

**Ranah Research****Journal of Multidisciplinary Research and Development**

082170743613

ranahresearch@gmail.com

<https://jurnal.ranahresearch.com>

E-ISSN: 2655-0865

DOI: <https://doi.org/10.38035/rj.v8i1>
<https://creativecommons.org/licenses/by/4.0/>

Prediksi Harga Cryptocurrency Menggunakan Algoritma Temporal Fusion Transformer, N-Beats dan Deepar

Fajar Nugraha Wahyu¹, Sajarwo Anggai², Tukiayat³¹Teknik Informatika S-2, Universitas Pamulang, Indonesia, fajarnugraha06@gmail.com²Teknik Informatika S-2, Universitas Pamulang, Indonesia, sajarwo@gmail.com³Teknik Informatika S-2, Universitas Pamulang/Badan Riset dan Inovasi Nasional, Indonesia, tukiayat64@gmail.comCorresponding Author: fajarnugraha06@gmail.com¹

Abstract: Cryptocurrencies such as Bitcoin, Ethereum, and Solana exhibit high price volatility, which makes accurate prediction challenging. This study aims to compare the accuracy of three deep learning algorithms, namely Temporal Fusion Transformer (TFT), N-BEATS, and DeepAR, in predicting the daily prices of these assets. The research data consist of closing prices, trading volume, and market capitalization obtained from CryptoDataDownload. The data were processed using Min-Max Scaling normalization, linear interpolation for missing values, and Pearson Correlation for feature selection. The dataset was then divided into training, validation, and testing subsets with adjustable proportions, allowing for the analysis of how different data splits affect model performance. The evaluation was conducted using MAE, RMSE, MAPE, and R^2 , as well as statistical tests to assess significant differences between models. The results showed that N-BEATS performed best with the lowest error and highest R^2 , while TFT ranked second with fairly stable results. In contrast, DeepAR consistently performed the worst with high errors and negative R^2 across almost all assets. Through intensive experimentation, this study demonstrates that N-BEATS outperforms TFT and DeepAR in explaining the variance of data for the three cryptocurrency assets: BTC, ETH, and SOL. Across all datasets, N-BEATS achieved the highest positive R^2 values under Configuration 2 (hidden size 32, 4 layers, dropout 0.3), peaking at 0.90 for BTC, 0.93 for ETH, and 0.55 for SOL. The corresponding MAPE values were 2.48% for BTC, 4.84% for ETH, and 6.55% for SOL. The analysis also revealed that variations in hidden layer size, epoch, dropout, number of layers, and data division affected the stability and performance of predictions, but increased complexity did not always result in better performance. Thus, N-BEATS can be identified as the most effective model for crypto price prediction, while also providing a theoretical contribution to the development of time series forecasting models and a practical contribution as a reference for investors in decision making.

Keywords: Cryptocurrency, DeepAR, N-BEATS, Price Prediction, Temporal Fusion Transformer

Abstrak: *Cryptocurrency* seperti *Bitcoin*, *ETHereum*, dan *Solana* memiliki volatilitas harga tinggi yang menyulitkan prediksi akurat. Penelitian ini bertujuan membandingkan akurasi tiga algoritma *deep learning*, yaitu *Temporal Fusion Transformer* (TFT), *N-BEATS*, dan *DeepAR*, dalam memprediksi harga harian ketiga aset tersebut. Data penelitian berupa harga penutupan, *volume*, dan kapitalisasi pasar yang diperoleh melalui *CryptoDataDownload*. Data diproses menggunakan normalisasi *Min-Max Scaling*, interpolasi linier untuk *missing values*, serta *feature selection Pearson Correlation*. *Dataset* kemudian dibagi ke dalam data pelatihan, validasi, dan pengujian dengan proporsi yang dapat disesuaikan, sehingga memungkinkan analisis pengaruh perbedaan pembagian data terhadap hasil model. Evaluasi dilakukan menggunakan MAE, RMSE, MAPE, dan R^2 , serta uji statistik untuk menilai perbedaan signifikan antar model. Hasil penelitian menunjukkan bahwa *N-BEATS* memberikan performa terbaik dengan *error* paling rendah dan R^2 tertinggi, sementara TFT berada di urutan kedua dengan hasil yang cukup stabil. Sebaliknya, *DeepAR* secara konsisten memiliki performa terburuk dengan *error* tinggi dan R^2 negatif hampir di seluruh aset. Melalui eksperimen intensif, penelitian ini menunjukkan bahwa *N-BEATS* mengungguli TFT dan *DeepAR* dalam menjelaskan variansi data pada ketiga aset kripto: BTC, ETH, dan SOL. Pada semua dataset, *N-BEATS* mencapai nilai R^2 positif tertinggi di bawah Konfigurasi 2 (*hidden size* 32, 4 *layers*, *dropout* 0.3), dengan puncak 0.90 pada BTC, 0.93 pada ETH, dan 0.55 pada SOL. Nilai MAPE yang sesuai adalah 2.48% untuk BTC, 4.84% untuk ETH, dan 6.55% untuk SOL. Analisis juga mengungkap bahwa variasi ukuran *hidden layer*, *epoch*, *dropout*, jumlah *layer*, maupun pembagian data memengaruhi stabilitas serta performa prediksi, namun peningkatan kompleksitas tidak selalu menghasilkan performa yang lebih baik. Dengan demikian, *N-BEATS* dapat diidentifikasi sebagai model paling efektif untuk prediksi harga kripto, sekaligus memberikan kontribusi teoritis bagi pengembangan model peramalan deret waktu dan kontribusi praktis sebagai acuan bagi investor dalam pengambilan keputusan.

Kata Kunci: *Cryptocurrency*, *DeepAR*, *N-BEATS*, Prediksi Harga, *Temporal Fusion Transformer*.

PENDAHULUAN

Cryptocurrency telah menjadi salah satu instrumen keuangan yang paling menarik dalam dekade terakhir, dengan *Bitcoin*, *Ethereum*, dan *Solana* menjadi aset utama yang mendominasi pasar. Hingga Mei 2025, kapitalisasi pasar *Cryptocurrency* global telah melampaui \$2 triliun, dengan *Bitcoin* menyumbang lebih dari 40% dari total kapitalisasi, diikuti oleh *Ethereum* dan *Solana* yang masing-masing dikenal karena teknologi smart contract dan skalabilitasnya (CoinmarketCap, 2025). Namun, volatilitas harga yang tinggi menjadi tantangan utama bagi investor. Sebagai contoh, harga *Bitcoin* dapat berfluktuasi tinggi naik ataupun turun dalam sehari, dipengaruhi oleh dinamika pasar, perubahan regulasi, dan faktor eksternal lainnya (Asmat & Maiyama, 2025). Kondisi ini menjadikan prediksi harga *Cryptocurrency* sebagai topik yang sangat relevan dan menantang dalam penelitian keuangan modern.

Prediksi harga *Cryptocurrency* menjadi tantangan signifikan karena karakteristiknya yang sangat volatil, non-linier, dan dipengaruhi oleh banyak faktor eksternal. Metode statistik tradisional seperti ARIMA atau SARIMA kurang mampu menangkap pola kompleks dalam data deret waktu *Cryptocurrency* yang dinamis dan sering kali tidak stasioner (Setiawan et al., 2025). Oleh karena itu, pendekatan berbasis *deep learning* semakin banyak digunakan karena keunggulannya dalam memodelkan hubungan temporal dan non-linier (Oreshkin et al., 2019). Salah satu pendekatan *deep learning* yang menonjol adalah *Temporal Fusion Transformer* (TFT), yang memanfaatkan self-attention dan variable selection untuk

menangkap hubungan temporal jangka panjang dalam data multivariat (Lim et al., 2021). Di sisi lain, *N-BEATS* adalah model feedforward interpretable yang terbukti unggul dalam berbagai kompetisi forecasting, termasuk dalam data keuangan seperti S&P 500 dan *Bitcoin* (Liu et al., 2023). Sementara itu, *DeepAR*, model berbasis RNN autoregresif, mampu melakukan prediksi probabilistik dengan mempertimbangkan ketidakpastian, dan telah digunakan secara luas untuk deret waktu finansial (Zahid et al., 2024).

TFT yang diperkenalkan oleh (Lim et al., 2021), adalah model berbasis Transformer yang dirancang khusus untuk peramalan deret waktu multivariat. TFT menggabungkan mekanisme self-attention, *Gated Linear Units* (GLU), dan *Variable Selection Networks* untuk menangkap hubungan temporal yang kompleks dan memilih variabel yang relevan secara otomatis. (Lim et al., 2021) melaporkan bahwa TFT mampu mengurangi *Root Mean Squared Error* (RMSE) hingga 15% dibandingkan model seperti *Long Short-Term Memory* (LSTM) dalam peramalan penjualan ritel.

Beberapa studi seperti (Liu et al., 2023) menunjukkan keunggulan *N-BEATS* dibanding LSTM dan GRU, dengan MAPE serendah 0.02% untuk indeks pasar dan MAE rendah untuk *Solana*. Sementara itu, TFT dilaporkan mengungguli LSTM hingga 15% dalam RMSE pada data retail (Lim et al., 2021), dan *DeepAR* lebih unggul dari SARIMA pada data produksi beras dengan MAPE 4.5% (Zahid et al., 2024). Namun, belum banyak riset yang secara langsung membandingkan ketiga model ini dalam konteks prediksi harga *Cryptocurrency*.

DeepAR, yang diperkenalkan oleh (Salinas et al., 2020), adalah model berbasis *Recurrent Neural Network* (RNN) yang dirancang untuk peramalan probabilistik. *DeepAR* menghasilkan prediksi dalam bentuk distribusi probabilitas, yang sangat berguna untuk pasar volatil seperti *Cryptocurrency*. (Salinas et al., 2020) melaporkan bahwa *DeepAR* memberikan akurasi yang kompetitif dalam peramalan deret waktu multivariat, terutama pada data dengan ketidakaturan temporal. Sementara itu, *DeepAR* merupakan model berbasis *Recurrent Neural Network* (RNN) autoregresif yang menghasilkan prediksi dalam bentuk distribusi probabilistik.

Inovasi pembaharuan model *DeepAR* terletak pada kemampuannya menangani banyak deret waktu sekaligus, serta memberikan prediksi dengan rentang ketidakpastian (Salinas et al., 2020). (Zahid et al., 2024) menemukan bahwa *DeepAR* mengungguli SARIMA dalam memprediksi produksi beras di Indonesia dengan MAPE 4.5% dibandingkan 5.44%. Selain itu, (Hong et al., 2024) menunjukkan bahwa model berbasis distribusi seperti *DeepAR* efektif dalam memodelkan volatilitas tinggi, meskipun memiliki keterbatasan dalam interpretabilitas dan kompleksitas implementasi. Dalam studi (Kraaijeveld & De Smedt, 2020), pendekatan *time series* dipadukan dengan data sentimen juga menunjukkan bahwa model prediktif berbasis deret waktu seperti *DeepAR* dapat diperkuat dengan informasi eksternal untuk pasar *Cryptocurrency*. Meskipun ketiga algoritma ini telah menunjukkan performa yang baik dalam berbagai konteks, belum banyak penelitian yang membandingkan akurasi TFT, *N-BEATS*, dan *DeepAR* secara langsung dalam prediksi harga *Cryptocurrency*, khususnya pada aset seperti *Bitcoin*, *Ethereum*, dan *Solana*.


Oleh karena itu, kajian ini difokuskan pada analisis komparatif akurasi ketiga model tersebut dengan menggunakan ukuran kinerja seperti *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE) dalam satuan USD (dolar Amerika). *Dataset* yang digunakan berasal dari situs <https://www.CryptoDataDownload.com/data/binance/>, yang mencakup tiga aset *Cryptocurrency*: *Bitcoin* (BTCUSD), *Ethereum* (ETHUSD), dan *Solana* (SOLUSD). Masing-masing *dataset* terdiri atas 10 *feature* utama seperti harga *open*, *high*, *low*, *close*, *volume*, *trade count*, dan *timestamp*. Ketiga *dataset* ini memiliki periode waktu yang berbeda, sehingga dilakukan penyesuaian rentang waktu agar seragam, yaitu dari 11 Agustus 2020 hingga 30 Juni 2025. Kebaruan dari penelitian ini terletak pada perbandingan model *deep learning* populer TFT, *N-BEATS*, dan *DeepAR* dalam konteks prediksi harga *Cryptocurrency*.

Selain itu, kebaruan lainnya yang dilakukan pada penelitian ini berada pada output nya dengan menghasilkan aplikasi prediksi yang dilengkapi dengan visualisasi dan hasil evaluasi dari model *deep learning* TFT, *N-BEATS*, dan *DeepAR* yang digunakan. Dengan dilakukannya penelitian ini diharapkan dapat memberikan kontribusi teoritis dengan memperluas literatur tentang peramalan deret waktu menggunakan *deep learning*, serta kontribusi praktis bagi investor dan analis keuangan dalam pengambilan keputusan yang mencerminkan dinamika pasar *Cryptocurrency* pasca adopsi massal dan perubahan regulasi global yang terjadi dalam beberapa tahun terakhir.

METODE

Implementasi model peramalan dalam penelitian ini didasarkan pada tiga arsitektur *deep learning*, yaitu Temporal Fusion Transformer (TFT), *N-BEATS*, dan *DeepAR*. Ketiga model tersebut diterapkan untuk meramalkan harga harian aset kripto utama, yakni Bitcoin (BTC), Ethereum (ETH), dan Solana (SOL). Data historis yang digunakan bersumber dari CryptoDataDownload untuk pasar Binance, mencakup periode pengamatan dari 11 Agustus 2020 hingga 30 Juni 2025. Dari total 1.785 catatan harian tersebut, diekstraksi sepuluh fitur utama yang merepresentasikan dinamika pasar. Fitur-fitur ini meliputi harga pembukaan (*open*), penutupan (*close*), tertinggi (*high*), terendah (*low*), volume perdagangan, dan jumlah transaksi, yang secara kolektif berfungsi sebagai proksi untuk mengukur aktivitas dan volatilitas pasar.

Setelah kebutuhan data dijabarkan, penelitian dilanjutkan dengan perancangan tahapan sistematis yang meliputi input dataset, preprocessing (normalisasi, penanganan missing value, dan seleksi fitur dengan korelasi Pearson), pelatihan model menggunakan data latih dan validasi, prediksi dengan data uji, serta evaluasi hasil menggunakan metrik performa. Seluruh proses dirancang agar menghasilkan analisis yang akurat dan dapat dipertanggungjawabkan dalam membandingkan efektivitas model peramalan harga kripto. Berikut merupakan *Flowchart* alur *Preprocessing*:



Gambar 1. Flowchart alur *Preprocessing*

HASIL DAN PEMBAHASAN

Analisis Model

Berikut merupakan analisis model dari masing-masing algoritma yang digunakan dan diterapkan pada masing-masing koin. Akan tetapi sebelum masuk dalam uji model berikut pada Tabel 1 merupakan penjabaran masing-masing *config* yang digunakan dalam pengujiannya.

Tabel 1. Config Hyperparameter yang digunakan

Config	Hyperparameter yang digunakan
Config 1	Num Layers 1, Hidden size 8, Dropout 0.3, Batch Size 32, Epoch 5
Config 2	Num Layers 4, Hidden size 32, Dropout 0.3, Batch Size 32, Epoch 25
Config 3	Num Layers 4, Hidden size 128, Dropout 0.5, Batch Size 128, Epoch 100

TFT

a. BTC

Pada *dataset* BTC, dilakukan pengujian dengan tiga konfigurasi *hyperparameter* yang berbeda untuk menilai pengaruh variasi *hidden size*, *num layers*, *dropout rate*, serta persentase data latih terhadap performa prediksi.

Tabel 2. Uji Model pada BTC menggunakan TFT

Config	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3
Split data	60%:40%			70%:30%			80%:20%			90%:10%		
MAE	34182.3	22173.4		39225.1	31196.4	32089.6	34443.2	27614.2	19944.2	16711.1	9486.42	
	9	4	28196.6	4	3	8	8	2	1	4	6	33155.4
RMS		26651.2	32792.3	41858.9	33572.6	35193.0	36830.4	29494.7	22315.4	19270.5	11122.6	35678.8
E	39105.4	2	4	5	5	8	2	3	5	1	1	2
MAP												
E	37.99%	23.66%	30.83%	41.36%	32.52%	33.77%	35.23%	28.09%	20.09%	16.71%	9.80%	32.60%
R ²												
	-4.1308	-1.3831	-2.6079	10.5906	-6.4559	-7.193	15.5865	-9.6373	-5.0891	-3.0307	-0.3428	12.8171
t-statistic												
c	31.6986	24.5008	30.5197	43.1467	39.6069	34.4267	35.2298	35.5511	26.4475	10.8403	3.3744	22.7338
P-value	0	0	0	0	0	0	0	0	0	0	0.0011	0

Hasil pengujian TFT pada dataset BTC menunjukkan bahwa konfigurasi dengan proporsi data latih 90% dan 10% data test, dan konfigurasi *config 2* (Num Layers 4, Hidden size 32, Dropout 0.3, Batch Size 32, Epoch 25) menghasilkan performa terbaik secara keseluruhan. Hal ini ditunjukkan oleh nilai MAE sebesar 9486.426, RMSE sebesar 11122.61, serta MAPE sebesar 9.80%. Satuan yang dipakai MAE dan RMSE adalah USD

Nilai R² sebesar -0.3428 masih negatif, menandakan bahwa model belum sepenuhnya mampu menjelaskan variasi data aktual, namun peningkatan signifikan terlihat dibanding konfigurasi lain yang memiliki R² sebesar -15.5865. Nilai p-value sebesar 0.0011 (< 0.05) menunjukkan bahwa model signifikan secara statistik. R² dapat bernilai negatif sesuai dengan definisi statistiknya ketika model gagal menjelaskan variansi data lebih baik daripada prediksi rata-rata historis; hal ini dijelaskan dalam *Applied Linear Statistical Models* oleh Kutner et al., (2005) yang menyatakan bahwa “R² dapat bernilai negatif ketika model tidak mencakup intersep atau ketika dievaluasi pada data yang tidak digunakan dalam estimasi kondisi yang umum terjadi dalam konteks machine learning dan peramalan deret waktu.”

Selain itu, *config 2* (Num Layers 4, Hidden size 32, Dropout 0.3, Batch Size 32, Epoch 25) yaitu *hidden size* sedang (32) menunjukkan hasil lebih stabil dibanding konfigurasi dengan *hidden size* terlalu kecil (8) atau terlalu besar (128). *Hidden size* yang terlalu besar berpotensi menyebabkan *overfitting*, sementara ukuran terlalu kecil menyebabkan

underfitting. Oleh karena itu, dapat disimpulkan bahwa *Config 2* dengan proporsi data latih 90% merupakan konfigurasi paling optimal untuk model TFT pada data BTC.

b. ETH

Pada *dataset* ETH, dilakukan pengujian dengan tiga konfigurasi *hyperparameter* yang berbeda untuk menilai pengaruh variasi *hidden size*, *num layers*, *dropout rate*, serta persentase data latih terhadap performa prediksi.

Tabel 3. Uji Model pada ETH menggunakan TFT

Config	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3
Split data	60%:40%			70%:30%			80%:20%			90%:10%		
MAE	727.047	206.051	295.553	584.515	218.334	263.274	678.820	188.617	215.451	603.224	136.710	
	5	1	3	1	9	9	8	5	5	8	1	216.887
RMS	913.266	278.434	386.874	727.735	269.934	342.065	822.607	238.818	265.148	711.620	172.630	263.858
E	1	6	3	6	2	4	4	5	6	1	8	9
MAP												
E	28.78%	7.46%	10.85%	23.66%	8.36%	9.92%	30.03%	7.87%	9.18%	27.52%	6.28%	10.11%
R ²	-1.4814	0.7693	0.5547	-0.3267	0.8175	0.7069	-1.281	0.8077	0.763	-1.9176	0.8283	0.5989
t-statistic							-					
c	-7.3689	0.8594	-5.6055	-4.3409	10.2637	6.7683	11.2141	-5.3015	-1.7895	-2.6111	1.5759	4.5956
P-value	0	0.3907	0	0	0	0	0	0	0.0752	0.0106	0.1186	0

Hasil pengujian TFT pada dataset ETH menunjukkan bahwa konfigurasi dengan proporsi data latih 90% dan 10% data test, dan konfigurasi *config 2* (*Num Layers 4, Hidden size 32, Dropout 0.3, Batch Size 32, Epoch 25*) menghasilkan performa terbaik secara keseluruhan. Hal ini ditunjukkan oleh nilai MAE sebesar 136.7101, RMSE sebesar 172.6308, MAPE sebesar 6.28%, serta nilai R² sebesar 0.8283 menandakan bahwa model memiliki kemampuan prediksi yang cukup baik.

Sebaliknya, *config 1* (*Num Layers 1, Hidden size 8, Dropout 0.3, Batch Size 32, Epoch 5*) menunjukkan performa yang kurang optimal, terutama pada split data 60%:40%, dan 80%:20%, dimana nilai MAE, RMSE, MAPE jauh lebih tinggi serta R² negatif yang menandakan model tidak mampu menjelaskan variasi data secara baik. Dari hasil uji statistik, sebagian besar nilai p-value menunjukkan angka 0, yang berarti terdapat hubungan yang signifikan antara nilai aktual dan nilai prediksi. Nilai t-statistic pada konfigurasi terbaik juga relatif tinggi, memperkuat bukti bahwa parameter model TFT pada ETH memiliki kontribusi signifikan terhadap hasil prediksi.

Dengan demikian, dapat disimpulkan bahwa konfigurasi optimal untuk model TFT pada dataset ETH adalah *Config 2* dengan rasio data latih 90%:10%, karena menghasilkan performa prediksi paling baik dan stabil di antara seluruh percobaan.

c. SOL

Pada *dataset* SOL, dilakukan pengujian dengan tiga konfigurasi *hyperparameter* yang berbeda untuk menilai pengaruh variasi *hidden size*, *num layers*, *dropout rate*, serta persentase data latih terhadap performa prediksi.

Tabel 4. Uji Model pada SOL menggunakan TFT

Config	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3
Split data	60%:40%			70%:30%			80%:20%			90%:10%		
MAE	60.2614	32.147	23.6075	57.5956	15.6258	55.382	60.5058	21.5049	25.4653	30.6942	11.5724	18.2498
RMSE	75.1428	39.937	30.5356	71.0862	20.3164	65.9029	76.331	30.2189	31.5977	38.2485	14.7443	21.5036
MAPE	35.38%	19.18%	13.97%	31.98%	8.83%	30.49%	36.55%	12.60%	15.70%	20.62%	7.88%	12.25%
R ²	-3.4313	-0.2517	0.2682	-2.4839	0.7154	-1.9944	-3.6876	0.2653	0.1967	-3.4457	0.3394	-0.4052
t-statistic												
c	6.0203	-2.6743	1.8458	8.1116	1.1067	23.9063	3.7198	-0.1056	-0.7296	-0.4395	-0.4233	4.5446
P-value	0	0.0078	0.0657	0	0.2694	0	0.0003	0.916	0.4666	0.6614	0.6731	0

Hasil pengujian TFT pada dataset SOL menunjukkan bahwa konfigurasi dengan proporsi data latih 90% dan 10% data test, dan konfigurasi *config 2* (*Num Layers 4, Hidden size 32, Dropout 0.3, Batch Size 32, Epoch 25*) menghasilkan performa terbaik secara keseluruhan. Hal ini ditunjukkan oleh nilai MAE sebesar 11.5724, RMSE sebesar

14.7443, MAPE sebesar 7.88%. Nilai R^2 sebesar 0.8283 menandakan bahwa model memiliki kemampuan prediksi yang cukup baik.

Sebaliknya, *config 1* (Num Layers 1, Hidden size 8, Dropout 0.3, Batch Size 32, Epoch 5) dan *config 3* (Num Layers 4, Hidden size 128, Dropout 0.5, Batch Size 128, Epoch 100) menghasilkan nilai kesalahan prediksi yang lebih tinggi serta beberapa nilai R^2 negatif, yang menandakan bahwa model tidak mampu menjelaskan pola data dengan baik pada konfigurasi tersebut. Kemudian beberapa konfigurasi nilai p-value bernilai 0, yang berarti terdapat hubungan yang signifikan antara nilai aktual dan nilai prediksi.

Secara keseluruhan, dapat disimpulkan bahwa *config 2* dengan rasio 90%:10% memberikan hasil prediksi paling baik pada model TFT untuk dataset SOL.

NBEATS

a. BTC

Pada *dataset* BTC, dilakukan pengujian dengan tiga konfigurasi *hyperparameter* yang berbeda untuk menilai pengaruh variasi *hidden size*, *num layers*, *dropout rate*, serta persentase data latih terhadap performa prediksi.

Tabel 5. Uji Model pada BTC menggunakan NBEATS

Confi g	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3
Split data	60%:40%			70%:30%			80%:20%			90%:10%		
MAE	8106.42		13288.8	9648.08	14762.7	19577.9	8742.73	12171.5	15541.4	7582.82		8925.51
	3	14889.1	6	8	6	8	9	6	1	6	2354.31	8
RMS		17881.3		11510.9	16240.6	20826.5	10057.4	13111.3	16587.1	8324.94	3012.62	9643.51
E	10081	6	16029.4	6	8	2	4	1	3	2	5	6
MAP												
E	9.39%	15.81%	14.10%	10.36%	15.22%	20.47%	9.57%	12.32%	15.75%	7.50%	2.48%	8.80%
R^2	0.659	-0.0728	0.1379	0.1235	-0.7448	-1.8692	-0.2368	-1.102	-2.3642	0.2478	0.9015	-0.0094
t- statisti c	-5.3341	25.9362	24.0489	16.845	34.8266	45.0411	21.9987	33.1693	35.7725	17.7973	-1.8811	20.2428
P- value	0	0	0	0	0	0	0	0	0	0	0.0632	0

Berdasarkan Tabel 5, terlihat bahwa *config 2* (Num Layers 4, Hidden size 32, Dropout 0.3, Batch Size 32, Epoch 25) dan *config 3* (Num Layers 4, Hidden size 128, Dropout 0.5, Batch Size 128, Epoch 100) belum mampu memberikan hasil yang konsisten dibandingkan *config 1* (Num Layers 1, Hidden size 8, Dropout 0.3, Batch Size 32, Epoch 5). Hal ini dikarenakan beberapa nilai R^2 bernilai negatif, menandakan model tidak dapat menjelaskan variasi data dengan baik pada konfigurasi tersebut. sebaliknya, *config 1* dengan rasio data 90%:10% menunjukkan performa terbaik dengan nilai MAE sebesar 7582.83, RMSE sebesar 8324.94, dan MAPE sebesar 7.50%, serta R^2 sebesar 0.2478 yang menunjukkan kemampuan model dalam menangkap sebagian pola pergerakan harga BTC.

Selain itu, hasil uji statistik memperlihatkan bahwa hampir seluruh konfigurasi memiliki p-value = 0, menandakan hubungan signifikan antara nilai aktual dan hasil prediksi. Namun, pada beberapa konfigurasi ditemukan t-statistic negatif, yang mengindikasikan arah hubungan yang tidak konsisten antara prediksi dan nilai aktual, kemungkinan disebabkan oleh fluktuasi ekstrem pada data harga BTC.

Secara keseluruhan, dapat disimpulkan bahwa *config 1* dengan rasio 90%:10% memberikan hasil prediksi paling baik pada model N-BEATS untuk dataset BTC.

b. ETH

Pada *dataset* ETH, dilakukan pengujian dengan tiga konfigurasi *hyperparameter* yang berbeda untuk menilai pengaruh variasi *hidden size*, *num layers*, *dropout rate*, serta persentase data latih terhadap performa prediksi.

Tabel 6. Uji Model pada ETH menggunakan NBEATS

Config	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3
Split data	60%:40%			70%:30%			80%:20%			90%:10%		
MAE	304.973		130.753	156.611	126.854	759.375	335.691	178.359	145.444		163.130	705.827
	8	131.218	8	1	6	2	4	7	9	140.769	8	4
RMS		179.304	168.552		168.865	810.377	377.155	210.051	186.077	193.064	200.320	
E	350.188	7	8	198.463	5	2	9	2	9	2	3	751.596
MAP												
E	12.53%	4.96%	4.94%	6.14%	4.84%	28.32%	15.34%	7.76%	6.23%	6.41%	7.41%	31.51%
R ²	0.6352	0.9043	0.9155	0.9013	0.9286	-0.6451	0.5205	0.8513	0.8833	0.7853	0.7688	-2.2546
t-statistic	-						-	-				
c	21.4463	2.3634	6.6106	-0.9642	1.4763	43.8534	18.4843	12.0632	9.9044	-0.4895	-5.2648	25.782
P-value	0	0.0186	0	0.3358	0.141	0	0	0	0	0.6257	0	0

Berdasarkan Tabel 6, terlihat bahwa *config 2* (*Num Layers 4, Hidden size 32, Dropout 0.3, Batch Size 32, Epoch 25*) secara umum memberikan performa terbaik dibandingkan konfigurasi lainnya, terutama pada rasio data 60%:40% dan 70%:30%. Pada kedua rasio tersebut, model menghasilkan nilai MAE masing-masing 131.218 dan 126.8546, RMSE sebesar 179.3047 dan 168.8655, serta MAPE sebesar 4.96% dan 4.84%, yang menunjukkan tingkat kesalahan prediksi yang rendah. Nilai R² sebesar 0.9043 dan 0.9286 menandakan bahwa model mampu menjelaskan lebih dari 92% variasi data harga ETH, sehingga cukup representatif dalam mempelajari pola historis harga.

Sebaliknya, pada *config 3* (*Num Layers 4, Hidden size 128, Dropout 0.5, Batch Size 128, Epoch 100*) dan rasio data 90%:10%, nilai R² turun drastis menjadi -2.2546 dengan MAPE tertinggi yaitu mencapai 31.51%, yang menunjukkan bahwa model mengalami *overfitting* dan tidak mampu melakukan generalisasi dengan baik pada data uji. Hasil uji statistik menunjukkan sebagian besar p-value = 0, menandakan hubungan signifikan antara nilai aktual dan hasil prediksi. Namun, pada beberapa konfigurasi ditemukan t-statistic negatif, yang mengindikasikan arah hubungan yang tidak konsisten antara prediksi dan nilai aktual, kemungkinan disebabkan oleh volatilitas tinggi pada data harga ETH.

Secara keseluruhan, dapat disimpulkan bahwa *config 2* dengan rasio 70%:30% memberikan hasil prediksi paling baik pada model N-BEATS untuk dataset ETH.

c. SOL

Pada *dataset SOL*, dilakukan pengujian dengan tiga konfigurasi *hyperparameter* yang berbeda untuk menilai pengaruh variasi *hidden size*, *num layers*, *dropout rate*, serta persentase data latih terhadap performa prediksi.

Tabel 7. Uji Model pada SOL menggunakan NBEATS

Config	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3
Split data	60%:40%			70%:30%			80%:20%			90%:10%		
MAE	14.8098	14.5796	56.9291	21.2867	13.3113	65.5121	15.9389	12.5822	56.5892	10.2029	9.772	50.4502
RMSE	18.6018	18.3497	59.5859	25.6796	17.4719	68.1069	19.9396	17.9716	59.9144	12.2974	12.1839	51.8727
MAPE	8.73%	8.54%	33.51%	12.01%	7.30%	37.36%	9.43%	7.12%	34.00%	6.84%	6.55%	33.45%
R ²	0.7284	0.7357	-1.7864	0.5454	0.7895	-2.198	0.6801	0.7401	-1.8881	0.5404	0.5489	-7.177
t-statistic	7.3626	17.2464	61.0503	17.8435	14.1901	57.4897	4.9062	9.3406	38.3589	7.7867	8.4045	39.4498
P-value	0	0	0	0	0	0	0	0	0	0	0	0

Berdasarkan Tabel 7, terlihat bahwa *config 2* (*Num Layers 4, Hidden size 32, Dropout 0.3, Batch Size 32, Epoch 25*) secara umum memberikan performa terbaik dibandingkan konfigurasi lainnya, terutama pada rasio data 80%:20% dan 90%:10%. Pada kedua rasio tersebut, model menghasilkan nilai MAE masing-masing 12.5822 dan 9.772, RMSE sebesar 17.9716 dan 12.1839, serta MAPE sebesar 7.12% dan 6.55%, yang menunjukkan tingkat kesalahan prediksi yang rendah. Nilai R² sebesar 0.7401 dan 0.5489 menandakan bahwa model mampu menjelaskan sekitar 74%-54% variasi data harga SOL.

Sebaliknya, pada *config 3* (*Num Layers 4, Hidden size 128, Dropout 0.5, Batch Size 128, Epoch 100*) dan rasio data 70%:30%, nilai R² turun drastis menjadi -2.198 dengan MAPE

tertinggi yaitu mencapai 37.36%, yang menunjukkan bahwa model mengalami *overfitting* dan tidak mampu melakukan generalisasi dengan baik pada data uji.

Hasil uji statistic menunjukkan semua nilai $p\text{-value} = 0$, menandakan hubungan signifikan antara nilai aktual dan hasil prediksi. Pada $t\text{-statistic}$ yaitu positif, yang mengindikasikan arah hubungan yang konsisten antara prediksi dan nilai aktual. Secara keseluruhan, dapat disimpulkan bahwa *config* 2 dengan rasio 90%:10% memberikan hasil prediksi paling baik pada model N-BEATS untuk dataset SOL.

DeepAR

a. BTC

Pada *dataset Bitcoin*, dilakukan pengujian dengan tiga konfigurasi *hyperparameter* yang berbeda untuk menilai pengaruh variasi *hidden size*, *num layers*, *dropout rate*, serta persentase data latih terhadap performa prediksi.

Tabel 8. Uji Model pada BTC menggunakan DeepAR

Config	Config	Config	Config	Config	Config	Config	Config	Config	Config	Config	Config	Config
g	1	2	3	1	2	3	1	2	3	1	2	3
Split data	60%:40%			70%:30%			80%:20%			90%:10%		
MAE	69401.6	48901.9	56092.5	73360.2	56854.2	55711.0	63778.0	57299.3	32750.3	58180.3	44255.8	28289.3
	7	6	2	5	5	5	6	8	3	4	1	5
RMSE	75566.0	54298.9	58836.4	76102.5	59498.3	57352.3	66532.8	59756.8	35833.8	62501.6	50136.0	33083.4
	6	4	9	8	8	9	3	3	6	9	7	1
MAPE	80.78%	55.73%	64.65%	79.03%	60.79%	59.50%	66.04%	59.25%	33.47%	58.55%	44.41%	28.31%
R ²	-	-	-	-	-	-	-	-	-	-	-	-
	18.1587	-8.8922	10.6146	37.3113	22.4174	20.7586	53.1269	42.6633	-14.701	41.4013	26.2833	-10.88
t-statistic												
c	43.4636	38.5787	59.5971	59.2093	52.965	66.8247	44.9106	45.0734	29.8036	24.0348	16.8307	12.7057
P-value	0	0	0	0	0	0	0	0	0	0	0	0

Berdasarkan Tabel 8, dapat diamati bahwa nilai MAE dan RMSE menunjukkan fluktuasi yang cukup signifikan antar konfigurasi dan pembagian data latih-uji. Secara umum, nilai error cenderung menurun seiring dengan peningkatan proporsi data latih, terutama pada *config* 3 (*Num Layers* 4, *Hidden size* 128, *Dropout* 0.5, *Batch Size* 128, *Epoch* 100) dengan split data 90%:10% yang menghasilkan nilai MAE sebesar 28.289,35 dan RMSE sebesar 33.083,41, yang merupakan hasil terbaik dibandingkan konfigurasi lainnya. Hal ini menunjukkan bahwa semakin banyak data latih yang digunakan, semakin baik model dalam mempelajari pola historis harga BTC.

Dari sisi MAPE, pola serupa terlihat di mana nilai kesalahan relatif menurun dari 80,78% pada *config* 1 (*Num Layers* 1, *Hidden size* 8, *Dropout* 0.3, *Batch Size* 32, *Epoch* 5) yaitu pada split 60%:40% menjadi 28,31% pada *config* 3 (*Num Layers* 4, *Hidden size* 128, *Dropout* 0.5, *Batch Size* 128, *Epoch* 100) pada split 90%:10%, yang menunjukkan peningkatan akurasi prediksi. Meskipun begitu, nilai MAPE di atas 20% masih menandakan bahwa model belum dapat menghasilkan prediksi dengan akurasi tinggi, kemungkinan disebabkan oleh volatilitas tinggi pada harga BTC dan kompleksitas pola waktunya.

Sementara itu, nilai R^2 yang bernilai negatif pada seluruh konfigurasi menunjukkan bahwa model DeepAR belum mampu memprediksi dengan baik terhadap data aktual. Nilai R^2 negatif menandakan bahwa model memiliki performa yang lebih buruk dibandingkan model sederhana yang hanya menggunakan rata-rata sebagai prediksi. Dengan kata lain, walaupun nilai error menurun pada proporsi data latih yang lebih besar, model masih belum mampu menangkap hubungan yang kuat antara input dan output.

Untuk parameter $t\text{-statistic}$ dan $p\text{-value}$, terlihat bahwa seluruh konfigurasi memiliki $p\text{-value}$ sebesar 0, yang menunjukkan bahwa parameter model signifikan secara statistik. Namun, karena performa model secara umum (berdasarkan R^2) masih rendah, hasil ini belum dapat dikatakan cukup untuk mendukung reliabilitas model dalam konteks

prediksi harga BTC. Secara keseluruhan, konfigurasi terbaik diperoleh pada *Config 3* dengan split data 90%:10%, karena memberikan nilai error paling kecil (MAE, RMSE, dan MAPE paling rendah) dibandingkan konfigurasi lain.

b. ETH

Pada *dataset* ETH, dilakukan pengujian dengan tiga konfigurasi *hyperparameter* yang berbeda untuk menilai pengaruh variasi *hidden size*, *num layers*, *dropout rate*, serta persentase data latih terhadap performa prediksi.

Tabel 9. Uji Model pada ETH menggunakan DeepAR

Config	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3
Split data	60%:40%			70%:30%			80%:20%			90%:10%		
MAE	1096.31	1119.84	925.318	1268.77	1087.97	854.195	769.449	751.722	741.780	841.019	826.426	469.911
RMS	1378.34	1303.65			1277.91	1043.44	979.855	957.192	945.993	1012.47	998.259	548.219
E	2	6	1079.99	1600.26	3	2	9	3	8	7	9	3
MAP												
E	42.65%	40.08%	31.84%	49.39%	37.66%	28.74%	32.86%	30.52%	30.68%	40.82%	40.46%	20.04%
R ²	-4.6523	-4.0563	-2.4702	-5.415	-3.0909	-1.7274	-2.2365	-2.0885	-2.0166	-4.9061	-4.7414	-0.7316
t-statistic												
c	4.6968	25.8558	27.8938	4.0892	25.1415	20.2858	0.411	5.4936	3.5735	-2.0373	-2.9633	7.4916
P-value	0	0	0	0.0001	0	0	0.6816	0	0.0005	0.0446	0.0039	0

Berdasarkan Tabel 9, dapat diamati bahwa performa model meningkat seiring dengan meningkatnya proporsi data latih, terutama pada *config 3* (*Num Layers 4*, *Hidden size 128*, *Dropout 0.5*, *Batch Size 128*, *Epoch 100*) dengan split data 90%:10%. Pada konfigurasi tersebut, model menghasilkan nilai MAE sebesar 469,91 dan RMSE sebesar 548,22, yang merupakan nilai error terendah di antara seluruh konfigurasi. Hal ini menunjukkan bahwa semakin banyak data historis yang digunakan dalam pelatihan, semakin baik kemampuan model dalam mengenali pola harga ETH. Nilai MAPE juga menunjukkan tren penurunan yang konsisten, dari 42,65% pada split 60%:40% menjadi 20,04% pada split 90%:10%, yang berarti tingkat kesalahan prediksi relatif terhadap data aktual semakin kecil. Hasil ini mengindikasikan bahwa model memiliki akurasi yang lebih baik dibandingkan pada proporsi data latih yang lebih sedikit.

Namun, nilai R² pada seluruh konfigurasi masih bernilai negatif, menandakan bahwa model belum mampu memberikan hasil prediksi yang lebih baik dibandingkan estimasi sederhana berbasis rata-rata. Nilai R² terendah mencapai -0,7316 pada konfigurasi terbaik yaitu pada proporsi 90%:10%, menunjukkan bahwa meskipun error menurun, model masih belum memiliki kemampuan generalisasi yang optimal terhadap pola harga yang kompleks. Dari sisi t-statistic dan p-value, sebagian besar konfigurasi menunjukkan p-value mendekati 0, yang berarti parameter model signifikan secara statistik. Secara keseluruhan, hasil menunjukkan bahwa *config 3* (*Num Layers 4*, *Hidden size 128*, *Dropout 0.5*, *Batch Size 128*, *Epoch 100*) dengan split data 90%:10% merupakan kombinasi paling optimal karena menghasilkan error paling kecil dan MAPE terendah.

c. SOL

Pada *dataset* SOL, dilakukan pengujian dengan tiga konfigurasi *hyperparameter* yang berbeda untuk menilai pengaruh variasi *hidden size*, *num layers*, *dropout rate*, serta persentase data latih terhadap performa prediksi.

Tabel 10. Uji Model pada SOL menggunakan DeepAR

Config	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3
Split data	60%:40%			70%:30%			80%:20%			90%:10%		
MAE	123.351	143.669		128.352		138.404	114.200			66.861		73.226
	1	2	149.068	9	88.5844	6	1	95.1786	97.9389	88.0411	6	2
RMSE		148.216	153.393		108.400	144.426	144.201	113.795	113.241	104.025	83.330	91.128
	151.815	8	6	152.873	5	8	9	6	2	4	4	4
MAPE												
	72.78%	84.72%	88.04%	72.77%	49.40%	78.14%	71.95%	57.07%	58.13%	59.37%	45.24%	49.53%
R ²												
	-17.088	-16.2407	-17.4661	-15.1122	-7.1013	-13.381	-15.7298	-9.4184	-9.3171	-31.8846	-20.101	-24.236

Config	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3	Config 1	Config 2	Config 3
Split data	60%:40%			70%:30%			80%:20%			90%:10%		
t-statistic	17.4206	74.4028	77.7596	17.9188	16.5721	54.7981	10.986	16.2617	22.0315	8.8153	7.0757	7.4245
P-value	0	0	0	0	0	0	0	0	0	0	0	0

Berdasarkan Tabel 10, terlihat bahwa performa model cenderung membaik ketika proporsi data latih meningkat, meskipun secara keseluruhan tingkat kesalahan masih relatif tinggi. Pada *config 2* (*Num Layers 4, Hidden size 32, Dropout 0.3, Batch Size 32, Epoch 25*) dengan split data 90%:10%, model mencapai nilai MAE terendah sebesar 66,86 dan RMSE sebesar 83,33, yang menunjukkan penurunan error dibandingkan konfigurasi dengan proporsi data latih yang lebih kecil.

Nilai MAPE juga memperlihatkan tren penurunan dari 72,78% pada split 60%:40% menjadi 45,24% pada split 90%:10%, yang menandakan adanya peningkatan akurasi relatif terhadap data aktual. Namun demikian, angka MAPE di atas 40% mengindikasikan bahwa model masih mengalami kesulitan dalam memprediksi pergerakan harga SOL.

Nilai R^2 pada seluruh konfigurasi masih bernilai negatif, menandakan bahwa model belum mampu memberikan hasil prediksi yang lebih baik dibandingkan estimasi sederhana berbasis rata-rata. Dari sisi t-statistic dan p-value, sebagian besar konfigurasi menunjukkan p-value mendekati 0, yang berarti parameter model signifikan secara statistik. Secara keseluruhan, hasil menunjukkan bahwa *config 2* dengan split data 90%:10% merupakan kombinasi paling optimal karena menghasilkan MAE, RMSE, dan MAPE terendah.

PEMBAHASAN

Analisis Model menggunakan algoritma TFT, *N-BEATS*, dan *DeepAR* dilakukan menggunakan metrik MAE, *RMSE*, MAPE, dan R^2 terhadap tiga aset kripto: BTC, ETH, SOL.

Tabel 11. Perbandingan Performa Terbaik per Algoritma dan Aset

Aset	Algoritma	Config & Split	MAE	RMSE	MAPE (%)	R^2
BTC	N-BEATS	2 (90%:10%)	2354.31	3012.63	2.48	0.9
BTC	TFT	2 (90%:10%)	9486.43	11122.61	9.8	-0.34
BTC	DeepAR	3 (90%:10%)	28289.35	33083.41	28.31	-10.88
ETH	N-BEATS	2 (70%:30%)	126.85	168.87	4.84	0.93
ETH	TFT	2 (90%:10%)	136.71	172.63	6.28	0.83
ETH	DeepAR	3 (90%:10%)	469.91	548.22	20.04	-0.73
SOL	N-BEATS	2 (90%:10%)	9.77	12.18	6.55	0.55
SOL	TFT	2 (90%:10%)	11.57	14.74	7.88	0.34
SOL	DeepAR	2 (90%:10%)	66.86	83.33	45.24	-1.25

N-BEATS unggul karena arsitektur *feed-forward*-nya yang secara eksplisit memisahkan komponen tren dan musiman, memungkinkan adaptasi lebih baik terhadap pola non-linear dan volatilitas tinggi pada data kripto. Sebaliknya, TFT menunjukkan performa kompetitif pada ETH dan SOL, tetapi kurang optimal pada BTC yang sangat volatil. DeepAR secara konsisten menghasilkan R^2 negatif dan MAPE tinggi, mengindikasikan ketidakmampuan model berbasis RNN dalam menangkap dinamika harga kripto yang tidak stasioner. Hal ini sejalan dengan pernyataan Chicco et al., (2021) menjelaskan bahwa nilai R^2 dapat bernilai negatif ketika model memiliki performa lebih buruk dibandingkan prediksi rata-rata (*baseline*). Pendapat lain menurut Kutner et al., (2005) R^2 dapat bernilai negatif sesuai dengan definisi statistiknya ketika model gagal menjelaskan variansi data lebih baik

daripada prediksi rata-rata historis; hal ini dijelaskan dalam *Applied Linear Statistical Models* oleh Kutner et al., (2005), yang menyatakan bahwa “ R^2 dapat bernilai negatif ketika model tidak mencakup intersep atau ketika dievaluasi pada data yang tidak digunakan dalam estimasi kondisi yang umum terjadi dalam konteks *machine learning* dan peramalan deret waktu.” Kondisi tersebut menunjukkan bahwa model tidak mampu melakukan generalisasi dengan baik terhadap data uji, sehingga error yang dihasilkan justru lebih besar daripada prediksi konstan. Dengan demikian, nilai R^2 negatif pada model DeepAR menegaskan lemahnya kemampuan model dalam merepresentasikan pola dan fluktuasi harga kripto yang bersifat sangat dinamis dan tidak stasioner.

a. Konfigurasi Optimal

Konfigurasi *hyperparameter* terbaik secara umum adalah:

Config 2:

1. *Num Layers*: 4
2. *Hidden Size*: 32
3. *Dropout*: 0.3
4. *Batch Size*: 32
5. *Epoch*: 25

Konfigurasi ini menghasilkan keseimbangan optimal antara kapasitas model dan generalisasi. Konfigurasi terlalu sederhana (*Config 1*) menyebabkan *underfitting*, sementara konfigurasi terlalu kompleks (*Config 3*) memicu *overfitting*, terutama pada split data 90%:10% untuk DeepAR dan TFT.


Pada N-BEATS, Config 2 dengan split data 90%:10% memberikan hasil terbaik untuk BTC dan SOL, sedangkan untuk ETH, split 70%:30% menghasilkan R^2 tertinggi (0.9286), menunjukkan bahwa proporsi data latih optimal bergantung pada karakteristik volatilitas aset.

b. Pengaruh Hyperparameter

1. *Hidden Size*: Ukuran 32 memberikan performa paling stabil. Ukuran terlalu kecil (8) tidak cukup menangkap kompleksitas data; terlalu besar (128) meningkatkan risiko *overfitting*.
2. *Num Layers*: Empat lapisan memberikan representasi hierarkis yang cukup tanpa menambah noise berlebihan.
3. *Dropout*: Nilai 0.3 efektif dalam mencegah *overfitting* pada model sedang; nilai 0.5 pada model besar (Config 3) tidak selalu cukup, terutama pada DeepAR.
4. *Epoch*: 25 epoch cukup untuk konvergensi stabil pada N-BEATS dan TFT; pelatihan lebih lama (100 epoch) justru memperburuk generalisasi pada DeepAR.
5. *Split Data*: Rasio 90%:10% umumnya meningkatkan akurasi pada N-BEATS, tetapi berisiko tinggi untuk DeepAR dan TFT tanpa regularisasi yang memadai.


c. Visualisasi Performa

Grafik *Train* dan *Validation Loss* menunjukkan bahwa N-BEATS mencapai konvergensi cepat dengan *loss* sangat rendah (<0.02) dan minim fluktuasi, bahkan pada split 90%:10%. Sebaliknya, DeepAR menunjukkan kesenjangan besar antara *train* dan *validation loss*, terutama pada Config 2 dan 3, mengonfirmasi *overfitting* ekstrem.



Gambar 1. Perbandingan MAPE Terbaik Tiap Algoritma

N-BEATS secara konsisten menghasilkan MAPE terendah di ketiga aset, menunjukkan akurasi prediksi relatif paling tinggi. DeepAR menunjukkan error sangat tinggi, terutama pada SOL (>45%).



Gambar 2. Grafik Perbandingan R^2 antar Konfigurasi

Gambar 2 menyajikan tiga grafik garis yang secara konsisten menunjukkan superioritas N-BEATS dalam menjelaskan variansi data pada ketiga aset kripto BTC, ETH, dan SOL dibandingkan TFT dan DeepAR. Pada semua dataset, N-BEATS mencapai nilai R^2 positif tertinggi pada Config 2 (hidden size 32, 4 layers, dropout 0.3), dengan puncak 0.90 pada BTC, 0.93 pada ETH, dan 0.55 pada SOL, mengindikasikan kemampuan generalisasi yang kuat dan akurasi prediksi yang andal. Sebaliknya, TFT menunjukkan R^2 negatif pada BTC (≤ -0.34), meskipun meningkat menjadi positif pada ETH (0.83) dan SOL (0.34) di Config 2, mencerminkan sensitivitasnya terhadap tingkat volatilitas. DeepAR secara konsisten menghasilkan R^2 negatif di seluruh konfigurasi dan aset (paling rendah -20.0 pada BTC dan SOL), menegaskan ketidakmampuan arsitektur autoregresif berbasis RNN dalam menangkap pola kompleks pada data keuangan yang sangat fluktuatif. Pola konvergensi optimal pada Config 2 di ketiga algoritma (terutama N-BEATS) menegaskan bahwa kombinasi hyperparameter menengah—bukan ekstrem—merupakan titik keseimbangan ideal antara kapasitas model dan pencegahan overfitting, sebagaimana didukung oleh prinsip optimasi deep learning dalam forecasting time-series. Secara keseluruhan, *N-BEATS* menunjukkan performa paling konsisten dan superior di ketiga aset. Ini menyatakan bahwa *N-BEATS* memiliki kemampuan prediksi finansial unggul dibanding metode tradisional dan menyajikan hasil yang lebih andal pada pola non-linier kompleks.

Sementara itu, TFT meskipun berguna untuk aset dengan pola lebih stabil seperti ETH dan SOL, gagal optimal pada aset dengan volatilitas ekstrem seperti BTC. Temuan ini menunjukkan bahwa feed-forward model seperti *N-BEATS* cenderung lebih unggul daripada arsitektur berorientasi ujung-ke-ujung seperti TFT dalam *forecasting* meskipun

dalam konteks yang berbeda (*day-ahead load forecasting*), relevansinya tetap pada perbandingan arsitektur *deep learning*.

Sedangkan performa buruk *DeepAR* pada aset kripto menunjukkan bahwa pendekatan autoregresif berbasis RNN kurang cocok untuk data dengan volatilitas ekstrem hal ini juga dicatat dalam evaluasi model *DeepAR* yang menunjukkan akurasi lebih rendah dalam kondisi volatil tinggi. Dengan demikian, dapat disimpulkan bahwa *N-BEATS* adalah algoritma paling andal untuk prediksi harga kripto karena konsistensinya dalam menghasilkan *error* rendah dan R^2 tinggi pada BTC, ETH, dan SOL. TFT tetap relevan untuk aset dengan pola harga lebih stabil, namun kurang efektif untuk aset yang sangat volatil seperti BTC. Sementara itu, *DeepAR* tidak cocok untuk memprediksi harga kripto karena keterbatasannya dalam menangani kompleksitas pola dan fluktuasi harga tinggi.

KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, maka kesimpulan yang dapat diambil sesuai dengan rumusan masalah adalah sebagai berikut:

1. Model TFT mampu memprediksi harga BTC, ETH, SOL dengan tingkat performa yang cukup baik. Hasil evaluasi menunjukkan bahwa TFT menempati posisi kedua dalam hal performa, dengan prediksi relatif stabil.
2. Model *N-BEATS* terbukti memberikan performa terbaik dalam memprediksi harga ketiga aset kripto. *N-BEATS* menghasilkan nilai MAE, RMSE, dan MAPE terendah serta R^2 tertinggi, sehingga lebih efektif dalam menangkap pola tren dan musiman pada data kripto.
3. Model *DeepAR* menunjukkan performa yang kurang optimal dalam prediksi harga BTC, ETH, SOL. *Error* yang dihasilkan cukup tinggi dan bahkan menghasilkan nilai R^2 negatif, sehingga model ini kurang direkomendasikan untuk digunakan dalam konteks prediksi aset kripto.
4. Berdasarkan perbandingan ketiga algoritma, *N-BEATS* merupakan model paling akurat dibandingkan TFT dan *DeepAR*. Hal ini menegaskan bahwa arsitektur *feed-forward* pada *N-BEATS* lebih unggul dalam menangani karakteristik data kripto yang kompleks dan fluktuatif.
5. Untuk mengimplementasikan model terbaik tersebut dalam sistem prediksi harga kripto, di mana hasil prediksi divisualisasikan dalam bentuk grafik pergerakan harga aktual dan hasil peramalan. Implementasi ini membuktikan bahwa model dapat berjalan secara fungsional serta memberikan prediksi yang mendekati nilai aktual, sehingga dapat membantu pengguna dalam melakukan analisis tren harga dan pengambilan keputusan investasi.

REFERENSI

- Asmat, G., & Maiyama, K. M. (2025). Bitcoin Price Prediction Using N-BEATs ML Technique. *ICST Transactions on Scalable Information Systems*, 12(1), 1–8. <https://doi.org/10.4108/eetsis.9006>
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, 1–24. <https://doi.org/10.7717/PEERJ-CS.623>
- CoinmarketCap. (2025). *Data Crypto*. CoinmarketCap.
- Hong, S., An, S., & Jeon, J. J. (2024). Cryptocurrency Price Forecasting using Variational Autoencoder with Versatile Quantile Modeling. *International Conference on Information and Knowledge Management, Proceedings*, 4530–4537. <https://doi.org/10.1145/3627673.3680027>
- Kraaijeveld, O., & De Smedt, J. (2020). The predictive power of public Twitter sentiment for forecasting cryptocurrency prices. *Journal of International Financial Markets*,

- Institutions and Money*, 65. <https://doi.org/10.1016/j.intfin.2020.101188>
- Kutner, M. H., Nachtsheim, C. J., Neter, J., & Li, W. (2005). *Applied Linear Statistical Models*. McGraw-Hill Irwin.
- Lim, B., Arik, S., Loeff, N., & Pfister, T. (2021). Temporal Fusion Transformers for interpretable multi-horizon time series forecasting. *International Journal of Forecasting*, 37(4), 1748–1764. <https://doi.org/10.1016/j.ijforecast.2021.03.012>
- Liu, Y., Zhong, C., Ma, Q., Jiang, Y., & Zhang, C. (2023). The S&P 500 Index Prediction Based on N-BEATS. *Proceedings of the 2nd International Academic Conference on Blockchain, Information Technology and Smart Finance (ICBIS 2023)*, 2, 923–929. https://doi.org/10.2991/978-94-6463-198-2_96
- Oreshkin, B. N., Carpo, D., Chapados, N., & Bengio, Y. (2019). N-Beats: Neural Basis Expansion Analysis for Interpretable Time Series Forecasting. *8th International Conference on Learning Representations, ICLR 2020*, 1–31.
- Salinas, D., Flunkert, V., Gasthaus, J., & Januschowski, T. (2020). DeepAR: Probabilistic forecasting with autoregressive recurrent networks. *International Journal of Forecasting*, 36(3), 1181–1191. <https://doi.org/10.1016/j.ijforecast.2019.07.001>
- Setiawan, D., Septiarini, T. W., Kurniawan, H., Terbuka, U., & Selatan, T. (2025). Systematic Literature Review: Metode Dan Teknik Peramalan Cryptocurrency. *Prosiding Seminar Nasional Sains Dan Teknologi Seri III*, 2(1), 1271–1291.
- Zahid, M. F., Fitrianto, A., Silvianti, P., & Alamudi, A. (2024). Comparison Between SARIMA and DeepAR with Optuna Hyperparameter Optimization for Estimating Rice Production Data in Indonesia. *Indonesian Journal of Statistics and Its Applications*, 8(2), 95–111. <https://doi.org/10.29244/ijsa.v8i2p95-111>