



PENERAPAN *DEEP LEARNING* UNTUK PREDIKSI BITCOIN MENGUNAKAN *HYPERPARAMETER TUNING BAYESIAN OPTIMIZATION*

TUGAS AKHIR

Diajukan Sebagai Salah Satu Syarat
untuk Memperoleh Gelar Sarjana Komputer pada
Program Studi Sistem Informasi

Oleh:

KIA KURNIAWAN

12250311811



UIN SUSKA RIAU

UIN SUSKA RIAU

FAKULTAS SAINS DAN TEKNOLOGI

UNIVERSITAS ISLAM NEGERI SULTAN SYARIF KASIM RIAU

PEKANBARU

2026

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

LEMBAR PERSETUJUAN

PENERAPAN *DEEP LEARNING* UNTUK PREDIKSI BITCOIN MENGUNAKAN *HYPERPARAMETER TUNING BAYESIAN OPTIMIZATION*


TUGAS AKHIR

Oleh:

KIA KURNIAWAN
12250311811

Telah diperiksa dan disetujui sebagai Laporan Tugas Akhir
di Pekanbaru, pada tanggal 23 Januari 2026

Ketua Program Studi


Angraini, S.Kom., M.Eng., Ph.D.
NIP. 198408212009012008

Pembimbing


Mustakim, ST., M.Kom.
NIP. 198807022025211003

LEMBAR PENGESAHAN

PENERAPAN *DEEP LEARNING* UNTUK PREDIKSI BITCOIN MENGUNAKAN *HYPERPARAMETER TUNING BAYESIAN* *OPTIMIZATION*

TUGAS AKHIR

Oleh:

KIA KURNIAWAN
12250311811


Telah dipertahankan di depan sidang dewan penguji
sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer
Fakultas Sains dan Teknologi Universitas Islam Negeri Sultan Syarif Kasim Riau
di Pekanbaru, pada tanggal 15 Januari 2026

Pekanbaru, 15 Januari 2026

Mengesahkan,


Dekan
Dr. Yuslenita Muda, S.Si., M.Sc.
NIP. 197701032007102001

Ketua Program Studi


Anraini, S.Kom., M.Eng., Ph.D.
NIP. 198408212009012008


DEWAN PENGUJI:

Ketua : Dr. Rice Novita, S.Kom., M.Kom.

Pembimbing : Mustakim, ST., M.Kom.

Anggota 1 : Inggih Permana, ST., M.Kom.

Anggota 2 : Tengku Khairil Ahsyar, S.Kom., M.Kom.



Lampiran Surat :

Nomor : Nomor 25/2021

Tanggal : 10 September 2021

SURAT PERNYATAAN

Saya yang bertandatangan di bawah ini:

Nama : Kia Kurniawan
NIM : 12250311811
Tempat/Tgl. Lahir : Dumai, 10 Juli 2004
Fakultas/Pascasarjana : Sains dan Teknologi
Prodi : Sistem Informasi

Judul Disertasi/Thesis/Skripsi/Karya Ilmiah lainnya*:

PENERAPAN DEEP LEARNING UNTUK PREDIKSI BITCOIN
MENGUNAKAN HYPERPARAMETER TUNING BAYESIAN
OPTIMIZATION

Menyatakan dengan sebenar-benarnya bahwa :

1. Penulisan Disertasi/Thesis/Skripsi/Karya Ilmiah lainnya* dengan judul sebagaimana tersebut di atas adalah hasil pemikiran dan penelitian saya sendiri.
2. Semua kutipan pada karya tulis saya ini sudah disebutkan sumbernya.
3. Oleh karena itu Disertasi/Thesis/Skripsi/Karya Ilmiah lainnya* saya ini, saya nyatakan bebas dari plagiat.
4. Apa bila dikemudian hari terbukti terdapat plagiat dalam penulisan Disertasi/Thesis/Skripsi/(Karya Ilmiah lainnya)* saya tersebut, maka saya bersedia menerima sanksi sesuai peraturan perundang-undangan.

Demikianlah Surat Pernyataan ini saya buat dengan penuh kesadaran dan tanpa paksaan dari pihak manapun juga.

Pekanbaru, 27 Januari 2026

embuat pernyataan



Kia Kurniawan
Kurniawan

NIM : 12250311811

* pilih salah satu sesuai jenis karya tulis



LEMBAR HAK ATAS KEKAYAAN INTELEKTUAL

Tugas Akhir yang tidak diterbitkan ini terdaftar dan tersedia di Perpustakaan Universitas Islam Negeri Sultan Syarif Kasim Riau adalah terbuka untuk umum, dengan ketentuan bahwa hak cipta ada pada penulis. Referensi kepustakaan diperkenankan dicatat, tetapi pengutipan atau ringkasan hanya dapat dilakukan atas izin penulis dan harus dilakukan mengikuti kaedah dan kebiasaan ilmiah serta menyebutkan sumbernya.

Penggandaan atau penerbitan sebagian atau seluruh Tugas Akhir ini harus memperoleh izin tertulis dari Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Sultan Syarif Kasim Riau. Perpustakaan dapat meminjamkan Tugas Akhir ini untuk anggotanya dengan mengisi nama, tanda peminjaman dan tanggal pinjam pada *form* peminjaman.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



LEMBAR PERNYATAAN

Dengan ini saya menyatakan bahwa Tugas Akhir ini merupakan hasil karya ilmiah yang disusun secara mandiri dan belum pernah diajukan untuk memperoleh gelar kesarjanaan di perguruan tinggi mana pun. Seluruh isi dan substansi yang tertuang dalam naskah ini merupakan hasil pemikiran, analisis, dan pengolahan penulis sendiri sesuai dengan kaidah akademik yang berlaku.

Sepanjang pengetahuan penulis, tidak terdapat karya atau pendapat orang lain yang digunakan dalam penyusunan Tugas Akhir ini tanpa mencantumkan sumber secara jelas dan benar. Setiap rujukan, baik berupa kutipan langsung maupun tidak langsung, telah disajikan sesuai dengan ketentuan penulisan ilmiah dan dicantumkan dalam daftar pustaka. Apabila di kemudian hari ditemukan adanya ketidaksesuaian terhadap pernyataan ini, penulis bersedia menerima sanksi sesuai dengan peraturan akademik yang berlaku.

Pekanbaru, 15 Januari 2026

Yang membuat pernyataan,

KIA KURNIAWAN
NIM. 12250311811

UIN SUSKA RIAU

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



LEMBAR PERSEMBAHAN

Dengan memohon ridha Allah SWT, penelitian ini saya persembahkan sebagai bentuk rasa syukur atas nikmat iman, ilmu, dan kesehatan yang telah diberikan sehingga proses akademik ini dapat diselesaikan dengan baik. Semoga karya ini menjadi amal jariyah dan bernilai ibadah dalam upaya menuntut serta mengamalkan ilmu pengetahuan.

Dengan penuh hormat dan kasih sayang, karya ini saya persembahkan kepada kedua orang tua tercinta, Ayah dan Ibu, yang senantiasa mengiringi setiap langkah dengan doa, kesabaran, dan pengorbanan tanpa pamrih. Semoga Allah SWT membalas seluruh kebaikan dan jerih payah mereka dengan pahala yang berlipat ganda serta keberkahan dalam hidup mereka.

Semoga penelitian ini membawa manfaat, menjadi bagian dari ikhtiar akademik yang diridai Allah SWT, serta dapat memberikan kontribusi positif bagi pengembangan ilmu pengetahuan dan kemaslahatan umat.

Pekanbaru, 23 Januari 2026

Peneliti,

KIA KURNIAWAN

NIM. 12250311811

UIN SUSKA RIAU

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

KATA PENGANTAR

Alhamdulillah Rabbil 'Alamin, segala puji hanya bagi Allah Subhanahu Wa Ta'ala atas limpahan rahmat, taufik, dan hidayah-Nya sehingga Peneliti dapat menuntaskan penyusunan Tugas Akhir ini. Shalawat beserta salam senantiasa tercurah kepada junjungan Nabi *Muhammad Shallallahu 'Alaihi Wa Sallam*, keluarga, serta para sahabat beliau. Dengan penuh rasa syukur, Tugas Akhir ini disusun sebagai salah satu persyaratan untuk memperoleh gelar Sarjana Komputer pada Program Studi Sistem Informasi Universitas Islam Negeri Sultan Syarif Kasim Riau. Berbagai bentuk dukungan, baik berupa bantuan materi, motivasi, maupun dorongan moral, telah Peneliti terima dari banyak pihak sepanjang proses penyusunan Tugas Akhir ini. Oleh karena itu, dengan penuh rasa hormat Peneliti menyampaikan terima kasih yang sebesar-besarnya kepada:

1. Ibu Prof. Dr. Hj. Leny Nofianti, MS., SE., M.Si., sebagai Rektor Universitas Islam Negeri Sultan Syarif Kasim Riau.
2. Ibu Dr. Yuslenita Muda, S.Si., M.Sc., sebagai Dekan Fakultas Sains dan Teknologi.
3. Ibu Angraini, S.Kom., M.Eng., Ph.D., sebagai Ketua Program Studi Sistem Informasi dan Dosen Pembimbing Akademik. Penulis mengucapkan terima kasih atas bimbingan, arahan, serta motivasi yang diberikan. Beliau tidak hanya meluangkan waktu dan tenaga dalam penyusunan laporan ini, tetapi juga telah menjadi pendengar yang baik bagi penulis selama menempuh pendidikan.
4. Ibu Dr. Rice Novita, S.Kom., M.Kom., sebagai Sekretaris Program Studi Sistem Informasi dan selaku Ketua Sidang yang telah meluangkan waktunya untuk melaksanakan Sidang Tugas Akhir peneliti dan memberikan arahan tambahan terkait penelitian ini.
5. Bapak M. Afdal, S.T., M.Kom., selaku Koordinator Tugas Akhir, atas segala dedikasi dan bantuan yang diberikan dalam mengoordinasikan pelaksanaan Tugas Akhir, serta kesabaran beliau dalam memberikan penjelasan terkait prosedur teknis yang penulis lalui.
6. Bapak Mustakim, ST., M.Kom., sebagai dosen pembimbing Kerja Praktek dan Tugas Akhir. Terima kasih atas segala waktu, tenaga, dan pikiran yang telah diluangkan untuk memberikan bimbingan, arahan, serta saran-saran yang sangat berharga selama penyusunan skripsi ini.
7. Bapak Inggih Permana, ST., M.Kom., sebagai dosen penguji pertama yang

Hak Cipta Dilindungi Undang-Undang

© Hal Cipta Dilindungi Undang-Undang

State Islamic University of Sultan Syarif Kasim Riau

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

telah memberikan kritik, saran, serta masukan yang sangat membangun dalam proses penyusunan dan penyempurnaan Tugas Akhir ini, sehingga peneliti dapat memperbaiki kekurangan dan memperoleh pemahaman yang lebih mendalam terhadap penelitian yang dilakukan.

8. Bapak Tengku Khairil Ahsyar, S.Kom., M.Kom., sebagai dosen penguji Kedua yang telah meluangkan waktu, memberikan penilaian, serta memberikan arahan dan masukan yang konstruktif demi penyempurnaan isi dan kualitas Tugas Akhir ini, sehingga hasilnya menjadi lebih baik dan bermakna.
9. Bapak dan Ibu Dosen Program Studi Sistem Informasi Fakultas Sains dan Teknologi Universitas Islam Negeri Sultan Syarif Kasim Riau yang telah berbagi ilmu bermanfaat serta memberikan motivasi sepanjang perkuliahan.
10. Orang tua Peneliti tercinta, Ayahanda Marjohan dan Ibunda Idayu yang senantiasa memberikan dukungan, doa, perhatian, dan kasih sayang tanpa henti, menjadi sumber kekuatan terbesar bagi Peneliti dalam menyelesaikan pendidikan Strata-1 ini. Semoga Allah membalas setiap kebaikan dan pengorbanan.
11. Teman seperjuangan di grup **Awal yang baru**, yang tidak bisa saya sebutkan satu per satu terimakasih atas support selama menyelesaikan perkuliahan ini.

Peneliti menyadari sepenuhnya bahwa Tugas Akhir ini tidak lepas dari kekurangan maupun kesalahan. Oleh sebab itu, kritik dan saran yang membangun sangat berarti bagi penyempurnaan karya ini. Kritik dan saran dapat disampaikan melalui e-mail 12250311811@students.uin-suska.ac.id. Besar harapan Peneliti agar Laporan Tugas Akhir ini dapat memberikan manfaat bagi pembaca. *Aamiin.*

Pekanbaru, 23 Januari 2026

Peneliti,

KIA KURNIAWAN
NIM. 12250311811



PENERAPAN *DEEP LEARNING* UNTUK PREDIKSI BITCOIN MENGUNAKAN *HYPERPARAMETER TUNING BAYESIAN OPTIMIZATION*

KIA KURNIAWAN
NIM: 12250311811

Tanggal Sidang: 15 Januari 2026
Periode Wisuda:

Program Studi Sistem Informasi
Fakultas Sains dan Teknologi
Universitas Islam Negeri Sultan Syarif Kasim Riau
Jl. Soebrantas, No. 155, Pekanbaru

ABSTRAK

Bitcoin dikenal dengan volatilitas harga yang ekstrem dan pola non-linear yang kompleks, menjadikannya tantangan tersendiri bagi model prediksi statistik konvensional. Penelitian ini bertujuan untuk menerapkan dan mengevaluasi kinerja arsitektur *Deep Learning*, meliputi *Long Short-Term Memory* (LSTM), *Gated Recurrent Unit* (GRU), N-BEATS, dan *Hybrid CNN-LSTM*, untuk memprediksi harga Bitcoin. Guna mengatasi permasalahan efisiensi dan bias pada penentuan parameter manual, penelitian ini mengimplementasikan metode *Bayesian Optimization* untuk melakukan *hyperparameter tuning* secara otomatis pada setiap model. Eksperimen dilakukan menggunakan data historis harian dari *Yahoo Finance* periode 2015 hingga 2025 dengan membandingkan skema pembagian data (80/10/10 dan 70/15/15) serta penggunaan *optimizer* Adam dan AdamW. Hasil evaluasi menunjukkan bahwa model LSTM dengan skema data 80/10/10 dan *optimizer* Adam menghasilkan tingkat kesalahan terendah dengan RMSE 2435.20 dan MAPE 2.00%. Sementara itu, model *Hybrid CNN-LSTM* dengan skema 70/15/15 menunjukkan kemampuan generalisasi terbaik dengan nilai R2 mencapai 0.99506. Penelitian ini menyimpulkan bahwa integrasi *Bayesian Optimization* efektif dalam menemukan konfigurasi optimal, serta mengidentifikasi adanya *trade-off* antara presisi jangka pendek dan stabilitas tren jangka panjang antar arsitektur model.

Kata Kunci: *Bayesian Optimization*, Bitcoin, *Deep Learning*, *Hybrid CNN-LSTM*, *Time Series Forecasting*

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Hak cipta milik UIN Suska Riau



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

APPLICATION OF DEEP LEARNING FOR BITCOIN PREDICTION USING BAYESIAN OPTIMIZATION HYPERPARAMETER TUNING

KIA KURNIAWAN
NIM: 12250311811

Date of Final Exam: January 15th 2026
Graduation Period:

Department of Information System
Faculty of Science and Technology
State Islamic University of Sultan Syarif Kasim Riau
Soebrantas Street, No. 155, Pekanbaru

ABSTRACT

Bitcoin is known for extreme price volatility and complex non-linear patterns, presenting a distinct challenge for conventional statistical prediction models. This research aims to apply and evaluate the performance of cutting-edge Deep Learning architectures, including Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), N-BEATS, and Hybrid CNN-LSTM, to predict Bitcoin prices. To address efficiency and bias issues in manual parameter determination, this study implements the Bayesian Optimization method to perform automatic hyperparameter tuning on each model. Experiments were conducted using daily historical data from Yahoo Finance for the period 2015 to 2025 by comparing data splitting schemes (80/10/10 and 70/15/15) and the use of Adam and AdamW optimizers. Evaluation results show that the LSTM model with the 80/10/10 data scheme and Adam optimizer produced the lowest error rate with an RMSE of 2435.20 and MAPE of 2.90%. Meanwhile, the Hybrid CNN-LSTM model with the 70/15/15 scheme demonstrated the best generalization capability with an R2 value reaching 0.99506666. This study concludes that the integration of Bayesian Optimization is effective in finding optimal configurations and identifies a trade-off between short-term precision and long-term trend stability among the model architectures.

Keywords: *Bayesian Optimization, Bitcoin, Deep Learning, hybrid CNN-LSTM, Time Series Forecasting*

UIN SUSKA RIAU

DAFTAR ISI

LEMBAR PERSETUJUAN	ii
LEMBAR PENGESAHAN	iii
LEMBAR HAK ATAS KEKAYAAN INTELEKTUAL	iv
LEMBAR PERNYATAAN	v
LEMBAR PERSEMBAHAN	vi
KATA PENGANTAR	vii
ABSTRAK	ix
ABSTRACT	x
DAFTAR ISI	xi
DAFTAR GAMBAR	xv
DAFTAR TABEL	xvii
DAFTAR SINGKATAN	xix
PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Perumusan Masalah	3
1.3 Batasan Masalah	4
1.4 Tujuan	4
1.5 Manfaat	5
1.6 Sistematika Penulisan	5
LANDASAN TEORI	7
2.1 Bitcoin	7
2.2 <i>Cryptocurrency</i>	8
2.3 Volatilitas Pasar Kripto	8
2.4 Investasi	9
2.5 Risiko Keuangan	10

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

2.6	<i>Forecasting pada Pasar Keuangan</i>	10
2.7	<i>Time Series</i>	11
2.8	<i>Deep Learning</i>	11
2.9	<i>Long Short-Term Memory</i>	12
2.10	<i>Gated Recurrent Unit</i>	13
2.11	<i>Neural Basis Expansion Analysis for Time Series</i>	14
2.12	<i>Hybrid CNN-LSTM</i>	15
2.13	<i>Bayesian Optimization</i>	16
2.14	<i>Optimizer</i>	17
2.15	<i>Adaptive Moment Estimation</i>	18
2.16	<i>Adam With Weight Decay</i>	19
2.17	<i>Mean Squared Error (MSE)</i>	19
2.18	<i>Root Mean Squared Error (RMSE)</i>	20
2.19	<i>Mean Absolute Error (MAE)</i>	20
2.20	<i>Mean Absolute Percentage Error (MAPE)</i>	21
2.21	<i>R-Square (R2)</i>	21
2.22	Penelitian Terdahulu	22
3	METODOLOGI PENELITIAN	24
3.1	Tahap Perencanaan	24
3.1.1	Identifikasi Masalah	24
3.1.2	Menentukan Tujuan	25
3.1.3	Batasan Masalah	25
3.1.4	Studi Pustaka	25
3.2	Tahap Persiapan Data	26
3.2.1	Pengumpulan Data	26
3.2.2	Preprocessing Data	26
3.2.3	Pembagian Data	26
3.2.4	Normalisasi Data	27
3.3	Tahap Melatih Model	27
3.3.1	Hyperparameter Bayesian Optimization	27
3.4	Tahap Analisis dan Hasil	31
3.4.1	Evaluasi Model	31
3.4.2	Discussion	31



4	ANALISA DAN PERANCANGAN	33
© Hak cipta milik UIN Suska Riau	4.1 Analisa dan Identifikasi Kebutuhan Penelitian	33
	4.1.1 Lingkungan Implementasi	33
	4.1.2 Analisa Kebutuhan <i>Library Python</i>	33
	4.2 Pengumpulan Data	34
	4.3 Preprocessing Data	35
	4.4 Normalisasi Data	35
	4.5 Pembagian Data	36
	4.6 <i>Long Short-Term Memory</i>	37
	4.6.1 <i>Best Hyperparameter LSTM</i>	37
	4.6.2 Evaluasi Model LSTM	38
	4.6.3 Perbandingan Aktual dan Prediksi LSTM	39
	4.6.4 Prediksi 1 Tahun ke depan LSTM	42
	4.7 <i>Gated Recurrent Unit</i>	45
	4.7.1 <i>Best Hyperparameter GRU</i>	45
	4.7.2 Evaluasi Model GRU	47
	4.7.3 Perbandingan Aktual dan Prediksi GRU	48
	4.7.4 Prediksi 1 Tahun ke depan GRU	51
	4.8 <i>Neural Basis Expansion Analysis for Interpretable Time Series</i>	54
	4.8.1 <i>Best hyperparameter N-BEATS</i>	54
	4.8.2 Evaluasi Model N-BEATS	56
	4.8.3 Perbandingan Aktual dan Prediksi N-BEATS	58
	4.8.4 Prediksi 1 Tahun ke depan N-BEATS	60
	4.9 Hybrid CNN-LSTM	64
	4.9.1 <i>Best Hyperparameter Hybrid CNN-LSTM</i>	64
	4.9.2 Evaluasi Model Hybrid CNN-LSTM	65
	4.9.3 Perbandingan Aktual dan Prediksi Hybrid CNN-LSTM	67
	4.9.4 Prediksi 1 Tahun ke depan Hybrid CNN-LSTM	69
	4.10 <i>Discussion</i>	73
	4.10.1 Temuan Utama	73
	4.10.2 Perbandingan Hasil Temuan Penelitian Terdahulu	74
	PENUTUP	76
	5.1 Kesimpulan	76
	5.1.1 Pembangunan Model dan Dependensi Data	76
	5.1.2 Peran <i>Bayesian Optimization</i>	76




Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

5.1.3	Efektivitas <i>Decoupled Weight Deecay</i> pada Stabilitas	76
5.1.4	Implementasi Strategis dan Proyeksi	77
5.1.5	Arsitektur Paling Optimal	77
5.2	Saran	77

DAFTAR PUSTAKA

LAMPIRAN A	<i>YAHOO FINANCE</i>	A - 1
LAMPIRAN B	SOURCE CODE <i>BAYESIAN OPTIMIZATION</i>	B - 1
LAMPIRAN C	SIARAN PERS	C - 1



UIN SUSKA RIAU

DAFTAR GAMBAR

© Hak cipta milik UIN Suska Riau

State Islamic University of Sultan Syarif Kasim Riau

Hak Cipta Dilindungi Undang-Undang

1. Diarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Diarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

2.1	Bitcoin	7
2.2	Arsitektur LSTM	12
2.3	Arsitektur Algoritma GRU	13
2.4	Arsitektur Algoritmat N-BEATS	14
2.5	Arsitektur Algoritma Hybrid CNN-LSTM	15
3.1	Metodologi Penelitian	24
4.1	Hasil Visual Aktual dan Prediksi LSTM 80/10/10 <i>Optimizer</i> Adam	40
4.2	Hasil Visual Aktual dan Prediksi LSTM 80/10/10 <i>Optimizer</i> AdamW	40
4.3	Hasil Visual Aktual dan Prediksi LSTM 70/15/15 <i>Optimizer</i> Adam	41
4.4	Hasil Visual Aktual dan Prediksi LSTM 70/15/15 <i>Optimizer</i> AdamW	41
4.5	Prediksi 1 Tahun Ke depan LSTM 80/10/10 Adam	42
4.6	Prediksi 1 Tahun ke Depan LSTM 80/10/10 AdamW	43
4.7	Prediksi 1 Tahun ke Depan LSTM 70/15/15 Adam	44
4.8	Prediksi 1 Tahun ke Depan LSTM 70/15/15 AdamW	44
4.9	Hasil Visual Aktual dan Prediksi GRU 80/10/10 <i>Optimizer</i> Adam .	49
4.10	Hasil Visual Aktual dan Prediksi GRU 80/10/10 <i>Optimizer</i> AdamW	49
4.11	Hasil Visual Aktual dan Prediksi GRU 70/15/15 <i>Optimizer</i> AdamW	50
4.12	Hasil Visual Aktual dan Prediksi GRU 70/15/15 <i>Optimizer</i> AdamW	50
4.13	Prediksi 1 Tahun ke Depan GRU 80/10/10 Adam	51
4.14	Prediksi 1 Tahun ke Depan GRU 80/10/10 AdamW	52
4.15	Prediksi 1 Tahun ke Depan GRU 70/15/15 Adam	53
4.16	Prediksi 1 Tahun ke Depan GRU 70/15/15 AdamW	53
4.17	Hasil Visual Aktual dan Prediksi N-BEATS 80/10/10 <i>Optimizer</i> Adam	58
4.18	Hasil Visual Aktual dan Prediksi N-BEATS 80/10/10 <i>Optimizer</i> AdamW	58
4.19	Hasil Visual Aktual dan Prediksi N-BEATS 70/15/15 <i>Optimizer</i> Adam	59
4.20	Hasil Visual Aktual dan Prediksi N-BEATS 70/15/15 <i>Optimizer</i> AdamW	60
4.21	Prediksi 1 Tahun ke Depan N-BEATS 80/10/10 Adam	61
4.22	Prediksi 1 Tahun ke Depan N-BEATS 80/10/10 AdamW	61
4.23	Prediksi 1 Tahun ke Depan N-BEATS 70/15/15 Adam	62



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

4.24	Prediksi 1 Tahun ke Depan N-BEATS 70/15/15 AdamW	63
4.25	Perbandingan Aktual dan Preediksi Model Hybrid CNN-LSTM 80/10/10 Adam	67
4.26	Perbandingan Aktual dan Preediksi Model Hybrid CNN-LSTM 80/10/10 AdamW	67
4.27	Perbandingan Aktual dan Prediksi Model Hybrid CNN-LSTM 70/15/15 Adam	68
4.28	Perbandingan Aktual dan Prediksi Model Hybrid CNN-LSTM 70/15/15 AdamW	69
4.29	Prediksi 1 Tahun ke depan Hybrid CNN-LSTM 80/10/10 Adam . .	70
4.30	Prediksi 1 Tahun ke depan Hybrid CNN-LSTM 80/10/10 AdamW .	70
4.31	Prediksi 1 Tahun ke Depan Hybrid CNN-LSTM 70/15/15 Adam . .	71
4.32	Prediksi 1 Tahun ke Depan Hybrid CNN-LSTM 70/15/15 AdamW .	72
A.1	Yahoo Finance - Bitcoin	A - 1
B.1	Algoritma LSTM - <i>Bayesian Optimization</i>	B - 1
B.2	Algoritma GRU - <i>Bayesian Optimization</i>	B - 2
B.3	Algoritma N-BEATS <i>Block</i>	B - 3
B.4	Algoritma N-BEATS - <i>Bayesian Optimization</i>	B - 4
B.5	Algoritma <i>Hybrid CNN-LSTM - Bayesian Optimization</i>	B - 5
C.1	Siaran Pers	C - 1
C.2	Siaran Pers	C - 2

DAFTAR TABEL

© Hak cipta milik UIN Suska Riau

State Islamic University of Sultan Syarif Kasim Riau

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.


3.1	Rentang Hyperparameter dan Konfigurasinya pada Model Deep Learning	27
4.1	Spesifikasi Perangkat Keras dan Perangkat Lunak	33
4.2	Daftar Library yang Digunakan dalam Penelitian	34
4.3	Data Awal Bitcoin	35
4.4	Data Harga Penutupan Bitcoin	35
4.5	Data Harga Bitcoin dan Hasil Normalisasi	36
4.6	Pembagian Data 80/10/10	36
4.7	Pembagian Data 70/15/15	36
4.8	Perbandingan Best <i>Hyperparameter</i> Model LSTM 80/10/10	37
4.9	Perbandingan Best <i>Hyperparameter</i> Model LSTM 70/15/15	37
4.10	Perbandingan Evaluasi Model LSTM 80/10/10	38
4.11	Perbandingan Evaluasi Model LSTM 70/15/15	39
4.12	Perbandingan Hasil Visual Aktual dan Prediksi LSTM 80/10/10	40
4.13	Perbandingan Hasil Visual Aktual dan Prediksi LSTM 70/15/15	42
4.14	Prediksi Bitcoin 1 Tahun ke Depan LSTM 80/10/10	43
4.15	Prediksi Bitcoin 1 Tahun ke Depan LSTM 70/15/15	45
4.16	Perbandingan Best <i>Hyperparameter</i> Model GRU 80/10/10	46
4.17	Perbandingan Best <i>Hyperparameter</i> Model GRU 70/15/15	46
4.18	Perbandingan Evaluasi Model GRU 80/10/10	47
4.19	Perbandingan Kinerja Model GRU 70/15/15	48
4.20	Perbandingan Hasil Visual Aktual dan Prediksi GRU 80/10/10	49
4.21	Perbandingan Hasil Visual Aktual dan Prediksi GRU 70/15/15	51
4.22	Prediksi 1 Tahun ke Depan GRU 80/10/10	52
4.23	Perbandingan Hasil Prediksi Harga Bitcoin GRU 70/15/15	53
4.24	Perbandingan Best <i>Hyperparameter</i> Model N-BEATS 80/10/10	55
4.25	Perbandingan Best <i>Hyperparameter</i> Model N-BEATS 70/15/15	55
4.26	Perbandingan Hasil Evaluasi Model N-BEATS 80/10/10	56
4.27	Perbandingan Hasil Evaluasi Model N-BEATS 70/15/15	57
4.28	Perbandingan Hasil Visual Aktual dan Prediksi N-BEATS 80/10/10	59
4.29	Perbandingan Hasil Visual Aktual dan Prediksi N-BEATS 70/15/15	60
4.30	Prediksi 1 Tahun ke Depan Model N-BEATS 80/10/10	61
4.31	Prediksi 1 Tahun ke Depan Model N-BEATS 70/15/15	63



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

4.32 Perbandingan Best <i>Hyperparameter</i> Model Hybrid CNN-LSTM	
80/10/10	64
4.33 Perbandingan Best <i>Hyperparameter</i> Model CNN-LSTM 70/15/15 .	65
4.34 Perbandingan Evaluasi Model Hybrid CNN-LSTM 80/10/10	66
4.35 Perbandingan Evaluasi Model Hybrid CNN-LSTM 70/15/15	66
4.36 Perbandingan Hasil Visual Aktual dan Prediksi Hybrid CNN-LSTM (Bayesian Search)	68
4.37 Perbandingan Hasil Visual Aktual dan Prediksi Hybrid CNN-LSTM 70/15/15	69
4.38 Perbandingan Prediksi 1 Tahun ke Depan Hybrid CNN-LSTM 80/10/10	70
4.39 Perbandingan Prediksi 1 Tahun ke Depan Hybrid CNN-LSTM 70/15/15	72



UIN SUSKA RIAU



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

DAFTAR SINGKATAN

AI	Artificial Intelligence
API	Application Programming Interface
ARIMA	Autoregressive Integrated Moving Average
BTC	Bitcoin
CNN	Convolutional Neural Network
DeFi	Decentralized Finance
GRU	Gated Recurrent Unit
GARCH	Generalized Autoregressive Conditional Heteroskedasticity
LSTM	Long Short-Term Memory
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
ML	Machine Learning
MSE	Mean Squared Error
N-BEATS	Neural Basis Expansion Analysis for Time Series
OJK	Otoritas Jasa Keuangan
PoW	Proof-of-Work
RNN	Recurrent Neural Network
R^2	Coefficient of Determination
RMSE	Root Mean Squared Error
VAR	Vector Autoregression



BAB 1

PENDAHULUAN

1.1 Latar Belakang

Bitcoin telah mengukuhkan posisinya sebagai aset digital dengan kapitalisasi pasar terbesar secara *global*, namun dinamikanya pada periode 2024 hingga 2025 menunjukkan tingkat volatilitas yang *ekstrem* (Nakamoto, 2008; Adekunle, 2024). Data pasar memperlihatkan bahwa volume transaksi *on-chain global* mencapai puncaknya pada akhir 2024, didorong oleh pertumbuhan signifikan di kawasan Asia Pasifik yang mencatat kenaikan nilai transaksi sebesar 69% *year-on-year* pada pertengahan 2025 (Dubey dan Enke, 2025). Meskipun adopsi institusional semakin matang, pasar kripto tetap rentan terhadap fluktuasi harga yang tajam, menjadikannya data deret waktu yang sangat non-linear dan *stochastic* (Huang dkk., 2024; Wang dkk., 2023). Kompleksitas pergerakan harga ini menegaskan bahwa instrumen investasi aset kripto memerlukan pendekatan analisis risiko yang presisi secara teknis, mengingat metode peramalan konvensional sering kali gagal menangkap pola volatilitas *ekstrem* tersebut (Leong dkk., 2025).

Dalam konteks nasional, Indonesia menghadapi fase krusial dengan pertumbuhan pasar yang eksplosif. Data terbaru dari Badan Pengawas Perdagangan Berjangka Komoditi (Bappebti) mencatat lonjakan aktivitas pasar yang luar biasa, di mana nilai transaksi aset kripto sepanjang Januari hingga November 2024 menembus angka Rp556,53 triliun (Badan Pengawas Perdagangan Berjangka Komoditi (Badan Pengawas Perdagangan Berjangka Komoditi (Bappebti), 2024). Angka ini merepresentasikan pertumbuhan fantastis sebesar 356,16% dibandingkan periode yang sama pada tahun sebelumnya yang sebesar Rp122 triliun. Dengan jumlah pasangan terdaftar yang telah mencapai 22,1 juta jiwa pada November 2024, partisipasi publik di pasar ini sangat masif. Namun, antusiasme ini berhadapan dengan transisi regulasi fundamental pada tahun 2025, yakni peralihan wewenang pengawasan dari Bappebti ke Otoritas Jasa Keuangan (OJK) (Alhakim dan Tantinin, 2024). Dalam lanskap regulasi baru yang menuntut standar perlindungan konsumen lebih ketat ini, pengembangan model prediksi yang akurat bukan lagi sekadar kebutuhan teknis, melainkan urgensi strategis untuk memitigasi risiko bagi jutaan investor ritel Indonesia di tengah volatilitas pasar (Bajwa, 2025).

Guna mengatasi tantangan prediksi pada data yang sangat fluktuatif tersebut, pendekatan *Deep Learning* telah terbukti lebih unggul secara teknis dibandingkan model ekonometrika tradisional seperti ARIMA (Sezer dkk., 2020). Liter-

1. Diarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Diarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

atur terkini menunjukkan bahwa arsitektur berbasis jaringan saraf mampu mengekstraksi pola tersembunyi dan dependensi temporal dari data historis secara otomatis. Di antara berbagai arsitektur yang ada, algoritma *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) telah menjadi standar emas dalam analisis deret waktu (Rahmadeyan dan Mustakim, 2024). Studi empiris oleh (Bagheri dan Giudici, 2025) menemukan bahwa LSTM dan GRU secara konsisten menjadi model yang paling akurat dibandingkan metode *Machine Learning* klasik, di mana GRU secara khusus unggul dalam memberikan tingkat pengembalian investasi *cumulative return* yang maksimal karena efisiensi komputasinya.

Selain model *Recurrent Neural Networks* (RNN) standar, pengembangan arsitektur *Hybrid* menjadi pendekatan alternatif untuk meningkatkan akurasi prediksi. Model *Hybrid CNN-LSTM* mengintegrasikan keunggulan *Convolutional Neural Network* (CNN) dalam mengekstraksi fitur spasial yang relevan dari data input dengan kemampuan LSTM dalam memodelkan ketergantungan jangka panjang (Xifeng Guo dkk., 2020; Shawon dkk., 2025). Penelitian Li dan Dai (2020) membuktikan bahwa model hibrida ini mampu mengurangi *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE) secara signifikan dibandingkan model tunggal, serta memberikan prediksi arah pergerakan harga yang lebih presisi. Hal ini mengindikasikan bahwa kombinasi ekstraksi fitur dan pemrosesan sekuensial sangat efektif untuk data Bitcoin yang kompleks.

Perkembangan teknologi *Deep Learning* juga melahirkan arsitektur mutakhir seperti *Neural Basis Expansion Analysis for Time Series* (N-BEATS), yang menawarkan pendekatan berbeda melalui struktur blok berbasis *trend* dan *seasonality* (Kasprzyk dkk., 2025). Asmat dan Maiyama (2025) menunjukkan bahwa N-BEATS memiliki keunggulan performa yang superior dibandingkan LSTM maupun Regresi Linear, dengan capaian skor determinasi (R^2) mencapai 0.9998. Berbeda dengan model RNN yang sering dianggap sebagai *black box*, N-BEATS menawarkan transparansi melalui dekomposisi sinyal yang jelas, menjadikannya kandidat kuat untuk memenuhi kebutuhan analisis pasar modern yang menuntut keseimbangan antara akurasi tinggi dan kemampuan interpretasi.

Meskipun algoritma-algoritma tersebut (LSTM, GRU, CNN-LSTM, dan N-BEATS) menawarkan potensi performa yang tinggi, penerapannya sering kali terkendala oleh sensitivitas terhadap *hyperparameter*. Model *Deep Learning* kerap dipandang sebagai "kotak hitam" di mana performanya sangat bergantung pada konfigurasi parameter seperti *learning rate*, jumlah layer, dan momentum (Bao dkk., 2025). Metode penentuan *parameter* secara manual *trial and error* atau penggu-



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

naan *Grid Search* sering kali tidak efisien secara komputasional karena memerlukan evaluasi kombinasi yang sangat banyak dan berisiko gagal menemukan konfigurasi optimal global (Zulfiqar dkk., 2022). Inefisiensi ini dapat menyebabkan bias dalam evaluasi model, di mana kinerja yang suboptimal bukan disebabkan oleh arsitektur model, melainkan oleh parameterisasi yang kurang tepat.

Untuk mengatasi kesenjangan metodologis tersebut, penerapan teknik optimasi otomatis menjadi solusi yang esensial. *Bayesian Optimization* menawarkan pendekatan probabilistik yang lebih cerdas dibandingkan pencarian acak *Random Search* dengan memanfaatkan *Teorema Bayes* untuk membangun model dari fungsi tujuan berdasarkan evaluasi sebelumnya (Garrido-Merchán dan Hernández-Lobato, 2020). Penelitian Victoria dan Maragatham (2021) membuktikan bahwa metode ini mampu menemukan global optima dengan jumlah iterasi yang jauh lebih sedikit, serta secara signifikan mengurangi tingkat kesalahan validasi pada model *Deep Learning* (Zulfiqar dkk., 2022). Efisiensi ini tidak hanya berdampak pada akurasi, tetapi juga menjawab aspek etis dan efisiensi *Green AI* dengan meminimalkan biaya komputasi dan energi yang diperlukan untuk pelatihan model.

Berdasarkan uraian di atas, penelitian ini bertujuan untuk menerapkan dan mengevaluasi kinerja algoritma LSTM, GRU, N-BEATS, dan Hybrid CNN-LSTM dalam memprediksi harga Bitcoin. Analisis komparatif ini didorong oleh kebutuhan untuk mengidentifikasi arsitektur yang paling adaptif terhadap karakteristik pasar kripto yang unik, di mana GRU menawarkan efisiensi, CNN-LSTM menawarkan ekstraksi fitur mendalam, dan N-BEATS menawarkan interpretabilitas struktur data (Boozary dkk., 2025). Oleh karena itu, integrasi komprehensif keempat algoritma tersebut dengan metode *hyperparameter tuning* berbasis *Bayesian Optimization* menjadi langkah krusial. Pendekatan ini memastikan bahwa perbandingan kinerja antar model dilakukan dalam kondisi optimal yang setara *fair comparison*, sehingga menghasilkan model prediksi yang tidak hanya akurat dan tangguh, tetapi juga efisien secara komputasional dan dapat dipertanggungjawabkan secara ilmiah.

1.2 Perumusan Masalah

Berdasarkan kompleksitas pergerakan harga Bitcoin yang bersifat *non-linier* dan volatil serta meningkatnya penggunaan *deep learning* sebagai alat prediksi deret waktu keuangan, permasalahan utama dalam penelitian ini adalah bagaimana merancang dan mengevaluasi model prediksi harga Bitcoin yang akurat, stabil, dan efisien secara komputasi dengan memanfaatkan berbagai arsitektur *deep learning modern*. Secara khusus, penelitian ini berfokus pada bagaimana kinerja al-



goritma LSTM, GRU, N-BEATS, dan *hybrid* CNN-LSTM dalam memprediksi harga Bitcoin ketika seluruh model dioptimalkan menggunakan *hyperparameter tuning Bayesian Optimization*, serta sejauh mana pendekatan tersebut mampu meningkatkan akurasi prediksi pada berbagai metrik evaluasi dan waktu prediksi.

1.3 Batasan Masalah

Batasan masalah tugas akhir ini adalah:

1. Penelitian ini dibatasi pada prediksi harga Bitcoin (BTC) sebagai satu-satunya aset *cryptocurrency* yang dianalisis.
2. Data yang digunakan merupakan data historis harga Bitcoin yang bersumber dari platform *Yahoo Finance*, dengan rentang waktu tertentu sesuai ketersediaan data penelitian.
3. Variabel input penelitian dibatasi pada data harga Bitcoin berbasis deret waktu, tanpa memasukkan indikator makroekonomi, sentimen media sosial, atau data fundamental lainnya.
4. Metode prediksi yang digunakan dalam penelitian ini terbatas pada algoritma *deep learning*, yaitu *Long Short-Term Memory* (LSTM), *Gated Recurrent Unit* (GRU), N-BEATS, dan *hybrid* CNN-LSTM.
5. Proses optimasi model hanya difokuskan pada *hyperparameter* tuning menggunakan metode *Bayesian Optimization*, tanpa membandingkan secara langsung dengan metode tuning lain.
6. Evaluasi kinerja model dibatasi pada metrik kesalahan prediksi yang umum digunakan dalam peramalan deret waktu keuangan, seperti MSE, RMSE, MAE, MAPE dan R2.
7. Penelitian ini tidak membahas aspek implementasi sistem perdagangan otomatis, manajemen portofolio, maupun analisis keuntungan dan risiko investasi secara langsung.
8. Lingkup analisis difokuskan pada evaluasi akurasi dan stabilitas model prediksi, tanpa melakukan pengujian dampak kebijakan regulasi atau peristiwa eksternal terhadap harga Bitcoin.

1.4 Tujuan

Tujuan tugas akhir ini adalah:

1. Membangun model prediksi harga Bitcoin berbasis *deep learning* menggunakan arsitektur LSTM, GRU, N-BEATS, dan *Hybrid* CNN-LSTM.
2. Mengimplementasikan *Bayesian Optimization* sebagai metode *hyperparameter* tuning utama pada masing-masing arsitektur *deep learning*.



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

3. Menganalisis dan membandingkan kinerja prediksi keempat model *deep learning* berdasarkan metrik evaluasi kesalahan yang relevan.
4. Mengevaluasi pengaruh *hyperparameter* tuning *Bayesian Optimization* terhadap peningkatan akurasi dan stabilitas prediksi harga Bitcoin.
5. Mengidentifikasi arsitektur *deep learning* yang paling optimal untuk prediksi harga Bitcoin dalam kerangka tuning.

Manfaat

Manfaat tugas akhir ini adalah:

1. Penelitian ini memberikan bukti empiris mengenai efektivitas *Bayesian Optimization* sebagai solusi atas inefisiensi metode konvensional *Grid Search* atau *Trial and Error* dalam pelatihan model *Deep Learning*. Secara spesifik, penelitian ini berkontribusi pada literatur komputasi dengan menunjukkan bagaimana pendekatan probabilistik dapat menemukan lebih cepat dan efisien pada ruang pencarian parameter yang kompleks.
2. Penelitian ini memperkaya literatur prediksi deret waktu *finansial* dengan menyajikan evaluasi perbandingan yang adil *fair comparison* antara arsitektur berbasis *Recurrent* (LSTM, GRU), arsitektur *Hybrid* (CNN- LSTM), dan arsitektur berbasis *Basis Expansion* (N-BEATS). Hal ini mengisi celah penelitian terdahulu yang sering kali hanya membandingkan model tunggal tanpa standarisasi metode optimasi.
3. Bagi pengembang *sistem AI* di industri *finansial*, penerapan *Bayesian Optimization* dalam penelitian ini menawarkan panduan praktis untuk membangun model berkinerja tinggi dengan biaya komputasi yang lebih rendah. Hal ini mendukung prinsip efisiensi energi *Green AI*, yang krusial bagi industri yang memproses data transaksi bervolume besar secara *real-time*.

Sistematika Penulisan

Sistematika penulisan laporan adalah sebagai berikut:

BAB 1. PENDAHULUAN

Bab ini menjelaskan latar belakang, rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian dan sistematika penelitian dalam penulisan tugas akhir.

BAB 2. LANDASAN TEORI

Bab ini menyajikan teori-teori yang berasal dari jurnal ilmiah, buku dan *proceeding* yang digunakan sebagai tinjauan dalam penulisan tugas akhir.

BAB 3. METODOLOGI PENELITIAN



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Bab ini memaparkan alur penelitian mulai dari tahap perencanaan penelitian hingga tahap analisis.

BAB 4. ANALISA DAN PERANCANGAN

Bab ini menyajikan hasil penelitian yang telah dilakukan secara sistematis dan komprehensif. Pembahasan difokuskan pada pemaparan hasil pengolahan data, analisis kinerja model yang digunakan, serta interpretasi temuan utama berdasarkan metode yang telah dirancang pada bab sebelumnya. Selain itu, bab ini juga menguraikan perbandingan antara nilai prediksi dan data aktual guna menilai tingkat akurasi dan reliabilitas model, sehingga dapat memberikan gambaran yang jelas mengenai pencapaian tujuan penelitian.

BAB 5. PENUTUP


Bab ini menyajikan kesimpulan yang diperoleh dari seluruh rangkaian penelitian yang telah dilakukan, mulai dari tahap perancangan metodologi, pengolahan data, hingga analisis hasil prediksi. Selain itu, bab ini juga memuat saran yang ditujukan bagi peneliti selanjutnya maupun pihak terkait, sebagai rekomendasi pengembangan penelitian di masa depan, baik dari sisi metode, data, maupun ruang lingkup analisis agar diperoleh hasil prediksi yang lebih akurat, stabil, dan komprehensif.

BAB 2

LANDASAN TEORI

© Hak cipta milik UIN Suska Riau

2.1 Bitcoin



Gambar 2.1. Bitcoin

Bitcoin merupakan mata uang digital pertama yang diperkenalkan oleh Satoshi Nakamoto pada tahun 2009, berbasis teknologi *blockchain* yang memungkinkan transaksi dicatat secara desentralisasi, transparan, dan aman tanpa perantara lembaga keuangan (Nakamoto, 2008; Shukla dkk., 2024). Karakteristik utamanya meliputi suplai terbatas sebesar 21 juta unit, mekanisme *peer-to-peer*, serta sistem konsensus melalui *proof-of-work* (Soria dkk., 2023). Keunikan inilah yang menjadikan Bitcoin berbeda dengan mata uang fiat konvensional, sekaligus mendorongnya menjadi pionir dalam ekosistem *cryptocurrency modern* (R. Kumar dkk., 2025; Gautami Tripathi, 2023).

Seiring waktu, Bitcoin berkembang menjadi salah satu aset digital paling dominan di pasar global. Kapitalisasi pasarnya mencapai ratusan miliar dolar AS, menjadikannya aset kripto dengan tingkat adopsi dan likuiditas tertinggi dibandingkan ribuan mata uang kripto lainnya (Ballis dkk., 2025; Leong dkk., 2025). Bitcoin juga semakin dipandang sebagai *store of value alternatif* atau “emas digital” karena keterbatasan pasokan dan sifatnya yang tahan sensor (Dionysopoulos dan Uquhart, 2024; Gurgul dkk., 2025). Namun demikian, fluktuasi harga yang sangat ekstrem membuat Bitcoin tidak hanya dianggap sebagai instrumen investasi potensial, tetapi juga instrumen spekulatif dengan risiko tinggi (Adekunle, 2024; Bajwa, 2025).

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

© Hak cipta milik UIN Suska Riau



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

2.2 Cryptocurrency

Cryptocurrency merupakan aset digital yang menggunakan kriptografi sebagai *mekanisme* keamanan dan verifikasi transaksi. Berbasis pada teknologi *blockchain*, *cryptocurrency* memungkinkan pencatatan transaksi secara terdistribusi dan transparan tanpa memerlukan otoritas pusat (Shukla dkk., 2024; Gautami Tripathi, 2023). Selain Bitcoin sebagai pionir, saat ini telah berkembang ribuan jenis *cryptocurrency* lain dengan fungsi dan tujuan yang beragam, mulai dari *utility token*, *stablecoin*, hingga aset yang mendukung ekosistem *decentralized finance* (DeFi) (R. Kumar dkk., 2025). Keberagaman ini menjadikan *cryptocurrency* bukan hanya instrumen investasi, melainkan juga fondasi baru dalam inovasi sistem keuangan digital global (Ballis dkk., 2025; Gurgul dkk., 2025).

Secara global, perkembangan *Cryptocurrency* sangat pesat dengan kapitalisasi pasar yang mencapai triliunan dolar AS, mendorong adopsi oleh investor ritel maupun institusional (Leong dkk., 2025). Namun, di balik peluang tersebut, pasar kripto juga dikenal dengan volatilitas yang tinggi, risiko regulasi, serta kerentanan terhadap spekulasi pasar (Wang dkk., 2023). Dalam konteks akademik, hal ini menempatkan *cryptocurrency* sebagai objek kajian yang menarik, baik dari sisi teknologi, ekonomi, maupun manajemen risiko (Sezer dkk., 2020). Oleh karena itu, pemahaman mendalam terhadap karakteristik *cryptocurrency* menjadi landasan penting dalam penelitian *forecasting* harga aset digital, khususnya Bitcoin sebagai representasi utama pasar kripto (Huang dkk., 2024).

2.3 Volatilitas Pasar Kripto

Volatilitas pasar kripto merupakan salah satu karakteristik utama yang membedakan aset digital dengan instrumen keuangan tradisional. Harga aset kripto, termasuk Bitcoin, dapat mengalami perubahan yang sangat drastis dalam waktu singkat, dipengaruhi oleh faktor internal seperti mekanisme penawaran dan permintaan, serta faktor eksternal berupa kebijakan regulasi, kondisi ekonomi makro, maupun sentimen pasar global (Adekunle, 2024). Ketidakstabilan harga ini menimbulkan tantangan signifikan bagi investor dan analis keuangan, sekaligus menjadikan pasar kripto sebagai laboratorium empiris yang ideal untuk menguji pendekatan *forecasting* berbasis data (Huang dkk., 2024).

Secara historis, volatilitas tinggi pada pasar kripto sering memicu euforia maupun kepanikan di kalangan investor ritel. Peristiwa seperti lonjakan harga Bitcoin pada 2017 hingga kejatuhan nilai pasar pada tahun-tahun berikutnya menunjukkan bahwa fluktuasi yang ekstrem merupakan bagian inheren dari dinamika aset

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

digital (Ballis dkk., 2025). Tingginya volatilitas tidak hanya meningkatkan risiko kerugian, tetapi juga membuka peluang keuntungan yang besar, sehingga menarik perhatian baik investor spekulatif maupun institusional (Bajwa, 2025). Dalam konteks penelitian, pemodelan volatilitas menjadi aspek penting untuk memahami pola pergerakan harga kripto dan mendukung pengambilan keputusan investasi yang lebih rasional (R. Kumar dkk., 2025).

Dengan demikian, volatilitas pasar kripto tidak hanya relevan sebagai fenomena *finansial*, tetapi juga sebagai tantangan metodologis. Model tradisional sering kali gagal merepresentasikan sifat *non-linear* dan ketidakpastian tinggi yang melekat pada aset kripto, sehingga diperlukan pendekatan yang lebih adaptif, seperti *deep learning* (Sezer dkk., 2020). Penelitian mengenai volatilitas dan prediksi harga Bitcoin dengan menggunakan arsitektur *modern* memungkinkan terciptanya strategi mitigasi risiko yang lebih baik bagi investor dan memberikan kontribusi pada literatur akademik di bidang *forecasting* keuangan (Bagheri dan Giudici, 2025; Gurgul dkk., 2025).

2.4 Investasi

Investasi merupakan aktivitas penanaman modal atau alokasi sumber daya dengan harapan memperoleh keuntungan di masa mendatang. Dalam literatur keuangan, investasi mencakup beragam instrumen, mulai dari aset tradisional seperti saham, obligasi, dan emas, hingga aset alternatif seperti *real estate* dan *cryptocurrency* (Nurhakim dkk., 2024; Sangeetha dan Alfia, 2024). Tujuan utama dari investasi adalah memperoleh *return* yang optimal dengan mempertimbangkan tingkat risiko tertentu. Oleh karena itu, konsep dasar investasi selalu berkaitan erat dengan prinsip *risk-return trade-off*, di mana potensi keuntungan yang tinggi biasanya disertai risiko yang lebih besar (Bajwa, 2025; Leong dkk., 2025).

Perkembangan teknologi digital telah memperluas pilihan instrumen investasi, salah satunya melalui kehadiran *cryptocurrency*. Bagi sebagian investor, Bitcoin dan aset kripto lainnya dipandang sebagai peluang diversifikasi portofolio karena karakteristiknya yang berbeda dari aset tradisional (R. Kumar dkk., 2025). Namun, tingginya volatilitas pada pasar kripto menjadikan investasi ini sarat risiko, terutama bagi investor pemula yang belum memahami dinamika pasar digital (Adekunle, 2024). Kondisi tersebut memperkuat urgensi penelitian *forecasting* harga Bitcoin, agar investor dapat mengambil keputusan yang lebih rasional dan terukur dalam menghadapi fluktuasi pasar (Boozary dkk., 2025).



2.5 Risiko Keuangan

Risiko keuangan merupakan potensi kerugian yang timbul akibat ketidakpastian dalam pengelolaan aset, investasi, maupun aktivitas ekonomi. Dalam konteks investasi, risiko ini mencakup berbagai bentuk, seperti risiko pasar, risiko likuiditas, risiko kredit, hingga risiko operasional (Adekunle, 2024). Salah satu tantangan terbesar dalam dunia keuangan modern adalah bagaimana mengelola volatilitas harga yang tinggi, khususnya pada instrumen yang sifatnya spekulatif seperti *cryptocurrency* (Leong dkk., 2025). Tingginya fluktuasi membuat investor berhadapan dengan kemungkinan kerugian yang besar dalam waktu singkat, sehingga manajemen risiko menjadi aspek fundamental dalam setiap keputusan investasi (Bajwa, 2025).

Pada pasar kripto, risiko keuangan semakin kompleks karena adanya faktor-faktor eksternal yang sulit diprediksi, seperti perubahan regulasi, sentimen media sosial, serta intervensi institusi besar (Wang dkk., 2023). Investor ritel sering kali terjebak pada euforia kenaikan harga tanpa memperhitungkan potensi penurunan drastis, sehingga rentan mengalami kerugian signifikan. Oleh sebab itu, pemahaman mengenai risiko keuangan tidak hanya penting dalam konteks teoritis, tetapi juga menjadi dasar praktis dalam membangun strategi investasi yang lebih adaptif dan berkelanjutan (Ballis dkk., 2025).

2.6 Forecasting pada Pasar Keuangan

Forecasting pada pasar keuangan merupakan pendekatan analitis yang bertujuan untuk memperkirakan pergerakan harga, tren, maupun volatilitas aset berdasarkan data historis maupun variabel eksternal. Dalam teori keuangan, pasar bersifat dinamis dan sering kali menunjukkan pola *non-linear*, sehingga peramalan menjadi instrumen penting bagi investor, analis, dan pembuat kebijakan dalam mengambil keputusan (Sezer dkk., 2020). Teknik *forecasting* tradisional, seperti *autoregressive integrated moving average* (ARIMA), *vector autoregression* (VAR), maupun model berbasis volatilitas seperti GARCH, telah lama digunakan untuk memprediksi pergerakan pasar (Mutinda dan Langat, 2024). Namun, model-model tersebut cenderung terbatas dalam menangani kompleksitas dan ketidakstabilan data keuangan *modern* (Bao dkk., 2025).

Seiring dengan meningkatnya volume data dan kebutuhan akan akurasi prediksi yang lebih tinggi, *forecasting* keuangan berkembang menuju pendekatan berbasis *machine learning* dan *deep learning* (Wang dkk., 2023). Metode ini dinilai lebih adaptif dalam menangkap pola *non-linear*, interaksi antarvariabel, serta



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

dinamika pasar yang sering kali sulit dijelaskan oleh model statistik konvensional (S. Kumar dkk., 2025). Dalam konteks pasar kripto, *forecasting* menjadi semakin penting karena volatilitas harga yang ekstrem dan sensitivitas tinggi terhadap faktor eksternal, mulai dari regulasi hingga sentimen media (Adekunle, 2024).

2.7 Time Series

Time series adalah sekumpulan data yang diobservasi secara berurutan dalam suatu rentang waktu, di mana setiap titik data bergantung pada periode sebelumnya (Sezer dkk., 2020). Karakteristik utama dari data *time series* meliputi tren, musiman, siklus, serta komponen acak yang memengaruhi pergerakan nilai di masa depan (Sulandari dkk., 2020). Karena adanya sifat ketergantungan temporal, analisis *time series* sering digunakan untuk melakukan *forecasting* dalam berbagai bidang, termasuk ekonomi, keuangan, cuaca, dan energi (Kasprzyk dkk., 2025).

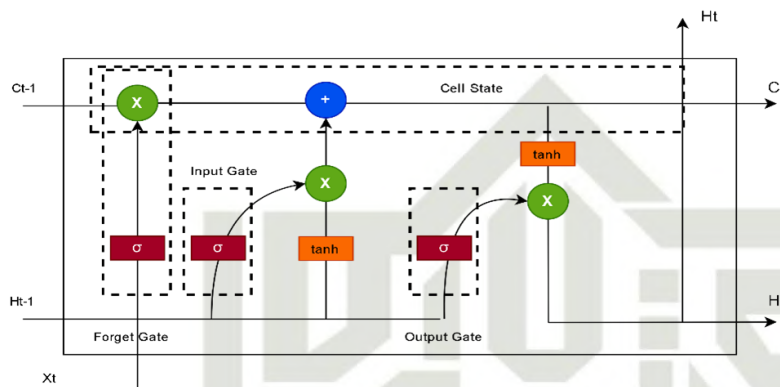
Dalam penelitian *forecasting* Bitcoin, data *time series* menjadi landasan utama karena harga mata uang kripto ditentukan oleh faktor dinamis yang berubah dari waktu ke waktu (Adekunle, 2024). Sifat volatilitas tinggi pada Bitcoin menambah tantangan dalam pemodelan *time series*, karena fluktuasi dapat terjadi dalam hitungan menit (Huang dkk., 2024). Oleh karena itu, metode *deep learning* berbasis *time series* digunakan untuk menangkap pola kompleks dalam data historis harga Bitcoin, sehingga prediksi menjadi lebih akurat dibanding pendekatan tradisional (Boozary dkk., 2025).

2.8 Deep Learning

Deep Learning merupakan cabang dari *machine learning* yang menggunakan arsitektur jaringan saraf tiruan *artificial neural networks* dengan banyak lapisan *deep neural networks* untuk mempelajari representasi data secara hierarkis (Bao dkk., 2025; Sezer dkk., 2020). Berbeda dengan algoritma tradisional, *deep learning* mampu secara otomatis mengekstraksi fitur kompleks dari data mentah tanpa memerlukan rekayasa fitur yang ekstensif (S. Kumar dkk., 2025). Hal ini membuat *deep learning* sangat unggul dalam menangani data berukuran besar, bersifat non-linear, dan memiliki kompleksitas tinggi, seperti data finansial maupun gambar (Gurgul dkk., 2025).

Dalam konteks penelitian *forecasting* Bitcoin, *deep learning* memiliki peran penting karena mampu menangkap pola tersembunyi dari fluktuasi harga yang tidak dapat diakomodasi oleh model statistik klasik (Moghar dan Hamiche, 2020; Wang dkk., 2023). Arsitektur seperti LSTM, GRU, N-BEATS, dan *Hybrid CNN+LSTM* dapat mempelajari hubungan temporal, tren jangka panjang, serta pola volatili-

2.2 Long Short-Term Memory



Gambar 2.2. Arsitektur LSTM

Model *Long Short-Term Memory* (LSTM) merupakan salah satu varian dari *Recurrent Neural Network* (RNN) yang dirancang khusus untuk mengatasi masalah *vanishing gradient* dan *long-term dependency* pada data runtun waktu (time series) (Moghar dan Hamiche, 2020; Rahmadeyan dan Mustakim, 2024). LSTM memiliki struktur internal berupa *cell state* dan *gating mechanism* (*input gate*, *forget gate*, dan *output gate*) yang memungkinkan model menyimpan, memperbarui, atau melupakan informasi secara selektif. Hal ini menjadikan LSTM sangat efektif dalam mempelajari pola jangka panjang pada data keuangan yang bersifat non-linear dan volatil, seperti pergerakan harga Bitcoin (Sezer dkk., 2020; Wang dkk., 2023).


Pada kasus Bitcoin, harga seringkali dipengaruhi oleh kombinasi faktor fundamental, teknikal, serta sentimen pasar yang bersifat dinamis (Adekunle, 2024; Gargul dkk., 2025). Pola jangka pendek maupun panjang ini sulit ditangkap oleh model statistik tradisional seperti ARIMA (Mutinda dan Langat, 2024). Oleh karena itu, LSTM dipandang sebagai pendekatan yang lebih unggul dalam *forecasting*, karena kemampuannya menangkap dependensi temporal yang kompleks pada data historis harga Bitcoin (Bagheri dan Giudici, 2025; Boozary dkk., 2025; Kenrick dkk., 2024). Secara matematis, mekanisme internal LSTM dapat dirumuskan sebagai berikut:

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

$$\begin{aligned}
 f_t &= \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\
 i_t &= \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\
 \tilde{C}_t &= \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \\
 C_t &= f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \\
 o_t &= \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\
 h_t &= o_t \cdot \tanh(C_t)
 \end{aligned} \tag{2.1}$$

2.10 Gated Recurrent Unit



Gambar 2.3. Arsitektur Algoritma GRU


Gated Recurrent Unit (GRU) merupakan varian dari Recurrent Neural Network (RNN) yang diperkenalkan sebagai alternatif yang lebih sederhana dibandingkan LSTM, namun tetap efektif dalam menangani permasalahan long-term dependency pada data runtun waktu (Rahmadayan Mustakim, 2024; Sezer et al., 2020). Tidak seperti LSTM yang memiliki tiga gerbang utama (input, forget, output), GRU hanya menggunakan dua gerbang, yaitu reset gate dan update gate, yang membuat arsitektur ini lebih ringan dan efisien secara komputasi (Bao et al., 2025). Hal ini menjadikan GRU populer digunakan dalam forecasting data dengan volatilitas tinggi, termasuk harga Bitcoin (Adekunle, 2024; Huang et al., 2024).

Pada konteks pasar kripto, harga Bitcoin dipengaruhi oleh faktor multifaktorial seperti transaksi harian, volume perdagangan, regulasi pemerintah, hingga sentimen investor global (Ballis et al., 2025; Gurgul et al., 2025). GRU mampu menangkap pola temporal jangka pendek maupun panjang dari data historis de-

ngan parameter yang lebih sedikit dibandingkan LSTM, sehingga model ini sering lebih cepat dalam pelatihan (training) tanpa kehilangan performa prediksi yang signifikan (Bagheri Giudici, 2025; Kenrick et al., 2024). Secara matematis, mekanisme internal GRU dapat dijelaskan dengan persamaan sebagai berikut:

$$\begin{aligned} z_t &= \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \\ r_t &= \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \\ \tilde{h}_t &= \tanh(W_h \cdot [r_t \cdot h_{t-1}, x_t] + b_h) \\ h_t &= (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t \end{aligned} \quad (2.2)$$

2.11 Neural Basis Expansion Analysis for Time Series




Gambar 2.4. Arsitektur Algoritma N-BEATS

N-BEATS (Neural Basis Expansion Analysis for Time Series) merupakan salah satu model deep learning yang dirancang secara khusus untuk time series forecasting (Kasprzyk et al., 2025). Berbeda dengan model berbasis RNN (LSTM dan GRU) yang fokus pada dependensi temporal (Rahmadayan Mustakim, 2024), N-BEATS menggunakan pendekatan fully-connected feed-forward network dengan arsitektur blok terstruktur yang dirancang untuk menghasilkan backcast (rekonstruksi masa lalu) dan forecast (prediksi masa depan). Struktur ini memungkinkan model menangani pola musiman, tren, serta komponen nonlinier dengan performa kompetitif dibandingkan model state-of-the-art lain (Sezer et al., 2020).

Dalam konteks harga Bitcoin, N-BEATS menjadi relevan karena volatilitas kripto sering kali tidak hanya dipengaruhi faktor temporal jangka pendek, tetapi juga pola tren jangka panjang serta fluktuasi yang muncul akibat berita atau regulasi global (Adekunle, 2024). Keunggulan utama N-BEATS adalah sifatnya yang interpretable, karena mampu memisahkan sinyal harga ke dalam komponen trend, seasonal, dan residual (Asmat Maiyama, 2025). Dengan demikian, model ini tidak hanya memberikan prediksi yang akurat, tetapi juga wawasan tambahan bagi peneliti maupun investor mengenai faktor struktural yang memengaruhi pergerakan harga Bitcoin (Bao et al., 2025). Secara matematis, N-BEATS terdiri dari rangkaian blocks yang memproses input time series secara iteratif. Pada setiap blok i , input x diproyeksikan ke dalam dua komponen utama:

$$\begin{aligned} b^{(i)} &= \Theta_b^{(i)} f^{(i)}(x) \\ f^{(i)} &= \Theta_f^{(i)} f^{(i)}(x) \\ \hat{y} &= \sum_{i=1}^K f^{(i)} \end{aligned} \quad (2.3)$$

2.12 Hybrid CNN-LSTM



Gambar 2.5. Arsitektur Algoritma Hybrid CNN-LSTM

Hybrid CNN+LSTM merupakan pendekatan deep learning yang menggabungkan keunggulan Convolutional Neural Network (CNN) dalam ekstraksi fitur spasial dengan Long Short-Term Memory (LSTM) dalam menangkap ketergantungan temporal pada data runtun waktu (Li Dai, 2020). CNN umumnya digunakan dalam pengolahan citra untuk mengekstraksi pola lokal, namun pada time series CNN dapat diaplikasikan untuk mendeteksi pola jangka pendek dan fluktuasi lokal pada urutan data (Guo et al., 2020). Sementara itu, LSTM dirancang untuk menga-



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

tasi masalah long-term dependency sehingga efektif dalam memprediksi tren jangka panjang pada pasar keuangan yang sangat dinamis (Moghar Hamiche, 2020; Rahmadeyan Mustakim, 2024).

Dalam konteks prediksi harga Bitcoin, CNN berperan sebagai "feature extractor" yang mengidentifikasi pola volatilitas harga harian, candlestick movement, atau sinyal teknikal dari data historis. Pola yang dihasilkan CNN kemudian diteruskan ke LSTM untuk memodelkan keterkaitan jangka panjang, misalnya efek tren global, siklus halving, maupun reaksi pasar terhadap regulasi internasional (Adekunle, 2024). Dengan struktur ini, CNN+LSTM mampu menghasilkan prediksi yang lebih stabil dibandingkan penggunaan CNN atau LSTM secara tunggal, sehingga cocok untuk multihorizon forecasting pada aset kripto dengan volatilitas tinggi (Bagheri Giudici, 2025; S. Kumar et al., 2025). Secara matematis, ekstraksi fitur dengan CNN diteruskan ke lapisan LSTM untuk memodelkan dependensi temporal:

$$\begin{aligned}
 h_t^{\text{CNN}} &= \sigma \left(\sum_{k=1}^K W_k * x_{t:t+m} + b_k \right) \\
 f_t &= \sigma (W_f \cdot [h_t^{\text{CNN}}, h_{t-1}] + b_f) \\
 i_t &= \sigma (W_i \cdot [h_t^{\text{CNN}}, h_{t-1}] + b_i) \\
 o_t &= \sigma (W_o \cdot [h_t^{\text{CNN}}, h_{t-1}] + b_o) \\
 \tilde{c}_t &= \tanh (W_c \cdot [h_t^{\text{CNN}}, h_{t-1}] + b_c) \\
 c_t &= f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \\
 h_t &= o_t \odot \tanh(c_t) \\
 y_{t+1} &= W_y h_t + b_y
 \end{aligned} \tag{2.4}$$

2.13 Bayesian Optimization

Bayesian *Optimization* merupakan pendekatan optimisasi global yang sangat efisien untuk menangani fungsi objektif yang bersifat *black-box*, mahal secara komputasi, dan sering kali mengandung noise (Ilemobayo dkk., 2024). Berbeda dengan metode konvensional seperti *Grid Search* atau *Random Search* yang membutuhkan evaluasi ekstensif dan sering kali tidak efisien pada ruang parameter yang besar, metode ini membangun model probabilistik untuk memandu proses pencarian parameter secara cerdas berdasarkan evaluasi sebelumnya (Garrido-Merchán dan Hernández-Lobato, 2020). Efisiensi ini menjadikan Bayesian *Optimization* sangat relevan untuk diterapkan dalam pelatihan model *Deep Learning* yang kompleks, di



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

mana setiap iterasi pelatihan membutuhkan sumber daya waktu dan komputasi yang signifikan.

Secara fundamental, kerangka kerja ini beroperasi melalui integrasi dua komponen utama, surrogate model dan *acquisition function* (Habtemariam dkk., 2023). *Surrogate* model, yang umumnya menggunakan *Gaussian Process* (GP), berfungsi untuk mengaproksimasi fungsi objektif serta mengukur tingkat ketidakpastian (uncertainty) di seluruh ruang pencarian (Binois dan Wycoff, 2022). Selanjutnya, *acquisition function*, seperti *Expected Improvement* (EI), memanfaatkan informasi posterior dari model probabilistik tersebut untuk menyeimbangkan strategi eksplorasi di area yang belum dipetakan dan eksploitasi di area yang menjanjikan, guna menentukan konfigurasi parameter berikutnya yang paling optimal untuk dievaluasi (Garrido-Merchán dan Hernández-Lobato, 2020).

Dalam konteks pengembangan model *Deep Learning* untuk prediksi runtun waktu, penerapan Bayesian *Optimization* terbukti krusial dalam penyetelan *hyperparameter Tuning*. Tadayonrad dan Ndiaye (2023) menunjukkan bahwa pendekatan ini secara signifikan mengungguli metode penyetelan manual maupun pencarian acak, terutama dalam ruang pencarian berdimensi tinggi pada model LSTM. Oleh karena itu, penelitian ini mengadopsi Bayesian *Optimization* untuk mengoptimalkan struktur jaringan (seperti jumlah *neuron*, *hidden layers*, dan dimensi *blocks* pada N-BEATS) serta parameter pelatihan (*learning rate* dan *batch size*) pada model LSTM, GRU, N-BEATS, dan *Hybrid CNN-LSTM*, guna meminimalkan risiko *overfitting* serta mencapai konvergensi model yang efisien dan akurat sebagaimana disarankan dalam studi komparatif terkini (Bagheri dan Giudici, 2025).

2.14 Optimizer

Optimizer merupakan algoritma yang berfungsi untuk memperbarui bobot (weights) model secara iteratif berdasarkan data pelatihan, dengan tujuan meminimalkan fungsi kerugian (loss function) (Ruder, 2017). Proses optimisasi sangat penting karena menentukan seberapa cepat dan seberapa baik model dapat menemukan representasi pola dari data yang kompleks (Sezer et al., 2020). Pada penelitian forecasting harga Bitcoin, pemilihan optimizer yang tepat menjadi krusial karena data bersifat nonlinier, penuh volatilitas, serta memiliki pola jangka pendek dan jangka panjang yang harus dipelajari model secara simultan (Boozary et al., 2025; Gkonis Tsakalos, 2025; Huang et al., 2024). Secara umum, optimisasi dapat digambarkan melalui persamaan dasar pembaruan bobot:

$$\theta_{t+1} = \theta_t - \eta \cdot \nabla_{\theta} J(\theta_t) \quad (2.5)$$



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

© Hak cipta milik UIN Suska Riau

dengan:

- θ_t menyatakan bobot model pada iterasi ke- t ,
- η merupakan *learning rate*,
- $\nabla_{\theta} J(\theta_t)$ adalah gradien fungsi kerugian terhadap parameter θ_t .

2.15 Adaptive Moment Estimation

Adam merupakan salah satu optimizer yang paling banyak digunakan karena kemampuannya menggabungkan keunggulan dari algoritma Momentum (Ruder, 2017). Adam bekerja dengan menghitung estimasi rata-rata pertama (first moment) dan rata-rata kedua (second moment) dari gradien, sehingga proses pembaruan bobot menjadi lebih adaptif terhadap dinamika data yang bersifat non-linear dan volatil seperti pasar kripto (Boozary et al., 2025; Huang et al., 2024). Secara matematis, Adam melakukan pembaruan parameter berdasarkan persamaan berikut:

$$\begin{aligned} m_t &= \beta_1 m_{t-1} + (1 - \beta_1) g_t \\ v_t &= \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \\ \hat{m}_t &= \frac{m_t}{1 - \beta_1^t}, \quad \hat{v}_t = \frac{v_t}{1 - \beta_2^t} \\ \theta_{t+1} &= \theta_t - \alpha \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} \end{aligned} \quad (2.6)$$

dengan keterangan:

- g_t adalah gradien pada iterasi ke- t ,
- m_t merupakan estimasi rata-rata pertama (*first moment/momentum*),
- v_t merupakan estimasi rata-rata kedua (*second moment/RMS*),
- $\hat{m}_t$ dan $\hat{v}_t$ adalah *bias-corrected estimates*,
- α menyatakan *learning rate*,
- β_1 dan β_2 adalah konstanta eksponensial (umumnya bernilai 0,9 dan 0,999),
- ϵ merupakan nilai kecil untuk mencegah pembagian dengan nol.



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

2.16 Adam With Weight Decay

AdamW merupakan pengembangan dari optimizer Adam yang memperbaiki kelemahan utama Adam terkait regularisasi. Pada algoritma Adam klasik, penerapan L2 regularization (weight decay) sering kali tercampur dengan perhitungan gradien adaptif sehingga menghasilkan perilaku yang tidak konsisten, terutama ketika berhadapan dengan data pasar kripto yang sangat fluktuatif. AdamW memisahkan secara eksplisit proses weight decay dari update gradien, sehingga menghasilkan pembelajaran yang lebih stabil, mengurangi overfitting, dan mempercepat konvergensi (Ruder, 2017). Secara matematis, persamaan pembaruan parameter pada AdamW dapat dituliskan sebagai berikut:

$$\begin{aligned} m_t &= \beta_1 m_{t-1} + (1 - \beta_1) g_t \\ v_t &= \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \\ \hat{m}_t &= \frac{m_t}{1 - \beta_1^t}, \quad \hat{v}_t = \frac{v_t}{1 - \beta_2^t} \\ \theta_{t+1} &= \theta_t - \alpha \left(\frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} + \lambda \theta_t \right) \end{aligned} \quad (2.7)$$

dengan keterangan:

- g_t adalah gradien pada iterasi ke- t ,
- m_t dan v_t merupakan estimasi rata-rata pertama dan kedua,
- $\hat{m}_t$ dan $\hat{v}_t$ adalah *bias-corrected estimates*,
- α menyatakan *learning rate*,
- β_1 dan β_2 adalah konstanta eksponensial (biasanya bernilai 0,9 dan 0,999),
- ϵ merupakan nilai kecil untuk menjaga stabilitas numerik,
- λ menyatakan koefisien *weight decay*.

2.17 Mean Squared Error (MSE)

MSE merupakan salah satu metrik evaluasi yang paling banyak digunakan dalam penelitian forecasting untuk mengukur tingkat kesalahan prediksi model. MSE menghitung rata-rata kuadrat selisih antara nilai aktual dengan nilai hasil prediksi. Penggunaan kuadrat pada selisih kesalahan membuat MSE lebih sensitif terhadap kesalahan besar (outlier), sehingga cocok diterapkan pada data dengan



volatilitas tinggi. Dengan demikian, MSE mampu memberikan gambaran mengenai seberapa jauh hasil prediksi model menyimpang dari harga aktual yang diamati (Karunasingha, 2022). secara matematis, MSE dirumuskan sebagai berikut:

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2 \quad (2.8)$$

dengan:

- n menyatakan jumlah data observasi,
- y_t merupakan nilai aktual harga Bitcoin pada waktu ke- t ,
- $\hat{y}_t$ adalah nilai prediksi harga Bitcoin pada waktu ke- t .

2.18 Root Mean Squared Error (RMSE)

RMSE merupakan salah satu metrik evaluasi yang digunakan untuk mengukur akurasi prediksi model dengan cara menghitung akar kuadrat dari nilai rata-rata kesalahan kuadrat. RMSE pada dasarnya adalah turunan langsung dari MSE, namun memiliki keunggulan karena hasilnya berada pada skala yang sama dengan data asli. Hal ini membuat RMSE lebih mudah dipahami oleh praktisi maupun peneliti, karena kesalahan prediksi dapat langsung diinterpretasikan sebagai deviasi harga yang nyata dalam pasar (Karunasingha, 2022). Secara matematis, RMSE dapat dirumuskan sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (2.9)$$

dengan:

- n menyatakan jumlah data observasi,
- y_t merupakan nilai aktual harga Bitcoin pada waktu ke- t ,
- $\hat{y}_t$ adalah nilai prediksi harga Bitcoin pada waktu ke- t .

2.19 Mean Absolute Error (MAE)

MAE adalah metrik evaluasi yang digunakan untuk mengukur tingkat kesalahan prediksi dengan cara menghitung rata-rata nilai absolut dari selisih antara harga aktual dan harga hasil prediksi. Tidak seperti MSE atau RMSE yang memberikan penalti lebih besar terhadap kesalahan ekstrem karena menggunakan



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

kuadrat, MAE menilai kesalahan secara linier, sehingga memberikan gambaran yang lebih proporsional terhadap deviasi rata-rata model. Metrik ini sering dianggap lebih “robust” dalam menghadapi data dengan volatilitas tinggi seperti Bitcoin, karena tidak terlalu dipengaruhi oleh outlier (Karunasingha, 2022). Secara matematis, MAE dirumuskan sebagai:

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

dengan:

- n menyatakan jumlah data observasi,
- y_t merupakan nilai aktual harga Bitcoin pada waktu ke- t ,
- $\hat{y}_t$ adalah nilai prediksi harga Bitcoin pada waktu ke- t .

2.20 Mean Absolute Percentage Error (MAPE)

MAPE merupakan metrik evaluasi yang banyak digunakan dalam penelitian forecasting karena memberikan ukuran kesalahan prediksi dalam bentuk persentase. MAPE menghitung rata-rata kesalahan absolut antara nilai aktual dan hasil prediksi, lalu mengekspresikannya sebagai proporsi terhadap nilai aktual. Keunggulan utama MAPE adalah sifatnya yang intuitif dan mudah dipahami, karena menyajikan kesalahan prediksi dalam satuan persen yang dapat langsung diinterpretasikan oleh peneliti maupun praktisi pasar (Kim Kim, 2016). Secara matematis, MAPE dirumuskan sebagai:

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (2.11)$$

dengan:

- n menyatakan jumlah data observasi,
- y_t merupakan nilai aktual harga Bitcoin pada waktu ke- t ,
- $\hat{y}_t$ adalah nilai prediksi harga Bitcoin pada waktu ke- t .

2.21 R-Square (R²)

R-Square (Coefficient of Determination) merupakan metrik evaluasi yang digunakan untuk mengukur seberapa besar variasi nilai aktual yang dapat dijelaskan oleh model prediksi. R-Square membandingkan jumlah kesalahan prediksi model dengan variasi total data aktual terhadap nilai rata-ratanya. Nilai R-Square berada



Hak Cipta Ditanggung Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

pada rentang 0 hingga 1, di mana nilai yang semakin mendekati 1 menunjukkan bahwa model memiliki kemampuan yang semakin baik dalam merepresentasikan pola dan dinamika data historis. Dalam penelitian forecasting harga Bitcoin, R-Square digunakan untuk menilai kemampuan model dalam menjelaskan pergerakan harga secara keseluruhan, bukan hanya berdasarkan besarnya kesalahan prediksi. Secara matematis, R-Square dirumuskan sebagai berikut:

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

dengan:

- n menyatakan jumlah data observasi,
- y_t merupakan nilai aktual harga Bitcoin pada waktu ke- t ,
- $\hat{y}_t$ adalah nilai prediksi harga Bitcoin pada waktu ke- t ,
- $\bar{y}$ menyatakan nilai rata-rata harga Bitcoin aktual.

2.22 Penelitian Terdahulu

Penelitian mengenai prediksi harga Bitcoin telah berkembang pesat seiring meningkatnya volatilitas pasar kripto dan kompleksitas faktor-faktor yang memengaruhi pergerakan harganya. Berbagai pendekatan deep learning digunakan untuk memodelkan hubungan nonlinier dan dependensi temporal yang sulit ditangkap oleh model statistik klasik. Tiga penelitian utama (Asmat Maiyama, 2025; Bagheri Giudici, 2025; Li Dai, 2020) menunjukkan arah perkembangan riset yang berbeda namun saling melengkapi dalam domain cryptocurrency forecasting.

(Bagheri Giudici, 2025) menekankan pendekatan multi-dimensi berbasis SAFE-AI framework, yang mengevaluasi model tidak hanya dari aspek akurasi, tetapi juga security (robustness) dan explainability. Studi ini menguji performa berbagai arsitektur deep learning seperti LSTM, GRU, CNN, dan hybrid CNN-GRU pada data Bitcoin harian periode 2016–2024. Hasilnya menunjukkan bahwa CNN-GRU dan LSTM memberikan akurasi tertinggi dengan Rank Graduation Accuracy (RGA) sebesar 0.8897 dan 0.8621, sementara GRU dan CNN menunjukkan keunggulan dalam stabilitas dan pengendalian risiko. Pendekatan ini menjadi penting karena tidak hanya mempertimbangkan prediksi numerik semata, tetapi juga kemampuan model untuk tetap andal pada kondisi pasar ekstrem, menjadikannya pionir dalam penggabungan explainable AI dengan financial forecasting.



Hak Cipta Diindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Sebaliknya, (Asmat Maiyama, 2025) mengusulkan pendekatan N-BEATS, sebuah arsitektur deep learning berbasis blok residual yang dirancang khusus untuk time series forecasting tanpa memerlukan rekayasa fitur domain-spesifik. Berbeda dengan model LSTM yang mengandalkan struktur berulang untuk mempelajari ketergantungan temporal, N-BEATS mengandalkan lapisan fully connected yang membangun representasi tren dan musiman secara hierarkis. Dengan data harga per jam selama 729 hari, penelitian ini membuktikan bahwa N-BEATS mampu mengungguli LSTM dan Linear Regression dengan hasil yang sangat presisi ($R^2 = 0.9998$; MAE = 0.00240). Kelebihan utama N-BEATS adalah kemampuannya untuk generalize terhadap data volatil tanpa risiko overfitting yang sering muncul pada model rekuren. Namun, penelitian ini terbatas pada univariate forecasting tanpa mempertimbangkan variabel eksternal seperti sentimen pasar atau indikator makroekonomi.


Sementara itu, penelitian (Li Dai, 2020) memperkenalkan model hybrid CNN–LSTM sebagai solusi terhadap keterbatasan model tunggal dalam menangkap dinamika harga Bitcoin. CNN digunakan untuk mengekstraksi pola spasial dan fitur jangka pendek dari data historis (seperti harga buka, tutup, volume, dan indikator teknikal), sedangkan LSTM berfungsi untuk mempelajari hubungan temporal jangka panjang. Data yang digunakan mencakup kombinasi faktor internal (transaksi Bitcoin) dan faktor eksternal (harga minyak, emas, indeks saham, nilai tukar, dan perhatian investor). Hasil evaluasi menunjukkan bahwa CNN–LSTM memberikan peningkatan signifikan dibanding CNN atau LSTM tunggal dalam hal nilai prediksi (MAE, RMSE, MAPE) dan arah tren (Precision, Recall, F1-Score). Pendekatan hibrid ini menunjukkan efektivitasnya dalam menangani data multidimensional dan volatilitas tinggi, sekaligus menegaskan pentingnya integrasi feature extraction dan sequence modeling dalam prediksi keuangan.

UIN SUSKA RIAU

BAB 3

METODOLOGI PENELITIAN

Adapun langkah dan tahapan yang dilakukan pada penelitian ini dapat dilihat melalui skema alir pada Gambar 3.1 Tahapan dimulai dari perencanaan dan berakhir hingga dokumentasi.



Gambar 3.1. Metodologi Penelitian

3.1 Tahap Perencanaan

Tahap perencanaan merupakan langkah awal dalam mengimplementasikan ide penelitian. Tahap ini mencakup beberapa komponen utama, antara lain:

3.1.1 Identifikasi Masalah

Peneliti mengamati sejumlah permasalahan terkait investasi aset kripto, khususnya Bitcoin, seperti tingginya volatilitas harga yang menyebabkan risiko investasi yang signifikan. Selain itu, masih banyak investor yang kurang memahami teknik analisis prediktif yang efektif untuk mengambil keputusan jual-beli. Ketidak-



pastian harga yang sangat fluktuatif serta minimnya informasi berbasis data historis dan *machine learning* menjadi tantangan utama dalam melakukan prediksi yang akurat.

3.1.2 Menentukan Tujuan

Penelitian yang berkualitas tidak hanya dituntut untuk memberikan solusi konkret atas permasalahan yang ada, tetapi juga harus memiliki orientasi dan fokus penelitian yang presisi. Penelitian ini bertujuan untuk memproyeksikan pergerakan harga Bitcoin melalui pendekatan *time series forecasting* berbasis *Deep Learning*. Sebagai pengembangan dari studi terdahulu yang umumnya terbatas pada penggunaan LSTM dan GRU, penelitian ini memperluas cakupan analisis dengan menggaji empat algoritma mutakhir: LSTM, GRU, N-BEATS, dan *Hybrid CNN-LSTM*. Kebaharuan signifikan dalam penelitian ini terletak pada penerapan *Bayesian Optimization* untuk mengotomatisasi penyetelan *hyperparameter*, guna memastikan setiap model beroperasi pada konfigurasi optimalnya sehingga menghasilkan prediksi harga Bitcoin yang lebih akurat dan andal.

3.1.3 Batasan Masalah

Penelitian ini membatasi ruang lingkup analisis pada prediksi harga Bitcoin (BTC) sebagai aset tunggal menggunakan data historis harian dari *Yahoo Finance* dengan pendekatan univariat, tanpa melibatkan variabel eksternal seperti indikator makroekonomi atau sentimen media sosial. Fokus metodologi dipusatkan pada penerapan algoritma *Deep Learning* yang meliputi LSTM, GRU, N-BEATS, dan *Hybrid CNN-LSTM* untuk prediksi jangka pendek maupun panjang, di mana optimasi kinerja model dilakukan secara eksklusif menggunakan *Bayesian Optimization* tanpa komparasi dengan metode tuning lain. Evaluasi model diukur berdasarkan metrik kesalahan statistik standar (MSE, RMSE, MAE, MAPE, dan R^2) untuk menilai akurasi dan stabilitas teknis, sehingga penelitian ini secara tegas tidak mencakup aspek implementasi sistem perdagangan otomatis, manajemen portofolio, analisis risiko investasi secara finansial, maupun dampak dinamika regulasi terhadap volatilitas harga.

3.1.4 Studi Pustaka

Studi pustaka ini dilaksanakan secara sistematis dengan menghimpun, menelaah, dan menyintesis literatur empiris terkini yang relevan dengan dinamika prediksi harga Bitcoin, mencakup evaluasi mendalam terhadap kinerja arsitektur *Deep Learning* mutakhir seperti *Long Short-Term Memory* (LSTM) dan *Gated*



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Recurrent Unit (GRU) yang telah menjadi standar dalam analisis deret waktu, model hibrida CNN-LSTM yang terbukti efektif mengintegrasikan ekstraksi fitur spasial dan temporal, serta arsitektur N-BEATS yang menawarkan keunggulan interpretabilitas dalam menangkap pola tren dan musiman tanpa rekayasa fitur manual. Selain analisis model, kajian ini secara khusus mengeksplorasi literatur mengenai metode optimasi, di mana *Bayesian Optimization* diidentifikasi sebagai solusi probabilistik yang krusial untuk mengatasi inefisiensi dan bias pada penyetelan *hyperparameter* manual atau *Grid Search* yang umum ditemukan pada penelitian terdahulu. Tujuan utama dari sintesis literatur ini adalah untuk memetakan kesenjangan penelitian (*research gap*) terkait belum adanya studi yang membandingkan keempat algoritma tersebut secara komprehensif dalam satu kerangka optimasi yang seragam, sekaligus memperkuat landasan teoretis guna mendukung validitas dan efisiensi pendekatan yang diusulkan dalam penelitian ini.

3.2 Tahap Persiapan Data

Tahap persiapan data merupakan langkah krusial dalam penelitian prediksi harga Bitcoin, yang bertujuan untuk memastikan bahwa data yang digunakan dalam proses pelatihan dan pengujian model telah bersih, terstruktur, dan siap diolah secara optimal. Berikut adalah tahapan dalam proses persiapan data:

3.2.1 Pengumpulan Data

Data historis harga Bitcoin yang digunakan dalam penelitian ini diperoleh dari platform *Yahoo Finance* dengan rentang waktu tertentu yang disesuaikan dengan kebutuhan analisis. Data mencakup informasi harga pembukaan, penutupan, harga tertinggi, harga terendah, dan volume perdagangan harian.

3.2.2 Preprocessing Data

Pada tahap ini dilakukan pembersihan data (*data cleaning*) untuk menghapus kolom yang tidak relevan terhadap proses prediksi harga, seperti simbol mata uang atau metadata teknis lainnya. Selain itu, dilakukan penghapusan baris yang memiliki nilai kosong (*missing value*) untuk memastikan kualitas data yang tinggi dan menghindari gangguan pada proses pelatihan model.

3.2.3 Pembagian Data

Pada tahap ini dilakukan pembersihan data (*data cleaning*) untuk menghapus kolom yang tidak relevan terhadap proses prediksi harga, seperti simbol mata uang atau metadata teknis lainnya. Selain itu, dilakukan penghapusan baris yang memiliki nilai kosong (*missing value*) untuk memastikan kualitas data yang tinggi



Hak Cipta Ditanggung Undang-Undang

1. Diarangi mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Diarangi mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

dan menghindari gangguan pada proses pelatihan model.

3.2.4 Normalisasi Data

Untuk mengoptimalkan kinerja algoritma *deep learning*, dilakukan normalisasi data menggunakan metode *Min-Max Normalization*, yaitu mengubah nilai numerik pada dataset ke dalam rentang 0 hingga 1. Teknik ini membantu mempercepat proses pelatihan dan meningkatkan stabilitas konvergensi model.

3.3 Tahap Melatih Model

Tahap ini merupakan proses pengolahan data untuk mendapatkan model yang telah dilatih. Adapun algoritma yang digunakan yaitu LSTM, GRU, N-BEATS dan *Hybrid CNN-LSTM* dengan *hyperparameter tuning bayesian optimization* yang dioptimasi dengan Adam dan AdamW.

3.3.1 Hyperparameter Bayesian Optimization

Tabel 3.1. Rentang Hyperparameter dan Konfigurasinya pada Model Deep Learning

Hyperparameter	Model yang Menggunakan	Rentang / Pilihan Nilai	Penjelasan
Lookback	N-BEATS, GRU, CNN-LSTM, LSTM	10–60 (step 10)	Menentukan jumlah <i>timestep</i> historis yang digunakan sebagai input model. Nilai <i>lookback</i> yang lebih besar memberikan konteks temporal yang lebih panjang, namun meningkatkan kompleksitas komputasi dan risiko <i>overfitting</i> .

Bersambung ke halaman berikutnya



Lanjutan Tabel 3.1

Hyperparameter	Model yang Menggunakan	Rentang / Pilihan Nilai	Penjelasan
Learning Rate	N-BEATS, GRU, CNN-LSTM, LSTM	10^{-5} , 10^{-2} (log scale)	Mengatur kecepatan pembaruan bobot selama proses pelatihan. Skala logaritmik memungkinkan eksplorasi nilai kecil hingga besar secara efisien untuk mencapai konvergensi optimal.
Batch Size	N-BEATS, GRU, CNN-LSTM, LSTM	16, 32, 64	Menentukan jumlah data dalam satu iterasi pelatihan. Batch kecil meningkatkan stabilitas gradien, sedangkan batch besar mempercepat pelatihan namun dapat menurunkan kemampuan generalisasi.
Dropout Rate	GRU, CNN-LSTM, LSTM	0.1-, -0.5 (step 0.1)	Digunakan untuk mengurangi <i>overfitting</i> dengan menonaktifkan neuron secara acak selama pelatihan, sehingga meningkatkan kemampuan generalisasi model.

Bersambung ke halaman berikutnya

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



Lanjutan Tabel 3.1

Hyperparameter	Model yang Menggunakan	Rentang / Pilihan Nilai	Penjelasan
Unit (Dense / RNN Unit)	N-BEATS, GRU, LSTM	N-BEATS: 64–256 GRU: 50–200 LSTM: 50–200	Menentukan kapasitas representasi model. Jumlah unit yang lebih besar memungkinkan model menangkap pola yang lebih kompleks, namun meningkatkan risiko <i>overfitting</i> dan beban komputasi.
N Block	N-BEATS	2–6	Menentukan jumlah blok pada arsitektur N-BEATS. Setiap blok mempelajari residual deret waktu, sehingga jumlah blok yang lebih banyak memungkinkan pemodelan pola nonlinier yang lebih kompleks.
CNN Filters	CNN-LSTM	32, 64, 128	Menentukan jumlah filter pada <i>convolutional layer</i> untuk mengekstraksi fitur lokal, seperti fluktuasi harga jangka pendek.

Bersambung ke halaman berikutnya

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Lanjutan Tabel 3.1

Hyperparameter	Model yang Menggunakan	Rentang / Pilihan Nilai	Penjelasan
Kernel Size	CNN-LSTM	2–5	Menentukan ukuran jendela konvolusi dalam menangkap pola temporal lokal. Nilai kernel dijaga lebih kecil dari lookback untuk memastikan validitas operasi konvolusi.
Pool Size	CNN-LSTM	2–3	Digunakan pada <i>pooling layer</i> untuk reduksi dimensi fitur hasil ekstraksi CNN sekaligus mempertahankan informasi penting.
LSTM (Hybrid)	Unit CNN-LSTM	32–128	Menentukan jumlah unit LSTM pada model hybrid untuk menangkap dependensi jangka panjang dari fitur yang telah diekstraksi oleh CNN.
Optimizer	N-BEATS, GRU, CNN-LSTM, LSTM	Adam dan AdamW	Menentukan metode optimisasi untuk memperbarui bobot model selama pelatihan, yang memengaruhi kecepatan konvergensi dan stabilitas proses training.

Bersambung ke halaman berikutnya

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Lanjutan Tabel 3.1

Hyperparameter	Model yang Menggunakan	Rentang / Pilihan Nilai	Penjelasan
Epoch	N-BEATS, GRU, CNN-LSTM, LSTM	50–300	Menentukan jumlah siklus pelatihan penuh terhadap seluruh data latih. Nilai epoch yang terlalu kecil berisiko <i>underfitting</i> , sedangkan nilai terlalu besar meningkatkan risiko <i>overfitting</i> .
Early Stopping	GRU, CNN-LSTM, LSTM	Patience 10–30	Digunakan untuk menghentikan pelatihan secara otomatis ketika performa validasi tidak mengalami peningkatan, sehingga mencegah <i>overfitting</i> .

3.4 Tahap Analisis dan Hasil

Tahapan ini menghasilkan output berupa informasi dan pengetahuan yang diperoleh dari proses analisis terhadap permasalahan yang diteliti. Berikut adalah rincian tahapan dari analisis dan hasil:

3.4.1 Evaluasi Model

Untuk menentukan algoritma yang paling optimal dalam memprediksi harga Bitcoin, dilakukan evaluasi terhadap performa masing-masing model menggunakan metrik evaluasi seperti *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE) dan *R-Square* (R²). Metrik ini digunakan untuk mengukur tingkat kesalahan antara nilai prediksi dan nilai aktual, sehingga dapat diketahui algoritma mana yang menghasilkan prediksi paling akurat.

3.4.2 Discussion

Pembahasan difokuskan pada interpretasi hasil temuan penelitian dengan mengaitkannya secara kritis terhadap tujuan penelitian serta membandingkannya

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

Hak cipta milik UIN Suska Riau

State Islamic University of Sultan Syarif Kasim Riau



dengan hasil penelitian terdahulu yang dijadikan sebagai referensi utama. Analisis dilakukan untuk mengidentifikasi kesesuaian maupun perbedaan temuan, sekaligus menjelaskan faktor-faktor yang memungkinkan terjadinya variasi hasil, seperti perbedaan metode, data, dan konteks penelitian. Melalui pendekatan ini, bagian discussion tidak hanya berfungsi sebagai pemaparan ulang hasil, tetapi juga sebagai ruang argumentatif untuk menegaskan kontribusi ilmiah penelitian ini dalam memperkaya dan memperluas pemahaman yang telah dibangun oleh penelitian sebelumnya.



UIN SUSKA RIAU

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

BAB 5

PENUTUP

5.1 Kesimpulan

Berdasarkan hasil pengujian, analisis, dan evaluasi yang telah dilakukan terhadap model prediksi harga Bitcoin menggunakan arsitektur deep learning (LSTM, GRU, N-BEATS, dan Hybrid CNN-LSTM) dengan kerangka kerja Bayesian Optimization, dapat disimpulkan hal-hal sebagai berikut:

5.1.1 Pembangunan Model dan Dependensi Data

Penelitian ini berhasil membangun empat arsitektur model prediksi dan mengidentifikasi pola dependensi yang kuat antara kinerja optimizer dengan ketersediaan volume data. Keunggulan model tidak bersifat tunggal, melainkan bergantung pada skenario data:

1. Skema 80/10/10 *optimizer* Adam terbukti superior, mampu mendorong model LSTM, GRU, dan N-BEATS mencapai presisi tertinggi dengan mengeksplorasi kapasitas komputasi secara agresif.
2. Skema 70/15/15 AdamW muncul sebagai mekanisme penyeimbang krusial yang mempertahankan stabilitas generalisasi ketika Adam mengalami penurunan performa akibat *overfitting*.

5.1.2 Peran Bayesian Optimization

Implementasi *Bayesian Optimization* menyingkap perbedaan adaptasi fundamental dalam penentuan *hyperparameter* optimal:

1. Adam cenderung mengarahkan pencarian ke arsitektur berkapasitas besar (jumlah *neuron/filter* tinggi) dengan jendela memori jangka pendek, berfokus pada penangkapan detail fitur secara mikro dan responsivitas cepat.
2. AdamW menunjukkan preferensi pada efisiensi dan konteks jangka panjang. *Optimizer* ini lebih sering menyarankan model yang ramping namun dengan look-back window yang lebih luas dan *learning rate* konservatif, memprioritaskan pemahaman pola tren global yang halus.

5.1.3 Efektivitas Decoupled Weight Decay pada Stabilitas

Fitur *decoupled weight decay* pada AdamW terbukti menjadi kunci utama dalam meredam volatilitas. Hal ini memberikan dampak signifikan pada arsitektur dengan kompleksitas tinggi seperti *Hybrid CNN-LSTM*, di mana AdamW mampu mencegah *overfitting* dan menjaga konsistensi akurasi, berbeda dengan Adam yang



1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

cenderung menghasilkan tingkat kesalahan lebih tinggi pada arsitektur kompleks tersebut.

5.1.4 Implementasi Strategis dan Proyeksi

Pemilihan *optimizer* terbukti bukan sekadar masalah teknis akurasi, melainkan menentukan profil risiko dari prediksi masa depan (2025–2026):

1. Skenario Optimis (*Bullish*): LSTM (80/10/10 + Adam) adalah model paling optimis, memproyeksikan harga bertahan di kisaran tinggi (112.000).
2. Skenario Pesimis (*Bearish*): N-BEATS (70/15/15 + AdamW) memproyeksikan skenario terburuk dengan kejatuhan harga hingga level 27.500, mengindikasikan sensitivitas tinggi model ini terhadap pengurangan data latih.
3. Skenario Moderat/Stabil: *Hybrid* CNN-LSTM (AdamW) menawarkan jalan tengah dengan prediksi yang paling stabil dan tidak fluktuatif di kisaran 73.000.

5.1.5 Arsitektur Paling Optimal

Dalam kerangka tuning yang dilakukan, *Hybrid* CNN-LSTM dengan *optimizer* AdamW adalah konfigurasi paling optimal untuk stabilitas dan keamanan prediksi jangka panjang, terutama dalam kondisi ketidakpastian data. Namun, jika tujuannya adalah mengejar potensi keuntungan jangka pendek dengan dukungan data yang masif, N-BEATS atau LSTM dengan *optimizer* Adam merupakan pilihan arsitektur yang paling responsif.

5.2 Saran

Berdasarkan keterbatasan dan temuan dalam studi ini, beberapa rekomendasi untuk pengembangan penelitian di masa depan meliputi:

1. *Eksplorasi Variabel Eksogen (Multivariat)*: Penelitian ini berfokus pada data historis harga. Mengingat temuan bahwa *look-back window* panjang pada AdamW memberikan hasil positif, penelitian selanjutnya disarankan untuk mengintegrasikan data eksternal seperti sentimen pasar (dari media sosial atau berita), data *on-chain* (volume transaksi blockchain), atau indikator makroekonomi global. Penggunaan data dapat membantu model, khususnya N-BEATS dan *Hybrid* CNN-LSTM, untuk menangkap kausalitas pergerakan harga yang tidak terlihat hanya dari grafik harga masa lalu.
2. Penerapan Mekanisme *Attention* dan *Transformer*: Meskipun LSTM dan GRU menunjukkan kinerja yang solid, arsitektur berbasis *Transformer* de-



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

ngan mekanisme *Self-Attention* saat ini menjadi standar baru dalam *time-series forecasting*. Penelitian masa depan dapat membandingkan efektivitas regularisasi AdamW pada model *Transformer* untuk melihat apakah *weight decay* mampu mengatasi isu *data-hungry* yang biasanya menjadi kelemahan utama model Transformer pada dataset keuangan yang terbatas.

3. Pengujian *Walk-Forward Validation*: Alih-alih hanya menggunakan pembagian data statis (80:10:10 dan 70:15:15), penelitian selanjutnya disarankan menggunakan metode *Expanding Window* atau *Rolling Window Validation*. Metode ini lebih menyerupai kondisi trading di dunia nyata di mana model dilatih ulang secara berkala seiring masuknya data baru. Hal ini akan menguji apakah stabilitas AdamW tetap konsisten dalam kondisi pasar yang berubah dinamis dari waktu ke waktu.

4. Kombinasi *Ensemble Learning*: Mengingat adanya divergensi tren yang ekstrem antara Adam dan AdamW dalam prediksi jangka panjang, penelitian selanjutnya dapat mencoba menggabungkan kedua hasil ini menggunakan teknik *Ensemble Averaging* atau *Stacking*. Dengan mengambil jalan tengah antara agresivitas Adam dan kehati-hatian AdamW, diharapkan dapat dihasilkan prediksi harga yang lebih seimbang dan akurat secara rata-rata.



DAFTAR PUSTAKA

- Deekunle, A. O. (2024). Cryptocurrency market volatility and risk management during global crises: A systematic literature review (2013–2023). *Sinergi International Journal of Accounting and Taxation*, 2(1), 55–68. Retrieved from <https://journal.sinergi.or.id/index.php/ijat/article/view/479> doi: <https://doi.org/10.61194/ijat.v2i1.479>
- Shakim, A., dan Tantimin, T. (2024). The legal status of cryptocurrency and its implications for money laundering in indonesia. *Padjadjaran Jurnal Ilmu Hukum (Journal of Law)*, 11(2), 4. Retrieved from <https://jurnal.unpad.ac.id/pjih/article/view/49106> doi: <https://doi.org/10.22304/pjih.v11n2.a4>
- Asmat, G., dan Maiyama, K. (2025). Bitcoin price prediction using n-beats ml technique. *EAI Endorsed Transactions on Scalable Information Systems*, 12(2). Retrieved from <https://publications.eai.eu/index.php/sis/article/view/9006> doi: <https://doi.org/10.4108/eetsis.9006>
- Badan Pengawas Perdagangan Berjangka Komoditi (Bappebti). (2024, dec 27). *Tumbuh 356,16 persen tahun ini, transaksi aset kripto capai rp 556,53 triliun*. Press release. Retrieved from https://bappebti.go.id/siaran_pers/detail/15717
- Bagheri, M., dan Giudici, P. (2025). Accurate, secure and explainable bitcoin forecasting. *Physica A: Statistical Mechanics and its Applications*, 678, 130974. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0378437125006260> doi: <https://doi.org/10.1016/j.physa.2025.130974>
- Bojiwa, I. A. (2025). Reinvestment intentions in cryptocurrency: Examining the dynamics of risks and investor risk tolerance. *Digital Business*, 5(1), 100104. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2666954424000322> doi: <https://doi.org/10.1016/j.digbus.2024.100104>
- Bullis, A., Karagiorgis, A., Anastasiou, D., dan Kallandranis, C. (2025). Cryptocurrency dynamics during global crises: Insights from bitcoin's interplay with traditional markets. *International Review of Economics & Finance*, 103, 104512. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1059056025006756> doi: <https://doi.org/10.1016/j.iref.2025.104512>



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

- Bao, W., Cao, Y., Yang, Y., Che, H., Huang, J., dan Wen, S. (2025). Data-driven stock forecasting models based on neural networks: A review. *Information Fusion*, 113, 102616. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1566253524003944> doi: <https://doi.org/10.1016/j.inffus.2024.102616>
- Binois, M., dan Wycoff, N. (2022). *A survey on high-dimensional gaussian process modeling with application to bayesian optimization*. Retrieved from <https://arxiv.org/abs/2111.05040>
- Boozary, P., Sheykhani, S., dan GhorbanTanhaei, H. (2025). Forecasting the bitcoin price using the various machine learning: A systematic review in data-driven marketing. *Systems and Soft Computing*, 7, 200209. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2772941925000274> doi: <https://doi.org/10.1016/j.sasc.2025.200209>
- Dionysopoulos, L., dan Urquhart, A. (2024). 10 years of stablecoins: Their impact, what we know, and future research directions. *Economics Letters*, 244, 111939. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0165176524004233> doi: <https://doi.org/10.1016/j.econlet.2024.111939>
- Dubey, R., dan Enke, D. (2025). Bitcoin price direction prediction using on-chain data and feature selection. *Machine Learning with Applications*, 20, 100674. Retrieved from <https://www.sciencedirect.com/science/article/pii/S266682702500057X> doi: <https://doi.org/10.1016/j.mlwa.2025.100674>
- Garrido-Merchán, E. C., dan Hernández-Lobato, D. (2020). Dealing with categorical and integer-valued variables in bayesian optimization with gaussian processes. *Neurocomputing*, 380, 20-35. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0925231219315619> doi: <https://doi.org/10.1016/j.neucom.2019.11.004>
- Gautami Tripathi, G. C., Mohd Abdul Ahad. (2023). A comprehensive review of blockchain technology: Underlying principles and historical background with future challenges. *Decision Analytics Journal*, 9, 100344. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2772662223001844> doi: <https://doi.org/10.1016/j.dajour.2023.100344>
- Gargul, V., Lessmann, S., dan Härdle, W. K. (2025). Deep learning and nlp in cryptocurrency forecasting: Integrating financial, blockchain, and social media data. *International Journal of Forecasting*, 41(4), 1666-1695. Re-



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

trieved from <https://www.sciencedirect.com/science/article/pii/S0169207025000147> doi: <https://doi.org/10.1016/j.ijforecast.2025.02.007>

Abtemariam, E. T., Kekeba, K., Martínez-Ballesteros, M., dan Martínez-Álvarez, F. (2023). A bayesian optimization-based lstm model for wind power forecasting in the adama district, ethiopia. *Energies*, 16(5). Retrieved from <https://www.mdpi.com/1996-1073/16/5/2317> doi: 10.3390/en16052317

Haang, Z.-C., Sangiorgi, I., dan Urquhart, A. (2024). Forecasting bitcoin volatility using machine learning techniques. *Journal of International Financial Markets, Institutions and Money*, 97, 102064. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1042443124001306> doi: 10.1016/j.intfin.2024.102064

Ilemobayo, J. A., Durodola, O., Alade, O., Awotunde, O. J., Olanrewaju, A. T., Falana, O., ... Ifeanyi, A. (2024, June). Hyperparameter tuning in machine learning: A comprehensive review. *Journal of Engineering Research and Reports*, 26(6), 388–395. Retrieved from <https://journaljerr.com/index.php/JERR/article/view/1188> doi: 10.9734/jerr/2024/v26i61188

Kasprzyk, M., Pełka, P., Oreshkin, B. N., dan Dudek, G. (2025). Enhanced n-beats for mid-term electricity demand forecasting. *Applied Soft Computing*, 182, 113575. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1568494625008865> doi: <https://doi.org/10.1016/j.asoc.2025.113575>

Kenrick, Ivancio, S. C., Isabellini, E., Adhi, C. G. S., dan Prasetyo, A. (2024). Multivariate stock market forecasting using lstm on indonesian banking stock market. *Procedia Computer Science*, 245, 1047-1056. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1877050924031417> (9th International Conference on Computer Science and Computational Intelligence 2024 (ICCSCI 2024)) doi: <https://doi.org/10.1016/j.procs.2024.10.333>

Kamar, R., Sharma, S. K., Kishor, K., dan Devi, P. (2025). Decentralized finance evolution: A comprehensive bibliometric analysis. *Sustainable Futures*, 10, 101209. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2666188825007713> doi: <https://doi.org/10.1016/j.sftr.2025.101209>

Kumar, S., Rao, A., dan Dhochak, M. (2025). Hybrid ml models for volatility prediction in financial risk management. *International Review of Economics &*



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Finance, 98, 103915. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1059056025000784> doi: <https://doi.org/10.1016/j.iref.2025.103915>

Leong, M., Alexeev, V., dan Kwok, S. (2025). Managing cryptocurrency risk exposures in equity portfolios: Evidence from high-frequency data. *Journal of International Financial Markets, Institutions and Money*, 99, 102123. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1042443125000137> doi: <https://doi.org/10.1016/j.intfin.2025.102123>

Li, Y., dan Dai, W. (2020). Bitcoin price forecasting method based on cnn-lstm hybrid neural network model. *The journal of engineering*, 2020(13), 344–347. Retrieved from <https://ietresearch.onlinelibrary.wiley.com/doi/10.1049/joe.2019.1203> doi: <https://doi.org/10.1049/joe.2019.1203>

Moghar, A., dan Hamiche, M. (2020). Stock market prediction using lstm recurrent neural network. *Procedia Computer Science*, 170, 1168-1173. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1877050920304865> (The 11th International Conference on Ambient Systems, Networks and Technologies (ANT) / The 3rd International Conference on Emerging Data and Industry 4.0 (EDI40) / Affiliated Workshops) doi: <https://doi.org/10.1016/j.procs.2020.03.049>

Mutinda, J. K., dan Langat, A. K. (2024). Stock price prediction using combined garch-ai models. *Scientific African*, 26, e02374. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2468227624003168> doi: <https://doi.org/10.1016/j.sciaf.2024.e02374>

Nakamoto, S. (2008). *Bitcoin: A peer-to-peer electronic cash system*. <https://bitcoin.org/bitcoin.pdf>. (White paper)

Nurhakim, E. S., Soma, A. M., dan Yunita, I. (2024). Constructing optimal portfolios using the single index model and markowitz model: A study on cryptocurrencies. *JASF: Journal of Accounting and Strategic Finance*, 7(2), 200–218. Retrieved from <https://jasf.upnjatim.ac.id/index.php/jasf/article/view/485> doi: <https://doi.org/10.33005/jasf.v7i2.485>

Rahmadeyan, A., dan Mustakim. (2024). Long short-term memory and gated recurrent unit for stock price prediction. *Procedia Computer Science*, 234, 204-212. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1877050924003533> (Seventh Information Systems International Conference (ISICO 2023)) doi: <https://doi.org/10.1016/j.procs.2024.02.167>



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

- Sangeetha, J. M., dan Alfia, K. J. (2024). Financial stock market forecast using evaluated linear regression based machine learning technique. *Measurement: Sensors*, 31, 100950. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2665917423002866> doi: <https://doi.org/10.1016/j.measen.2023.100950>
- Sezer, O. B., Gudelek, M. U., dan Ozbayoglu, A. M. (2020). Financial time series forecasting with deep learning : A systematic literature review: 2005–2019. *Applied Soft Computing*, 90, 106181. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1568494620301216> doi: <https://doi.org/10.1016/j.asoc.2020.106181>
- Shawon, S. M., Haider, S. N., Barua, A., Austin, S., Adan, I. A., Hossain, M. S., dan Zubair, H. (2025). Hybrid cnn-lstm model for urban energy load forecasting with iga-xai for smart grids: Peak and off-peak variability insights. *Results in Engineering*, 28, 107245. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2590123025033006> doi: <https://doi.org/10.1016/j.rineng.2025.107245>
- Shukla, A., Jirli, P., Mishra, A., dan Singh, A. K. (2024). An overview of blockchain research and future agenda: Insights from structural topic modeling. *Journal of Innovation & Knowledge*, 9(4), 100605. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2444569X24001446> doi: <https://doi.org/10.1016/j.jik.2024.100605>
- Soria, J., Moya, J., dan Mohazab, A. (2023). Optimal mining in proof-of-work blockchain protocols. *Finance Research Letters*, 53, 103610. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1544612322007863> doi: <https://doi.org/10.1016/j.frl.2022.103610>
- Silandari, W., Subanar, S., Lee, M. H., dan Rodrigues, P. C. (2020). Time series forecasting using singular spectrum analysis, fuzzy systems and neural networks. *MethodsX*, 7, 101015. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2215016120302351> doi: <https://doi.org/10.1016/j.mex.2020.101015>
- Tadayonrad, Y., dan Ndiaye, A. B. (2023). A new key performance indicator model for demand forecasting in inventory management considering supply chain reliability and seasonality. *Supply Chain Analytics*, 3, 100026. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2949863523000250> doi: <https://doi.org/10.1016/j.sca.2023.100026>
- Victoria, A. H., dan Maragatham, G. (2021, March). Automatic tuning of hyper-



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

parameters using bayesian optimization. *Evolving Systems*, 12(1), 217–223. Retrieved from <https://doi.org/10.1007/s12530-020-09345-2> doi: 10.1007/s12530-020-09345-2

Wang, Y., Andreeva, G., dan Martin-Barragan, B. (2023). Machine learning approaches to forecasting cryptocurrency volatility: Considering internal and external determinants. *International Review of Financial Analysis*, 90, 102914. Retrieved from <https://www.research.ed.ac.uk/en/publications/machine-learning-approaches-to-forecasting-cryptocurrency-volatil-2/> doi: <https://doi.org/10.1016/j.irfa.2023.102914>

Xiefeng Guo, Q. Z., Zheng, D., Ning, Y., dan Gao, Y. (2020). A short-term load forecasting model of multi-scale cnn-lstm hybrid neural network considering the real-time electricity price. *Energy Reports*, 6, 1046-1053. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2352484720315031> (2020 The 7th International Conference on Power and Energy Systems Engineering) doi: <https://doi.org/10.1016/j.egyr.2020.11.078>

Zulfiqar, M., Gamage, K. A. A., Kamran, M., dan Rasheed, M. B. (2022). Hyperparameter optimization of bayesian neural network using bayesian optimization and intelligent feature engineering for load forecasting. *Sensors*, 22(12). Retrieved from <https://www.mdpi.com/1424-8220/22/12/4446> doi: 10.3390/s22124446




LAMPIRAN A

YAHOO FINANCE

Hak Cipta Dilindungi Undang-Undang

1. Diarangi mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Diarangi mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



Gambar A.1. Yahoo Finance - Bitcoin



Hak Cipta Diilindungi Undang-Undang

1. Diarangi mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Diarangi mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

LAMPIRAN B

SOURCE CODE *BAYESIAN OPTIMIZATION*

```
# -----
# 3. Objective Function for Optuna
# -----
def objective(trial):
    # Suggest hyperparameters
    look_back = trial.suggest_int("look_back", 10, 60, step=10) # Timesteps
    lstm_units = trial.suggest_int("lstm_units", 50, 200, step=25)
    dropout_rate = trial.suggest_float("dropout_rate", 0.1, 0.5, step=0.1)
    learning_rate = trial.suggest_float("learning_rate", 1e-5, 1e-2, log=True)
    batch_size = trial.suggest_categorical("batch_size", [16, 32, 64])

    # Prepare data with current look_back
    train_data = scaled_data[:train_len + val_len] # Train + Val for validation
    X_full, y_full = create_dataset(train_data, look_back)

    # Split into train and validation (time-series safe)
    X_train = X_full[:len(X_full) - val_len]
    y_train = y_full[:len(y_full) - val_len]
    X_val = X_full[len(X_full) - val_len:]
    y_val = y_full[len(y_full) - val_len:]

    # Reshape for LSTM [samples, timesteps, features]
    X_train = X_train.reshape((X_train.shape[0], X_train.shape[1], 1))
    X_val = X_val.reshape((X_val.shape[0], X_val.shape[1], 1))

    # Build model
    model = Sequential([
        LSTM(lstm_units, return_sequences=True, input_shape=(look_back, 1)),
        Dropout(dropout_rate),
        LSTM(lstm_units),
        Dropout(dropout_rate),
        Dense(1)
    ])
    return
```

Gambar B.1. Algoritma LSTM - *Bayesian Optimization*



Hak Cipta Dilindungi Undang-Undang

1. Diarangi mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Diarangi mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

```
# 3. Objective Function for Optuna
# -----
def objective(trial):
    # Suggest hyperparameters
    look_back = trial.suggest_int("look_back", 10, 60, step=10) # Timesteps
    gru_units = trial.suggest_int("gru_units", 50, 200, step=25)
    dropout_rate = trial.suggest_float("dropout_rate", 0.1, 0.5, step=0.1)
    learning_rate = trial.suggest_float("learning_rate", 1e-5, 1e-2, log=True)
    batch_size = trial.suggest_categorical("batch_size", [16, 32, 64])

    # Prepare data with current look_back
    train_data = scaled_data[:train_len + val_len] # Train + Val for validation
    X_full, y_full = create_dataset(train_data, look_back)

    # Split into train and validation (time-series safe)
    X_train = X_full[:len(X_full) - val_len]
    y_train = y_full[:len(y_full) - val_len]
    X_val = X_full[len(X_full) - val_len:]
    y_val = y_full[len(y_full) - val_len:]

    # Reshape for GRU [samples, timesteps, features]
    X_train = X_train.reshape((X_train.shape[0], X_train.shape[1], 1))
    X_val = X_val.reshape((X_val.shape[0], X_val.shape[1], 1))

    # Build model
    model = Sequential([
        GRU(gru_units, return_sequences=True, input_shape=(look_back, 1)),
        Dropout(dropout_rate),
        GRU(gru_units),
        Dropout(dropout_rate),
        Dense(1)
    ])
    return loss
```

Gambar B.2. Algoritma GRU - *Bayesian Optimization*



Hak Cipta Diindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

```
# 3. Custom N-BEATS Block & Model
# -----
class NBeatsBlock(Layer):
    def __init__(self, units, theta_dim, **kwargs):
        super(NBeatsBlock, self).__init__(**kwargs)
        self.units = units
        self.theta_dim = theta_dim
        self.fc1 = Dense(units, activation='relu')
        self.fc2 = Dense(units, activation='relu')
        self.fc3 = Dense(units, activation='relu')
        self.fc4 = Dense(units, activation='relu')
        self.backcast_layer = Dense(theta_dim, activation=None)
        self.forecast_layer = Dense(theta_dim, activation=None)

    def call(self, inputs):
        x = self.fc1(inputs)
        x = self.fc2(x)
        x = self.fc3(x)
        x = self.fc4(x)
        backcast = self.backcast_layer(x)
        forecast = self.forecast_layer(x)
        return backcast, forecast

class NBeats(Model):
    def __init__(self, lookback, horizon=1, n_blocks=3, units=128, **kwargs):
        super(NBeats, self).__init__(**kwargs)
        self.lookback = lookback
        self.horizon = horizon
        self.n_blocks = n_blocks
        self.blocks = [NBeatsNetBlock(units, lookback) for _ in range(n_blocks)]

    def call(self, inputs):
        residuals = inputs
        forecast = tf.zeros((tf.shape(inputs)[0], self.horizon), dtype=tf.float32)
        for block in self.blocks:
            backcast, block_forecast = block(residuals)
            residuals = residuals - backcast
            # Take only the first 'horizon' elements (we predict 1 step)
            forecast += block_forecast[:, :self.horizon]
        return forecast

# Fix: Use correct class name in list comprehension
class NBeatsNetBlock(NBeatsBlock):
    pass
```

Gambar B.3. Algoritma N-BEATS *Block*



Hak Cipta Dilindungi Undang-Undang

1. Diarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Diarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

```
# -----
# 3. Objective Function for Optuna
# -----
def objective(trial):
    # Suggest hyperparameters
    look_back = trial.suggest_int("look_back", 10, 60, step=10) # Timesteps
    lstm_units = trial.suggest_int("lstm_units", 50, 200, step=25)
    dropout_rate = trial.suggest_float("dropout_rate", 0.1, 0.5, step=0.1)
    learning_rate = trial.suggest_float("learning_rate", 1e-5, 1e-2, log=True)
    batch_size = trial.suggest_categorical("batch_size", [16, 32, 64])

    # Prepare data with current look_back
    train_data = scaled_data[:train_len + val_len] # Train + Val for validation
    X_full, y_full = create_dataset(train_data, look_back)

    # Split into train and validation (time-series safe)
    X_train = X_full[:len(X_full) - val_len]
    y_train = y_full[:len(y_full) - val_len]
    X_val = X_full[len(X_full) - val_len:]
    y_val = y_full[len(y_full) - val_len:]

    # Reshape for LSTM [samples, timesteps, features]
    X_train = X_train.reshape((X_train.shape[0], X_train.shape[1], 1))
    X_val = X_val.reshape((X_val.shape[0], X_val.shape[1], 1))

    # Build model
    model = Sequential([
        LSTM(lstm_units, return_sequences=True, input_shape=(look_back, 1)),
        Dropout(dropout_rate),
        LSTM(lstm_units),
        Dropout(dropout_rate),
        Dense(1)
    ])
```

Gambar B.4. Algoritma N-BEATS - *Bayesian Optimization*



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

```
# 3. Objective Function for Optuna (True CNN-LSTM)
# -----
def objective(trial):
    # Suggest hyperparameters
    lookback = trial.suggest_int("lookback", 10, 60, step=10)
    cnn_filters = trial.suggest_categorical("cnn_filters", [32, 64, 128])
    kernel_size = trial.suggest_int("kernel_size", 2, min(5, lookback // 2)) # Ensure kernel < lookback
    pool_size = trial.suggest_int("pool_size", 2, 3)
    lstm_units = trial.suggest_int("lstm_units", 32, 128, step=16)
    dropout_rate = trial.suggest_float("dropout_rate", 0.1, 0.5, step=0.1)
    learning_rate = trial.suggest_float("learning_rate", 1e-5, 1e-2, log=True)
    batch_size = trial.suggest_categorical("batch_size", [16, 32, 64])

    # Skip if kernel or pool too large
    if kernel_size >= lookback:
        return float('inf')

    # Prepare data
    train_val_data = scaled_data[:train_len + val_len]
    X_full, y_full = create_dataset(train_val_data, lookback)

    if len(X_full) <= val_len:
        return float('inf') # Not enough data

    X_train = X_full[:-val_len]
    y_train = y_full[:-val_len]
    X_val = X_full[-val_len:]
    y_val = y_full[-val_len:]

    # Reshape to [samples, timesteps, features]
    X_train = X_train.reshape((X_train.shape[0], X_train.shape[1], 1))
    X_val = X_val.reshape((X_val.shape[0], X_val.shape[1], 1))

    # Build TRUE Hybrid CNN-LSTM
    model = Sequential()
    # CNN for feature extraction
    model.add(Conv1D(filters=cnn_filters, kernel_size=kernel_size, activation='relu',
                    input_shape=(lookback, 1), padding='same'))
    model.add(Conv1D(filters=cnn_filters, kernel_size=kernel_size, activation='relu', padding='same'))
    model.add(MaxPooling1D(pool_size=pool_size, padding='same'))

    # LSTM for sequential modeling
    model.add(LSTM(lstm_units, return_sequences=False))
    model.add(Dropout(dropout_rate))
```

Gambar B.5. Algoritma *Hybrid CNN-LSTM - Bayesian Optimization*



Hak Cipta Diindungi Undang-Undang

1. Diarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Diarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

LAMPIRAN C

SIARAN PERS



SIARAN PERS

Biro Hubungan Masyarakat
Gd. I Lt. 2, Jl. M.I. Ridwan Rais No. 5, Jakarta 10110
Telp: 021-3860371/Fax: 021-3508711
www.kemendag.go.id



Tumbuh 356,16 Persen Tahun Ini, Transaksi Aset Kripto Capai Rp 556,53 Triliun

Jakarta, 27 Desember 2024 – Badan Pengawas Perdagangan Berjangka Komoditi (Bappebti) mencatat nilai transaksi aset kripto di Indonesia telah mencapai Rp556,53 triliun sepanjang Januari-November 2024. Nilai tersebut meningkat 356,16 persen dibandingkan periode yang sama pada tahun sebelumnya, yakni sebesar Rp122 triliun. Pertumbuhan transaksi perdagangan aset kripto yang terus meningkat tersebut merupakan salah satu wujud kepercayaan masyarakat terhadap perdagangan aset kripto di Indonesia.

"Perkembangan nilai transaksi aset kripto pada periode Januari–November 2024 mencapai Rp556,53 triliun. Nilai tersebut meningkat 356,16 persen dibandingkan periode yang sama pada 2023, yaitu sebesar Rp122 triliun. Hal ini membuktikan perdagangan aset kripto merupakan salah satu pilihan perdagangan yang diminati masyarakat," ujar Plt. Kepala Bappebti Tommy Andana hari ini, Jumat (27/12).

Lebih lanjut, Tommy menjelaskan, jumlah pelanggan aset kripto hingga November 2024 mencapai 22,1 juta pelanggan. Sementara itu, pelanggan yang aktif bertransaksi melalui Calon Pedagang Fisik Aset Kripto (CPFAK) dan PFAK pada November 2024 berjumlah 1,3 juta pelanggan. Adapun jenis aset kripto dengan nilai transaksi tertinggi pada November 2024 antara lain Tether (USDT), Bitcoin (BTC), Doge Coin (DOGE), Pepe (PEPE), XRP (XRP).

"Peningkatan jumlah pelanggan saat ini menunjukkan potensi pasar aset kripto di Indonesia yang masih sangat besar. Dalam beberapa tahun ke depan, Indonesia diprediksi mampu menjadi salah satu pemimpin pasar kripto di dunia," tegas Tommy.

Bappebti terus memperkuat kolaborasi dengan organisasi regulator mandiri (*self regulatory organization/SRO*), asosiasi, dan para pemangku kepentingan industri aset kripto di Indonesia. Hal ini dilakukan untuk mengembangkan ekosistem dan tata kelola aset kripto di samping tentunya untuk memperkuat regulasi dan literasi kepada masyarakat. Dengan demikian, Bappebti optimistis nilai transaksi aset kripto akan meningkat pada 2025.

Sekretaris Bappebti Olvy Andrianita menegaskan, selain fokus pada peningkatan transaksi, Bappebti, SRO, dan PFAK juga harus konsisten dalam memberikan literasi untuk penguatan perlindungan kepada masyarakat. Literasi ditujukan terutama untuk pelanggan perdagangan aset kripto yang didominasi generasi muda.

www.kemendag.go.id

@kemendag

Kementerian Perdagangan

#AyoDagang

Gambar C.1. Siaran Pers



Hak Cipta Diindungi Undang-Undang

1. Diarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Diarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

"Tingginya antusiasme masyarakat terhadap aset kripto harus diimbangi dengan edukasi dan literasi yang komprehensif. Penguatan literasi diharapkan menjadi langkah efektif dalam meningkatkan perlindungan kepada masyarakat, memberikan kepastian berusaha bagi pelaku industri, dan mengurangi aduan," tegas Olvy.

Sementara itu, Kepala Biro Pembinaan dan Pengembangan Perdagangan Berjangka Komoditi Tirta Karma Senjaya mengatakan, Bappebti berkomitmen untuk mewujudkan aset kripto yang berintegritas dan adaptif. Bappebti juga terus mendorong para CPFAK untuk segera menjadi PFAK.


"Bappebti tetap konsisten melakukan pembinaan kepada PFAK dan CPFAK. Saat ini sembilan perusahaan sudah menjadi PFAK meliputi PT Pintu Kemana Saja (Pintu), PT Bumi Santosa Cemerlang (Pluang), PT Aset Digital Berkas (Tokocrypto), dan PT Kagum Teknologi Indonesia (Ajaib). Berikutnya, PT Tiga Inti Utama (Triv), PT Sentra Bitwewe Indonesia (Bitwewe), dan PT CTXG Indonesia Berkarya (Mobee), PT Rekeningku Dotcom Indonesia (Reku), dan PT Ekripsi Teknologi Handal (Usenobi). Selanjutnya, kami berharap perusahaan lain yang berstatus CPFAK dapat segera menjadi PFAK," tutup Tirta.

--selesai--

Informasi lebih lanjut hubungi:

M. Rivai Abbas
Kepala Biro Hubungan Masyarakat
Kementerian Perdagangan
Email: pusathumas@kemendag.go.id

Olvy Andrianita
Sekretaris
Badan Pengawas Perdagangan Berjangka Komoditi
Kementerian Perdagangan
Email: humas.bappebti@kemendag.go.id



Gambar C.2. Siaran Pers



DAFTAR RIWAYAT HIDUP



Kia Kurniawan lahir pada 10 Juli 2004 dan menempuh pendidikan dasar di SD Negeri 013 Buluh Kasap Dumai Timur, pendidikan menengah pertama di SMP Negeri 01 Dumai Kota, serta pendidikan menengah atas di SMA Swasta Budi Dharma. Pada tahun 2022, saya meraih predikat Siswa Terbaik Mata Pelajaran Fisika, sebagai bentuk pengakuan atas capaian akademik di bidang sains. Selanjutnya, pada tahun 2023 saya menerima Beasiswa Pemerintah Kota Dumai sebagai apresiasi atas prestasi akademik yang telah dicapai, yang semakin memotivasi saya untuk terus mengembangkan diri serta berkontribusi secara positif dalam bidang pendidikan dan pengembangan kompetensi profesional.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.