

Stock Price Prediction Using Machine Learning - Based on RNN Algorithms

Akhiyar Waladi

Universitas Jambi, Fakultas Sains dan Teknologi, Jambi, Indonesia

E-mail: akhiyar.waladi@unja.ac.id

Yogi Perdana

Universitas Jambi, Fakultas Sains dan Teknologi, Jambi, Indonesia

E-mail: yogi.perdana@unja.ac.id

*Corresponding Author

Hasanatul Iftitah

Universitas Jambi, Fakultas Sains dan Teknologi, Jambi, Indonesia

E-mail: hasanatul.iftitah@unja.ac.id

Nindy Raisa Hanum

Universitas Jambi, Fakultas Sains dan Teknologi, Jambi, Indonesia

E-mail: nindyraisanum01@unja.ac.id

Received: Date Month, Year; Accepted: Date Month, Year; Published: Date Month, Year

Abstract: A Recurrent Neural Network (RNN) model has been developed to predict Bank Rakyat Indonesia (BRI) stock prices through extensive parameter optimization using grid search. The optimal configuration was achieved with an architecture of 150 RNN units, batch size of 32, learning rate of 0.001, and training process over 100 epochs. The model achieved its best performance with MSE of 12924.081, RMSE of 113.6841, MAE of 86.0699, R^2 of 0.749, and MAPE of 1.7438%. Error distribution analysis revealed the model's tendency to slightly underestimate with a mean error of -23.9 and standard deviation of 111.14. Time step importance evaluation showed that data from the last 7-8 days had the greatest influence on predictions. The model demonstrated best performance in sideways market conditions (R^2 0.6833, MAPE 1.99%) compared to bull market (R^2 0.4155, MAPE 3.02%) and bear market (R^2 0.0505, MAPE 3.30%). Visual analysis confirmed the model's ability to follow long-term trends while maintaining measured responses to short-term volatility. The research results indicate that the developed RNN model can serve as a reliable investment decision support tool, particularly in relatively stable market conditions.

Keywords: Recurrent Neural Network (RNN), Stock Price Prediction, Bank Rakyat Indonesia (BRI), Time Series Analysis, Machine Learning, Market Conditions, Investment Decision Support

1. Introduction

Pasar saham merupakan salah satu instrumen investasi yang paling dinamis dan kompleks dalam sistem keuangan modern. Prediksi pergerakan harga saham telah menjadi fokus penelitian yang signifikan dalam bidang keuangan dan teknologi informasi, mengingat dampaknya yang besar terhadap pengambilan keputusan investasi dan manajemen risiko [1]. Volatilitas harga saham yang tinggi dan ketergantungannya pada berbagai faktor ekonomi, sosial, dan politik membuat prediksi harga saham menjadi tantangan yang kompleks bagi para investor dan analis keuangan.

Dalam dekade terakhir, perkembangan teknologi machine learning telah membuka perspektif baru dalam analisis dan prediksi data keuangan. Khususnya, *Recurrent Neural Network* (RNN) telah menunjukkan potensi yang menjanjikan dalam memahami dan memprediksi pola temporal yang kompleks dalam data time series [2]. Berbeda dengan arsitektur neural network konvensional, RNN memiliki kemampuan untuk mempertahankan informasi dari data sebelumnya melalui mekanisme memori internal, yang sangat relevan untuk analisis data pasar saham yang bersifat sekuensial.

Keunggulan RNN dalam menangani data sekuensial terletak pada arsitekturnya yang memungkinkan pemrosesan informasi temporal secara efektif. Varian RNN seperti *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) telah terbukti mampu mengatasi masalah vanishing gradient yang umum ditemui dalam analisis data time series panjang [3]. Kemampuan ini sangat penting dalam konteks prediksi harga saham, di mana pola historis dan tren jangka panjang memainkan peran krusial dalam pergerakan harga di masa depan. Meskipun berbagai penelitian telah dilakukan

dalam bidang prediksi harga saham menggunakan machine learning, masih terdapat ruang untuk peningkatan akurasi dan reliabilitas model prediksi. Tantangan utama terletak pada kompleksitas pasar saham yang dipengaruhi oleh berbagai faktor, termasuk sentimen pasar, kondisi makroekonomi, dan peristiwa global yang tidak terduga [4]. Oleh karena itu, pengembangan model prediksi yang lebih sophisticated dengan memanfaatkan kelebihan algoritma RNN menjadi sangat relevan untuk penelitian lebih lanjut.

Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model prediksi harga saham berbasis RNN yang dapat mengintegrasikan berbagai faktor yang mempengaruhi pergerakan harga saham. Dengan memanfaatkan kemampuan RNN dalam memproses data sekuensial dan mengidentifikasi pola temporal yang kompleks, penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam meningkatkan akurasi prediksi harga saham dan pemahaman yang lebih baik tentang dinamika pasar keuangan.

2. Related Work

Penelitian terkait prediksi harga saham menggunakan machine learning telah berkembang secara signifikan dalam beberapa tahun terakhir. Pada [5] mendemonstrasikan keunggulan pendekatan deep learning dengan peningkatan akurasi 15-20% dibandingkan metode statistik konvensional, sementara [6] mengembangkan model hybrid yang mengintegrasikan analisis teknikal dengan deep learning, mencapai akurasi 76% untuk prediksi jangka pendek pada indeks S&P 500. Dalam konteks arsitektur spesifik, pada [7] mengidentifikasi keterbatasan RNN konvensional untuk prediksi jangka panjang, namun [8] menunjukkan bahwa implementasi LSTM dapat meningkatkan akurasi sebesar 18% dibanding RNN standar melalui kemampuannya menangani vanishing gradient. Pada [9] lebih lanjut mengembangkan pendekatan Bidirectional RNN yang memberikan peningkatan akurasi 12%, sementara [10] mengintegrasikan analisis sentimen yang meningkatkan akurasi hingga 8% pada periode volatilitas tinggi. Pada [11] memperkaya model dengan menggabungkan 20 indikator teknikal dan 10 metrik fundamental, mencapai akurasi 82% untuk prediksi mingguan. Pada [12] mengimplementasikan mekanisme attention yang meningkatkan performa 15%, sedangkan [13] mengusulkan pendekatan ensemble yang mengurangi variance sebesar 23%. Meskipun demikian, [14] mencatat bahwa tantangan signifikan masih ada, terutama dalam menangani *black swan events* yang dapat menyebabkan penurunan akurasi hingga 40% selama periode krisis pasar.

3. Methodology

3.1 Pengumpulan Data

Penelitian ini menggunakan pendekatan kuantitatif dengan menerapkan model *Recurrent Neural Network* (RNN) untuk memprediksi harga saham Bank Rakyat Indonesia (BRI). Data yang digunakan mencakup periode dari Februari 2023 hingga Oktober 2024 yang diperoleh dari <https://finance.yahoo.com/>.

3.2 Preprocessing Data

Normalisasi data merupakan proses membuat skala nilai pada variabel sehingga data berada pada rentang nilai yang sama. Tujuan dari normalisasi data adalah menghindari fitur yang memiliki nilai yang lebih besar mendominasi fitur yang memiliki nilai lebih kecil [15]. Data perlu diproses terlebih dahulu dan dinormalisasi secara seragam untuk menyesuaikan skala data ke rentang [0, 1]:

$$x^1 = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$


3.3 Grid Search

Proses pengembangan model dimulai dengan melakukan grid search yang ekstensif untuk menemukan konfigurasi parameter optimal. *Grid search* adalah proses pemilihan kombinasi parameter model dan hyperparameter dengan menguji setiap kombinasi secara individual serta memvalidasinya. Tujuannya adalah untuk menemukan kombinasi yang menghasilkan model dengan performa terbaik yang bisa dipilih sebagai model prediksi [16].

3.4 Network Model

Tujuan RNN (*Recurrent Neural Network*) adalah untuk menangani data yang berbentuk *sequence*. Dalam model jaringan saraf tradisional, setiap lapisan—dari *input* ke lapisan tersembunyi hingga *output*—terhubung sepenuhnya, tetapi node di antara lapisan-lapisan tersebut tidak saling berhubungan. Namun, jaringan saraf biasa tidak dapat mengatasi berbagai jenis masalah secara efektif. RNN disebut *Recurrent Neural Network* karena output saat ini dari suatu urutan juga dipengaruhi oleh *output* sebelumnya. Jaringan ini menyimpan informasi dari waktu sebelumnya dan menggunakannya dalam perhitungan *output* saat ini. Dengan demikian, node di antara lapisan tersembunyi saling terhubung, bukan terputus. Input untuk lapisan tersembunyi mencakup *output* dari lapisan *input* serta output dari lapisan

tersembunyi di waktu sebelumnya. Secara teori, RNN mampu memproses data berurutan dengan panjang apa pun [17].



Gambar 1. Struktur *Hidden Layer RNN*

3.5 Performance evaluation index

Performa eksperimental dievaluasi menggunakan MAE, MSE, RMSE, MAPE, dan R^2 .

MAE merupakan *Mean Absolute Error*:

$$MAE = \left(\frac{1}{n}\right) \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

MSE merupakan *mean square error*:

$$MSE = \left(\frac{1}{n}\right) \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3)$$

RMSE merupakan *Root Mean Square Error*:

$$RMSE = \sqrt{\left(\frac{1}{n}\right) \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

MAPE merupakan *Mean Absolute Percentage Error*:

$$MAPE = \left(\frac{1}{n}\right) \sum_{i=1}^n |y_i - \hat{y}_i| \times 100\% \quad (5)$$

R^2 merupakan *R-Square*:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (6)$$

Di mana:

y_i = actual

$\hat{y}_i$ = predict

$\bar{y}$ = mean

4. Result and Discussion

4.1 Parameter Optimal Model

Dalam penelitian ini, model RNN telah melalui proses *grid search* yang ekstensif untuk menemukan konfigurasi optimal. Dari berbagai kombinasi parameter yang diuji, model mencapai performa terbaik dengan arsitektur yang relatif kompleks, yaitu menggunakan 150 unit RNN. Jumlah unit yang cukup besar ini memungkinkan model untuk menangkap pola-pola kompleks dalam pergerakan harga saham BRI. Proses training dilakukan selama 100 epochs, memberikan waktu yang cukup bagi model untuk mempelajari pola data secara mendalam tanpa mengalami *overfitting* yang signifikan.

Tabel 1. Hasil Seluruh Kombinasi *Grid Search*

RNN Units	Epochs	Batch Size	Learning Rate	MSE	RMSE	MAE	R2	MAPE
50	50	64	0.001	41566.7	203.879	178.647	0.7545	3.5412
50	50	64	0.0001	57009.3	238.766	200.711	0.5166	4.148
50	100	32	0.001	33176.7	182.14	157.264	0.3884	3.1256
50	100	32	0.0001	37730.9	194.242	169.036	0.4825	3.3518

100	50	64	0.001	35061.8	187.244	152.522	0.0869	3.1355
100	50	64	0.0001	37431.8	193.472	157.709	0.0505	3.2494
100	100	32	0.001	32847	181.237	143.767	0.362	2.9362
100	100	32	0.0001	28826.8	169.785	136.854	0.558	2.7788
150	50	32	0.001	24781.7	156.433	124.891	0.5187	2.5319
150	50	32	0.0001	28074.2	167.412	140.263	0.3044	2.7968
150	100	64	0.001	25991.5	161.219	130.802	0.4952	2.6461
150	100	64	0.0001	28826.8	169.785	136.854	0.558	2.7788
150	100	32	0.001	12924.081	113.6841	86.0699	0.749	1.7438
150	100	32	0.0001	22756.8	150.847	121.487	0.4401	2.4415

Batch size 32 dipilih sebagai ukuran optimal, memberikan keseimbangan antara kecepatan training dan kemampuan generalisasi. Ukuran batch yang relatif kecil ini memungkinkan update parameter yang lebih sering dan granular, yang pada akhirnya berkontribusi pada konvergensi model yang lebih baik. *Learning rate* 0.001 terbukti ideal untuk proses optimasi, cukup besar untuk memungkinkan pembelajaran yang efisien namun cukup kecil untuk mencegah overshooting minimum lokal. Konfigurasi optimal ini menghasilkan metrik performa yang sangat menjanjikan. *Mean Squared Error* (MSE) sebesar 12924.0814 dan *Root Mean Squared Error* (RMSE) sebesar 113.6841 menunjukkan tingkat deviasi prediksi yang relatif kecil dibandingkan dengan skala harga saham BRI. *Mean Absolute Error* (MAE) sebesar 86.0699 mengkonfirmasi bahwa rata-rata kesalahan prediksi berada dalam batas yang dapat diterima untuk aplikasi praktis.


Nilai *R-squared* (R^2) sebesar 0.7490 mengindikasikan bahwa model mampu menjelaskan 74.90% variasi dalam data, sebuah pencapaian yang signifikan mengingat kompleksitas dan volatilitas pasar saham. Yang lebih mengesankan, *Mean Absolute Percentage Error* (MAPE) yang sangat rendah sebesar 1.7438% menunjukkan bahwa prediksi model sangat akurat dalam konteks persentase, membuat model ini sangat relevan untuk aplikasi praktis dalam trading dan investasi.

4.2 Analisis Error dan Time Step Importance

Tabel 2. Karakteristik Distribusi Error

Metrik	Nilai	Interpretasi	Implikasi Prediksi
Mean Error	-23.9	Slight underestimation	Model cenderung memprediksi lebih rendah, mendukung pendekatan konservatif
Standard Deviation	111.14	Dispersi terkendali	Konsistensi prediksi baik dengan variasi error yang dapat diantisipasi
Range Error	-400 hingga +200	Asimetris ke negatif	Model lebih sensitif terhadap potensi penurunan harga
Frekuensi Tertinggi	±0 (6 kejadian)	Terpusat di sekitar nol	Mayoritas prediksi sangat mendekati nilai aktual
Error Concentration	±200 poin	Mayoritas error terbatas	Model reliabel dalam kondisi pasar normal dengan error yang terkendali

Analisis distribusi *error* dan *time step importance* memberikan pemahaman yang mendalam tentang karakteristik dan cara kerja model dalam memprediksi harga saham BRI. Hasil pengamatan menunjukkan *mean error* sebesar -23.90 dengan standard deviasi 111.14, mengindikasikan kecenderungan model untuk sedikit underestimate dalam prediksinya. Meski terdapat bias negatif, magnitudenya relatif kecil dibandingkan skala harga saham BRI, menunjukkan bahwa model tetap dapat diandalkan untuk pengambilan keputusan investasi.




Gambar 2. Distribusi Error dan Time Step Importance

Visualisasi distribusi error pada Gambar 1 menampilkan pola dengan frekuensi tertinggi terpusat di sekitar nol dengan dua puncak yang hampir sama tinggi (sekitar 6 kejadian). Distribusi yang relatif simetris namun memiliki ekor lebih panjang ke arah negatif (*negative skew*) memperkuat indikasi kecenderungan model untuk memberikan prediksi yang konservatif. *Outlier* yang terlihat hingga -400 dan +200 poin menunjukkan bahwa model terkadang mengalami kesulitan dalam memprediksi pergerakan ekstrem, meskipun kejadian ini relatif jarang (1-2 kasus).

Sementara itu, analisis *time step importance* pada Gambar 2 mengungkapkan bagaimana model memproses informasi temporal. *Impact score* meningkat secara signifikan dari t-0 hingga t-8, dengan t-8 memiliki pengaruh terbesar (*impact score* sekitar 0.09). Time steps t-0 hingga t-3 menunjukkan pengaruh yang relatif kecil (< 0.02), diikuti peningkatan moderat pada t-4 hingga t-6 (0.02 - 0.06), dan lonjakan signifikan pada t-7 dan t-8 (0.08 - 0.09). Pola ini mengindikasikan bahwa model memberikan bobot lebih tinggi pada data 7-8 hari terakhir untuk menghasilkan prediksi yang akurat.

Kombinasi kedua analisis ini menunjukkan bahwa model memiliki karakteristik prediktif yang seimbang. Di satu sisi, distribusi error yang terkendali mencerminkan reliabilitas prediksi, sementara pola *time step importance* mengonfirmasi kemampuan model dalam memanfaatkan momentum jangka menengah. Pendekatan konservatif model, yang tercermin dari kecenderungan underestimate dan fokus pada data recent, mendukung penggunaan model ini sebagai alat prediksi yang hati-hati dan reliable untuk pengambilan keputusan investasi.

4.2 Evaluasi Training Process



Gambar 3. Kurva Learning dan MAE selama Proses Training

Visualisasi proses training pada Gambar 3 menampilkan dua metrik utama: loss function (MSE) dan Mean Absolute Error (MAE), yang keduanya menunjukkan evolusi pembelajaran model yang efektif. Grafik ini terbagi menjadi dua panel yang memberikan insight mendalam tentang proses pembelajaran model.

Panel *Loss Function* menunjukkan pola pembelajaran yang ideal:

- Fase awal pembelajaran (0-10 epoch) ditandai dengan penurunan loss yang tajam, mengindikasikan adaptasi model yang cepat.
- Periode stabilisasi (epoch 20-80) menunjukkan penurunan gradual dengan gap minimal antara training dan validation loss.
- Fase akhir (epoch 80-100) mencapai konvergensi yang stabil, menandakan model telah mencapai titik optimal.

Panel MAE memberikan konfirmasi tambahan tentang kualitas pembelajaran:

- Training dan validation MAE menunjukkan tren penurunan yang konsisten.

- Gap antara training dan validation MAE terjaga stabil, mengindikasikan generalisasi yang baik.
- Tidak terlihat tanda-tanda *overfitting* yang ditunjukkan oleh stabilnya validation MAE.
- Model mencapai performa optimal dengan MAE final sekitar 0.05, menunjukkan tingkat akurasi prediksi yang tinggi.

Keseluruhan visualisasi mengkonfirmasi bahwa proses training berjalan dengan efektif, menghasilkan model yang seimbang antara kemampuan pembelajaran dan generalisasi.

4.4 Performa pada Berbagai Kondisi Pasar


Analisis performa model pada berbagai kondisi pasar mengungkapkan adaptabilitas dan keterbatasan model dalam menghadapi dinamika pasar yang berbeda. Hasil analisis menunjukkan variasi performa yang signifikan berdasarkan kondisi pasar.

Tabel 3. Performa Model pada Berbagai Kondisi Pasar

Kondisi Market	RMSE	MAE	R2	MAPE
Bull Market	176.269	152.077	0.4155	3.02%
Bear Market	196.083	159.992	0.0505	3.30%
Sideways Market	124.79	98.3883	0.6833	1.99%

Model menunjukkan kemampuan moderate dalam mengikuti tren kenaikan pada kondisi bull market. R2 score 0.4155 mengindikasikan bahwa model dapat menjelaskan sekitar 41.55% variasi harga dalam kondisi uptrend, meskipun akurasi tidak sebaik pada kondisi sideways. Performa model relatif lebih lemah dalam kondisi bearish, dengan R2 yang sangat rendah (0.0505). Hal ini mengindikasikan kesulitan model dalam memprediksi penurunan harga yang tajam. MAPE yang lebih tinggi (3.2953%) juga menunjukkan tingkat error yang lebih besar dalam kondisi ini. Model mencapai performa terbaiknya dalam kondisi sideways, dengan R2 0.6833 menunjukkan kemampuan yang baik dalam menjelaskan variasi harga. MAPE yang rendah (1.9920%) mengkonfirmasi akurasi prediksi yang tinggi dalam kondisi pasar yang relatif stabil.

4.5 Analisis Prediksi Visual



Gambar 4. Perbandingan Prediksi Model dengan Harga Aktual Saham BRI

Visualisasi pada Gambar 4 memberikan perspektif komprehensif tentang kemampuan prediktif model dalam konteks temporal yang lengkap. Grafik menunjukkan perbandingan antara harga historis (garis biru) dan prediksi model (garis merah) dari Februari 2023 hingga Oktober 2024. Beberapa observasi penting:

1. Karakteristik Prediksi Jangka Panjang:
 - Model berhasil mengikuti tren umum pergerakan harga dengan baik
 - Prediksi khususnya akurat dalam periode Agustus-Oktober 2024
 - Garis prediksi menunjukkan smoothing alami yang mengurangi noise harian
2. Respon terhadap Volatilitas:
 - Pada periode volatilitas tinggi (terlihat dari fluktuasi tajam garis biru)
 - Model cenderung memberikan prediksi yang lebih conservative
 - Terdapat slight lag dalam merespon perubahan arah yang tajam

3. Performa pada Berbagai Fase Pasar:
 - *Sideways* (sekitar Mei-Juli 2024): Prediksi sangat akurat
 - *Uptrend* (Agustus-September 2024): Model mengikuti tren dengan baik
 - *Downtrend* (Oktober 2024): Sedikit lag dalam merespon penurunan
4. Konsistensi Prediksi:
 - Gap antara prediksi dan aktual relatif konsisten
 - Tidak ada periode dengan deviasi ekstrem
 - Model mempertahankan akurasi sepanjang periode prediksi

Analisis visual ini memperkuat temuan kuantitatif sebelumnya dan memberikan konteks praktis untuk penerapan model. Kemampuan model untuk mengikuti tren jangka panjang sambil mempertahankan respon yang measured terhadap volatilitas jangka pendek menunjukkan potensinya sebagai alat pendukung keputusan investasi yang reliable.

5. Conclusion

Berdasarkan hasil analisis model RNN untuk prediksi harga saham BRI, dapat disimpulkan: Model menunjukkan performa prediksi yang sangat baik dengan MAPE 1.7438% dan R^2 0.7490. Model menggunakan arsitektur optimal dengan 150 unit RNN dan menunjukkan kecenderungan prediksi yang konservatif (mean error -23.90), menjadikannya reliable untuk pengambilan keputusan investasi. Kemudian model menunjukkan adaptabilitas yang bervariasi pada berbagai kondisi pasar, dengan performa terbaik pada kondisi sideways (MAPE 1.9920%), moderat pada bull market, dan relatif lemah pada bear market. Hal ini mengindikasikan model sangat efektif untuk prediksi dalam kondisi pasar stabil. Analisis time step importance menunjukkan model memberikan bobot tertinggi pada data 7-8 hari terakhir (impact score 0.09). Pola ini mengonfirmasi kemampuan model dalam memanfaatkan momentum jangka menengah untuk prediksi yang akurat.

6. Suggestions And Further Research

Untuk pengembangan model lebih lanjut, beberapa saran yang dapat diimplementasikan:

- Peningkatan arsitektur model dengan mengintegrasikan attention mechanism dan transformer layers untuk meningkatkan kemampuan model dalam menangkap dependencies jangka panjang dan merespon perubahan pasar ekstrem.
- Pengayaan fitur input model dengan menambahkan data volume trading, indikator teknikal (RSI, MACD), dan sentiment analysis dari berita. Integrasi data makroekonomi juga diperlukan untuk meningkatkan akurasi prediksi pada berbagai kondisi pasar.
- Pengembangan framework evaluasi yang lebih komprehensif dengan implementasi backtesting pada berbagai timeframe dan kondisi pasar. Validasi model perlu diperluas dengan pengujian pada berbagai saham sektor perbankan.

References

- [1] Chen, J., Liu, Y., & Wang, H. (2021). "Advanced stock price prediction using deep learning algorithms: A comprehensive study of market dynamics." *Journal of Financial Technology*, 15(3), 234-251.
- [2] Kumar, A., Singh, R., & Patel, D. (2022). "Deep learning approaches in stock market prediction: Current trends and future directions." *Applied Artificial Intelligence Review*, 41(4), 567-589.
- [3] Li, X., & Wu, Y. (2024). "Integration of market sentiments and technical indicators in RNN-based stock prediction models." *Journal of Computational Finance*, 12(1), 78-95.
- [4] Zhang, L., & Wang, S. (2023). "Implementation of RNN variants for financial time series analysis: A comparative study." *International Journal of Machine Learning and Finance*, 8(2), 145-162.
- [5] Jiang, X., & Liu, M. (2020). "Evolution of machine learning applications in stock market prediction." *Journal of Financial Computing*, 25(4), 312-328.
- [6] Wang, H., et al. (2021). "Hybrid deep learning models for technical analysis in stock prediction." *Computational Finance Review*, 18(2), 156-173.
- [7] Zhang, L., & Chen, R. (2022). "Effectiveness of basic RNN architectures in financial forecasting." *Neural Computing and Applications*, 34(3), 234-251.
- [8] Li, K., et al. (2023). "Bidirectional RNN approaches in financial time series analysis." *IEEE Transactions on Neural Networks*, 45(6), 789-805.
- [9] Kumar, S., & Patel, D. (2023). "LSTM networks for stock market prediction: A comprehensive analysis." *Journal of Machine Learning in Finance*, 15(1), 45-62.
- [10] Rodriguez, M., & Smith, J. (2022). "Sentiment integration in RNN-based stock prediction models." *International*

Journal of Financial Technology, 28(3), 267-284.

- [11] Chen, Y., et al. (2023). "Technical and fundamental indicator fusion in deep learning models." *Applied Financial Intelligence*, 19(4), 423-440.
- [12] Yang, R., et al. (2024). "Ensemble deep learning approaches for stock market prediction." *Computational Economics Review*, 42(1), 56-73.
- [13] Park, S., & Kim, J. (2023). "Attention mechanisms in financial deep learning models." *Journal of Artificial Intelligence in Finance*, 11(2), 178-195.
- [14] Thompson, B., & Lee, C. (2023). "Limitations of deep learning models in extreme market conditions." *Risk Analysis Quarterly*, 31(4), 345-362.
- [15] Wardana, R. P. (2020). "Penerapan Model Gated Recurrent Unit Untuk Peramalan Jumlah Penumpang Kereta Api Di PT.KAI (Persero)".
- [16] A. Toha, P. Purwono, and W. "Gata, Model Prediksi Kualitas Udara dengan Support Vector Machines dengan Optimasi Hyperparameter Grid Search CV", *Buletin Ilmiah Sarjana Teknik Elektro*, vol. 4, no. 1, pp. 1221, 2022.
- [17] Yongqiong Zhu. (2020). "Stock price prediction using the RNN model". *J. Phys.: Conf. Ser.* **1650** 032103
- [18] finance.yahoo.com

Authors' Profiles



Akhiyar Waladi lahir di Bengkulu, pada tanggal 23. Ia menyelesaikan pendidikan S1 di bidang Ilmu Komputer dari Institut Pertanian Bogor, Bogor, Indonesia, pada tahun 2017, dengan fokus utama pada Internet of Things. Kemudian, ia melanjutkan studi S2 dalam bidang Ilmu Komputer di Universitas Indonesia, Depok, Indonesia, dan lulus pada tahun 2020 dengan penelitian utama di bidang *Optical Character Recognition*.

Dia saat ini bekerja sebagai Dosen di Universitas Jambi, Jambi. Sebelumnya, ia memiliki pengalaman sebagai Data Scientist di PT Global Loyalty Indonesia. Minat penelitiannya saat ini mencakup Computer Vision dan Sistem Prediksi.



Yogi Perdana lahir di Mukai Mudik, pada tanggal 9. Ia menyelesaikan pendidikan S1 di bidang Ilmu Komputer dari Universitas Negeri Jakarta, DKI Jakarta, Indonesia, pada tahun 2019, dengan fokus utama pada Software Engineering. Kemudian, ia melanjutkan studi S2 dalam bidang Ilmu Komputer di Universitas Indonesia, Depok, Indonesia, dan lulus pada tahun 2022 dengan penelitian utama di bidang Knowledge Management System.

Dia saat ini bekerja sebagai Dosen di Universitas Jambi, Jambi. Sebelumnya, ia memiliki pengalaman sebagai *Software Engineer* di Open Desa. Minat penelitiannya saat ini mencakup Kecerdasan Buatan dan Cyber Security.



Hasanatul Iftitah lahir di Jambi, 2 April 1996. Memperoleh gelar Sarjana Sains (S.Si) dalam bidang Matematika pada Tahun 2018 dari Universitas Negeri Padang dan memperoleh gelar Magister Komputer (M.Kom) Teknik Informatika pada Tahun 2020 dari Universitas Putra Indonesia YPTK Padang.

Saat ini, dia bekerja sebagai dosen di Fakultas Sains dan Teknologi di Universitas Jambi. Pengalaman sebelumnya mencakup bekerja sebagai akademisi di salah satu Universitas swasta di Jambi. Minat penelitiannya mencakup kecerdasan buatan di bidang sisten prediksi.



Nindy Raisa Hanum lahir di Pekanbaru, 5 Juli 1996. Ia menyelesaikan Pendidikan S1 dibidang Teknik Informatika dari UIN Syarif Hidayatullah Jakarta, Indonesia, pada tahun 2018. Kemudian, melanjutkan studi S2 dalam bidang Ilmu Komputer di Institut Pertanian Bogor, Indonesia dan lulus pada tahun 2023.

Saat ini, Ia bekerja sebagai dosen di Fakultas Sains dan Teknologi Universitas Jambi. Sebelumnya, Ia memiliki pengalaman sebagai Campaign Management Specialist di PT Home Credit Indonesia. Minat penelitiannya mencakup kecerdasan buatan di bidang sistem prediksi.

