

Prediksi Harga Saham Malindo Feedmill Tbk. (MAIN) Menggunakan Jaringan Saraf Tiruan Long Short-Term Memory (LSTM)

Vivin Mahat Putri^{*1}, M Syafrizal Zain², Satria Agus Darma³

^{1,2,3} Politeknik Manufaktur Negeri Bangka Belitung

Penulis Korespondensi: vivin@polman-babel.ac.id*,
msyafrizal@polman-babel.ac.id², satria@polman-babel.ac.id³

Article Information:

Received: 02 Juni, 2025, Accepted: 04 Juli, 2025, Published: 07 Juli 2025

Abstract

Stock price prediction presents a significant yet intricate challenge in financial forecasting, primarily due to volatile market dynamics and the nonlinear nature of data. This study investigates the efficacy of the Long Short-Term Memory (LSTM) model, a specialized Recurrent Neural Network (RNN), for forecasting the stock price of PT. Malindo Feedmill, Tbk., a publicly listed agribusiness firm on the Indonesia Stock Exchange. A five-year historical dataset of daily stock prices (open, high, low, close, volume) was utilized. Pre-processing involved data normalization, the application of a sliding window approach, and partitioning the data into training and testing subsets. The LSTM model was trained on sequential closing prices to effectively learn and model long-term dependencies inherent in stock price movements. The model's predictive performance was rigorously assessed using Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), and Mean Absolute Percentage Error (MAPE) metrics. Our results reveal that the LSTM model adeptly captures price trends, yielding a low MAPE of 3.47% on the test set. Comparative analysis against traditional models like linear regression confirms that LSTM provides superior accuracy and robustness, especially under volatile market conditions. This research highlights the significant potential of deep learning models in facilitating smarter investment decisions within the Indonesian agricultural sector. Subsequent work will aim to integrate sentiment analysis and macroeconomic indicators to further improve real-time predictive accuracy..

Keyword: Prediksi Harga Saham, LSTM, Deep Learning, Regresi Linier, Malindo Feedmill

1. Pendahuluan

Prediksi harga saham telah menjadi tantangan fundamental dalam bidang analisis keuangan karena sifat pergerakan harga yang kompleks, nonlinier, dan sangat fluktuatif. Fluktuasi

tersebut dipengaruhi oleh berbagai faktor internal dan eksternal seperti kinerja perusahaan, indikator ekonomi, peristiwa politik, serta sentimen pasar. Oleh karena itu, prediksi harga saham yang akurat menjadi sangat penting bagi investor, analis, dan lembaga keuangan dalam mengambil keputusan yang tepat dan meminimalkan risiko.

Dalam konteks industri agribisnis di Indonesia, PT. Malindo Feedmill, Tbk. merupakan salah satu perusahaan publik yang bergerak di bidang produksi pakan ternak. Pergerakan harga saham perusahaan ini menjadi perhatian penting karena dipengaruhi oleh fluktuasi harga komoditas, kebijakan pemerintah, serta dinamika rantai pasok sektor pertanian. Dengan demikian, kemampuan untuk memprediksi harga saham PT. Malindo Feedmill secara akurat menjadi nilai tambah dalam penyusunan strategi investasi di sektor agrikultur.


Metode prediksi tradisional seperti regresi linier dan ARIMA telah banyak digunakan namun memiliki keterbatasan dalam menangkap pola nonlinier dan ketergantungan jangka panjang dalam data deret waktu [1][2]. Seiring berkembangnya teknologi pembelajaran mesin dan kecerdasan buatan, pendekatan baru berbasis deep learning mulai menunjukkan keunggulannya. Salah satu algoritma yang efektif untuk prediksi deret waktu adalah Long Short-Term Memory (LSTM), yang merupakan bagian dari jaringan saraf tiruan Recurrent Neural Network (RNN)[3][4]. LSTM dirancang untuk mengatasi masalah *vanishing gradient* dan mampu mempertahankan informasi historis penting dalam jangka waktu panjang.

Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model LSTM untuk memprediksi harga saham penutupan harian PT Malindo Feedmill Tbk. (MAIN), salah satu perusahaan di sektor pakan ternak. Fokus penelitian adalah pada pra-pemrosesan data yang efektif, arsitektur model LSTM yang sesuai, dan evaluasi kinerja model menggunakan metrik standar.

2. Tinjauan Literatur

Long Short-Term Memory (LSTM) merupakan turunan dari metode Recurrent Neural Network (RNN)[5]. RNN sendiri merupakan salah satu dari Artificial Neural Network (ANN) yang dikembangkan berdasarkan Feedforward Neural Network[6][7]. Pada Recurrent Neural Network dilakukan proses secara berulang ulang untuk memproses input data berupa data sekuensial [8]. Meskipun RNN lebih baik dari tradisional ANN akan tetapi RNN memiliki kelemahan dimana RNN tidak efektif pada data jangka panjang karena permasalahan *vanishing gradient*. LSTM menggunakan sel memori untuk mengatasi masalah *vanishing gradient* yang terdiri dari input layer, hidden layer, cell state, dan output layer.[9].

Pada LSTM terdapat mekanisme gerbang yang bertujuan untuk menghapus dan memodifikasi informasi dari cell state. Sel memori (C) memperbarui informasi menggunakan tiga gerbang: input gate (i), forget gate (f), dan change gate (C). Ilustrasi untuk setiap gerbang dapat dilihat pada gambar 3. Sedangkan formula untuk input gate (i), forget gate (f) (C i) dapat dilihat pada persamaan (1), (2), (3). [9]



Gambar 1. Arsitektur LSTM

$$i_t = \sigma(W_i x_t W_{hi} h_{t-1} + b_i) \quad (1)$$

$$f_t = \sigma(W_f x_t W_{hf} h_{t-1} + b_f) \quad (2)$$

$$\tilde{c}_t = \tanh(W_c x_t + W_{hc} h_{t-1} + b_c) \quad (3)$$

Hidden state (h_t) diperbarui menggunakan output gate (o_t) dan sel memori (C_t) pada persamaan (4),(5),(6).

$$C_t = f_t * C_{t-1} + i_t * \tilde{c}_t \quad (4)$$


$$o_t = \sigma(W_o x_t W_{ho} h_{t-1} + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

Dimana σ adalah fungsi sigmoid dan $\tanh$ adalah fungsi tanh. Operator $*$ menandakan *element-wise product*. W merupakan bobot dan b adalah bias.

Arsitektur dari LSTM yang digunakan pada penelitian ini menggunakan multiple layer LSTM dengan jumlah neuron berdasarkan penelitian [10]. Sedangkan berkaitan dengan jumlah layer LSTM yang digunakan, penelitian ini melakukan uji coba dengan empat dan delapan layer yang masing-masing layer memiliki 96 neurons. Struktur model LSTM dengan delapan layer dapat dilihat pada gambar 4. Tabel 1 merupakan rincian struktur model LSTM dengan delapan layer. Pada 81able tersebut jumlah time step yang digunakan adalah pada masing-masing layer adalah 25 dengan jumlah neurons sebanyak 96. Dense layer merupakan layer yang berfungsi mengubah output dari layer sebelumnya menjadi nilai hasil prediksi [11][12]. Pada proses pelatihan dan pengujian dibutuhkan beberapa parameter yang harus dilakukan uji coba untuk mendapatkan model terbaik. Parameter ini berupa jumlah time step, epoch, serta jumlah layer yang akan digunakan untuk mencari model terbaik pada setiap emiten. Hal ini dilakukan karena setiap emiten memiliki pola data yang berbeda-beda, sehingga memungkinkan bahwa setiap emiten akan memiliki model terbaik yang berbeda beda. Penelitian ini menggunakan beberapa time step saat melakukan pelatihan dan pengujian yaitu 25, 50, 75, 100. Sedangkan untuk epoch

digunakan beberapa epoch yaitu 12, 25, 50, 100.



Gambar 2. Struktur model LSTM dengan delapan *layer*

3. Metode Penelitian

Penelitian ini menggunakan data historis harga saham harian PT. Malindo Feedmill, Tbk yang diperoleh dari IDX selama Empat tahun (2021–2025). Metodologi yang diterapkan mengikuti tahapan-tahapan sebagai berikut:

3.1. Pengumpulan dan Pra-pemrosesan Data

Data yang diperoleh mencakup atribut harga pembukaan (Open), tertinggi (High), terendah (Low), penutupan (Close), date, dan volume. Data dibersihkan dari nilai null dan outlier, kemudian dilakukan normalisasi menggunakan metode Min-Max untuk meratakan rentang nilai ke skala 0-1 sesuai rumus: Data kemudian disegmentasi menjadi data latih (80%) dan data uji (20%), serta dibentuk dalam jendela waktu (time step) sebanyak 25, 50, 75, dan 100 untuk evaluasi performa model terbaik.

3.2. Pembentukan Urutan (Sequence Creation)


Untuk melatih model LSTM, data diubah menjadi bentuk urutan waktu (sequences). Setiap sampel input (X) terdiri dari 60 hari data historis ($n_{past} = 60$), dan output target (y) adalah harga penutupan (Close) untuk 1 hari ke depan ($n_{future} = 1$).

3.3. Pembagian Data Pelatihan dan Pengujian

Dataset dibagi menjadi data pelatihan dan data pengujian dengan rasio 80% untuk pelatihan dan 20% untuk pengujian. Pembagian dilakukan secara sekuensial untuk menjaga urutan waktu data.

Berikut merupakan tahapan pelatihan yang dilakukan pada penelitian ini:

- Input data latih yang telah didapat.
- Inisialisasi parameter dengan menentukan banyak layer pada model LSTM, jumlah epoch serta time step yang akan digunakan pada pembuatan model LSTM.
- Pembentukan time step Gambar 3 adalah ilustrasi dari pola time series.



Gambar 3. Ilustrasi Time step

Gambar ini menunjukkan mekanisme pembentukan **time step** dalam pemodelan data deret waktu (time series) untuk pelatihan model LSTM.

Input:

Bagian input terdiri dari sejumlah data historis berturut-turut yang digunakan sebagai fitur untuk memprediksi nilai berikutnya. Misalnya, pada gambar pertama, input terdiri dari data x_1, x_2, x_3, x_4, x_5 , x_1, x_2, x_3, x_4, x_5 .

Target:

Target adalah nilai yang ingin diprediksi oleh model berdasarkan input yang diberikan. Pada gambar pertama, target adalah data x_6 , yaitu nilai yang berada tepat setelah data input terakhir.

Sliding Window:

Pada gambar kedua, mekanisme **time step** bergeser satu posisi ke depan. Input berubah menjadi x_2, x_3, x_4, x_5, x_6 , x_2, x_3, x_4, x_5, x_6 dan target bergeser menjadi x_7 .

Mekanisme ini menggambarkan cara model belajar memprediksi nilai berikutnya berdasarkan sejumlah data historis yang berurutan, dengan menggeser jendela input satu langkah ke depan secara iteratif sampai seluruh data selesai diproses.

Dalam konteks pelatihan LSTM:

Published by:

1. Model diberikan data input berupa urutan n nilai (time step), misalnya 5 data berurutan,
2. Model kemudian mencoba memprediksi nilai pada waktu ke- $n+1$, $n+1$, $n+1$,
3. Setelah itu, window input bergeser satu posisi ke depan dan proses diulang,
4. Ini membantu model menangkap pola temporal dan dependensi antar waktu dalam data deret waktu.

Model LSTM dibangun menggunakan API Sequential dari TensorFlow/Keras dengan arsitektur sebagai berikut:

Lapisan LSTM Pertama: 100 unit LSTM, dengan `return_sequences=True` untuk meneruskan output urutan lengkap ke lapisan LSTM berikutnya. `input_shape` disesuaikan dengan dimensi lookback dan jumlah fitur. Lapisan Dropout Pertama: 0.3 (30%) untuk mengurangi overfitting. Lapisan LSTM Kedua: 100 unit LSTM, tanpa `return_sequences` karena ini adalah lapisan LSTM terakhir sebelum lapisan Dense. Lapisan Dropout Kedua: 0.3 (30%) untuk mengurangi overfitting. Lapisan Dense (Output): 1 unit, untuk memprediksi nilai tunggal (harga penutupan).

3.4. Model LSTM yang digunakan terdiri atas:

- a. Multiple LSTM layers (4 dan 8 layer), masing-masing dengan 96 neuron.
- b. Dropout layer setelah setiap LSTM untuk mencegah overfitting.
- c. Dense layer sebagai layer output yang menghasilkan nilai prediksi harga.

Ilustrasi arsitektur model: $\text{Input} \rightarrow [\text{LSTM} + \text{Dropout}] \times n \rightarrow \text{Dense} \rightarrow \text{Output}$

3.5. Rancangan Percobaan

Pelatihan Model

Model dilatih menggunakan parameter sebagai berikut:

- a. Epoch: 150
- b. Time step: 60
- c. Batch size tetap: 32

Fungsi aktivasi yang digunakan adalah sigmoid dan tanh sesuai struktur LSTM:

- a. Forget gate
- b. Input gate
- c. Cell state update
- d. Output gate

3.6. Denormalisasi dan Evaluasi Model

Denormalisasi merupakan proses yang dilakukan untuk mengubah data hasil prediksi yang masih berbentuk range interval 0-1 menjadi nilai hasil prediksi harga saham sesuai nilai aktual dari harga saham. Denormalisasi dilakukan agar hasil prediksi mudah dibaca dan dimengerti serta hasil prediksi dapat dibandingkan dengan harga aktual untuk mengetahui kesalahan prediksi. Perhitungan denormalisasi (d) dengan cara mengkalikan hasil prediksi (y) dengan selisih harga maksimal (max) dengan harga minimal (min) yang kemudian ditambahkan harga minimal (min) seperti pada persamaan (7) [14].

Setelah prediksi diperoleh, hasil dikembalikan ke skala aslinya dengan rumus:

$$d = y (\max - \min) + \min \quad (7)$$

Evaluasi model bertujuan untuk mengetahui ketepatan dari model yang telah dibuat. Pada penelitian ini evaluasi model menggunakan Mean Absolute Percentage Error (MAPE) [15][16]. MAPE dapat dihitung dengan cara mencari rata-rata dari selisih absolute harga aktual dengan harga hasil prediksi dibagi dengan harga aktual. Formula MAPE dapat dilihat pada persamaan (8) [17].

$$MAPE = \frac{1}{n} \sum \left| \frac{\text{actual} - \text{pred}}{\text{actual}} \right| \quad (8)$$

Nilai MAPE yang dihasilkan perlu dikelompokkan menjadi beberapa kategori berdasarkan rentang nilai untuk menentukan kualitas dari model yang digunakan dalam memprediksi harga saham syariah. Sehingga dapat dengan mudah dalam mengambil kesimpulan apakah prediksi tersebut masuk kedalam kategori akurat maupun tidak. Pengelompokan nilai MAPE dapat dilihat dalam tabel 1 [18].

Evaluasi performa model dilakukan dengan:

Mean Absolute Error (MAE) : Rata-rata dari nilai absolut kesalahan antara prediksi dan nilai aktual.

Root Mean Squared Error (RMSE) : Akar kuadrat dari rata-rata kuadrat kesalahan, memberikan bobot lebih pada kesalahan yang besar.

Mean Absolute Percentage Error (MAPE) : Ukuran akurasi dalam bentuk persentase, berguna untuk perbandingan antar model dengan skala berbeda.

Tabel 1. Kategori performa berdasarkan MAPE:

MAPE	KATEGORI
< 10%	akurat
10–20%	baik
20–50%	layak
21 > 50%	tidak akurat

Model terbaik dipilih berdasarkan kombinasi parameter yang menghasilkan nilai MAPE terendah pada data uji. Visualisasi grafik prediksi juga digunakan untuk mengobservasi kecocokan pola harga aktual dan hasil prediksi.

Penelitian ini bertujuan untuk menerapkan model LSTM dalam memprediksi harga penutupan saham harian PT. Malindo Feedmill, Tbk. menggunakan data historis selama lima tahun terakhir. Proses penelitian mencakup pengolahan data, normalisasi, pembentukan model sekuensial, serta evaluasi performa model dengan metrik kesalahan yang relevan. Hasil dari penelitian ini diharapkan mampu menunjukkan potensi LSTM dalam membantu investor dalam mengambil keputusan berbasis data yang lebih akurat di pasar saham Indonesia, khususnya pada sektor agribisnis. Dengan menggabungkan teknik deep learning dan data keuangan riil, penelitian ini memberikan kontribusi pada pengembangan teknologi kecerdasan

buatan di bidang keuangan serta menawarkan wawasan praktis dalam implementasi prediksi saham berbasis AI di lingkungan pasar yang tidak stabil.

4. Hasil dan Pembahasan

4.1. Exploratory Data Analysis (EDA)

Data saham PT. Malindo Feedmill, Tbk. diekstraksi dan ditampilkan untuk pemahaman awal terhadap pola distribusi, tren, dan potensi outlier. Atribut utama yang dianalisis meliputi harga penutupan (Close), volume transaksi, serta variasi harga harian. Data divisualisasikan menggunakan grafik garis untuk menggambarkan fluktuasi harga saham selama periode 2021–2025.


4.2. Hasil Evaluasi Numerik

Tabel 2. menunjukkan metrik evaluasi model pada data pengujian:

Metrik Evaluasi	Nilai
Mean Absolute Error (MAE)	13.27
Root Mean Squared Error (RMSE)	17.42
Mean Absolute Percentage Error (MAPE)	1.64%
R-squared Coefficient	0.6854

Nilai MAPE sebesar 1.64% mengindikasikan bahwa rata-rata kesalahan prediksi model adalah sekitar 1.64% dari harga aktual, yang merupakan tingkat akurasi yang relatif baik untuk peramalan harga saham. Nilai R-squared 0.6854 menunjukkan bahwa sekitar 68.54% dari variasi harga saham dapat dijelaskan oleh model. MAE dan RMSE yang relatif rendah mengindikasikan bahwa kesalahan prediksi model cenderung kecil.

a. Analisis Plot Loss Pelatihan



Gambar 1: Kurva Loss Pelatihan dan Validasi Model LSTM]

Pada Gambar 1 menunjukkan kurva loss selama proses pelatihan. Terlihat bahwa training loss dan validation loss keduanya menurun seiring dengan peningkatan epochs, menunjukkan bahwa model belajar dengan efektif. Konvergensi kedua kurva tanpa divergensi signifikan pada validation loss menandakan model tidak mengalami overfitting yang parah, berkat penggunaan lapisan dropout dan early stopping. memperlihatkan kurva loss untuk proses pelatihan dan validasi model LSTM selama sejumlah epoch. Pada grafik ini, sumbu horizontal

merepresentasikan jumlah epoch, sedangkan sumbu vertikal menunjukkan nilai loss menggunakan metrik Mean Squared Error (MSE).

Terlihat bahwa nilai training loss dan validation loss secara konsisten menurun seiring bertambahnya epoch, yang menunjukkan bahwa model secara bertahap mempelajari pola dalam data pelatihan dan mampu menggeneralisasi dengan baik ke data validasi. Penurunan loss yang stabil ini menandakan bahwa proses pelatihan berjalan efektif dan model mengalami konvergensi menuju solusi optimal.


Selain itu, tidak terdapat gap yang signifikan antara kurva training loss dan validation loss, yang berarti model belum mengalami overfitting secara parah. Overfitting biasanya terjadi jika training loss terus menurun namun validation loss mulai meningkat, menunjukkan bahwa model hanya menghafal data latih tanpa mampu menggeneralisasi pola baru. Dalam grafik ini, kedua kurva justru cenderung bergerak paralel dan berdekatan, mengindikasikan model memiliki kemampuan generalisasi yang baik.

Hal ini juga menunjukkan bahwa penggunaan teknik regulasi seperti dropout yang diterapkan di lapisan LSTM efektif dalam mencegah overfitting. Dropout secara acak menonaktifkan sejumlah neuron selama pelatihan, sehingga model tidak bergantung pada fitur tertentu secara berlebihan dan lebih tahan terhadap variabilitas data.

Selain itu, penggunaan mekanisme early stopping yang menghentikan pelatihan saat validation loss tidak membaik juga berkontribusi pada kestabilan performa model. Dengan demikian, pelatihan model tidak berjalan berlebihan dan menghindari risiko overfitting.

Secara keseluruhan, grafik loss ini menggambarkan proses pembelajaran model LSTM yang optimal, dimana model mampu belajar pola dari data historis harga saham tanpa kehilangan kemampuan generalisasi pada data baru. Kondisi ini sangat penting agar prediksi harga saham yang dihasilkan dapat diandalkan dan relevan untuk pengambilan keputusan di dunia nyata

b. Analisis Plot Prediksi Aktual vs. Prediksi



Gambar 2: Perbandingan Harga Aktual dan Prediksi pada Data Pengujian]

Pada Gambar 2 memvisualisasikan perbandingan antara harga saham aktual dan harga prediksi model LSTM pada data pengujian (test set). Garis biru mewakili harga aktual, sedangkan garis putus-putus merah menunjukkan harga yang diprediksi oleh model. Secara umum, model

LSTM mampu menangkap tren dan pola pergerakan harga dengan cukup baik. Pergerakan garis prediksi mengikuti arah naik turun harga aktual pada sebagian besar waktu, menandakan model efektif dalam memahami dinamika pasar saham dari data historis. Ini menunjukkan kemampuan model dalam menggeneralisasi pola temporal yang kompleks, termasuk fluktuasi jangka pendek maupun jangka menengah.

Namun, terdapat beberapa periode di mana prediksi menyimpang cukup signifikan dari harga aktual, terutama pada saat terjadi lonjakan harga mendadak atau volatilitas yang tinggi. Hal ini adalah fenomena umum dalam prediksi deret waktu finansial, yang sifatnya non-linear dan sangat dipengaruhi oleh faktor eksternal seperti berita pasar, kebijakan ekonomi, dan sentimen investor yang sulit dimodelkan hanya dari data harga historis. Selain itu, prediksi model cenderung lebih halus dibandingkan harga aktual yang kadang mengalami perubahan ekstrem dalam waktu singkat. Ini menunjukkan bahwa meskipun model dapat menangkap tren utama, beberapa noise dan fluktuasi kecil sulit untuk diprediksi secara presisi.

Analisis ini mengindikasikan bahwa model LSTM memberikan hasil prediksi yang cukup relevan dan dapat diandalkan sebagai alat bantu dalam pengambilan keputusan investasi, terutama untuk tren harga secara keseluruhan. Namun, untuk pengambilan keputusan pada waktu dengan volatilitas tinggi, model mungkin perlu dipadukan dengan data tambahan atau metode lain yang mampu menangani ketidakpastian tersebut.

Secara keseluruhan, grafik ini memperkuat keunggulan metode LSTM dalam mengolah data time series finansial dan memberikan dasar empiris yang kuat untuk implementasi prediksi harga saham berbasis kecerdasan buatan.

c. Diskusi Penambahan Fitur

Pada fase awal pengembangan model, penambahan berbagai indikator teknis (seperti SMA, EMA, RSI, MACD, dan Bollinger Bands) sebagai fitur tambahan sempat dipertimbangkan. Namun, setelah dilakukan eksperimen dan evaluasi, tidak ditemukan peningkatan signifikan pada kinerja model. Bahkan, metrik evaluasi menunjukkan sedikit penurunan performa dibandingkan model yang hanya menggunakan fitur harga dan volume dasar. Hal ini dapat diinterpretasikan bahwa untuk dataset spesifik ini dan arsitektur model yang digunakan, fitur dasar sudah cukup komprehensif, atau indikator teknis tersebut memperkenalkan kompleksitas/kebisingan yang tidak dapat dimanfaatkan secara optimal oleh model tanpa penyesuaian hyperparameter yang lebih dalam. Oleh karena itu, model akhir dipertahankan dengan set fitur yang lebih sederhana.

5. Kesimpulan

Penelitian ini berhasil mengembangkan dan mengimplementasikan model Long Short-Term Memory (LSTM) untuk memprediksi harga penutupan saham harian PT Malindo Feedmill, Tbk., dengan menggunakan data historis selama lima tahun. Model yang dibangun mampu menangkap pola dan tren harga saham dengan tingkat akurasi yang tinggi, dibuktikan dengan nilai Mean Absolute Percentage Error (MAPE) sebesar 1,64% pada data pengujian. Hasil ini menunjukkan bahwa pendekatan deep learning berbasis LSTM sangat efektif dalam mengatasi kompleksitas dan nonlinieritas data harga saham, terutama dalam mempertahankan informasi historis jangka panjang yang krusial untuk prediksi deret waktu.

Kontribusi utama dari penelitian ini adalah demonstrasi kemampuan model LSTM dalam meningkatkan akurasi prediksi harga saham di sektor agribisnis Indonesia, khususnya pada PT Malindo Feedmill, Tbk. Temuan ini menambah literatur di bidang pemodelan deret waktu finansial dengan pendekatan kecerdasan buatan, serta memberikan fondasi empiris untuk aplikasi teknologi deep learning dalam pengambilan keputusan investasi yang lebih cerdas dan berbasis data. Dengan demikian, penelitian ini memberikan kontribusi nyata dalam pengembangan metode analisis keuangan modern, yang berpotensi meningkatkan efektivitas strategi investasi dan manajemen risiko di pasar saham yang dinamis dan volatil. Penelitian selanjutnya akan dilakukan pengembangan model hibrida yang menggabungkan LSTM dengan arsitektur deep learning lain seperti Convolutional Neural Networks (CNN) untuk meningkatkan akurasi dan kemampuan generalisasi.

Referensi

- [1] Mohammadrezaei M, Shiri ME, Rahmani AM. Identifying fake accounts on social networks based on graph analysis and classification algorithms". *Hindawi Secur Commun Netw* 2018
- [2] Wanda, Putra and Huang Jin Jie." DeepProfile: Finding fake profile in online social network using dynamic CNN". *Journal of Information Security and Applications*.2020.
- [3] Li M, Xiang Y, Zhang B, Wei F, Song Q. "A novel organizing scheme of single topic user group based on trust chain model in social network. *Int J Commun Syst* 2018;31:3387.
- [4] Anglano C, Canonico M, Guazzone M. "Analysis of Telegram Messenger on Android smartphones." *Digital investigation*, Elsevier, 23; 2017. p. 31–49.
- [5] C. T, E. Dwoskin, Twitter Is Sweeping Out Fake Accounts like Never before, Putting User Growth at Risk, 2018. <https://www.washingtonpost.com/technology/2018/07/06/twitter-is-sweeping-out-fake-accounts-like-never-before-putting-user-growth-risk/>
- [6] A. Wani, S. Jabin, A. Nehaluddin, A Sneak into the Devil's Colony-fake Profiles in Online Social Networks, *arXiv.org ePrint Archive* vol. 5, 2018, pp. 26-39.
- [7] E.V.D. Walt, J. Eloff, Using machine learning to detect fake identities: bots vs humans, *IEEE Access* 6 (2018) 6540e6549, <https://doi.org/10.1109/ACCESS.2018.2796018>.
- [8] E. Ahmadizadeh, E. Aghasian, H.P. Taheri, R.F. Nejad, An automated model to detect fake profiles and botnets in online social networks using steganography technique, *IOSR J. Comput. Eng.* 17 (2015) 65e71, <https://doi.org/10.9790/0661-17146571>.
- [9] R.S. Perdana, T.H. Muliawati, R. Alexandro, Bot spammer detection in Twitter using tweet similarity and time interval entropy, *Jurnal Ilmu Komputer dan Informasi* 8 (2015) 19e25, <https://doi.org/10.21609/jiki.v8i1.280>.
- [10] S.M. Asadullah, S. Viraktamath, Classification of twitter spam based on profile and message model using Svm, *Int. J. Eng. Res. Technol.* 4 (2017) 2862e2865.

- [11] Ç.B. Aslan, R.B. Saglam, S. Li, Automatic Detection Of Cyber Security Related Accounts On Online Social Networks: Twitter As An Example, in: Proceedings of the 9th International Conference on Social Media and Society, 2018, pp. 236e240, <https://doi.org/10.1145/3217804.3217919>.
- [12] G. Qingyuan, Y. Chen, X. He, Z. Zhuang, T. Wang, H. Huang, X. Wang, X. Fu, DeepScan: Exploiting deep learning for malicious account detection in location-based social networks, *IEEE Commun. Mag.* 56 (2018) 21e27, <https://doi.org/10.1109/MCOM.2018.1700575>.
- [14] Q. Fu, B. Feng, D. Guo, Q. Li, Combating the evolving spammers in online social networks, *Comput. Secur.* 72 (2018) 60e73, <https://doi.org/10.1016/j.cose.2017.08.014>.
- [15] S. Rathore, A.K. Sangaiah, J.H. Park, A novel framework for internet of knowledge protection in social networking services, *J. Comput. Sci.* 26 (2018) 55e65, <https://doi.org/10.1016/j.jocs.2017.12.010>.
- [16] Jie, Huang. "A Survey of Network and Information Security. *International Journal of Informatics and Computation*". [S.l.], v. 1, n. 2, p. 15-22, dec. 2019.
- [17] Dr. Dongseong Kim, Xiran Zhang. Network Intrusion Detection Using Generative Adversarial Networks.
- [18] Purser et al." Using Generative Adversarial Networks For Intrusion Detection In Cyber-Physical Systems".2020.

Copyrights

Copyright for this article is retained by the author(s), with first publication rights granted to the journal.

This is an open-access article distributed under the terms and conditions of the Creative Commons Attribution license (<http://creativecommons.org/licenses/by/4.0/>)

