

# Perbandingan Metode *Temporal Fusion Transformer* (TFT) dan *Long Short-Term Memory* (LSTM) Dalam Prediksi Harga Saham Indonesia Berbasis Data Teknikal dan Fundamental

Nurhasan <sup>1\*</sup>, Ghufron <sup>2</sup>

<sup>1</sup> Universitas Islam Sultan Agung; 32603300014@std.unissula.ac.id

<sup>2</sup> Universitas Islam Sultan Agung; ghufronl@unissula.ac.id

## Info Artikel:

Dikirim: 20 Mei 2026

Direvisi: 02 Juni 2026

Diterima: 05 Juni 2026

**Abstract:** The Indonesian capital market exhibits a high level of volatility, requiring stock price prediction models that are accurate and adaptive. Conventional forecasting models have limitations in capturing nonlinear patterns and multivariate relationships within stock time series data. This study compares the performance of Long Short-Term Memory (LSTM) and Temporal Fusion Transformer (TFT) models in predicting stock prices of LQ45 index companies, namely BBRI, TLKM, and ADRO, with a 7-day forecasting horizon. Both models were trained using 12 combined technical and fundamental features with a data split ratio of 70:15:15. Model evaluation was conducted using Mean Absolute Error (MAE), Root Mean Square Error (RMSE), and Mean Absolute Percentage Error (MAPE). The results indicate that the TFT model achieved better performance on BBRI with a MAPE of 0.74% and TLKM with a MAPE of 0.91%, while also demonstrating faster training convergence compared to LSTM. In contrast, the LSTM model outperformed TFT on ADRO with a MAPE of 2.71%, which exhibited a relatively consistent trend pattern. Overall, TFT proved to be more effective for stocks with complex multivariate dynamics, whereas LSTM remained competitive for stocks with more stable trend patterns. The selection of prediction models should therefore consider the volatility characteristics and movement patterns of each stock issuer.

**Keywords:** Temporal Fusion Transformer; Long Short-Term Memory; Stock Price Prediction; Technical Analysis; Fundamental Analysis; LQ45.

**Intisari:** Pasar modal Indonesia memiliki tingkat volatilitas yang tinggi sehingga membutuhkan model prediksi harga saham yang akurat dan adaptif. Model prediksi konvensional memiliki keterbatasan dalam menangkap pola nonlinear dan hubungan multivariat pada data time series saham. Penelitian ini membandingkan performa model *Long Short-Term Memory* (LSTM) dan *Temporal Fusion Transformer* (TFT) dalam memprediksi harga saham indeks LQ45, yaitu BBRI, TLKM, dan ADRO, pada horizon 7 hari bursa. Kedua model dilatih menggunakan 12 fitur gabungan teknikal dan fundamental dengan rasio pembagian data sebesar 70:15:15. Evaluasi dilakukan menggunakan metrik *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). Hasil penelitian menunjukkan bahwa model TFT memberikan performa lebih baik pada saham BBRI dengan MAPE 0,74% dan TLKM dengan MAPE 0,91%, serta menunjukkan proses konvergensi pelatihan yang lebih cepat dibandingkan LSTM. Sebaliknya, model LSTM memberikan performa lebih baik pada saham ADRO dengan MAPE 2,71% yang memiliki pola tren relatif konsisten. Secara umum, TFT lebih efektif untuk saham dengan dinamika multivariat yang kompleks, sedangkan LSTM tetap kompetitif pada saham dengan pola tren yang lebih stabil. Pemilihan model prediksi perlu mempertimbangkan karakteristik volatilitas dan pola pergerakan masing-masing emiten.

**Kata Kunci:** *Temporal Fusion Transformer*; *Long Short-Term Memory*; Prediksi Harga Saham; Analisis Teknikal; Analisis Fundamental; LQ45.

## 1. Pendahuluan

Pasar modal Indonesia telah mengalami transformasi signifikan dalam beberapa tahun terakhir, yang ditandai dengan lonjakan jumlah investor domestik serta digitalisasi sistem perdagangan yang semakin masif. Fenomena ini membawa likuiditas yang lebih tinggi, namun di sisi lain juga meningkatkan kompleksitas dan volatilitas pasar yang sering kali dipengaruhi oleh sentimen makroekonomi global maupun dinamika geopolitik. Dalam kondisi pasar yang bergerak cepat dan *fluktuatif* ini, pendekatan analisis tradisional sering kali menemui jalan buntu karena tidak mampu menangkap sifat data keuangan yang tidak *linear* (*non-linear*). Oleh karena itu, kebutuhan akan model prediksi yang akurat sangat krusial bagi para pelaku pasar guna meminimalkan risiko portofolio. Secara global, berbagai penelitian menunjukkan bahwa algoritma *deep learning* memiliki kemampuan yang kompetitif dalam menangkap pola pasar saham dibandingkan pendekatan konvensional [1]. Keunggulan utama dari arsitektur berbasis kecerdasan buatan ini terletak pada fleksibilitasnya dalam memproses data mentah tanpa memerlukan rekayasa fitur manual yang rumit. Algoritma pembelajaran mesin ini juga sangat tangguh dalam menangani seleksi fitur dan menemukan pola tersembunyi pada kumpulan data keuangan yang *masif* [2]. Tren adopsi teknologi ini tidak lagi terbatas pada bursa global di Indonesia, pemodelan pasar saham berbasis *deep learning* juga mulai banyak diterapkan, khususnya untuk mengantisipasi dinamika pasar yang tidak menentu [3], [4]

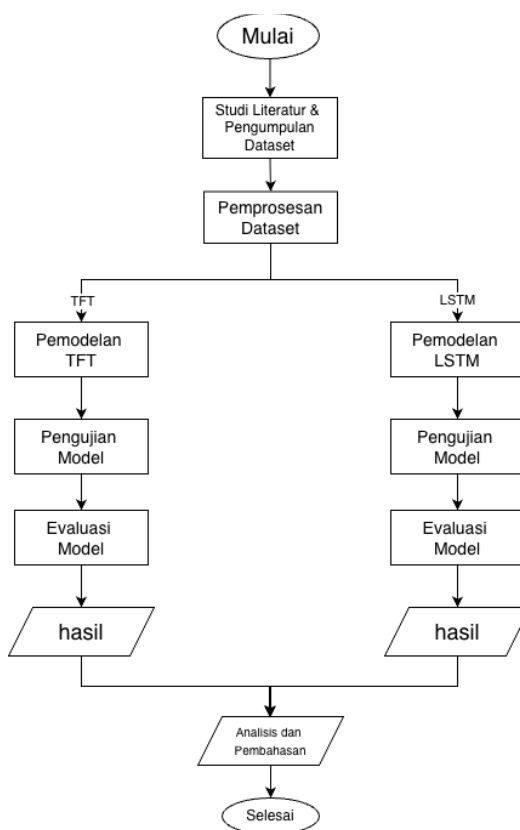
Dalam ranah arsitektur sekuensial, *Long Short-Term Memory* (LSTM) yang diperkenalkan sejak tahun 1997 [5] telah menjadi standar acuan utama untuk menangani data deret waktu. Sebelum era modern saat ini, LSTM menjadi pilihan mutlak karena kemampuannya mengatasi masalah *vanishing gradient* sebuah kondisi di mana model komputer kehilangan informasi penting dari masa lalu saat proses pelatihan jangka panjang. Kemampuan LSTM untuk memecahkan masalah memori jangka panjang menjadikannya sangat efektif di berbagai sektor keuangan, mulai dari meramalkan pergerakan strategi trading [6], merancang aplikasi prediksi harga saham harian, hingga memprediksi pergerakan aset saham berbasis syariah [7], [8]. Di ranah domestik, para peneliti terus berupaya mengoptimalkan arsitektur ini dengan menggabungkannya bersama algoritma lain, kinerja LSTM bahkan terbukti semakin baik ketika diintegrasikan menjadi model *ensemble* seperti CNN-LSTM untuk meramalkan indeks Bursa Efek Indonesia [9]. Meskipun terbukti tangguh dalam berbagai pengujian, komunitas akademis mulai menemukan batasan serius ketika model ini dihadapkan pada realitas pasar modern. Arsitektur LSTM seringkali dianggap memiliki keterbatasan dalam *interpretabilitas* model artinya, model ini bekerja layaknya "kotak hitam" yang sulit menjelaskan *variabel* apa yang paling memengaruhi keputusan prediksi. Selain itu, LSTM rentan mengalami kesulitan ketika dihadapkan pada *variabel multivariat* berdimensi tinggi yang kompleks, seperti gabungan indikator fundamental dan teknikal secara bersamaan, karena sifat pemrosesannya yang harus mengurai data secara berurutan (*step-by-step*).

Sebagai solusi atas batasan tersebut, muncul sebuah paradigma baru bernama *Temporal Fusion Transformer* (TFT) yang dirancang dengan menggabungkan mekanisme pemrosesan memori dan lapisan *multi-head attention*. Berbeda dengan LSTM yang cenderung memperlakukan semua data masa lalu dengan bobot yang seragam, TFT mampu memberikan "perhatian" lebih pada titik waktu atau *variabel* tertentu yang paling relevan. Kemampuan TFT untuk memilih dan memilih variabel yang paling berpengaruh (*variable selection*) terbukti sukses memprediksi *realized volatility* di masa turbulensi pasar [10] serta mengoptimalkan penilaian performa saham dan portofolio secara holistik [11]. *Fleksibilitas* ini membuat TFT menjadi senjata yang sangat kuat untuk menangani data yang bising (*noisy*). Selain itu, fleksibilitas arsitektur TFT telah terbukti secara empiris sangat efisien dalam memproses gabungan indikator teknikal dengan data eksternal lainnya untuk merancang strategi perdagangan di berbagai aset keuangan yang sangat *volatil* [12] serta tangguh ketika diterapkan pada pengkategorian sub-seri waktu untuk menangkap tren spesifik secara lebih presisi [13]. Di Indonesia sendiri, penelitian mengenai penggunaan *Temporal Fusion Transformer* pada prediksi harga saham *multivariat* juga mulai berkembang dan menunjukkan hasil yang kompetitif [14]. Bersama dengan tren peramalan probabilistik canggih lainnya seperti *Lag-Llama* [15], TFT menunjukkan potensi dalam meningkatkan kemampuan pemodelan *time series multivariat* pada data keuangan, membuka babak baru dalam analisis prediktif yang lebih transparan dan akurat.

Meskipun demikian, terdapat sebuah kesenjangan (*gap*) penelitian yang belum terisi di dalam literatur akademik saat ini. Kajian yang secara khusus membandingkan ketangguhan TFT dan LSTM dengan menggabungkan rasio fundamental (yang mencerminkan nilai intrinsik perusahaan) dan indikator teknikal (yang mencerminkan momentum pasar) pada indeks Liquid 45 (LQ45) masih sangat terbatas. Oleh karena itu, penelitian ini bertujuan untuk menguji dan membandingkan performa model LSTM dan TFT dalam memprediksi harga saham tiga emiten yang mewakili sektor strategis berbeda di LQ45, yaitu BBRI (perbankan), TLKM (telekomunikasi), dan ADRO (energi/komoditas), pada horizon 7 hari bursa ke depan. Melalui perbandingan *head-to-head* ini, penelitian ini diharapkan dapat memberikan kesimpulan utama mengenai sejauh mana mekanisme *attention* pada TFT mampu mengungguli dependensi sekuensial pada LSTM dalam mengekstrak fitur *multivariat*, sehingga dapat menjadi sistem pendukung keputusan yang akurat bagi para investor untuk menghadapi ketidakpastian pasar bursa.

## 2. Metode Penelitian

Penelitian ini menggunakan metode kuantitatif komparatif dengan pendekatan eksperimental untuk membandingkan performa dua arsitektur deep learning, yaitu *Long Short-Term Memory* (LSTM) dan *Temporal Fusion Transformer* (TFT) dalam prediksi harga saham. Alur penelitian yang digunakan ditunjukkan pada Gambar 1.



Gambar 1. Flowchart Alur Penelitian

Berdasarkan Gambar 1, penelitian diawali dengan studi literatur dan pengumpulan dataset saham. Tahapan selanjutnya adalah *preprocessing* data yang meliputi pembersihan data, perhitungan indikator teknikal, normalisasi, dan pembentukan *sequence* data. Setelah itu, model LSTM dan TFT dikembangkan dan dilatih menggunakan dataset yang sama. Kedua model kemudian diuji menggunakan data testing dan dievaluasi menggunakan metrik MAE, RMSE, dan MAPE. Hasil evaluasi digunakan untuk menganalisis performa masing-masing model hingga diperoleh kesimpulan penelitian.

### 2.1. Dataset dan Pemrosesan Data

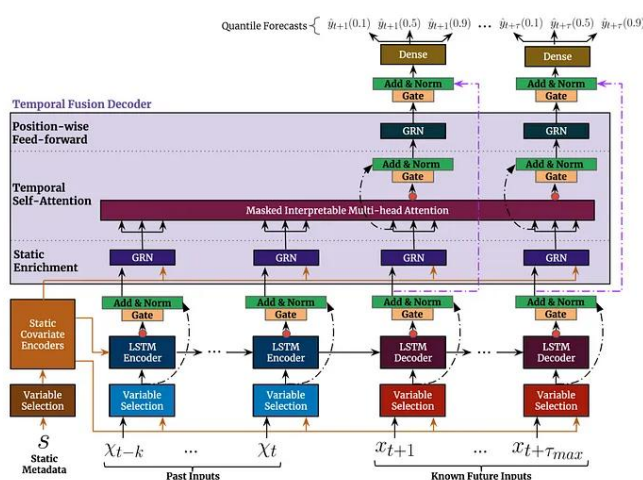
Penelitian ini menggunakan data harian dari tiga emiten indeks LQ45, yaitu BBRI, TLKM, dan ADRO, dengan periode Januari 2019 hingga Desember 2025. Dataset terdiri dari sekitar 1.704–1.705 observasi untuk setiap emiten. Penelitian menggunakan 12 variabel yang terdiri atas 9 fitur teknikal, yaitu *Close*, *Volume*, *EMA20*, *EMA50*, *RSI14*, *MACD Line*, *MACD Signal*, *MACD Histogram*, dan *VWMA14*, serta 3 fitur fundamental kuartalan berupa *EPS*, *ROE*, dan *PER*. Data fundamental diselaraskan ke data harian menggunakan teknik *forward-fill*.

Proses prapemrosesan data meliputi pembersihan missing value, normalisasi data, dan pembentukan *sequence* data. Normalisasi pada model LSTM menggunakan *Min-Max Scaler*, sedangkan model TFT menggunakan *StandardScaler*. Dataset kemudian dibagi secara kronologis menjadi 70% data latih, 15% data validasi, dan 15% data uji. Data dibentuk menggunakan *lookback window* sepanjang 90 hari untuk memprediksi harga saham pada horizon 7 hari bursa ke depan.

## 2.2 Perancangan Arsitektur Model


Kedua model dikonfigurasi dengan *lookback window* sepanjang 90 hari untuk memprediksi *horizon* 7 hari bursa ke depan.

1. Model TFT: diimplementasikan menggunakan *hidden size* sebesar 64, 4 *attention heads*, 2 layer LSTM internal, dan *dropout* sebesar 0.2. Proses optimasi menggunakan *optimizer Adam* dengan fungsi kerugian *QuantileLoss*. Arsitektur TFT memanfaatkan komponen *Gated Residual Network (GRN)*, *Variable Selection Network (VSN)*, serta *Multi-Head Attention Layer* untuk memproses hubungan temporal multivariat secara adaptif. Selain fitur teknis dan fundamental, model TFT juga menggunakan fitur temporal berbasis kalender seperti *day of week*, *month*, serta penanda awal dan akhir bulan untuk membantu mendeteksi pola musiman pada data saham. Arsitektur TFT yang digunakan pada penelitian ini ditunjukkan pada Gambar 2.



Gambar 2. Arsitektur Model TFT

2. Model LSTM: dibangun menggunakan dua layer LSTM dengan masing-masing 128 unit *neuron*, diikuti oleh *layer Dense* berukuran 64 unit dan *dropout* sebesar 0.2 untuk mengurangi *overfitting*. Model dioptimasi menggunakan *optimizer Adam* dengan fungsi kerugian *Huber Loss*. Arsitektur LSTM yang digunakan pada penelitian ini ditunjukkan pada Gambar 3.



Gambar 3. Arsitektur Model LSTM

## 2.3 Evaluasi Model Prediksi

Untuk menilai dan membandingkan performa akurasi prediksi dari model LSTM dan TFT, penelitian ini menggunakan tiga metrik evaluasi utama, yaitu *Mean Absolute Error (MAE)*, *Root Mean Square Error (RMSE)*, dan *Mean Absolute Percentage Error (MAPE)* Ketiga metrik tersebut dipilih karena mampu mengukur tingkat kesalahan prediksi baik dalam bentuk nilai absolut maupun persentase relatif terhadap data aktual.

- *Mean Absolute Error (MAE)*

MAE digunakan untuk mengukur rata-rata selisih absolut antara nilai aktual dan nilai prediksi tanpa memperhatikan arah kesalahan. Semakin kecil nilai MAE, maka semakin baik kemampuan model dalam melakukan prediksi

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \tag{1}$$

- *Root Mean Square Error (RMSE)*  
 RMSE mengukur akar rata-rata kuadrat error antara nilai aktual dan nilai prediksi. Metrik ini memberikan penalti yang lebih besar terhadap kesalahan prediksi yang tinggi, sehingga lebih sensitif terhadap outlier atau fluktuasi ekstrem pada harga saham.

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

- *Mean Absolute Percentage Error (MAPE)*  
 MAPE digunakan untuk mengukur persentase rata-rata kesalahan prediksi terhadap nilai aktual. Persamaan MAPE ditunjukkan pada Persamaan

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \tag{3}$$

Keterangan :

- $n$ = jumlah data pengujian
- $y_i$ = nilai aktual harga saham
- $\hat{y}_i$ = nilai prediksi harga saham

Semakin kecil nilai MAE, RMSE, dan MAPE, maka semakin baik performa model dalam memprediksi harga saham.

### 3. Hasil dan Pembahasan

Hasil pengujian terhadap data uji (*test set*) menunjukkan adanya perbedaan kecepatan *konvergensi* antara kedua model. Model TFT mencapai *konvergensi* pada *epoch* ke-4 sebelum dihentikan oleh mekanisme *Early Stopping*. Sementara itu, model LSTM membutuhkan jumlah *epoch* pelatihan yang berbeda pada setiap saham, yaitu BBRI pada *epoch* ke-37, TLKM pada *epoch* ke-15, dan ADRO pada *epoch* ke-11. Perbandingan metrik kinerja *Mean Absolute Error (MAE)*, *Root Mean Square Error (RMSE)*, dan *Mean Absolute Percentage Error (MAPE)* ditampilkan pada Tabel 1.

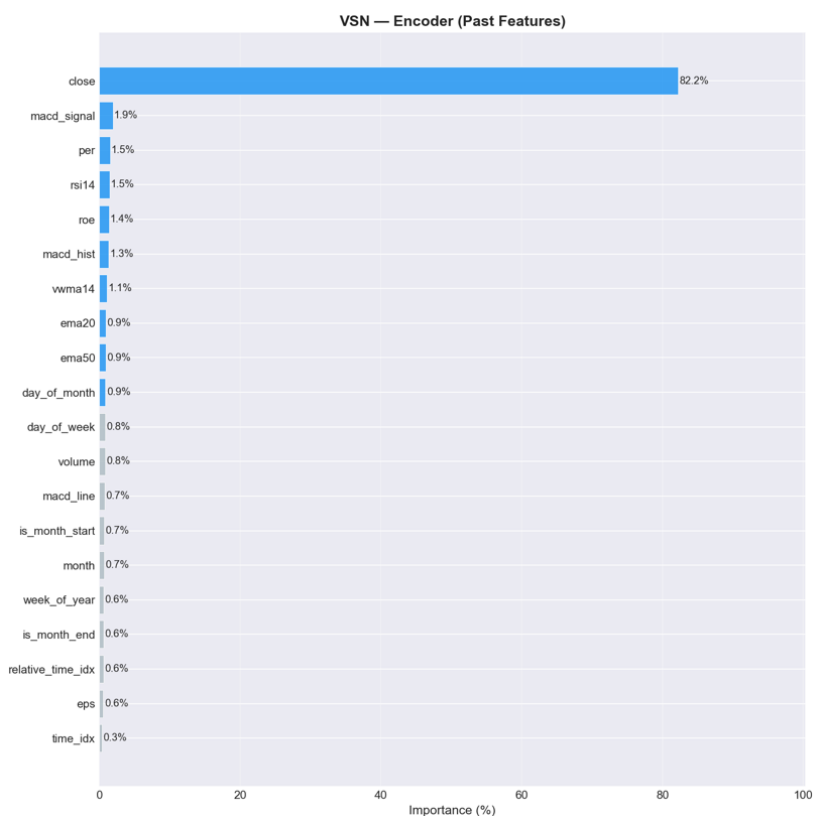
**Tabel 1.** Hasil matrik evaluasi model TFT dan LSTM

Emiten	TFT			LSTM		
	MAE	RMSE	MAPE	MAE	RMSE	MAPE
BBRI	27.68	36.58	0.74	32.18	49.79	0.86
TLKM	31.70	38.59	0.91	80.73	89.27	2.33
ADRO	79.45	87.13	4.16	51.76	58.56	2.71

Berdasarkan Tabel 1, model TFT menunjukkan performa lebih baik dibandingkan LSTM pada saham BBRI dan TLKM. Perbedaan performa paling signifikan terlihat pada saham TLKM dengan nilai MAPE sebesar 0,91% pada TFT dan 2,33% pada LSTM. Hasil ini mengindikasikan bahwa mekanisme *self-attention* pada TFT mampu menangkap hubungan temporal *multivariat* secara lebih efektif dibandingkan arsitektur *recurrent* tradisional, sebaliknya, pada saham sektor komoditas yaitu ADRO, model LSTM memberikan performa lebih baik dibandingkan TFT dengan nilai MAPE sebesar 2,71%, sedangkan TFT memperoleh nilai MAPE sebesar 4,16%. Kondisi ini menunjukkan bahwa pola tren penurunan yang relatif konsisten pada saham ADRO masih dapat dipelajari secara efektif oleh arsitektur sekuensial LSTM.

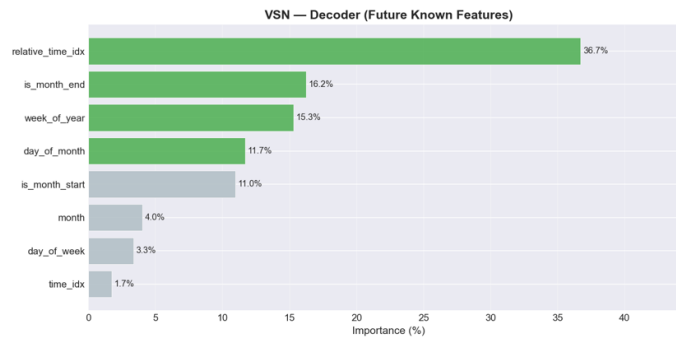
Selain itu, model TFT menunjukkan proses konvergensi yang lebih cepat dibandingkan LSTM. Hal ini mengindikasikan bahwa TFT memiliki efisiensi pembelajaran yang lebih baik dalam memproses data *time series multivariat* berbasis indikator teknikal dan fundamental. Kemampuan tersebut juga didukung oleh mekanisme *Variable Selection Network* (VSN) yang memungkinkan model memberikan bobot adaptif terhadap fitur-fitur input yang paling relevan selama proses pelatihan.

Berdasarkan hasil analisis VSN pada *encoder* yang ditunjukkan pada Gambar 4, fitur harga penutupan (*Close*) memberikan kontribusi dominan sebesar 82,2%. Hasil ini menunjukkan bahwa informasi historis harga saham menjadi faktor utama dalam proses pembelajaran pola deret waktu oleh model TFT. Sementara itu, fitur teknikal dan fundamental lainnya memberikan kontribusi yang lebih kecil sebagai informasi pendukung dalam membentuk representasi kontekstual model.



Gambar 4. Hasil *Variable Selection Network* (VSN) pada Encoder

Pada tahap decoder yang ditunjukkan pada Gambar 5, fitur *relative\_time\_idx* memberikan kontribusi terbesar sebesar 36,7%, diikuti oleh beberapa fitur kalender seperti *is\_month\_end*, *week\_of\_year*, dan *day\_of\_month*. Temuan ini mengindikasikan bahwa model TFT mampu memanfaatkan pola temporal dan musiman dalam proses prediksi multi-horizon.



Gambar 5. Hasil Variable Selection Network (VSN) PADA Decoder

## 5. Kesimpulan

Pada Penelitian ini membandingkan performa algoritma *Long Short-Term Memory* (LSTM) dan *Temporal Fusion Transformer* (TFT) dalam memprediksi harga saham pada emiten indeks LQ45, yaitu BBRI, TLKM, dan ADRO, menggunakan kombinasi fitur teknikal dan fundamental. Hasil penelitian menunjukkan bahwa model TFT memberikan performa lebih baik pada saham dengan pola volatilitas yang lebih kompleks seperti BBRI dan TLKM, serta menunjukkan proses konvergensi pelatihan yang lebih cepat dibandingkan LSTM. Sebaliknya, model LSTM memberikan hasil yang lebih baik pada saham ADRO yang memiliki pola tren penurunan relatif konsisten.

Secara umum, penelitian ini menunjukkan bahwa tidak terdapat satu model yang secara absolut unggul pada seluruh kondisi pasar saham. Pemilihan model prediksi perlu mempertimbangkan karakteristik tren, volatilitas, serta sektor dari masing-masing emiten. Penelitian selanjutnya dapat mengembangkan model dengan menambahkan variabel makroekonomi, sentimen pasar, maupun data time series dengan periode yang lebih panjang untuk meningkatkan performa prediksi.

## Daftar Pustaka

- [1] G. L. Gil, P. Duhamel-Seblin, and A. McCarren, "An Evaluation of Deep Learning Models for Stock Market Trend Prediction," Aug. 2024, [Online]. Available: <http://arxiv.org/abs/2408.12408>
- [2] J. Park and M. Shin, "An Approach for Variable Selection and Prediction Model for Estimating the Risk-Based Capital (RBC) Based on Machine Learning Algorithms," *Risks*, vol. 10, no. 1, Jan. 2022, doi: 10.3390/risks10010013.
- [3] W. Budiharto, "Data science approach to stock prices forecasting in Indonesia during Covid-19 using Long Short-Term Memory (LSTM)," *J. Big Data*, vol. 8, no. 1, Dec. 2021, doi: 10.1186/s40537-021-00430-0.
- [4] A. Arfan and dan Lussiana ETP, "Prediksi Harga Saham Di Indonesia Menggunakan Algoritma Long Short-Term Memory," *Universitas Gunadarma Jl. Margonda Raya No*, vol. 3, no. 1, 2019, [Online]. Available: <https://www.ofx.com>
- [5] Sepp Hochreiter and Jürgen Schmidhuber, "long short term memori".
- [6] Y. Touzani and K. Douzi, "An LSTM and GRU based trading strategy adapted to the Moroccan market," *J. Big Data*, vol. 8, no. 1, Dec. 2021, doi: 10.1186/s40537-021-00512-z.
- [7] C. Genta, K. Simatupang, W. Swastika, and T. R. Suganda, "PERANCANGAN APLIKASI BERBASIS WEB UNTUK PREDIKSI HARGA SAHAM DENGAN METODE LSTM," 2022.
- [8] D. I. Puteri, "Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah," *Euler : Jurnal Ilmiah Matematika, Sains dan Teknologi*, vol. 11, no. 1, pp. 35–43, May 2023, doi: 10.34312/euler.v11i1.19791.
- [9] H. Widiputra, A. Mailangkay, and E. Gautama, "Prediksi Indeks BEI dengan Ensemble Convolutional Neural Network dan Long Short-Term Memory," *Jurnal RESTI*, vol. 5, no. 3, pp. 456–465, Jun. 2021, doi: 10.29207/resti.v5i3.3111.
- [10] J. Frank and F. Erlangen-Nürnberg, "Forecasting Realized Volatility in Turbulent Times using Temporal Fusion Transformers," 2023, [Online]. Available: <https://www.iwf.rw.fau.de/discussion-papers/>
- [11] J. Yang, P. Li, Y. Cui, X. Han, and M. Zhou, "Multi-Sensor Temporal Fusion Transformer for Stock Performance Prediction: An Adaptive Sharpe Ratio Approach," *Sensors*, vol. 25, no. 3, Feb. 2025, doi: 10.3390/s25030976.

- [12] M. C. Lee, "Temporal Fusion Transformer-Based Trading Strategy for Multi-Crypto Assets Using On-Chain and Technical Indicators," *Systems*, vol. 13, no. 6, Jun. 2025, doi: 10.3390/systems13060474.
- [13] A. Peik, M. Ali Zare Chahooki, A. Milani Fard, and M. Agha Sarram, "The 38th Canadian Conference on Artificial Intelligence Enhancing Cryptocurrency Price Prediction by Applying Temporal Fusion Transformers on Subseries," 2025. [Online]. Available: <https://github.com/arashitc2/tft-on-subseries-for-cryptocurrency-forecasting>
- [14] S. Hartanto, A. Agung, and S. Gunawan, "Temporal Fusion Transformers for Enhanced Multivariate Time Series Forecasting of Indonesian Stock Prices," *IJACSA) International Journal of Advanced Computer Science and Applications*, vol. 15, no. 7, p. 2024, 2024, [Online]. Available: [www.ijacsa.thesai.org](http://www.ijacsa.thesai.org)
- [15] A. Hanafiah, W. Monika, M. Sham Mohamad, and A. Alamsyah, "Assessing Lag-Llama in Probabilistic Time Series Forecasting for the Indonesian Stock Market Arbi Haza Nasution," 2025. [Online]. Available: <https://github.com/>