

PREDIKSI HARGA SAHAM TRANSPORTASI LAUT DI INDONESIA MENGGUNAKAN METODE LONG SHORT-TERM MEMORY (LSTM)

Trie Yuniarsih¹, Hozairi², Aminollah Hamzah³

¹Teknik Informatika, Teknik, Universitas Islam Madura

²Teknik Informatika, Teknik, Universitas Islam Madura

triyuniarsih123@gmail.com, dr.hozairi@gmail.com, hamzahmni@gmail.com

ABSTRAK

Sektor transportasi laut berperan penting dalam mendukung perekonomian Indonesia sebagai negara kepulauan. Penelitian ini merancang model prediksi harga saham sektor tersebut di Bursa Efek Indonesia (BEI) dengan metode Long Short-Term Memory (LSTM) untuk mengatasi keterbatasan metode konvensional dalam menghadapi fluktuasi pasar. Fokus penelitian mencakup saham PT Samudera Indonesia Tbk (SMDR), PT Pelayaran Nelly Dwi Putri Tbk (NELY), dan PT Pelayaran Tempuran Emas Tbk (TMAS) periode 2020–2025, menggunakan variabel input berupa data historis harga saham serta indikator makroekonomi. Metodologi meliputi preprocessing data dengan normalisasi Min-Max dan pembagian dataset 80:20, pembentukan sliding window 30 timestep, penerapan arsitektur LSTM berisi 64 unit dengan dropout 0,2, serta evaluasi performa model menggunakan metrik MAPE dan RMSE. Hasil menunjukkan kinerja terbaik pada saham SMDR dengan MAE 8,96, MSE 161,53, RMSE 12,70, dan R^2 0,91. Sementara itu, TMAS memperoleh MAE 2,93, MSE 14,18, RMSE 3,76, dan R^2 0,85, sedangkan NELY mencatat MAE 6,61, MSE 89,88, RMSE 9,48, dan R^2 0,77. Prediksi 10 hari ke depan menunjukkan tren stabil pada SMDR, fluktuatif pada NELY, dan menurun pada TMAS. Secara akademis, penelitian ini memperkaya literatur penerapan deep learning di sektor transportasi laut Indonesia, sedangkan secara praktis, menyediakan alat bantu prediksi bagi investor dengan akurasi lebih tinggi daripada model tradisional. Implikasi riset menekankan potensi LSTM sebagai solusi prediksi, meski diperlukan perbaikan dalam penanganan outlier dan stabilitas model. Untuk penelitian berikutnya disarankan pengembangan model hybrid dan integrasi variabel eksternal guna meningkatkan akurasi prediksi model hybrid serta integrasi variabel eksternal guna meningkatkan performa prediksi.

Kata kunci: prediksi harga saham, LSTM, transportasi laut, volatilitas pasar, deep learning.

ABSTRACT

The maritime transportation sector plays a crucial role in supporting Indonesia's economy as an archipelagic nation. This study proposes a stock price prediction model for maritime transportation companies listed on the Indonesia Stock Exchange (IDX) using the Long Short-Term Memory (LSTM) method to overcome the limitations of conventional approaches in capturing market volatility. The research focuses on the shares of PT Samudera Indonesia Tbk (SMDR), PT Pelayaran Nelly Dwi Putri Tbk (NELY), and PT Pelayaran Tempuran Emas Tbk (TMAS) from 2020 to 2025, utilizing historical stock prices and macroeconomic indicators as input variables. The methodology involves data preprocessing with Min-Max normalization and an 80:20 train-test split, constructing a 30-timestep sliding window, implementing an LSTM architecture with 64 units and a 0.2 dropout rate, and evaluating the model using MAPE and RMSE metrics. Results show that SMDR achieved the best performance with an R^2 of 0.91 and an MAE of 8.96, followed by TMAS (R^2 0.85) and NELY (R^2 0.77). A 10-day forecast suggests a stable pattern for SMDR, volatile movements for NELY, and a downward trend for TMAS. Academically,

this research contributes to filling the gap in literature on deep-learning applications within Indonesia's maritime transportation sector, while practically it provides investors with a forecasting tool that surpasses traditional models in accuracy. The findings highlight LSTM's potential as a predictive solution, though further improvements are needed to better handle outliers and maintain model stability. Future work is recommended to develop hybrid models and integrate external factors to enhance predictive accuracy.

Keywords: stock price prediction, LSTM, maritime transport, market volatility, deep learning.

1. PENDAHULUAN

Transportasi laut merupakan sektor penting bagi perekonomian Indonesia sebagai negara kepulauan yang sangat bergantung pada distribusi barang dan jasa melalui jalur laut. Harga saham perusahaan pelayaran di Bursa Efek Indonesia (BEI), seperti PT Samudera Indonesia Tbk (SMDR), PT Pelayaran Nelly Dwi Putri Tbk (NELY), dan PT Pelayaran Tempuran Emas Tbk (TMAS), cenderung berfluktuasi akibat faktor makroekonomi, kebijakan pemerintah, dan permintaan logistik. Kondisi ini membuat prediksi harga saham menjadi krusial bagi investor, namun metode analisis konvensional sering kurang akurat karena volatilitas yang tinggi.

Penelitian ini fokus pada pemanfaatan metode Long Short-Term Memory (LSTM), salah satu teknik deep learning yang unggul dalam memodelkan data deret waktu, untuk memprediksi harga saham transportasi laut di BEI periode 2020–2025. Variabel yang dianalisis meliputi harga historis (open, close, high, low), volume perdagangan, nilai tukar USD, dan inflasi, serta dibandingkan dengan model ARIMA sebagai pembanding.


Tujuan penelitian adalah menilai akurasi model LSTM melalui metrik MAPE dan RMSE, sekaligus mengidentifikasi faktor paling berpengaruh terhadap prediksi. Penelitian ini diharapkan memberi kontribusi akademis dengan memperkaya literatur penerapan deep learning pada sektor saham yang masih jarang dikaji, serta manfaat praktis sebagai alat bantu keputusan investasi.

Penelitian sebelumnya menunjukkan LSTM mampu memberikan akurasi tinggi (MAPE 2,5%), namun penerapannya pada saham

transportasi laut di Indonesia masih terbatas. Dengan metodologi berupa pengumpulan data dari Yahoo Finance dan Bank Indonesia, pra-proses data, pembangunan arsitektur LSTM, penyetelan hyperparameter, dan evaluasi melalui backtesting, penelitian ini diharapkan mengisi kesenjangan riset sekaligus membantu investor, analis, dan pembuat kebijakan menghadapi gejolak pasar seperti kenaikan BBM atau perubahan regulasi.

2. METODOLOGI PENELITIAN

Penelitian ini mencakup pengumpulan data, pra-proses, dan pemodelan LSTM dengan optimasi hyperparameter untuk memprediksi harga saham transportasi laut secara akurat.



Gambar 1. Alur Penelitian

2.1 Pengumpulan Data

Dataset yang digunakan terdiri dari data historis harga saham perusahaan transportasi laut yang terdaftar di BEI yaitu SMDR, NELY, dan TMAS untuk periode 2020–2025 dalam format CSV yang diunduh dari situs investing.com. Tahapan pengumpulan data tersebut dijelaskan sebagai berikut:

2.2 Praprocessing Data

Pre-processing data adalah langkah penting dalam machine learning untuk mengubah data mentah menjadi format yang lebih terstruktur sehingga dapat diolah oleh model. Proses ini mencakup pembersihan, transformasi, normalisasi, dan pemisahan dataset guna meningkatkan ketepatan prediksi, khususnya pada model LSTM yang menangani data time series. Implementasinya menggunakan Python dengan library seperti Pandas untuk manipulasi data, NumPy untuk komputasi, serta scikit-learn (contohnya MinMaxScaler) untuk normalisasi, dan biasanya dijalankan di platform seperti Google Colab atau Jupyter Notebook (Katy, 2025).

2.3 Pembersihan Data

Setelah data dibersihkan, tahap selanjutnya adalah eksplorasi data (EDA) untuk memahami karakteristik dataset. Proses ini mencakup pengecekan rentang waktu dengan fungsi seperti `min()`, `max()`, dan `date_range()` guna memastikan tidak ada periode yang hilang. Frekuensi pencatatan (harian, mingguan, atau bulanan) dianalisis dengan `resample()` atau `value_counts()`, sedangkan visualisasi awal fluktuasi harga dilakukan menggunakan Matplotlib atau Seaborn. Tahap ini membantu mengungkap pola dasar dan potensi masalah sebelum pemodelan dilakukan. (Velarde et al., 2025).

2.4 Visualisasi Harga Saham

Visualisasi harga saham adalah bagian penting dari EDA untuk mengidentifikasi pola, tren, dan anomali dalam data time series. Dengan Matplotlib dan Seaborn, pergerakan harga diplot terhadap waktu untuk melihat tren jangka panjang, pola musiman, atau lonjakan harga akibat peristiwa pasar. Proses ini biasanya dilakukan di Google Colab atau Jupyter Notebook, membantu peneliti memahami dinamika historis saham sebelum pemodelan prediktif. (Lavanya Addepalli et al., 2023).


2.5 Persiapan Model

Tahap awal pengembangan model LSTM dilakukan dengan memisahkan dataset secara

kronologis menjadi data latih (80%) dan data uji (20%) menggunakan library Pandas (Kumaravel, 2025). Setelah itu, data dinormalisasi ke rentang $[0,1]$ memakai MinMaxScaler dari scikit-learn guna meningkatkan performa model dan mencegah kebocoran data. Selanjutnya, diterapkan sliding window sepanjang 30 timestep dengan TimeseriesGenerator dari Keras atau metode manual, sehingga terbentuk array tiga dimensi $[\text{samples}, \text{timesteps}, \text{features}]$ yang sesuai dengan format masukan standar LSTM (Encord, 2023).

2.6 Model Pendekatan Long Short-Term Memory (LSTM)

LSTM adalah jenis Recurrent Neural Network (RNN) yang memiliki keunggulan dalam menangkap pola jangka panjang melalui cell state dan gates (forget, input, output) yang mengatur aliran informasi (Ghojogh & Ghodsi, 2023; Peng et al., 2021).



Gambar 2. Metode LSTM

Perbedaan utama dengan RNN biasa terletak pada strukturnya yang lebih kompleks, memungkinkan penghapusan atau penambahan informasi secara selektif.

Perbedaan utama dengan RNN biasa terletak pada strukturnya yang lebih kompleks, memungkinkan penghapusan atau penambahan informasi secara selektif.

Pembangunan model dimulai dengan arsitektur LSTM layer (64 unit), diikuti Dense layer (32 neuron, ReLU), dan Dropout layer (rate 0.2) untuk mengurangi overfitting, lalu output layer tunggal untuk prediksi nilai kontinu (Seyed Mousavi, 2024). Model dikembangkan menggunakan Keras/TensorFlow dengan

optimizer Adam dan loss MSE, serta dievaluasi memakai MAPE.

Optimasi dilakukan dengan GridSearchCV dan KerasRegressor melalui 5-fold cross-validation untuk menguji kombinasi unit LSTM [16, 32, 64] serta dropout [0.1, 0.2]. Hasil terbaik diperoleh pada konfigurasi 64 unit dengan dropout 0.2, dilatih 50 epoch dengan batch size 32 dan validation set 10% (Mostafa Abotaleb & Makarovskikh, 2024). EarlyStopping digunakan untuk menghentikan pelatihan saat validation loss stagnan, menghasilkan model yang mampu mempelajari pola temporal kompleks tanpa overfitting (Muthoni Wanyoike, 2024).

2.7 Evaluasi Model

Evaluasi performa model LSTM dilakukan secara menyeluruh melalui analisis visual dan kuantitatif. Tahap awal mencakup learning curve yang memantau training loss dan validation loss untuk mendeteksi proses pembelajaran dan risiko overfitting, dengan visualisasi menggunakan Matplotlib (Pilla & Mekonen, 2025). Akurasi prediksi juga diuji melalui plot time series yang membandingkan nilai aktual dan hasil prediksi pada data testing dengan bantuan Matplotlib dan Seaborn.

Secara kuantitatif, model dievaluasi menggunakan metrik MAE, RMSE (akar kuadrat MSE), dan R² melalui fungsi mean_absolute_error, mean_squared_error, dan r2_score dari scikit-learn. Perhitungan dilakukan pada data training dan testing untuk menilai kemampuan model dalam mempelajari pola historis sekaligus menggeneralisasi data baru (Pilla & Mekonen, 2025). Seluruh evaluasi dijalankan di Google Colab atau Jupyter Notebook untuk integrasi kode, grafik, dan interpretasi hasil.

2.8 Peramalan Masa Depan

Peramalan harga saham 10 hari ke depan menggunakan model LSTM dilakukan dengan memanfaatkan pola temporal yang telah dipelajari selama proses pelatihan. Prediksi dijalankan secara bertahap, di mana setiap hasil keluaran dimasukkan kembali sebagai masukan untuk langkah selanjutnya. Nilai prediksi kemudian dikonversi kembali ke skala aslinya menggunakan MinMaxScaler melalui fungsi transform() dan inverse_transform() (Babu, 2025).

Hasil peramalan divisualisasikan dengan Matplotlib, menampilkan garis historis (biru) dan proyeksi (merah) agar tren, seasonality, dan volatility mudah diamati (Lara-Benítez et al., 2021). Proses ini biasanya dijalankan di Google Colab atau Jupyter Notebook untuk mendukung eksekusi interaktif. Prediksi LSTM dapat menjadi bahan pertimbangan investasi, namun tetap perlu dilengkapi analisis fundamental dan faktor eksternal agar interpretasinya lebih akurat (Babu, 2025; Lara-Benítez et al., 2021).

3 HASIL DAN PEMBAHASAN

3.1 Hasil Dataset

Dataset dibaca menggunakan Pandas yang diinisialisasikan sebagai pd dan dikonversi menjadi dataframe (df) agar mudah diolah. Selanjutnya, ditampilkan 10 baris data teratas dan terbawah untuk mengecek struktur dan isi dataset. Berikut ditampilkan 10 baris data teratas dan baris data terbawah sebagai berikut:

Date	Price	Open	High	Low	Vol.	Change %
8/21/00/2025	230	232	234	228	725M	-0.86%
1/20/00/2025	232	236	240	232	454M	-1.69%
2/19/00/2025	236	232	228	228	381M	1.72%
3/18/00/2025	232	240	242	234	193M	0.25%
4/17/00/2025	238	238	242	236	625M	0.85%
5/16/00/2025	236	240	240	234	838M	-1.67%
6/15/00/2025	240	242	242	236	338M	-0.80%
7/12/00/2025	242	238	242	236	625M	1.68%
8/11/00/2025	238	240	242	236	402M	-0.80%
9/10/00/2025	240	246	246	238	707M	-1.64%

Gambar 3. Dataset PT SMDR, PT NELLY dan PT TEMAS

3.2 Hasil Prapemrosesan Data

Proses pembersihan data meliputi penghilangan simbol seperti %, K, M, dan B, lalu mengubahnya menjadi format numerik. Nilai yang kosong dihapus menggunakan df.dropna(), sementara kolom Date dikonversi ke format datetime agar analisis deret waktu menjadi lebih mudah.

(a)						
	Date	Price	Open	High	Low	Vol. Change %
0	2020-01-02	250	254	254	248	15700.0 -1.57
1	2020-01-03	248	250	252	246	43500.0 -0.80
2	2020-01-06	242	248	248	242	108400.0 -2.42
3	2020-01-07	246	248	248	244	54900.0 1.65
4	2020-01-08	242	246	246	240	69600.0 -1.63

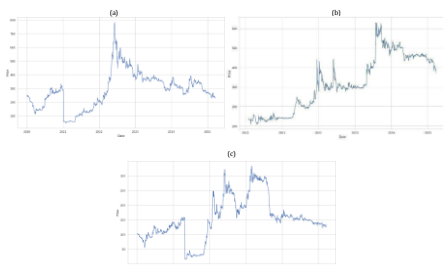
(b)						
	Date	Price	Open	High	Low	Vol. Change %
0	2020-01-02	104	104	109	102	6300000.0 1.96
1	2020-01-03	103	104	105	101	4820000.0 -0.96
2	2020-01-06	102	103	105	102	5120000.0 -0.97
3	2020-01-07	102	103	104	100	6340000.0 0.00
4	2020-01-08	101	102	102	100	2950000.0 -0.98

(c)						
	Date	Price	Open	High	Low	Vol. Change %
0	2020-01-02	104	104	109	102	6300000.0 1.96
1	2020-01-03	103	104	105	101	4820000.0 -0.96
2	2020-01-06	102	103	105	102	5120000.0 -0.97
3	2020-01-07	102	103	104	100	6340000.0 0.00
4	2020-01-08	101	102	102	100	2950000.0 -0.98

Gambar 4. Pembersihan Data (Missing Values)

3.3 Hasil Visual Data

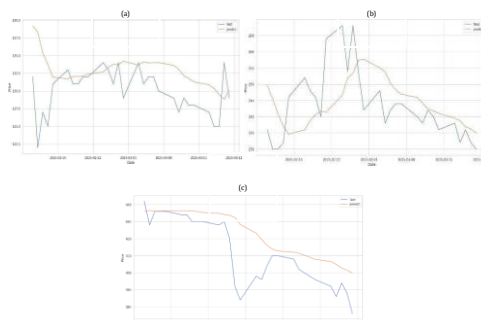
Grafik pergerakan harga saham menggambarkan periode pola fluktuasi yang kompleks dengan volatilitas tinggi dan tren jangka panjang. Pola ini menjadi alasan pemilihan LSTM, yang mampu menangkap dependensi waktu dan pola non-linear lebih baik dibanding model statistik seperti ARIMA. sumber pustakanya.



Gambar 5. Tren historiharga saham SMDR, NELLY, dan TEMAS

3.4 Hasil Preparasi Data

Data ketiga saham (SMDR, Nelly, Temas) dibagi 80% untuk training dan 20% untuk testing secara kronologis. Nilai harga kemudian dinormalisasi ke rentang [0,1] menggunakan Min-Max Scaler (fit hanya pada data training) untuk mencegah data leakage. Selanjutnya, dibentuk sliding window 30 timestep agar data siap diproses model LSTM dalam format 3 dimensi.



Gambar 6. (Test and predict) SMDR, NELLY dan TEMAS

3.5 Hasil Evaluasi Model

Berdasarkan hasil evaluasi model pada tiga saham transportasi laut yang diperoleh, model LSTM menunjukkan performa yang sangat baik dalam memprediksi harga saham. Hasil evaluasi model training dan testing pada saham SMDR di bawah berikut menunjukkan performa yang sangat buruk pada data training dengan MAE 285.84, MSE 103,677.04, RMSE 321.98 dan R² negatif (-3.70), yang berarti model gagal mempelajari pola data latih dengan baik. Namun, anehnya, model justru bekerja sangat baik pada data testing dengan MAE 8.96, MSE 161.53, RMSE 12.70 dan R² 0.91, menunjukkan prediksi yang akurat. Berikut hasil evaluasi model dapat dilihat pada Tabel 1.

Tabel 1. Hasil Model (SMDR)

Metrik Evaluasi	Training	Test
MAE	285.840	8.960
MSE	103,677.04	161.53
RMSE	321.98	12.70
R2	-3.70	0.91

Hasil evaluasi model pada data training dan testing unstick saham Nelly menunjukkan adanya permasalahan signifikan dalam proses pelatihan. Pada data training, model tampil sangat buruk dengan MAE 293,95, MSE 104.305,89, RMSE 322,96, dan R² negatif (-4,81), yang mengindikasikan kegagalan model dalam mempelajari pola data. Namun, secara

megejutkan, model justru menunjukkan performa yang cukup baik pada data testing dengan MAE 6,61, MSE 89,88, RMSE 9,48 dan R^2 0,77. Rincian hasil evaluasi model dapat dilihat pada tabel 2.

Tabel 2. Hasil Evaluasi Model (NELLY)

Metrik Evaluasi	Training Set	Test Set
MAE	293.95	6.61
MSE	104,305.89	89.88
RMSE	322.96	9.48
R2	-4.80	0.77

Hasil evaluasi model training dan testing saham TEMAS di bawah berikut menunjukkan ketidakwajaran yang signifikan antara performa training dan testing. Pada data training, model menunjukkan kegagalan total dengan MAE 156.15, MSE 30.847, RMSE 175.63 dan R^2 negatif (-3.74), yang berarti model sama sekali tidak mampu mempelajari pola data yang diberikan. Namun anehnya, model justru bekerja cukup baik pada data testing dengan MAE hanya 2.93, MSE 14.18, RMSE 3.76 dan R^2 0.85. Berikut hasil evaluasi model dapat dilihat pada Tabel.3

Tabel 3. Hasil Evaluasi Model (TEMAS)

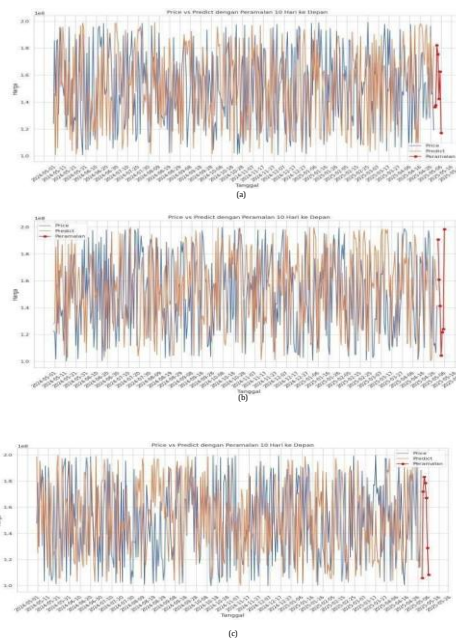
Metrik Evaluasi	Training Set	Test Set
MAE	156.15	2.93
MSE	30.847	14.18
RMSE	175.63	3.76
R2	-3.74	0.85

3.6 Hasil Prediksi

Visualisasi prediksi LSTM pada tiga saham transportasi laut (SMDR, NELY, TMAS) menampilkan kemampuan dan tantangan model dalam mempelajari pola historis serta

meramalkan harga 10 hari ke depan (27 Mei–5 Juni 2025). Untuk SMDR, garis prediksi historis (oranye) selaras dengan harga aktual (biru), sementara titik prediksi ke depan (merah) menunjukkan tren stabil tanpa lonjakan besar, menandakan proyeksi pasar yang relatif tenang.

Pada NELY, meski pola historis cukup mengikuti data aktual, prediksi jangka pendek terlihat sangat fluktuatif dengan perubahan tajam antarhari. Hal ini menunjukkan sensitivitas model yang tinggi atau potensi overfitting akibat volatilitas harga. Sedangkan TMAS menampilkan prediksi historis yang cukup akurat, namun proyeksi 10 hari ke depan cenderung menurun secara bertahap, menandakan kemungkinan sinyal pelemahan harga atau indikasi underfitting karena model kurang menangkap detail dinamika pasar. Secara keseluruhan, Model LSTM dapat menangkap pola historis, namun kestabilan prediksi jangka pendek sangat bergantung pada karakteristik masing-masing saham, termasuk tingkat volatilitas dan kualitas data latih.



Gambar 7. Hasil Prediksi SMDR, NELLY dan TEMAS

4 KESIMPULAN

Penelitian ini menilai akurasi prediksi harga saham SMDR, TMAS, dan NELY di BEI menggunakan LSTM berbasis data historis OHLCV dengan pendekatan sliding window.

Hasil menunjukkan SMDR memiliki akurasi terbaik ($R^2 = 0,91$), disusul TMS (0,85), sedangkan NELY lebih rendah (0,77) karena volatilitas tinggi. Nilai R^2 negatif (-3,70) saat pelatihan menandakan potensi overfitting. Studi ini memberi kontribusi pada literatur prediksi saham berbasis deep learning dan menawarkan manfaat praktis bagi investor, namun keterbatasan dalam menghadapi market shock menunjukkan perlunya integrasi faktor makroekonomi, teknik ensemble, atau LSTM dengan mekanisme Attention untuk meningkatkan ketahanan model.

UCAPAN TERIMA KASIH

Dengan rasa Syukur kepada Allah SWT yang telah memberikan kesehatan, rezeki berupa ilmu, dan kemudahan lainnya sehingga penulis dapat menyusun artikel ilmiah ini dengan baik. Dan Terima kasih Juga kepada kedua orang tua, keluarga, teman, serta semua pihak yang telah memberikan dukungan dan bimbingan, khususnya dosen pembimbing atas arahan dan masukan berharga. Penulis menyadari artikel ini masih jauh dari sempurna, sehingga kritik dan saran sangat diharapkan untuk perbaikan ke depan. Semoga karya ini bermanfaat bagi pengembangan ilmu, khususnya prediksi harga saham dengan metode LSTM.

DAFTAR PUSTAKA

- [1] H. Suryanto, I. N. S. Degeng, E. T. Djatmika, and D. Kuswandi, "The effect of creative problem solving with the intervention social skills on the performance of creative tasks," *Creativity Studies*, vol. 14, no. 2, pp. 323–335, 2021, doi: 10.3846/cs.2021.12364.
- [2] N. N. Shehata, H. Elwakil, S. S. Elshewemi, D. Doaa, B. Ghareeb, et al., "Selenium nanoparticles coated bacterial polysaccharide with potent antimicrobial and anti-lung cancer activities," *Scientific Reports*, vol. 13, p. 21871, 2023, doi: 10.1038/s41598-023-48921-9.
- [3] M. Diqi, I. W. Ordiyasa, and H. Hamzah, "Enhancing Stock Price Prediction Using Stacked Long Short-Term Memory," *IT Journal Research and Development*, vol. 8, no. 2, pp. 164–174, 2024, doi: 10.25299/itjrd.2023.13486.
- [4] N. Wijayanti and S. A. Widodo, "Studi korelasi motivasi belajar terhadap hasil belajar matematika selama daring," *Journal of Instructional Mathematics*, vol. 2, no. 1, pp. 1–9, 2021, doi: 10.37640/jim.v2i1.849.
- [5] F. Landi, L. Baraldi, M. Cornia, and R. Cucchiara, "Working Memory Connections for LSTM," *Neural Networks*, vol. 144, pp. 334–341, 2021, doi: 10.1016/j.neunet.2021.08.030.
- [6] D. Siswara, A. M. Soleh, and A. H. Wigena, "Classification Modeling with RNN-Based, Random Forest, and XGBoost for Imbalanced Data: A Case of Early Crash

-
- Detection in ASEAN-5 Stock Markets,” arXiv, 2024, doi: 10.48550/arXiv.2406.07888.
- [7] V. K. Pilli, H. T. Chugani, and C. Juhász, “Enlargement of deep medullary veins during the early clinical course of Sturge–Weber syndrome,” *Neurology*, vol. 88, no. 1, pp. 103–105, 2017, doi: 10.1212/WNL.0000000000003455.
- [8] J. Illes, M. L. Perreault, K. Bassil, J. G. Bjaalie, R. L. Taylor-Bragge, H. Chneiweiss, et al., “Two-Eyed Seeing and other Indigenous perspectives for neuroscience,” *Nature*, vol. 638, no. 6, pp. 58–68, 2025, doi: 10.1038/s41586-024-08437-2.
- [9] M. Li, A. Pal, A. Aghakhani, A. Pena-Francesch, and M. Sitti, “Soft actuators for real-world applications,” *Nature Reviews Materials*, vol. 7, no. 3, pp. 235–249, 2021, doi: 10.1038/s41578-021-00389-7.
- [10] A. Panagiotelis, G. Athanasopoulos, P. Gamakumara, and R. J. Hyndman, “Forecast reconciliation: A geometric view with new insights on bias correction,” *International Journal of Forecasting*, vol. 37, no. 1, pp. 343–359, 2021, doi: 10.1016/j.ijforecast.2020.06.004.
- [11] A. Das, W. Kong, A. Leach, S. Mathur, R. Sen, and R. Yu, “Long-term Forecasting with TiDE: Time-series Dense Encoder,” arXiv, 2024, doi: 10.48550/arXiv.2304.08424.
- [12] A. Ghodsi, J. K. Ghosh, E. Kiritsis, F. Nitti, and V. Nourry, “Holographic QFTs on AdS_n , wormholes and holographic interfaces,” *Journal of High Energy Physics*, vol. 2023, no. 1, p. 121, 2023, doi: 10.1007/JHEP01(2023)121.
- [13] S. Cui, R. Zhang, Y. Peng, X. Gao, Z. Li, et al., “New insights into ball milling effects on MgAl-LDHs exfoliation on biochar support: A case study for cadmium adsorption,” *Journal of Hazardous Materials*, vol. 416, p. 126258, 2021, doi: 10.1016/j.jhazmat.2021.126258.