

BAB VI

KESIMPULAN DAN SARAN

6.1 KESIMPULAN

Berdasarkan pengolahan data dan analisis yang telah dilakukan, penelitian ini menghasilkan beberapa kesimpulan.

Pertama, model H2O Deep Learning dapat digunakan untuk memprediksi harga penutupan saham telekomunikasi di Asia Tenggara. Namun, kinerja model berbeda pada setiap saham dan skenario fitur. Berdasarkan hasil pemodelan H2O Deep Learning, setiap saham memiliki skenario fitur terbaik yang berbeda. Pada saham TLKM Indonesia, kinerja terbaik diperoleh dari skenario OHLC + RSI dengan rata-rata RMSE sebesar 35,6870. Pada saham AXIATA Malaysia, kinerja terbaik diperoleh dari skenario OHLC + Bollinger Bands dengan rata-rata RMSE sebesar 0,0632. Pada saham ADVANC Thailand, kinerja terbaik diperoleh dari skenario OHLC + RSI dengan rata-rata RMSE sebesar 2,1684. Sementara itu, pada saham TEL Filipina, kinerja terbaik diperoleh dari skenario OHLC + MACD dengan rata-rata RMSE sebesar 0,0614. Hasil ini menunjukkan bahwa tidak ada satu skenario fitur yang selalu menjadi pilihan terbaik untuk seluruh saham.

Kedua, hasil perbandingan antara ARIMA dan H2O Deep Learning menunjukkan bahwa H2O Deep Learning memberikan kinerja prediksi yang lebih baik pada sebagian besar saham. Berdasarkan perbandingan RMSE, H2O Deep Learning mengungguli ARIMA pada tiga dari empat saham, yaitu

TLKM, ADVANC, dan TEL. Sementara itu, pada saham AXIATA, ARIMA menghasilkan RMSE yang lebih rendah dibandingkan H2O Deep Learning. Dengan demikian, H2O Deep Learning dapat menjadi model prediksi yang lebih baik ketika skenario fitur yang digunakan sesuai dengan karakteristik saham, tetapi ARIMA tetap relevan sebagai model baseline klasik.

Ketiga, kontribusi indikator teknikal terhadap peningkatan kinerja prediksi tidak bersifat seragam. Pada saham TLKM dan ADVANC, skenario OHLC + RSI menghasilkan rata-rata RMSE terendah. Hal ini menunjukkan bahwa informasi momentum dari RSI relevan untuk membantu prediksi harga penutupan kedua saham tersebut. Pada saham AXIATA, skenario OHLC + Bollinger Bands menghasilkan RMSE terendah, tetapi nilainya sangat dekat dengan skenario Skenario OHLC. Hal ini menunjukkan bahwa penambahan Bollinger Bands hanya memberikan peningkatan kecil. Pada saham TEL, skenario OHLC + MACD menghasilkan kinerja terbaik, sehingga informasi arah momentum dan tren dari MACD lebih relevan untuk saham tersebut. Oleh karena itu, indikator teknikal perlu diuji secara empiris sebelum digunakan dalam model prediksi.

Keempat, hasil pemilihan lag menunjukkan bahwa setiap saham memiliki struktur ketergantungan historis yang berbeda. TLKM menggunakan lag 9, AXIATA menggunakan lag 1, ADVANC menggunakan lag 8, dan TEL menggunakan lag 2. Perbedaan ini menunjukkan bahwa setiap saham memiliki pola temporal, autokorelasi, dan karakteristik historis yang berbeda. Dengan demikian, saham telekomunikasi di Asia Tenggara tidak dapat diperlakukan sebagai data dengan struktur prediksi yang sama, meskipun berasal dari sektor industri yang sama.

Kelima, hasil validasi lanjutan menunjukkan bahwa kinerja H2O Deep Learning tidak selalu berubah dengan pola yang sama pada setiap saham. RMSE validasi TLKM turun dari 35,6870 menjadi 35,5136, AXIATA turun dari 0,0632 menjadi 0,0448, dan TEL turun dari 0,0614 menjadi 0,051344. Namun, RMSE ADVANC meningkat dari 2,1684 menjadi 2,7634. Hasil ini menunjukkan bahwa stabilitas model juga berbeda pada setiap saham dan perlu dievaluasi kembali ketika model diterapkan pada periode data lanjutan.

Secara keseluruhan, penelitian ini menunjukkan bahwa kinerja prediksi harga saham tidak hanya ditentukan oleh model yang digunakan, tetapi juga oleh kesesuaian fitur, struktur lag, dan karakteristik masing-masing saham. H2O Deep Learning dapat memberikan hasil prediksi yang lebih baik daripada ARIMA pada sebagian besar saham, tetapi penambahan indikator teknikal tidak selalu meningkatkan akurasi. Oleh karena itu, pemilihan fitur perlu dilakukan secara sistematis berdasarkan hasil pengujian, bukan hanya berdasarkan penggunaan umum indikator teknikal dalam analisis saham.

6.2 SARAN

Berdasarkan kesimpulan penelitian ini, terdapat beberapa saran yang dapat diajukan untuk penelitian selanjutnya dan penggunaan praktis.

Pertama, penelitian selanjutnya disarankan untuk membandingkan H2O Deep Learning dengan model deep learning lain yang secara khusus dirancang untuk data deret waktu, seperti LSTM, GRU, CNN, atau model berbasis Transformer. Saran ini penting karena H2O Deep Learning dalam penelitian ini bekerja sebagai model feed-forward neural network. Oleh karena itu, informasi temporal perlu dibentuk terlebih dahulu melalui transformasi lag. Berbeda dengan itu, LSTM dan GRU memiliki mekanisme

yang lebih langsung dalam membaca ketergantungan sekuensial antarperiode. Dengan membandingkan beberapa arsitektur, penelitian selanjutnya dapat mengetahui apakah kinerja prediksi lebih dipengaruhi oleh skenario fitur, jumlah lag, atau jenis arsitektur model yang digunakan.

Kedua, penelitian selanjutnya disarankan untuk menggunakan lebih dari satu model baseline. Dalam penelitian ini, ARIMA digunakan sebagai model baseline statistik klasik. Hasil penelitian menunjukkan bahwa H2O Deep Learning menghasilkan RMSE lebih rendah daripada ARIMA pada saham TLKM, ADVANC, dan TEL. Namun, pada saham AXIATA, ARIMA menghasilkan RMSE lebih rendah daripada H2O Deep Learning. Temuan tersebut menunjukkan bahwa model yang lebih kompleks tidak selalu menghasilkan kinerja terbaik pada semua saham. Oleh karena itu, penelitian berikutnya dapat menambahkan baseline lain, seperti Random Walk, Naive Forecasting, ARIMAX, SARIMAX, Random Forest, Support Vector Regression, XGBoost, atau Prophet. Penggunaan beberapa baseline dapat memberikan pembandingan yang lebih kuat dan membantu menilai apakah H2O Deep Learning benar-benar unggul secara konsisten.

Ketiga, penelitian selanjutnya disarankan untuk menguji skenario fitur secara lebih luas. Penelitian ini menguji skenario fitur secara terpisah, yaitu Skenario OHLC, OHLC + RSI, OHLC + MACD, OHLC + Bollinger Bands, OHLC + Entropy Divergence, dan OHLC + Prometheus Topological Persistent Entropy. Hasil penelitian menunjukkan bahwa skenario terbaik berbeda pada setiap saham. TLKM dan ADVANC memperoleh hasil terbaik pada skenario OHLC + RSI, AXIATA pada skenario OHLC + Bollinger Bands, dan TEL pada skenario OHLC + MACD. Oleh karena itu, penelitian berikutnya dapat menguji kombinasi beberapa indikator dalam satu model,

misalnya OHLC + RSI + MACD, OHLC + RSI + Bollinger Bands, atau skenario fitur teknikal dengan indikator berbasis entropi dan topologi. Pengujian ini dapat membantu mengetahui apakah gabungan beberapa indikator mampu memberikan informasi yang lebih baik dibandingkan penggunaan indikator secara terpisah.

Keempat, penelitian selanjutnya disarankan untuk menambahkan variabel lain di luar OHLC dan indikator teknikal. Variabel seperti volume perdagangan, nilai tukar, suku bunga, inflasi, indeks pasar, fundamental perusahaan, sentimen berita, dan sentimen investor dapat memberikan informasi tambahan yang belum sepenuhnya direpresentasikan oleh data harga historis. Hal ini penting karena harga saham tidak hanya dipengaruhi oleh pola harga masa lalu, tetapi juga oleh kondisi ekonomi, kebijakan pasar, kinerja perusahaan, dan respons investor terhadap informasi terbaru. Penambahan variabel eksternal dapat membantu model membaca pergerakan harga secara lebih komprehensif.

Kelima, penelitian selanjutnya disarankan untuk memperluas objek penelitian. Penelitian ini hanya menggunakan empat saham telekomunikasi dari empat negara, yaitu TLKM dari Indonesia, AXIATA dari Malaysia, ADVANC dari Thailand, dan TEL dari Filipina. Perluasan objek dapat dilakukan dengan menambahkan saham telekomunikasi lain, negara ASEAN lain, atau sektor industri lain. Perluasan tersebut dapat membantu menguji apakah hasil penelitian ini hanya berlaku pada saham telekomunikasi tertentu atau dapat diterapkan pada konteks pasar yang lebih luas. Perbandingan lintas sektor juga dapat menunjukkan apakah indikator tertentu lebih sesuai untuk sektor tertentu.

Keenam, penelitian selanjutnya disarankan untuk menerapkan metode validasi yang lebih beragam. Penelitian ini telah menggunakan validasi lanjutan pada periode enam bulan setelah periode pengujian utama dengan skenario fitur dan lag terbaik pada setiap saham. Namun, penelitian berikutnya dapat menggunakan validasi bergulir atau walk-forward validation agar kemampuan model dapat diuji pada beberapa periode waktu secara lebih rinci. Validasi seperti ini penting untuk melihat kestabilan kinerja model ketika kondisi pasar berubah dari waktu ke waktu.

Ketujuh, penelitian selanjutnya perlu memperhatikan konsistensi prapemrosesan data. Periode data, pembagian training dan testing, metode scaling, pembentukan lag, pemilihan fitur, dan metrik evaluasi harus diterapkan secara konsisten. Konsistensi ini penting karena perbedaan perlakuan data dapat memengaruhi nilai RMSE dan menghasilkan perbandingan model yang bias. Hal ini menjadi semakin penting ketika penelitian membandingkan beberapa saham dari negara yang berbeda, karena setiap saham memiliki kalender perdagangan, jumlah observasi, skala harga, dan karakteristik volatilitas yang berbeda.

Bagi peneliti dan pengembang model prediksi, hasil penelitian ini menunjukkan bahwa indikator teknikal perlu diuji secara empiris sebelum digunakan dalam model prediksi. Indikator tidak sebaiknya ditambahkan hanya karena sering digunakan dalam analisis teknikal. Setiap indikator perlu dibandingkan dengan skenario OHLC agar kontribusinya terhadap penurunan error prediksi dapat diketahui dengan jelas. Hasil penelitian ini juga menunjukkan bahwa indikator yang efektif pada satu saham belum tentu efektif pada saham lain.

Bagi praktisi, hasil penelitian ini dapat digunakan sebagai referensi awal dalam pengembangan sistem analitik prediktif untuk saham telekomunikasi. Namun, hasil model tidak sebaiknya digunakan sebagai satu-satunya dasar dalam pengambilan keputusan investasi. Prediksi harga saham tetap perlu dilengkapi dengan analisis fundamental, analisis makroekonomi, analisis risiko, likuiditas pasar, dan informasi terbaru. Oleh karena itu, output model lebih tepat digunakan sebagai alat pendukung keputusan, bukan sebagai rekomendasi langsung untuk membeli, menjual, atau menahan saham.

DAFTAR PUSTAKA

- Adebiyi, A. A., Adewumi, A. O., & Ayo, C. K. (2014). Comparison of ARIMA and artificial neural networks models for stock price prediction. *Journal of Applied Mathematics*, 2014, Article 614342.
- Adsure, A., Deshpande, A., Bendale, G., Bhawar, P., & Kulkarni, R. A. (2025). Stock price and Nifty 50 index forecasting using LNN and BiLSTM-based deep learning models. *International Journal of Scientific Research in Engineering and Management*, 9(4), 1–6.
- Advanced Info Service Public Company Limited. (2024). *Annual report 2023*. Advanced Info Service Public Company Limited.
- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19(6), 716–723.
- Alam, S., Hidayah, M. N. S., Ashif, M., Bakri, R., & Hamzah, M. Q. (2026). Deep learning for investment decision support: A SimpleRNN approach to stock price prediction with real-time API deployment. *Online Journal of Management, Innovation, Economics, and Digital Studies*, 1(1), 16–26.
- Alhaziva, M. B. Y., Sunarsih, & Herdiana, R. (2023). Analysis and prediction of Bollinger Bands to predict stock prices in determining investment strategies. *International Journal of Current Science Research and Review*, 6(11), 7158–7168.
- AlQahtani, H. S., Alhaddad, M. J., & Jarrah, M. (2026). Deep learning-based stock price forecasting for the Saudi telecommunication sector: A comparative evaluation with baseline models. *Journal of Advances in Information Technology*, 17(4), 696–710.
- Ariyo, A. A., Adewumi, A. O., & Ayo, C. K. (2014). Stock price prediction using the ARIMA model. In *2014 UKSim-AMSS 16th International Conference on Computer Modelling and Simulation* (pp. 106–112). IEEE.

- Armstrong, J. S. (2006). Findings from evidence-based forecasting: Methods for reducing forecast error. *International Journal of Forecasting*, 22(3), 583–598.
- Axiata Group Berhad. (2025). *Integrated annual report 2024*. Axiata Group Berhad.
- Ayyıldız, N. (2025). Predicting market direction with deep learning: An application on E-7 country stock markets. *Maliye Finans Yazıları*, 40(123), 92–111.
- Bao, W., Yue, J., & Rao, Y. (2017). A deep learning framework for financial time series using stacked autoencoders and long-short term memory. *PLOS ONE*, 12(7), Article e0180944.
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: Forecasting and control* (5th ed.). Wiley.
- Burnham, K. P., & Anderson, D. R. (2002). *Model selection and multimodel inference: A practical information-theoretic approach* (2nd ed.). Springer.
- Cariolle, J. (2012). *Measuring macroeconomic volatility*. Fondation pour les Études et Recherches sur le Développement International.
- Cerqueira, V., Torgo, L., & Mozetič, I. (2020). Evaluating time series forecasting models: An empirical study on kinerjance estimation methods. *Machine Learning*, 109, 1997–2028.
- Cerqueira, V., Torgo, L., & Mozetič, I. (2020). Evaluating time series forecasting models: An empirical study on kinerjance estimation methods. *Machine Learning*, 109, 1997–2028.
- Chaengkham, S., & Wianwiwat, S. (2021). Stock market index prediction using machine learning: Evidence from leading Southeast Asian countries. *Thailand and The World Economy*, 39(2), 56–64.

- 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, 1247–1250.
- Chung, J., Gülçehre, Ç., Cho, K., & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv*.
- de Jesus, L. C., Jr., Fernández-Navarro, F., & Carbonero-Ruz, M. (2025). Enhancing financial time series forecasting through topological data analysis. *Neural Computing and Applications*, 37, 6527–6545.
- Dhokane, R. M., & Agarwal, S. (2024). LSTM deep learning based stock price prediction with Bollinger Band, RSI, MACD, and OHLC features. *International Journal of Intelligent Systems and Applications in Engineering*, 12(3), 1169–1176.
- Dickey, D. A., & Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American Statistical Association*, 74(366), 427–431.
- Ding, X., & Zhou, Z. (2025). On the partial autocorrelation function for locally stationary time series: Characterization, estimation and inference. *Biometrika*, 112(2), Article asaf016.
- Dwiandiyanta, B. Y., Hartanto, R., & Ferdiana, R. (2025). Harnessing deep learning and technical indicators for enhanced stock predictions of blue-chip stocks on the Indonesia Stock Exchange (IDX). *Engineering, Technology & Applied Science Research*, 15(1), 20348–20357.
- Ependi, Z., & Firmananda, F. I. (2025). Predictive modeling of Unilever Indonesia's stock prices with linear regression: A RapidMiner-based approach. *Journal of Engineering and Science Application*, 2(2), 29–37.
- Fathali, Z., Kodia, Z., & Ben Said, L. (2022). Stock market prediction of NIFTY 50 index applying machine learning techniques. *Applied Artificial Intelligence*, 36(1), Article 2111134.

- Fatima, S. S. W., & Rahimi, A. (2024). A review of time-series forecasting algorithms for industrial manufacturing systems. *Machines*, 12(6), Article 380.
- Fiszeder, P., Fałdziński, M., & Molnár, P. (2023). Modeling and forecasting dynamic conditional correlations with opening, high, low, and closing prices. *Journal of Empirical Finance*, 70, 308–321.
- Gidea, M. (2017). Topology data analysis of critical transitions in financial networks. *arXiv*.
- Gidea, M., & Katz, Y. (2017). Topological data analysis of financial time series: Landscapes of crashes. *Physica A: Statistical Mechanics and Its Applications*, 491, 820–834.
- Giantsidi, S., & Tarantola, C. (2025). Deep learning for financial forecasting: A review of recent trends. *International Review of Economics & Finance*, 104, Article 104719.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Goodwin, P., Petropoulos, F., & Hyndman, R. J. (2017). A note on upper bounds for forecast-value-added relative to naïve forecasts. *Journal of the Operational Research Society*, 68(9), 1082–1084.
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2019). *Multivariate data analysis* (8th ed.). Cengage Learning.
- H2O.ai. (2024). *Deep learning (neural networks)*. H2O.ai Documentation.
- Hodson, T. O. (2022). Root-mean-square error (RMSE) or mean absolute error (MAE): When to use them or not. *Geoscientific Model Development*, 15, 5481–5487.
- Htun, H. H., Biehl, M., & Petkov, N. (2023). Survey of feature selection and extraction techniques for stock market prediction. *Financial Innovation*, 9, Article 26.

- Huang, W., Wang, H., & Wang, S. (2024). A structural VAR and VECM modeling method for open-high-low-close data contained in candlestick chart. *Financial Innovation*, 10, Article 97.
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688.
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts.
- Hyndman, R. J., & Khandakar, Y. (2008). Automatic time series forecasting: The forecast package for R. *Journal of Statistical Software*, 27(3), 1–22.
- Hyndman, R. J., & Kostenko, A. V. (2007). Minimum sample size requirements for seasonal forecasting models. *Foresight: The International Journal of Applied Forecasting*, 6, 12–15.
- Idrees, S. M., Alam, M. A., & Agarwal, P. (2019). A prediction approach for stock market volatility based on time series data. *IEEE Access*, 7, 17287–17298.
- Iftikhar, H., Khan, F., Torres Armas, E. A., Rodrigues, P. C., & López-Gonzales, J. L. (2025). A novel hybrid framework for forecasting stock indices based on the nonlinear time series models. *Computational Statistics*, 40, 4163–4186.
- Ji, G., Yu, J., Hu, K., Xie, J., & Ji, X. (2022). An adaptive feature selection schema using improved technical indicators for predicting stock price movements. *Expert Systems with Applications*, 200, Article 116941.
- Kabir, M. R., Bhadra, D., Ridoy, M., & Milanova, M. (2025). LSTM–Transformer-based robust hybrid deep learning model for financial time series forecasting. *Sci*, 7(1), Article 7.

- Kalange, D. N. (2025). Advancements in stock price prediction: Integrating statistical, machine learning, and deep learning models. *International Journal on Science and Technology*, 16(3), 1–11.
- Kang, B.-K. (2021). Improving MACD technical analysis by optimizing parameters and modifying trading rules: Evidence from the Japanese Nikkei 225 futures market. *Journal of Risk and Financial Management*, 14(1), Article 37.
- Kang, S., & Kim, J.-K. (2025). Stock price prediction using triple barrier labeling and raw OHLCV data: Evidence from Korean markets. *arXiv*.
- Khairudin, S., Elias, S. M., Kamil, K. H., & Chukari, N. A. (2022). Application of Relative Strength Index oscillator for equity portfolio construction in Malaysia. In *European Proceedings of Multidisciplinary Sciences: ICONSPADU 2021* (pp. 34–43). European Publisher.
- Kim, S., Ku, S., Chang, W., & Song, J. W. (2020). Predicting the direction of US stock prices using effective transfer entropy and machine learning techniques. *IEEE Access*, 8, 111660–111682.
- Kingma, D. P., & Ba, J. (2015). Adam: A method for stochastic optimization. In *International Conference on Learning Representations*.
- Kolambe, M., & Arora, S. (2024). Forecasting the future: A comprehensive review of time series prediction techniques. *Journal of Electrical Systems*, 20(2s), 575–586.
- Kopczewski, T., & Bil, Ł. (2024). Exploring stock markets dynamics: A two-dimensional entropy approach in return/volume space. *Bank i Kredyt*, 55(6), 731–758.
- Kulkarni, S., Pharasi, H. K., Vijayaraghavan, S., Kumar, S., Chakraborti, A., & Samal, A. (2023). Investigation of Indian stock markets using topological data analysis and geometry-inspired network measures. *arXiv*.

- Le, T. A. T. (2025). The impact of digital transformation on economic integration in ASEAN-4: Evidence from a generalized least squares (GLS) model. *Journal of Risk and Financial Management*, 18(4), Article 189.
- LeCun, Y., Bottou, L., Orr, G. B., & Müller, K.-R. (1998). Efficient BackProp. In G. B. Orr & K.-R. Müller (Eds.), *Neural networks: Tricks of the trade* (pp. 9–50). Springer.
- Leites, J., Cerqueira, V., & Soares, C. (2024). Lag selection for univariate time series forecasting using deep learning: An empirical study. *arXiv*.
- Li, A. W., & Bastos, G. S. (2020). Stock market forecasting using deep learning and technical analysis: A systematic review. *IEEE Access*, 8, 185232–185242.
- Li, Z., Han, J., & Song, Y. (2020). On the forecasting of high-frequency financial time series based on ARIMA model improved by deep learning. *Journal of Forecasting*, 39(7), 1081–1097.
- Ljung, G. M., & Box, G. E. P. (1978). On a measure of lack of fit in time series models. *Biometrika*, 65(2), 297–303.
- Lu, Q., & Moorthy, R. (2025). US-China digital infrastructure competition in Southeast Asia: Strategies and implications for ASEAN's 5G future. *Journal of International Studies*, 21(2), 45–67.
- Luo, T., Wei, G., & Zhang, F. (2025). A study of the impact of corporate market forecasting capability on the accuracy of strategic decision-making based on computational analysis of business data. *Journal of Combinatorial Mathematics and Combinatorial Computing*, 127b, 6081–6097.
- Malibari, N., Katib, I., & Mehmood, R. (2021). Predicting stock closing prices in emerging markets with transformer neural networks: The Saudi Stock Exchange case. *International Journal of Advanced Computer Science and Applications*, 12(12), 876–886.

- Marleny, F. D., & Mambang. (2022). Predictive modeling classification of post-flood and abrasion effects with deep learning approach. *TIERS Information Technology Journal*, 3(1), 1–10.
- Massaro, A., Maritati, V., & Galiano, A. (2018). Data mining model kinerjance of sales predictive algorithms based on RapidMiner workflows. *International Journal of Computer Science & Information Technology*, 10(3), 39–54.
- Melda, Mira, & Nurlina. (2025). Analysis of the effectiveness of RSI and MACD indicators in addressing stock price volatility. *Wiga: Jurnal Penelitian Ilmu Ekonomi*, 15(1), 71–79.
- Ming, K. L. Y., Jais, M., & Soon, L. P. (2022). New approach for e-commerce stock prices prediction: Combination of machine learning and technical analysis. *International Journal of Academic Research in Accounting, Finance and Management Sciences*, 12(3), 653–665.
- Moedjahedy, J. H., Rotikan, R., Roshandi, W. F., & Mambu, J. Y. (2020). Stock price forecasting on telecommunication sector companies in Indonesia Stock Exchange using machine learning algorithms. In *2020 2nd International Conference on Cybernetics and Intelligent System (ICORIS)* (pp. 1–4). IEEE.
- Montesinos López, O. A., Montesinos López, A., & Crossa, J. (2022). Fundamentals of artificial neural networks and deep learning. In *Multivariate statistical machine learning methods for genomic prediction* (pp. 379–425). Springer.
- Moodi, F., & Jahangard-Rafsanjani, A. (2024). Integrating feature selection and regression methods with technical indicators for predicting Apple Inc. stock prices. *arXiv*.
- Mostafavi, S. M., & Hooman, A. R. (2025). Key technical indicators for stock market prediction. *Machine Learning with Applications*, 20, Article 100631.

- Naik, N., & Mohan, B. R. (2020). Intraday stock prediction based on deep neural network. *National Academy Science Letters*, 43, 241–246.
- National Institute of Standards and Technology. (2012). *NIST/SEMATECH e-Handbook of statistical methods*. U.S. Department of Commerce.
- Nti, I. K., Adekoya, A. F., & Weyori, B. A. (2020). A systematic review of fundamental and technical analysis of stock market predictions. *Artificial Intelligence Review*, 53, 3007–3057.
- Nhlapho, W. J., Atemkeng, M., & Ndogmo, J.-C. (2025). An attention-guided hybrid statistical and deep learning modeling for enhanced time series forecasting: A case study of South African telecommunication companies. *Scientific African*, 30, Article e02950.
- Olbryś, J., & Ostrowski, K. (2021). An entropy-based approach to measurement of stock market depth. *Entropy*, 23(5), Article 568.
- Pathak, P. (2024). Stock market prediction using machine learning. *International Journal for Multidisciplinary Research*, 6(1), 1–13.
- PLDT Inc. (2025). *Annual report 2024*. PLDT Inc.
- PT Telkom Indonesia (Persero) Tbk. (2025). *Annual report 2024*. PT Telkom Indonesia (Persero) Tbk.
- Said, S. E., & Dickey, D. A. (1984). Testing for unit roots in autoregressive-moving average models of unknown order. *Biometrika*, 71(3), 599–607.
- Seabold, S., & Perktold, J. (2010). Statsmodels: Econometric and statistical modeling with Python. In *Proceedings of the 9th Python in Science Conference* (pp. 92–96).
- Sen, J., Mondal, S., & Nath, G. (2022). *Robust portfolio design and stock price prediction using an optimized LSTM model*.

- Sebastian, A., & Tania, V. (2024). Deep learning for stock price prediction and portfolio optimization. *International Journal of Advanced Computer Science and Applications*, 15(9), 926–941.
- 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, Article 106181.
- Shternshis, A., & Mazzarisi, P. (2024). Variance of entropy for testing time-varying regimes with an application to meme stocks. *Decisions in Economics and Finance*, 47, 215–258.
- Shternshis, A., Mazzarisi, P., & Marmi, S. (2022). Measuring market efficiency: The Shannon entropy of high-frequency financial time series. *Chaos, Solitons & Fractals*, 162, Article 112403.
- Shumway, R. H., & Stoffer, D. S. (2017). *Time series analysis and its applications: With R examples* (4th ed.). Springer.
- Shynkevich, Y., McGinnity, T. M., Coleman, S., Belatreche, A., & Li, Y. (2017). Forecasting price movements using technical indicators: Investigating the impact of varying input window length. *Neurocomputing*, 264, 71–88.
- Singaravel, S., Suykens, J., & Geyer, P. (2018). Deep-learning neural-network architectures and methods: Using component-based models in building-design energy prediction. *Advanced Engineering Informatics*, 38, 81–90.
- Suleiman, D., Al-Zewairi, M., Etaiwi, W., & Al-Naymat, G. (2020). Empirical evaluation of the classification of deep learning under big data processing platforms. *International Journal of Advanced Trends in Computer Science and Engineering*, 9(5), 9189–9196.
- Supri, B., Rudianto, Abdurrohm, Mawadah, B., & Ali, H. (2023). Asian stock index price prediction analysis using comparison of split data training and data testing. *JEMSI (Jurnal Ekonomi, Manajemen, dan Akuntansi)*, 9(4), 1403–1408.

- Thampanya, N., Wu, J., Nasir, M. A., & Liu, J. (2020). Fundamental and behavioural determinants of stock return volatility in ASEAN-5 countries. *Journal of International Financial Markets, Institutions and Money*, 65, Article 101193.
- TradingView. (n.d.). *Technical analysis: Indicators and strategies*.
- Tiyasha, Tung, T. M., & Yaseen, Z. M. (2021). Deep learning for prediction of water quality index classification: Tropical catchment environmental assessment. *Natural Resources Research*, 30(6), 4235–4254.
- Tsay, R. S. (2010). *Analysis of financial time series* (3rd ed.). Wiley.
- Van Poucke, S., Zhang, Z., Schmitz, M., Vukicevic, M., Vander Laenen, M., Celi, L. A., & De Deyne, C. (2016). Scalable predictive analysis in critically ill patients using a visual open data analysis platform. *PLOS ONE*, 11(1), Article e0145791.
- Viargo, A. K. B., Hikami, M. I., Hardiyanto, R., Huda, M. F., Isadika, A., & Mardianto, M. F. F. (2022). Prediction of telecommunication service providers' stock prices in Indonesia to support the digital economy. *International Journal of Mathematics and Computer Research*, 10(7), 2785–2788.
- Vuong, P. H., Phu, L. H., Nguyen, T. H. V., Duy, L. N., Bao, P. T., & Trinh, T. D. (2024). A bibliometric literature review of stock price forecasting: From statistical model to deep learning approach. *Science Progress*, 107(1), 1–31.
- Wang, H., Huang, W., & Wang, S. (2021). Forecasting open-high-low-close data contained in candlestick chart. *arXiv*.
- Yen, P. T.-W., & Cheong, S. A. (2021). Using topological data analysis (TDA) and persistent homology to analyze the stock markets in Singapore and Taiwan. *Frontiers in Physics*, 9, Article 572216.
- Yu, P., & Yan, X. (2019). Stock price prediction based on deep neural networks. *Neural Computing and Applications*, 32, 1609–1628.

- Ratchagit, M., & Xu, H. (2022). A two-delay combination model for stock price prediction. *Mathematics*, 10(19), 3447.
- Zeiler, M. D. (2012). ADADELTA: An adaptive learning rate method. *arXiv*.
- Zeng, Z. (2024). The impact of the regional military conflict in global stock and commodity market. *SHS Web of Conferences*, 181, Article 02017.
- Zhang, C., Sjarif, N. N. A., & Ibrahim, R. (2024). Deep learning models for price forecasting of financial time series: A review of recent advancements: 2020–2022. *WIREs Data Mining and Knowledge Discovery*, 14(1), Article e1519.
- Zhao, C., Wu, M., Liu, J., Duan, Z., Li, J., Shen, L., Shangguan, X., Liu, D., & Wang, Y. (2023). Progress and prospects of data-driven stock price forecasting research. *International Journal of Cognitive Computing in Engineering*, 4, 100–108.
- Zhao, X., Liang, C., Zhang, N., & Shang, P. (2019). Quantifying the multiscale predictability of financial time series by an information-theoretic approach. *Entropy*, 21(7), Article 684.
- Witten, I. H., & Frank, E. (2005). *Data mining: Practical machine learning tools and techniques* (2nd ed.). Morgan Kaufmann.
- Witten, I. H., Frank, E., Hall, M. A., & Pal, C. J. (2016). *Data mining: Practical machine learning tools and techniques* (4th ed.). Morgan Kaufmann.
- Botchkarev, A. (2019). A new typology design of kinerjance metrics to measure errors in machine learning regression algorithms. *Interdisciplinary Journal of Information, Knowledge, and Management*, 14, 45–79.