptif. Sebagai fungsi kerugian

(loss function), penelitian ini menggunakan Mean Squared Error (MSE), yang secara efektif mengukur rata-rata kuadrat selisih antara nilai prediksi dengan nilai aktual.

Setiap eksperimen akan dijalankan selama 10 epoch. Variasi utama dalam eksperimen ini adalah penggunaan ukuran batch yang berbeda, yaitu 32, 64, dan 128. Dengan menguji beberapa ukuran batch, penelitian ini bertujuan untuk menganalisis bagaimana parameter ini mempengaruhi kecepatan konvergensi dan performa akhir model. Untuk membantu proses pelatihan, diterapkan mekanisme callback ReduceLROnPlateau. Callback ini akan memantau performa model pada data validasi dan mengurangi learning rate secara otomatis jika performa mengalami stagnasi, sehingga membantu model mencapai konvergensi yang lebih baik.

#### f. Evaluasi Model

Setelah proses pelatihan selesai, tahap akhir dari metodologi ini adalah melakukan evaluasi kuantitatif terhadap performa model. Evaluasi ini dilakukan dengan menggunakan data uji (test set), yaitu data yang sama sekali belum pernah dilihat oleh model selama proses pelatihan. Tujuannya adalah untuk mengukur seberapa baik model dapat digeneralisasi pada data baru, yang mencerminkan kemampuannya dalam skenario dunia nyata.

MAPE digunakan untuk mengukur rata-rata kesalahan prediksi dalam bentuk persentase, yang memberikan gambaran intuitif tentang tingkat akurasi model. Sementara itu,  $R^2$  digunakan untuk mengukur seberapa baik

model dapat menjelaskan variabilitas data, yang menunjukkan tingkat kecocokan model dengan data yang diamati. Hasil dari kedua metrik ini akan menjadi dasar utama dalam menganalisis dan menyimpulkan performa dari setiap skenario model yang diuji.


### 3.5. Skenario

Untuk melakukan evaluasi yang mendalam dan membuktikan efektivitas dari pendekatan hibrida, penelitian ini dirancang dengan serangkaian skenario pengujian yang sistematis. Pengujian akan dibagi menjadi dua skenario utama untuk mendapatkan perbandingan performa yang adil. Skenario pertama bertujuan untuk membangun sebuah model dasar (baseline) dengan menggunakan arsitektur Long Short-Term Memory (LSTM) standar. Skenario kedua akan menguji arsitektur hibrida LSTM-Transformer yang diusulkan dalam penelitian ini, dengan tujuan untuk mengetahui apakah penambahan komponen Transformer dapat memberikan peningkatan performa yang signifikan. Di dalam masing-masing skenario, akan dilakukan tiga eksperimen terpisah dengan memvariasikan ukuran batch (batch size), yaitu 32, 64, dan 128. Seluruh eksperimen akan dijalankan selama 10 epoch. Dengan membandingkan hasil terbaik dari model LSTM dasar dengan hasil terbaik dari model hibrida, penelitian ini dapat menarik kesimpulan yang solid mengenai kontribusi dan keunggulan dari arsitektur yang diusulkan. Seluruh konfigurasi pengujian yang akan dijalankan dirangkum pada Tabel 3.2.

Tabel 3.1 Konfigurasi Skenario Pengujian Model

Skenario	Teknik Augmentasi	Epoch	Ukuran Batch
----------	-------------------	-------	--------------

Skenario 1	LSTM	10	32, 64, 128
Skenario 2	LSTM-Transformer	10	32, 64, 128



## BAB IV

### HASIL PENELITIAN DAN PEMBAHASAN

#### 4.1. Pendahuluan

Bab ini secara khusus akan memaparkan dan membahas secara komprehensif seluruh hasil dari penelitian yang telah dilaksanakan. Sesuai dengan metodologi yang telah diuraikan pada Bab III, bab ini berfokus pada penyajian data hasil eksperimen dari skenario-skenario pengujian model prediksi harga Bitcoin. Penyajian hasil tidak hanya terbatas pada angka-angka performa, tetapi juga mencakup visualisasi data yang relevan untuk memberikan gambaran yang lebih utuh mengenai perilaku dan kapabilitas model yang dikembangkan.

Selanjutnya, setiap hasil yang disajikan akan diikuti dengan tahap analisis dan pembahasan yang mendalam. Tahap ini bertujuan untuk menginterpretasikan makna di balik data, membandingkan performa antara model baseline Long Short-Term Memory (LSTM) dengan model hibrida LSTM-Transformer yang diusulkan, serta menghubungkan temuan yang diperoleh dengan landasan teoretis dan penelitian terdahulu. Melalui analisis ini, tujuan utamanya adalah untuk menjawab secara sistematis rumusan masalah yang telah ditetapkan, sehingga dapat ditarik kesimpulan yang valid dan dapat dipertanggungjawabkan pada bab berikutnya..

#### 4.2. Konfigurasi parameter

Penelitian ini menggunakan dataset historis harga Bitcoin (BTC/USD) per menit yang bersumber dari platform Kaggle, mencakup rentang waktu dari tahun

2023 sampai 2025. Data mentah yang terdiri dari fitur Open, High, Low, dan Close kemudian melalui tahap pra-pemrosesan yang meliputi normalisasi nilai menggunakan MinMaxScaler ke dalam rentang 0 hingga 1. Untuk membentuk data sekuensial, penelitian ini mengadopsi metode jendela waktu (windowing) dengan panjang sekuens 60, di mana data harga selama 60 menit sebelumnya digunakan untuk memprediksi harga pada menit berikutnya. Setelah diproses, dataset dibagi secara kronologis menjadi 80% data latih dan 20% data uji, menghasilkan 754.528 sampel untuk pelatihan dan 188.632 sampel untuk pengujian. Distribusi pembagian data ini diilustrasikan secara visual pada Gambar 4.1.



Gambar 4.1 Visualisasi Pembagian Dataset Latih dan Uji

Untuk menjawab rumusan masalah, penelitian ini merancang dan membandingkan dua arsitektur model deep learning. Model pertama adalah model LSTM standar yang berfungsi sebagai baseline, terdiri dari dua lapis LSTM bertumpuk dengan masing-masing 30 unit. Model kedua, yang merupakan fokus utama dari penelitian ini, adalah model hibrida LSTM-Transformer.

Arsitektur model hibrida ini dirancang secara spesifik untuk memproses data input melalui dua cabang pemrosesan paralel untuk menangkap jenis pola yang berbeda secara simultan. Cabang pertama menggunakan dua lapis LSTM untuk mempelajari dependensi temporal yang sekuensial. Cabang kedua menggunakan mekanisme Multi-Head Attention dari arsitektur Transformer untuk mengidentifikasi hubungan kontekstual di seluruh sekuens input. Output dari kedua cabang ini kemudian digabungkan untuk menghasilkan prediksi akhir. Rincian dari setiap komponen utama dalam arsitektur model hibrida, beserta fungsi dan parameter kuncinya, disajikan secara jelas pada Tabel 4.1.

Tabel 4.1 Konfigurasi Parameter Penelitian

Bagian Arsitektur	Komponen / Lapisan	Parameter Kunci	Tujuan / Fungsi Utama
Input	Input Layer	shape=(60, 1)	Menerima sekuens harga input (60 menit).
Cabang 1: LSTM	LSTM Layer 1 & LSTM Layer 2	units=30	Menangkap pola tren secara berurutan.
Cabang 2: Transformer	MultiHeadAttention	num_heads=1, key_dim=4	Mencari hubungan penting di seluruh sekuens.
Penggabungan	Concatenate Layer	-	Menggabungkan hasil dari cabang LSTM & Transformer.
Output	Dense Layer	units=1	Menghasilkan nilai prediksi harga akhir.

### 4.3. Hasil Pengujian

#### 4.3.1 Hasil Pengujian Skenario 1 (LSTM)

Hasil pengujian model hybrid LSTM–Transformer dengan variasi batch size ditunjukkan pada Tabel 4.2.

Tabel 4.2 Hasil Pengujian Skenario 1 LSTM

Batch Size	RMSE	MSE	MAPE	R <sup>2</sup>
32	521.1787	281.4125	0.003408	0.998523
64	200.9424	115.4527	0.001432	0.999780
128	82.2155	44.8264	0.000643	0.999963

Berdasarkan tabel 4.1, terlihat bahwa peningkatan batch size memberikan dampak positif terhadap kinerja model LSTM. Pada batch size 32, nilai RMSE sebesar 521.17 dan MAE sebesar 281.41 masih menunjukkan deviasi yang cukup besar, meskipun nilai R<sup>2</sup> sebesar 0.9985 sudah mengindikasikan bahwa model mampu menjelaskan sebagian besar variasi data. Ketika ukuran batch dinaikkan menjadi 64, performa model meningkat secara signifikan dengan penurunan RMSE menjadi 200.94, MAE menjadi 115.45, serta MAPE turun hingga 0.0014. Nilai R<sup>2</sup> meningkat menjadi 0.9998, menandakan kemampuan generalisasi model semakin baik.

Peningkatan paling optimal dicapai pada batch size 128 dengan RMSE 82.22, MAE 44.83, dan MAPE 0.00064. Nilai R<sup>2</sup> sebesar 0.99996 mendekati sempurna, menegaskan bahwa model LSTM mampu memberikan prediksi yang sangat akurat pada konfigurasi ini. Secara keseluruhan, LSTM cenderung semakin

stabil dan presisi ketika batch size diperbesar, meskipun konsekuensinya adalah kebutuhan komputasi yang lebih tinggi.

#### 4.3.2 Skenario 2: LSTM–Transformer

Hasil pengujian model hybrid LSTM–Transformer dengan variasi batch size ditunjukkan pada Tabel 4.2.

Tabel 4.3 Hasil Pengujian Skenario 2 (LSTM–Transformer)

Batch Size	RMSE	MSE	MAPE	R <sup>2</sup>
32	327.8430	158.8432	0.001825	0.999415
64	78.4925	43.4646	0.000607	0.999966
128	78.4304	40.5664	0.000594	0.999967

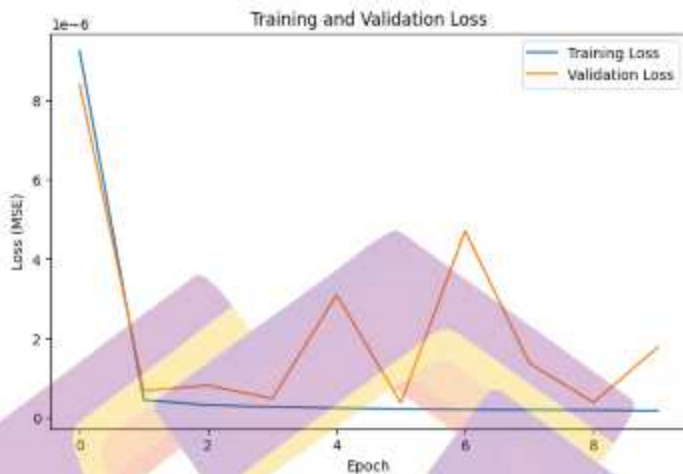
Tabel 4.3 memperlihatkan bahwa integrasi LSTM dengan Transformer mampu meningkatkan akurasi prediksi secara signifikan, terutama pada batch size menengah dan besar. Pada batch size 32, hybrid model mencatat RMSE 327.84, MAE 158.85, dan MAPE 0.00182 dengan R<sup>2</sup> 0.9994. Hasil ini lebih baik dibandingkan LSTM murni batch 32, meskipun error masih relatif besar.

Kinerja model meningkat tajam pada batch size 64, dengan RMSE turun drastis menjadi 78.49, MAE 43.46, serta MAPE 0.00061. Nilai R<sup>2</sup> sebesar 0.99997 menandakan bahwa model hampir sepenuhnya mampu menjelaskan variasi data aktual. Pada batch size 128, performa model sedikit lebih baik dengan RMSE 78.43, MAE 40.57, MAPE 0.00059, dan R<sup>2</sup> 0.99997. Angka-angka ini menunjukkan bahwa hybrid model mencapai akurasi terbaik dari seluruh eksperimen, dengan deviasi prediksi yang sangat kecil terhadap data aktual.

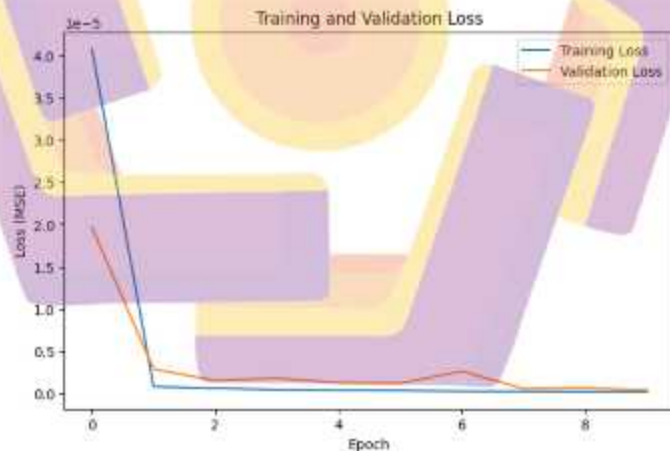
Dengan demikian, hasil pengujian menegaskan bahwa penggunaan arsitektur hybrid LSTM-Transformer memberikan peningkatan performa signifikan dibandingkan LSTM murni. Kehadiran mekanisme self-attention pada Transformer terbukti mampu melengkapi kelemahan LSTM dalam menangkap pola jangka panjang, sehingga menghasilkan prediksi harga Bitcoin yang lebih presisi dan stabil.

#### 4.4. Visualisasi Hasil

Gambar 4.2 menunjukkan grafik training loss dan validation loss pada model LSTM dengan konfigurasi batch size 32. Terlihat bahwa training loss menurun secara signifikan sejak epoch pertama dan mencapai nilai yang sangat kecil setelah beberapa epoch, menandakan proses pembelajaran berjalan baik. Namun, validation loss masih memperlihatkan pola fluktuatif, naik-turun pada beberapa epoch meskipun tetap berada pada kisaran nilai rendah (sekitar  $1e-6$ ). Hal ini mengindikasikan bahwa meskipun model mampu belajar dengan efektif dari data latih, pada batch size 32 stabilitas generalisasi terhadap data uji masih belum optimal.




Gambar 4.2 grafik loss LSTM batch size 32



Gambar 4.3 grafik loss LSTM batch size 64

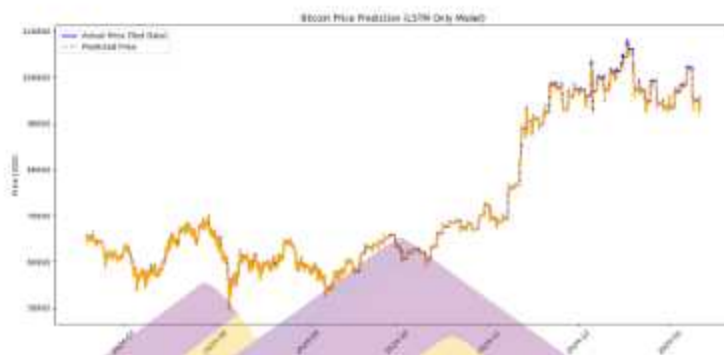
Gambar 4.3 memperlihatkan hasil training dan validation loss pada model LSTM dengan batch size 64. Pola penurunan training loss serupa dengan batch 32, di mana nilai loss menurun drastis pada epoch awal hingga mendekati nol.

Validation loss menunjukkan tren yang lebih stabil dibanding batch 32, walaupun masih terdapat fluktuasi pada epoch pertengahan. Secara keseluruhan, grafik ini memperlihatkan bahwa penggunaan batch size 64 menghasilkan model dengan kemampuan generalisasi yang lebih baik dibanding batch size 32, ditandai dengan berkurangnya deviasi antara training loss dan validation loss.



Gambar 4.4 grafik loss LSTM batch size 128

Gambar 4.4 menampilkan hasil training dan validation loss pada model LSTM dengan batch size 128. Kedua garis loss, baik training maupun validation, mengalami penurunan yang cepat pada epoch awal dan kemudian stabil pada nilai yang sangat rendah. Tidak tampak fluktuasi besar pada validation loss, yang berarti model berhasil mencapai keseimbangan antara kemampuan belajar dari data latih dan generalisasi pada data uji. Dengan kata lain, batch size 128 memberikan hasil paling optimal di antara seluruh konfigurasi yang diuji, karena mampu menjaga stabilitas training sekaligus menghasilkan kinerja validasi yang konsisten.



Gambar 4.5 grafik prediksi LSTM batch size 32

Gambar 4.5 memperlihatkan perbandingan harga Bitcoin aktual (garis biru) dengan hasil prediksi model LSTM menggunakan batch size 32 (garis oranye). Secara umum, pola prediksi mengikuti tren harga aktual, baik pada periode kenaikan maupun penurunan harga. Namun, masih terdapat deviasi pada beberapa titik, terutama ketika terjadi fluktuasi tajam pada harga aktual. Hal ini menunjukkan bahwa batch size 32 cukup mampu menangkap pola jangka panjang, tetapi sensitivitasnya terhadap perubahan harga yang cepat masih terbatas.



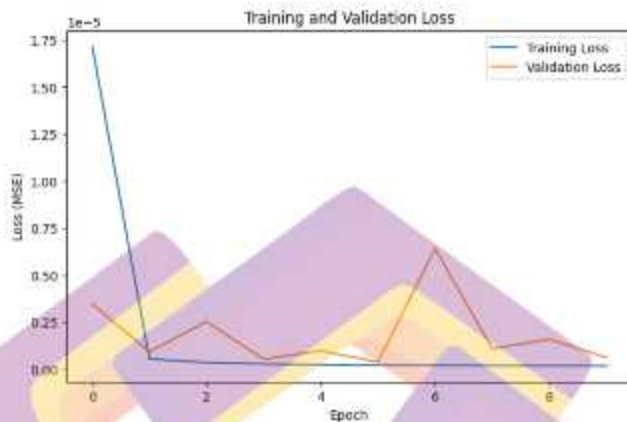
Gambar 4.6 grafik prediksi LSTM batch size 64

Gambar 4.6 menunjukkan hasil prediksi model LSTM dengan batch size 64. Dibandingkan batch 32, hasil prediksi terlihat lebih halus dan semakin mendekati pola harga aktual. Deviasi antara garis prediksi dan garis aktual berkurang, khususnya pada fase kenaikan harga di pertengahan tahun 2024. Hal ini mengindikasikan bahwa konfigurasi batch size 64 meningkatkan kemampuan generalisasi model, sehingga prediksi lebih akurat dan konsisten dengan pergerakan harga riil



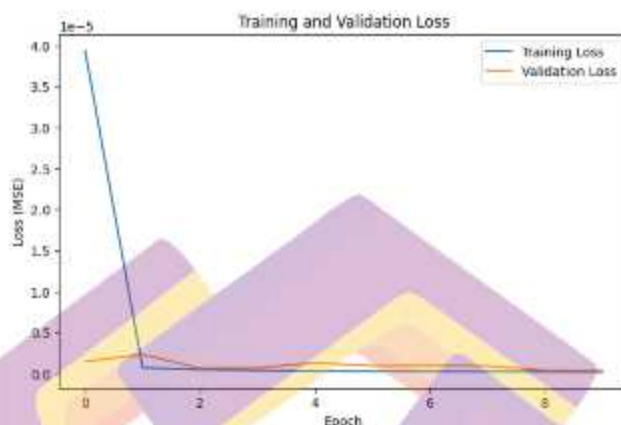
Gambar 4.7 grafik prediksi LSTM batch size 128

Gambar 4.7 menampilkan hasil prediksi dengan batch size 128. Garis prediksi hampir menyatu dengan garis aktual pada sebagian besar periode pengujian, baik pada fase tren naik maupun tren turun. Deviasi yang muncul relatif kecil dan tidak signifikan terhadap keseluruhan pola prediksi. Hal ini menegaskan bahwa batch size 128 menghasilkan performa terbaik pada model LSTM, dengan akurasi prediksi yang tinggi serta kemampuan mengikuti pola harga aktual secara lebih konsisten dibanding konfigurasi batch size lainnya.



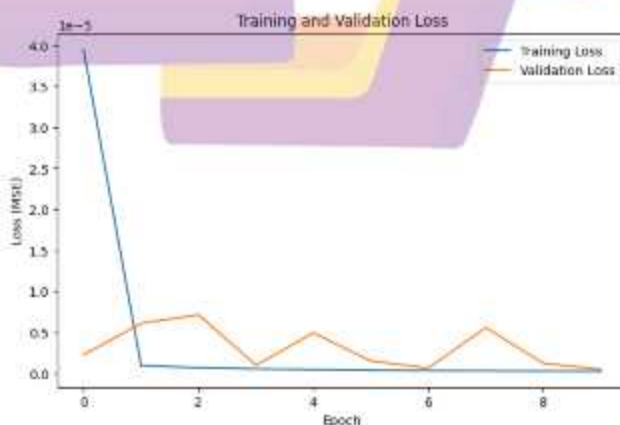
Gambar 4.8 grafik loss LSTM-transformer batch size 32

Gambar 4.8 menunjukkan hasil training dan validation loss pada model hibrida LSTM + Transformer dengan batch size 32. Training loss menurun dengan cepat sejak epoch pertama dan segera mencapai nilai mendekati nol. Validation loss relatif rendah, namun masih menunjukkan fluktuasi pada beberapa titik, terutama pada epoch pertengahan. Kondisi ini menandakan bahwa meskipun model mampu belajar dengan baik, generalisasi pada batch kecil masih kurang stabil akibat sensitivitas yang tinggi terhadap variasi data.



Gambar 4.9 Grafik loss LSTM-transformer batch size 64

Gambar 4.9 memperlihatkan pola training dan validation loss dengan batch size 64. Training loss menurun tajam dan stabil di nilai sangat kecil. Validation loss juga menunjukkan tren yang lebih halus dengan deviasi minimal dari training loss. Hal ini memperlihatkan bahwa penggunaan batch size 64 memberikan keseimbangan optimal antara kemampuan belajar model dan stabilitas generalisasi pada data validasi.



Gambar 4.10 grafik loss LSTM-transformer batch size 128

Gambar 4.10 menampilkan hasil loss pada batch size 128. Baik training loss maupun validation loss sama-sama menurun signifikan dan kemudian bertahan pada nilai yang sangat rendah, tanpa adanya fluktuasi besar. Tren ini menunjukkan bahwa model dengan batch size 128 mencapai kinerja paling stabil, di mana perbedaan antara training dan validation loss sangat kecil. Dengan demikian, konfigurasi batch size 128 terbukti paling konsisten dalam menjaga kualitas pembelajaran sekaligus generalisasi pada model LSTM - Transformer.



Gambar 4.11 Grafik prediksi LSTM-transformer batch size 32

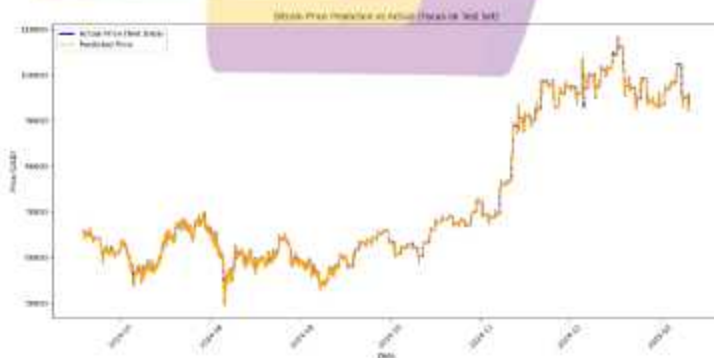
Gambar 4.11 menampilkan perbandingan harga aktual Bitcoin (garis biru) dengan hasil prediksi model LSTM-Transformer menggunakan batch size 32 (garis oranye). Secara umum, pola prediksi mengikuti tren harga aktual baik pada fase kenaikan maupun penurunan. Namun, masih terdapat deviasi pada titik-titik dengan fluktuasi tajam. Hal ini menunjukkan bahwa meskipun model hibrida sudah memberikan hasil yang lebih baik dibanding LSTM murni, penggunaan batch size

yang kecil masih menimbulkan keterbatasan dalam menangkap pola volatilitas jangka pendek secara konsisten.



Gambar 4.12 grafik prediksi LSTM-transformer batch size 64

Gambar 4.12 memperlihatkan hasil prediksi dengan konfigurasi batch size 64. Dibandingkan batch 32, garis prediksi terlihat lebih stabil dan semakin mendekati garis aktual. Model mampu mengikuti tren harga dengan deviasi yang lebih kecil, baik pada fase tren naik maupun turun. Hasil ini menunjukkan bahwa batch size 64 memberikan keseimbangan yang lebih baik antara akurasi prediksi



dan stabilitas generalisasi model. Dengan kata lain, model lebih adaptif dalam menghadapi variasi data tanpa kehilangan presisi prediksi.

Gambar 4.13 Grafik prediksi LSTM-transformer batch size 128

Gambar 4.13 memperlihatkan performa terbaik model pada batch size 128. Garis prediksi hampir menyatu dengan garis aktual pada hampir seluruh rentang waktu pengujian, termasuk pada periode kenaikan harga yang curam maupun saat harga mengalami koreksi. Deviasi prediksi relatif sangat kecil dan konsisten, menegaskan bahwa konfigurasi batch 128 memberikan hasil paling optimal. Temuan ini juga sejalan dengan hasil metrik evaluasi (MAPE dan  $R^2$ ) yang menunjukkan akurasi hampir sempurna pada skenario ini.

#### **4.5 Analisis hasil dan Perbandingan**

Untuk mengontekstualisasikan temuan dari penelitian ini, dilakukan perbandingan performa model hibrida LSTM-Transformer dengan hasil dari penelitian-penelitian sebelumnya yang paling relevan. Perbandingan ini bertujuan untuk memposisikan hasil penelitian dalam lanskap akademik yang lebih luas, dengan memperhatikan perbedaan metodologi, granularitas data, dan metrik evaluasi yang digunakan. Tabel 4.4 berikut menyajikan perbandingan hasil penelitian ini dengan beberapa studi terpilih yang juga berfokus pada prediksi harga Bitcoin menggunakan model deep learning.

Tabel 4. 4 Perbandingan Hasil dengan Penelitian Terdahulu

Penelitian	Model yang digunakan	Dataset	RMSE	MAE	MAPE	R <sup>2</sup>
Penelitian ini ( Rio irawan, 2025)	Hibrida LSTM-Transformer	BTC/USD (per menit)	78.43	40.56	0.000594	0.999967
[25]	Hibrida Transformer+GRU	BTC/USD (harian)	1954.00	1419.97	0.0282	-
[26]	Hibrida CNN-LSTM	BTC/USD (per menit)	144	174	0.00323	-
[27]	Stacking Ensemble (LSTM & GRU)	BTC (per 30 menit)	173.40	88.74	0.0069	-
[28]	LSTM 2-Layer	BTC (per jam)	125.38	-	-	-
[29]	LSTM-Attention	BTC (per jam)	1210.71	816.25	0.048	-

Berdasarkan Tabel 4.4, model hibrida LSTM-Transformer yang diusulkan dalam penelitian ini menunjukkan kinerja yang sangat unggul. Dengan nilai RMSE 78.43 dan MAE 40.56, model ini menunjukkan hasil yang sangat baik, dengan nilai MAPE sebesar 0.000594 dan R<sup>2</sup> (0.999967) menegaskan bahwa model ini memiliki akurasi prediksi yang tinggi dan mampu menjelaskan hampir seluruh variabilitas pada data aktual. Saat membandingkan hasil ini dengan penelitian lain, pengaruh granularitas data menjadi sangat signifikan. Hasil penelitian ini tidak dapat dibandingkan secara langsung dengan studi seperti [25] yang menggunakan

data harian. Data per menit yang digunakan dalam penelitian ini memiliki volatilitas dan.

noise yang jauh lebih tinggi, sehingga pencapaian error yang sangat rendah menunjukkan kemampuan superior model dalam menangkap fluktuasi pasar jangka sangat pendek, sebuah tantangan yang jauh lebih kompleks. Jika dibandingkan dengan model serupa pada data frekuensi tinggi, keunggulan model ini semakin terlihat. Penelitian oleh [26] yang juga menggunakan data per menit dengan model hibrida CNN-LSTM, melaporkan RMSE sebesar 144. Hasil dari penelitian ini (RMSE 78.43) secara signifikan lebih baik, mengindikasikan bahwa arsitektur hibrida LSTM-Transformer lebih efektif dalam memodelkan data per menit. Demikian pula, model

Stacking Ensemble dari [27] yang memprediksi harga 30 menit ke depan, menghasilkan MAE sebesar 88.74, sementara model dalam penelitian ini mencapai MAE yang jauh lebih rendah (40.56). Metrik relatif seperti MAPE memungkinkan perbandingan yang lebih adil. Nilai MAPE penelitian ini (0.000594) jauh lebih rendah dibandingkan dengan MAPE dari penelitian lain seperti Mahdi et al. (0.0282) dan Ye et al. (0.0069), yang semakin memperkuat kesimpulan mengenai akurasi superior dari model yang diusulkan. Secara keseluruhan, data yang disajikan secara konsisten menempatkan model hibrida LSTM-Transformer dari penelitian ini sebagai salah satu model dengan performa terbaik, terutama dalam konteks prediksi frekuensi tinggi.

#### 4.6 Pembahasan

Temuan utama dari penelitian ini adalah bahwa arsitektur hibrida yang menggabungkan Long Short-Term Memory (LSTM) dan Transformer secara signifikan lebih unggul daripada model LSTM murni untuk memprediksi harga Bitcoin pada data per menit. Signifikansi utama dari penggunaan komponen Transformer terletak pada kemampuannya untuk mengatasi keterbatasan fundamental model sekuensial murni seperti LSTM dalam menghadapi data harga Bitcoin yang sangat volatil. Secara kualitatif, dampak signifikan ini terlihat dari kemampuan pemodelan yang lebih canggih. Model LSTM standar yang memproses data secara berurutan rentan kehilangan konteks dari data yang letaknya jauh di awal sekuens. Transformer, melalui mekanisme self-attention, secara signifikan memungkinkan model untuk menimbang hubungan antara semua titik data dalam satu jendela waktu secara bersamaan. Ini berarti model tidak hanya melihat tren menit-ke-menit, tetapi juga dapat mengidentifikasi level harga kritis (seperti support atau resistance) yang muncul 50 menit yang lalu dan masih relevan dengan pergerakan harga saat ini—sebuah cerminan yang lebih akurat dari dinamika pasar nyata. Kemampuan pemodelan yang superior ini juga terbukti secara kuantitatif melalui peningkatan akurasi. Perbandingan antara hasil Skenario 1 (LSTM Murni) pada Tabel 4.2 dan Skenario 2 (LSTM-Transformer) pada Tabel 4.3 menunjukkan adanya peningkatan performa pada metrik evaluasi. Meskipun peningkatannya terlihat kecil secara absolut (misalnya, MAPE turun dari 0.000643 menjadi 0.000594), dalam konteks peramalan keuangan frekuensi tinggi, penurunan tingkat kesalahan sekecil apapun memiliki signifikansi yang sangat tinggi karena dapat


memengaruhi keputusan trading dan profitabilitas secara nyata. Dengan demikian, signifikansi Transformer bukan hanya sekedar meningkatkan angka akurasi, tetapi secara fundamental mengubah cara model memahami konteks data, membuatnya lebih tangguh dalam menangani sifat non-linear dan non-stasioner dari harga Bitcoin.

Secara spesifik, komponen LSTM berperan dalam menjawab 'mengapa' pergerakan harga sesaat bisa terjadi. Dengan desain rekurensya, LSTM sangat efektif menangkap pola-pola momentum dan tren mikro dalam data per menit, misalnya mengenali bahwa kenaikan harga selama lima menit berturut-turut cenderung diikuti oleh kenaikan lebih lanjut. Ini adalah pemahaman sekuensial terhadap 'alur cerita' harga. Di sisi lain, komponen Transformer menjawab 'mengapa' konteks pasar yang lebih luas itu penting. Melalui mekanisme self-attention, Transformer mampu mengidentifikasi hubungan non-sekuensial yang signifikan. Sebagai contoh, ia dapat memberi bobot lebih pada level harga kritis yang terjadi 40 menit yang lalu yang ternyata memicu reaksi pasar 10 menit yang lalu—sebuah hubungan yang mungkin terlewatkan oleh LSTM. Dengan demikian, Transformer menangkap konteks pasar secara holistik. Sinergi inilah yang menjadi jawaban utama 'mengapa' model ini berhasil: prediksi tidak hanya didasarkan pada tren sesaat (kekuatan LSTM), tetapi juga diperkaya oleh pemahaman konteks pasar yang lebih luas dalam satu jam terakhir (kekuatan Transformer), menghasilkan prediksi yang lebih presisi dan stabil bahkan di tengah volatilitas tinggi.

Hasil penelitian ini memiliki beberapa implikasi penting, baik secara teoretis maupun praktis. Dari sisi teoretis, penelitian ini memperkuat argumen bahwa model hibrida deep learning merupakan pendekatan yang sangat menjanjikan untuk mengatasi masalah pada data deret waktu keuangan yang bersifat non-linear dan non-stasioner. Ini menunjukkan bahwa menggabungkan arsitektur dengan kekuatan komplementer dapat mengatasi keterbatasan yang dimiliki oleh model tunggal. Secara praktis, model dengan tingkat akurasi setinggi ini dapat menjadi alat bantu yang sangat berharga bagi investor atau trader jangka pendek (day trader) dalam membuat keputusan investasi. Prediksi harga per menit yang akurat dapat membantu dalam mengidentifikasi titik masuk (entry) dan keluar (exit) yang optimal, serta mendukung perumusan strategi algorithmic trading.

Meskipun hasil yang diperoleh sangat menjanjikan, penelitian ini memiliki sejumlah keterbatasan yang perlu diakui. Pertama, dataset yang digunakan terbatas hanya pada Bitcoin, sehingga generalisasi performa model pada aset kripto lain yang memiliki karakteristik pasar berbeda belum dapat dipastikan. Kedua, pelatihan model dibatasi hanya selama 10 epoch untuk menjaga efisiensi komputasi, padahal pelatihan dengan durasi yang lebih panjang berpotensi untuk lebih lanjut meningkatkan kinerja model. Keterbatasan lainnya adalah model belum diuji secara spesifik pada kondisi pasar yang ekstrem, seperti flash crash atau lonjakan harga mendadak yang dipicu oleh berita besar, sehingga ketahanannya (robustness) dalam skenario tersebut masih perlu diverifikasi lebih lanjut. Terakhir, lingkup penelitian ini berfokus pada pengembangan dan evaluasi akurasi model, dan tidak sampai

pada tahap implementasi dalam sebuah sistem trading otomatis atau aplikasi real-time.



## **BAB V**

### **PENUTUP**

#### **5.1. Kesimpulan**


Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi sebuah model prediksi harga Bitcoin dengan mengintegrasikan arsitektur Long Short-Term Memory (LSTM) dan Transformer. Berdasarkan analisis hasil dan pengujian yang telah dilakukan, dapat ditarik beberapa kesimpulan utama. Pertama, arsitektur hibrida paralel LSTM-Transformer terbukti mampu mengatasi keterbatasan yang ada pada model LSTM standar. Dengan menggabungkan kemampuan LSTM dalam memproses data sekuensial jangka pendek dan kekuatan Transformer dalam menangkap dependensi kontekstual jangka panjang melalui mekanisme self-attention, model yang diusulkan berhasil memodelkan data harga Bitcoin yang sangat volatil secara lebih komprehensif. Kedua, sinergi arsitektural antara cabang pemrosesan sekuensial LSTM dan cabang pemrosesan kontekstual Transformer secara efektif meningkatkan presisi dan stabilitas prediksi, terutama saat diterapkan pada dataset historis harga Bitcoin per menit (BTC/USD) yang digunakan dalam penelitian ini. Hal ini dibuktikan secara kuantitatif melalui metrik evaluasi pada data uji, di mana model hibrida pada konfigurasi optimal (batch size 128) berhasil mencapai nilai Mean Absolute Percentage Error (MAPE) sebesar 0.000594 dan Koefisien Determinasi ( $R^2$ ) sebesar 0.999967. Pencapaian ini menunjukkan bahwa model mampu menjelaskan hampir seluruh variabilitas dalam data harga Bitcoin yang sangat volatil, sekaligus menegaskan bahwa pendekatan hibrida secara

signifikan lebih unggul dalam memprediksi pergerakan harga pada dataset tersebut dibandingkan dengan model LSTM murni sebagai baseline.

## 5.2. Saran

Meskipun hasil penelitian menunjukkan kinerja yang sangat baik, masih terdapat beberapa ruang untuk pengembangan di masa depan. Berdasarkan keterbatasan yang teridentifikasi selama penelitian, beberapa saran untuk penelitian selanjutnya adalah sebagai berikut. Pertama, penelitian ini hanya berfokus pada dataset Bitcoin. Disarankan bagi penelitian selanjutnya untuk menguji model hibrida ini pada berbagai aset kripto lainnya. Hal ini penting untuk menilai konsistensi dan kemampuan generalisasi model di berbagai instrumen digital yang memiliki karakteristik pasar berbeda. Kedua, durasi pelatihan dalam penelitian ini dibatasi hanya 10 epoch. Terdapat peluang untuk meningkatkan akurasi lebih lanjut apabila dilakukan pelatihan dengan jumlah epoch yang lebih besar serta eksplorasi hyperparameter yang lebih mendalam. Hal ini dapat membantu model untuk menggali potensi penuh dari arsitektur hibrida yang kompleks. Ketiga, penelitian selanjutnya disarankan untuk menguji ketahanan (robustness) model pada kondisi pasar yang ekstrem, seperti saat terjadi flash crash atau lonjakan harga mendadak yang dipicu oleh berita fundamental. Pengujian ini diperlukan untuk memverifikasi seberapa andal model dapat bekerja dalam menghadapi situasi nyata yang lebih volatil dan tidak terduga. Terakhir, pengembangan di masa depan dapat diarahkan pada penerapan model ini dalam sebuah sistem real-time, seperti platform algorithmic trading atau decision support system bagi investor. Implementasi

praktis semacam ini akan mentransformasi nilai akademis dari penelitian menjadi kontribusi nyata bagi para pelaku pasar.



## DAFTAR PUSTAKA

- [1] Moch Farryz Rizkilloh and Sri 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, Feb. 2022, doi: 10.29207/resti.v6i1.3630.
- [2] Z. Chen, C. Li, and W. Sun, "Bitcoin price prediction using machine learning: An approach to sample dimension engineering," *J Comput Appl Math*, vol. 365, Feb. 2020, doi: 10.1016/j.cam.2019.112395.
- [3] E. Koo and G. Kim, "Centralized decomposition approach in LSTM for Bitcoin price prediction," *Expert Syst Appl*, vol. 237, 2024, doi: 10.1016/j.eswa.2023.121401.
- [4] S. M. Raju and A. M. Tarif, "Real-Time Prediction of BITCOIN Price using Machine Learning Techniques and Public Sentiment Analysis."
- [5] A. Dag, A. Z. Dag, A. Asilkalkan, S. Simsek, and D. Delen, "A Tree Augmented Naïve Bayes-based methodology for classifying cryptocurrency trends," *J Bus Res*, vol. 156, 2023, doi: 10.1016/j.jbusres.2022.113522.
- [6] S. Ranjan, P. Kayal, and M. Saraf, "Bitcoin Price Prediction: A Machine Learning Sample Dimension Approach," *Comput Econ*, vol. 61, no. 4, 2023, doi: 10.1007/s10614-022-10262-6.
- [7] G. Cohen, "Intraday trading of cryptocurrencies using polynomial auto regression," *AIMS Mathematics*, vol. 8, no. 4, 2023, doi: 10.3934/MATH.2023493.

- [8] J. Hohm, A. Heinemann, and A. Wiesmaier, "Towards a Maturity Model for Crypto-Agility Assessment," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2023, doi: 10.1007/978-3-031-30122-3\_7.
- [9] T. Li, "Prediction of Bitcoin Price Based on LSTM," in *Proceedings - 2022 International Conference on Machine Learning and Intelligent Systems Engineering, MLISE 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 19–23. doi: 10.1109/MLISE57402.2022.00012.
- [10] R. Sari, K. Kusriani, T. Hidayat, and T. Orphanoudakis, "Improved LSTM Method of Predicting Cryptocurrency Price Using Short-Term Data," *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, vol. 17, no. 1, p. 33, Feb. 2023, doi: 10.22146/ijccs.80776.
- [11] S. E. Parameswaran, V. Ramachandran, and S. Shukla, "Crypto Trend Prediction Based on Wavelet Transform and Deep Learning Algorithm," in *Procedia Computer Science*, Elsevier B.V., 2024, pp. 1179–1189. doi: 10.1016/j.procs.2024.04.112.
- [12] M. R. Kabir, D. Bhadra, M. Ridoy, and M. Milanova, "LSTM-Transformer-Based Robust Hybrid Deep Learning Model for Financial Time Series Forecasting," *Sci*, vol. 7, no. 1, Mar. 2025, doi: 10.3390/sci7010007.
- [13] Y. Li and W. Dai, "Bitcoin price forecasting method based on CNN-LSTM hybrid neural network model," *The Journal of Engineering*, vol. 2020, no. 13, pp. 344–347, Jul. 2020, doi: 10.1049/joe.2019.1203.

- [14] Moch Farryz Rizkilloh and Sri 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, Feb. 2022, doi: 10.29207/resti.v6i1.3630.
- [15] S. Singh, A. Pise, and B. Yoon, "Prediction of bitcoin stock price using feature subset optimization," *Heliyon*, vol. 10, no. 7, Apr. 2024, doi: 10.1016/j.heliyon.2024.e28415.
- [16] A. Rahmadeyan and Mustakim, "Long Short-Term Memory and Gated Recurrent Unit for Stock Price Prediction," in *Procedia Computer Science*, Elsevier B.V., 2024, pp. 204–212. doi: 10.1016/j.procs.2024.02.167.
- [17] M. D. Angelo, I. Fadhiilrahman, and Y. Purnama, "Comparative Analysis of ARIMA and Prophet Algorithms in Bitcoin Price Forecasting," in *Procedia Computer Science*, Elsevier B.V., 2023, pp. 490–499. doi: 10.1016/j.procs.2023.10.550.
- [18] A. Lewis, *Bitcoin on the Go: The Basics of Bitcoins and Blockchains*. Mango Media, 2022. [Online]. Available: <https://books.google.co.id/books?id=IXifEAAAQBAJ>
- [19] A. Glassner, *Deep Learning: A Visual Approach*. No Starch Press, 2021. [Online]. Available: <https://books.google.co.id/books?id=NgTyDwAAQBAJ>
- [20] T. Jo, *Machine Learning Foundations: Supervised, Unsupervised, and Advanced Learning*. Springer International Publishing, 2021. [Online]. Available: <https://books.google.co.id/books?id=0egdEAAAQBAJ>

- [21] E. Hvitfeldt and J. Silge, *Supervised Machine Learning for Text Analysis in R*. in Chapman & Hall/CRC Data Science Series. CRC Press, 2021. [Online]. Available: <https://books.google.co.id/books?id=rtVEEAAAQBAJ>
- [22] A. Vaswani *et al.*, "Attention is all you need," in *Advances in Neural Information Processing Systems*, 2017.
- [23] F. Lazzeri, *Machine Learning for Time Series Forecasting with Python*. Wiley, 2020. [Online]. Available: <https://books.google.co.id/books?id=m9sMEAAAQBAJ>
- [24] R. Bourday, I. Aatouchi, M. A. Kerroum, and A. Zaaouat, "Cryptocurrency Forecasting Using Deep Learning Models: A Comparative Analysis," *HighTech and Innovation Journal*, vol. 5, no. 4, pp. 1055–1067, Dec. 2024, doi: 10.28991/HIJ-2024-05-04-013.
- [25] E. Mahdi, C. Martin-Barreiro, and X. Cabezas, "A Novel Hybrid Approach Using an Attention-Based Transformer + GRU Model for Predicting Cryptocurrency Prices," *Mathematics*, vol. 13, no. 9, May 2025, doi: 10.3390/math13091484.
- [26] R. Zahilah, S. Hajar, and D. Stiawan, "CNN-LSTM Hybrid Model for Improving Bitcoin Price Prediction Results," 2023.
- [27] Z. Ye, Y. Wu, H. Chen, Y. Pan, and Q. Jiang, "A Stacking Ensemble Deep Learning Model for Bitcoin Price Prediction Using Twitter Comments on Bitcoin," *Mathematics*, vol. 10, no. 8, Apr. 2022, doi: 10.3390/math10081307.

- [28] X. Jiang, "Bitcoin Price Prediction Based on Deep Learning Methods," *Journal of Mathematical Finance*, vol. 10, no. 01, pp. 132–139, 2020, doi: 10.4236/jmf.2020.101009.
- [29] A. Ladhari and H. Boubaker, "Deep Learning Models for Bitcoin Prediction Using Hybrid Approaches with Gradient-Specific Optimization," *Forecasting*, vol. 6, no. 2, pp. 279–295, Jun. 2024, doi: 10.3390/forecast6020016.

