

PERBANDINGAN MODEL LSTM DAN GRU UNTUK PREDIKSI HARGA SAHAM TELEKOMUNIKASI INDONESIA

Ahmad Jamalul Noor¹, Dian Ade Kurnia², Yudhistira Arie Wijaya³, Heliyanti Susana

¹ Teknik Informatika, STMIK IKMI Cirebon, ² Manajemen Informatika, STMIK IKMI Cirebon, ³ Sistem Informasi, STMIK IKMI Cirebon, ⁴ Teknik Informatika, STMIK IKMI Cirebon

Jl. Perjuangan, Karyamulya, Kec. Kesambi, Kota Cirebon, Jawa Barat, Indonesia

¹ a.jamalul.n@gmail.com, ² dianade2012@gmail.com, ³ yudhistira010471@gmail.com, ⁴ heliyanti3105@gmail.com

Abstrak : Penelitian ini bertujuan untuk mengevaluasi dan membandingkan performa model Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) dalam memprediksi harga saham harian pada sektor telekomunikasi Indonesia, sebuah sektor yang memiliki karakteristik volatilitas fluktuatif dan dipengaruhi oleh dinamika pasar jangka pendek. Dua emiten yang dianalisis adalah GHON dan EXCL dengan rentang data dua tahun yang diambil dari platform Investing.com. Proses penelitian mencakup tahapan preprocessing, normalisasi menggunakan MinMaxScaler, pembentukan sliding window sepanjang 30 hari, serta pembagian data secara kronologis menjadi data latih, validasi, dan uji. Optimasi hyperparameter dilakukan menggunakan KerasTuner dengan pendekatan Random Search untuk memperoleh konfigurasi terbaik bagi masing-masing model. Evaluasi performa menggunakan tiga metrik utama yakni Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE). Hasil eksperimen menunjukkan bahwa GRU memberikan performa yang lebih unggul pada saham EXCL yang memiliki volatilitas tinggi, ditunjukkan oleh nilai RMSE, MAE, dan MAPE yang lebih rendah dibandingkan LSTM. Sebaliknya, pada saham GHON yang lebih stabil, kedua model menghasilkan performa yang relatif sebanding. Temuan ini menegaskan bahwa efektivitas model sangat dipengaruhi oleh karakteristik data, di mana GRU lebih adaptif pada pola harga yang dinamis, sedangkan LSTM tetap kompetitif pada pola yang lebih konsisten. Secara keseluruhan, GRU dapat direkomendasikan sebagai model yang lebih efisien dan akurat untuk prediksi harga saham pada lingkungan pasar yang berfluktuasi tinggi.

Kata Kunci : Prediksi Harga Saham, LSTM, GRU, Deep Learning, Deret Waktu.

Abstract: This study aims to evaluate and compare the performance of Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU) models in predicting daily stock prices in the Indonesian telecommunications sector, a sector characterised by volatile fluctuations and influenced by short-term market dynamics. The two issuers analysed are GHON and EXCL, with a two-year data range taken from the Investing.com platform. The research process included preprocessing, normalisation using MinMaxScaler, the formation of a 30-day sliding window, and the chronological division of data into training, validation, and test data. Hyperparameter optimisation was performed using KerasTuner with a Random Search approach to obtain the best configuration for each model. Performance evaluation used three main metrics, namely Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and Mean Absolute Percentage Error (MAPE). The results of the experiment showed that GRU performed better on EXCL shares, which have high volatility, as indicated by lower RMSE,

MAE, and MAPE values compared to LSTM. Conversely, for the more stable GHON stock, both models produced relatively comparable performance. These findings confirm that the effectiveness of the model is greatly influenced by data characteristics, where GRU is more adaptive to dynamic price patterns, while LSTM remains competitive in more consistent patterns. Overall, GRU can be recommended as a more efficient and accurate model for stock price prediction in highly volatile market environments.

Keywords: *Stock Price Prediction, LSTM, GRU, Deep Learning, Time Series.*

PENDAHULUAN

Perkembangan teknologi informasi telah mendorong meningkatnya kebutuhan terhadap model prediksi keuangan yang mampu memproses data dalam jumlah besar dan berperilaku nonlinier. Pasar saham, termasuk sektor telekomunikasi Indonesia, memiliki karakteristik volatilitas tinggi, ketergantungan temporal, serta pola yang sulit ditangkap oleh metode statistik klasik seperti Autoregressive Integrated Moving Average (ARIMA), yang cenderung efektif hanya pada data stasioner dan linear [1]. Kondisi ini mendorong peneliti untuk mengadopsi pendekatan Artificial Intelligence (AI), khususnya Deep Learning (DL), yang mampu mempelajari representasi fitur secara otomatis dan menangani dinamika deret waktu yang kompleks [2].

Di antara model DL, Recurrent Neural Network (RNN) dan turunannya, LSTM serta GRU, menjadi algoritma yang paling banyak digunakan dalam prediksi pasar finansial. LSTM memanfaatkan mekanisme gerbang untuk menjaga informasi jangka panjang, sehingga efektif untuk memodelkan pola tren yang relatif stabil. Sebaliknya, GRU menawarkan arsitektur yang lebih sederhana dengan dua gerbang utama, reset dan update yang dapat mempercepat proses pelatihan tanpa mengorbankan akurasi [3]. Studi-studi mutakhir menunjukkan bahwa GRU sering kali unggul dalam konteks data yang sangat volatil karena kemampuannya

merespons perubahan temporal secara lebih adaptif [4], [5], sedangkan LSTM tetap relevan ketika struktur data menunjukkan pola musiman atau dependensi panjang [6].

Selain pemilihan arsitektur model, proses hyperparameter tuning menjadi elemen krusial dalam meningkatkan akurasi prediksi. Parameter seperti jumlah neuron, dropout rate, dan learning rate secara langsung memengaruhi stabilitas prediksi dan kemampuan generalisasi model. Teknik pencarian seperti Random Search (RS) dan Bayesian Optimization (BO) terbukti dapat menghasilkan konfigurasi model yang lebih optimal dibandingkan penetapan parameter secara manual [7], [8]. Dalam konteks penelitian finansial, tuning terbukti meningkatkan performa model hingga lebih dari 20% pada metrik seperti RMSE, MAE, dan MAPE [9], [10].

Berdasarkan kesenjangan penelitian sebelumnya, khususnya minimnya studi yang secara khusus mengkaji kinerja LSTM dan GRU pada saham telekomunikasi Indonesia seperti GHON dan EXCL, penelitian ini dilakukan untuk menjawab tiga pertanyaan utama yaitu bagaimana karakteristik volatilitas dan pola temporal memengaruhi performa model prediksi, bagaimana efektivitas LSTM dan GRU setelah melalui proses hyperparameter tuning, dan model mana yang menunjukkan akurasi terbaik berdasarkan RMSE, MAE, dan MAPE. Dengan merancang eksperimen

komparatif berbasis deret waktu harian selama dua tahun serta menerapkan teknik preprocessing dan tuning yang sistematis, penelitian ini dapat memberikan kontribusi empiris bagi pengembangan sistem prediksi harga saham berbasis DL di Indonesia.

KAJIAN PUSTAKA DAN LANDASAN TEORI

Prediksi harga saham merupakan salah satu fokus utama dalam analisis deret waktu karena sifatnya yang nonlinier, dinamis, dan dipengaruhi oleh volatilitas pasar. Metode statistik klasik seperti ARIMA sering mengalami keterbatasan dalam menangani pola kompleks dan dependensi jangka panjang [11]. Oleh karena itu, pendekatan berbasis DL mulai banyak diadopsi, terutama RNN, yang memiliki kemampuan untuk memodelkan hubungan temporal secara lebih fleksibel dan adaptif [12].

LSTM dan Gated Recurrent Unit merupakan dua arsitektur RNN yang paling sering digunakan dalam prediksi finansial. LSTM memperkenalkan tiga mekanisme gerbang yakni input, forget, dan output gates yang memungkinkan penyimpanan informasi jangka panjang serta mitigasi masalah vanishing gradient [13]. GRU, sebagai arsitektur yang lebih sederhana, hanya menggunakan update dan reset gates sehingga menawarkan efisiensi komputasi lebih baik dengan performa prediksi yang sering kali setara atau unggul pada data dengan volatilitas tinggi [14], [15]. Studi terbaru juga menunjukkan bahwa GRU lebih responsif terhadap perubahan harga jangka pendek, sedangkan LSTM cenderung unggul pada pola yang lebih stabil atau musiman [16], [17].

Selain pemilihan arsitektur, proses hyperparameter tuning menjadi faktor krusial dalam mencapai performa optimal. Parameter seperti jumlah neuron, dropout rate, dan learning rate memiliki dampak langsung terhadap akurasi dan stabilitas model [18]. KerasTuner menyediakan mekanisme pencarian sistematis seperti RS dan BO yang memungkinkan eksplorasi ruang parameter secara efisien, sehingga model dapat dikonfigurasi secara optimal berdasarkan data validasi [19]. Berbagai penelitian terdahulu pada domain pasar saham menunjukkan bahwa kombinasi preprocessing yang baik, sliding window, pembagian data kronologis, dan tuning hyperparameter mampu meningkatkan kinerja model secara signifikan [20], [21]. Landasan teori ini menjadi dasar utama dalam perancangan dan analisis model LSTM dan GRU pada penelitian ini.

METODE

Penelitian ini menggunakan pendekatan eksperimen kuantitatif berbasis DL untuk membandingkan performa model LSTM dan GRU dalam memprediksi harga penutupan saham harian. Data sekunder diperoleh dari Investing.com untuk dua emiten telekomunikasi Indonesia, GHON dan EXCL, dengan rentang waktu 1 Oktober 2023 hingga 1 Oktober 2025. Seluruh proses analisis dilakukan menggunakan Python, TensorFlow, dan Keras di lingkungan Google Colab.

Proses pengolahan data diawali dengan pemeriksaan konsistensi nilai, penanganan missing values, serta normalisasi menggunakan MinMaxScaler, mengingat normalisasi terbukti meningkatkan stabilitas

pelatihan jaringan RNN [22]. Data kemudian dikonversi menjadi sekuens deret waktu menggunakan teknik sliding window sepanjang 30 hari, sesuai rekomendasi penelitian sebelumnya bahwa window 20 hingga 30 hari efektif dalam memetakan pola harga harian [23]. Setelah pembentukan sekuens, data dipisahkan secara kronologis ke dalam subset pelatihan, validasi, dan pengujian untuk menjaga integritas temporal dan mencegah data leakage, sebagaimana dianjurkan untuk pemodelan deret waktu keuangan [24].

Arsitektur model terdiri dari dua lapisan utama dan satu lapisan Dense sebagai output. Kedua model memanfaatkan fungsi aktivasi tanh, sementara lapisan output menggunakan aktivasi linear untuk menghasilkan prediksi harga riil. Optimasi dilakukan menggunakan Adam Optimizer dan fungsi kerugian Mean Squared Error (MSE), sebagaimana kombinasi ini telah terbukti stabil pada prediksi deret waktu finansial [25]. Untuk memperoleh performa terbaik, dilakukan hyperparameter tuning menggunakan KerasTuner dengan metode RS, meliputi variasi jumlah neuron, dropout rate, dan learning rate, mengikuti rekomendasi tuning pada model RNN untuk data volatil [26].

Evaluasi performa dilakukan menggunakan tiga metrik utama, yakni RMSE, MAE, dan MAPE. Ketiga metrik tersebut dipilih karena mampu menggambarkan kesalahan absolut, relatif, dan kuadrat dalam prediksi

harga, serta umum digunakan dalam studi prediksi harga aset finansial [27]. Seluruh prosedur dianalisis secara sistematis untuk memastikan replikasi dan validitas empiris dari perbandingan performa LSTM dan GRU.

HASIL DAN PEMBAHASAN

Hasil Eksperimen

Eksperimen dilakukan untuk mengevaluasi kinerja model LSTM dan GRU dalam memprediksi harga saham dua emiten telekomunikasi Indonesia, GHON dan EXCL. Evaluasi menggunakan tiga metrik utama yakni RMSE, MAE, dan MAPE yang umum digunakan dalam analisis deret waktu [28]. Ringkasan performa kedua model ditampilkan pada Tabel 1.

Tabel 1 Ringkasan Metrik Evaluasi

Emiten	Model	RMSE	MAE	MAPE
GHON	LSTM	37.896	28.234	1.708
GHON	GRU	38.333	29.391	1.781
EXCL	LSTM	85.776	72.350	2.614
EXCL	GRU	70.772	56.610	2.042

Tabel 1 menunjukkan bahwa GRU unggul pada EXCL, sedangkan LSTM memberikan kinerja sedikit lebih baik pada GHON.

Analisis Perbandingan Model

Akurasi dan Stabilitas Prediksi

Hasil evaluasi mengindikasikan bahwa performa kedua model bergantung pada karakteristik dataset. Pada GHON, yang memiliki pola harga relatif stabil, LSTM memberikan nilai RMSE dan MAE sedikit lebih rendah dibanding GRU. Hal ini sejalan dengan literatur yang menyatakan bahwa mekanisme cell state pada LSTM mampu mempertahankan informasi jangka panjang dengan lebih stabil pada pola deret waktu yang tidak terlalu bergejolak [29], [30].

Sebaliknya, pada EXCL yang memiliki volatilitas lebih tinggi, GRU menunjukkan

performa lebih baik pada seluruh metrik. Sifat arsitekturnya yang lebih sederhana dan memiliki lebih sedikit parameter membuat GRU mampu beradaptasi dengan perubahan harga yang cepat, sesuai temuan [31] dan [32], yang melaporkan dominasi GRU dalam memodelkan data dengan dinamika tinggi.

Dampak Hyperparameter Tuning

Hyperparameter tuning menggunakan KerasTuner memberikan pengaruh signifikan terhadap peningkatan performa kedua model. Parameter seperti jumlah unit, dropout, dan learning rate menentukan kestabilan dan kecepatan konvergensi model [33]. Konfigurasi terbaik untuk masing-masing model dan emiten ditampilkan pada Tabel 2.

Tabel 2 Konfigurasi Terbaik Hyperparameter

Model & Emiten	Units_1	Units_2	Dropout Rate	Learning Rate
LSTM GHON	32	16	0.1	0.01
GRU GHON	64	32	0.2	0.001
LSTM EXCL	64	32	0.2	0.001
GRU EXCL	32	16	0.1	0.01

Tabel 2 memperlihatkan bahwa kebutuhan konfigurasi optimal berbeda antar dataset, menegaskan sensitivitas tuning terhadap distribusi dan volatilitas harga saham.

Diskusi Umum

Secara keseluruhan, hasil penelitian ini konsisten dengan literatur yang menempatkan GRU sebagai model yang lebih efisien dan responsif pada data yang bersifat volatil [34], [35]. Sementara itu, LSTM tetap memberikan performa kuat pada dataset yang stabil dan memiliki rangkaian pola jangka panjang.

Hal ini menunjukkan bahwa tidak ada satu model yang unggul secara universal. Pemilihan model harus mempertimbangkan karakteristik dataset, volatilitas, serta tujuan prediksi. Pada konteks pasar telekomunikasi Indonesia, GRU dapat dipertimbangkan sebagai alternatif yang lebih efisien, sementara LSTM tetap relevan untuk analisis tren jangka panjang yang lebih halus.

KESIMPULAN

Hasil penelitian menunjukkan bahwa model LSTM dan GRU sama-sama mampu menghasilkan prediksi harga saham harian dengan tingkat akurasi tinggi, yang tercermin dari nilai RMSE, MAE, dan MAPE yang relatif rendah pada kedua emiten. Secara umum, GRU memberikan performa yang lebih unggul terutama pada saham EXCL yang memiliki tingkat volatilitas lebih tinggi, sedangkan LSTM tampil stabil pada data GHON yang menunjukkan fluktuasi lebih moderat. Temuan ini menegaskan bahwa pemilihan model prediksi sangat dipengaruhi oleh karakteristik pola temporal dan dinamika pasar dari data yang digunakan, sehingga tidak ada satu model yang secara universal lebih baik untuk seluruh kondisi. Keunggulan utama penelitian ini terletak pada penggunaan hyperparameter tuning yang sistematis, sehingga konfigurasi model yang digunakan benar-benar mencerminkan kinerja optimal untuk masing-masing dataset. Meski demikian, penelitian ini masih memiliki keterbatasan terutama pada penggunaan satu variabel utama tanpa mempertimbangkan indikator eksternal seperti volume atau sentimen pasar, serta keterbatasan komputasi yang membatasi eksplorasi model yang lebih kompleks. Penelitian selanjutnya dapat mengembangkan model prediksi dengan memasukkan lebih banyak fitur relevan, menguji data berdimensi lebih besar atau

resolusi lebih tinggi seperti intraday, serta membandingkan performa LSTM dan GRU dengan model modern seperti Transformer atau arsitektur hibrida untuk mendapatkan gambaran yang lebih menyeluruh mengenai efektivitas pendekatan DL dalam prediksi harga saham.

REFERENSI

- [1] Z. D. Akşehir dan E. Kılıç, "Analyzing the critical steps in deep learning-based stock forecasting: a literature review," *PeerJ Comput. Sci.*, vol. 10, hal. 1–45, 2024, doi: 10.7717/peerj-cs.2312.
- [2] S. Wang, C. Shao, J. Zhang, Y. Zheng, dan M. Meng, "Traffic flow prediction using bi-directional gated recurrent unit method," *Urban Informatics*, vol. 1, no. 1, hal. 1–12, 2022, doi: 10.1007/s44212-022-00015-z.
- [3] Y. Jiang *et al.*, "Leaking source localization approach in multi-obstacle scenarios based on CNN and attention mechanism," *Comput. Chem. Eng.*, vol. 204, no. September 2025, 2026, doi: 10.1016/j.compchemeng.2025.109435.
- [4] S. Zaheer *et al.*, "A Multi Parameter Forecasting for Stock Time Series Data Using LSTM and Deep Learning Model," *Mathematics*, vol. 11, no. 3, hal. 1–24, 2023, doi: 10.3390/math11030590.
- [5] V. I. Kontopoulou, A. D. Panagopoulos, I. Kakkos, dan G. K. Matsopoulos, "A Review of ARIMA vs. Machine Learning Approaches for Time Series Forecasting in Data Driven Networks," *Futur. Internet*, vol. 15, no. 8, hal. 1–31, 2023, doi: 10.3390/fi15080255.
- [6] G. Sonkavde, D. S. Dharrao, A. M. Bongale, S. T. Deokate, D. Doreswamy, dan S. K. Bhat, "Forecasting Stock Market Prices Using Machine Learning and Deep Learning Models: A Systematic Review, Performance Analysis and Discussion of Implications," *Int. J. Financ. Stud.*, vol. 11, no. 3, 2023, doi: 10.3390/ijfs11030094.
- [7] D. Xiao dan J. Su, "Research on Stock Price Time Series Prediction Based on Deep Learning and Autoregressive Integrated Moving Average," *Sci. Program.*, vol. 2022, 2022, doi: 10.1155/2022/4758698.
- [8] A. Lawi, H. Mesra, dan S. Amir, "Implementation of Long Short-Term Memory and Gated Recurrent Units on grouped time-series data to predict stock prices accurately," *J. Big Data*, vol. 9, no. 1, 2022, doi: 10.1186/s40537-022-00597-0.
- [9] T. B. Shahi, A. Shrestha, A. Neupane, dan W. Guo, "Stock price forecasting with deep learning: A comparative study," *Mathematics*, vol. 8, no. 9, hal. 1–15, 2020, doi: 10.3390/math8091441.
- [10] Y. Touzani dan K. Douzi, "An LSTM and GRU based trading strategy adapted to the Moroccan market," *J. Big Data*, vol. 8, no. 1, 2021, doi: 10.1186/s40537-021-00512-z.
- [11] Y. Ulu, "Forecasting Stock Prices via Deep Learning During COVID-19: A Case Study from an Emerging Economy," *Eur. J. Theor. Appl. Sci.*, vol. 2, no. 1, hal. 497–503, 2024, doi: 10.59324/ejtas.2024.2(1).42.
- [12] X. Song, L. Deng, H. Wang, Y. Zhang, dan Y. He, "Deep learning-based time series forecasting," 2025.
- [13] A. Bareket dan B. Pârv, "Enhancing Stock Market Forecasting Using Recursive Time Series Decomposition Techniques," *J. Mach. Intell. Data Sci.*, vol. 4, 2023, doi: 10.11159/jmids.2023.06.
- [14] A. Palacios Gutiérrez, J. L. Valencia Delfa, dan M. Villeta López, "Time series clustering using trend, seasonal and autoregressive components to identify maximum temperature patterns in the Iberian Peninsula," *Environ. Ecol. Stat.*, vol. 30, no. 3, hal. 421–442, 2023, doi: 10.1007/s10651-023-00572-9.
- [15] T. Kreuzer, J. Zdravkovic, dan P.

- Papapetrou, “Unpacking the trend: decomposition as a catalyst to enhance time series forecasting models,” *Data Min. Knowl. Discov.*, vol. 39, no. 5, hal. 1–41, 2025, doi: 10.1007/s10618-025-01120-8.
- [16] Z. Ma, G. Mei, dan N. Xu, “Characterizing Seasonality and Trend From In Situ Time-Series Observations Using Explainable Deep Learning for Ground Deformation Forecasting,” *J. Geophys. Res. Mach. Learn. Comput.*, vol. 1, no. 2, 2024, doi: 10.1029/2024jh000122.
- [17] A. Sohrabbeig, O. Ardakanian, dan P. Musilek, “Decompose and Conquer: Time Series Forecasting with Multiseasonal Trend Decomposition Using Loess,” *Forecasting*, vol. 5, no. 4, hal. 684–696, 2023, doi: 10.3390/forecast5040037.
- [18] H. Hewamalage, K. Ackermann, dan C. Bergmeir, “Forecast evaluation for data scientists: common pitfalls and best practices,” *Data Min. Knowl. Discov.*, vol. 37, no. 2, hal. 788–832, 2023, doi: 10.1007/s10618-022-00894-5.
- [19] T. O. Hodson, “Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not,” *Geosci. Model Dev.*, vol. 15, no. 14, hal. 5481–5487, 2022, doi: 10.5194/gmd-15-5481-2022.
- [20] S. Lima, A. M. Gonçalves, dan M. Costa, “Predictive accuracy of time series models applied to economic data: the European countries retail trade,” *J. Appl. Stat.*, vol. 51, no. 9, hal. 1818–1841, 2024, doi: 10.1080/02664763.2023.2238249.
- [21] P. Manandhar, H. Rafiq, E. Rodriguez-Ubinas, dan T. Palpanas, “New Forecasting Metrics Evaluated in Prophet, Random Forest, and Long Short-Term Memory Models for Load Forecasting,” *Energies*, vol. 17, no. 23, hal. 1–30, 2024, doi: 10.3390/en17236131.
- [22] K. R. Baskaran dan B. Kaviya, “Stock Market Prediction Using Machine Learning and Deep Learning Algorithms,” *Sustain. Digit. Technol. Smart Cities Heal. Commun. Transp.*, hal. 127–138, 2023, doi: 10.1201/9781003307716-12.
- [23] A. Varshini, P. Kayal, dan M. Maiti, “How good are different machine and deep learning models in forecasting the future price of metals? Full sample versus sub-sample,” *Resour. Policy*, vol. 92, no. August 2023, hal. 105040, 2024, doi: 10.1016/j.resourpol.2024.105040.
- [24] S. M. Al-Selwi *et al.*, “RNN-LSTM: From applications to modeling techniques and beyond—Systematic review,” *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 36, no. 5, hal. 102068, 2024, doi: 10.1016/j.jksuci.2024.102068.
- [25] M. Krichen dan A. Mihoub, “Long Short-Term Memory Networks: A Comprehensive Survey,” *AI*, vol. 6, no. 9, hal. 1–21, 2025, doi: 10.3390/ai6090215.
- [26] I. Malashin, V. Tynchenko, A. Gantimurov, V. Nelyub, dan A. Borodulin, “Applications of Long Short-Term Memory (LSTM) Networks in Polymeric Sciences: A Review,” *Polymers (Basel)*, vol. 16, no. 18, hal. 1–44, 2024, doi: 10.3390/polym16182607.
- [27] I. D. Mienye, T. G. Swart, dan G. Obaido, “Recurrent Neural Networks: A Comprehensive Review of Architectures, Variants, and Applications,” *Inf.*, vol. 15, no. 9, hal. 1–34, 2024, doi: 10.3390/info15090517.
- [28] X. Li, “CNN-GRU model based on attention mechanism for large-scale energy storage optimization in smart grid,” *Front. Energy Res.*, vol. 11, no. July, hal. 1–16, 2023, doi: 10.3389/fenrg.2023.1228256.
- [29] D.-J. Pyo, “Enhancing GDP Growth Forecasting with LSTM, GRU, and Hybrid Model: Evidence from South Korea,” *SAGE Open*, vol. 15, no. 3, hal. 1–23, 2025, doi:

- 10.1177/21582440251359828.
- [30] C. Systems, A. B. Fawait, H. Maghfiroh, A. Azzawagama, dan I. Suwarno, "Literature Review on the Performance of Deep Learning," *Int. J. Robot. Control Syst.*, vol. 4, no. 3, hal. 1506–1526, 2024.
- [31] Z. Yu, Y. Sun, J. Zhang, Y. Zhang, dan Z. Liu, "Gated recurrent unit neural network (GRU) based on quantile regression (QR) predicts reservoir parameters through well logging data," *Front. Earth Sci.*, vol. 11, no. January, hal. 1–8, 2023, doi: 10.3389/feart.2023.1087385.
- [32] X. Kong *et al.*, *Deep learning for time series forecasting: a survey*, vol. 16, no. 7–8. Springer Berlin Heidelberg, 2025. doi: 10.1007/s13042-025-02560-w.
- [33] H. Oukhouya dan K. El Himdi, "Comparing Machine Learning Methods—SVR, XGBoost, LSTM, and MLP— For Forecasting the Moroccan Stock Market," hal. 39, 2023, doi: 10.3390/iocma2023-14409.
- [34] F. Rivas, J. E. Sierra-Garcia, dan J. M. Camara, "Comparison of LSTM- and GRU-Type RNN Networks for Attention and Meditation Prediction on Raw EEG Data from Low-Cost Headsets," *Electron.*, vol. 14, no. 4, hal. 1–33, 2025, doi: 10.3390/electronics14040707.
- [35] Z. Wang, "Stock price prediction using LSTM neural networks: Techniques and applications," *Appl. Comput. Eng.*, vol. 86, no. 1, hal. 294–300, 2024, doi: 10.54254/2755-2721/86/20241605.