

SKRIPSI

**ANALISIS KINERJA DAN KONSISTENSI MODEL TCN DAN BIGRU
DALAM PREDIKSI HARGA EMAS**



**DISUSUN OLEH :
GITA ALLAMANDA LESTARI
223030503165**

**JURUSAN/PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS TEKNIK
UNIVERSITAS PALANGKA RAYA
2026**

HALAMAN PENGESAHAN
ANALISIS KINERJA DAN KONSISTENSI MODEL TCN DAN BIGRU
DALAM PREDIKSI HARGA EMAS

SKRIPSI

Sebagai salah satu syarat untuk menyelesaikan Program Strata-1 pada Jurusan
Teknik Informatika Fakultas Teknik Universitas Palangka Raya

Oleh
GITA ALLAMANDA LESTARI
223030503165

Telah dipertahankan di depan tim penguji, pada :

Hari/Tanggal : Kamis, 17 September 2026

Waktu : 13:00 - 14:30 WIB

Tempat : Ruang Ujian 1

1. **NAHUMI NUGRAHANINGSIH, S.T., M.T., Ph.D.**
NIP. 19791009 200801 2 016 (Ketua Penguji)
2. **NOVA NOOR KAMALA SARI, S.T., M.Kom.**
NIP. 19890407 201504 2 004 (Pembimbing Utama/Pertama)
3. **RONY TEGUH, S.Kom., M.T., Ph.D.**
NIP. 19760624 200501 1 015 (Pembimbing Pendamping/Kedua)
4. **DEVI KAROLITA, S.Kom., M.Kom., Ph.D.**
NIP. 19821206 200604 2 001 (Anggota)

Mengetahui :

Jurusan / Program Studi Teknik Informatika
Fakultas Teknik Universitas Palangka Raya
Ketua Jurusan,


ARIESTA LESTARI, S.Kom., M.Cs., Ph.D.
NIP. 19800322 200501 2 004

HALAMAN PERNYATAAN

Dengan ini menyatakan bahwa skripsi yang berjudul:

“ANALISIS KINERJA DAN KONSISTENSI MODEL TCN DAN BIGRU
DALAM PREDIKSI HARGA EMAS”

merupakan hasil karya saya sendiri dengan ketentuan sebagai berikut:

1. Skripsi ini disusun secara mandiri dan merupakan hasil pemikiran, penelitian, serta analisis saya sendiri.
2. Skripsi ini tidak mengandung karya atau pendapat yang pernah diajukan untuk memperoleh gelar akademik pada perguruan tinggi mana pun, kecuali yang secara tertulis telah dicantumkan sebagai referensi dalam naskah dan daftar pustaka.
3. Seluruh sumber informasi, data, kutipan, maupun pendapat dari karya orang lain telah disebutkan secara jelas dan dicantumkan sesuai dengan kaidah penulisan ilmiah yang berlaku.
4. Skripsi ini bebas dari unsur plagiarisme, baik sebagian maupun seluruhnya.
5. Apabila di kemudian hari terbukti terdapat pelanggaran terhadap pernyataan ini, saya bersedia menerima sanksi akademik sesuai dengan ketentuan yang berlaku di Universitas Palangka Raya.

Palangka Raya, 10 September 2026



Gita Allamanda Lestari
223030503165

ANALISIS KINERJA DAN KONSISTENSI MODEL TCN DAN BIGRU DALAM PREDIKSI HARGA EMAS

GITA ALLAMANDA LESTARI (223030503165)

Jurusan Teknik Informatika, Fakultas Teknik, Universitas Palangka Raya
Kampus Tunjung Nyaho Jl. Yos Sudarso Palangka Raya 73112
allamandalestari09@mhs.eng.upr.ac.id

ABSTRAK

Harga emas sebagai aset finansial *safe haven* kerap menunjukkan pola pergerakan yang non-stasioner dan volatil, sehingga akurasi maupun konsistensi model prediksi menjadi tantangan penting, khususnya pada kondisi pasar yang mengalami perubahan tren tajam. Penelitian ini menerapkan, membandingkan, dan mengevaluasi kinerja dua model deep learning, yaitu Temporal Convolutional Network (TCN) dan Bidirectional Gated Recurrent Unit (BiGRU), untuk memprediksi harga penutupan emas harian berdasarkan data historis univariat periode 4 Januari 2010 sampai 30 Desember 2025 (4.022 observasi, 4.000 di antaranya digunakan dalam eksperimen rolling window), serta membandingkan keduanya terhadap baseline Naive Persistence. Model dievaluasi menggunakan pendekatan fixed-length rolling window validation sebanyak 10 window yang mencakup kondisi pasar berbeda-beda, dianalisis stabilitasnya melalui variansi, standar deviasi, dan coefficient of variation (CV), diuji signifikansi statistiknya menggunakan Wilcoxon Signed-Rank Test pada tiga variasi panjang sequence input (20, 30, dan 60 hari), serta diuji robustness-nya terhadap inisialisasi bobot acak menggunakan tiga random seed independen pada seluruh variasi. Hasil menunjukkan BiGRU secara konsisten unggul dibandingkan TCN pada seluruh 10 window pengujian, dengan rata-rata MAE (dirata-ratakan dari tiga seed) sebesar 26,06 USD berbanding 318,58 USD pada SEQ_LEN = 20 hari, sedangkan TCN menunjukkan gap performa yang signifikan akibat kecenderungan menghasilkan prediksi flat yang tidak responsif terhadap perubahan tren, terutama pada periode lonjakan harga pandemi COVID-19 dan harga tertinggi sepanjang sejarah. Di antara tiga variasi panjang sequence, BiGRU mencatatkan akurasi dan konsistensi terbaik pada SEQ_LEN = 30 hari (MAE 24,95 USD, CV 0,5771). Perbedaan performa TCN vs BiGRU, BiGRU vs Naive Persistence, dan TCN vs Naive Persistence terbukti signifikan secara statistik ($p = 0,002$; effect size $r = 1,000$) pada seluruh variasi panjang sequence. Meskipun BiGRU merupakan model deep learning terbaik dalam penelitian ini, MAE-nya tetap berada di atas baseline Naive Persistence (13,19 USD) pada seluruh window dan variasi pengujian, dan tingkat stabilitasnya (CV) tidak melampaui Naive Persistence pada seluruh variasi yang diuji setelah inisialisasi bobot acak diperhitungkan, sehingga BiGRU tidak dapat digeneralisasi sebagai metode peramalan harga emas terbaik secara mutlak.

Kata Kunci: Temporal Convolutional Network, Bidirectional GRU, Prediksi Harga Emas, Rolling Window Validation, Stabilitas Model

ANALYSIS OF THE PERFORMANCE AND CONSISTENCY OF TCN AND BIGRU MODELS IN GOLD PRICE PREDICTION

GITA ALLAMANDA LESTARI (223030503165)

*Department of Informatics Engineering, Faculty of Engineering, University of
Palangka Raya
Tanjung Nyaho Campus, Jl. Yos Sudarso, Palangka Raya 73112, Indonesia
allamandalestari09@mhs.eng.upr.ac.id*

ABSTRACT

Gold, as a safe-haven financial asset, frequently exhibits non-stationary and volatile price movements, making both the accuracy and consistency of prediction models a critical challenge, particularly under market conditions involving sharp trend shifts. This study implements, compares, and evaluates the performance of two deep learning models, namely Temporal Convolutional Network (TCN) and Bidirectional Gated Recurrent Unit (BiGRU), in predicting daily gold closing prices using univariate historical data from January 4, 2010 to December 30, 2025 (4,022 observations, 4,000 of which were used in the rolling window experiment), and benchmarks both models against a Naive Persistence baseline. The models were evaluated using a fixed-length rolling window validation approach across 10 windows covering distinct market conditions, with stability analyzed through variance, standard deviation, and coefficient of variation (CV), statistical significance tested using the Wilcoxon Signed-Rank Test across three input sequence length variations (20, 30, and 60 days), and robustness to random weight initialization tested using three independent random seeds across all variations. Results show that BiGRU consistently outperformed TCN across all 10 test windows, with an average MAE (averaged over three seeds) of 26.06 USD compared to 318.58 USD at SEQ_LEN = 20 days, while TCN exhibited a significant performance gap due to its tendency to produce flat, trend-unresponsive predictions, particularly during the COVID-19 price surge and the all-time-high price period. Among the three sequence-length variations, BiGRU achieved its best accuracy and consistency at SEQ_LEN = 30 days (MAE 24.95 USD, CV 0.5771). Performance differences for TCN vs BiGRU, BiGRU vs Naive Persistence, and TCN vs Naive Persistence were statistically significant ($p = 0.002$; effect size $r = 1.000$) across all sequence-length variations. Although BiGRU was the best-performing deep learning model in this study, its MAE remained above the Naive Persistence baseline (13.19 USD) across all windows and variations, and its stability (CV) did not exceed that of Naive Persistence in any variation once random initialization was accounted for meaning BiGRU cannot be generalized as the absolute best gold-price forecasting method.

Keywords: *Temporal Convolutional Network, Bidirectional GRU, Gold Price Prediction, Rolling Window Validation, Model Stability*

KATA PENGANTAR

Puji dan syukur penulis panjatkan ke hadirat Allah SWT atas rahmat, karunia, kesehatan, dan pertolongan-Nya sehingga skripsi yang berjudul “Analisis Kinerja dan Konsistensi Model TCN dan BiGRU dalam Prediksi Harga Emas” dapat diselesaikan dengan baik.

Skripsi ini disusun sebagai salah satu syarat untuk menyelesaikan Program Strata-1 pada Jurusan Teknik Informatika, Fakultas Teknik, Universitas Palangka Raya. Penelitian ini bertujuan untuk menerapkan dan membandingkan model deep learning Temporal Convolutional Network (TCN) dan Bidirectional Gated Recurrent Unit (BiGRU) dalam memprediksi harga emas berdasarkan data historis univariat.

Penulis menyadari bahwa skripsi ini masih memiliki kekurangan. Oleh karena itu, kritik dan saran yang membangun sangat diharapkan untuk penyempurnaan di masa yang akan datang. Semoga skripsi ini dapat memberikan manfaat bagi pembaca dan menjadi referensi bagi penelitian selanjutnya.

Palangka Raya, 10 September 2026



Gita Allamanda Lestari
223030503165

DAFTAR ISI

HALAMAN PENGESAHAN.....	ii
HALAMAN PERNYATAAN	iii
RIWAYAT PENYUSUN	iv
HALAMAN PERSEMBAHAN	v
KATA PENGANTAR	viii
ABSTRAK	ix
<i>ABSTRACT</i>	x
DAFTAR ISI.....	xi
DAFTAR GAMBAR	xiii
DAFTAR TABEL	xiv
BAB I	1
PENDAHULUAN	1
1.1. Latar Belakang	1
1.2. Rumusan Masalah	3
1.3. Batasan Masalah	4
1.4. Tujuan Penelitian	4
1.5. Manfaat Penelitian	4
1.6. Sistematika Penulisan	5
1.7. Jadwal Penelitian.....	5
BAB II.....	7
LANDASAN TEORI.....	7
2.1 Tinjauan Pustaka	7
2.2 Teori-Teori Pendukung	13
2.2.1 Data <i>Time Series</i> Finansial.....	13
2.2.2 Prediksi <i>Time Series</i> Dengan Deep Learning.....	13
2.2.3 Model Temporal Convolutional Network (TCN)	14
2.2.4 Model Bidirectional GRU (BiGRU)	16
2.2.5 Evaluasi Model Forecasting	17
2.2.6 <i>Rolling Window Evaluation</i>	18
2.2.7 Operasional Kestabilan Model.....	19
2.2.8 Wilcoxon Signed-Rank Test	20
BAB III	22
METODOLOGI PENELITIAN.....	22
3.1 Metodologi Penelitian	22

3.1.1	Pengumpulan Data	22
3.1.2	Preprocessing Global Dataset	23
3.1.3	Eksplorasi Data Awal (EDA).....	24
3.1.4	Desain <i>Rolling Window</i>	25
3.1.5	Proses Eksperimen Per Window	28
3.1.6	Analisis Stabilitas dan Konsistensi	37
3.1.7	Uji Wilcoxon Signed-Rank Test	38
3.1.8	Eksperimen Variasi Panjang Sequence Input	40
BAB IV		41
HASIL DAN PEMBAHASAN.....		41
4.1	Preprocessing Global Dataset	41
4.2	Eksplorasi Data Awal (EDA).....	42
4.3	Desain <i>Rolling Window</i>	44
4.4	Proses Eksperimen Per Window	46
4.4.1	Normalisasi dan Pembentukan Sequence.....	46
4.4.2	Arsitektur Model TCN	47
4.4.3	Arsitektur Model BiGRU	48
4.4.4	Hasil Pelatihan dan Evaluasi Akurasi	49
4.5	Hasil Evaluasi Kinerja Model Per Window	51
4.5.1	Analisis Window Representatif	51
4.5.2	Pola Umum Kinerja Model	54
4.5.3	Analisis <i>Gap</i> Performa TCN terhadap BiGRU dan Naive Persistence 55	
4.5.4	Analisis Robustness Terhadap Random Seed	56
4.6	Analisis Stabilitas dan Konsistensi Model.....	58
4.6.1	Uji Signifikansi Statistik (Wilcoxon Signed-Rank Test).....	59
4.7	Perbandingan Variasi Panjang Sequence Input.....	61
4.7.1	Perbandingan Rata – rata MAE.....	61
4.7.2	Detail Hasil Evaluasi Per Window.....	62
4.7.3	Uji Signifikansi Semua Variasi.....	64
4.7.4	Kesimpulan Pemilihan Konfigurasi Terbaik.....	66
BAB V.....		67
KESIMPULAN		67
5.1	Kesimpulan	67
5.2	Saran.....	68
DAFTAR PUSTAKA		69

DAFTAR GAMBAR

Gambar 2. 1 Arsitektur Temporal Convolutional Network (TCN)	14
Gambar 3. 1 Alur Penelitian	22
Gambar 4. 1 Eksplorasi Data Harga Emas Harian (2010–2025)	43
Gambar 4. 2 Prediksi Window 1	52
Gambar 4. 3 Prediksi Window 5	52
Gambar 4. 4 Prediksi Window 10	53
Gambar 4. 5 MAE Per Window	54
Gambar 4. 6 Sebaran Robustness Antar Seed (Boxplot CV MAE) SEQ_LEN = 20 hari	58
Gambar 4. 7 Distribusi MAE antar window (SEQ_LEN = 20 hari)	59

DAFTAR TABEL

Tabel 1. 1 Jadwal Penelitian	6
Tabel 2.1 Penelitian Terdahulu	12
Tabel 3. 1 Rincian Indeks Window	28
Tabel 4. 1 Ringkasan Hasil Preprocessing Global Dataset	41
Tabel 4. 2 Sampel Dataset Harga Emas Harian	42
Tabel 4. 3 Statistik Deskriptif Dataset Harga Emas Harian (2010–2025)	42
Tabel 4. 4 Konfigurasi Eksperimen <i>Rolling Window</i>	45
Tabel 4. 5 Rincian Indeks dan Periode Aktual 10 Window Evaluasi	45
Tabel 4. 6 Ringkasan Normalisasi dan Pembentukan Sequence (Window 1)	46
Tabel 4. 7 Ringkasan Arsitektur TCN	47
Tabel 4. 8 Ringkasan Arsitektur BiGRU	49
Tabel 4. 9 Perbandingan Parameter TCN dan BiGRU	49
Tabel 4. 10 Hasil Evaluasi dan Konvergensi Seluruh Window (SEQ_LEN = 20 hari)	50
Tabel 4. 11 Robustness MAE Antar Seed per Window (SEQ_LEN = 20 hari) ...	56
Tabel 4. 12 Analisis Stabilitas Performa Model (SEQ_LEN = 20 hari)	58
Tabel 4. 13 Hasil Uji Wilcoxon Signed-Rank Test (SEQ_LEN = 20 hari)	60
Tabel 4. 14 Ringkasan Perbandingan Seluruh Variasi SEQ_LEN	61
Tabel 4. 15 Hasil Evaluasi Seluruh Window (SEQ_LEN = 30 hari)	62
Tabel 4. 16 Hasil Evaluasi Seluruh Window (SEQ_LEN = 60 hari)	63
Tabel 4. 17 Hasil Uji Wilcoxon Seluruh Variasi SEQ_LEN	65

DAFTAR PUSTAKA

- Akhtaruzzaman, M., Boubaker, S., Lucey, B. M., & Sensoy, A. (2021). Is gold a hedge or a safe-haven asset in the COVID–19 crisis? *Economic Modelling*, 102(4), 105588. <https://doi.org/10.1016/j.econmod.2021.105588>
- Bai, S., Kolter, J. Z., & Koltun, V. (2018). *An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling*. <http://arxiv.org/abs/1803.01271>
- Bergmeir, C., & Benítez, J. M. (2012). On the use of cross-validation for time series predictor evaluation. *Information Sciences*, 191, 192–213. <https://doi.org/10.1016/j.ins.2011.12.028>
- Bergmeir, C., Hyndman, R. J., & Koo, B. (2018). A note on the validity of cross-validation for evaluating autoregressive time series prediction. *Computational Statistics & Data Analysis*, 120, 70–83. <https://doi.org/10.1016/j.csda.2017.11.003>
- Cerqueira, V., Torgo, L., & Mozetič, I. (2020). Evaluating time series forecasting models: an empirical study on performance estimation methods. *Machine Learning*, 109(11), 1997–2028. <https://doi.org/10.1007/s10994-020-05910-7>
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? -Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7(3), 1247–1250. <https://doi.org/10.5194/gmd-7-1247-2014>
- Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). *Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation*. <http://arxiv.org/abs/1406.1078>
- Eugene F. Fama. (1970). *Efficient Capital Markets- A Review of Theory and Empirical Work*. 25(2), 383–417.
- Fajou, J., & Andrew McCarren. (2021). *Forecasting Gold Prices Using Temporal Convolutional Networks*.
- Foroutan, P., & Lahmiri, S. (2024). Deep learning systems for forecasting the prices of crude oil and precious metals. *Financial Innovation*, 10(1). <https://doi.org/10.1186/s40854-024-00637-z>
- He, K., Yang, Q., Ji, L., Pan, J., & Zou, Y. (2023). Financial Time Series Forecasting with the Deep Learning Ensemble Model. *Mathematics*, 11(4). <https://doi.org/10.3390/math11041054>
- İncekırık, A. (2026). ANALYSIS OF GOLD PRICE PREDICTION USING COMMODITY AND FOREIGN EXCHANGE MARKET INDICATORS WITH UNIDIRECTIONAL AND BIDIRECTIONAL DEEP LEARNING MODELS. *SCIENTIFIC CULTURE*, 12(3), 182–196. <https://doi.org/10.5281/zenodo.18908963>
- Isabelle Guyon. (1997). *A scaling law for the validation-set training-set size ratio*.
- Kingma, D. P., & Ba, J. (2015). *Adam: A Method for Stochastic Optimization*. <http://arxiv.org/abs/1412.6980>
- Livieris, I. E., Pintelas, E., & Pintelas, P. (2020). A CNN–LSTM model for gold price time-series forecasting. *Neural Computing and Applications*, 32(23), 17351–17360. <https://doi.org/10.1007/s00521-020-04867-x>

- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PLoS ONE*, 13(3). <https://doi.org/10.1371/journal.pone.0194889>
- Oord, A. van den, Dieleman, S., Zen, H., Simonyan, K., Vinyals, O., Graves, A., Kalchbrenner, N., Senior, A., & Kavukcuoglu, K. (2016). *WaveNet: A Generative Model for Raw Audio*. <http://arxiv.org/abs/1609.03499>
- Reimers, N., & Gurevych, I. (2017). *Reporting Score Distributions Makes a Difference: Performance Study of LSTM-networks for Sequence Tagging*. <http://arxiv.org/abs/1707.09861>
- Sezer, O. B., Gudelek, M. U., & Ozbayoglu, A. M. (2020). Financial time series forecasting with deep learning : A systematic literature review: 2005–2019. *Applied Soft Computing*, 90, 106181. <https://doi.org/10.1016/j.asoc.2020.106181>
- Shen, L., Wei, Z., & Wang, Y. (2021). Determining the rolling window size of deep neural network based models on time series forecasting. *Journal of Physics: Conference Series*, 2078(1). <https://doi.org/10.1088/1742-6596/2078/1/012011>
- Tholib, A., Agusmawati, N. K., & Khoiriyah, F. (2023). PREDIKSI HARGA EMAS MENGGUNAKAN METODE LSTM DAN GRU. *Jurnal Informatika Dan Teknik Elektro Terapan*, 11(3). <https://doi.org/10.23960/jitet.v11i3.3250>
- Wilcoxon, F. (1945). Individual Comparisons by Ranking Methods. In *Biometrics Bulletin* (Vol. 1, Number 6). <http://www.jstor.org/about/terms.html>.
- Willmott C., & Matsuura k. (2005). *Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance*. www.int-res.com