
PREDIKSI HARGA XAUUSD PADA TIMEFRAME 1 MENIT MENGUNAKAN LSTM DAN TCN

Gilbert Letan¹, Meinahen Budi Bansoma², Hanna M. Baun³, Paulus kusuma dewata hoka djoka⁴

Universitas Citra Bangsa, Kupang

e-mail: ¹letangilbert@gmail.com; ²patointer12@gmail.com, ³hannabaun06@gmail.com, ⁴ciptawidyakarya@gmail.com

Abstract: *The increasing complexity of financial markets, particularly in high-frequency trading environments, presents significant challenges in accurately forecasting asset price movements. XAUUSD price data at the 1-minute timeframe is characterized by high volatility, non-linearity, non-stationarity, and substantial noise, making it difficult to model using conventional statistical approaches. This study aims to conduct a comparative analysis of Long Short-Term Memory (LSTM) and Temporal Convolutional Network (TCN) models in predicting XAUUSD prices. A quantitative experimental approach is employed using the CRISP-DM framework, encompassing data understanding, preparation, modeling, and evaluation stages. The dataset consists of historical XAUUSD data obtained from MetaTrader 5. Preprocessing steps include data cleaning, feature engineering with technical indicators (EMA, RSI, ATR), and transformation of both input features and the prediction target into log-return form to address the non-stationarity of raw price-level data, confirmed empirically through an Augmented Dickey-Fuller test. Data was chronologically split into training (70%), validation (15%), and testing (15%) sets, with the scaler fitted exclusively on training data to prevent data leakage. Model performance is evaluated using MAE, RMSE, MAPE, and Directional Accuracy, and benchmarked against a naive no-change baseline. The results indicate that TCN achieves modestly lower error than LSTM (MAE: 1.0689; RMSE: 1.5729; MAPE: 0.0244% vs. LSTM's MAE: 1.3883; RMSE: 1.8304; MAPE: 0.0316%). However, TCN's performance is nearly identical to the naive baseline (MAE: 1.0688; RMSE: 1.5728; MAPE: 0.0244%), while LSTM performs slightly worse than it. Both models achieve Directional Accuracy near 49%, statistically indistinguishable from random guessing. These findings are consistent with the Random Walk Hypothesis at very short time horizons and highlight the importance of naive baseline comparisons when evaluating deep learning models for high-frequency financial forecasting.*

Keywords: XAUUSD, Time Series Forecasting, Deep Learning, LSTM, TCN, Random Walk Hypothesis, Naive Baseline

Abstrak: Kompleksitas pasar keuangan yang semakin meningkat, khususnya pada lingkungan perdagangan frekuensi tinggi, menghadirkan tantangan signifikan dalam memprediksi pergerakan harga aset secara akurat. Data harga XAUUSD pada timeframe 1 menit memiliki karakteristik volatilitas tinggi, non-linearitas, non-stasioneritas, dan noise yang substansial, sehingga sulit dimodelkan menggunakan pendekatan statistik konvensional. Penelitian ini bertujuan untuk melakukan analisis komparatif terhadap model Long Short-Term Memory (LSTM) dan Temporal Convolutional Network (TCN) dalam memprediksi harga XAUUSD. Pendekatan eksperimental kuantitatif digunakan dengan kerangka kerja CRISP-DM, yang mencakup tahap data understanding, data preparation, modeling, dan evaluation. Dataset terdiri atas data historis XAUUSD yang diperoleh dari MetaTrader 5. Tahapan pra-pemrosesan meliputi pembersihan data, feature engineering dengan indikator teknikal (EMA, RSI, ATR), serta transformasi fitur input dan target prediksi ke dalam bentuk log-return untuk mengatasi non-stasioneritas data harga level, yang dikonfirmasi secara empiris melalui uji Augmented Dickey-Fuller. Data

dibagi secara kronologis menjadi data training (70%), validation (15%), dan testing (15%), dengan proses scaling yang hanya di-fit pada data training untuk mencegah data leakage. Performa model dievaluasi menggunakan MAE, RMSE, MAPE, dan Directional Accuracy, serta dibandingkan terhadap baseline naif no-change. Hasil penelitian menunjukkan bahwa TCN menghasilkan error yang sedikit lebih rendah dibandingkan LSTM (MAE: 1,0689; RMSE: 1,5729; MAPE: 0,0244% berbanding LSTM dengan MAE: 1,3883; RMSE: 1,8304; MAPE: 0,0316%). Namun, performa TCN hampir identik dengan baseline naif (MAE: 1,0688; RMSE: 1,5728; MAPE: 0,0244%), sedangkan LSTM justru tampil sedikit lebih buruk darinya. Kedua model menghasilkan Directional Accuracy mendekati 49%, yang secara statistik tidak dapat dibedakan dari tebakan acak. Temuan ini konsisten dengan Random Walk Hypothesis pada horizon waktu yang sangat pendek, serta menegaskan pentingnya perbandingan terhadap baseline naif dalam mengevaluasi model deep learning untuk peramalan finansial frekuensi tinggi.

Kata kunci: XAUUSD, Peramalan Time Series, Deep Learning, LSTM, TCN, Random Walk Hypothesis, Baseline Naif

PENDAHULUAN

Pasar keuangan global, khususnya instrumen emas (XAUUSD), merupakan salah satu instrumen dengan tingkat likuiditas tinggi dan volatilitas yang signifikan. Pada timeframe 1 menit, data harga termasuk dalam kategori high-frequency data yang memiliki karakteristik kompleks, seperti fluktuasi cepat, noise tinggi, serta pola yang tidak stabil dari waktu ke waktu. Kondisi ini menyebabkan pendekatan tradisional berbasis statistik, yang umumnya mengasumsikan linearitas dan stasioneritas, menjadi kurang efektif dalam menghasilkan prediksi yang akurat.

Dalam beberapa tahun terakhir, perkembangan deep learning telah memberikan alternatif yang lebih adaptif dalam memodelkan data time series yang kompleks. Model Long Short-Term Memory (LSTM) banyak digunakan karena kemampuannya dalam menangkap dependensi jangka panjang melalui mekanisme memori internal (Hochreiter & Schmidhuber, 1997). (Fischer & Krauss, 2018) menunjukkan bahwa LSTM unggul dibandingkan model machine learning konvensional seperti Random Forest dan Gradient Boosting dalam memprediksi arah pergerakan harian indeks S&P 500. Namun, pada data dengan volatilitas tinggi, model

berbasis recurrent ini cenderung mengalami overfitting serta kurang responsif terhadap perubahan pola yang cepat.


Sebagai alternatif, Temporal Convolutional Network (TCN) hadir dengan pendekatan berbasis convolution yang memanfaatkan dilated convolution untuk memperluas receptive field, sehingga mampu menangkap pola jangka panjang tanpa mengorbankan efisiensi komputasi. (Borovykh et al., 2017) membuktikan bahwa arsitektur konvolusi berbasis WaveNet mampu mengungguli model autoregresif maupun LSTM dalam peramalan deret waktu finansial, sementara (Bai et al., 2018) secara empiris menunjukkan bahwa TCN secara konsisten mengungguli arsitektur recurrent klasik pada berbagai tugas pemodelan sequence.

Meskipun studi-studi tersebut secara konsisten melaporkan keunggulan TCN atau model berbasis konvolusi dibandingkan LSTM, sebagian besar evaluasi dilakukan murni berdasarkan metrik error (MAE, RMSE, MAPE) tanpa dibandingkan terhadap baseline naif (no-change) sebagai acuan minimum kemampuan prediktif. Pada data finansial dengan horizon prediksi yang sangat pendek seperti timeframe 1 menit, nilai error yang tampak kecil berpotensi menyesatkan apabila tidak diuji terhadap

kemungkinan bahwa model sekadar mereplikasi pola "harga tidak berubah", sebuah fenomena yang konsisten dengan Random Walk Hypothesis (Fama, 1970). Celah inilah yang menjadi fokus penelitian ini: membandingkan performa LSTM dan TCN dalam memprediksi harga XAUUSD pada timeframe 1 menit, sekaligus mengevaluasi kedua model secara eksplisit terhadap baseline naif dan metrik Directional Accuracy, untuk memperoleh gambaran yang lebih proporsional mengenai kemampuan prediktif riil kedua model pada data finansial berfrekuensi tinggi.

METODE

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan desain time series forecasting (Creswell, 2014) dan (Hyndman & Athanasopoulos, 2021; Tsay, 2010). Data yang digunakan merupakan data historis XAUUSD timeframe 1 menit sebanyak 100.000 data dengan variabel OHLC (Novianto & Wibowo, 2023).

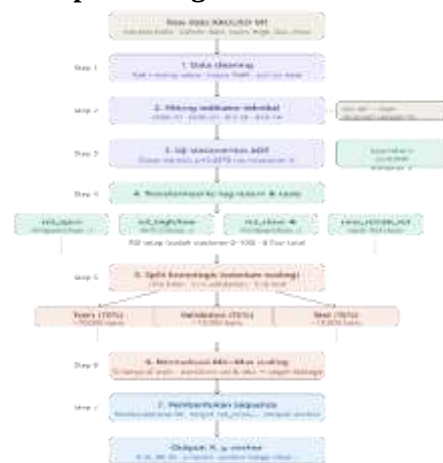


Gambar 1 Alur Penelitian

Gambar 1 menunjukkan alur penelitian yang digunakan dalam

pengembangan model prediksi harga XAUUSD menggunakan Long Short-Term Memory (LSTM) dan Temporal Convolutional Network (TCN). Penelitian diawali dengan pengumpulan data historis XAUUSD timeframe 1 menit dari platform MetaTrader 5. Selanjutnya dilakukan tahap *data preprocessing* yang mencakup *data cleaning*, *feature engineering*, transformasi data, normalisasi, pembentukan data sekuens menggunakan metode *sliding window*, serta pembagian data secara kronologis menjadi data *training*, *validation*, dan *testing*. Dataset yang telah diproses kemudian digunakan untuk melatih model LSTM dan TCN. Tahap terakhir adalah evaluasi performa kedua model menggunakan metrik MAE, RMSE, MAPE, *Directional Accuracy*, serta perbandingan terhadap *naive baseline* (*no-change*) untuk memperoleh model dengan kinerja terbaik.

1.1 Preprocessing Data



Gambar 2 Diagram Tahapan Preprocessing Data

Tahap preprocessing data dalam penelitian ini dilakukan melalui tujuh langkah berurutan sebagaimana ditunjukkan pada Gambar 2, yang masing-masing dijelaskan pada bagian berikut.

Data Cleaning

Pertama, data historis XAUUSD M1 sebanyak 100.000 baris dibersihkan

dari nilai yang hilang dan diurutkan secara kronologis.

Feature Engineering

Kedua, dihitung empat indikator teknikal: EMA 20, EMA 50, RSI 14, dan ATR 14 (Murphy, 1999; Wilder, 1978) dengan penanganan khusus pada kondisi RSI tak hingga (*inf*) yang dikonversi ke NaN sebelum *dropna()*.

Uji ADF

Ketiga, dilakukan uji stasioneritas *Augmented Dickey-Fuller* (ADF) yang mengonfirmasi bahwa harga *close* mentah bersifat non-stasioner ($p=0,2878$), sedangkan *log-return*-nya stasioner ($p\approx 0,000$), sehingga menjadi dasar statistik formal untuk transformasi fitur.

Tabel 1 Uji ADF

Series	ADF Statistic	p-value	Kesimpulan
Close Mentah	-1,9972	0,2878	Non-stasioner
Log Return Close	-53,7172	$\approx 0,000$	Stasioner

Konversi Ke Log Return

Tabel 2 Normalisasi Data

ret_open	ret_high	ret_low	ret_close	ema20_re	ema50_re	rsi	atr_rel
0.727599078	0.512300014	0.735300004	0.529100001	0.707099074	0.726400008	0.539690972	0.078299099
0.727599078	0.504999095	0.726000011	0.519800007	0.695400000	0.718599905	0.500500023	0.076300003
0.726300001	0.506399089	0.736299092	0.527999097	0.690699095	0.715499907	0.540300012	0.072400004

Sliding Window

Ketujuh, data yang telah dinormalisasi dibentuk menjadi *sequence* menggunakan teknik *sliding window* dengan panjang 90 (Gambar 4), di mana setiap *sequence* menyimpan nilai *log-return close* bar berikutnya sebagai target prediksi (y) serta harga *close* aktual bar sebelumnya sebagai titik jangkar (*anchor*) yang digunakan pada tahap evaluasi untuk merekonstruksi prediksi kembali ke skala harga absolut melalui rumus $\text{harga}_{(t)} =$

Keempat, seluruh fitur OHLC diubah ke bentuk *log-return* terhadap harga *close* bar sebelumnya $\ln(\text{harga}_{(t)}/\text{harga}_{(t-1)})$ sementara EMA diubah menjadi rasio relatif terhadap harga *close* dan ATR menjadi volatilitas relatif; RSI tidak diubah karena nilainya sudah stasioner secara alami pada rentang 0–100.

Data Split

Kelima, data dibagi secara kronologis menjadi *training* (70%), *validation* (15%), dan *testing* (15%) sebelum proses normalisasi, untuk memastikan tidak ada informasi masa depan yang bocor/




Gambar 3 Data Split

Normalisasi Data

Keenam, normalisasi Min-Max *scaling* diterapkan dengan proses *fit* hanya pada data *training*, kemudian parameter yang sama di-*transform* ke data *validation* dan *testing* untuk mencegah *data leakage*.

$$\text{harga}_{(t-1)} \times e^{\text{r}}$$



Gambar 4 Ilustrasi Pembentukan Sequence dengan Sliding Window

Hyperparameter Model

Parameter model yang digunakan meliputi:

Tabel 3 Hyperparameter

Parameter	LSTM	TCN
Arsitektur	BiLSTM(64)+LSTM(32)	TCN(32 filter dilasi [1,2,4,8,16])
Optimizer / LR	Adam / 0,001	Adam / 0,001
Batch / Epoc	32 / 25 (early stopping p=5)	32 / 25 (early stopping p=5)
Window	90	90
Total param	59.073	30.113

Kedua model dibangun menggunakan framework Keras dengan hyperparameter yang disamakan untuk memastikan perbandingan yang adil. Model LSTM menggunakan arsitektur Bidirectional LSTM (Hochreiter & Schmidhuber, 1997) dengan 64 unit, dilanjutkan lapisan LSTM 32 unit, masing-masing diselengi Dropout 0,2, dan diakhiri lapisan Dense 32 unit (ReLU) serta output tunggal. Model TCN menggunakan satu lapisan TCN (Bai et al., 2018) dengan 32 filter, kernel size 3, dan dilasi [1, 2, 4, 8, 16], diikuti lapisan Dense 32 unit (ReLU) dan output tunggal. Kedua model dikompilasi dengan optimizer Adam (Kingma & Ba, 2015), learning rate 0,001, dan loss MSE, dilatih dengan batch size 32, maksimum 25 epoch, EarlyStopping (patience 5), dan ReduceLROnPlateau (patience 2). Total parameter LSTM sebesar 59.073 berbanding TCN sebesar 30.113, menunjukkan bahwa TCN mampu menangkap dependensi temporal secara lebih efisien dengan jumlah parameter yang lebih sedikit.

Metrik Evaluasi

Evaluasi dilakukan menggunakan empat metrik yaitu: MAE, RMSE, dan MAPE (Hyndman & Koehler, 2006), dilengkapi dengan Directional Accuracy serta perbandingan terhadap baseline naif (no-change) sebagai acuan minimum kemampuan prediktif.

Pertama, *Mean Absolute Error* (MAE) mengukur rata-rata selisih absolut antara nilai aktual dan prediksi:

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

Kedua, *Root Mean Squared Error* (RMSE) mengukur akar rata-rata kuadrat selisih, memberikan bobot lebih besar pada error yang besar:

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

Ketiga, *Mean Absolute Percentage Error* (MAPE) mengukur rata-rata persentase selisih relatif terhadap nilai aktual (Hyndman & Koehler, 2006):

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

Keempat, *Directional Accuracy* (DA) mengukur persentase seberapa sering arah pergerakan yang diprediksi sesuai dengan arah aktual:


$$DA = \frac{1}{n} \sum_{t=1}^n \mathbb{1}[\text{sign}(r_t) = \text{sign}(\hat{r}_t)] \times 100\%$$

di mana r_t adalah log-return aktual dan $\hat{r}_t$ adalah log-return hasil prediksi pada waktu t . Nilai DA sebesar 50% setara dengan tebakan acak. Selain keempat metrik tersebut, seluruh hasil dibandingkan terhadap *baseline* naif *no-change* sebagai acuan minimum kemampuan prediktif.


Karena target prediksi berupa log-return, nilai $\hat{y}_i$ pada formula MAE, RMSE, dan MAPE diperoleh melalui rekonstruksi terlebih dahulu menggunakan rumus harga $(t) = \text{harga}_{(t-1)} \times e^r$, sehingga ketiga metrik tersebut tetap dilaporkan dalam satuan harga (USD).

HASIL DAN PEMBAHASAN

Training Model



Gambar 5 LSTM Training



Gambar 6 TCN Training

Model LSTM menunjukkan penurunan training loss yang tajam dari sekitar 0,0014 menjadi sekitar 0,0007 dalam tiga epoch pertama, kemudian melandai dan stabil hingga epoch ke-10 saat early stopping aktif. Validation loss LSTM berada pada level yang lebih rendah (sekitar 0,0004) sejak awal dan tetap stabil sepanjang proses pelatihan. Pola ini wajar karena lapisan Dropout aktif selama training namun tidak diaktifkan saat evaluasi validation, sehingga tidak mengindikasikan overfitting. Model TCN menunjukkan pola konvergensi yang berbeda: training loss awal jauh lebih tinggi (sekitar 0,059) namun turun sangat drastis dalam dua epoch pertama sebelum melandai mendekati nol dan stabil hingga epoch ke-16. Validation loss TCN mengikuti training loss dengan sangat rapat sepanjang proses pelatihan, mengindikasikan generalisasi yang sangat baik. Secara keseluruhan, kedua model menunjukkan proses pelatihan yang stabil tanpa indikasi overfitting yang signifikan.

Evaluasi Model


Tabel 4 menyajikan perbandingan performa model LSTM, TCN, dan baseline naif no-change berdasarkan keempat metrik evaluasi pada data testing yang belum pernah dilihat model selama proses pelatihan.

Tabel 4 Hasil Evaluasi

Model	MAE	RMSE	MAPE (%)	Directional Accuracy (%)
Baseline (No-Change)	1,0688	1,5728	0,0244	—
LSTM	1,3883	1,8304	0,0316	48,88
TCN	1,0689	1,5729	0,0244	49,13

Hasil evaluasi pada tabel 4 menunjukkan bahwa model TCN menghasilkan nilai error yang konsisten lebih rendah dibandingkan LSTM pada seluruh metrik, meskipun selisihnya bersifat moderat. Perbandingan terhadap baseline naif no-change mengungkap temuan yang lebih penting: nilai error TCN secara praktis identik dengan baseline tersebut, sedangkan LSTM justru sedikit lebih buruk darinya. Hal ini mengindikasikan bahwa TCN sebagian besar mereplikasi strategi "harga tidak berubah", bukan menunjukkan kemampuan prediktif yang benar-benar baru.

Residual Plot



Gambar 7 Residual Plot


Secara umum, kedua model menghasilkan sebaran residual yang terdistribusi secara acak di sekitar garis nol tanpa pola sistematis yang terdeteksi, mengindikasikan bahwa tidak terdapat *bias* prediksi yang konsisten pada rentang harga manapun. Namun, terdapat perbedaan yang dapat diamati antara keduanya: LSTM menunjukkan sebaran residual yang sedikit lebih lebar dengan

kepadatan titik yang lebih longgar di sekitar nol, disertai beberapa *outlier* ekstrem yang mencapai ± 20 USD. Sebaliknya, TCN menghasilkan sebaran yang lebih rapat dan lebih homogen sepanjang seluruh rentang harga prediksi (4.280–4.550 USD), mengindikasikan stabilitas estimasi yang lebih baik. Pola residual yang acak dan simetris pada kedua model ini juga konsisten dengan *Random Walk Hypothesis* yang telah dibahas sebelumnya, jika terdapat pola sistematis pada residual, model seharusnya mampu mempelajarinya; fakta bahwa tidak ada pola berarti komponen yang tersisa memang bersifat acak dan tidak dapat diprediksi lebih lanjut dari data historis OHLC saja.

Perbandingan Model



Gambar 8 Perbandingan Model



Gambar 9 Perbandingan Model Zoom 200 Bar pertama

Secara visual, garis LSTM dan TCN tampak sangat rapat mengikuti garis aktual namun kerapatan ini lebih mencerminkan skala harga yang besar relatif terhadap pergerakan per-bar, bukan bukti kemampuan prediktif yang luar biasa. Gambar 9 menyajikan tampilan diperbesar (zoom) pada 200 bar pertama data testing untuk mengamati perilaku kedua model pada resolusi yang lebih detail. Pada skala ini terlihat bahwa LSTM dan TCN secara umum mampu mengikuti arah tren harga, namun keduanya menunjukkan pola lagging yang

konsisten pada titik-titik pembalikan harga yang tajam — prediksi terlambat satu langkah mengikuti pergerakan aktual. Pola ini merupakan karakteristik inheren dari prediksi satu langkah berbasis log-return dan semakin mengonfirmasi bahwa kedua model belum mampu mengantisipasi perubahan arah secara mendahului, sejalan dengan nilai *Directional Accuracy* yang mendekati 50% dan interpretasi *Random Walk Hypothesis* yang telah dibahas sebelumnya.

Temuan ini diperkuat oleh nilai *Directional Accuracy* kedua model (LSTM 48,88%; TCN 49,13%) yang mendekati 50%, setara tebak acak, menunjukkan bahwa kemampuan kedua model dalam menebak arah pergerakan harga bar berikutnya secara statistik tidak lebih baik dibandingkan melempar koin. Hasil ini konsisten dengan *Random Walk Hypothesis*, yang menyatakan bahwa pada pasar likuid, perubahan harga jangka sangat pendek mendekati proses acak karena informasi baru terserap ke dalam harga dengan sangat cepat (Fama, 1970). Dengan demikian, keunggulan TCN yang teramati lebih tepat dimaknai sebagai kemampuannya melakukan estimasi yang lebih robust dan stabil mendekati titik optimal secara statistik pada kondisi keteracakan tinggi, bukan sebagai bukti TCN menemukan pola harga yang dapat diandalkan untuk pengambilan keputusan trading secara langsung (Bai et al., 2018; Dai et al., 2021).

SIMPULAN

Penelitian ini menyimpulkan bahwa model Temporal Convolutional Network (TCN) menghasilkan error yang secara konsisten lebih rendah dibandingkan Long Short-Term Memory (LSTM) dalam prediksi harga XAUUSD timeframe 1 menit, meskipun selisihnya bersifat moderat. Perbandingan terhadap baseline naif menunjukkan bahwa TCN secara praktis menyamai baseline tersebut, sedangkan LSTM tampil sedikit

lebih buruk, dan Directional Accuracy kedua model mendekati 50%, konsisten dengan Random Walk Hypothesis pada horizon prediksi yang sangat pendek. Implikasi dari penelitian ini menunjukkan bahwa metrik error harga yang terlihat kecil pada data finansial intraday tidak serta-merta membuktikan kemampuan prediktif yang nyata, sehingga perlu selalu diuji terhadap baseline naif sebelum diklaim sebagai keunggulan model. Oleh karena itu, TCN lebih tepat digunakan sebagai alat bantu estimasi harga (decision support), bukan sebagai sistem penghasil sinyal arah trading yang berdiri sendiri. Penelitian selanjutnya disarankan untuk mengeksplorasi horizon prediksi yang lebih panjang (misalnya 5–15 menit), mengingat horizon 1 menit pada penelitian ini sangat mendekati random walk, serta selalu menyertakan baseline naif dan metrik Directional Accuracy agar klaim keunggulan model dapat dimaknai secara proporsional.

DAFTAR PUSTAKA

- Bai, S., Kolter, J. Z., & Koltun, V. (2018). *An empirical evaluation of generic convolutional and recurrent networks for sequence modeling*. <https://arxiv.org/abs/1803.01271>
- Borovykh, A., Bohte, S., & Oosterlee, C. W. (2017). Conditional time series forecasting with convolutional neural networks. *International Conference on Artificial Neural Networks (ICANN)*.
- Caroline. (2025). Forex Price Predictions using Hybrid TCN-LSTM and LSTM-TCN Models. *Indonesian Journal of Artificial Intelligence and Data Mining*. <https://ejournal.uin-suska.ac.id/index.php/IJAIDM/article/view/38354>
- Creswell, J. W. (2014). *Research design: Qualitative, quantitative, and mixed methods approaches* (4, Ed.). Sage Publications.
- Dai, W., An, Y., & Long, W. (2021). Price change prediction of ultra high frequency financial data based on temporal convolutional network. In *arXiv*. <https://arxiv.org/abs/2107.00261>
- Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, 25(2), 383–417. <https://doi.org/10.2307/2325486>
- Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654–669. <https://doi.org/https://doi.org/10.1016/j.ejor.2017.11.054>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780.
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3, Ed.). OTexts. <https://otexts.com/fpp3/>
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688. <https://doi.org/https://doi.org/10.1016/j.ijforecast.2006.03.001>
- Kingma, D. P., & Ba, J. (2015). *Adam: A method for stochastic optimization* BT - *International Conference on Learning Representations*.
- Murphy, J. J. (1999). *Technical Analysis of the Financial Markets*. McGraw-Hill.
- Novianto, S., & Wibowo, A. (2023). The implementation of data mining for predicting XAU/USD price trends in the forex market on MetaTrader 5 using Naïve Bayes method. *INTELMATICS*, 3(2), 85–90. <https://doi.org/10.25105/itm.v3i2.17199>
- Tsay, R. S. (2010). *Analysis of Financial Time Series* (3rd ed.). Wiley.
- Wilder, J. W. (1978). *New Concepts in Technical Trading Systems*. Trend Research.