

Prediksi Harga Mata Uang Kripto Menggunakan Algoritma *Temporal Convolutional Network*

Aris Munandar¹, Ghuftron²

Teknik Informatika, Universitas Islam Sultan Agung^{1,2}
aris.munandar1802@gmail.com¹, ghuftron@unissula.ac.id²

ABSTRAK

Cryptocurrency merupakan mata uang digital yang kini menjadi salah satu alternatif investasi dengan pertumbuhan yang sangat pesat. Salah satu tantangan utama dalam investasi cryptocurrency adalah volatilitas harga yang tinggi, sehingga memerlukan pendekatan analitik yang akurat untuk meminimalkan risiko. Ethereum, sebagai salah satu aset kripto paling populer, sering menjadi objek penelitian dalam prediksi harga karena fluktuasinya yang signifikan. Berbagai metode telah digunakan untuk memprediksi harga Cryptocurrency, salah satunya adalah Temporal Convolutional Network (TCN). Penelitian ini bertujuan untuk memprediksi harga penutupan harian Ethereum menggunakan algoritma Temporal Convolutional Network (TCN). Data historis diambil dari tahun 2018 hingga 2024 dan melalui proses pra-pemrosesan, pelatihan model, denormalisasi, serta evaluasi menggunakan metrik RMSE dan MAPE. Hasil menunjukkan bahwa konfigurasi terbaik diperoleh pada batch size 16 dan epoch 50, dengan nilai RMSE sebesar 91,45 dan MAPE sebesar 2,38%.

Kata-kata kunci : Prediksi *Cryptocurrency*, Ethereum, TCN.

A. Pendahuluan

Kemajuan teknologi informasi telah menyebabkan dampak yang cukup berpengaruh terhadap beberapa aspek kehidupan, termasuk sektor keuangan (Aysa, 2021). Salah satu inovasi besar dalam dunia keuangan modern adalah kemunculan mata uang kripto, yang berfungsi sebagai alternatif investasi selain instrumen keuangan tradisional (Wasiman & Saparudin, 2022). Berdasarkan data dari Badan Pengawas Perdagangan Berjangka Komoditi (Bappebti), transaksi aset kripto di Indonesia mencapai lebih dari Rp475 triliun pada tahun 2024, nilai tersebut meningkat sebanyak tiga kali lipat dibandingkan tahun sebelumnya. Hal tersebut membuktikan bahwa pasar kripto di Indonesia memiliki potensi yang cukup besar (Zaki dkk., 2025). Salah satu mata uang kripto yang cukup populer adalah Ethereum. Meskipun menjadi salah satu aset kripto yang paling diminati oleh investor, Ethereum masih menunjukkan tingkat volatilitas harga yang tinggi (Andromeda & Winarsih, 2025). Ketidakstabilan ini menjadi tantangan tersendiri dalam pengambilan keputusan investasi. Oleh karena itu, dibutuhkan suatu pendekatan prediktif yang mampu mengidentifikasi pola dari data historis secara akurat, guna mendukung pengambilan keputusan investasi yang lebih informatif.

Penelitian sebelumnya dilakukan untuk mengetahui perbandingan model TCN dengan model hybrid CNN-LSTM. Hasilnya TCN menghasilkan RMSE sebesar 15,26, MAE sebesar 10,05, dan R2 sebesar 0,9954. Sedangkan hybrid CNN-LSTM yang menghasilkan RMSE 23,53, MAE 15,40 dan R2 sebesar 0,9892. Hal ini menunjukkan bahwa model TCN mampu melakukan prediksi dengan baik (Fajou & McCarren, 2021). Penelitian selanjutnya mengetahui performa dari model Support Vector Regression dalam memprediksi harga Solana. Hasilnya menunjukkan nilai MAPE 9,93 dan akurasi model sebesar 97,44% (Atmaja & Hakim, 2022). Penelitian lainnya membandingkan model TCN, Transformers dan RNN untuk prediksi kenaikan permukaan air di Pesisir Surabaya. Hasilnya menunjukkan bahwa TCN secara konsisten memberikan kinerja yang lebih baik dibandingkan model lainnya pada semua interval perkiraan dengan R2 nilai 0,9950 dan nilai RMSE 0,0487 (Saepudin dkk., 2024). Penelitian yang lain tentang prediksi harga Ethereum menggunakan algoritma Long Short-Term Memory. Hasilnya menunjukkan bahwa model menghasilkan nilai yang optimal dengan nilai rata-rata MSE sebesar 0,018 pada 10 kali percobaan terbaik (Bastian Sianturi dkk., 2023).

Berdasarkan permasalahan yang telah diuraikan pada hasil penelitian sebelumnya, penulis tertarik untuk melakukan prediksi harga *cryptocurrency* khususnya Ethereum menggunakan TCN. Penelitian ini diharapkan mampu menghasilkan model dengan tingkat akurasi yang tinggi dalam memprediksi harga Ethereum.

B. Landasan Teori

1. Cryptocurrency

Cryptocurrency merupakan mata uang digital yang diciptakan dari rangkaian *code* atau biasa disebut *blockchain* (Rizkilloh & Widiyanesti, 2022). Mata uang kripto memiliki kelebihan dibandingkan mata uang konvensional, yaitu lebih fleksibel, transparan, cepat, dan biaya transaksi yang rendah (Baharani dkk., 2024). *Cryptocurrency* dapat menjadi salah satu alternatif dalam berinvestasi. Investasi dalam bentuk uang *virtual* khususnya kripto dapat membantu masyarakat dalam mempersiapkan finansial untuk masa yang akan datang (Atmaja & Hakim, 2022).

2. Ethereum


Ethereum merupakan salah satu jenis mata uang kripto yang cukup populer. Ethereum juga disebut *platform blockchain* terdesentralisasi berbasis *smart contract* yang berfungsi untuk mewujudkan layanan pertukaran secara *online* (Goa Mere, 2023). Ethereum memungkinkan pengguna untuk melakukan transaksi melalui jaringan internet tanpa perlu menggunakan kartu kredit atau melibatkan bank sentral, sehingga prosesnya menjadi lebih mudah dan efisien (Bastian Sianturi dkk., 2023).

3. Deep Learning

Deep Learning atau pembelajaran mendalam merupakan bidang turunan dari *machine learning* yang memanfaatkan jaringan syaraf tiruan, menggunakan lebih dari satu lapisan tersembunyi (*hidden layer*) dalam proses pemodelannya. Konsep dari *deep learning* adalah menambahkan banyak lapisan pada model sehingga proses belajar menjadi lebih kompleks dan mendalam (Nurhakiki & Yahfizham, 2024). Hal yang membedakan *deep learning* dengan *machine learning* adalah data yang digunakan merupakan data yang lebih banyak. Dengan begitu diperlukan pula proses komputasi yang membutuhkan spesifikasi hardware yang mumpuni, biasanya digunakan *Graphics Processing Unit* (GPU) (Digo Saputra & Hatta Fudholi, 2023). Sebuah arsitektur jaringan dapat disebut sebagai *deep learning* apabila terdiri atas lebih dari tiga lapisan, termasuk lapisan *input* dan *output*.

4. Temporal Convolutional Network

Temporal Convolutional Network (TCN) merupakan algoritma yang dibuat untuk menangani permasalahan pada data sekuensial atau deret waktu dengan memanfaatkan konvolusi satu dimensi (*1D convolution*) secara mendalam. Algoritma tersebut sering digunakan dalam tugas segmentasi tindakan dan prediksi deret waktu (Aisyah dkk., 2024). TCN menggunakan pendekatan konvolusional yang memungkinkan pemrosesan data secara paralel dan efisien. Struktur TCN menggabungkan beberapa komponen penting seperti *causal convolutions*, *dilated convolutions* dan *residual connections*, yang meningkatkan efektivitasnya (Saepudin dkk., 2024).



Gambar 1. Struktur TCN

Gambar 1 menunjukkan arsitektur model *Temporal Convolutional Network* (TCN) yang dirancang untuk memproses data deret waktu secara efisien. Model ini menggunakan *causal convolution* untuk memastikan bahwa prediksi pada suatu waktu hanya dipengaruhi oleh data dari masa lalu, bukan masa depan. Setiap *residual block* terdiri dari dua lapisan *dilated causal convolution* yang kemudian diproses melalui tahapan normalisasi bobot (*weight normalization*), aktivasi ReLU, dan *dropout*, lalu dijumlahkan kembali dengan input aslinya untuk menjaga kestabilan pembelajaran.

Proses *dilated causal convolution* dirumuskan secara matematis sebagai berikut:

$$F(s) = (x_d f) = \sum_{i=0}^s f(i) \cdot x_{s-d.i} \quad (1)$$

Keterangan:


$F(s)$: Hasil konvolusi pada waktu s
 x : Urutan input
 f : filter konvolusi
 $x_{s-d.i}$: nilai input pada waktu lampau
 $*_d$: operasi konvolusi dengan dilasi

Dilasi digunakan untuk memperluas jangkauan pemrosesan data historis tanpa menambah beban komputasi. Dengan menumpuk beberapa *residual block* yang masing-masing memiliki faktor dilasi berbeda, model ini mampu menangkap pola jangka panjang dalam data deret waktu secara efektif. Untuk memastikan bahwa panjang output tetap sama dengan input dan tetap menjaga kausalitas, maka dilakukan penambahan *padding nol (zero-padding)* pada proses *dilated causal convolution*. Untuk menghitung jumlah *padding* digunakan rumus (2) yaitu ukuran kernel dikurangi satu:

$$P = k - 1 \quad (2)$$

C. Metode Penelitian

Pada penelitian ini, menggunakan algoritma *Temporal Convolution Network* untuk proses memprediksi harga kripto *ethereum*. Penelitian ini memerlukan beberapa langkah yang harus dilakukan sebagai berikut. Berikut merupakan tahapan yang akan dilakukan pada penelitian ini yang dapat ditemukan pada gambar 2.



Gambar 2. Tahapan Proses Penelitian

1. Pengumpulan data

Pada penelitian ini menggunakan data harga penutupan harian Ethereum dalam USD yang diambil dari situs *website* Kaggle.com dengan judul "*Ethereum Historical Data 2018-2024*" Data tersebut diunggah oleh Heidar Mirhaji Sadati pada 2024.

2. Pra-pemrosesan data

Tahapan pra-pemrosesan data yang diterapkan dalam penelitian ini mencakup beberapa langkah, antara lain pembersihan data untuk mengatasi nilai yang hilang atau tidak lengkap, serta proses normalisasi guna menyetarakan skala data. Normalisasi dilakukan dengan mengubah nilai harga penutupan Ethereum ke dalam rentang antara 0 hingga 1 menggunakan metode *min-max normalization* (Richia Putri dkk., 2023). Setelah proses pra-pemrosesan selesai, dataset kemudian dibagi menjadi dua bagian, yaitu data pelatihan (*training*) sebesar 80% dan data pengujian (*testing*) sebesar 20%.

3. Pelatihan Model

Setelah tahap pra-pemrosesan data selesai dilakukan, selanjutnya dilakukan pembuatan model *Temporal Convolution Network* untuk mengetahui hasil prediksi harga Ethereum.

4. Denormalisasi

Langkah selanjutnya adalah denormalisasi ini bertujuan untuk mengonversi kembali hasil prediksi yang sebelumnya telah dinormalisasi ke dalam skala nilai asli harga Ethereum.

5. Evaluasi model

Evaluasi model dilakukan untuk menilai tingkat akurasi dari model yang telah dibangun. Pada penelitian ini, proses evaluasi menggunakan dua indikator utama, yaitu *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE) sebagai ukuran kinerja prediksi.

RMSE evaluasi model yang mengukur seberapa besar kesalahan model prediksi dibandingkan dengan data aslinya. Nilainya dihitung dengan mencari selisih antara nilai yang diprediksi dan nilai sebenarnya, kemudian dikuadratkan, dirata-rata, dan diambil akar kuadratnya. Semakin kecil nilai RMSE, berarti hasil prediksi model semakin mendekati data yang sebenarnya (Julkarnaen dkk., 2024). Berikut persamaan untuk menghitung RMSE:

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

MAPE menggambarkan rata-rata selisih antara nilai aktual dan hasil prediksi dalam bentuk persentase, sehingga memudahkan dalam interpretasi serta perbandingan tingkat akurasi model (Pratiwi & Nurjanah, 2025). Berikut persamaan untuk menghitung MAPE :

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \times 100\% \quad (4)$$

Berikut skala nilai akurasi prediksi berdasarkan nilai MAPE yang dapat dilihat pada tabel 1

Tabel 1. Skala nilai akurasi MAPE

Skala MAPE	Interpretasi
<10%	Hasil prediksi sangat tepat
10-20%	Hasil prediksi tepat
20-25%	Hasil prediksi cukup
>50%	Hasil prediksi tidak akurat

D. Hasil Dan Pembahasan

Setelah model TCN berhasil dibuat, langkah selanjutnya adalah menguji hasil prediksi terhadap data uji yang sudah disiapkan sebelumnya. Sebelum proses pengujian dilakukan, berbagai kombinasi parameter dicoba untuk mengetahui performa terbaik dari model, seperti penggunaan optimizer, ukuran batch, dan jumlah epoch. Parameter yang dianggap paling optimal dipilih berdasarkan nilai RMSE dan MAPE yang paling rendah. Dalam proses ini, pengujian model difokuskan pada variasi jumlah epoch untuk melihat pengaruhnya terhadap hasil prediksi. Adapun jumlah epoch yang digunakan dalam pengujian adalah 30, 50, dan 100, dengan ukuran batch yang divariasikan antara 16 dan 32.

Tabel 2. Hasil Evaluasi Model


Perbandingan evaluasi model TCN

Optimizer	Bastch size	Epoch	RMSE	MAPE
Adam	16	30	171,99	5,82%
Adam	16	50	91,45	2,38%
Adam	16	100	94,72	2,52%
Adam	32	30	146,86	3,87%
Adam	32	50	99,90	2,63%
Adam	32	100	105,09	2,74%

Berdasarkan hasil evaluasi model TCN pada Tabel 2, kombinasi parameter terbaik diperoleh pada penggunaan batch size 16 dan epoch 50, dengan nilai RMSE sebesar 91,45 dan MAPE sebesar 2,38%. Hasil ini menunjukkan bahwa konfigurasi tersebut mampu menghasilkan prediksi yang paling akurat dibandingkan kombinasi konfigurasi lainnya. Secara umum, batch size 16 menunjukkan performa yang lebih baik dibanding batch size 32, karena mampu menangkap pola data dengan lebih detail meskipun memerlukan waktu pelatihan yang lebih lama.

Selain itu, peningkatan jumlah epoch dari 30 ke 50 memberikan dampak signifikan terhadap penurunan nilai error, yang mengindikasikan proses pembelajaran model yang lebih optimal. Namun, penambahan epoch hingga 100 justru tidak memberikan peningkatan performa yang berarti dan cenderung menyebabkan overfitting ringan, ditandai dengan kenaikan nilai RMSE dan MAPE. Oleh karena itu, penggunaan batch size 16 dan epoch 50 menjadi kombinasi paling optimal untuk model TCN dalam memprediksi harga Ethereum pada pengujian ini.

Setiap data Ethereum yang diuji menghasilkan model terbaik dengan nilai RMSE dan MAPE terendah pada model TCN. Hasil prediksi dengan harga aktual untuk model TCN tersebut terdapat dalam bentuk grafik pada gambar 3.



Gambar 3. Grafik Prediksi Harga Ethereum

Pada gambar 3 menunjukkan hasil prediksi harga penutupan Ethereum menggunakan model TCN, yang divisualisasikan dalam satu grafik dengan tiga komponen utama meliputi garis biru menunjukkan data historis dari 2018 sampai 2024 yang digunakan untuk melatih model, sedangkan garis hijau adalah data asli yang digunakan untuk menguji seberapa baik model bekerja. Hasil prediksi ditampilkan dalam garis oranye, dan bisa dilihat bahwa garis ini cukup mengikuti pola dari data asli, terutama setelah garis putus-putus yang menandai batas antara data pelatihan dan pengujian. Ini menunjukkan bahwa model cukup mampu memahami pola pergerakan harga Ethereum dan memberikan prediksi yang mendekati kenyataan.

Berikut perbandingan hasil dari data aktual dengan data prediksi pada model TCN yang terdapat pada tabel 3.

Tabel 3. Hasil prediksi model TCN

Hasil prediksi model TCN		
Date	Actual Close Price	Predicted Close Price
23/5/2023	1854.48	1820.47
24/5/2023	1799.99	1859.22
25/5/2023	1806.04	1823.29
26/5/2023	1828.68	1823.13
26/5/2023	1830.98	1821.82
...	...	...
22/9/2024	2581.43	2694.2
23/9/2024	2647.17	2641.6
24/9/2024	2653.41	2658.69
25/9/2024	2579.69	2652.16
26/9/2024	2636.51	2653.22

Tabel 3 menunjukkan perbandingan antara harga penutupan Ethereum yang sebenarnya dengan hasil prediksi model Temporal Convolutional Network (TCN) dari tahun 2023 hingga 2024. Dari data tersebut, terlihat bahwa model TCN mampu menghasilkan prediksi yang mendekati nilai aktual. Secara keseluruhan, tabel ini menunjukkan bahwa model TCN cukup andal dalam menangkap arah pergerakan harga Ethereum. Analisis secara menyeluruh dari model TCN untuk memprediksi harga saham Bank Mandiri dengan nilai rata-rata RMSE dan MAPE ditunjukkan pada tabel 4.

Tabel 4 Nilai rata-rata evaluasi pada masing-masing model

Nilai rata-rata evaluasi model TCN		
Metode	RMSE	MAPE
TCN	91.45	2,38%

Berdasarkan nilai rata-rata evaluasi model yang disajikan pada Tabel 4, dapat disimpulkan bahwa metode *Temporal Convolutional Network* (TCN) memiliki performa yang cukup baik dalam melakukan prediksi harga penutupan aset kripto. Rata-rata nilai *Root Mean Square Error* (RMSE) yang diperoleh sebesar 91,45 menunjukkan bahwa selisih antara nilai prediksi dan nilai aktual relatif kecil, sehingga model mampu menghasilkan estimasi yang mendekati kondisi sebenarnya. Selain itu, nilai *Mean Absolute Percentage Error* (MAPE) sebesar 2,38% juga mengindikasikan bahwa tingkat kesalahan relatif model terhadap data aktual sangat rendah, yang memperkuat keandalan TCN dalam memodelkan pola historis dan tren harga.

E. Kesimpulan Dan Saran

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa model *Temporal Convolutional Network* (TCN) mampu memberikan performa yang baik dalam memprediksi harga penutupan Ethereum. Hal ini dibuktikan dengan nilai RMSE dan MAPE yang rendah. Model TCN menghasilkan nilai RMSE sebesar 91,45 dan MAPE sebesar 2,38%, yang menunjukkan tingkat kesalahan prediksi yang rendah dan akurasi yang tinggi. Model ini terbukti efektif dalam mengenali pola historis dan tren harga, sehingga dapat diandalkan untuk mendukung pengambilan keputusan investasi pada aset kripto, khususnya Ethereum. Untuk penelitian selanjutnya, disarankan untuk melakukan eksperimen dengan menggunakan dataset yang lebih besar dan beragam yang mencakup data dari sektor lain atau periode waktu yang panjang untuk meningkatkan generalisasi model.

DAFTAR PUSTAKA

- Aisyah, S., Angraini, Y., Sadik, K., Sartono, B., & Dito, G. A. (2024). *Technical Analysis of the Indonesian Stock Market with Gated Recurrent Unit and Temporal Convolutional Network*. 12(2), 187–196.
- Andromeda, R. S., & Winarsih, N. A. S. (2025). *Perbandingan Kinerja Metode LSTM dan GRU dalam Prediksi Harga Close Cryptocurrency Performance Comparison of LSTM and GRU Methods in Predicting Cryptocurrency Closing Prices*. 14, 366–379.
- Atmaja, D. M. U., & Hakim, A. R. (2022). Peramalan Harga Mata Uang Kripto Solana Menggunakan Metode Support Vector Regression (Svr). *Jurnal Media Elektro*, XI(2), 97–104. <https://doi.org/10.35508/jme.v0i0.8117>
- Aysa, I. R. (2021). Tantangan Transformasi Digital Bagi Kemajuan Perekonomian Indonesia. *Jurnal At-Tamwil: Kajian Ekonomi Syariah*, 3(2), 140–153. <https://doi.org/10.33367/at.v2i3.1458>
- Baharani, A. W., Apriza, Z., Mutmaina, N. A., & Sutabri, T. (2024). IJM: Indonesian Journal of Multidisciplinary Perbandingan Kinerja Mata Uang Kripto Utama: Bitcoin vs Ethereum. *IJM: Indonesian Journal of Multidisciplinary*, 2, 138–145. <https://journal.csspublishing/index.php/ijm>
- Bastian Sianturi, T., Cholissodin, I., & Yudistira, N. (2023). Penerapan Algoritma Long Short-Term Memory (LSTM) berbasis Multi Fungsi Aktivasi Terbobot dalam Prediksi Harga Ethereum. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 7(3), 1101–1107. <http://j-ptiik.ub.ac.id>
- Digo Saputra, R., & Hatta Fudholi, D. (2023). *Model Mobile untuk Deteksi Objek pada On-Shelf Availability Produk Retail*.
- Fajou, J., & McCarren, A. (2021). Forecasting Gold Prices Using Temporal Convolutional Networks. *CEUR Workshop Proceedings*, 3105, 248–259.
- Goa Mere, J. H. B. (2023). *Pembuatan dan pengujian token crypto pada jaringan mainnet menggunakan smart contract binance smart chain (bsc) dan remix.ethereum*. 14(c), 82–89.
- Julkarnaen, A., Irma Purnamasari, A., & Ali, I. (2024). Analisis Penjualan Roti Pada Distributor My Roti Menggunakan Metode Regresi Linear Berdasarkan Nilai Rmse. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(3), 3225–3229. <https://doi.org/10.36040/jati.v8i3.9426>
- Nurhakiki, J., & Yahfizham, Y. (2024). Studi Kepustakaan: Pengenalan 4 Algoritma Pada Pembelajaran Deep Learning Beserta Implikasinya. *Jurnal Pendidikan Berkarakter*, 1, 270–281. <https://doi.org/10.51903/pendekar.v2i1.598>
- Pratiwi, K., & Nurjanah, S. (2025). *Evaluasi Sistem Manajemen Persediaan untuk Mencegah Stockout Dan Mencapai Kepuasan Pelanggan (Studi Kasus Industri Distribusi Listrik)*. 12(1).
- Richia Putri, M., Gibran Satya Nugraha, & Ramaditia Dwiyanaputra. (2023). Pengelompokan Provinsi di Indonesia Berdasarkan Indikator Pendidikan Menggunakan Metode K-Means Clustering. *Journal of Computer Science and Informatics Engineering (J-Cosine)*, 7(1), 1–8. <https://doi.org/10.29303/jcosine.v7i1.509>
- Rizkilloh, M. F., & Widiyanesti, S. (2022). Prediksi Harga Cryptocurrency Menggunakan Algoritma Long Short Term Memory (LSTM). *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 6(1), 25–31. <https://doi.org/10.29207/resti.v6i1.3630>
- Saepudin, D., Egi Shidqi Rabbani, Dio Navialdy, & Didit Adytia. (2024). Water Level Time Series Forecasting Using TCN Study Case in Surabaya. *Jurnal Online Informatika*, 9(1), 61–69. <https://doi.org/10.15575/join.v9i1.1312>
- Wasiman, & Saparudin. (2022). Di Kota Batam. *Snistek*, 4, 447–452.
- Zaki, M., Baharuddin, Z., Hakim, A., Maulana, A., Islam, U., & Sumatera, N. (2025).

