



KEMENTERIAN PENDIDIKAN TINGGI, SAINS,
DAN TEKNOLOGI
UNIVERSITAS JEMBER
FAKULTAS KEGURUAN DAN ILMU PENDIDIKAN
Jalan Kalimantan Nomor 37 Kampus Bumi Tegalboto Jember 68121
Telepon: 0331- 334988, 330738 Faks: 0331-334988
Laman: www.fkip.unej.ac.id

LEMBAR REVISI SKRIPSI

NAMA MAHASISWA : Indra Irawan
NIM : 210210101081
JUDUL SKRIPSI : **Multi-Time Forecasting dalam Volatilitas Cryptocurrency Berbasis Analisis Fundamental, Technical, dan Machine Learning**
TANGGAL UJIAN : 14 Januari 2025
PEMBIMBING : Prof. Drs. Dafik, M.Sc., Ph.D.
Rafiantika Megahnia Prihandini, S.Pd., M.Si.

MATERI PEMBETULAN / PERBAIKAN

No.	HALAMAN	HAL-HAL YANG HARUS DIPERBAIKI
1.	27-30	Menambahkan tanggal dari berita <i>cryptocurrency</i> dan efek sebelum-sesudah pada pasar
2.	31	Menambahkan keterangan waktu pada <i>technical chart</i>
3.	32	Menambah kriteria <i>support-resistance line</i> dan kriteria jual dan tahan
4.	35	Menambahkan alasan terkait pemilihan periode 20 hari awal pada perhitungan EMA
5.	37	Menampilkan bulan terakhir <i>csv</i> yaitu desember pada grafik EMA Solana 2024
6.	42	Menambahkan apa yang dilakukan ketika RSI berada di rentang 30-70
7.	69-71	Menambahkan perbandingan MSE dan MAE dari TCN dengan LSTM dan GRU
8.	28	Menambahkan ATM Bitcoin sebagai penunjang
9.	34	Menambahkan BTC.D dari Tradingview
10.	70	Menambahkan gambar dari prediksi TCN, LSTM, dan GRU

JABATAN	NAMA TIM PENGUJI	TTD dan Tanggal
Ketua	Prof. Drs. Dafik, M.Sc., Ph.D.	
Sekretaris	Rafiantika Megahnia P., S.Pd., M.Si.	
Anggota	Prof. Drs. Antonius C.P., M.App.Sc., Ph.D.	
	Robiatul Adawiyah, S.Pd., M.Si.	

Dosen Pembimbing I, Jember, 17 Januari 2025
Mengetahui / menyetujui :
Dosen Pembimbing II, Mahasiswa Yang Bersangkutan

Prof. Drs. Dafik, M.Sc., Ph.D.
NIP. 19680802 199303 1 004

Rafiantika Megahnia P., S.Pd., M.Si.
NIP. 19891005 201903 2 034

Indra Irawan
NIM. 210210101081

Mengetahui,
Ketua Jurusan P.MIPA

Dr. Erfan Yudianto, S.Pd., M.Pd.
NIP. 19850316 201504 1 001



***MULTI-TIME FORECASTING DALAM VOLATILITAS
CRYPTOCURRENCY BERBASIS ANALISIS FUNDAMENTAL,
TECHNICAL, DAN MACHINE LEARNING***

*Diajukan untuk memenuhi sebagian persyaratan memperoleh gelar Sarjana pada
program studi Pendidikan Matematika*

SKRIPSI

Oleh :

Indra Irawan

NIM 210210101081

KEMENTERIAN PENDIDIKAN TINGGI, SAINS, DAN TEKNOLOGI

UNIVERSITAS JEMBER

FAKULTAS KEGURUAN DAN ILMU PENDIDIKAN

PROGRAM STUDI PENDIDIKAN MATEMATIKA

JEMBER

2025



***MULTI-TIME FORECASTING DALAM VOLATILITAS
CRYPTOCURRENCY BERBASIS ANALISIS FUNDAMENTAL,
TECHNICAL, DAN MACHINE LEARNING***

*Diajukan untuk memenuhi sebagian persyaratan memperoleh gelar Sarjana pada
program studi Pendidikan Matematika*

SKRIPSI

Oleh :

Indra Irawan

NIM 210210101081

Dosen Pembimbing I : Prof. Drs. Dafik, M.Sc., Ph.D.
Dosen Pembimbing II : Rafiantika Megahnia Prihandini, S.Pd., M.Si.
Dosen Penguji I : Prof. Drs. Antonius Cahya Prihandoko, M.App.Sc., Ph.D
Dosen Penguji II : Robiatul Adawiyah, S.Pd., M.Si

**KEMENTERIAN PENDIDIKAN TINGGI, SAINS, DAN TEKNOLOGI
UNIVERSITAS JEMBER
FAKULTAS KEGURUAN DAN ILMU PENDIDIKAN
PROGRAM STUDI PENDIDIKAN MATEMATIKA
JEMBER**

2025

PERSEMBAHAN

Dengan menyebut nama Allah yang Maha Pengasih dan Maha Penyayang serta sholawat dan salam selalu tercurahkan kepada Nabi Muhammad SAW, penulis persembahkan skripsi ini sebagai ungkapan kebahagiaan dan rasa terima kasih kepada:

1. Keluarga besar saya, Bapak Supriyani dan Almh. Ibu Muji Astuti, serta kakak saya Agus Pitana dan Rinawati yang telah mendukung dan memberikan doa, kasih sayang, motivasi, kepercayaan dan senyuman yang selalu menguatkan di setiap perjalanan hidup saya;
2. Bapak Prof. Drs. Dafik, M.Sc., Ph.D. selaku Dosen Pembimbing Utama dan Ibu Rafiantika Megahnia Prihandini, S.Pd., M.Si. selaku Dosen Pembimbing Anggota yang senantiasa meluangkan waktu dalam memberikan pengarahan dan bimbingan hingga terselesaikannya penulisan skripsi ini;
3. Bapak Prof. Drs. Antonius Cahya Prihandoko, M.App.Sc., Ph.D. selaku Dosen Penguji I dan Ibu Robiatul Adawiyah, S.Pd., M.Si. selaku Dosen Penguji II yang telah memberikan kritik dan saran yang membangun dalam penyempurnaan skripsi ini;
4. Seluruh guru dan dosen beserta almamater sekolah yang telah memberikan banyak ilmu dan suasana kekeluargaan di setiap masanya serta teman-teman CGANT yang telah membagikan ilmu dan pengalaman berharga serta mengajarkan bahwa sebuah perbedaan bukanlah alasan untuk tidak saling membantu;
5. Sahabat terbaik dan tersayang yang selalu memberi dukungan, motivasi, selalu menerima keluh kesah saya dan kebersamai saya dalam keadaan susah maupun senang dalam penyusunan skripsi ini;
6. Seluruh keluarga besar Mathematics Students Club (MSC) angkatan 2021 Pendidikan Matematika FKIP Universitas Jember;
7. Almamater tercinta Program Studi Pendidikan Matematika Fakultas Keguruan dan Ilmu Pendidikan Universitas Jember.

MOTTO

لَا يُكَلِّفُ اللَّهُ نَفْسًا إِلَّا وُسْعَهَا

"Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya."

(Terjemahan QS. Al-Baqarah: 286)

"Saya tidak pernah kalah. Saya menang atau saya belajar."

(Nelson Mandela)

PERNYATAAN

Saya yang bertanda tangan di bawah ini:

Nama : Indra Irawan

NIM : 210210101081

Menyatakan dengan sesungguhnya bahwa skripsi yang berjudul "*Multi-Time Forecasting dalam Volatilitas Cryptocurrency Berbasis Analisis Fundamental, Technical, dan Machine Learning*" adalah benar-benar hasil karya sendiri, kecuali jika dalam pengutipan substansi disebutkan sumbernya, dan belum pernah diajukan pada institusi manapun, serta bukan karya jiplakan. Saya bertanggung jawab atas keabsahan dan kebenaran isinya sesuai dengan skripsi ilmiah yang harus dijunjung tinggi.

Demikian pernyataan ini saya buat dengan sebenarnya, tanpa adanya tekanan dan paksaan dari pihak manapun serta bersedia mendapat sanksi akademik jika ternyata di kemudian hari pernyataan ini tidak benar.

Jember, 14 Januari 2025

Yang menyatakan,

Indra Irawan

NIM 210210101081

HALAMAN PERSETUJUAN

Skripsi berjudul ”*Multi-Time Forecasting dalam Volatilitas Cryptocurrency Berbasis Analisis Fundamental, Technical, dan Machine Learning*” telah diuji oleh fakultas Keguruan dan Ilmu Pendidikan Universitas Jember pada:

Hari :

Tanggal :

Tempat : Fakultas Keguruan dan Ilmu Pendidikan Universitas Jember

Pembimbing

Tanda Tangan

1. Pembimbing Utama

Nama : Prof. Drs. Dafik, M.Sc., Ph.D.

(.....)

NIP : 19680802 199303 1 004

2. Pembimbing Anggota

Nama : Rafiantika Megahnia Prihandini, S.Pd., M.Si.

(.....)

NIP : 19891005 201903 2 034

Penguji

1. Penguji Utama

Nama : Prof. Drs. Antonius C. P., M.App.Sc., Ph.D.

(.....)

NIP : 19690928 199302 1 001

2. Penguji Anggota

Nama : Robiatul Adawiyah, S.Pd., M.Si.

(.....)

NIP : 19920731 201903 2 015

ABSTRACT

This research focuses on multi-time forecasting of cryptocurrency volatility by integrating fundamental analysis, technical analysis, and machine learning techniques. Cryptocurrencies are known for their high volatility, making accurate price forecasting an essential aspect of understanding market dynamics. Fundamental analysis in this study examines critical factors such as the performance of top coins, correlation matrices, and the influence of market news. Technical analysis incorporates key indicators, including candlestick patterns, support and resistance lines, Simple Moving Averages (SMA), Exponential Moving Averages (EMA), and the Relative Strength Index (RSI), to capture market trends and patterns. To enhance predictive accuracy, a machine learning approach using Temporal Convolutional Networks (TCN) is implemented to process time-series data and generate multi-step forecasts. By integrating these methodologies, this research aims to provide a robust framework for analyzing cryptocurrency volatility across multiple time frames. The results of this study are expected to contribute to better understanding and management of cryptocurrency market dynamics, supporting informed decision-making in various applications.

Keywords: cryptocurrency volatility, fundamental analysis, technical analysis, Temporal Convolutional Networks (TCN), machine learning

RINGKASAN

Multi-Time Forecasting dalam Volatilitas Cryptocurrency Berbasis Analisis Fundamental, Technical, dan Machine Learning ; Indra Irawan, 210210101081; 2024: halaman; Program Studi Sarjana Pendidikan Matematika Fakultas Keguruan dan Ilmu Pengetahuan Universitas Jember.

Penelitian ini membahas topik *multi-time forecasting* dalam volatilitas *cryptocurrency* berbasis analisis fundamental, *technical*, dan *machine learning*. Beberapa analisis tersebut digunakan untuk mengetahui prediksi dari volatilitas *cryptocurrency* kedepannya. Volatilitas *cryptocurrency* adalah tingkat perubahan harga *cryptocurrency* yang sangat cepat dan fluktuatif dalam periode waktu tertentu. Banyak faktor yang mempengaruhi volatilitas *cryptocurrency*, seperti penurunan pasar keuangan global, tingkat pengangguran, dan perubahan perilaku konsumen. *Multi-time forecasting* adalah prediksi gabungan mata uang *cryptocurrency* dalam satu *time frame* pada platform trading, sehingga dengan adanya prediksi ini dapat meminimalisir kerugian dari aktivitas transaksi *cryptocurrency*.

Analisis fundamental dalam *cryptocurrency* melibatkan evaluasi nilai intrinsik aset melalui metrik seperti adopsi teknologi, jumlah transaksi harian, biaya transaksi, dan aktivitas jaringan. Bitcoin sebagai pelopor dan pemimpin pasar *cryptocurrency* memiliki pengaruh dominan terhadap volatilitas altcoin melalui fenomena "*Bitcoin Effect*," di mana pergerakan harga Bitcoin sering memicu fluktuasi altcoin seperti Ethereum dan Solana, yang dapat dianalisis melalui matriks korelasi. Platform seperti Solscan menyediakan data aktivitas *blockchain*, termasuk volume transaksi dan staking, yang mencerminkan dinamika pasar. Dompet seperti Phantom dan MetaMask memfasilitasi transaksi dan memberikan wawasan tambahan terkait tren pasar melalui volume penggunaannya. Sentimen pasar juga dipengaruhi oleh berita, seperti pernyataan tokoh terkenal, yang dapat menciptakan optimisme atau ketidakpastian. Dampak gabungan dari volatilitas Bitcoin, data fundamental, dan sentimen pasar sering kali menentukan arah pergerakan harga aset di pasar *cryptocurrency*.

Selanjutnya analisis *technical* dalam *cryptocurrency* bertujuan untuk memprediksi pergerakan harga berdasarkan pola pasar dan indikator teknis seperti

pola *candlestick*, garis *support* dan *resistance*, *Moving Average*, serta *Relative Strength Index* (RSI). Pola *candlestick* merepresentasikan pergerakan harga pembukaan, penutupan, tertinggi, dan terendah dalam kerangka waktu tertentu. Pola ini digunakan untuk mengidentifikasi kondisi *bullish* dan *bearish*, termasuk sinyal beli atau jual. Indikator seperti *Simple Moving Average* (SMA) dan *Exponential Moving Average* (EMA) memberikan gambaran tren harga jangka pendek, menengah, hingga panjang. EMA 9, 21, dan 100 sering digunakan untuk menentukan titik beli dan jual berdasarkan hubungan antara harga aktual dan nilai EMA. Kombinasi ini memberikan panduan praktis untuk menentukan waktu optimal transaksi.

RSI melengkapi analisis *technical* dengan mengukur kekuatan tren dan mengidentifikasi kondisi *overbought* atau *oversold*. RSI 7 dan RSI 21 digunakan untuk melihat tren jangka pendek dan menengah. Nilai RSI di atas 70 menunjukkan kondisi *overbought*, sedangkan di bawah 30 menandakan *oversold*, memberikan indikasi potensi pembalikan harga. Dalam contoh analisis harga XRP/USD, pola *candlestick* seperti Marubozu, Doji, dan Bullish Harami dikombinasikan dengan sinyal dari RSI dan EMA untuk mengonfirmasi tren. Misalnya, saat RSI mendekati 70 dan harga mendekati *resistance*, pola Doji menunjukkan potensi pembalikan tren dari *bullish* ke *bearish*. Sebaliknya, pola Bullish Harami pada area *support* memberikan sinyal pembalikan ke arah atas. Kombinasi indikator ini membantu memahami perubahan kekuatan antara pembeli dan penjual serta memandu pengambilan keputusan di pasar *cryptocurrency*.

Algoritma *Temporal Convolutional Network* (TCN) menggunakan *Python* menunjukkan performa baik dalam memprediksi harga *cryptocurrency* seperti Bitcoin, dengan nilai MAE sebesar 733.94 dan MSE sebesar 1,340,144.46 pada data latih, serta MAE 1,344.52 dan MSE 3,498,533.78 pada data uji. Prediksi 5 langkah ke depan menunjukkan tren kenaikan harga dari 9,440.6 ke 92,487.73, menunjukkan kemampuan algoritma dalam menangkap pola kompleks data historis dan memberikan indikasi pergerakan harga di masa depan. Meski demikian, performa pada data uji mengindikasikan potensi optimasi untuk meningkatkan generalisasi algoritma. Secara keseluruhan, TCN terbukti efektif dalam mendukung analisis volatilitas *cryptocurrency* dan pengambilan keputusan berbasis data.

PRAKATA

Puji syukur ke hadirat Allah SWT atas segala rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi yang berjudul ”*Multi-Time Forecasting dalam Volatilitas Cryptocurrency Berbasis Analisis Fundamental, Technical, dan Machine Learning*”. Penelitian ini diajukan guna melengkapi tugas akhir dan memenuhi salah satu syarat untuk menyelesaikan Pendidikan strata satu (S1) pada Program Studi Pendidikan Matematika Fakultas Keguruan Dan Ilmu Pendidikan Universitas Jember.

Penyusunan skripsi ini tidak lepas dari bantuan berbagai pihak. Oleh karena itu, penulis menyampaikan terima kasih kepada:

1. Dekan Fakultas Keguruan dan Ilmu Pendidikan Universitas Jember;
2. Ketua Jurusan Pendidikan MIPA FKIP Universitas Jember;
3. Koordinator Program Studi Pendidikan Matematika FKIP Universitas Jember;
4. Ketua Laboratorium Matematika Program Studi Pendidikan Matematika Jurusan Pendidikan MIPA FKIP Universitas Jember;
5. Dosen Pembimbing Akademik yang telah membimbing dan memberikan ilmu;
6. Prof. Drs. Dafik, M.Sc., Ph.D. dan Ibu Rafiantika Megahnia Prihandini, S.Pd., M.Si. selaku Dosen Pembimbing yang telah meluangkan waktu dan pikiran hingga terselesaikannya penulisan skripsi ini;
7. Prof. Drs. Antonius Cahya Prihandoko, M.App.Sc., Ph.D. dan Ibu Robiatul Adawiyah, S.Pd., M.Si. selaku Dosen Penguji yang telah memberikan kritik dan saran yang membangun dalam penyempurnaan skripsi ini;
8. Dosen dan Karyawan FKIP Universitas Jember;
9. Semua pihak yang telah membantu terselesaikannya skripsi ini.

Penulis juga menerima segala kritik dan saran dari semua pihak demi kesempurnaan skripsi ini. Akhirnya penulis berharap, semoga skripsi ini dapat bermanfaat.

Jember, 14 Januari 2025

Penulis

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
HALAMAN PERSEMBAHAN	ii
HALAMAN MOTTO	iii
HALAMAN PERNYATAAN	iv
HALAMAN PERSETUJUAN	v
ABSTRACT	vi
RINGKASAN	vii
PRAKATA	ix
DAFTAR ISI	x
DAFTAR GAMBAR	xii
DAFTAR TABEL	xiv
BAB 1. PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Tujuan Penelitian	3
1.4 Manfaat Penelitian	4
1.5 Batasan Masalah	4
1.6 Kebaharuan	4
BAB 2. TINJAUAN PUSTAKA	5
2.1 Cryptocurrency	5
2.2 Analisis Fundamental	6
2.3 Analisis Technical	7
2.4 Analisis On-chain	10

2.5 Temporal Convolutional Network	12
BAB 3. METODE PENELITIAN	14
3.1 Jenis Penelitian	14
3.2 Jenis dan Sumber Data	14
3.3 Teknik Pengumpulan Data	15
3.4 Prosedur Penelitian	16
BAB 4. HASIL DAN PEMBAHASAN	18
4.1 Analisis Fundamental	19
4.2 Analisis Technical	30
4.3 Analisis On-Chain	46
4.4 Temporal Convolutional Network	52
4.5 Integrasi Analisis Fundamental, Technical, dan Machine Learning	71
BAB 5. KESIMPULAN DAN SARAN	76
5.1 Kesimpulan	76
5.2 Saran	77
DAFTAR PUSTAKA	78
LAMPIRAN	82

DAFTAR GAMBAR

	Halaman
2.1 Historical BTC Volatility	5
2.2 Cryptocurrency News	6
2.3 Candlestick	7
2.4 Support & Resistance Line	8
2.5 Moving Average dan Relative Strength Index	9
2.6 MetaMask	11
2.7 Etherscan	11
2.8 Temporal Convolutional Network	13
3.1 Prosedur Penelitian	17
4.1 Urutan Aset Terbaik Cryptocurrency Oleh Market Cap	20
4.2 Konektivitas Cryptocurrency Berdasarkan Matriks Korelasi	21
4.3 Aplikasi Phantom	22
4.4 Dexscreener	23
4.5 Token nub pada Dexscreener	24
4.6 Token nub pada Solscan	26
4.7 Pembelian \$1M Dollar BTC oleh Bank Italia	27
4.8 Berita Pertumbuhan Bitcoin ATM	28
4.9 Heatmap Pasar Cryptocurrency sebelum Berita	29
4.10 Heatmap Pasar Cryptocurrency setelah Berita	30
4.11 Analisis Pola Candlestick	31
4.12 Analisis Candlestick Jual-Beli	32
4.13 Analisis Candlestick dengan FR	33

4.14 Dominasi Bitcoin pada Pasar <i>Cryptocurrency</i>	34
4.15 EMA Solana tahun 2024	37
4.16 EMA Solana November-Desember 2024	38
4.17 RSI Bitcoin 2024	43
4.18 Diagram Uji XRP 9-12 Desember 2024	45
4.19 Normalisasi Harga dan Total Transaksi Bitcoin 2024	47
4.20 Normalisasi Harga dan Ukuran Blok Bitcoin 2024	48
4.21 Normalisasi Harga dan <i>Hash Rate</i> Bitcoin 2024	49
4.22 Normalisasi Harga dan <i>Trade Volume</i> Bitcoin 2024	50
4.23 Normalisasi Harga dan <i>Difficulty</i> Bitcoin 2024	52
4.24 <i>Temporal Convolutional Network</i>	53
4.25 Library TCN	59
4.26 Import Dataset	59
4.27 Normalisasi Data	60
4.28 Membangun Data Input dan Label	61
4.29 Arsitektur TCN	62
4.30 <i>Train Data</i>	63
4.31 Metrik Evaluasi	63
4.32 Algoritma <i>Forecasting</i> TCN	64
4.33 <i>Forecasting</i> Harga Penutupan BTC	67
4.34 <i>Forecasting</i> Harga Pembukaan BTC	67
4.35 <i>Forecasting</i> Harga Tertinggi BTC-USD	68
4.36 <i>Forecasting</i> Harga Terendah BTC-USD	69
4.37 Perbandingan MAE dan MSE pada TCN, LSTM, dan GRU	70
4.38 Berita Pernyataan BTC sebagai <i>Digital Gold</i>	72
4.39 Analisis <i>Technical</i> Bitcoin/USDT	73
4.40 <i>Forecasting</i> TCN pada Bitcoin/USDT	74

DAFTAR TABEL

	Halaman
3.1 Definisi Operasional Variabel Penelitian	15
4.1 Contoh Dataset Harga Cryptocurrency Harian	36
4.2 Contoh Dataset Harga Cryptocurrency Harian dengan Perubahan Harga	40
4.3 Tabel Perubahan Harga Positif dan Negatif Cryptocurrency Harian	41
4.4 Dataset Harga Ethereum	54
4.5 Dataset Harga Open Ethereum	55
4.6 Contoh Dataset Harga Cryptocurrency Harian	58
4.7 Eksperimen Parameter TCN	66
4.8 Perbandingan Kinerja Model TCN, LSTM, dan GRU	70

BAB 1. PENDAHULUAN

1.1 Latar Belakang

Investasi menjadi aktivitas yang semakin diminati masyarakat karena berpotensi menghasilkan keuntungan finansial. Masyarakat melakukan investasi untuk mencapai tujuan seperti menciptakan keuntungan, memperoleh profit maksimal, dan meningkatkan kesejahteraan (Judijanto et al., 2024). Berbagai instrumen investasi telah tersedia, seperti saham, obligasi, emas, properti, dan *cryptocurrency* (mata uang kripto). *Cryptocurrency* seperti Bitcoin dan Ethereum adalah mata uang digital yang menggunakan teknologi kriptografi. Teknologi ini menjamin keamanan transaksi dan memungkinkan transfer digital yang efisien (Dharma & Gusniati, 2023).

Cryptocurrency menarik minat besar di kalangan investor karena potensi pertumbuhan yang signifikan, meskipun disertai volatilitas yang tinggi. Volatilitas *cryptocurrency* adalah tingkat perubahan harga *cryptocurrency* yang sangat cepat dan fluktuatif dalam periode waktu tertentu. Faktor-faktor seperti penurunan pasar keuangan global, krisis perusahaan, tingkat pengangguran yang meningkat, dan perubahan perilaku konsumen sering mempengaruhi harga *cryptocurrency*. Faktor-faktor ini membuat pasar *cryptocurrency* menjadi sulit diprediksi (Kuncara & Anugrah, 2023). Oleh karena itu, diperlukan metode prediksi untuk meminimalisir risiko kerugian.

Multi-time forecasting adalah prediksi gabungan mata uang yang memanfaatkan data dari berbagai kerangka waktu untuk menganalisis volatilitas *cryptocurrency* dengan menggabungkan analisis fundamental, *technical*, dan *machine learning*. Analisis fundamental digunakan untuk menilai nilai intrinsik *cryptocurrency* dengan mengevaluasi faktor ekonomi global, kebijakan moneter, adopsi teknologi blockchain, dan berita pasar yang dapat memengaruhi harga jangka panjang. Analisis *technical* digunakan untuk mengidentifikasi pola dan tren harga dengan memanfaatkan data

historis. Selain menggunakan analisis fundamental, penelitian ini juga menerapkan analisis *technical* seperti pola *candlestick*, *support-resistance line*, *Simple Moving Average (SMA)*, dan *Exponential Moving Average (EMA)*. Pola *candlestick* membantu investor mengenali perubahan signifikan pada harga, sedangkan *support-resistance line* menunjukkan level harga yang penting dalam pergerakan pasar. *Simple Moving Average (SMA)* digunakan untuk menghitung rata-rata harga dalam periode tertentu, sehingga membantu mengidentifikasi tren secara keseluruhan. *Exponential Moving Average (EMA)* memberikan bobot lebih besar pada data harga terbaru, sehingga lebih responsif terhadap perubahan harga terkini. Selain itu, indikator *Relative Strength Index (RSI)* digunakan untuk mengukur kekuatan dan kecepatan pergerakan harga, membantu investor mendeteksi kondisi *overbought* atau *oversold* yang dapat mengindikasikan potensi pembalikan arah harga.

Penerapan analisis fundamental dan *technical* dapat diperkuat dengan memanfaatkan *machine learning* seperti *Temporal Convolutional Network (TCN)*. Menurut penelitian Dai et al. (2022), *Temporal Convolutional Network (TCN)* memiliki kemampuan yang kuat dalam memproses data sekuensial yang sangat besar dan dinamis, sehingga mampu meningkatkan akurasi prediksi perubahan harga dalam frekuensi ultra tinggi. TCN menggunakan mekanisme konvolusi kausal dan dilatasi untuk menangkap pola jangka panjang tanpa menggunakan informasi waktu di masa depan, memberikan model ini keunggulan signifikan dibandingkan model tradisional seperti *Long Short Term Memory (LSTM)* dalam prediksi data pasar keuangan. Penelitian Shaikh et al. (2023) juga menegaskan bahwa TCN mampu memproses data secara paralel, mempercepat komputasi serta meningkatkan akurasi pada data dengan pola musiman atau fluktuasi jangka panjang.

Berdasarkan latar belakang yang telah dijelaskan, penelitian ini akan mengeksplorasi bagaimana analisis fundamental dapat memberikan wawasan tentang nilai intrinsik *cryptocurrency*, sementara analisis *technical* membantu

mengidentifikasi pola dan tren harga yang berulang. Selain itu, algoritma TCN menggunakan *Python* diharapkan mampu meningkatkan akurasi dalam memprediksi pergerakan harga yang fluktuatif. Penelitian ini mengajukan studi yang berjudul “***Multi-Time Forecasting dalam Volatilitas Cryptocurrency Berbasis Analisis Fundamental, Technical, dan Machine Learning***”.

1.2 Rumusan Masalah

Berdasarkan pemaparan latar belakang di atas, maka rumusan masalah dalam penelitian ini adalah:

- a. Bagaimana analisis *multi-time forecasting* terhadap volatilitas *cryptocurrency* dapat diaplikasikan dengan mengintegrasikan analisis fundamental?
- b. Bagaimana analisis *multi-time forecasting* terhadap volatilitas *cryptocurrency* dapat diaplikasikan dengan mengintegrasikan analisis *technical*?
- c. Bagaimana skema model *multi-step time series forecasting* terhadap volatilitas *cryptocurrency* dengan menggunakan model *Temporal Convolutional Network* (TCN)?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah dan pemaparan latar belakang di atas, adapun tujuan dari penelitian ini adalah:

- a. Menjelaskan bagaimana analisis *multi-time forecasting* terhadap volatilitas *cryptocurrency* dapat diaplikasikan dengan mengintegrasikan analisis fundamental.
- b. Menjelaskan bagaimana analisis *multi-time forecasting* terhadap volatilitas *cryptocurrency* dapat diaplikasikan dengan mengintegrasikan analisis *technical*.
- c. Mengembangkan dan mengevaluasi model *multi-time series forecasting* terhadap volatilitas *cryptocurrency* dengan menggunakan model *Temporal Convolutional Network* (TCN).

1.4 Manfaat Penelitian

Manfaat yang diharapkan dari hasil penelitian ini adalah:

- a. Memberikan wawasan dan pengetahuan mendalam mengenai penerapan analisis fundamental, *technical*, dan model *Temporal Convolutional Network* (TCN) dalam melakukan *multi-time forecasting* terhadap volatilitas *cryptocurrency*.
- b. Menambah wawasan dan sebagai bahan pertimbangan dalam pengambilan keputusan investasi pada *cryptocurrency* dengan memanfaatkan analisis volatilitas yang lebih akurat melalui pendekatan *multi-time forecasting*.

1.5 Batasan Masalah

Batasan masalah dalam penelitian ini adalah:

- a. Program yang digunakan adalah *Python* melalui aplikasi *Anaconda*.
- b. Data yang diambil adalah *date*, *open*, *close*, *low*, dan *high* pada tahun 2024.
- c. Penerapan *Temporal Convolutional Network* (TCN) menggunakan *Python* untuk menganalisis volatilitas *cryptocurrency*.
- d. Jenis *coin cryptocurrency* yang digunakan adalah Bitcoin dan 31 *coin* lainnya yang berkorelasi .

1.6 Kebaruan

Kebaruan dalam penelitian ini adalah:

- a. Penerapan *multi-time forecasting* untuk memprediksi volatilitas *cryptocurrency* dengan gabungan analisis fundamental, *technical*, dan *machine learning* menggunakan pendekatan *Temporal Convolutional Network* (TCN) .
- b. Memanfaatkan indikator teknikal seperti *candle pattern*, *EMA*, *SMA*, *resistance support level*, dan *RSI* untuk analisis volatilitas *cryptocurrency* .
- c. Penerapan Algoritma *Temporal Convolutional Network* (TCN) menggunakan *Python* untuk menganalisis volatilitas *cryptocurrency*.

BAB 2. TINJAUAN PUSTAKA

2.1 *Cryptocurrency*

Cryptocurrency adalah bentuk mata uang digital yang menggunakan teknologi *blockchain* untuk mengamankan transaksi, mengontrol penciptaan unit baru, dan memverifikasi transfer kepemilikan (Zohuri et al., 2022). *Blockchain* sendiri merupakan buku besar digital yang terdesentralisasi dan tidak dapat diubah, yang mencatat semua transaksi *cryptocurrency* secara publik dan permanen. Volatilitas dalam pasar *cryptocurrency* mengacu pada perubahan harga yang cepat dan signifikan dalam jangka waktu singkat pada koin *cryptocurrency* (Mighri & Alsaggaf, 2019). Ciri utama dari volatilitas *cryptocurrency* adalah pergerakan harga yang tidak terduga dan sering kali ekstrem, yang dapat terjadi karena faktor spekulatif, kecepatan transaksi, dan lingkungan (Dudek et al., 2024). Berikut adalah contoh volatilitas pada bitcoin



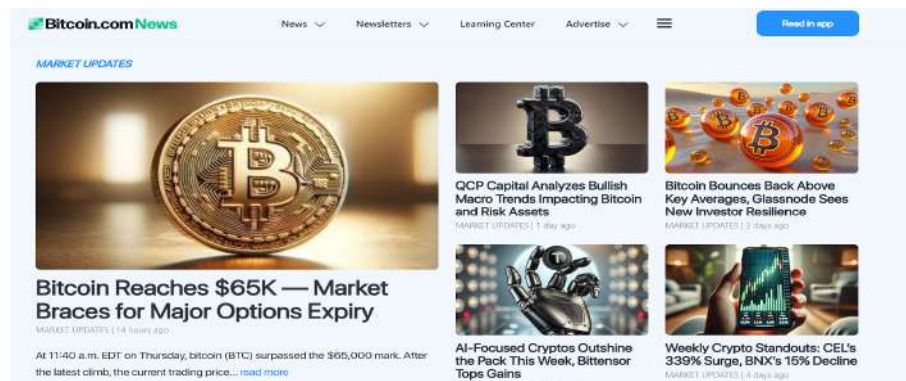
Gambar 2.1. *Historical BTC Volatility.* (Sumber: <https://www.tradingview.com/>)

Gambar 2.1 menunjukkan bahwa tiap waktu harga dari *cryptocurrency* mengalami perubahan yang signifikan. Istilah *bullish* dan *bearish* sering digunakan untuk mendeskripsikan situasi volatilitas pasar *cryptocurrency*. *Bullish* mengacu pada kondisi ketika harga aset digital mengalami peningkatan signifikan, mencerminkan

kepercayaan dan optimisme investor bahwa harga akan terus naik. Sebaliknya, bearish merujuk pada penurunan harga yang tajam, menggambarkan sikap pesimis investor terhadap prospek aset tersebut. Kedua kondisi ini, baik *bullish* maupun *bearish*, menunjukkan betapa sensitifnya harga *cryptocurrency* (Wiharno et al., 2023).

2.2 Analisis Fundamental

Analisis fundamental adalah metode evaluasi yang digunakan untuk menentukan nilai intrinsik suatu aset dengan menganalisis faktor-faktor ekonomi, keuangan, dan berbagai elemen kualitatif lainnya. Analisis fundamental pada *cryptocurrency* bertujuan untuk menilai apakah suatu *cryptocurrency* bernilai lebih rendah atau lebih tinggi dari nilai sesungguhnya dengan mempertimbangkan faktor-faktor mendasar yang mempengaruhi nilai aset tersebut (Olabanji et al., 2024). Berbeda dengan analisis *technical* yang berfokus pada pergerakan harga historis, analisis fundamental mencoba melihat nilai dari faktor-faktor yang dapat memengaruhi permintaan dan penawaran aset di masa mendatang.



Gambar 2.2. *Cryptocurrency News.* (Sumber: <https://news.bitcoin.com/>)

Gambar 2.2 merupakan contoh *website* yang menyediakan berita seputar *cryptocurrency*. Faktor-faktor utama yang dianalisis dalam analisis fundamental *cryptocurrency* meliputi kondisi ekonomi makro seperti inflasi, kebijakan moneter, dan stabilitas ekonomi global, serta perkembangan teknologi *blockchain* yang

digunakan dalam *cryptocurrency*. Selain itu, aspek regulasi juga memainkan peran penting, di mana perubahan dalam kebijakan atau pengakuan legal *cryptocurrency* di berbagai negara dapat memengaruhi adopsi dan penggunaan *cryptocurrency*. (Fang et al., 2024).

2.3 Analisis *Technical*

Analisis *technical* adalah metode analisis yang digunakan untuk memprediksi pergerakan harga aset berdasarkan data historis, seperti harga, volume, dan pola grafik. Indikator yang sering digunakan dalam analisis ini meliputi *candlestick*, *support-resistance*, *moving average*, dan RSI (*Relative Strength Index*) (Gazizova & Agcaoili, 2022). Berikut adalah penjelasan lebih lanjut tentang setiap indikator yang digunakan:

a. *Candlestick*

Candlestick adalah salah satu alat analisis *technical* yang digunakan secara luas dalam perdagangan *cryptocurrency*. *Candlestick* mencerminkan pergerakan harga dalam periode waktu tertentu dan dapat memberikan wawasan mengenai volatilitas serta arah pasar. Dalam analisis volatilitas, *candlestick* sangat berguna karena mampu menggambarkan fluktuasi harga yang terjadi (Person, 2004).



Gambar 2.3. *Candlestick*. (Sumber: <https://www.tradingview.com/>)

Gambar 2.3 menunjukkan bahwa tiap *candlestick* terdiri dari tubuh (*body*) dan bayangan (*shadow*). *Body* dari *candlestick* menunjukkan perbedaan antara harga pembukaan dan penutupan dalam suatu periode waktu. Ketika harga penutupan lebih tinggi dari pembukaan, *body* akan berwarna putih atau hijau (tergantung pada *platform* yang digunakan). Sebaliknya, saat harga penutupan lebih rendah dari pembukaan, *body* akan berwarna hitam atau merah. Panjang *body* menunjukkan seberapa besar perubahan harga dalam periode tersebut, yang juga mencerminkan tingkat volatilitas.

b. ***Support Line dan Resistance Line***

Support-Resistance adalah garis yang berfungsi menentukan saluran di mana harga cryptocurrency diperkirakan akan bergerak setelah analisis dilakukan. Garis ini membantu mengidentifikasi titik potensial untuk pembalikan harga atau kelanjutan tren (Yıldırım & Özbayoğlu, 2019). Contoh *resistance dan support line* dapat dilihat pada gambar 2.4.



Gambar 2.4. *Support & Resistance Line.* (Sumber: <https://www.tradingview.com/>)

Gambar 2.4 memperlihatkan bahwa *support-resistance line* membantu menentukan batasan harga tertinggi dan terendah, serta membantu trader dalam pengambilan keputusan untuk beli atau jual. *Support-resistance line* juga dapat mengalami kenaikan, seiring tren yang ada pada *market*.

c. **Moving Average**

Moving Average adalah strategi yang melibatkan pembelian dan penjualan secara sistematis ketika harga melintasi rata-ratanya. Tren naik terjadi ketika harga naik, dan tren turun terjadi ketika harga menurun. Ketika harga naik melewati rata-ratanya dari bawah, ini disebut sebagai sinyal beli karena harga terbaru lebih tinggi dari harga sebelumnya. Sebaliknya, ketika harga turun melewati rata-ratanya dari atas, ini disebut sebagai sinyal jual karena harga terbaru lebih rendah (Toms, 2011). Berikut adalah contoh dalam penerapan *Moving Average*



Gambar 2.5. *Moving Average* dan RSI. (Sumber: <https://www.tradingview.com/>)

Moving Average yang sering digunakan dalam *forecasting cryptocurrency* adalah *Exponential Moving Average*. Rumus perhitungan pada *Exponential Moving Average* adalah $EMA = \left(\frac{2}{t+1} \times (X_t - F_{t-1})\right) + F_{t-1}$, dimana t adalah periode yang diinginkan dalam peramalan, X_t adalah harga penutupan, dan F_{t-1} adalah nilai *EMA* sebelumnya. Pada *Exponential Moving Average* membutuhkan *EMA* sebelumnya, untuk mendapatkan nilai tersebut digunakan *Moving Average* dengan jenis *Simple Moving Average* (Sulistyanto et al., 2015). Adapun formula dari SMA adalah $SMA = \frac{\sum \text{Harga penutupan dalam periode } t}{t}$ (Kumila et al., 2019).

d. **Relative Strength Index (RSI)**

RSI adalah indikator momentum yang mengukur kekuatan atau kelemahan relatif

dari harga aset berdasarkan perubahan harga terkini. Nilai RSI berkisar antara 0 hingga 100, di mana nilai di atas 70 menunjukkan kondisi *overbought* (jenuh beli) dan di bawah 30 menunjukkan kondisi *oversold* (jenuh jual). RSI sering digunakan untuk menentukan titik masuk dan keluar dari suatu perdagangan. Relative Strength Index (RSI) dihitung menggunakan rumus:

$$RSI = 100 - \frac{100}{1 + RS}$$

Dimana:

$$RS = \frac{\text{Rata-rata kenaikan (Average Gain)}}{\text{Rata-rata penurunan (Average Loss)}}$$

Rata-rata kenaikan dan penurunan dapat dihitung sebagai berikut:

$$\text{Average Gain} = \frac{\sum \text{Kenaikan harga dalam periode } t}{t}$$

$$\text{Average Loss} = \frac{\sum \text{Penurunan harga dalam periode } t}{t}$$

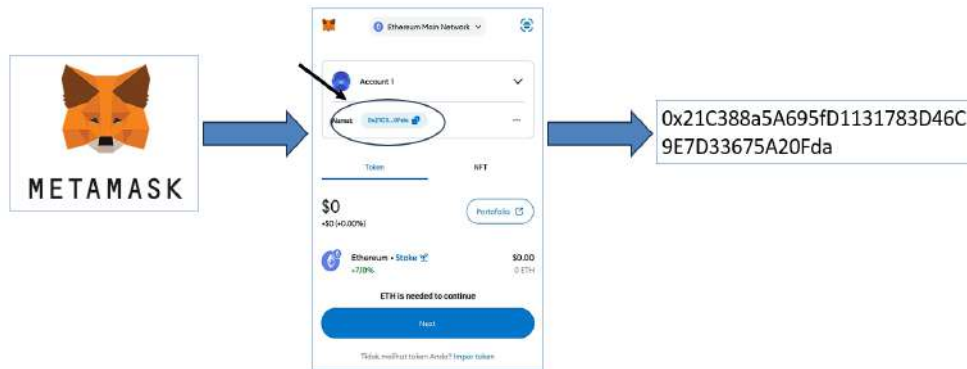
Dengan:

- t : Jumlah periode yang digunakan dalam perhitungan RSI (umumnya 14).
- \sum : Jumlah dari kenaikan atau penurunan harga selama periode t .

2.4 Analisis *On-chain*

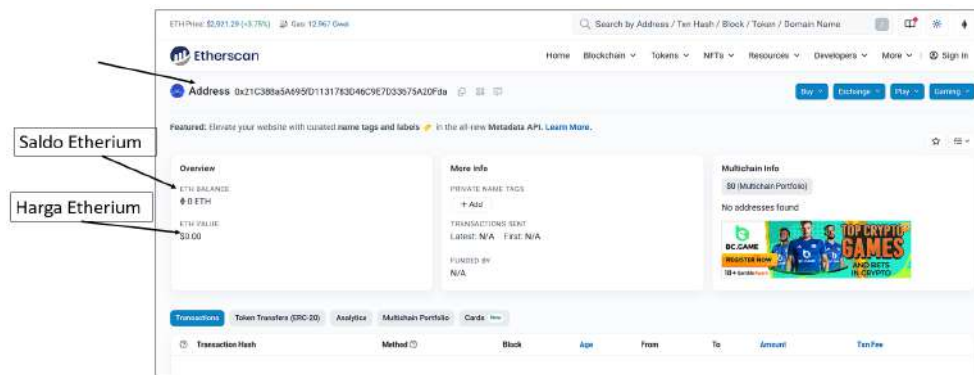
Analisis *on-chain* adalah studi tentang data yang tersimpan di jaringan *blockchain*, atau dikenal juga sebagai analisis *blockchain*. Semua data transaksi tercatat dalam *blockchain* dan tidak dapat diubah, sehingga memungkinkan untuk melihat keseluruhan data tersebut (Gu, Lin, & Wu, 2022). Salah satu alat penting dalam ekosistem *blockchain* adalah MetaMask. MetaMask merupakan dompet digital berbasis perangkat lunak (*software wallet*) yang berfungsi sebagai jembatan

antara pengguna dan jaringan *blockchain* seperti Ethereum. Berikut adalah contoh penggunaan MetaMask.



Gambar 2.6. *MetaMask*

Gambar 2.6 menunjukkan alamat wallet pengguna yang unik ditampilkan, dimulai dengan "0x" yang merupakan identitas pengguna di jaringan blockchain Ethereum. Alamat ini, seperti yang terlihat pada gambar (0x21C388a5A695fD1131783D46C9E7D33675A20Fda), digunakan untuk mengirim dan menerima aset *cryptocurrency*, di mana setiap aktivitas akan dicatat secara *on-chain* di jaringan Ethereum, yang bersifat transparan dan dapat diakses melalui penjelajah *blockchain* seperti *Etherscan* seperti gambar di bawah.



Gambar 2.7. *Etherscan*

Gambar 2.7 merupakan tampilan Etherscan yang menunjukkan informasi dasar

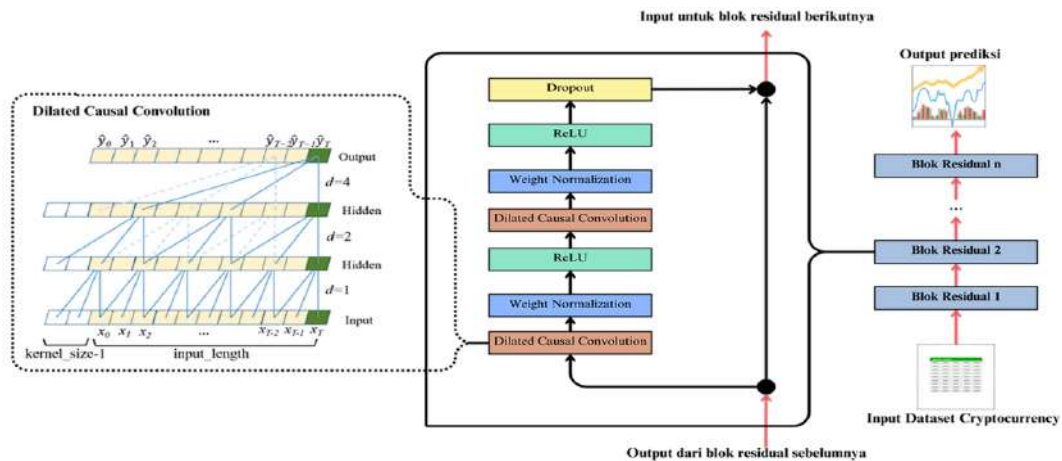
mengenai alamat wallet Ethereum, termasuk saldo, nilai aset dalam mata uang, serta harga Ethereum terkini. Etherscan berfungsi sebagai penjelajah *blockchain* yang memungkinkan pengguna untuk memantau aktivitas *on-chain* secara transparan, seperti melihat saldo, riwayat transaksi, dan biaya gas yang berlaku. Dengan fitur ini, pengguna dapat memverifikasi status transaksi dan aset *cryptocurrency* yang tersimpan di dalam dompet, sehingga Etherscan menjadi alat penting dalam ekosistem *blockchain* untuk memastikan keterbukaan data.

2.5 *Temporal Convolutional Network*

Temporal Convolutional Network (TCN) adalah model jaringan saraf berbasis convolusi yang dirancang khusus untuk menangani data sekuensial atau deret waktu. Berbeda dengan model *Recurrent Neural Network* (RNN) yang memproses data secara berurutan, TCN menggunakan convolusi untuk memproses data dalam format sekuensial tanpa memerlukan dependensi urutan langsung (Chen et al., 2024). Dengan memanfaatkan struktur convolusi kausal, TCN memastikan bahwa prediksi pada waktu tertentu hanya dipengaruhi oleh data masa lalu dan saat ini, tanpa menggunakan informasi dari masa depan.

Elemen penting yang digunakan dalam TCN adalah *dilated convolution* atau convolusi yang diperlebar, untuk menangkap pola jangka panjang dalam data deret waktu. *Dilated convolution* memungkinkan TCN memperluas jangkauan pengaruh setiap layer convolusi tanpa menambah jumlah parameter secara signifikan (Bouteska et al., 2024). Dalam data deret waktu, TCN dapat "melihat" jauh ke belakang dalam data historis, sehingga sangat efektif dalam memodelkan data yang memerlukan pemahaman pola jangka panjang, seperti harga pasar atau transaksi frekuensi tinggi. TCN juga menggunakan *weight normalization* dan *dropout* untuk meningkatkan performa model. *Weight normalization* membantu mempercepat konvergensi pelatihan dengan mengatur bobot (*weights*) dalam jaringan, sehingga

pelatihan menjadi lebih stabil dan efisien. *Dropout* berfungsi sebagai teknik regulasi untuk mencegah *overfitting* dengan mengacak sejumlah neuron secara acak selama pelatihan, sehingga jaringan menjadi mampu mempelajari pola yang lebih umum daripada hanya menghafal data pelatihan (Gopali et al., 2021).



Gambar 2.8. *Temporal Convolutional Network*

Gambar 2.8 menunjukkan siklus dari perhitungan dalam algoritma TCN. TCN memanfaatkan *residual connections*, yang sangat penting dalam arsitektur convolusi bertingkat. Selain itu, *ReLU* digunakan sebagai fungsi aktivasi pada setiap lapisan convolusi untuk menambah non-linearitas dan meningkatkan kemampuan model dalam mempelajari pola kompleks. *ReLU* (*Rectified Linear Unit*) adalah fungsi aktivasi yang paling umum digunakan dalam TCN. Fungsi ini mengembalikan 0 jika menerima input negatif, tetapi untuk nilai positif x , fungsi ini mengembalikan nilai tersebut. Oleh karena itu, fungsi ini dapat ditulis sebagai $f(x) = \max(0, x)$. Hal ini membuat TCN lebih efektif dalam mempelajari pola yang kompleks dalam data deret waktu (Siame-Namini et al., 2018).

BAB 3. METODE PENELITIAN

3.1 Jenis Penelitian

Jenis penelitian yang digunakan dalam penelitian ini adalah penelitian analitik dan eksperimental. Penelitian analitik diterapkan dalam analisis *on-chain*, analisis *candlestick*, dan analisis korelasi. Analisis *on-chain* dilakukan untuk memahami data *cryptocurrency* pada *market blockchain*. Analisis *candlestick* mengarah pada analisis *technical* dalam perubahan harga *cryptocurrency* pada. Sementara itu, analisis korelasi digunakan dalam mencari korelasi dari beberapa aset koin *cryptocurrency*.

Pendekatan eksperimental dalam pemrograman komputer diterapkan untuk membangun dan menguji model prediksi volatilitas berbasis *Temporal Convolutional Network* (TCN) yang bertujuan melakukan *multi-time forecasting*, yakni prediksi untuk berbagai jangka waktu berdasarkan data pasar yang telah diolah. Model ini memanfaatkan data seperti *open*, *high*, *low*, dan *close* dari setiap koin untuk menghasilkan pola volatilitas yang lebih akurat dan andal. Selama pelatihan, algoritma *Backpropagation Through Time* (BPTT) digunakan untuk menghitung gradien dari kesalahan prediksi, dengan metrik evaluasi seperti *Mean Squared Error* (MSE) dan *Mean Absolute Error* (MAE) yang berfungsi untuk mengukur akurasi prediksi dalam berbagai jangka waktu. Dalam implementasinya, TCN menerapkan konvolusi kausal dengan dilatasi dan koneksi residual, yang memungkinkan model menangkap pola jangka panjang dalam data tanpa kehilangan informasi historis. Proses ini membantu TCN mengenali pola volatilitas dari data historis *cryptocurrency* dan meningkatkan akurasi prediksi volatilitas dalam berbagai jangka waktu.

3.2 Jenis dan Sumber Data

Dalam penelitian ini diperlukan dataset historis harga Bitcoin. Dataset tersebut terdiri dari tujuh jenis variabel yang relevan. Peneliti kemudian menyederhanakan

dataset menjadi lima variabel utama, yaitu *date*, *open price*, *high price*, *low price*, dan *close price*. Dataset ini diambil dari *website* Marketwatch dan Yahoo Finance, dengan data tahun 2023-2024. Format dari dataset adalah *csv*, yaitu format file teks sederhana yang digunakan untuk menyimpan data dalam bentuk tabel. Tabel berikut menjelaskan definisi operasional dari variabel-variabel yang digunakan dalam penelitian ini:

Tabel 3.1. Definisi Operasional Variabel Penelitian

Variabel	Definisi Operasional
Date	Tanggal pencatatan data harga saham dalam format YYYY-MM-DD
Open Price	Harga pembukaan saham pada hari perdagangan yang dimulai
High Price	Harga tertinggi yang dicapai saham selama sesi perdagangan
Low Price	Harga terendah yang dicapai saham selama sesi perdagangan
Close Price	Harga penutupan saham pada akhir sesi perdagangan

3.3 Teknik Pengumpulan Data

Dalam penelitian ini, teknik pengumpulan data yang digunakan adalah sebagai berikut:

1. Teknik *Time Series*

Data yang digunakan dalam penelitian ini disusun berdasarkan urutan waktu (*time series*) untuk menganalisis perubahan volatilitas harga *cryptocurrency* dalam berbagai rentang waktu (*multi-time frame*). Data yang dikumpulkan meliputi harga pembukaan (*open*), harga tertinggi (*high*), harga terendah (*low*), harga penutupan (*close*), dan tanggal (*date*).

2. Studi Pustaka

Penelitian ini juga dilakukan dengan teknik studi pustaka, yaitu mengumpulkan literatur dari jurnal, buku, laporan penelitian, dan artikel yang berkaitan dengan volatilitas *cryptocurrency*, analisis fundamental, analisis *technical*, dan teknik *machine learning*, khususnya penggunaan model *Temporal Convolutional Network* (TCN).

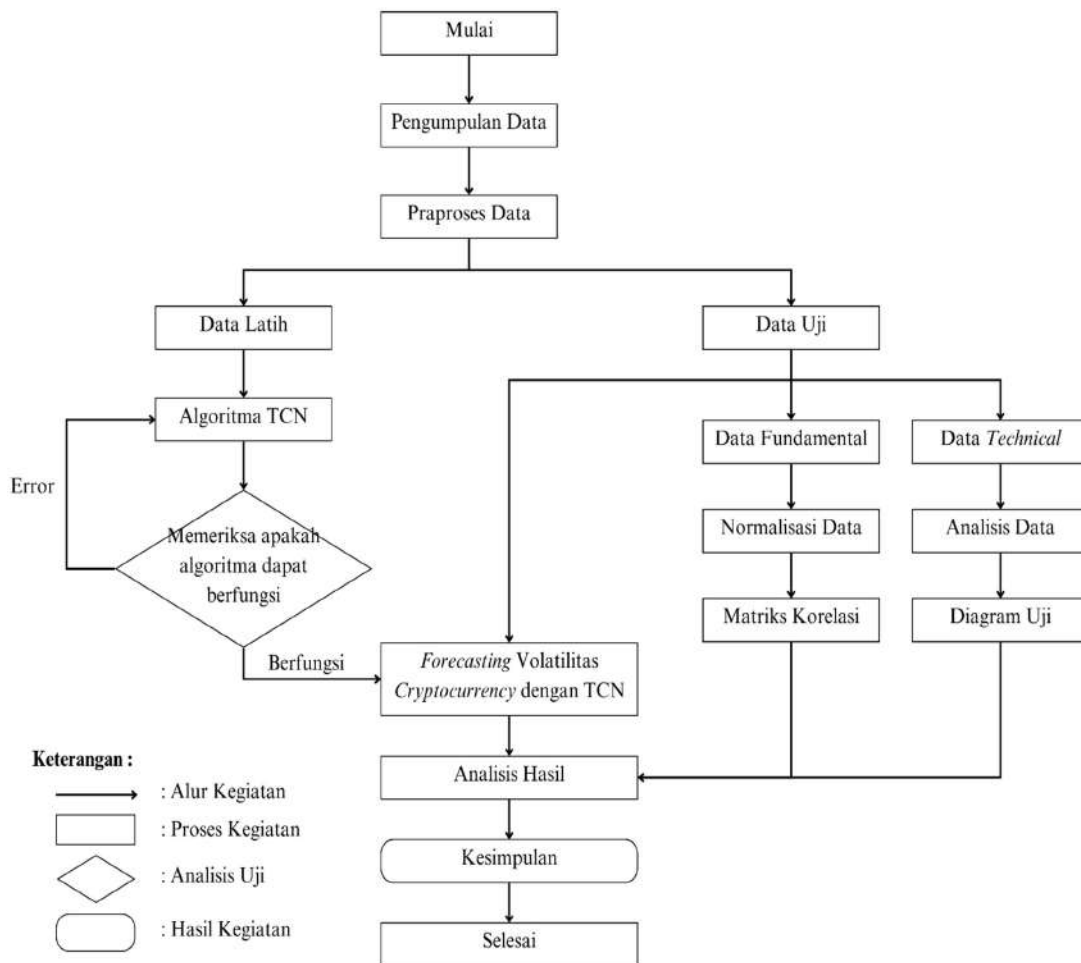
3.4 Prosedur Penelitian

Prosedur penelitian merupakan langkah-langkah yang dilakukan sebagai pedoman penelitian agar diperoleh hasil yang sesuai dengan tujuan penelitian. Berikut prosedur penelitian yang digunakan dalam penelitian ini:

1. Pengumpulan data historis *cryptocurrency* yang terdiri dari:
 - a. *Date* (tanggal),
 - b. *Open price* (harga pembukaan),
 - c. *High price* (harga tertinggi),
 - d. *Low price* (harga terendah),
 - e. *Close price* (harga penutupan).
2. Praproses data untuk memastikan bahwa data tidak ada yang NaN atau kosong;
3. Pembagian data dilakukan menjadi data latih dan data uji, dengan perbandingan jumlah data latih 80% dan data uji 20%;
4. Pembentukan model *Temporal Convolutional Network* (TCN) dengan menggunakan data latih;
5. Pemeriksaan model TCN:
 - a. Jika model tidak berfungsi dengan baik, lakukan penyesuaian *hyperparameter* atau struktur model.
 - b. Jika model berfungsi dengan baik, lanjutkan ke tahap berikutnya.
6. Melakukan prediksi volatilitas *cryptocurrency* menggunakan TCN dengan data uji yang sudah diproses;
7. Analisis hasil:
 - a. Analisis matriks korelasi untuk memahami hubungan antarkoin *cryptocurrency*;
 - b. Analisis hasil pada diagram uji *technical* untuk menebak pergerakan harga berdasarkan *open*, *high*, *low*, dan *close price*;

- c. Analisis grafik hasil *forecasting* menggunakan *TCN* untuk mengetahui harga di periode yang akan datang.
8. Menyusun kesimpulan berdasarkan hasil analisis fundamental, *technical*, dan *Machine Learning* model *TCN*.

Secara umum, prosedur penelitian dalam penelitian ini dapat dilihat pada *flowcart* yang disajikan pada Gambar 3.1.



Gambar 3.1. Prosedur Penelitian

BAB 4. HASIL DAN PEMBAHASAN

Bab ini menjelaskan hasil penelitian mengenai penerapan *multi-time forecasting* pada volatilitas *cryptocurrency* dengan integrasi analisis fundamental, analisis *technical*, dan metode *machine learning*. Proses penelitian dimulai dengan pengumpulan data historis *cryptocurrency* yang mencakup data fundamental dan *technical*. Data fundamental diambil dari website yang menyediakan seputar berita dan tingkatan tiap koin *cryptocurrency* dan data *technical* diambil dari website *yahoo finance* sebagai salah satu penyedia data harga historis *cryptocurrency*. Setelah data dikumpulkan, dilakukan tahap praproses data untuk memastikan data terisi semua dan tidak ada nilai yang hilang, sehingga siap untuk analisis lebih lanjut. Data yang telah diproses kemudian dibagi menjadi dua kelompok utama, yaitu data latih dan data uji.

Analisis fundamental melibatkan pengolahan data ekonomi makro, seperti inflasi, tingkat suku bunga, volume perdagangan, dan sentimen pasar, yang kemudian dinormalisasi untuk memastikan skala seragam. Hasil dari analisis ini dipetakan dalam matriks korelasi, yang menggambarkan hubungan antara variabel fundamental dan volatilitas *cryptocurrency*. Di sisi lain, data *technical* dianalisis menggunakan indikator *technical* seperti *Exponential Moving Average (EMA)*, garis *support-resistance*, dan *Relative Strength Index (RSI)*. Hasil analisis *technical* divisualisasikan dalam bentuk diagram untuk memahami pola volatilitas harga.

Data latih digunakan untuk melatih algoritma *Temporal Convolutional Networks (TCN)*. Proses pelatihan ini mencakup evaluasi error secara iteratif hingga algoritma berhasil berfungsi dengan baik. Setelah algoritma TCN berfungsi optimal, data uji digunakan untuk memvalidasi performa prediksi volatilitas. Akhirnya, hasil dari prediksi algoritma TCN dibandingkan dengan matriks korelasi dan analisis *technical* untuk memastikan konsistensi. Analisis hasil ini menjadi dasar dalam menyusun kesimpulan penelitian terkait dengan efektivitas integrasi fundamental, *technical*, dan

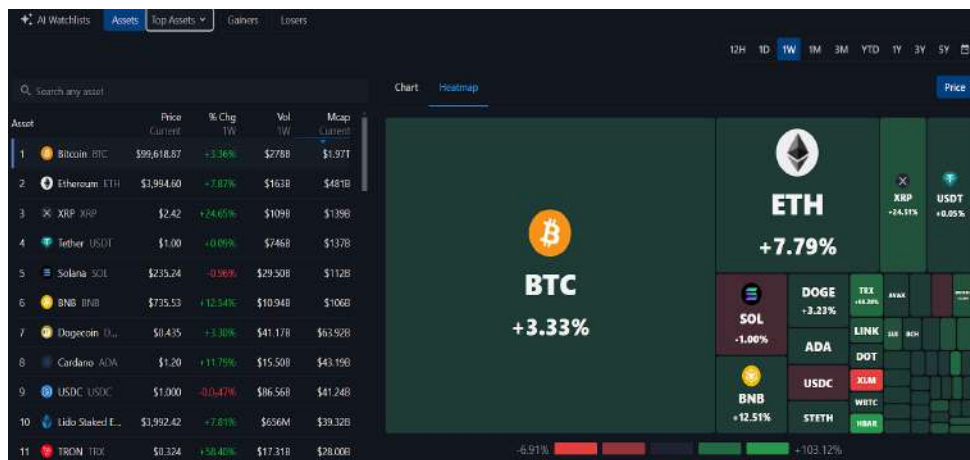
metode TCN dalam memprediksi volatilitas *cryptocurrency*.

4.1 Analisis Fundamental

Analisis *fundamental* dalam *cryptocurrency* berfokus pada evaluasi nilai intrinsik suatu aset dengan memanfaatkan data fundamental yang relevan, seperti adopsi teknologi, jumlah transaksi harian, biaya transaksi rata-rata, jumlah alamat aktif, serta aktivitas jaringan. Analisis ini bertujuan untuk memahami faktor-faktor dasar yang dapat memengaruhi nilai aset di masa depan, dengan memperhatikan aspek-aspek seperti perkembangan proyek, berita atau sentimen pasar, regulasi, dan utilitas *blockchain*. Investor biasanya menggunakan metrik fundamental ini untuk menilai kesehatan dan potensi pertumbuhan suatu aset, sehingga dapat membantu dalam pengambilan keputusan terkait pembelian atau penjualan aset berdasarkan volatilitas *cryptocurrency* di pasar.

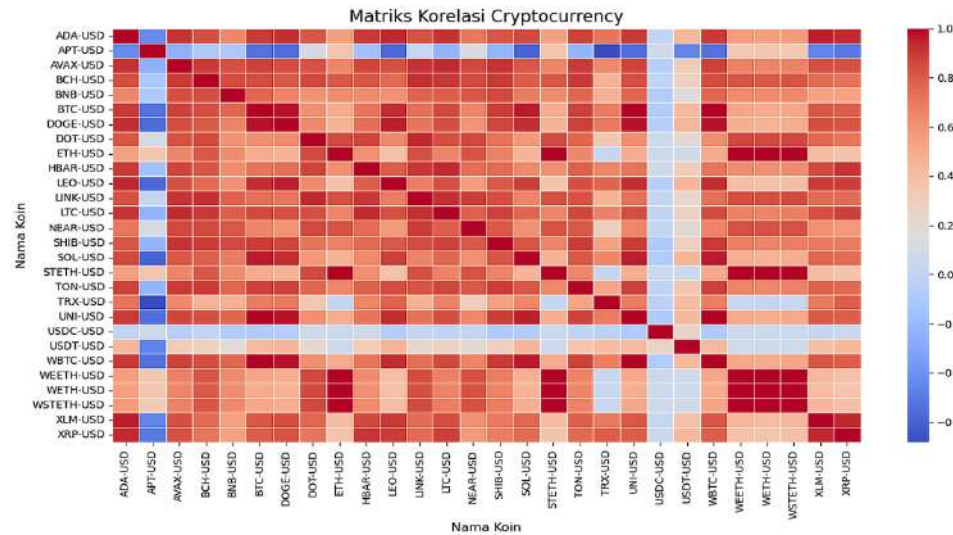
Bitcoin adalah mata uang digital yang sangat populer dan sering digunakan sebagai investasi atau alat pembayaran global, sehingga dinobatkan sebagai koin paling berpengaruh terhadap *cryptocurrency* lainnya. Status Bitcoin sebagai pelopor dan pion yang mendominasi pasar *cryptocurrency*. Sebagai *cryptocurrency* pertama, Bitcoin menjadi acuan bagi mata uang digital dan memegang kapitalisasi pasar terbesar di antara seluruh *cryptocurrency*. Dominasi ini menjadikan Bitcoin sebagai pedoman arah bagi seluruh pasar *crypto* dan pergerakan volatilitasnya diawasi ketat oleh trader dan sering kali menentukan suasana pasar secara keseluruhan. Ketika Bitcoin mengalami volatilitas, biasanya Bitcoin akan menyebarkan pengaruhnya ke Altcoin (*Alternative Coin*), yaitu semua koin selain Bitcoin, seperti Ethereum, Binance Coin, dan lainnya, yang sering kali bergantung pada teknologi blockchain serupa namun dengan fitur tambahan dan Memecoin, yaitu koin yang berfokus pada tren dan meme, seperti Dogecoin atau Shiba Inu, yang cenderung bergantung pada popularitas internet dan sering kali mengalami volatilitas tinggi, sehingga menyebabkan

volatilitasnya bergerak seperti Bitcoin. Fenomena ini, yang dikenal sebagai ”*Bitcoin Effect*” menggambarkan bagaimana volatilitas atau sentimen di sekitar Bitcoin dapat menyebabkan pergerakan yang berkorelasi pada *cryptocurrency* lainnya. Pengaruhnya begitu signifikan sehingga kesehatan dan tren pasar Bitcoin sering dilihat sebagai indikator keadaan lengkap *cryptocurrency*, lihat <https://messari.io/> pada gambar 4.1.



Gambar 4.1. Urutan Aset Terbaik *Cryptocurrency* Oleh Market Cap.

Dari Gambar 4.1 dapat dilihat bahwa Bitcoin menjadi nomor 1 aset berdasarkan hasil yang diperoleh dari halaman web *messari.io* yang bersumber dari *Market Cap*, disusul urutan kedua adalah Ethereum dan lainnya. Pengaruh Bitcoin yang begitu dominan tidak hanya membentuk arah pasar *cryptocurrency*, tetapi juga menciptakan hubungan yang erat dengan Altcoin lainnya. Korelasi ini dapat dilihat pada pergerakan harga antara Bitcoin dan Altcoin utama seperti Ethereum, Solana, dan lainnya, sebagaimana ditunjukkan dalam grafik berikut.



Gambar 4.2. Konektivitas *Cryptocurrency* Berdasarkan Matriks Korelasi

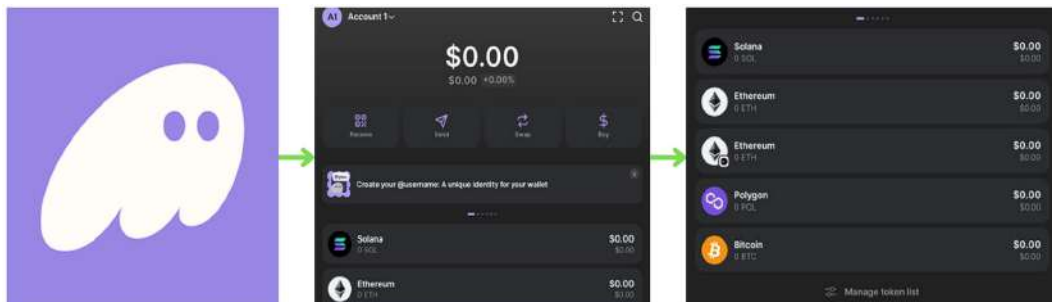
Melalui matriks korelasi yang ditampilkan pada Gambar 4.2, terlihat bahwa Bitcoin memiliki hubungan yang signifikan dengan beberapa Altcoin utama. Matriks korelasi ini menggambarkan sejauh mana pergerakan harga Bitcoin berkaitan dengan pergerakan harga Altcoin lainnya. Berdasarkan warna dalam matriks tersebut, korelasi positif ditunjukkan dengan warna merah, sementara korelasi negatif atau tidak berkaitan ditunjukkan dengan warna biru. Altcoin seperti Ethereum (ETH-USD) dan Solana (SOL-USD) menunjukkan korelasi positif yang tinggi terhadap Bitcoin, sedangkan Aptos (APT) dan USDC menunjukkan hubungan yang rendah atau bahkan negatif.

Melalui analisis matriks korelasi tersebut, dapat disimpulkan bahwa korelasi positif yang tinggi antara Bitcoin dengan Altcoin seperti Ethereum (ETH-USD) dan Solana (SOL-USD) menunjukkan bahwa kedua koin ini cenderung mengikuti pergerakan harga Bitcoin. Hal ini dapat menjadi pedoman bagi investor yang ingin memanfaatkan tren kenaikan Bitcoin dengan memilih Altcoin yang memiliki korelasi tinggi untuk diversifikasi investasi. Dengan demikian, saat Bitcoin mengalami kenaikan harga, investor dapat mengharapkan potensi keuntungan serupa pada

koin-koin tersebut.

Sebaliknya, bagi investor yang ingin menghindari risiko atau volatilitas yang terkait erat dengan Bitcoin, koin seperti Apto (APT) atau stablecoin seperti USDC dapat menjadi alternatif. Koin-koin ini menunjukkan korelasi rendah atau bahkan negatif dengan Bitcoin, yang berarti pergerakan harga mereka tidak terlalu terpengaruh oleh fluktuasi Bitcoin. Strategi ini cocok bagi mereka yang mencari stabilitas atau ingin mengurangi eksposur terhadap potensi risiko dari tren pasar yang dipengaruhi oleh Bitcoin.

Selain itu, sistem transaksi di *blockchain* juga memegang peranan penting dalam memahami pergerakan harga *cryptocurrency*. Salah satu yang sering digunakan adalah Phantom, dompet yang berjalan di atas jaringan Solana. Phantom memfasilitasi transaksi dengan cepat dan biaya rendah, yang membuatnya populer di kalangan pengguna Solana. Volume transaksi yang tinggi di Phantom dapat mencerminkan meningkatnya minat terhadap Solana, yang sering kali berdampak langsung pada harga Solana. Begitu juga dengan MetaMask, dompet yang lebih banyak digunakan di jaringan Ethereum. Dengan integrasi MetaMask, volume transaksi pada Ethereum juga dapat memberikan indikasi awal tentang potensi pergerakan harga, seiring dengan fluktuasi volume transaksi yang tercatat dalam dompet tersebut. Berikut adalah tampilan aplikasi Phantom.



Gambar 4.3. Aplikasi Phantom.

Gambar 4.3 menunjukkan antarmuka Phantom Wallet, salah satu dompet

cryptocurrency yang banyak digunakan pada jaringan Solana. Pada gambar ini, diperlihatkan beberapa fitur utama dari Phantom, seperti kemampuan untuk menerima (*Receive*), mengirim (*Send*), menukar (*Swap*), dan membeli (*Buy*) aset digital. Phantom juga memberikan pengguna akses mudah ke berbagai token yang didukung, seperti Solana (SOL), Ethereum (ETH), Polygon (MATIC), dan Bitcoin (BTC). Selain itu, fitur pengelolaan token (*Manage Token List*) memungkinkan pengguna untuk menambahkan token tambahan ke daftar aset mereka. Antarmuka yang intuitif ini mempermudah pengguna untuk memantau saldo mereka dan melakukan transaksi dengan cepat dan efisien di jaringan Solana atau *blockchain* lain yang terintegrasi. Phantom sering digunakan sebagai dompet yang terintegrasi dengan Dexscreener, yaitu alat analisis pasar yang menyediakan berbagai Memecoin.

TOKEN	PRICE	AGE	TXNS	VOLUME	MAKERS	5M	1H	6H	24H	LIQUIDITY	MCAP
nub nubool	\$0.02064	9mo	19,344	\$16.6M	4,987	-0.10%	-2.29%	1.40%	60.75%	\$2.3M	\$20.6M
MLG 360scope420blazet	\$0.1385	9mo	78,293	\$61.3M	14,359	7.49%	8.50%	-3.70%	105%	\$2.4M	\$138.2M
SAGE Sage Universe	\$0.01238	9mo	7,995	\$3.9M	2,414	-3.38%	-27.53%	-44.74%	149%	\$748K	\$12.3M
gg good game \$100	\$0.002248	5mo	27,350	\$8.7M	4,782	-0.11%	-15.78%	-40.92%	732%	\$298K	\$2.2M
YZK Doloom	\$0.002251	2mo	17,059	\$6.7M	3,732	-1.03%	1.96%	-24.96%	91.74%	\$473K	\$8.2M
TRISIG TRI SIGMA	\$0.04100	1mo	20,252	\$7.3M	3,869	0.31%	2.27%	-12.55%	-38.59%	\$12M	\$41.0M
ALCH Alchemist AI	\$0.1900	1mo	46,934	\$44.4M	8,606	1.46%	2.28%	-1.99%	17.97%	\$5.0M	\$615M
MAX MAX	\$0.1863	1mo	39,433	\$41.3M	10,029	0.81%	7.88%	40.04%	84.84%	\$4.9M	\$188.3M
GRIFT ORBIT	\$0.05978	1mo	24,190	\$13.6M	5,078	0.78%	9.69%	7.04%	48.23%	\$1.8M	\$52.5M
CHICO Side Eye Dog	\$0.006897	29d	38,882	\$5.1M	11,382	-5.48%	-17.45%	-47.63%	-38.98%	\$177K	\$688K

Gambar 4.4. Dexscreener.

Gambar 4.4 menunjukkan antarmuka platform Dexscreener, sebuah alat analisis pasar yang memungkinkan pengguna untuk memantau aset *cryptocurrency* secara real-time, termasuk Memecoin, token DeFi, dan Altcoin lainnya. Dalam gambar ini, tertera berbagai data penting dari token pada jaringan Solana, seperti nub, MLG, dan SAGE, yang mencakup informasi harga token, jumlah transaksi (TXNS), volume perdagangan, jumlah penyedia likuiditas (Makers), dan kapitalisasi pasar (Market

Cap). Dexscreener juga menunjukkan perubahan harga dalam interval waktu tertentu (5 menit, 1 jam, 6 jam, hingga 24 jam), memungkinkan pengguna untuk menganalisis tren pasar dengan lebih mendalam.

Salah satu fitur utama Dexscreener adalah kemampuan untuk terintegrasi dengan dompet *cryptocurrency* seperti Phantom Wallet, yang banyak digunakan pada jaringan Solana. Phantom Wallet memungkinkan pengguna untuk menyimpan, mengirim, menerima, dan menukar aset digital, sementara Dexscreener menyediakan data pasar dan alat analisis untuk mendukung pengambilan keputusan. Keterkaitan ini terjadi karena Dexscreener memungkinkan pengguna untuk memantau aset yang mereka miliki di dompet Phantom langsung melalui data pasar *real-time*. Dengan sekali klik pada token tertentu di Dexscreener, pengguna dapat diarahkan ke pasar desentralisasi (DEX), seperti Raydium atau Orca, untuk melakukan transaksi seperti pembelian, penjualan, atau pertukaran aset secara langsung menggunakan Phantom Wallet sebagai alat autentikasi dan pembayaran. Berikut adalah data tiap Memecoin yang disediakan oleh Dexscreener.



Gambar 4.5. Token nub pada Dexscreener.

Gambar 4.5 menampilkan data *real-time* token nub di platform Dexscreener, yang menyediakan berbagai metrik penting untuk analisis pasar *cryptocurrency*.

Likuiditas sebesar \$2.2 juta menunjukkan jumlah dana yang tersedia untuk transaksi pembelian dan penjualan tanpa menyebabkan fluktuasi harga signifikan. FDV (*Fully Diluted Valuation*) sebesar \$20.5 juta menggambarkan nilai total token jika semua token telah diterbitkan ke pasar, sementara market cap token *nub* juga senilai \$20.5 juta karena semua token sudah beredar. Volume perdagangan mencapai \$16.6 juta dalam 24 jam terakhir, mencerminkan tingginya aktivitas di pasar, dengan 19,345 transaksi yang terdiri dari 10,315 pembelian dan 9,030 penjualan. Perubahan harga yang signifikan, seperti kenaikan 59.82% dalam 24 jam terakhir, menunjukkan potensi keuntungan besar tetapi juga mengindikasikan volatilitas tinggi yang menjadi ciri khas Memecoin.

Indikator seperti likuiditas yang tinggi, volume perdagangan yang stabil, dan proyek yang memiliki *roadmap* jelas adalah tanda bahwa aset tersebut memiliki potensi lebih kredibel. Namun, Memecoin tetap menjadi aset berisiko tinggi karena sering menjadi target manipulasi harga, memiliki volatilitas ekstrem, dan kadang-kadang likuiditas rendah yang membuat transaksi sulit dilakukan. Dengan alat seperti Dexscreener, data pasar dapat dianalisis secara mendalam untuk membuat keputusan yang lebih terinformasi. *Platform* ini juga mempermudah akses langsung ke pasar desentralisasi seperti Raydium, sehingga memberikan pengguna peluang untuk memanfaatkan pergerakan pasar dengan lebih efisien, terutama di pasar Memecoin yang cenderung volatilitasnya tinggi.

Langkah verifikasi token menjadi bagian penting sebelum melakukan transaksi di pasar desentralisasi. Alat analisis *blockchain* seperti Solscan untuk Solana dapat digunakan dalam memeriksa token yang akan dibeli. Proses verifikasi ini mencakup pengecekan jumlah pemegang token, volume transaksi, total pasokan token, serta pola aktivitas jaringan *blockchain* Solana. Memasukkan alamat kontrak token dari Dexscreener ke Solscan memungkinkan pengguna mendapatkan detail penting yang membantu dalam mengevaluasi risiko. Proses ini memberikan perlindungan terhadap

kemungkinan kerugian akibat token dengan likuiditas rendah atau manipulasi harga, sekaligus mendukung pengambilan keputusan investasi yang lebih aman dan terarah. Berikut adalah contoh verifikasi nub yang memiliki alamat token, yaitu `GtDZKAqvMZMnti46ZewMiXCa4oXF4bZxwQPoKzXPFxZn` di *Platform Solscan*.

The screenshot shows the Solscan interface for the token nubcat (nub). The market overview includes:

- Price: \$0.02069
- Market Cap: \$20,690,878.46
- Current Supply: 999,966,579.13
- Holders: 24,584
- Social Channels: nubcat.xyz

The profile summary shows:

- Token name: nubcat (nub)
- Decimals: 9
- Authority: FSZHEz...FcyQRU
- Creator: FSZHEz...FcyQRU
- Token Extensions: FALSE

The transactions table shows the following data:

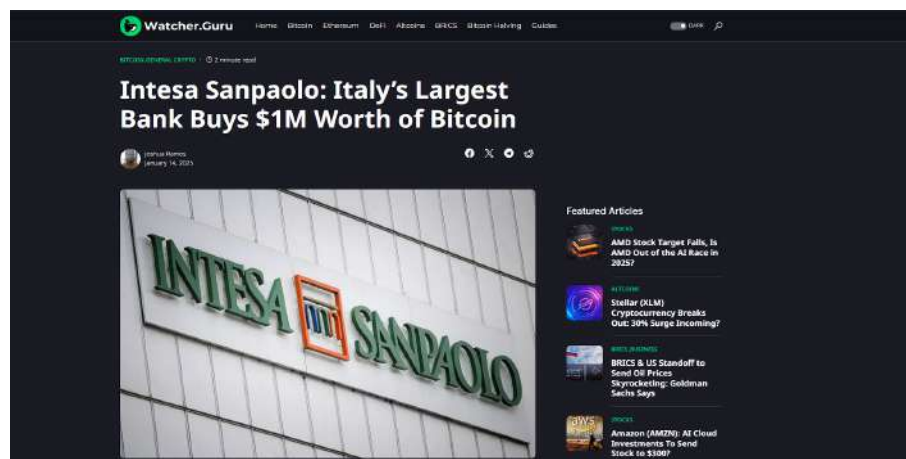
Signature	Time	Action	From	To	Amount	Token	Value
2vakzAdtk3F2LnFgB...	3 mins ago	TRANSFER	2VdatLvPZzp...5jbC1KC671	Orca (SOL:nub) Market	63.691816083	nub	\$1.3178
2vakzAdtk3F2LnFgB...	3 mins ago	TRANSFER	Raydium Authority V4	2VdatLvPZzp...5jbC1KC671	63.691816083	nub	\$1.3178

Gambar 4.6. Token nub pada Solscan.

Gambar 4.6 menunjukkan hasil pengecekan token nubcat (disingkat nub) di platform Solscan, yang menyediakan informasi detail mengenai token tersebut pada jaringan Solana. Harga token saat ini tercatat sebesar \$0.02069, dengan kapitalisasi pasar (Market Cap) mencapai \$20,690,878.46, yang menandakan ukuran pasar token ini dalam ekosistem. Token ini memiliki total pasokan (*Current Supply*) sebesar 999,966,579.13 token, yang berarti hampir semua token yang direncanakan sudah beredar. Jumlah pemegang (*Holders*) sebanyak 24,584 alamat wallet menunjukkan adanya komunitas yang cukup aktif di sekitar token ini. Solscan juga menyediakan informasi tentang sumber daya eksternal terkait token, seperti saluran sosial resmi (nubcat.xyz), untuk membantu pengguna dalam melakukan verifikasi lebih lanjut. Pada bagian bawah, terdapat riwayat transfer yang menunjukkan transaksi terbaru untuk token nub, seperti transfer antara dompet dan pasar terdesentralisasi seperti

Orca dan Raydium. Setiap transaksi memiliki detail seperti jumlah token yang ditransfer, waktu transaksi, dan nilai transaksi dalam USD. Misalnya, transaksi terakhir menunjukkan transfer sebesar 63.69 nub, dengan nilai sekitar \$1.3178.

Pentingnya data dari Solscan adalah memberikan transparansi penuh kepada pengguna mengenai aktivitas token, termasuk riwayat transaksi, jumlah pemegang, dan distribusi token. Berdasarkan data ini, token nub memiliki likuiditas dan aktivitas yang memadai, namun tetap perlu pertimbangan karena risiko yang tinggi pada Memecoin. Verifikasi melalui alat seperti Solscan sangat penting sebelum melakukan transaksi di DEX untuk memastikan keamanan dan keabsahan token. Alat untuk tiap Memecoin dari Altcoin berbeda, seperti Ethereum yang memiliki alat bernama Etherscan, maka untuk Memecoin dari Ethereum dapat dicek melalui Etherscan. Selanjutnya adalah contoh berita tentang *cryptocurrency* khususnya Bitcoin yang diakses melalui <https://wacher.guru/news/>.



Gambar 4.7. Pembelian \$1M Dollar BTC oleh Bank Italia.

Berita pada Gambar 4.7 diambil pada tanggal 14 Januari 2025, yang menampilkan keputusan Intesa Sanpaolo, bank terbesar di Italia, untuk membeli Bitcoin senilai \$1 juta, menyoroti perubahan signifikan dalam adopsi aset digital oleh institusi keuangan tradisional. Keputusan ini dianggap sebagai langkah strategis yang

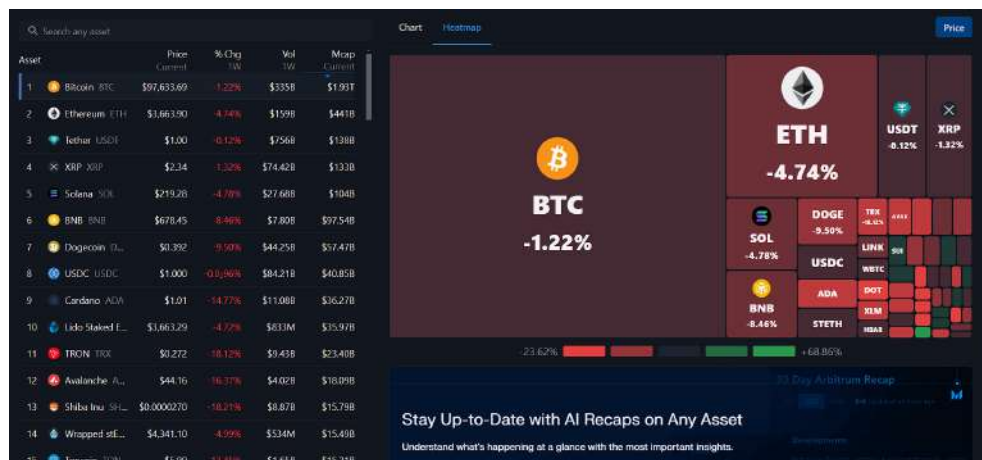
mencerminkan meningkatnya kepercayaan terhadap mata uang kripto di sektor perbankan. Meski nilai investasi tersebut relatif kecil dibandingkan dengan aset bank secara keseluruhan, hal ini dapat menjadi langkah awal dalam memperluas integrasi Bitcoin dalam ekosistem keuangan yang lebih luas. Efek dari berita ini turut memengaruhi sentimen pasar secara global, di mana para investor melihatnya sebagai sinyal positif bagi volatilitas Bitcoin. Langkah ini sejalan dengan tren pertumbuhan infrastruktur pendukung *cryptocurrency*, seperti peningkatan jumlah ATM Bitcoin secara global, yang mencerminkan adopsi yang semakin luas di berbagai sektor keuangan, berita dapat dilihat pada gambar berikut.



Gambar 4.8. Berita Pertumbuhan Bitcoin ATM.

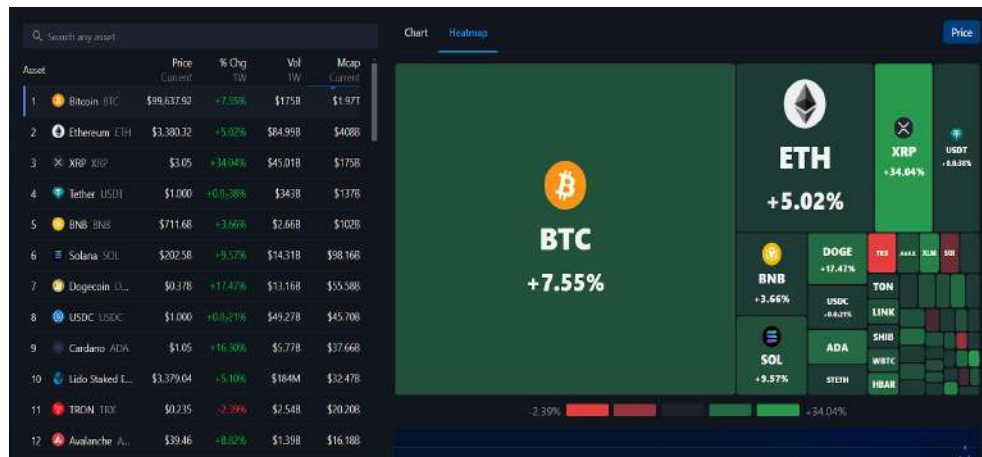
Berita pada Gambar 4.8 menunjukkan bahwa jumlah ATM Bitcoin di seluruh dunia meningkat sebesar 6% sepanjang tahun 2024, mencapai total lebih dari 37.500 mesin yang tersebar di 70 negara. Amerika Serikat memimpin dengan menguasai 81% pangsa pasar global, memiliki lebih dari 31.500 ATM pada awal tahun 2025. Pertumbuhan ini mencerminkan adopsi *cryptocurrency* yang semakin meluas, meskipun tantangan regulasi dan infrastruktur masih menjadi hambatan di beberapa wilayah, terutama di Asia dan Afrika. Regulasi yang ketat, seperti yang diterapkan oleh Financial Crimes Enforcement Network (FinCEN) di AS dan

Financial Conduct Authority (FCA) di Inggris, menuntut operator ATM Bitcoin untuk mematuhi aturan Anti-Pencucian Uang (AML) dan Know Your Customer (KYC). Meskipun demikian, peningkatan jumlah ATM Bitcoin menunjukkan minat yang terus berkembang terhadap aset digital ini di kalangan masyarakat global dan mengubah tren dari semula semua koin minus pada gambar berikut.



Gambar 4.9. Heatmap Pasar Cryptocurrency sebelum Berita.

Gambar 4.9 menunjukkan *heatmap* yang merefleksikan kondisi pasar *cryptocurrency* sebelum munculnya berita positif pada Gambar 4.7 dan 4.8. Dalam *heatmap* tersebut, mayoritas Altcoin mengalami penurunan signifikan, seperti Ethereum (-4.74%), Solana (-4.78%), Dogecoin (-9.50%), dan Tron (-18.12%). Bitcoin, meskipun hanya mengalami penurunan kecil sebesar -1.22%, tetap gagal mempertahankan momentum positif di pasar. Warna merah yang mendominasi *heatmap* ini mencerminkan dampak sentimen negatif dan ketidakpastian yang melanda pasar saat itu. Kondisi ini menunjukkan tren bearish yang cukup kuat, yang kemudian berubah menjadi tren bullish setelah munculnya berita-berita positif pada Gambar 4.7 dan 4.8, sebagaimana dapat dilihat dalam Gambar 4.10.



Gambar 4.10. Heatmap Pasar Cryptocurrency setelah Berita.

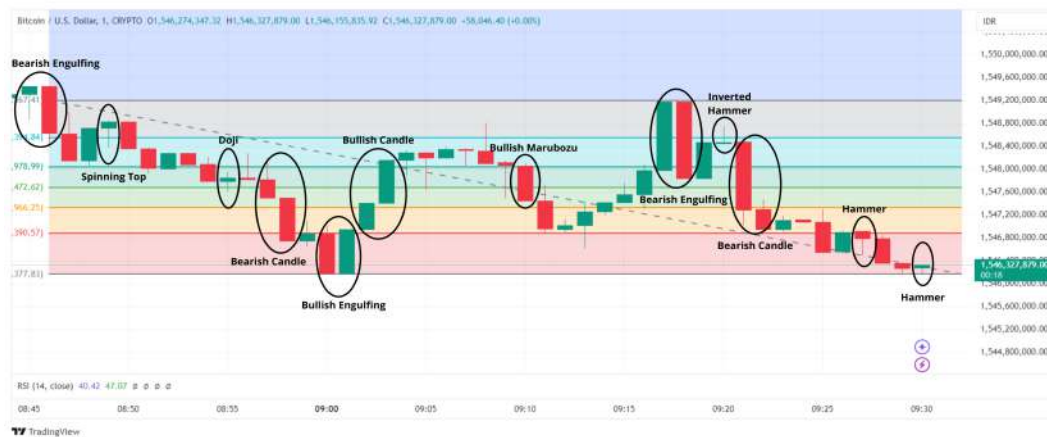
Gambar 4.10 menunjukkan pergeseran tren dari *bearish* menjadi *bullish* yang signifikan, terutama setelah berita positif seperti keputusan Intesa Sanpaolo membeli Bitcoin senilai \$1 juta dan peningkatan jumlah ATM Bitcoin di seluruh dunia. Sebelumnya, pada Gambar 4.9, Ethereum mengalami penurunan sebesar -4.74%, namun kini telah rebound menjadi +5.02%. Solana yang sebelumnya turun -4.78% kini mencatat kenaikan +9.57%, sementara Dogecoin yang sebelumnya merosot -9.50% kini meningkat +17.47%. Bahkan Tron, yang mencatat penurunan tajam -18.12% sebelumnya, menunjukkan tanda-tanda pemulihan meskipun masih berada dalam zona merah. Bitcoin, yang sebelumnya turun -1.22%, kini mencatat kenaikan signifikan sebesar +7.55%, menunjukkan pemulihan kuat di pasar. Perubahan ini mencerminkan bagaimana sentimen positif dapat dengan cepat membalikkan momentum pasar cryptocurrency dan memulihkan kepercayaan pasar.

4.2 Analisis Technical

Analisis *technical* dalam *cryptocurrency* memanfaatkan data pasar, harga aktual atau terkini, volume penawaran, dan permintaan untuk memprediksi pergerakan harga ke depannya. Analisis ini menggunakan indikator yang dapat diketahui melalui pencerminan harga, jadi lebih fokus untuk mengidentifikasi pola dan tren yang dapat

memberikan gambaran apa yang akan terjadi pada pasar. Indikator *technical* yang digunakan berupa pola *Candlestick*, *Support-Resistance Line*, *Moving Average*, dan *Relative Strength Index*. Berbagai indikator tadi dapat digunakan untuk identifikasi titik beli dan jual pada volatilitas *cryptocurrency* di pasar.

Elemen fundamental dari analisis *technical* dalam *cryptocurrency* adalah penggunaan pola *candlestick* untuk merepresentasikan pergerakan harga setiap waktu. Pada satu *candlestick* menunjukkan informasi terkait harga pembukaan, harga penutupan, harga tertinggi, dan harga terendah pada *cryptocurrency* dalam *time frame* yang spesifik, misal dalam menit, jam, hari, atau lebih lama. Selanjutnya, dilakukan analisis pada *candlestick* untuk menentukan kondisi *bullish* dan *bearish* di pasar.



Gambar 4.11. Analisis Pola *Candlestick*.

Gambar 4.11 menunjukkan volatilitas harga Bitcoin pada tanggal 3 Januari 2025 dalam jangka waktu tiap 5 menit dengan pola *candlestick* tiap 1 menit yang mencerminkan aktivitas antara jual dan beli. Pola Bearish Engulfing (08:45) menjadi indikasi awal tekanan jual yang kuat, yang memulai tren turun di pasar. Pola ini diikuti oleh Spinning Top (08:46) dan Doji (08:48), yang menunjukkan kebimbangan pasar ketika pembeli dan penjual saling mencari keseimbangan. Tren turun ini semakin kuat dengan munculnya Bearish Candle (08:49), tetapi momentum pasar mulai

berbalik arah dengan hadirnya pola Bullish Engulfing (08:50), menandakan dominasi pembelian yang mulai meningkat.

Momentum *bullish* terus berlanjut dengan Bullish Candle (08:52) dan pola Bullish Marubozu (09:05), yang mencerminkan tekanan beli yang dominan tanpa adanya perlawanan berarti dari penjual. Setelah mencapai titik *resistance*, tekanan jual meningkat dengan munculnya pola Bearish Engulfing (09:15), yang diikuti oleh Inverted Hammer (09:20), memberikan sinyal potensi pembalikan *bullish*. Tren turun yang terjadi kemudian dikonfirmasi oleh Bearish Candle (09:25), tetapi grafik diakhiri dengan pola Hammer (09:30), yang menjadi sinyal potensi pembalikan *bullish* setelah tren turun yang signifikan. Grafik ini menunjukkan volatilitas yang mencerminkan perubahan dominasi beli dan jual. Pola seperti Bullish Engulfing, Bearish Engulfing, dan Hammer menjadi sinyal penting untuk pembalikan tren, sementara pola seperti Spinning Top dan Doji menunjukkan fase keseimbangan. Selanjutnya mengaplikasikan *support line* pada *candlestick*, dapat dilihat pada gambar di bawah dengan *support line* merupakan garis yang terletak pada 2 *candlestick* sejajar yang memiliki harga terendah dan *resistance line* merupakan garis yang lurus dengan 2 *candlestick* sejajar yang memiliki harga tertinggi.



Gambar 4.12. Analisis Pola *Candlestick* Jual-Beli.

Gambar 4.12 menunjukkan bahwa *support line* merupakan alat fundamental pada analisis *technical* dan membantu dalam penentuan waktu potensial untuk masuk ke dalam pasar dan melakukan kegiatan beli berdasarkan tren *bullish*. Area *support line* menunjukkan titik di mana harga sudah berhenti turun dan bergerak ke harga tinggi. Terlihat beberapa pola candle yang menggambarkan perubahan arah tren harga di pasar. Pola *bearish reversal* yang muncul menunjukkan pembalikan tren dari naik ke turun, memberikan sinyal untuk melakukan aksi jual karena harga diperkirakan akan bergerak turun. Sebaliknya, pola *bullish reversal* menandakan pembalikan tren dari turun ke naik, yang mengindikasikan peluang untuk membeli, karena harga diperkirakan akan meningkat. Selain itu, pola *mat hold* menunjukkan bahwa tren yang sedang berlangsung, baik naik maupun turun, memiliki kekuatan yang cukup untuk berlanjut, sehingga memberikan sinyal untuk mempertahankan posisi. Analisis *candlestick* juga dapat dilakukan menggunakan metode *Fibonacci Retracement*, yaitu alat analisis *technical* yang digunakan untuk mengidentifikasi potensi level *support* dan *resistance* berdasarkan rasio Fibonacci, seperti gambar di bawah.



Gambar 4.13. Analisis Candlestick dengan FR.

Gambar 4.13 menunjukkan penggunaan *Fibonacci Retracement* untuk memprediksi pergerakan harga di pasar. Garis Fibonacci ditarik dari titik harga

terendah (1.1549) ke harga tertinggi (1.1747) untuk menentukan titik kunci, seperti 0.236 (1.1595), 0.382 (1.1624), 0.5 (1.1648), 0.618 (1.1671), dan 0.786 (1.1710). Saat ini, harga berada di sekitar level 0.382 (1.1624), yang dapat menjadi acuan apakah harga akan naik atau turun. Jika harga memantul naik dari level ini, ada peluang harga akan mencapai level *resistance* berikutnya, seperti 0.5 atau 0.618. Namun, jika harga menembus ke bawah level ini, maka bisa diprediksi harga akan turun menuju level *support* di 0.236 atau lebih rendah. Penggunaan level Fibonacci ini membantu mempermudah prediksi pergerakan harga berdasarkan pola harga sebelumnya. Platform seperti TradingView dapat digunakan untuk memvisualisasikan dominasi Bitcoin (BTC Dominance) di pasar sebagai alat untuk melihat berapa persen dominasi pada pasar *cryptocurrency* yang dapat dilihat pada *chart* di bawah.



Gambar 4.14. Dominasi Bitcoin pada Pasar *Cryptocurrency*

Gambar 4.14 menunjukkan pergerakan dominasi Bitcoin (BTC Dominance) di pasar *cryptocurrency* setelah berita terkait investasi Bitcoin oleh Intesa Sanpaolo dan peningkatan infrastruktur ATM Bitcoin. Grafik ini menggambarkan fluktuasi dominasi Bitcoin yang berada pada kisaran 57.75%, mencerminkan penurunan kecil dibandingkan nilai sebelumnya. Penurunan ini dapat diartikan sebagai pergeseran sementara minat pasar menuju Altcoin, meskipun Bitcoin tetap mendominasi sebagai

aset utama dalam pasar cryptocurrency. Indikator Relative Strength Index (RSI) yang berada pada level 39.54 menunjukkan bahwa dominasi Bitcoin berada di zona netral, yang mencerminkan bahwa belum ada tekanan beli atau jual yang signifikan pada saat itu. Hal ini menunjukkan dampak dari berita positif yang memperkuat posisi Bitcoin, meskipun pasar secara keseluruhan masih menunjukkan volatilitas yang tinggi. Dominasi koin lain seperti Ethereum, Solana, dan Altcoin lainnya dapat dicek pada TradingView dengan menambahkan kata "Dominance" setelah nama Altcoin, misalnya Ethereum.D untuk melihat dominasi Ethereum di pasar *cryptocurrency*.

Analisis *candlestick* dipertkuat dengan perhitungan *Moving Average*, selanjutnya akan dilakukan proses perhitungan *Moving Average* yang mencakup SMA dan EMA. Dataset yang akan digunakan adalah dataset Solana dengan interval data dari 1 Januari hingga 1 Desember 2024. Dalam perhitungan *moving average*, pertama akan mencari nilai dari *Simpler Moving Average* (SMA) dari dataset ini berdasarkan periode waktu yang dipilih. Sebagai contoh mengambil periode 20 hari untuk mengamati tren jangka pendek dan menengah, selanjutnya dengan membuat persamaan 4.1

$$SMA = \frac{\sum_{i=1}^n \text{Harga Penutupan}_i}{n} \quad (4.1)$$

dengan n = periode yang digunakan. Akan dihitung SMA untuk dataset Solana pada interval 1-20 Januari 2024 yang ada pada tabel 4.1, sehingga diperoleh

$$SMA = \frac{1958.02}{20} = 97.90$$

Tabel 4.1. Contoh Dataset Harga Cryptocurrency Harian

Tanggal	Harga Penutupan (<i>Close</i>)
1 Januari	109,51
2 Januari	106,61
3 Januari	98,59
4 Januari	105,08
5 Januari	99,98
6 Januari	93,86
7 Januari	89,28
8 Januari	97,79
9 Januari	99,41
10 Januari	102,03
11 Januari	99,91
12 Januari	91,72
13 Januari	95,73
14 Januari	94,13
15 Januari	94,49
16 Januari	97,63
17 Januari	102,06
18 Januari	94,25
19 Januari	93,39
20 Januari	92,57

Nilai SMA yang sebelumnya telah dikalkulasi akan menjadi nilai *Exponential Moving Average* (EMA) awal. Setelah mendapatkan nilai awal, maka dapat dilakukan perhitungan EMA ke depannya pada dataset ini dengan menggunakan Persamaan 4.2

$$EMA_t = (\text{Harga Penutupan}_t - EMA_{t-1}) \times \text{Multiplier} + EMA_{t-1} \quad (4.2)$$

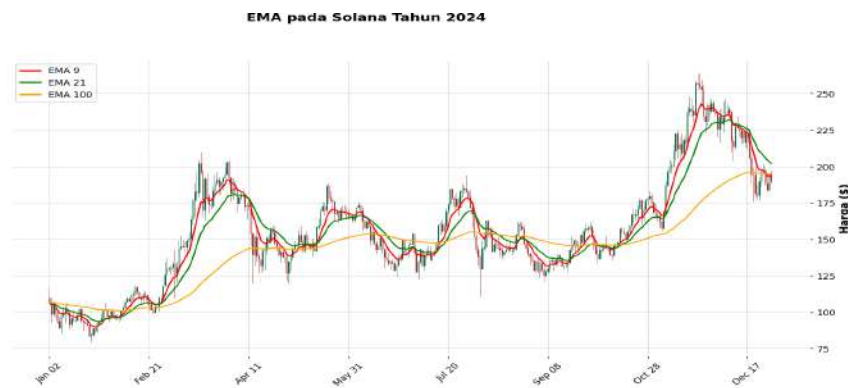
dengan $\text{Multiplier} = \frac{2}{n+1}$. Pada kasus ini, periode yang digunakan adalah 20, maka didapatkan nilai $\text{Multiplier} = \frac{2}{20+1} = 0.0952$. Selanjutnya akan mencari EMA untuk 3 hari ke depan, yaitu tanggal 21, 22, dan 23 Januari, perhitungan sebagai berikut. Pada perhitungan pertama, menggunakan nilai EMA awal yaitu 97.90 (SMA):

$$EMA_{21, Januari} = (90.85 - 97.90) \times 0.0952 + 97.90 = 97.23$$

$$EMA_{22, Januari} = (83.62 - 97.23) \times 0.0952 + 97.23 = 95.94$$

$$EMA_{23, Januari} = (84.27 - 95.94) \times 0.0952 + 95.94 = 94.83$$

Umumnya *market cryptocurrency* memiliki fitur untuk mengatur penggunaan periode EMA, yang sering digunakan adalah periode 9 (jangka pendek), 21 (jangka menengah), dan 100 (jangka panjang). Selanjutnya, untuk mendapatkan nilai EMA periode 9, 21, dan 100 dapat dilakukan dengan cara yang sama seperti perhitungan di atas, namun pada masing-masing periode akan menggunakan nilai $Multiplier = \frac{2}{9+1} = 0.2000$, $Multiplier = \frac{2}{21+1} = 0.0952$, $Multiplier = \frac{2}{100+1} = 0.0198$, sehingga saat periode 9 menggunakan nilai *Multiplier* sebesar 0.2, periode 21 menggunakan nilai *Multiplier* sebesar 0.0952, dan periode 100 menggunakan nilai *Multiplier* sebesar 0.0198. Kemudian untuk nilai EMA sepanjang interval dataset selanjutnya akan disajikan pada Gambar berikut.



Gambar 4.15. EMA Solana tahun 2024.

Gambar 4.15 menyajikan grafik EMA periode 7, 21, dan 100 pada dataset Solana. Prediksi *cryptocurrency* dapat dilakukan menggunakan indikator EMA 7, 21, dan 100. Penentuan tren volatilitas *cryptocurrency* harus diketahui terlebih dahulu

sebelum melakukan prediksi. Selanjutnya dicoba pada contoh interval Solana 4 November hingga 4 Desember seperti pada Gambar 4.4.



Gambar 4.16. EMA Solana November-Desember 2024.

Berdasarkan Gambar 4.16 didapatkan tren dari perubahan volatilitas *cryptocurrency* dan ketiga indikator EMA memiliki arah yang sama serta tidak ada indikator EMA yang berlawanan arah. Setelah mengetahui tren naik, selanjutnya perlu memastikan dinamika perubahan *candlestick* dari Solana. Dapat dilihat bahwa perubahan *candlestick* dari 4 November hingga 4 Desember berada di luar indikator EMA. Selanjutnya untuk memprediksi kapan melakukan transaksi pembelian, maka perlu melihat *candlestick* memasuki fase *pullback* menuju EMA 7 atau 21 yang kemudian kembali lagi harga menuju EMA 7 atau 21. Hal ini dapat dilihat dari dinamika *candlestick* pada interval 28 November-3 Desember. Dari dinamika ini, dapat masuk untuk melakukan pembelian pada tanggal 3 Desember dan melepasnya hingga memenuhi target untung. Setelah menghitung dari *Moving Average*, untuk lebih meyakinkan titik beli dan jual akan digunakan indikator *Relative Strength Index* (RSI).

Perhitungan *Relative Strength Index* (RSI) digunakan untuk mengukur kekuatan tren yang terjadi dan mengidentifikasi apakah harga Solana dalam kondisi *overbought* atau *oversold*. RSI adalah indikator momentum yang menunjukkan kecepatan dan perubahan pergerakan harga suatu aset. Indikator ini dapat membantu dalam

menentukan apakah suatu aset mengalami tekanan beli atau jual yang berlebihan.

Overbought terjadi ketika harga suatu aset sudah terlalu tinggi akibat tekanan beli yang berlebihan, yang menyebabkan harga bergerak jauh di atas nilai wajarnya. Kondisi ini sering kali menandakan bahwa pasar telah membeli secara berlebihan dan harga mungkin akan turun atau mengalami koreksi. Jika nilai RSI lebih dari 70, maka aset dianggap *overbought*. Sebaliknya, *Oversold* terjadi ketika harga suatu aset terlalu rendah akibat tekanan jual yang berlebihan, yang menyebabkan harga bergerak jauh di bawah nilai wajarnya. Kondisi ini sering kali menandakan bahwa pasar telah menjual secara berlebihan dan harga mungkin akan naik kembali atau mengalami pembalikan arah. Jika nilai RSI di bawah 30, maka aset dianggap *oversold*. RSI dihitung dengan rumus

$$RSI = 100 - \left(\frac{100}{1 + RS} \right)$$

dengan RS adalah rasio antara rata-rata kenaikan harga dengan rata-rata penurunan harga selama periode tertentu, biasanya 14 hari. Nilai RSI berkisar antara 0 hingga 100. Dengan demikian, RSI tidak hanya memberi gambaran tentang kekuatan tren, tetapi juga mengindikasikan potensi pembalikan arah pasar berdasarkan kondisi *overbought* atau *oversold*. Selanjutnya akan dilakukan perhitungan *Moving Average* dengan dataset harga *cryptocurrency*. Langkah pertama membuat tabel yang berisikan harga penutupan dan perubahan harga dari periode sebelumnya, di sini digunakan interval sepanjang 1 hari, dapat dilihat pada tabel di bawah.

Tabel 4.2. Contoh Dataset Harga Cryptocurrency Harian dengan Perubahan Harga

Tanggal	Harga Penutupan (<i>Close</i>)	Perubahan Harga (ΔP)
25 November	234,45	-
26 November	230,98	-3,47
27 November	242,20	11,22
28 November	237,76	-4,44
29 November	243,55	5,79
30 November	237,74	-5,81
1 Desember	237,07	-0,67
2 Desember	225,76	-11,31
3 Desember	234,20	8,44
4 Desember	229,12	-5,08
5 Desember	234,00	4,88
6 Desember	237,05	3,05
7 Desember	238,55	1,50

Perubahan harga harian (ΔP) dihitung menggunakan rumus $\Delta P = P_2 - P_1$, di mana P_2 adalah harga penutupan hari ini (*close*) dan P_1 adalah harga penutupan hari sebelumnya (*close*). Selanjutnya, nilai perubahan (ΔP) dipisahkan menjadi dua kategori, yaitu perubahan positif dan perubahan negatif. Jika $\Delta P > 0$, maka nilainya dimasukkan ke kolom "Perubahan Positif". Jika $\Delta P < 0$, maka nilai $|\Delta P|$ dimasukkan ke kolom "Perubahan Negatif". Jika $\Delta P = 0$, maka kedua kolom diisi dengan nilai 0. Berdasarkan aturan tersebut, tabel berikut menunjukkan pemisahan perubahan positif dan negatif.

Tabel 4.3. Tabel Perubahan Harga Positif dan Negatif Cryptocurrency Harian

Tanggal	Perubahan Positif	Perubahan Negatif
25 November	0	0
26 November	0	3,47
27 November	11,22	0
28 November	0	4,44
29 November	5,79	0
30 November	0	5,81
1 Desember	0	0,67
2 Desember	0	11,31
3 Desember	8,44	0
4 Desember	0	5,08
5 Desember	4,88	0
6 Desember	3,05	0
7 Desember	1,50	0

Total perubahan harga positif (kenaikan harga) dihitung dengan menjumlahkan semua nilai perubahan harga yang positif selama periode tersebut:

$$11,22 + 5,79 + 8,44 + 4,88 + 3,05 + 1,50 = 34,88$$

Sementara itu, total perubahan harga negatif (penurunan harga) dihitung dengan menjumlahkan semua nilai perubahan harga yang negatif:

$$3,47 + 4,44 + 5,81 + 0,67 + 11,31 + 5,08 = 30,78$$

Selanjutnya, menghitung rata-rata kenaikan (*Average Gain*) dan rata-rata penurunan (*Average Loss*). Rata-rata kenaikan dihitung dengan membagi total perubahan harga positif dengan jumlah periode yang ada, yaitu 13 hari:

$$\text{Average Gain} = \frac{34,88}{13} = 2,68$$

Rata-rata penurunan dihitung dengan cara yang sama, yaitu membagi total perubahan harga negatif dengan jumlah periode yang ada:

$$\text{Average Loss} = \frac{30,78}{13} = 2,37$$

Setelah memperoleh *Average Gain* dan *Average Loss*, selanjutnya dapat menghitung *Relative Strength* (RS), yang merupakan perbandingan antara rata-rata kenaikan dan rata-rata penurunan harga:

$$RS = \frac{\text{Average Gain}}{\text{Average Loss}} = \frac{2,68}{2,37} = 1,13$$

Selanjutnya, perhitungan *Relative Strength Index* (RSI) dengan rumus berikut:

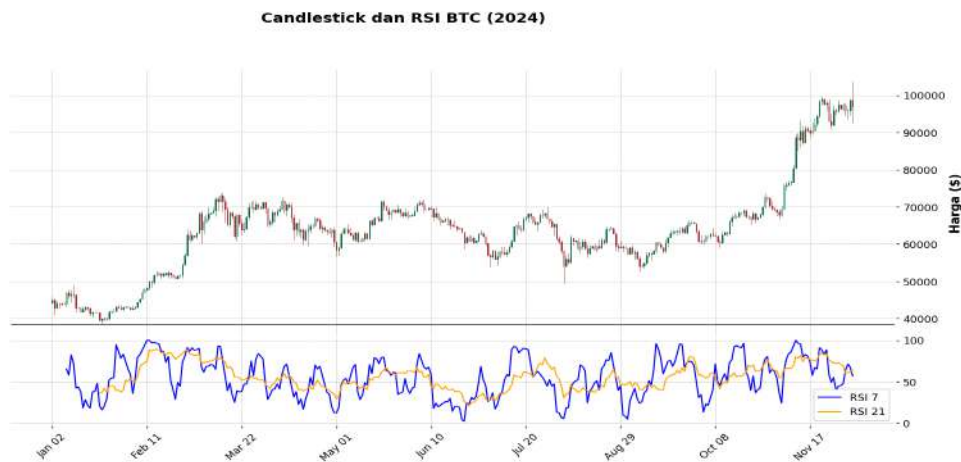
$$RSI = 100 - \frac{100}{1 + RS}$$

Substitusi nilai RS yang telah dihitung:

$$RSI = 100 - \frac{100}{1 + 1,13} = 100 - \frac{100}{2,13} = 100 - 46,95 = 53,05$$

Hasil perhitungan RSI adalah 53,05, yang menunjukkan bahwa harga Solana saat ini tidak berada dalam kondisi *overbought* (terlalu dibeli) maupun *oversold* (terlalu dijual). Dengan nilai RSI yang berada di kisaran ini, harga Solana berada dalam kondisi netral dan tidak menunjukkan adanya tekanan beli atau jual yang berlebihan. Dalam kondisi seperti ini, trader secara umum dapat mempertimbangkan untuk menunggu konfirmasi tren lebih lanjut sebelum mengambil keputusan. Mereka dapat memantau pergerakan harga dan indikator teknikal lainnya, seperti *support-resistance levels* atau pola *candlestick*, untuk mendapatkan sinyal yang lebih jelas terkait arah pasar berikutnya. Selain itu, strategi lindung nilai (*hedging*) atau pendekatan konservatif, seperti menerapkan stop-loss ketat, dapat membantu mengelola risiko di tengah ketidakpastian.

Sama seperti EMA, pada *market* terdapat fitur untuk mengatur penggunaan periode RSI, yang sering digunakan adalah periode 7 (jangka pendek) dan 21 (jangka panjang). Selanjutnya dilakukan visualisasi grafik dari perhitungan RSI periode 7 dan 21 menggunakan *Python*, dengan dataset Bitcoin. Untuk hasil dapat dilihat pada gambar di bawah.



Gambar 4.17. RSI Bitcoin 2024.

Dari Gambar 4.17, dapat dilihat bahwa grafik *candlestick* BTC menunjukkan tren kenaikan harga yang signifikan pada paruh kedua tahun 2024. Hal ini didukung oleh indikator RSI (*Relative Strength Index*), yang terdiri dari dua periode, yaitu RSI 7 (biru) dan RSI 21 (oranye). Kedua garis RSI ini memberikan wawasan tentang kekuatan tren dan kemungkinan *overbought* atau *oversold*.

Pada periode awal, nilai RSI 7 sering bergerak dengan fluktuasi yang lebih tinggi dibandingkan RSI 21, mencerminkan sensitivitasnya terhadap perubahan harga jangka pendek. Nilai RSI 7 beberapa kali melewati ambang batas 70, yang menunjukkan kondisi *overbought*, di mana harga berpotensi mengalami koreksi. Sebaliknya, pada saat nilai RSI turun di bawah 30, terdapat indikasi kondisi *oversold*, yang memberikan peluang untuk pembalikan tren ke arah atas.

Sementara itu, RSI 21 yang lebih halus menunjukkan tren jangka menengah

yang lebih stabil. Ketika RSI 21 tetap berada di atas garis tengah (50) selama periode yang cukup panjang, hal ini mengindikasikan kekuatan tren *bullish* yang konsisten. Namun, pergerakan RSI 21 yang mendekati garis tengah juga menjadi sinyal perlambatan momentum, seperti yang terlihat pada periode konsolidasi di pertengahan tahun. Kombinasi kedua indikator RSI ini memberikan konfirmasi tren harga. Misalnya, pada akhir tahun, ketika harga BTC mencapai puncaknya, kedua RSI menunjukkan nilai mendekati *overbought*, yang menandakan potensi risiko koreksi dalam waktu dekat.

Setelah membahas teori dasar mengenai analisis *technical* dalam pasar cryptocurrency, seperti pola *candlestick*, konsep *support* dan *resistance*, serta indikator-indikator seperti *Simple Moving Average* (SMA), *Exponential Moving Average* (EMA), dan *Relative Strength Index* (RSI), sekarang saatnya untuk menerapkan konsep-konsep tersebut dalam sebuah contoh kasus yang lebih praktis. Dalam contoh ini, akan dilakukan integrasi semua analisis tersebut untuk menganalisis pergerakan harga cryptocurrency. Dengan memanfaatkan grafik *candlestick* untuk mengidentifikasi pola pasar, garis *support* dan *resistance* untuk menandai area kunci, serta menggunakan indikator SMA, EMA, dan RSI untuk memberikan sinyal potensial untuk membeli atau menjual dengan gambaran yang lebih lengkap mengenai dinamika pasar. Koin yang akan digunakan untuk uji adalah XRP-USD, berikut adalah diagram uji XRP tanggal 7-9 Desember 2024.



Gambar 4.18. Diagram Uji XRP 9-12 Desember 2024.

Dari Gambar 4.18, yang menunjukkan pergerakan harga XRP/US Dollar menggunakan grafik candlestick 1 jam menunjukkan beberapa pola yang memberikan gambaran tentang perubahan tren. Pada awal grafik, terjadi pergerakan bullish yang cukup kuat, ditandai dengan pola candlestick Marubozu. Pola ini menunjukkan bahwa para pembeli sangat dominan, dan harga terus naik dengan kuat. Indikator EMA juga berada di bawah candlestick, yang mengonfirmasi bahwa tren tersebut adalah tren naik. Selain itu, indikator RSI menunjukkan angka yang semakin mendekati 70, yang biasanya menandakan pasar sedang berada dalam kondisi overbought atau jenuh beli, sehingga menunjukkan bahwa momentum naik masih cukup kuat.

Namun, setelah harga mendekati garis resistance, muncul pola Bearish Candlestick Doji. Pola ini menunjukkan adanya keraguan di pasar, di mana tekanan jual mulai muncul dan menahan kenaikan harga. Tak lama setelah itu, candlestick bearish yang lebih besar muncul, yang menandakan pembalikan arah dari tren naik menjadi tren turun. Saat itu, RSI mulai menurun dari level 70, menandakan bahwa pasar sedang memasuki kondisi overbought dan tekanan jual semakin kuat. Pada area support, pola Bullish Harami terbentuk, yang memberi sinyal bahwa ada potensi

pembalikan arah ke atas. Ditambah lagi, RSI yang mulai naik dari level 30 (oversold) mengindikasikan bahwa pembeli mulai kembali mendominasi. Namun, menjelang akhir grafik, muncul candlestick bearish besar, yang menunjukkan bahwa tren naik sebelumnya mulai kehilangan momentum. Indikator RSI juga turun tajam, menandakan bahwa tekanan jual kembali mendominasi pasar. Pola candlestick yang terbentuk, bersama dengan sinyal dari RSI dan EMA, memberikan gambaran jelas tentang perubahan kekuatan antara pembeli dan penjual di pasar.

4.3 Analisis On-Chain

Setelah menganalisis beberapa koin menggunakan analisis fundamental dan *technical*, selanjutnya akan dilakukan analisis *on-chain*. Analisis *on-chain* dalam prediksi volatilitas berguna untuk menganalisis sinyal dan perubahan tren pada pasar. *On-chain* menunjukkan pergerakan tiap waktu dari aktivitas pada *blockchain*, seperti volume transaksi, banyaknya transaksi, *hash rate*, dan lainnya. Dengan analisis dari data tersebut, dapat mengetahui permintaan secara dinamis, kesibukan jaringan, dan potensi terjadinya fluktuasi harga pada *cryptocurrency*.

Pentingnya pemantauan volume transaksi ini dapat dilihat dalam konteks analisis pergerakan harga yang sering kali bergantung pada intensitas aktivitas pasar. Dengan memantau fluktuasi harga dan volume transaksi, dapat memperoleh gambaran yang lebih jelas tentang apakah tren pasar tersebut akan berlanjut atau mengalami pembalikan. Indikator ini juga dapat memberikan insight tambahan untuk mengidentifikasi titik jenuh pasar dan potensi terjadinya koreksi harga.

Untuk mengilustrasikan dinamika ini, dapat dilakukan visualisasi hubungan antara harga dan volume transaksi dalam bentuk grafik yang menggambarkan normalisasi harga Bitcoin bersama dengan total jumlah transaksi yang dinormalisasi. Berikut adalah visualisasi dari normalisasi data, serta menunjukkan pergerakan harga dan total transaksi Bitcoin.



Gambar 4.19. Normalisasi Harga dan Total Transaksi Bitcoin 2024.

Gambar 4.19 menunjukkan bahwa harga Bitcoin yang dinormalisasi (garis merah) mengalami fluktuasi yang signifikan sepanjang periode pengamatan, sementara total jumlah transaksi yang dinormalisasi (garis hijau) menunjukkan tren kenaikan yang stabil. Hal ini menunjukkan bahwa meskipun aktivitas transaksi Bitcoin cenderung meningkat secara konsisten, volatilitas harga Bitcoin tetap tinggi, mencerminkan sensitivitas pasar terhadap faktor-faktor lain seperti sentimen investor, berita global, atau perubahan regulasi. Selanjutnya, untuk memperdalam analisis, akan dilakukan pengamatan terhadap data mengenai ukuran blok dalam jaringan Bitcoin, yang menggambarkan kapasitas jaringan untuk menangani transaksi. Grafik di bawah ini menunjukkan normalisasi antara harga Bitcoin (garis merah) dan ukuran blok (garis biru) sepanjang waktu. Dengan normalisasi ini, analisis hubungan antara perubahan harga Bitcoin dan kapasitas transaksi yang tercatat dalam ukuran blok menjadi lebih mudah dilakukan. Berikut adalah visualisasi dari data yang dianalisis, yang menunjukkan pergerakan harga dan ukuran blok Bitcoin, dengan kedua variabel tersebut dinormalisasi untuk memudahkan perbandingan.




Gambar 4.20. Normalisasi Harga dan Ukuran Blok Bitcoin 2024.

Gambar 4.20 menunjukkan perbandingan antara harga Bitcoin yang dinormalisasi (garis merah) dan ukuran blok yang dinormalisasi (garis biru) sepanjang periode pengamatan. Grafik ini menunjukkan bahwa harga Bitcoin mengalami fluktuasi yang signifikan, sementara ukuran blok menunjukkan pola yang relatif lebih stabil. Ukuran blok dalam jaringan Bitcoin mencerminkan kapasitas jaringan untuk memproses transaksi. Setiap blok dalam blockchain Bitcoin dapat memuat sejumlah transaksi, dan ukuran blok ini berhubungan langsung dengan volume transaksi yang dapat diproses dalam satu waktu. Secara umum, ukuran blok yang lebih besar dapat mengindikasikan peningkatan kapasitas jaringan, yang memungkinkan lebih banyak transaksi diproses dengan lebih cepat. Namun, meskipun kapasitas jaringan dapat meningkat, ukuran blok Bitcoin biasanya memiliki batasan yang tetap, sehingga faktor-faktor eksternal seperti permintaan transaksi atau perubahan dalam konsensus jaringan dapat memengaruhi fluktuasi ukuran blok.

Meskipun harga Bitcoin sangat volatil, ukuran blok cenderung menunjukkan tren yang lebih stabil. Hal ini menunjukkan bahwa meskipun aktivitas pasar Bitcoin dapat dipengaruhi oleh banyak faktor eksternal (seperti sentimen investor, berita ekonomi, atau perubahan regulasi), kapasitas jaringan untuk menangani transaksi (yang tercermin

dalam ukuran blok) lebih stabil. Ini juga mengindikasikan bahwa kapasitas transaksi jaringan Bitcoin, meskipun bertumbuh, tidak selalu bergerak seiring dengan fluktuasi harga, karena faktor-faktor lain seperti adopsi teknologi dan kebijakan penambangan dapat mempengaruhi pertumbuhan ukuran blok.

Selanjutnya, untuk melengkapi analisis ini, data terkait *hash rate* dalam jaringan Bitcoin akan dianalisis. *Hash rate* menggambarkan tingkat kecepatan perhitungan dalam jaringan Bitcoin, yang diukur dalam jumlah hash yang dihitung per detik. Semakin tinggi *hash rate*, semakin kuat dan aman jaringan Bitcoin, karena lebih banyak penambang yang berpartisipasi dalam proses validasi transaksi dan penciptaan blok baru. Grafik berikut ini akan menunjukkan bagaimana *hash rate* berfluktuasi sepanjang periode yang sama dengan harga Bitcoin dan ukuran blok, serta memberikan wawasan tentang hubungan antara kekuatan komputasi jaringan dan faktor-faktor lain yang mempengaruhi performa jaringan Bitcoin.




Gambar 4.21. Normalisasi Harga dan *Hash Rate* Bitcoin 2024.

Gambar 4.21 menunjukkan perbandingan antara normalisasi *hash rate* jaringan Bitcoin sepanjang waktu. *Hash rate* mengukur kecepatan perhitungan *hash* dalam jaringan Bitcoin, yang dihitung dalam jumlah *hash* yang dapat diproses per detik. Semakin tinggi *hash rate*, semakin besar daya komputasi yang digunakan

untuk menambang blok baru dan memvalidasi transaksi, yang meningkatkan keamanan jaringan. Grafik ini menunjukkan fluktuasi dalam *hash rate*, namun secara keseluruhan, ada kecenderungan untuk meningkat, yang mencerminkan partisipasi yang terus berkembang dari penambang dalam jaringan Bitcoin. Tren ini juga mencerminkan kapasitas jaringan untuk menangani transaksi yang lebih banyak seiring waktu, yang penting untuk menjaga keamanan dan integritas blockchain Bitcoin.

Selanjutnya, untuk melengkapi analisis on-chain, metrik trade volume atau volume perdagangan Bitcoin akan dianalisis. Exchange Trade Volume (USD) menggambarkan jumlah total transaksi perdagangan Bitcoin yang terjadi di bursa dalam mata uang USD. Metrik ini sangat penting untuk memahami likuiditas pasar dan aktivitas investor, karena volume perdagangan yang tinggi sering kali mencerminkan minat yang kuat dari pelaku pasar. Grafik berikut ini akan menunjukkan pergerakan volume perdagangan Bitcoin sepanjang waktu, yang dapat memberikan wawasan tentang tren pasar dan potensi korelasi antara volume perdagangan dengan pergerakan harga atau faktor lainnya.

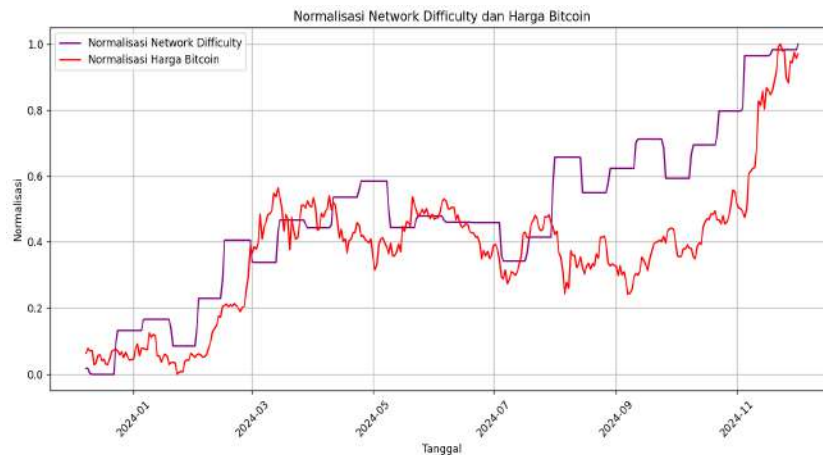


Gambar 4.22. Normalisasi Harga dan *Trade Volume* Bitcoin 2024.

Gambar 4.22 menunjukkan perbandingan antara normalisasi *trade volume*

(dalam USD) dan normalisasi harga Bitcoin sepanjang periode pengamatan. *Trade volume* mengacu pada jumlah total Bitcoin yang diperdagangkan di bursa dalam mata uang USD selama periode tertentu. Metrik ini sangat penting untuk mengukur likuiditas pasar dan aktivitas investor, karena volume perdagangan yang tinggi sering kali menunjukkan minat yang kuat dari para pelaku pasar. Grafik ini menunjukkan bahwa meskipun volume perdagangan Bitcoin bervariasi, terdapat tren tertentu yang menunjukkan hubungan antara aktivitas pasar dengan pergerakan harga Bitcoin. Perubahan dalam trade volume sering kali dapat mendahului atau mengikuti fluktuasi harga Bitcoin, mengindikasikan adanya korelasi antara pasar yang lebih aktif dan pergerakan harga yang tajam.

Selanjutnya, membuat metrik *network difficulty* untuk menunjukkan kondisi jaringan Bitcoin. *Difficulty* dalam jaringan Bitcoin menggambarkan tingkat kesulitan yang dihadapi para penambang untuk menemukan blok baru. Setiap 2016 blok, jaringan Bitcoin menyesuaikan kesulitan penambangan untuk memastikan bahwa waktu rata-rata untuk menambang satu blok tetap sekitar 10 menit, terlepas dari perubahan jumlah penambang yang berpartisipasi. Grafik berikut ini akan menunjukkan bagaimana kesulitan penambangan berubah sepanjang waktu dan memberikan wawasan tentang bagaimana perubahan dalam kesulitan ini memengaruhi keamanan dan stabilitas jaringan Bitcoin. Metrik ini sangat penting untuk memahami dinamika daya komputasi yang diperlukan untuk menjaga integritas dan desentralisasi jaringan Bitcoin.



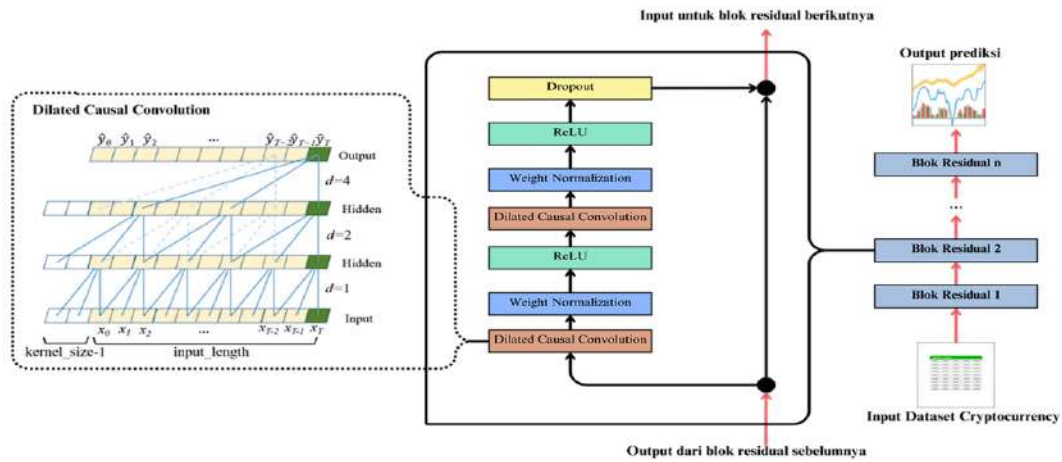
Gambar 4.23. Normalisasi Harga dan *Difficulty* Bitcoin 2024.

Gambar 4.23 menunjukkan perbandingan antara normalisasi *network difficulty* dan normalisasi harga Bitcoin sepanjang periode pengamatan. *Network difficulty* mengukur tingkat kesulitan yang dihadapi oleh penambang untuk menemukan blok baru dalam jaringan Bitcoin. Setiap 2016 blok, tingkat kesulitan ini disesuaikan untuk memastikan waktu rata-rata penambangan satu blok tetap sekitar 10 menit, terlepas dari jumlah penambang yang berpartisipasi. Grafik ini menunjukkan bagaimana tingkat kesulitan penambangan berubah seiring waktu, dengan fluktuasi yang menggambarkan respons jaringan terhadap jumlah penambang yang aktif dan perubahan dalam kapasitas komputasi jaringan. Kesulitan yang lebih tinggi menandakan adanya lebih banyak daya komputasi yang dibutuhkan untuk mempertahankan integritas jaringan, yang berarti jaringan Bitcoin menjadi lebih aman seiring bertambahnya kesulitan.

4.4 Temporal Convolutional Network

Temporal Convolutional Network (TCN) adalah algoritma yang dirancang untuk menangani data deret waktu dengan memanfaatkan teknik konvolusi dilasi untuk menangkap pola temporal. Algoritma ini bekerja dengan membagi

langkah-langkahnya menjadi beberapa tahap. Berikut adalah skema penerapan dari algoritma TCN.



Gambar 4.24. *Temporal Convolutional Network*

Pada langkah pertama, dataset di-normalisasi ke skala $[0, 1]$ menggunakan formula $x'_t = \frac{x_t - x_{\min}}{x_{\max} - x_{\min}}$, di mana x_{\min} dan x_{\max} masing-masing adalah nilai minimum dan maksimum dalam dataset. Setelah itu, pasangan data (X_t, y_t) dibentuk, di mana $X_t = [x_{t-t_s}, x_{t-t_s+1}, \dots, x_{t-1}]$ mewakili jendela waktu, dan $y_t = x_t$ adalah nilai aktual.

Langkah selanjutnya adalah inialisasi bobot untuk konvolusi dilasi. Bobot W_g diinisialisasi secara acak dengan ukuran $W_g^l \in \mathbb{R}^{m \times k}$, di mana m adalah jumlah filter dan k adalah ukuran kernel. Dilasi awal diatur menjadi $d = 1$ untuk lapisan pertama.

Dalam tahap konvolusi dilasi, dilakukan operasi $m_t^l = W_g^l \cdot h_{t-d \cdot i}^{l-1} + \beta_l$, di mana $i \in \{0, 1, \dots, k-1\}$. Faktor dilasi d meningkat eksponensial pada setiap lapisan ($d \leftarrow d \cdot 2$), dan h_t^l dihitung dengan fungsi aktivasi $\text{ReLU}(m_t^l)$.

Untuk menjaga stabilitas algoritma, koneksi residual digunakan pada setiap lapisan dengan operasi $h_t^l = h_t^l + h_t^{l-1}$, dan regularisasi seperti Dropout diterapkan untuk mencegah overfitting. Pada lapisan terakhir, output prediksi dihitung sebagai $\hat{y}^t = f(h_t^n)$, di mana f adalah fungsi aktivasi linier atau regresi.

algoritma kemudian dievaluasi menggunakan Mean Squared Error (MSE) dengan formula error = $\frac{1}{N} \sum_{i=1}^N (\hat{y}^i - y^i)^2$, di mana N adalah jumlah data. Jika error melebihi toleransi ϵ , bobot diperbarui menggunakan rumus $W_g^{l+1} = W_g^l - \alpha \cdot \frac{\partial \text{error}}{\partial W_g}$, dengan gradien $\frac{\partial \text{error}}{\partial W_g} = \frac{1}{N} \sum_{i=1}^N (\hat{y}^i - y^i) \cdot X_t$.

Setelah algoritma dilatih, prediksi langkah ke depan dilakukan dengan menggunakan algoritma yang telah terlatih. Prediksi langkah ke depan dihitung sebagai $\hat{y}^{t+1} = f(W_g \cdot h_t^n)$, dan hasil prediksi tersebut dimasukkan kembali ke jendela waktu untuk prediksi selanjutnya. Akhirnya, hasil prediksi diubah kembali ke skala aslinya dengan menggunakan formula $\hat{y}_{\text{asli}} = \hat{y}^t \cdot (x_{\text{max}} - x_{\text{min}}) + x_{\text{min}}$. Dari algoritma yang telah dijelaskan di atas, berikut adalah perhitungan secara matematis dalam memprediksi salah satu *coin cyptocurrency* menggunakan algoritma TCN.

Dataset:

Dataset harga Ethereum (dalam USD) selama 1 bulan terakhir:

Tabel 4.4. Dataset Harga Ethereum

Tanggal	Open	High	Low	Close
11/11/2024	3189	3378	3113	3375
11/12/2024	3370	3434	3216	3252
11/13/2024	3245	3326	3120	3186
11/14/2024	3183	3238	3043	3057
11/15/2024	3058	3126	3019	3090
...
12/03/2024	3644	3666	3517	3621
12/04/2024	3617	3877	3617	3834
12/05/2024	3837	3946	3756	3786
12/06/2024	3785	4082	3784	4004
12/07/2024	4000	4021	3975	3998

Panjang jendela waktu yang digunakan adalah $t_s = 27$, artinya, algoritma akan memprediksi harga hari ke $t + 1$ berdasarkan 27 hari sebelumnya.

Langkah Perhitungan:

Step 1: Normalisasi Data.

Contoh perhitungan normalisasi data dari tanggal 3-7 Desember 2024:

Tabel 4.5. Dataset Harga Open Ethereum

Tanggal	Open
12/03/2024	3644
12/04/2024	3617
12/05/2024	3837
12/06/2024	3785
12/07/2024	4000

Menghitung x_{\min} dan x_{\max}

$$x_{\min} = 3617 \quad (\text{nilai minimum dari 'Open'})$$

$$x_{\max} = 4000 \quad (\text{nilai maksimum dari 'Open'})$$

Menghitung Normalisasi untuk setiap nilai 'Open'

$$x'_t = \frac{x_t - x_{\min}}{x_{\max} - x_{\min}} = \frac{x_t - 3617}{4000 - 3617} = \frac{x_t - 3617}{383}$$

Untuk harga 3644:

$$x'_t = \frac{3644 - 3617}{383} = \frac{27}{383} \approx 0.0705$$

Untuk harga 3617:

$$x'_t = \frac{3617 - 3617}{383} = 0.0$$

Untuk harga 3837:

$$x'_t = \frac{3837 - 3617}{383} = \frac{220}{383} \approx 0.5741$$

Untuk harga 3785:

$$x'_t = \frac{3785 - 3617}{383} = \frac{168}{383} \approx 0.4387$$

Untuk harga 4000:

$$x'_t = \frac{4000 - 3617}{383} = \frac{383}{383} = 1.0$$

Sehingga, data setelah normalisasi:

$$X' = [0.0705, 0.0, 0.5741, 0.4387, 1.0]$$

Step 2: Pembentukan Jendela Waktu.

Pasangan input-output (X_t, y_t) dibentuk berdasarkan $t_s = 5$. Sebagai contoh, untuk hari ke-6 ($t = 6$):

$$X_6 = [0.0705, 0.0, 0.5741, 0.4387, 1.0], \quad y_6 = 0.150$$

Step 3: Operasi Konvolusi Dilasi.

Bobot awal untuk kernel konvolusi $W_g = [0.2, 0.4, 0.6, 0.8, 1.0]$, bias $\beta = 0$. Dilasi awal $d = 1$. Operasi konvolusi dilakukan sebagai berikut:

$$m_t^l = \sum_{i=1}^5 W_g[i] \cdot X_t[i] + \beta$$

Substitusi nilai X_6 dan W_g :

$$m_6^1 = (0.2 \cdot 0.0705) + (0.4 \cdot 0.0) + (0.6 \cdot 0.5741) + (0.8 \cdot 0.4387) + (1.0 \cdot 1.0)$$

$$m_6^1 = 0.0141 + 0.0 + 0.3445 + 0.3509 + 1.0 = 1.7095$$

Step 4: Aktivasi (ReLU).

Hasil konvolusi dilasi melewati fungsi aktivasi ReLU:

$$h_6^1 = \text{ReLU}(m_6^1) = \max(0, 1.7095) = 1.7095$$

Step 5: Residual Connection.

Koneksi residual ditambahkan ke hasil lapisan:

$$h_6^l = h_6^1 + X_6[5] = 1.7095 + 1.0 = 2.7095$$

Step 6: Prediksi Akhir.

Pada lapisan terakhir, output prediksi dihitung menggunakan fungsi regresi linier:

$$\hat{y}_6 = f(h_6^l) = h_6^l = 2.7095$$

Step 7: Denormalisasi Data.

Hasil prediksi dikembalikan ke skala aslinya menggunakan formula:

$$\hat{y}_{\text{asli}} = \hat{y}_t \cdot (x_{\text{max}} - x_{\text{min}}) + x_{\text{min}}$$

Substitusi nilai $\hat{y}_6 = 2.7095$:

$$\hat{y}_{\text{asli}} = 2.7095 \cdot (4000 - 3617) + 3617$$

$$\hat{y}_{\text{asli}} = 2.7095 \cdot 383 + 3617 = 1038.2 + 3617 = 4655.2$$

Prediksi harga Ethereum untuk hari ke-6 adalah **\$4655.2**.

Setelah memahami algoritma *Temporal Convolutional Network* melalui perhitungan manual secara matematis, langkah selanjutnya adalah mengimplementasikan algoritma tersebut menggunakan bahasa pemrograman Python. Dengan Python, proses prediksi dapat dilakukan secara otomatis atau dikerjakan oleh sistem komputer, sehingga proses perhitungan lebih cepat dan efisien. Selain itu, Python menyediakan pustaka seperti TensorFlow dan Keras, yang dapat membantu dalam pembangunan algoritma TCN. TensorFlow adalah pustaka *open-source* yang

dirancang untuk komputasi numerik dan *machine learning*. Pustaka ini populer karena dapat menangani perhitungan kompleks dan menjalankan perhitungan untuk *bigdata*. Kemudian, Keras adalah antarmuka yang lebih sederhana dan mudah digunakan yang dibangun di atas TensorFlow. Keras digunakan untuk pengembangan algoritma dalam *machine learning*, termasuk TCN yang membuatnya lebih cepat dan intuitif bagi pemula. Kombinasi TensorFlow dan Keras memungkinkan pengembangan algoritma menjadi fleksibel dan efisien.

Implementasi Algoritma *Temporal Convolutional Network* (TCN) menggunakan Python dimulai dengan mempersiapkan dataset yang akan digunakan untuk proses pelatihan dan pengujian algoritma. Dataset berisi data harga *cryptocurrency* harian, seperti harga pembukaan, harga tertinggi, harga terendah, dan harga penutupan. Dataset yang digunakan dalam eksperimen ini adalah harga mata uang *cryptocurrency* dalam format CSV, sebagai contoh adalah Doge26.csv. Berikut adalah tampilan dataset yang akan digunakan

Tabel 4.6. Contoh Dataset Harga Cryptocurrency Harian

Date	Open	High	Low	Close
11/01/2024	69,949	71,588	68,783	69,267
10/31/2024	71,824	72,905	69,942	69,948
10/30/2024	72,531	72,952	71,425	71,822
10/29/2024	69,587	73,595	69,428	72,532
10/28/2024	67,750	69,865	67,549	69,588

Algoritma TCN dirancang menggunakan pustaka Keras dengan backend TensorFlow, yang memungkinkan pembangunan algoritma deep learning untuk menangani data sekuensial. Pustaka-pustaka yang digunakan untuk membangun dan mengevaluasi algoritma peramalan berbasis TCN dapat dilihat pada *script* berikut.

```

1 import numpy as np
2 import pandas as pd
3 from tcn import TCN
4 from tensorflow.keras.models import Sequential
5 from tensorflow.keras.layers import Dense
6 from tensorflow.keras.optimizers import Adam
7 from tensorflow.keras.regularizers import l2
8 from tensorflow.keras.callbacks import EarlyStopping
9 from tensorflow.keras.optimizers import RMSprop
10 from sklearn.model_selection import KFold
11 from sklearn.preprocessing import MinMaxScaler
12 from sklearn.metrics import mean_absolute_error, mean_squared_error
13 import plotly.graph_objs as go
14 import plotly.io as pio
15 import statsmodels.api as sm
16 from plotly.subplots import make_subplots
17
18 pio.renderers.default = 'browser'

```

Gambar 4.25. Library TCN.

Gambar 4.25 menunjukkan pustaka-pustaka yang digunakan untuk membangun dan melatih algoritma TCN, seperti *NumPy* dan *Pandas* untuk manipulasi data, *Matplotlib* untuk visualisasi, dan *MinMaxScaler* untuk normalisasi data. Selain itu, *sklearn.metrics* menyediakan metrik evaluasi seperti *MAE* dan *MSE* untuk mengukur kinerja algoritma. Pustaka TCN dari `tcn` digunakan untuk implementasi algoritma konvolusional temporal itu sendiri. Pustaka *Plotly* menghasilkan visualisasi interaktif dengan *output* yang dipilih melalui browser, sedangkan `statsmodels.api` digunakan untuk analisis statistik seperti autokorelasi. Setelah membangun pustaka, dibangun perintah untuk membaca dataset yang memiliki format *csv*, perintah yang diperlukan dapat dilihat pada *script* berikut.

```

20 # Load dataset
21 df = pd.read_csv('BTC08.csv')
22 print("Dataframe sebelum dibalik:")
23 print(df.head())
24 df['Date'] = pd.to_datetime(df['Date'], errors='coerce') # 'coerce' mengubah entri tanggal yang tidak valid menjadi NaT
25 df.dropna(subset=['Date'], inplace=True)
26 df.set_index('Date', inplace=True)
27 print("\nDataframe setelah preprocessing tanggal:")
28 print(df.head())
29 def clean_column(column):
30     # Cek apakah kolom bertipe string (dengan koma)
31     if column.dtype == 'object':
32         return column.str.replace(',', '', regex=False).astype(float)
33     else:
34         return column # Jika sudah numerik, dikembalikan apa adanya
35 df['Open'] = clean_column(df['Open'])
36 df['High'] = clean_column(df['High'])
37 df['Low'] = clean_column(df['Low'])
38 df['Close'] = clean_column(df['Close'])
39 print("\nDataframe setelah membersihkan kolom:")
40 print(df.head())
41 closedf = df[['Low']]

```

Gambar 4.26. Import Dataset.

Gambar 4.26 menunjukkan proses pemrosesan data dari file `btc08.csv` menggunakan pustaka *Pandas*. Data ini kemudian ditampilkan untuk memastikan struktur awalnya sebelum dilakukan proses *praprocessing*. Kolom `Date` diubah menjadi tipe data `datetime` menggunakan fungsi `pd.to_datetime` agar lebih mudah dimanipulasi berdasarkan waktu. Selanjutnya, setiap entri yang memiliki nilai kosong atau tidak valid pada kolom `Date` dihapus menggunakan `dropna`, dan kolom `Date` diatur sebagai indeks dengan perintah `set_index`. Proses pembersihan kolom dilakukan melalui fungsi `clean_column`, yang memastikan data numerik dalam kolom seperti `Open`, `High`, `Low`, dan `Close` tidak memiliki karakter seperti koma atau string yang dapat mengganggu analisis. Jika ditemukan data berupa string, karakter tersebut diganti dengan format numerik *float*.

```
42 scaler = MinMaxScaler(feature_range=(0, 1))
43 closedf_scaled = scaler.fit_transform(closedf)
```

Gambar 4.27. Normalisasi Data.

Gambar 4.27 menunjukkan tahap normalisasi data menggunakan pustaka *MinMaxScaler* dari `sklearn.preprocessing`. Pada tahap ini, objek `scaler` dibuat dengan menggunakan `MinMaxScaler(feature_range=(0, 1))`, yang mengatur data untuk berada dalam rentang antara 0 dan 1. Langkah ini bertujuan untuk memastikan semua nilai input memiliki skala yang seragam, sehingga membantu dalam mempercepat proses pelatihan algoritma dan mengurangi risiko bias akibat skala data yang besar. Selanjutnya, dataset yang telah difilter (`closedf`) diubah dengan metode `fit_transform(closedf)`, yang secara bersamaan menghitung nilai minimum dan maksimum dari data serta melakukan transformasi ke rentang yang telah ditentukan. Hasil normalisasi ini disimpan kembali ke dalam variabel `closedf`, yang siap digunakan untuk analisis. Tahap berikutnya membangun data input dan label untuk pelatihan algoritma menggunakan pendekatan berbasis jendela waktu (*time-step*), dapat dilihat pada *script* berikut.

```

43 def add_noise(data, noise_factor=0.02):
44     noise = noise_factor * np.random.normal(loc=0.0, scale=1.0, size=data.shape)
45     return data + noise
46 early_stop = EarlyStopping(monitor='val_loss', patience=10, restore_best_weights=True)
47 kf = KFold(n_splits=3, shuffle=True, random_state=42)
48 time_step = 14 # window waktu untuk setiap urutan input
49 X, y = [], []
50 for i in range(len(closedf_scaled) - time_step):
51     X.append(closedf_scaled[i:i + time_step, 0])
52     y.append(closedf_scaled[i + time_step, 0])
53 X, y = np.array(X), np.array(y)
54 X = np.reshape(X, (X.shape[0], X.shape[1], 1)) # Reshape untuk TCN (samples, time steps, features)

```

Gambar 4.28. Membangun Data Input dan Label.

Gambar 4.28 menunjukkan Fungsi `add_noise` ditambahkan untuk menyisipkan derau (*noise*) ke dalam data guna meningkatkan generalisasi model. Derau yang ditambahkan dihitung berdasarkan parameter `noise_factor`, yang dikalikan dengan distribusi normal acak menggunakan fungsi `np.random.normal`. Nilai derau kemudian dijumlahkan dengan data asli untuk menghasilkan data dengan variasi tambahan. Proses berikutnya adalah mendefinisikan `early_stop`, yaitu callback untuk menghentikan pelatihan secara otomatis jika metrik `val_loss` tidak membaik setelah sejumlah epoch tertentu. Parameter `patience` diatur ke 10, sedangkan `restore_best_weights=True` memastikan bobot terbaik dipulihkan setelah pelatihan berhenti. Tahap berikutnya adalah membagi data menjadi beberapa lipatan (*fold*) menggunakan metode `KFold` dari pustaka `sklearn.model_selection`, dengan parameter `n_splits=3` yang menunjukkan bahwa data akan dibagi menjadi tiga lipatan. `Shuffle` diaktifkan (`shuffle=True`) untuk memastikan distribusi data yang merata, dan `random_state=42` digunakan untuk hasil yang dapat direproduksi.

Proses pembuatan data urutan dilakukan dengan mengatur `time_step` sebesar 14, yang merepresentasikan panjang jendela waktu untuk setiap urutan input. Melalui perulangan `for`, data fitur (`X`) dan target (`y`) disiapkan dengan cara memotong data skala (`closedf_scaled`) berdasarkan jendela waktu yang ditentukan. Untuk setiap iterasi, elemen-elemen dalam rentang `i : i+time_step` ditambahkan ke `X`, sedangkan nilai pada indeks `i+time_step` ditambahkan ke `y`. Setelah proses pembentukan data

selesai, X dan y dikonversi menjadi array menggunakan `np.array`. Langkah terakhir adalah melakukan penyesuaian bentuk data (*reshape*) dengan perintah `np.reshape`, di mana dimensi X diatur menjadi tiga dimensi, yaitu (`samples`, `time_steps`, `features`). Tahap selanjutnya adalah merancang arsitektur TCN untuk memproses deret waktu, dapat dilihat pada *script* berikut

```

60 # Split data menjadi train dan test set
61 train_size = int(len(X) * 0.8) # 80% untuk pelatihan
62 X_train, X_test = X[:train_size], X[train_size:]
63 y_train, y_test = y[:train_size], y[train_size:]
64 print(f"\nTrain size: {train_size}")
65 print(f"X_train shape: {X_train.shape}")
66 print(f"X_test shape: {X_test.shape}")
67 # Definisikan Model TCN
68 model = Sequential([
69     TCN(input_shape=(time_step, 1), nb_filters=32, kernel_size=5, dilations=[1, 2, 4],
70         dropout_rate=0.2, return_sequences=False), # Layer TCN
71     Dense(50, activation='relu'), # Layer Dense untuk pemrosesan lebih lanjut
72     Dense(1) # Layer output untuk regresi
73 ]) model.compile(optimizer=RMSprop(learning_rate=0.001), loss='mse')

```

Gambar 4.29. Arsitektur TCN.

Gambar 4.29 menunjukkan proses pembagian data menjadi train dan test set, serta definisi model TCN. Data dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian dengan menggunakan variabel `train_size`, yang dihitung berdasarkan panjang data X . Data pelatihan (`X_train` dan `y_train`) diambil dari awal hingga `train_size`, sedangkan data pengujian (`X_test` dan `y_test`) diambil dari `train_size` hingga akhir. Informasi mengenai ukuran data pelatihan dan pengujian dicetak menggunakan perintah `print`. Selanjutnya, model TCN didefinisikan menggunakan `Sequential` dari Keras. Model ini memiliki beberapa komponen utama, yaitu lapisan TCN, lapisan Dense untuk pemrosesan lebih lanjut, dan lapisan output untuk regresi. Lapisan TCN didefinisikan dengan parameter seperti `input_shape` (berisi jumlah timestep dan fitur), `nb_filters` sebanyak 32, `kernel_size` sebesar 5, dan `dilations` yang mencakup pola [1, 2, 4]. Lapisan ini juga menggunakan dropout sebesar 0.2 untuk mencegah *overfitting*, dengan `return_sequences=False` untuk memastikan outputnya diteruskan langsung ke lapisan berikutnya.

```

78 # Train model
79 history = model.fit(X_train, y_train, epochs=200, batch_size=32, verbose=1,
80 | validation_data=(X_test, y_test), callbacks=[early_stop] )
81 predictions_train = model.predict(X_train)
82 predictions_test = model.predict(X_test)
83 predictions_train_inv = scaler.inverse_transform(predictions_train)
84 original_train = scaler.inverse_transform(y_train.reshape(-1, 1))
85 predictions_test_inv = scaler.inverse_transform(predictions_test)
86 original_test = scaler.inverse_transform(y_test.reshape(-1, 1))

```

Gambar 4.30. *Train Data.*

Gambar 4.30 menunjukkan proses pelatihan algoritma TCN, pembuatan prediksi, dan transformasi balik hasil prediksi ke skala aslinya. Pada tahap pertama, algoritma dilatih menggunakan metode `fit()` dengan parameter `epochs=500` dan `batch_size=32`, serta memanfaatkan 30% data sebagai *validation split* untuk mengevaluasi kinerja algoritma selama pelatihan. Setelah pelatihan selesai, prediksi dibuat menggunakan metode `predict()` pada dataset input X . Hasil prediksi kemudian dikembalikan ke skala aslinya menggunakan metode `inverse_transform()` dari objek `scaler`, yang membatalkan normalisasi yang dilakukan sebelumnya. Proses ini juga dilakukan untuk variabel target y , yang diubah bentuknya menjadi dua dimensi dengan fungsi `reshape(-1, 1)` sebelum diterapkan transformasi balik. Hasil akhir adalah data prediksi dan target dalam skala aslinya untuk analisis lebih lanjut. Selanjutnya adalah perhitungan metrik evaluasi menggunakan Mean Absolute Error (MAE) dan Mean Squared Error (MSE) untuk mengukur performa prediksi algoritma, perintah dapat dilihat pada *script* berikut.

```

88 # Hitung MAE dan MSE
89 mae_train = mean_absolute_error(original_train, predictions_train_inv)
90 mse_train = mean_squared_error(original_train, predictions_train_inv)
91 mae_test = mean_absolute_error(original_test, predictions_test_inv)
92 mse_test = mean_squared_error(original_test, predictions_test_inv)

```

Gambar 4.31. *Metrik Evaluasi.*

Gambar 4.31 menunjukkan proses perhitungan metrik evaluasi model

menggunakan *Mean Absolute Error* (MAE) dan *Mean Squared Error* (MSE) untuk data pelatihan dan pengujian. Metrik ini digunakan untuk mengukur seberapa baik prediksi model dibandingkan dengan data sebenarnya. Pada baris pertama, MAE untuk data pelatihan dihitung menggunakan fungsi `mean_absolute_error()` dengan membandingkan nilai sebenarnya (`original_train`) dengan hasil prediksi model yang telah diinverse (`predictions_train_inv`). MSE untuk data pelatihan dihitung pada baris kedua menggunakan fungsi `mean_squared_error()`, yang menekankan penalti lebih besar terhadap kesalahan besar. Proses yang sama dilakukan untuk data pengujian pada baris ketiga dan keempat. MAE dan MSE dihitung dengan membandingkan nilai sebenarnya (`original_test`) dengan hasil prediksi yang telah diinvers (`predictions_test_inv`). MAE memberikan rata-rata selisih absolut antara prediksi dan nilai aktual, sedangkan MSE memberikan rata-rata selisih kuadrat yang lebih sensitif terhadap kesalahan besar. Selanjutnya proses pembuatan prediksi jangka panjang (*forecasting*) dengan algoritma TCN menggunakan iterasi berdasar prediksi sebelumnya, dapat dilihat pada *script* berikut.

```

99 # Forecasting beberapa langkah ke depan setelah data aktual
100 forecast_horizon = 20 # Jumlah langkah untuk diprediksi
101 last_sequence = X[-1] # Mulai dengan urutan terakhir dari data pelatihan
102 future_predictions = []
103 sm.graphics.tsa.plot_acf(closedf_scaled.flatten(), lags=30)
104 future_dates = pd.date_range(df.index[-1], periods=forecast_horizon + 1, freq='D')[1:]
105 for _ in range(forecast_horizon):
106     next_pred = model.predict(last_sequence.reshape(1, time_step, 1))[0, 0]
107     future_predictions.append(next_pred)
108     # Update last_sequence dengan prediksi baru
109     last_sequence = np.append(last_sequence[1:], [[next_pred]], axis=0)
110 future_predictions_inv = scaler.inverse_transform(np.array(future_predictions).reshape(-1, 1))
111 print(f"\nFuture Predictions (first 5): {future_predictions_inv[:5].flatten()}")
112 fig = make_subplots(rows=1, cols=1)

```

Gambar 4.32. Algoritma *Forecasting* TCN.

Gambar 4.32 menunjukkan proses peramalan harga beberapa langkah ke depan setelah data aktual menggunakan model TCN. Parameter `forecast_horizon` ditetapkan sebagai 20, yang menunjukkan jumlah langkah ke depan yang akan diprediksi. Peramalan dimulai dengan urutan terakhir dari data pelatihan

(`last_sequence`), yang digunakan sebagai input awal untuk menghasilkan prediksi masa depan. Pada awal proses, fungsi `pd.date_range()` digunakan untuk menghasilkan tanggal-tanggal masa depan sebanyak `forecast_horizon`, dengan melewati tanggal pertama yang merupakan tanggal terakhir dari data aktual. Peramalan dilakukan melalui loop `for`, di mana model memprediksi nilai berikutnya (`next_pred`) berdasarkan urutan terakhir (`last_sequence`). Prediksi tersebut kemudian ditambahkan ke daftar `future_predictions`, dan urutan terakhir diperbarui dengan memasukkan prediksi baru menggunakan `np.append()`.

Setelah semua prediksi dihitung, nilai prediksi yang masih dalam skala normalisasi diinverse ke skala aslinya menggunakan `scaler.inverse_transform()` dan disimpan dalam `future_predictions_inv`. Beberapa prediksi pertama ditampilkan menggunakan perintah `print()` untuk pemeriksaan cepat. Selain itu, fungsi `sm.graphics.tsa.plot_acf()` digunakan untuk memplot fungsi autokorelasi (ACF) guna menganalisis pola temporal dalam data.

Pembangunan algoritma TCN dilanjutkan dengan pengujian algoritma menggunakan dataset `csv`, yang berisi data historis pergerakan harga *cryptocurrency* seperti Bitcoin. Penentuan TCN terbaik dilakukan dengan beberapa skenario meliputi *timestep*, *filter*, *kernel size*, *dilation rate*, *dropout rate*, *batch size*, dan *epoch*. Tidak ada aturan untuk menentukan *timestep*, *filter*, *kernel size*, *dilation rate*, *dropout rate*, *batch size*, dan *epoch* sehingga perlu dilakukan eksperimen untuk mendapatkan hasil yang optimal. Pada pengujian ini TCN yang optimal adalah TCN yang memiliki nilai MSE dan MAE paling minimal. Tabel di bawah merupakan tabel hasil pengujian dengan beberapa percobaan dengan *dataset* harga Bitcoin dengan 80% data *training* dan 20% data *testing*.

Tabel 4.7. Eksperimen Parameter TCN

<i>Timestep</i>	<i>Filter</i>	<i>Kernel Size</i>	<i>Dilation Rate</i>	<i>Dropout Rate</i>	<i>Batch Size</i>	<i>Epoch</i>	MSE	MAE
14	64	3	[1, 2, 4, 8]	0.1	16	100	1347.3	3,454,888.1
10	32	5	[1, 2, 4]	0.2	32	150	1325.8	3,429,312.9
20	128	7	[1, 2, 4, 8, 16]	0.3	64	200	1332.5	3,460,802.3
14	64	5	[1, 2, 4, 8]	0.1	16	50	1343,6	3,466,351.7
14	32	5	[1, 2, 4, 8]	0.2	32	150	1332.7	3,438,575.8
10	64	5	[1, 2, 4]	0.1	32	150	1333.6	3,434,888.7

Tabel 4.8 menunjukkan parameter optimal untuk TCN adalah pada baris ke-2, dengan nilai MSE terendah sebesar 1325.8 dan MAE yang relatif rendah sebesar 3,429,312.9. parameter ini menggunakan *timestep* 10, *filter* 32, *kernel size* 5, *dilation rate* [1, 2, 4], *dropout rate* 0.2, *batch size* 32, dan 150 *epoch*, yang menunjukkan keseimbangan antara akurasi dan efisiensi. Nilai MSE dan MAE yang paling rendah menunjukkan bahwa TCN memiliki error kuadrat rata-rata yang rendah, sehingga lebih presisi dalam memprediksi harga *cryptocurrency*. Penggunaan *timestep* yang lebih pendek 10 membantu TCN menangkap pola temporal yang baik, sementara *filter* sebanyak 32 dan *kernel size* 5 memberikan kemampuan yang cukup bagi TCN untuk mengekstraksi fitur penting dari data. Selain itu, *dilation rate* [1, 2, 4] memungkinkan untuk menangkap pola temporal dengan jangkauan yang luas, dan *dropout rate* 0.2 membantu mencegah *overfitting*. Dengan hasil ini, konfigurasi pada baris ke-2 dapat dianggap sebagai yang paling optimal. Setelah menemukan parameter yang optimal, dilanjutkan dengan *forecasting* harga Bitcoin dengan parameter sebelumnya. *Forecasting* dilakukan dengan data *open*, *high*, *low*, dan *close* pada tanggal 1 Januari 2024 hingga 31 Desember 2024 untuk memprediksi pada bulan selanjutnya. Untuk *forecasting* harga *close* dapat dilihat pada gambar 4.30.



Gambar 4.33. *Forecasting* Harga Penutupan BTC.

Gambar 4.33 menunjukkan hasil prediksi harga penutupan Bitcoin (Close) menggunakan model TCN. Pada grafik tersebut, garis biru merepresentasikan data aktual, garis kuning putus-putus menunjukkan prediksi pada data pelatihan, garis magenta putus-putus mewakili prediksi pada data pengujian, dan garis hijau putus-putus menggambarkan prediksi masa depan. Hasil prediksi menunjukkan akurasi yang lebih rendah dibandingkan data pelatihan dengan MAE 1348.1 dan MSE 3,498,169.77, terutama pada periode dengan volatilitas tinggi, terlihat dari perbedaan antara prediksi dan harga aktual. Sementara itu, prediksi untuk masa depan menunjukkan pola yang melanjutkan tren sebelumnya. Selanjutnya dilakukan prediksi untuk harga pembukaan Bitcoin (Open).



Gambar 4.34. *Forecasting* Harga Pembukaan BTC.

Gambar 4.34 berfokus pada prediksi harga pembukaan Bitcoin (Open) yang menunjukkan pola serupa dengan Gambar 4.33. Garis prediksi pada data pelatihan hampir tumpang tindih dengan garis aktual, mengindikasikan model mampu menangkap pola historis dengan baik. Namun, pada data pengujian, kesalahan prediksi sedikit lebih besar, terutama pada tren menurun atau saat terjadi lonjakan harga signifikan. Nilai MAE dan MSE, masing-masing sebesar 733,94 dan 1.340.144,46 untuk pelatihan, serta 1.344,52 dan 3.498.533,78 untuk pengujian, menunjukkan performa TCN cukup baik. Selanjutnya *forecasting* dilakukan pada harga tertinggi (*high*) pada Bitcoin.



Gambar 4.35. *Forecasting* Harga Tertinggi BTC-USD.

Gambar 4.35 menunjukkan hasil prediksi harga tertinggi Bitcoin (High) menggunakan model TCN. Garis biru menggambarkan harga aktual, sementara garis putus-putus merah muda menunjukkan prediksi pada data pelatihan, yang hampir tumpang tindih dengan harga aktual. Hal ini menunjukkan bahwa model mampu menangkap pola historis dengan baik pada data pelatihan. Nilai MAE dan MSE masing-masing sebesar 659.22 dan 976,031.89 untuk pelatihan, serta 1,235.00 dan 2,894,203.36 untuk pengujian, menunjukkan bahwa model TCN memiliki performa yang baik dalam memprediksi data meskipun terdapat volatilitas tinggi pada pergerakan harga Bitcoin. Prediksi masa depan mengikuti pola peningkatan harga

yang tampak konsisten. Selanjutnya *forecasting* dilakukan pada harga terendah (*low*) pada Bitcoin.



Gambar 4.36. *Forecasting* Harga Terendah BTC-USD.

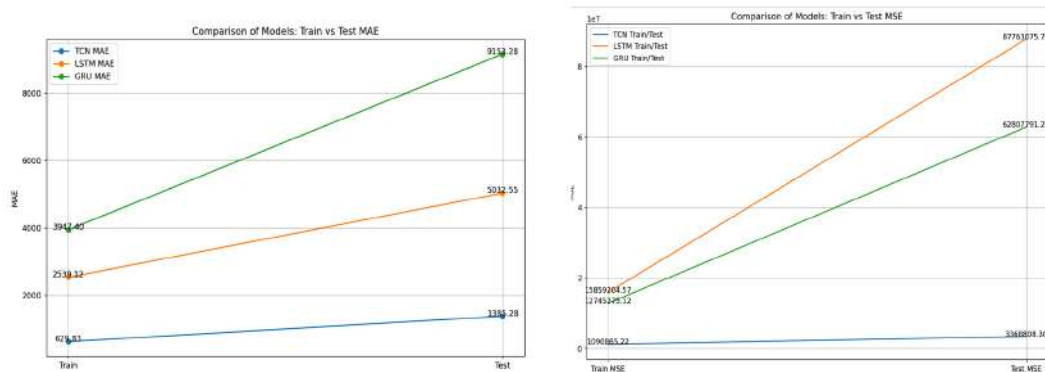
Gambar 4.36 berfokus pada prediksi harga terendah Bitcoin (Low) yang menunjukkan pola serupa dengan hasil prediksi harga pembukaan pada Gambar 4.33. Garis prediksi pada data pelatihan (putus-putus merah muda) hampir tumpang tindih dengan garis aktual (biru), mengindikasikan bahwa model TCN mampu menangkap pola historis dengan baik pada data pelatihan. Namun, pada data pengujian (garis putus-putus merah), kesalahan prediksi sedikit lebih besar, terutama pada periode tren menurun tajam atau saat terjadi lonjakan harga yang signifikan. Nilai MAE dan MSE masing-masing sebesar 601.94 dan 1,018,187.29 untuk pelatihan, serta 1,352.93 dan 3,410,206.56 untuk pengujian. Untuk memastikan apakah TCN optimal, dilakukan perbandingan dengan *Long Short-Term Memory* (LSTM), dan *Gated Recurrent Unit* (GRU) yang sudah populer sebagai alat peramalan untuk menentukan pendekatan paling efektif dalam memprediksi tren harga Bitcoin. Model-model ini dinilai berdasarkan *Mean Absolute Error* (MAE) dan *Mean Squared Error* (MSE) pada data pelatihan dan pengujian. Perbandingan ini menyoroti kemampuan masing-masing model dalam menangkap pola temporal yang kompleks dan menangani volatilitas harga. Hasil evaluasi dirangkum dalam Tabel 4.8, yang memberikan gambaran rinci

mengenai metrik kinerja dari setiap model.

Tabel 4.8. Perbandingan Kinerja Model TCN, LSTM, dan GRU

Model	Train MAE	Test MAE	Train MSE	Test MSE
TCN	629,83	1385,28	1.090.865,22	3.368.808,30
LSTM	2539,12	5032,55	15.859.204,57	87.763.075,73
GRU	3947,40	9153,28	12.745.275,12	62.807.791,25

Gambar 4.37 secara visual merepresentasikan metrik kinerja, menyoroti tren di antara model TCN, LSTM, dan GRU. Grafik ini menekankan keunggulan model TCN, dengan nilai kesalahan yang secara signifikan lebih rendah dibandingkan LSTM dan GRU. Meskipun nilai MSE dan MAE dari semua model meningkat pada data pengujian akibat tantangan generalisasi, model TCN menunjukkan celah kinerja terkecil, mencerminkan ketahanannya terhadap volatilitas data dan efektivitasnya dalam tugas peramalan deret waktu.



Gambar 4.37. Perbandingan MAE dan MSE pada TCN, LSTM, dan GRU.

Gambar 4.37 menunjukkan perbandingan antara TCN, LSTM, dan GRU untuk prediksi harga Bitcoin. *Temporal Convolutional Network* (TCN) secara konsisten mengungguli model lainnya dalam hal akurasi. Seperti yang ditunjukkan dalam Tabel 4.8, TCN mencapai nilai Train MAE terendah sebesar 629,83 dan Test MAE sebesar 1385,28, yang menyoroti kemampuannya untuk menangkap pola temporal dalam data secara lebih baik. Sebaliknya, LSTM dan GRU menunjukkan nilai MAE

yang jauh lebih tinggi, terutama pada data pengujian, dengan GRU mencatat performa terburuk dengan Test MAE sebesar 9153,28. Perbandingan grafis pada Gambar [4.21](#) semakin menegaskan ketahanan dan kemampuan generalisasi TCN, karena celah kesalahan antara pelatihan dan pengujian lebih kecil dibandingkan model lainnya. Hasil ini menunjukkan efektivitas TCN dalam menangani kompleksitas prediksi harga Bitcoin, menjadikannya pilihan yang lebih andal untuk peramalan deret waktu di pasar keuangan yang volatil.

4.5 Integrasi Analisis Fundamental, *Technical*, dan *Machine Learning*

Setelah memahami analisis fundamental, *technical*, dan *machine learning*, pada sub bab ini integrasi ketiga analisis tersebut akan dilakukan. Integrasi ini bertujuan untuk menggabungkan keunggulan dari masing-masing pendekatan, di mana analisis fundamental memberikan gambaran kondisi pasar, analisis *technical* memanfaatkan pola pergerakan harga historis, dan *machine learning* dengan *Temporal Convolutional Network* (TCN) digunakan untuk memproses data deret waktu secara lebih akurat. Penerapan analisis fundamental mengambil Bitcoin sebagai *cryptocurrency* utama. Fundamental Bitcoin yang kuat tercermin dalam berita terkini yang menunjukkan perannya sebagai aset bernilai jangka panjang. Faktor seperti pemanfaatan sebagai alat transaksi yang meluas oleh berbagai negara memberikan dampak signifikan terhadap peningkatan daya beli. Hal ini menciptakan pengaruh langsung terhadap volatilitas *cryptocurrency* khususnya Bitcoin. Berita terbaru terkait Bitcoin dapat dilihat pada gambar di bawah.



Gambar 4.38. Berita Pernyataan BTC sebagai *Digital Gold*.

Gambar 4.38 memberikan informasi bahwa Bitcoin semakin dipandang sebagai emas digital (*Digital Gold*), mencerminkan peran barunya sebagai aset lindung nilai di tengah ketidakpastian ekonomi global. Sentimen ini muncul seiring meningkatnya adopsi institusional dan persepsi bahwa Bitcoin memiliki karakteristik serupa dengan emas, seperti pasokan terbatas dan desentralisasi. Narasi ini semakin kuat ketika investor mencari instrumen alternatif untuk mengamankan aset mereka dari inflasi dan kebijakan moneter yang ekspansif. Ketahanan Bitcoin terhadap tekanan ekonomi global membuatnya dianggap sebagai aset yang berpotensi lebih unggul dibandingkan emas dalam jangka panjang.

Optimisme terhadap fundamental Bitcoin yang kuat perlu didukung dengan analisis *technical* untuk melihat pergerakan harga secara lebih jelas. Indikator *technical* menggunakan pola *candlestick*, garis *support* dan *resistance*, EMA, dan RSI. Analisis ini membantu mengidentifikasi level penting, seperti *support* sebagai titik pantul harga atau *resistance* sebagai batas atas pergerakan harga. Selain itu, pola-pola yang muncul pada grafik dapat memberikan petunjuk apakah tren harga akan berlanjut atau berbalik arah. Analisis *technical* dapat dilihat pada gambar di bawah.



Gambar 4.39. Analisis *Technical* Bitcoin/USDT

Gambar 4.39 menunjukkan bahwa pergerakan harga BTC/USDT memberikan sinyal *technical* yang penting. Pada grafik ini, terdapat area *Fibonacci Retracement* dengan level signifikan, di mana harga sempat bergerak mendekati level 0,236 (95.135,42), yang bertindak sebagai *resistance* sementara. Setelah itu, harga mengalami penurunan singkat menuju level 0,5 (94.906,30), yang berfungsi sebagai *support* sementara sebelum kembali naik. Pola *candlestick* yang signifikan juga terlihat pada grafik ini. Pola *Doji* muncul di dekat level 0,236, menunjukkan keraguan pasar antara tekanan beli dan jual. Di area *support Fibonacci* 0,618 (94.803,89), terbentuk pola *Bullish Hammer*, menunjukkan adanya tekanan beli yang kuat setelah harga sempat tertekan ke bawah. Setelah pola *hammer*, muncul *Bullish Engulfing*, yang mengonfirmasi momentum *bullish*. Di sisi lain, *Bearish Engulfing* terlihat mendekati *resistance* 95.371,97, menjadi peringatan potensi koreksi. Selain itu, pola *Bullish Marubozu* di sekitar level 0,5 menunjukkan momentum beli yang kuat tanpa bayangan atas atau bawah yang signifikan.

Indikator RSI (14) terlihat berada di level 65,68, yang menunjukkan momentum *bullish* yang masih dominan. RSI yang masih di bawah level *overbought* (70)

memberikan ruang bagi harga untuk melanjutkan tren naik tanpa tekanan jual yang besar. Namun, jika RSI mendekati atau melewati level 70, ada risiko koreksi atau konsolidasi. Garis EMA 21 (garis biru) terlihat bergerak naik secara konsisten, berperan sebagai support dinamis, yang memperkuat indikasi tren *bullish* dalam jangka pendek. Harga beberapa kali memantul ke atas setelah menyentuh garis EMA 21, yang menunjukkan EMA ini menjadi indikator penting. Selama harga tetap berada di atas EMA 21, tren *bullish* diperkirakan akan berlanjut. Namun, jika harga menembus ke bawah EMA 21, hal ini dapat menjadi sinyal awal pembalikan tren. Secara keseluruhan, kombinasi pola *candlestick*, level *Fibonacci*, indikator RSI, dan garis EMA memberikan gambaran yang komprehensif tentang pergerakan harga BTC/USDT dalam jangka pendek. Jika harga mampu menembus resistance di 95.371,97 dengan candle *bullish* yang kuat, tren naik kemungkinan akan berlanjut. Namun, jika terjadi pola reversal bearish, harga berpotensi kembali turun ke level support di sekitar 94.906,30.



Gambar 4.40. *Forecasting* TCN pada Bitcoin/USDT.

Gambar 4.40 menunjukkan bahwa algoritma *Temporal Convolutional Network* (TCN) mampu mengikuti tren harga aktual dengan baik, meskipun terdapat deviasi

pada data uji. Garis biru solid merepresentasikan harga aktual, sementara garis magenta putus-putus menunjukkan hasil prediksi pada data pelatihan, dan garis merah putus-putus menggambarkan prediksi pada data pengujian. Garis hijau putus-putus menunjukkan prediksi selama 14 hari ke depan. Berdasarkan evaluasi performa, TCN menghasilkan *Training Mean Absolute Error* (MAE) sebesar 708.68 dan *Mean Squared Error* (MSE) sebesar 1,313,675.54, yang menunjukkan prediksi yang cukup baik pada data pelatihan. Pada data pengujian, model menghasilkan Test MAE sebesar 1,331.29 dan Test MSE sebesar 3,434,374.62, yang menunjukkan bahwa deviasi pada fase validasi lebih rendah dibandingkan percobaan sebelumnya. Prediksi masa depan menunjukkan nilai 98,334.4, 98,450.35, 98,553.61, 98,636.945, dan 98,726.27 yang memperlihatkan bahwa model mampu menangkap pola stabil pada akhir periode data. Secara keseluruhan, performa model TCN pada percobaan ini menunjukkan peningkatan akurasi dalam memprediksi tren harga *cryptocurrency*.

BAB 5. KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil dari pembahasan dapat diperoleh kesimpulan sebagai berikut.

- a. Analisis fundamental memberikan kontribusi signifikan dalam memahami dinamika pasar *cryptocurrency*. Faktor-faktor seperti dominasi Bitcoin, aktivitas jaringan, volume transaksi, dan sentimen pasar terbukti menjadi indikator penting yang memengaruhi volatilitas aset digital. Dominasi Bitcoin, yang dikenal dengan istilah *Bitcoin Effect*, memiliki pengaruh besar terhadap pergerakan harga altcoin utama seperti Ethereum dan Solana, menciptakan hubungan korelasi yang erat di antara aset-aset tersebut. Selain itu, data fundamental seperti jumlah transaksi harian, jumlah alamat aktif, dan biaya transaksi rata-rata memberikan gambaran tentang kesehatan dan potensi pertumbuhan suatu *cryptocurrency*.
- b. Analisis *technical* pada volatilitas *cryptocurrency* dilakukan dengan menggunakan berbagai indikator seperti *Candlestick Patterns*, *Support-Resistance Lines*, *Moving Averages*, dan *Relative Strength Index (RSI)*. Pola *candlestick* memberikan gambaran dinamika pasar untuk mengidentifikasi potensi perubahan tren, baik bullish maupun bearish. Indikator *Moving Average*, baik *simple Moving Average (SMA)* maupun *Exponential Moving Average (EMA)*, membantu menentukan tren harga berdasarkan pergerakan rata-rata dalam periode tertentu. Perhitungan EMA untuk periode jangka pendek (9), menengah (21), dan panjang (100) menunjukkan arah tren yang konsisten. Data dari indikator ini dapat digunakan untuk mengidentifikasi titik potensial untuk masuk atau keluar dari pasar berdasarkan volatilitas harga. Selanjutnya, indikator RSI berfungsi untuk mengukur momentum harga, membantu mengidentifikasi kondisi *overbought* (tekanan beli berlebih) atau *oversold*

(tekanan jual berlebih).

- c. Berdasarkan analisis dengan *Temporal Convolutional Network* (TCN), algoritma ini menunjukkan performa yang baik dalam memprediksi harga *cryptocurrency*, dengan nilai MAE sebesar 733,94 dan MSE sebesar 1,340,144,46 pada data latih, serta MAE 1,344,52 dan MSE 3,498,533,78 pada data uji. Prediksi lima langkah ke depan menunjukkan tren kenaikan harga dari 93,946,95 hingga 94,900,31, yang mencerminkan kemampuan algoritma dalam menangkap pola data historis dan memberikan gambaran potensi pergerakan harga di masa depan. Perbandingan antara TCN, LSTM, dan GRU menunjukkan bahwa TCN memiliki MSE dan MAE paling rendah. Secara keseluruhan, TCN terbukti efektif dalam analisis volatilitas *cryptocurrency*, seperti pengambilan keputusan beli atau jual.

5.2 Saran

Berdasarkan hasil penelitian ini, beberapa saran dapat diajukan untuk penelitian selanjutnya. Pertama, perlu dilakukan perluasan cakupan data dengan melibatkan variabel makroekonomi, kebijakan regulasi, atau kejadian tak terduga guna meningkatkan pemahaman terhadap volatilitas *cryptocurrency*. Selanjutnya, penggunaan indikator teknikal tambahan seperti *Bollinger Bands* atau MACD dapat memberikan wawasan yang lebih komprehensif dalam memprediksi pergerakan harga. TCN menunjukkan potensi *overfitting* pada data uji, sehingga disarankan untuk menerapkan teknik regularisasi seperti *dropout* atau *early stopping* serta penggunaan lebih banyak data guna meningkatkan generalisasi model. Selain itu, penelitian mendatang sebaiknya mempertimbangkan analisis sentimen media sosial, karena faktor ini dapat mempengaruhi volatilitas harga *cryptocurrency*.

DAFTAR PUSTAKA

- Akgul, A., Sahin, E. E., & Senol, F. Y. (2022). *Blockchain-based cryptocurrency price prediction with chaos theory, on-chain analysis, sentiment analysis, and fundamental-technical analysis*. *Chaos Theory and Applications*, 4(3), 157–168. <https://doi.org/10.51537/chaos.1199241>
- Awalin, Q. I., Agustin, I. H., Hadi, A. F., Dafik, & Sunder, R. (2024). *Optimizing data classification in support vector machines using metaheuristic algorithms*. *CAUCHY: Jurnal Matematika Murni dan Aplikasi*, 9(2), 320-328. <https://doi.org/10.18860/ca.v9i2.29320>
- Baur, D. G., & Dimpfl, T. (2018). *Asymmetric volatility in cryptocurrencies*. *Economics Letters*, 173, 148-151. <https://doi.org/10.1016/j.econlet.2018.10.008>
- Benetton, M., & Compiani, G. (2024). *Investors' beliefs and cryptocurrency prices*. *The Review of Asset Pricing Studies*. <https://doi.org/10.1093/rapstu/raad015>
- Bitcoin.com. (2024). *Berita terkini seputar Bitcoin dan cryptocurrency*. Bitcoin.com. <https://news.bitcoin.com/>
- Blockchain.com. (2024). *Informasi tentang blockchain dan cryptocurrency*. Blockchain.com.
- Bouteska, A., Abedin, M. Z., Hajek, P., & Yuan, K. (2024). *Cryptocurrency price forecasting – A comparative analysis of ensemble learning and deep learning methods*. *International Review of Financial Analysis*, 92, 103055. <https://doi.org/10.1016/j.irfa.2023.103055>
- Chen, J., Cui, Y., Zhang, X., Yang, J., & Zhou, M. (2024). *Temporal Convolutional Network for Carbon Tax Projection: A Data-Driven Approach*. *Applied Sciences*, 14(20), 9213. <https://doi.org/10.3390/app14209213>
- Chen, Y., Kang, Y., Chen, Y., & Wang, Z. (2020). *Probabilistic Forecasting with Temporal Convolutional Neural Network*. *Neurocomputing*. <https://doi.org/10.1016/j.neucom.2020.03.011>
- Dai, W., An, Y., & Long, W. (2022). *Price change prediction of ultra-high frequency financial data based on temporal convolutional network*. *Procedia Computer Science*, 199, 1177–1183. <https://doi.org/10.1016/j.procs.2022.01.149>
- Dharma, B., Gusniati, P., & Wardani, T. (2023). *Analisis Pemanfaatan*

- Cryptocurrency Bitcoin sebagai Alat Alternatif Investasi.* Jurnal Publikasi Sistem Informasi dan Manajemen Bisnis (JUPSIM), 2(1), 175-182. <https://dx.doi.org/10.55606/jupsim.v2i1.858>
- Dudek, G., Fiszeder, P., Kobus, P., & Orzeszko, W. (2024). *Forecasting cryptocurrencies volatility using statistical and machine learning methods: A comparative study.* Applied Soft Computing. <https://doi.org/10.1016/j.asoc.2023.111132>
- Fang, F., Chung, W., Ventre, C., Basios, M., Kanthan, L., Li, L., & Wu, F. (2024). *Ascertaining price formation in cryptocurrency markets with machine learning.* The European Journal of Finance, 30(1), 78-100. <https://doi.org/10.1080/1351847X.2021.1908390>
- Gopali, S., Abri, F., Siami-Namini, S., & Siami Namin, A. (2021). *A Comparative Study of Detecting Anomalies in Time Series Data Using LSTM and TCN Models.* IEEE BigData 2021. <https://doi.org/10.48550/arXiv.2112.09293>
- Gu, Z., Lin, D., & Wu, J. (2022). *On-chain analysis-based detection of abnormal transaction amount on cryptocurrency exchanges.* Physica A: Statistical Mechanics and its Applications, 604, 127799
- Jagannath, N., Barbulescu, T., Sallam, K. M., Elgendi, I., & McGrath, B. (2021). *An on-chain analysis-based approach to predict ethereum prices.* IEEE Access, 9, 167972-167989. <https://doi.org/10.1016/j.physa.2022.127799>
- Judijanto, L., Utami, E. Y., Devi, E. K., Sarmiati, & Sudarmanto, E. (2024). *Analisis Dampak Investasi Cryptocurrency dan Volatilitas Pasar terhadap Profitabilitas Perusahaan Energi di Indonesia.* Sanskara Akuntansi dan Keuangan, 2(02), 90-99. <https://doi.org/10.58812/sak.v2i02>
- Kumila, A., Sholihah, B., Evizia, Safitri, N., & Fitri, S. (2019). *Perbandingan metode moving average dan metode naïve dalam peramalan data kemiskinan.* Jurnal Teori dan Aplikasi Matematika (JTAM), 3(1), 65-73. <https://doi.org/10.31764/jtam.v3i1.764>
- Kuncara, T., & Anugrah, K. P. (2023). *Analisis volatilitas cryptocurrency pada sebelum pandemi dan pada saat pandemi COVID-19 dengan metode return pada Bitcoin dan Ethereum.* Keunis, 11(1), 86-94. <http://dx.doi.org/10.32497/keunis.v11i1.3981>
- Mighri, Z., & Alsaggaf, M. I. (2019). *Volatility spillovers among the cryptocurrency*

- time series*. International Journal of Economics and Financial Issues, 9(3), 81-90.
<https://doi.org/10.32479/ijefi.7383>
- Nickolaevich, L. I., Igorevna, G. I., & Grigorievich, R. D. (2020). *Generating a multi-timeframe trading strategy based on three exponential moving averages and a stochastic oscillator*. International Journal of Technology, 11(6), 1233-1243.
- Olabanji, S. O., Oladoyinbo, T. O., Asonze, C. U., Adigwe, C. S., Okunleye, O. J., & Olaniyi, O. O. (2024). *Leveraging FinTech compliance to mitigate cryptocurrency volatility for secure US employee retirement benefits: Bitcoin ETF case study*. Available at SSRN 4739190.
<http://dx.doi.org/10.9734/ajebe/2024/v24i41270>.
- Person, J. L. (2004). *A complete guide to technical trading tactics: How to profit using pivot points, candlesticks & other indicators*. New Jersey : John Wiley & Sons.
- Shaikh, A. K., Nazir, A., Khalique, N., & Shah, A. S. (2023). *A new approach to seasonal energy consumption forecasting using temporal convolutional networks*. Results in Engineering, 19, 101296.
<https://doi.org/10.1016/j.rineng.2023.101296>
- Siami-Namini, S., Tavakoli, N., & Siami Namin, A. (2018). *A Comparison of ARIMA and LSTM in Forecasting Time Series*. In 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA) (pp. 1394–1401).
<https://doi.org/10.1109/ICMLA.2018.00227>
- Toms, M. C. (2011). *The technical analysis method of moving average trading: Rules that reduce the number of losing trades*. Doctoral dissertation, Newcastle University
- TradingView. (2024). *TradingView: Platform analisis pasar*. TradingView.
<https://www.tradingview.com/>
- Wiharno, H., Lesmana, A. S., Maulana, Y., & Komarudin, M. N. (2023). *Stock portfolio optimization in bullish and bearish conditions using the Black-Litterman model*. Jurnal Manajemen dan Kewirausahaan, 25(2), 92-104.
<https://doi.org/10.9744/jmk.25.2.92-104>
- Yıldırım, E. O., Uçar, M., & Özbayoğlu, A. M. (2019). *Evolutionary optimized stock support-resistance line detection for algorithmic trading systems*. UBMYK: International Conference on Business and Management, 34(2), 92–104.

<https://doi.org/10.1109/UBMYK48245.2019.8965471>

Zohuri, B., Nguyen, H. T., & Moghaddam, M. (2022). *What is the cryptocurrency? Is it a threat to our national security, domestically and globally?*. International Journal of Theoretical & Computational Physics, 3(1), 1-14.
<https://doi.org/10.47485/2767-3901.1020>

LAMPIRAN

Algoritma Temporal Convolutional Network

```
1 import numpy as np
2 import pandas as pd
3 from sklearn.preprocessing import MinMaxScaler
4 from sklearn.metrics import mean_absolute_error,
   ↪ mean_squared_error
5 from tensorflow.keras.models import Sequential
6 from tensorflow.keras.layers import Dense
7 from tcn import TCN
8 from tensorflow.keras.callbacks import EarlyStopping
9 from tensorflow.keras.optimizers import RMSprop
10 import plotly.graph_objs as go
11 from plotly.subplots import make_subplots
12 import plotly.io as pio
13
14 # Atur renderer Plotly sesuai dengan lingkungan Anda
15 # Jika Anda menggunakan Jupyter Notebook atau JupyterLab,
   ↪ uncomment salah satu di bawah ini:
16 # pio.renderers.default = 'notebook' # Untuk Jupyter Notebook
17 # pio.renderers.default = 'jupyterlab' # Untuk JupyterLab
18
19 # Jika Anda menjalankan skrip ini sebagai script Python biasa,
   ↪ gunakan renderer 'browser'
20 pio.renderers.default = 'browser'
21
22 # Load dataset
23 df = pd.read_csv('btc112.csv')
24
25 # Periksa data yang dimuat
26 print("Dataframe sebelum dibalik:")
27 print(df.head())
```

```

28
29
30 # Convert 'Date' column to datetime format and handle errors
   ↳ if any
31 df['Date'] = pd.to_datetime(df['Date'], errors='coerce') #
   ↳ 'coerce' mengubah entri tanggal yang tidak valid menjadi
   ↳ NaT
32
33 # Drop any rows with NaT (invalid dates)
34 df.dropna(subset=['Date'], inplace=True)
35
36 # Set 'Date' as the index for time series
37 df.set_index('Date', inplace=True)
38
39 # Periksa data setelah preprocessing tanggal
40 print("\nDataframe setelah preprocessing tanggal:")
41 print(df.head())
42
43 # Fungsi untuk membersihkan kolom (menghapus koma jika ada dan
   ↳ mengubah tipe data menjadi float)
44 def clean_column(column):
45     # Cek apakah kolom bertipe string (dengan koma)
46     if column.dtype == 'object':
47         return column.str.replace(',', '',
   ↳ regex=False).astype(float)
48     else:
49         return column # Jika sudah numerik, dikembalikan apa
   ↳ adanya
50
51 # Bersihkan kolom yang mungkin mengandung koma
52 df['Open'] = clean_column(df['Open'])
53 df['High'] = clean_column(df['High'])
54 df['Low'] = clean_column(df['Low'])
55 df['Close'] = clean_column(df['Close'])
56

```

```

57 # Periksa data setelah membersihkan kolom
58 print("\nDataframe setelah membersihkan kolom:")
59 print(df.head())
60
61 # Gunakan 'Open' sebagai fitur untuk prediksi
62 closedf = df[['Close']]
63
64 # Normalisasi data
65 scaler = MinMaxScaler(feature_range=(0, 1))
66 closedf_scaled = scaler.fit_transform(closedf)
67
68 # Siapkan dataset untuk pelatihan
69 time_step = 14 # Window waktu untuk setiap urutan input
70 X, y = [], []
71 for i in range(len(closedf_scaled) - time_step):
72     X.append(closedf_scaled[i:i + time_step, 0])
73     y.append(closedf_scaled[i + time_step, 0])
74
75 X, y = np.array(X), np.array(y)
76 X = np.reshape(X, (X.shape[0], X.shape[1], 1)) # Reshape
    ↪ untuk TCN (samples, time steps, features)
77
78 # Periksa bentuk data
79 print(f"\nBentuk X: {X.shape}")
80 print(f"Bentuk y: {y.shape}")
81
82 # Split data menjadi train dan test set
83 train_size = int(len(X) * 0.7) # 80% untuk pelatihan
84 X_train, X_test = X[:train_size], X[train_size:]
85 y_train, y_test = y[:train_size], y[train_size:]
86
87 print(f"\nTrain size: {train_size}")
88 print(f"X_train shape: {X_train.shape}")
89 print(f"X_test shape: {X_test.shape}")
90

```

```
91 # Definisikan Model TCN
92 model = Sequential([
93     TCN(input_shape=(time_step, 1), nb_filters=64,
94         ↪ kernel_size=3, dilations=[1, 2, 4, 8],
95         dropout_rate=0.1, return_sequences=False), # Layer
96         ↪ TCN
97     Dense(50, activation='relu'), # Layer Dense untuk
98         ↪ pemrosesan lebih lanjut
99     Dense(1) # Layer output untuk regresi
100 ])
101
102 model.compile(optimizer=RMSprop(learning_rate=0.001),
103             ↪ loss='mse')
104
105 # Tambahkan Early Stopping untuk mencegah overfitting
106 early_stop = EarlyStopping(monitor='val_loss', patience=50,
107                             ↪ restore_best_weights=True)
108
109 # Train model
110 history = model.fit(
111     X_train, y_train,
112     epochs=300,
113     batch_size=16,
114     verbose=1,
115     validation_data=(X_test, y_test),
116     callbacks=[early_stop]
117 )
118
119 # Buat prediksi pada data pelatihan dan pengujian
120 predictions_train = model.predict(X_train)
121 predictions_test = model.predict(X_test)
122
123 # Inverse transform prediksi ke skala asli
124 predictions_train_inv =
125     ↪ scaler.inverse_transform(predictions_train)
```

```

120 original_train = scaler.inverse_transform(y_train.reshape(-1,
    ↪ 1))
121
122 predictions_test_inv =
    ↪ scaler.inverse_transform(predictions_test)
123 original_test = scaler.inverse_transform(y_test.reshape(-1,
    ↪ 1))
124
125 # Hitung MAE dan MSE
126 mae_train = mean_absolute_error(original_train,
    ↪ predictions_train_inv)
127 mse_train = mean_squared_error(original_train,
    ↪ predictions_train_inv)
128 mae_test = mean_absolute_error(original_test,
    ↪ predictions_test_inv)
129 mse_test = mean_squared_error(original_test,
    ↪ predictions_test_inv)
130
131 print(f"\nTraining Mean Absolute Error (MAE): {mae_train}")
132 print(f"Training Mean Squared Error (MSE): {mse_train}")
133 print(f"Test Mean Absolute Error (MAE): {mae_test}")
134 print(f"Test Mean Squared Error (MSE): {mse_test}")
135 # Forecasting beberapa langkah ke depan setelah data aktual
136 forecast_horizon = 30 # Jumlah langkah untuk diprediksi
137 last_sequence = X[-1] # Mulai dengan urutan terakhir dari
    ↪ data pelatihan
138 future_predictions = []
139
140 # Generate tanggal masa depan berdasarkan tanggal terakhir di
    ↪ dataset
141 future_dates = pd.date_range(df.index[-1],
    ↪ periods=forecast_horizon + 1, freq='D')[1:] # Lewati
    ↪ tanggal pertama (tanggal aktual terakhir)
142
143 # Buat prediksi masa depan

```

```

144 for _ in range(forecast_horizon):
145     next_pred = model.predict(last_sequence.reshape(1,
        ↪ time_step, 1))[0, 0]
146     future_predictions.append(next_pred)
147     # Update last_sequence dengan prediksi baru
148     last_sequence = np.append(last_sequence[1:],
        ↪ [[next_pred]], axis=0)
149
150 # Inverse transform prediksi masa depan ke skala asli
151 future_predictions_inv =
        ↪ scaler.inverse_transform(np.array(future_predictions).reshape(-1,
        ↪ 1))
152
153 # Periksa apakah prediksi masa depan sudah dibuat
154 print(f"\nFuture Predictions (first 5):
        ↪ {future_predictions_inv[:5].flatten()}")
155
156 # Membuat Plot Interaktif dengan Plotly menggunakan template
        ↪ yang lebih terang
157 fig = make_subplots(rows=1, cols=1)
158
159 #Tambahkan anotasi ke grafik
160 annotations = [
161     dict(
162         x=0.5,
163         y=1.15,
164         xref='paper',
165         yref='paper',
166         showarrow=False,
167         text=(
168             f"<b>Training MAE:</b> {mae_train:.2f} | "
169             f"<b>Training MSE:</b> {mse_train:.2f} <br>"
170             f"<b>Test MAE:</b> {mae_test:.2f} | "
171             f"<b>Test MSE:</b> {mse_test:.2f}"
172         ),

```

```
173         font=dict(size=12, color="black"),
174         align="center"
175     )
176 ]
177
178 # Update layout dengan anotasi
179 fig.update_layout(annotations=annotations)
180
181 # Menambahkan Harga Aktual
182 fig.add_trace(
183     go.Scatter(
184         x=df.index[time_step:],
185
186         ↪ y=scaler.inverse_transform(closedf_scaled[time_step:]).flatten()
187         mode='lines',
188         name='Actual Prices',
189         line=dict(color='blue')
190     )
191 )
192 # Menambahkan Prediksi Pelatihan
193 fig.add_trace(
194     go.Scatter(
195         x=df.index[time_step:time_step +
196         ↪ len(predictions_train_inv)],
197         y=predictions_train_inv.flatten(),
198         mode='lines',
199         name='Predicted Prices (Train)',
200         line=dict(color='yellow', dash='dash')
201     )
202 )
203 # Menambahkan Prediksi Pengujian
204 fig.add_trace(
205     go.Scatter(
```

```

206         x=df.index[time_step + train_size:time_step +
207             ↪ train_size + len(predictions_test_inv)],
208         y=predictions_test_inv.flatten(),
209         mode='lines',
210         name='Predicted Prices (Test)',
211         line=dict(color='red', dash='dash')
212     )
213 )
214 # Menambahkan Prediksi Masa Depan
215 fig.add_trace(
216     go.Scatter(
217         x=future_dates,
218         y=future_predictions_inv.flatten(),
219         mode='lines',
220         name='Future Predictions',
221         line=dict(color='green', dash='dash')
222     )
223 )
224
225 # Mengatur Layout dengan template yang lebih terang
226 fig.update_layout(
227     title='Forecasting BTC dengan TCN',
228     xaxis_title='Tanggal',
229     yaxis_title='Harga Penutupan USD ($)',
230     legend=dict(x=0.01, y=0.99),
231     template='plotly_white', # Ganti template menjadi
232     ↪ 'plotly_white'
233     hovermode='x unified'
234 )
235
236
237 # Simpan plot sebagai file HTML untuk memastikan plot dibuat
238 fig.write_html("forecasting_plot.html")

```

```
239 print("\nPlot disimpan sebagai 'forecasting_plot.html'.  
    ↪ Silakan buka file tersebut di browser Anda.")  
240  
241 # Menampilkan Plot  
242 fig.show()  
243  
244 # Debugging prints  
245 print("\nOriginal train y shape:", original_train.shape)  
246 print("Train predictions shape:", predictions_train_inv.shape)  
247 print("Original test y shape:", original_test.shape)  
248 print("Test predictions shape:", predictions_test_inv.shape)  
249 print("Original train y data (first 10):",  
    ↪ original_train[:10].flatten())  
250 print("Train predictions data (first 10):",  
    ↪ predictions_train_inv[:10].flatten())  
251 print("Original test y data (first 10):",  
    ↪ original_test[:10].flatten())  
252 print("Test predictions data (first 10):",  
    ↪ predictions_test_inv[:10].flatten())
```