

Penerapan Metode *Long Short-Term Memory* (LSTM) untuk Prediksi Harga Saham Berdasarkan Tingkat Volatilitas

I Gede Febrana Putra¹, Ni Made Satvika Iswari², Eddy Muntina Dharma³
^{1,2,3}Informatika, Universitas Primakara
Email : febranaputra021@gmail.com

ABSTRACT

Memprediksi harga saham bukan perkara mudah karena banyaknya variabel luar yang berubah-ubah. Dalam riset ini, kami menerapkan model Long Short-Term Memory (LSTM) untuk melihat tren harga saham di indeks LQ45 sepanjang 2021–2024, khususnya dengan membedah bagaimana volatilitas pasar mempengaruhi ketepatan model. Menggunakan metrik MAPE, kami menemukan bahwa LSTM bekerja sangat optimal dengan skor rata-rata 1,85%. Menariknya, terdapat selisih performa yang nyata: saham dengan pergerakan stabil (volatilitas rendah) diprediksi jauh lebih akurat (1,48%) dibandingkan saham yang sangat fluktuatif (2,22%). Angka ini membuktikan bahwa pola historis lebih mudah dibaca oleh model saat harga tidak terlalu bergejolak. Secara praktis, temuan ini menyarankan agar investor lebih waspada saat menggunakan prediksi otomatis pada saham berisiko tinggi.

Keywords: *Long Short-Term Memory* (LSTM), Prediksi Harga Saham, Indeks LQ45, Volatilitas, MAPE, *Deep Learning*.

ABSTRACT

Forecasting stock prices remains a daunting task due to the constant shift of unpredictable external variables. In this study, we implemented a Long Short-Term Memory (LSTM) model to analyze price trends within the LQ45 index from 2021 to 2024, focusing specifically on how market volatility impacts the model's precision. Using MAPE as our primary evaluation metric, our findings show that LSTM performs exceptionally well, achieving an overall average error of 1.85%. Interestingly, a clear performance gap emerged: stocks with stable movement (low volatility) were predicted with much higher accuracy (1.48%) compared to those with high fluctuations (2.22%). This suggests that historical patterns are far easier for the model to decode when price movements are less erratic. Practically, these results serve as a cautionary note for investors to be more vigilant when relying on automated predictions for high-risk, volatile assets.

Keywords: *Long Short-Term Memory* (LSTM), Stocks Price Prediction, LQ45 Index, Volatility, MAPE, *Deep Learning*.

1. INTRODUCTION

Pasar modal merupakan salah satu pilar penting dalam perekonomian modern karena berperan sebagai sarana investasi sekaligus sumber pendanaan bagi perusahaan. Pergerakan harga saham yang dinamis memberikan peluang bagi investor untuk memperoleh keuntungan, namun di sisi lain juga menghadirkan risiko yang tinggi akibat fluktuasi harga. Oleh karena itu, kemampuan memprediksi pergerakan harga saham menjadi kebutuhan penting, baik bagi investor ritel maupun institusional, untuk mendukung pengambilan keputusan investasi yang lebih terukur.

Prediksi harga saham bukanlah hal yang sederhana, karena pergerakannya dipengaruhi oleh banyak faktor, baik ekonomi makro, kondisi industri, maupun faktor internal perusahaan (Li et al., 2022). Selain itu, sifat data saham yang berupa deret waktu (*time series*) dan cenderung non-linear membuat metode konvensional sering kali kurang mampu menangkap pola pergerakan harga secara akurat (Wathani et al., 2023). Dalam konteks inilah, perkembangan teknologi kecerdasan buatan, khususnya deep learning, memberikan alternatif solusi yang lebih menjanjikan (Kartika & Karmilasari, 2022).

Salah satu metode deep learning yang banyak digunakan untuk prediksi deret waktu adalah *Long Short-Term Memory* (LSTM). LSTM merupakan pengembangan dari *Recurrent Neural Network* (RNN) yang dirancang untuk mengatasi masalah *vanishing gradient* dan lebih efektif dalam mengenali pola jangka panjang (Julian & Pribadi, 2021). Sejumlah penelitian terdahulu membuktikan bahwa LSTM mampu memberikan hasil prediksi yang lebih baik dibandingkan metode tradisional seperti ARIMA dan *Support Vector Regression* (SVR), maupun model pembelajaran mesin lainnya (Arfan & ETP, 2020).

Namun demikian, sebagian besar penelitian masih berfokus pada penerapan LSTM secara umum tanpa mempertimbangkan aspek volatilitas saham. Padahal, volatilitas mencerminkan tingkat ketidakpastian pergerakan harga dan menjadi indikator penting dalam mengukur risiko investasi (Alkhatib et al., 2022). Dengan memahami bagaimana LSTM bekerja pada saham dengan tingkat volatilitas yang berbeda, investor dapat memperoleh gambaran yang lebih komprehensif mengenai potensi risiko dan peluang (Sari & Setiyawan, 2023).

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk menganalisis kinerja LSTM dalam memprediksi harga saham dengan mempertimbangkan perbedaan tingkat volatilitas. Secara teoritis, penelitian ini menambah wawasan mengenai penerapan LSTM dalam konteks pasar modal dengan memasukkan aspek volatilitas sebagai variabel pembeda. Secara praktis, hasil penelitian ini dapat memberikan rekomendasi bagi investor dan trader dalam menentukan strategi transaksi, karena prediksi harga saham tidak hanya memberikan gambaran tren, tetapi juga dapat digunakan untuk memperkirakan harga tertinggi dan terendah sebagai dasar pengambilan keputusan.

2. LITERATURE REVIEW

Penelitian terkait prediksi harga saham telah berkembang pesat dengan berbagai pendekatan, mulai dari metode statistik klasik hingga algoritma kecerdasan buatan. Model tradisional seperti ARIMA dan Support Vector Regression (SVR) terbukti memiliki keterbatasan ketika dihadapkan pada data saham yang bersifat non-linear dan sangat fluktuatif (Kolambe & Arora, 2024). Hal ini mendorong penggunaan metode berbasis deep learning yang lebih adaptif terhadap pola kompleks.

Salah satu metode yang paling menonjol adalah Long Short-Term Memory (LSTM), pengembangan dari Recurrent Neural Network (RNN) yang dirancang untuk mengatasi masalah *vanishing gradient* dan menangkap pola jangka panjang dalam data deret waktu (Julian & Pribadi, 2021). Sejumlah studi menunjukkan keunggulan LSTM dibandingkan model lain. Arfan dan ETP (2020) membuktikan bahwa LSTM mampu memberikan hasil lebih akurat dibanding ARIMA dan SVR, sementara Alim (2023) menegaskan keunggulan LSTM dalam

menangkap non-linearitas data saham. (Jie & Ramli (2023) juga menemukan bahwa LSTM dapat meningkatkan performa prediksi harga saham secara signifikan dibandingkan metode pembelajaran mesin lainnya.

Selain saham, penerapan LSTM juga meluas ke instrumen keuangan lain seperti *cryptocurrency* (Moch Farryz Rizkilloh & Sri Widiyanesti, 2022), yang menemukan bahwa LSTM efektif memprediksi harga aset kripto yang cenderung lebih volatil, memperlihatkan fleksibilitas metode ini di berbagai pasar. Namun, meskipun LSTM terbukti unggul, sebagian besar penelitian masih fokus pada perbandingan algoritma tanpa mempertimbangkan kondisi volatilitas sebagai faktor pembeda kinerja model.

Padahal, volatilitas merupakan indikator penting dalam pasar modal karena mencerminkan tingkat ketidakpastian harga dan risiko investasi. Penelitian dari Khalil & Bakar (2023) menunjukkan bahwa volatilitas berpengaruh terhadap efektivitas model prediksi saham, sementara Sari & Setiyawan (2023) menegaskan bahwa variasi volatilitas antar saham dapat menimbulkan perbedaan akurasi prediksi. Dengan demikian, gap penelitian yang muncul adalah minimnya kajian yang secara eksplisit mengintegrasikan aspek volatilitas dalam evaluasi kinerja LSTM.

3. METHODS

3.1 Sampling

Penelitian ini menggunakan sampel saham yang konsisten tergabung dalam indeks LQ45 pada periode 2021–2024. Dari keseluruhan saham dalam indeks, dipilih 26 saham yang memenuhi kriteria konsistensi keanggotaan selama periode penelitian. Selanjutnya, saham-saham tersebut dikelompokkan berdasarkan tingkat volatilitasnya ke dalam dua kategori: volatilitas rendah (nilai volatilitas tahunan $\leq$ median) dan volatilitas tinggi (nilai volatilitas tahunan $>$ median).

3.2 Data Collection

Data historis harga saham diunduh melalui Yahoo Finance API menggunakan pustaka *yfinance* dalam Python. Periode data yang diambil mencakup 1 Januari 2021 hingga 31 Desember 2024 dengan atribut: *Open*, *High*, *Low*, *Close*, *Volume*, serta *Adjusted Close*. Fitur *Adjusted Close* dipilih sebagai target utama karena telah disesuaikan dengan aksi korporasi perusahaan.

3.3 Measures

Sebelum digunakan dalam pemodelan, data diproses melalui beberapa tahap :

1. Normalisasi data menggunakan *Min-Max Scaling* untuk menyelaraskan rentang nilai antara 0 dan 1.
2. Pembentukan sequence time series dengan metode *sliding window*, yaitu teknik yang memanfaatkan sejumlah harga historis sebagai input untuk memprediksi harga pada hari berikutnya.
3. Data splitting dilakukan dengan proporsi 70% training, 15% validation, dan 15% testing. Pembagian ini memastikan model dapat belajar, divalidasi selama pelatihan, dan diuji pada data baru untuk mengukur kemampuan generalisasi.

Evaluasi model dilakukan menggunakan *Mean Absolute Percentage Error* (MAPE), karena metrik ini memberikan interpretasi kesalahan dalam bentuk persentase yang mudah dipahami dan relevan dalam konteks keuangan.

3.4 Modeling

Model yang digunakan adalah *Long Short-Term Memory* (LSTM), sebuah varian dari *Recurrent Neural Network* (RNN) yang efektif untuk data runtun waktu. Arsitektur model terdiri dari:

- Input layer: menerima sequence data historis.
- LSTM layer: dengan jumlah neuron yang ditentukan melalui tuning.
- Dropout layer: digunakan untuk mencegah *overfitting*.

- Dense layer (output): satu neuron dengan aktivasi linear, menghasilkan prediksi harga pada hari berikutnya.

Proses hyperparameter tuning dilakukan dengan pendekatan *random search* sebanyak 10 iterasi. Parameter yang diuji meliputi:

- Window size: 30, 60, 90
- Units: 50, 100, 150, 200
- Batch size: 16, 32, 64
- Learning rate: 0.001, 0.0005
- Dropout rate: 0.1, 0.2, 0.3

Model dilatih menggunakan *optimizer Adam* dan fungsi loss *Mean Squared Error (MSE)*. Untuk mencegah *overfitting*, digunakan mekanisme *early stopping* yang menghentikan pelatihan ketika tidak ada perbaikan pada data validasi.

4. RESULTS


Penelitian ini menganalisis saham-saham yang secara konsisten masuk dalam indeks LQ45 pada periode 2021 hingga 2024. Terdapat 26 saham yang sesuai dengan kriteria tersebut dan akan disajikan pada Tabel 1 berikut.

Tabel 1. Daftar Saham LQ45 Konsisten Periode 2021-2024

No	Nama Perusahaan	Kode Saham
1	PT Alamtri Resources Indonesia Tbk	ADRO
2	PT Aneka Tambang Tbk	ANTM
3	PT Astra International Tbk	ASII
4	PT Bank Central Asia Tbk	BBCA
5	PT Bank Negara Indonesia (Persero) Tbk	BBNI
6	PT Bank Rakyat Indonesia (Persero) Tbk	BBRI
7	PT Bank Tabungan Negara (Persero) Tbk	BBTN
8	PT Bank Mandiri (Persero) Tbk	BMRI
9	PT Charoen Pokphand Indonesia Tbk	CPIN
10	PT XLSMART Telecom Sejahtera Tbk	EXCL
11	PT Indofood CBP Sukses Makmur Tbk	ICBP
12	PT Vale Indonesia Tbk	INCO
13	PT Indofood Sukses Makmur Tbk	INDF
14	PT Indah Kiat Pulp & Paper Tbk	INKP
15	PT Indocement Tunggal Prakarsa Tbk	INTP
16	PT Indo Tambangraya Megah Tbk	ITMG
17	PT Kalbe Farma Tbk.	KLBF
18	PT Merdeka Copper Gold Tbk	MDKA
19	PT Medco Energi Internasional Tbk	MEDC
20	PT Perusahaan Gas Negara Tbk	PGAS
21	PT Bukit Asam Tbk	PTBA
22	PT Semen Indonesia (Persero) Tbk	SMGR
23	PT Telekomunikasi Indonesia (Persero) Tbk	TLKM
24	PT Sarana Menara Nusantara Tbk.	TOWR
25	PT United Tractors Tbk	UNTR
26	PT Unilever Indonesia Tbk	UNVR

Untuk menentukan tingkat volatilitas, digunakan standar deviasi return harian yang dianualisasi. Berdasarkan nilai median yang diperoleh sebesar 0,328, saham kemudian dikelompokkan menjadi dua kategori, yaitu kelompok

volatilitas rendah sebanyak 13 saham dan kelompok volatilitas tinggi sebanyak 13 saham. Berikut disajikan pada Gambar 1 merupakan kelompok saham berdasarkan volatilitas.



Gambar 1 Kelompok Saham Berdasarkan Volatilitas

Untuk memperoleh konfigurasi model yang optimal, dilakukan proses hyperparameter tuning dengan mencoba berbagai kombinasi parameter utama LSTM. Proses *tuning* ini bertujuan untuk menemukan kombinasi yang mampu menghasilkan kinerja prediksi terbaik sekaligus menjaga kestabilan model. Berikut merupakan hasil dari Hyperparameter Tuning.

Tabel 2. Hasil Hyperparameter Tuning

Kode Saham	Window Size	Units	Batch Size	Learning Rate	Dropout Rate	MAPE
ADRO	60	50	16	0.001	0.1	2,87%
ANTM	90	200	16	0.001	0.1	1,78%
ASII	30	150	32	0.001	0.2	1,23%
BBCA	90	200	16	0.0005	0.1	1,09%
BBNI	90	200	16	0.0005	0.1	1,71%
BBRI	90	100	16	0.001	0.1	1,43%
BBTN	90	100	32	0.001	0.1	1,41%
BMRI	90	150	16	0.0005	0.1	1,59%
CPIN	60	100	16	0.001	0.1	1,25%
EXCL	90	150	16	0.001	0.2	1,01%
ICBP	30	100	16	0.001	0.1	1,06%
INCO	90	150	16	0.0005	0.1	1,92%
INDF	90	150	16	0.0005	0.2	1,04%
INKP	90	200	32	0.001	0.2	1,41%
INTP	60	200	16	0.001	0.3	3,17%
ITMG	90	50	16	0.0005	0.3	1,44%
KLBF	30	200	32	0.001	0.1	1,54%
MDKA	90	200	16	0.0005	0.1	2,16%
MEDC	90	100	16	0.001	0.3	1,88%
PGAS	60	150	16	0.001	0.3	1,29%

PTBA	30	100	32	0.001	0.2	1,42%
SMGR	90	100	32	0.001	0.1	4,68%
TLKM	90	200	16	0.001	0.3	1,70%
TOWR	60	150	16	0.0005	0.1	2,38%
UNTR	60	200	32	0.001	0.1	1,33%
UNVR	90	200	32	0.001	0.3	4,72%

Setelah model LSTM dituning menggunakan kombinasi hyperparameter terbaik, langkah selanjutnya adalah melakukan evaluasi kinerja model pada data uji. Evaluasi dilakukan menggunakan metrik *Mean Absolute Percentage Error* (MAPE) untuk masing-masing dari 26 saham sampel. Nilai MAPE yang lebih rendah menunjukkan tingkat kesalahan prediksi yang lebih kecil dan akurasi model yang lebih tinggi. Hasil evaluasi lengkap ditampilkan pada Tabel 3.

Tabel 3. Hasil Evaluasi MAPE pada Seluruh Saham

No	Nama Perusahaan	Kode Saham	MAPE
1	PT Adaro Energy Indonesia Tbk	ADRO	2,70%
2	PT Aneka Tambang Tbk	ANTM	1,78%
3	PT Astra International Tbk	ASII	1,26%
4	PT Bank Central Asia Tbk	BBCA	1,11%
5	PT Bank Negara Indonesia (Persero) Tbk	BBNI	1,66%
6	PT Bank Rakyat Indonesia (Persero) Tbk	BBRI	1,47%
7	PT Bank Tabungan Negara (Persero) Tbk	BBTN	1,42%
8	PT Bank Mandiri (Persero) Tbk	BMRI	1,56%
9	PT Charoen Pokphand Indonesia Tbk	CPIN	1,22%
10	PT XL Axiata Tbk	EXCL	1,01%
11	PT Indofood CBP Sukses Makmur Tbk	ICBP	1,03%
12	PT Vale Indonesia Tbk	INCO	1,92%
13	PT Indofood Sukses Makmur Tbk	INDF	1,04%
14	PT Indah Kiat Pulp & Paper Tbk	INKP	1,43%
15	PT Indocement Tunggul Prakarsa Tbk	INTP	2,28%
16	PT Indo Tambangraya Megah Tbk	ITMG	1,51%
17	PT Kalbe Farma Tbk	KLBF	1,78%
18	PT Merdeka Copper Gold Tbk	MDKA	2,19%
19	PT Medco Energi Internasional Tbk	MEDC	2,05%
20	PT Perusahaan Gas Negara Tbk	PGAS	1,32%
21	PT Bukit Asam Tbk	PTBA	1,54%
22	PT Semen Indonesia (Persero) Tbk	SMGR	5,42%
23	PT Telekomunikasi Indonesia (Persero) Tbk	TLKM	1,69%
24	PT Sarana Menara Nusantara Tbk	TOWR	1,74%
25	PT United Tractors Tbk	UNTR	1,38%

26	PT Unilever Indonesia Tbk	UNVR	4,55%
Rata-rata MAPE			1,85%

Untuk menganalisis lebih lanjut, saham-saham tersebut dikelompokkan berdasarkan tingkat volatilitasnya. Tabel 4 menyajikan hasil evaluasi MAPE khusus untuk saham dengan volatilitas rendah, yaitu saham yang nilai volatilitas tahunannya berada di bawah atau sama dengan nilai median.

Tabel 4. Hasil Evaluasi MAPE pada Saham Volatilitas Rendah

No	Nama Perusahaan	Kode Saham	MAPE
1	PT Astra International Tbk	ASII	1,26%
2	PT Bank Central Asia Tbk	BBCA	1,11%
3	PT Bank Negara Indonesia (Persero) Tbk	BBNI	1,66%
4	PT Bank Rakyat Indonesia (Persero) Tbk	BBRI	1,47%
5	PT Bank Tabungan Negara (Persero) Tbk	BBTN	1,42%
6	PT Bank Mandiri (Persero) Tbk	BMRI	1,56%
7	PT Charoen Pokphand Indonesia Tbk	CPIN	1,22%
8	PT Indofood CBP Sukses Makmur Tbk	ICBP	1,03%
9	PT Indofood Sukses Makmur Tbk	INDF	1,04%
10	PT Indocement Tunggul Prakarsa Tbk	INTP	2,28%
11	PT Kalbe Farma Tbk	KLBF	1,78%
12	PT Telekomunikasi Indonesia (Persero) Tbk	TLKM	1,69%
13	PT Sarana Menara Nusantara Tbk	TOWR	1,74%
Rata-rata MAPE			1,48%

Sementara itu, Tabel 5 menampilkan hasil evaluasi MAPE untuk kelompok saham dengan volatilitas tinggi, yaitu saham dengan nilai volatilitas tahunan di atas median.

Tabel 5. Hasil Evaluasi MAPE pada Saham Volatilitas Tinggi

No	Nama Perusahaan	Kode Saham	MAPE
1	PT Adaro Energy Indonesia Tbk	ADRO	2,70%
2	PT Aneka Tambang Tbk	ANTM	1,78%
3	PT XL Axiata Tbk	EXCL	1,01%
4	PT Vale Indonesia Tbk	INCO	1,92%
5	PT Indah Kiat Pulp & Paper Tbk	INKP	1,43%
6	PT Indo Tambangraya Megah Tbk	ITMG	1,51%
7	PT Merdeka Copper Gold Tbk	MDKA	2,19%
8	PT Medco Energi Internasional Tbk	MEDC	2,05%
9	PT Perusahaan Gas Negara Tbk	PGAS	1,32%
10	PT Bukit Asam Tbk	PTBA	1,54%
11	PT Semen Indonesia (Persero) Tbk	SMGR	5,42%

12	PT United Tractors Tbk	UNTR	1,38%
13	PT Unilever Indonesia Tbk	UNVR	4,55%
Rata-rata MAPE			2,22%

5. Reporting Research Results

Sebagai rangkuman, rata-rata MAPE dari kedua kelompok volatilitas kemudian dibandingkan untuk menilai konsistensi dan stabilitas hasil prediksi. Ringkasan perbandingan rata-rata nilai MAPE antara kelompok volatilitas rendah dan tinggi ditampilkan pada Tabel 6, sehingga dapat terlihat secara jelas perbedaan kinerja model berdasarkan kategori volatilitas.

Tabel 6. Rata-Rata MAPE Saham Berdasarkan Kelompok Volatilitas

Kelompok Volatilitas	Rata-rata MAPE
Rendah	1,48%
Tinggi	2,22%

Tabel 6 memperlihatkan perbandingan nilai rata-rata *Mean Absolute Percentage Error* (MAPE) antara dua kelompok saham berdasarkan tingkat volatilitas. Kelompok saham dengan volatilitas rendah menghasilkan rata-rata MAPE sebesar 1,48%, sedangkan kelompok saham dengan volatilitas tinggi menghasilkan rata-rata MAPE sebesar 2,22%.

Hasil Berdasarkan hasil perbandingan tersebut, dapat disimpulkan bahwa tingkat volatilitas memiliki pengaruh signifikan terhadap akurasi prediksi harga saham menggunakan model LSTM. Dengan akurasi yang lebih tinggi pada saham volatilitas rendah, model terbukti lebih efektif ketika diterapkan pada instrumen dengan pola harga yang stabil. Sebaliknya, performa model cenderung menurun pada saham dengan volatilitas tinggi akibat fluktuasi harga yang lebih besar dan sulit diprediksi.

6. DISCUSSION

Penelitian ini bertujuan untuk mengevaluasi kinerja *Long Short-Term Memory* (LSTM) dalam memprediksi harga saham LQ45 dengan mempertimbangkan perbedaan tingkat volatilitas. Hasil penelitian menunjukkan bahwa LSTM mampu menghasilkan prediksi yang sangat akurat, dengan rata-rata MAPE keseluruhan 1,85%, yang termasuk kategori “sangat baik” (Lewis, 1982).

Perbedaan akurasi terlihat jelas antara dua kelompok volatilitas. Saham volatilitas rendah memiliki rata-rata MAPE 1,48%, lebih rendah dibandingkan saham volatilitas tinggi dengan rata-rata 2,22%. Hal ini menegaskan

bahwa stabilitas harga saham memudahkan model dalam mengenali pola historis, sehingga memberikan prediksi yang lebih presisi.

Secara praktis, hasil penelitian ini memberi implikasi bagi investor bahwa prediksi saham volatilitas rendah dapat dijadikan dasar keputusan yang lebih stabil, sementara pada saham volatilitas tinggi, hasil prediksi perlu diperlakukan lebih hati-hati. Dengan demikian, penelitian ini berkontribusi baik secara teoretis maupun praktis dalam memperkuat pemahaman penerapan LSTM di pasar modal Indonesia dengan menekankan pentingnya dimensi volatilitas.

7. CONCLUSION

Penelitian ini menunjukkan bahwa LSTM mampu memprediksi harga saham LQ45 dengan tingkat akurasi yang sangat baik (MAPE rata-rata pada seluruh saham adalah 1,85%). Perbedaan terlihat jelas antara dua kelompok volatilitas, di mana saham volatilitas rendah lebih akurat diprediksi (MAPE 1,48%) dibandingkan saham volatilitas tinggi (MAPE 2,22%). Hasil ini menegaskan pentingnya mempertimbangkan volatilitas dalam penerapan model prediksi berbasis deep learning.

Keterbatasan penelitian ini terletak pada cakupan data yang terbatas pada periode 2021–2024 dan penggunaan variabel yang hanya mencakup data harga historis. Studi selanjutnya disarankan untuk menambahkan indikator teknikal maupun fundamental serta menguji arsitektur model lain guna meningkatkan akurasi dan generalisasi hasil.

8. REFERENCES

- Alim, M. A. (2023). Pemodelan Time Series Data Saham LQ45 dengan Algoritma LSTM, RNN, dan Arima. *Prosiding Seminar Nasional Matematika*, 6, 694–701. <https://journal.unnes.ac.id/sju/index.php/prisma/>
- Alkhatib, K., Khazaleh, H., Alkhazaleh, H. A., Alsoud, A. R., & Abualigah, L. (2022). A New Stock Price Forecasting Method Using Active Deep Learning Approach. *Journal of Open Innovation: Technology, Market, and Complexity*, 8(2). <https://doi.org/10.3390/joitmc8020096>
- Arfan, A., & ETP, L. (2020). Perbandingan Algoritma Long Short-Term Memory dengan SVR Pada Prediksi Harga Saham di Indonesia. *PETIR*, 13(1), 33–43. <https://doi.org/10.33322/petir.v13i1.858>
- Jie, S. S., & Ramli, A. A. (2023). Stock Price Prediction Using Long Short-Term Memory. *Applied Information Technology And Computer Science*, 4(1), 1311–1324. <https://doi.org/10.30880/aitcs.2023.04.01.076>
- Julian, R., & Pribadi, M. R. (2021). Peramalan Harga Saham Pertambangan Pada Bursa Efek Indonesia (BEI) Menggunakan Long Short Term Memory (LSTM). *Jurnal Teknik Informatika Dan Sistem Informasi*, 8(3). <http://jurnal.mdp.ac.id>

- Kartika, D. S., & Karmilasari. (2022). Implementasi Long Short-Term Memory pada Prediksi Harga Saham PT Aneka Tambang Tbk. *Jurnal Ilmiah KOMPUTASI Volume 21 No 1*.
- Khalil, R. A. B., & Bakar, A. A. B. U. (2023). A Comparative Study of Deep Learning Algorithms in Univariate and Multivariate Forecasting of the Malaysian Stock Market. *Sains Malaysiana*, 52(3), 993–1009. <https://doi.org/10.17576/jsm-2023-5203-22>
- Kolambe, M., & Arora, S. (2024). Forecasting the Future: A Comprehensive Review of Time Series Prediction Techniques. In *J. Electrical Systems* (Vol. 20, Issue 2).
- Li, S., Wang, Y., Zhang, Z., & Zhu, Y. (2022). Research on the Factors Affecting Stock Price Volatility. *Advances in Economics, Business and Management Research, Volume 211*.
- Moch Farryz Rizkillah, & Sri Widiyanesti. (2022). Prediksi Harga Cryptocurrency Menggunakan Algoritma Long Short Term Memory (LSTM). *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 6(1), 25–31. <https://doi.org/10.29207/resti.v6i1.3630>
- Sari, W., & Setiawan, S. (2023). Volatilitas Saham Sektor Teknologi yang Terdaftar di Indeks Saham Syariah Indonesia pada Masa Pandemi COVID-19. *Jurnal Accounting Information System (AIMS)*, 6(1), 53–62. <https://doi.org/10.32627>
- Wathani, M. N., Kusrini, K., & Kusnawi, K. (2023). Prediksi Tren Pergerakan Harga Saham PT Bank Central Asia Tbk, Dengan Menggunakan Algoritma Long Shot Term Memory (LSTM). *Infotek: Jurnal Informatika Dan Teknologi*, 6(2), 502–512. <https://doi.org/10.29408/jit.v6i2.19824>