

Pendekatan Dengan Bilstm: Kasus Peramalan Harga Penutupan Saham

1st Laily Nur Qomariyati
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

lailynrq@student.telkomuniversity.ac.id

2nd Suryo Adhi Wibowo
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

suryoadhiwibowo@telkomuniversity.ac.id

3rd Unang Sunarya
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

unangsunarya@telkomuniversity.ac.id

Abstrak — Peramalan saham merupakan salah satu tugas penting di pasar saham karena prediksi harga saham di masa depan dapat membantu investor dalam mengambil keputusan yang lebih baik. Penelitian ini mengkaji potensi jaringan Bidirectional Long Short-Term Memory (BiLSTM) sebagai bagian dari model deep learning untuk meningkatkan akurasi prediksi saham. Model BiLSTM yang diusulkan memanfaatkan kemampuan arsitektur model ini untuk menangkap ketergantungan jangka pendek dan jangka panjang dengan memproses data secara dua arah. Hal ini memungkinkan model untuk memanfaatkan informasi dari masa lalu dan masa depan secara simultan, memberikan prediksi yang lebih akurat. Model BiLSTM ini dievaluasi menggunakan metrik evaluasi seperti Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan Mean Absolute Percentage Error (MAPE). Penelitian ini menguji model pada beberapa saham, termasuk Apple, Gold, Oil, dan Silver. Hasil penelitian menunjukkan bahwa pendekatan BiLSTM tidak hanya efektif dalam memajukan metode peramalan harga penutupan saham, tetapi juga memiliki aplikasi praktis pada berbagai instrumen keuangan lainnya. Temuan ini memberikan kontribusi signifikan dalam bidang peramalan pasar saham, memperlihatkan bahwa BiLSTM dapat menjadi alat yang andal dan efektif dalam memprediksi pergerakan harga saham dan instrumen keuangan lainnya.

Kata kunci — peramalan saham, deep learning, BiLSTM.

I. PENDAHULUAN

Investing Berinvestasi di pasar saham telah menjadi metode populer bagi individu dan institusi untuk menumbuhkan kekayaan dan mencapai stabilitas keuangan jangka panjang. Namun, pasar saham terkenal karena volatilitas dan ketidakpastiannya, sehingga membuat keputusan investasi menjadi tantangan. Peramalan saham memainkan peran penting dalam pengambilan keputusan keuangan, karena memberikan wawasan berharga kepada investor, pedagang, dan peserta pasar lainnya mengenai kemungkinan arah dan besarnya perubahan harga di masa depan [1]. Kebutuhan akan peramalan saham yang akurat menjadi sangat penting di pasar keuangan yang bergerak cepat dan sangat kompetitif saat ini [2]. Namun, peramalan saham adalah tugas yang menantang yang memerlukan teknik statistik dan pembelajaran mesin yang canggih. Pasar keuangan kompleks dan sangat tidak dapat diprediksi, serta

banyak faktor yang dapat mempengaruhi harga saham, termasuk indikator ekonomi, peristiwa geopolitik [3], [4], dan perubahan sentimen investor [5]–[8]. Akibatnya, peramalan saham memerlukan penggunaan model matematika dan algoritma canggih yang dapat menangkap hubungan kompleks antara berbagai faktor ini dan memprediksi pergerakan harga di masa depan dengan tingkat akurasi yang tinggi. Metode pembelajaran mesin, terutama pembelajaran mendalam, telah dikembangkan untuk memprediksi harga saham. Penerapan model Recurrent Neural Network (RNN) untuk memproses data deret waktu seperti Long-Short Term Memory (LSTM) digunakan untuk memprediksi indeks harga penutupan saham S&P 500 pada hari berikutnya. Ditemukan bahwa LSTM lapisan tunggal memiliki nilai RMSE sebesar 42.7093 dalam 100 epoch, sementara LSTM Multi-Layer memiliki nilai RMSE sebesar 53.9076 dalam 100 epoch [9]. Studi lain juga membandingkan model LSTM dan Bidirectional Long-Short Term Memory (BiLSTM) untuk memprediksi harga saham, di mana dengan parameter yang sama, BiLSTM menghasilkan nilai RMSE yang lebih rendah dibandingkan dengan LSTM [10]. Dalam penelitian lain, BiLSTM mencapai nilai MAE sebesar 21.952 dan nilai RMSE sebesar 31.694 dalam memprediksi Saham Indeks Komposit Shanghai [11]. Penelitian ini bertujuan untuk mengeksplorasi dan mengembangkan model BiLSTM yang akan mewakili pendekatan prediksi deret waktu, memungkinkan model untuk menangkap ketergantungan maju dan mundur dalam data sekuensial.


II. KAJIAN TEORI

Bab ini membahas konsep dasar pendahuluan dari rancangan yang diusulkan seperti Pemahaman Candlestick, dan model BiLSTM.

A. Memahami Grafik *Candlestick*

Grafik *candlestick* adalah alat yang berguna untuk memvisualisasikan harga saham dan mengidentifikasi pola yang dapat digunakan untuk meramalkan pergerakan harga saham di masa depan. Seperti yang terlihat pada Gambar 1, bagian utama dari candlestick adalah *body* dan *wick* (atau *shadow*). *Body* dari *candlestick* mewakili kisaran harga

antara harga pembukaan dan penutupan. Jika harga penutupan lebih tinggi daripada harga pembukaan, *body* biasanya berwarna hijau atau putih (*bullish*). Sebaliknya, jika harga penutupan lebih rendah daripada harga pembukaan, *body* biasanya berwarna merah atau hitam (*bearish*). *Candlestick* berwarna hijau atau putih menunjukkan sinyal kenaikan harga saham, sedangkan *candlestick* berwarna merah atau hitam menunjukkan sinyal penurunan. Pola harga saham yang direpresentasikan oleh bentuk *candlestick* memberikan petunjuk penting untuk memprediksi pergerakan harga saham di masa depan. *Wick* atau *shadow* memanjang di atas dan di bawah *body*, mewakili harga tertinggi (H) dan terendah (L) yang dicapai selama periode waktu tertentu. *Shadow* atas mewakili harga tertinggi, dan *shadow* bawah mewakili harga terendah. *Shadow* yang lebih panjang menunjukkan volatilitas harga yang lebih besar, sedangkan *shadow* yang lebih pendek menunjukkan pergerakan harga yang lebih stabil [12].



GAMBAR 1.
Komponen *Candlestick*


Pada grafik *candlestick*, setiap komponen akan memiliki pola dari empat harga yang menjadi indikator. Dengan melihat masing-masing indikator ini, setiap pedagang atau investor dapat menilai tingkat pergerakan suatu jenis komoditas saham. Informasi harga ini sangat mendasar untuk analisis *candlestick* dan secara tidak langsung direpresentasikan melalui komponen-komponen *candlestick* itu sendiri.

B. Bidirectional Long Short-Term Memory

BiLSTM adalah jenis RNN yang memungkinkan input mengalir dalam kedua arah, sehingga dapat memanfaatkan informasi dari keadaan masa lalu dan masa depan [13],[14]. Jika semua timestep dari urutan input tersedia, Bidirectional LSTM memanfaatkan dua LSTM untuk pelatihan pada urutan input, berbeda dengan hanya satu LSTM. Satu LSTM menangani urutan dalam arah maju (berpindah dari masa lalu ke masa depan), sementara yang lainnya menangani urutan dalam arah mundur (berpindah dari masa depan ke masa lalu). Metode bidirectional ini meningkatkan kemampuan model untuk memahami konteks, karena mengumpulkan informasi dari keadaan masa lalu dan masa depan [15],[16].

LSTM memiliki tiga gerbang, yaitu Forget gate, Input gate, dan Output gate. Forget gate memutuskan informasi apa dari cell state yang harus dibuang atau disimpan. Input gate bertanggung jawab untuk mengontrol jumlah informasi baru yang akan disimpan dalam cell state. Output gate menentukan apa yang seharusnya menjadi keadaan tersembunyi

berikutnya. Gerbang ini mempertimbangkan cell state yang diperbarui dan input saat ini, melalui fungsi sigmoid dan fungsi tanh [17]–[20]. Gambar 2 menunjukkan arsitektur LSTM tunggal dan Bidirectional LSTM.




GAMBAR 2.
Arsitektur dari
(A) LSTM and (B) BiLSTM

III. METODE

Bab ini membahas perancangan model dan sistem yang terdiri dari pemasangan dataset, pra-pemrosesan data, pemrosesan dan evaluasi model menggunakan parameter kinerja dalam memprediksi harga saham. Penelitian ini menggunakan harga historis Emas, Perak, Minyak dan Apple sebagai input dan memprediksi harga penutupan menggunakan model BiLSTM. Kinerja model dievaluasi menggunakan MAE, MAPE, dan RMSE.

A. Desain Sistem



GAMBAR 3
Sistem Desain dari Model yang Diusulkan

Desain sistem untuk peramalan saham menggunakan BiLSTM dapat dilihat pada Gambar 3. Desain ini melibatkan beberapa komponen penting. Langkah pertama adalah mengumpulkan data historis dari saham yang telah dipilih. Selanjutnya, tahap pembersihan data memastikan kebersihan dan konsistensi dataset, meminimalkan dampak data yang tidak valid atau mengganggu. Kemudian, untuk mengatasi ukuran data yang tidak konsisten, kami menerapkan normalisasi data dan membagi data menjadi set pelatihan dan pengujian. Selanjutnya, model BiLSTM dibangun dan dilatih menggunakan data pelatihan, dengan menggunakan fungsi kerugian dan pengoptimal untuk mengoptimalkan kinerja model. Setelah model dilatih, model dievaluasi pada set validasi untuk menentukan hiperparameter dan arsitektur model terbaik. Terakhir, model diuji pada set pengujian untuk melihat efektivitasnya dalam memprediksi harga penutupan saham.

B. Dataset

Saham yang digunakan adalah saham Apple, Gold, Oil, dan Silver. Sektor yang berbeda dapat memberikan wawasan tentang dinamika dan tren pasar yang beragam sehingga model dapat belajar dan berkinerja lebih baik. Dataset yang

digunakan diperoleh dari situs web Yahoo Finance (<https://finance.yahoo.com>). Dataset yang digunakan di sini mencakup data harga historis dengan kerangka waktu harian. Dataset ini menunjukkan pergerakan dan tren harga dalam periode satu hari. Harga historis mencakup informasi tentang tanggal, harga pembukaan, harga tertinggi, harga terendah, harga penutupan, adj. close, dan volume seperti yang terlihat pada Gambar 4.

Date	Open	High	Low	Close	Adj Close	Volume
Oct 09, 2023	176.81	179.05	175.80	178.99	178.75	42,390,800
Oct 06, 2023	173.80	177.99	173.18	177.49	177.26	57,224,100
Oct 05, 2023	173.79	175.45	172.68	174.91	174.68	48,527,900
Oct 04, 2023	171.09	174.21	170.97	173.66	173.43	53,020,300
Oct 03, 2023	172.26	173.63	170.82	172.40	172.17	49,594,600
Oct 02, 2023	171.22	174.30	170.93	173.75	173.52	52,164,500

GAMBAR 4.

Contoh harga saham historis yang diperoleh dari yahoofinance

C. Preprocessing

Pre-processing adalah langkah penting dalam mempersiapkan data pasar saham untuk peramalan. Metode ini terdiri dari beberapa tahapan yang memastikan kualitas, keandalan, dan kegunaan data untuk melatih model pembelajaran mesin. Tahapan utama praproses meliputi pembersihan dataset, pemisahan dataset menjadi set pelatihan dan pengujian, serta normalisasi data.

1. Pembersihan Data

Pembersihan dataset adalah langkah awal untuk memastikan kualitas dan akurasi data yang digunakan untuk melatih model. Pertama, menangani nilai yang hilang. Selanjutnya, memperbaiki tipe data untuk memastikan bahwa semua informasi dalam format yang benar. Terakhir, menyaring data yang tidak relevan dengan menghapus fitur yang tidak diperlukan dan tidak berkontribusi pada prediksi. Dalam studi ini, kami menghapus kolom "Date" seperti yang ditunjukkan pada Gambar 5.

	Open	High	Low	Close	Adj Close	Volume
0	7.622500	7.660714	7.585000	7.643214	6.461977	493729600.0
1	7.664286	7.699643	7.616071	7.656429	6.473148	601904768.0
2	7.656429	7.686786	7.526786	7.534643	6.370185	552160000.0
3	7.562500	7.571429	7.466071	7.520714	6.358407	477131200.0
4	7.510714	7.571429	7.466429	7.570714	6.400682	447610816.0

GAMBAR 5.

Hasil dari Pembersihan Data

2. Pemisahan Data

Setelah membersihkan dataset, data perlu dipisahkan menjadi set pelatihan, validasi, dan pengujian untuk memastikan evaluasi model yang kuat dan kinerja yang optimal. Seperti yang terlihat pada Tabel 1, untuk setiap dataset dalam penelitian ini, 70% data dialokasikan untuk set pelatihan, yang digunakan untuk melatih model dan membantu model belajar dari pola harga saham historis. Sisanya 30% data disisihkan untuk set pengujian, yang digunakan untuk mengevaluasi kinerja akhir model. Selain itu, selama pelatihan model, dilakukan pemisahan validasi sebesar 0,2 dari data pelatihan.

TABEL 1.
Pemisahan Data untuk Tiap Saham

Stock	Number of Training Data	Number of Test Data
Gold	7005	3003

Apple	1408	604
Silver	2423	1039
Oil	2424	1039

3. Normalisasi


Data keuangan sering kali memiliki rentang nilai yang sangat bervariasi antara satu fitur dengan fitur lainnya. Untuk mengatasi ukuran data yang tidak konsisten, kami menerapkan normalisasi data. Dengan melakukan normalisasi, skala data diubah menjadi rentang yang seragam, memastikan setiap fitur memiliki dampak yang seimbang dalam proses pembelajaran model [21]. Dalam penelitian ini, kami menggunakan skala Min-Max, yang mentransformasikan data ke rentang yang telah ditentukan, yaitu antara 0 dan 1. Rumus untuk skala Min-Max ditunjukkan pada (1).

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

dimana X adalah individual data, sementara X_{min} dan X_{max} menunjukkan nilai terendah dan nilai tertinggi dari dataset.

D. Processing

1. Membangun BiLSTM Model



GAMBAR 6.

Desain Processing Model

Seperti yang terlihat pada Gambar 6, alur dimulai dengan data input, yang mencakup berbagai fitur terkait saham. Data mentah ini pertama-tama mengalami normalisasi, yaitu langkah praproses yang menskalakan data ke rentang standar untuk meningkatkan kinerja model dan stabilitas pelatihan. Setelah normalisasi, data memasuki lapisan BiLSTM. Lapisan ini memproses urutan input dalam arah maju dan mundur, secara efektif menangkap ketergantungan temporal. Ini sangat penting untuk peramalan saham, di mana pemahaman tentang tren jangka panjang sangat diperlukan. Setelah lapisan BiLSTM mengekstraksi dan memproses fitur-fitur, data berpindah ke lapisan yang sepenuhnya terhubung. Lapisan ini menggabungkan semua fitur yang dipelajari dari lapisan sebelumnya dan menyiapkan output akhir. Akhirnya, data yang telah diproses mencapai lapisan prediksi output, yang menghasilkan harga penutupan saham.

2. Training and Validating Model

Pelatihan dan validasi model melibatkan proses sistematis untuk mengoptimalkan kinerja dan memastikan generalisasi. Dalam studi ini, pelatihan dilakukan hingga maksimum 100 epoch dengan ukuran batch 128. Proses pembelajaran model dipandu oleh fungsi kerugian Huber, yang menyeimbangkan sensitivitas terhadap outlier dan kelancaran pengukuran kesalahan, serta pengoptimal Adamax, yang dikenal karena kekuatannya dalam menangani gradien yang jarang dan laju pembelajaran yang besar. Parameter `validation_split=0.2` menetapkan 20% dari data pelatihan sebagai set validasi,

memungkinkan model dievaluasi pada data yang belum terlihat selama pelatihan. Set validasi ini membantu memantau kinerja model secara real-time dan memastikan bahwa model tidak mengalami overfitting pada data pelatihan.

E. Evaluasi Model Evaluation

Dalam penelitian ini, metrik kinerja tertentu digunakan untuk menilai akurasi prediksi. Metrik ini berfokus pada evaluasi seberapa dekat nilai yang diprediksi dengan nilai sebenarnya. Parameter kinerja yang digunakan dalam tesis ini adalah MAE, MAPE, dan RMSE.

MAE mengukur rata-rata perbedaan absolut antara nilai yang diprediksi dan nilai sebenarnya. Rumus untuk menghitung MAE dapat dilihat pada (2), di mana N mewakili jumlah total data, Y_j mewakili nilai sebenarnya, dan $\hat{Y}_j$ mewakili nilai yang diprediksi.

$$MAE = \frac{1}{N} \sum_{j=1}^N |Y_j - \hat{Y}_j| \quad (2)$$

MAPE mengukur selisih persentase antara nilai sebenarnya dan nilai yang diprediksi serta memberikan ukuran kemampuan model dalam meramalkan data secara akurat. Rumus untuk menghitung MAPE dapat dilihat pada (3).

$$MAPE = \frac{1}{N} \sum_{j=1}^N \left| \frac{Y_j - \hat{Y}_j}{Y_j} \right| \times 100\% \quad (3)$$

RMSE mengukur rata-rata besaran kesalahan antara nilai yang diprediksi dan nilai sebenarnya, dan merupakan metrik evaluasi yang populer karena memberikan bobot lebih pada kesalahan besar dibandingkan dengan kesalahan kecil [22]. Rumus RMSE dapat dilihat pada (4).

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (\hat{Y}_j - Y_j)^2}{N}} \quad (4)$$

IV. HASIL DAN DISKUSI

Bab ini mengkaji kekuatan model BiLSTM dengan membandingkan prediksinya dengan data sebenarnya. Saham yang digunakan dalam studi ini adalah Apple, Emas, Perak, dan Minyak. Studi ini mengukur kinerja model dan mengidentifikasi area yang memerlukan perbaikan menggunakan metrik kinerja seperti MAE, RMSE, dan MAPE serta interpretasi grafis.

A. Hasil Pengujian Model

Dalam evaluasi kinerja model BiLSTM untuk peramalan harga saham, hasil metrik kinerja memberikan wawasan penting tentang efektivitas model dalam memprediksi harga saham dari berbagai sektor. Analisis berikut menjelaskan bagaimana model ini berkinerja terhadap saham Apple, Silver, Oil dan Gold.

TABLE 2.

Hasil dari BiLSTM Model di beberapa saham

Mode	Stock	MAE	RMSE	MAPE
------	-------	-----	------	------

BiLSTM	Gold	2.36	3.16	2.38%
	Apple	6.44	7.25	4.97%
	Silver	2.39	3.29	2.45%
	Oil	3.69	4.48	4.47%

Untuk saham emas, model BiLSTM menunjukkan hasil yang sangat baik dengan MAE sebesar 2,36, RMSE 3,16, dan MAPE 2,38%. Metrik ini menandakan bahwa model mampu memprediksi harga saham emas dengan tingkat akurasi yang tinggi, serta kesalahan rata-rata yang relatif kecil. MAPE yang rendah menunjukkan bahwa prediksi harga emas sangat mendekati nilai aktual, dan model ini menunjukkan kemampuan yang solid dalam menangkap pola harga saham emas.

Saham perak menunjukkan hasil yang serupa baiknya, dengan MAE 2.39, RMSE 3.29, dan MAPE 2.45%. Ini menunjukkan bahwa model BiLSTM juga efektif dalam memprediksi harga saham perak dengan akurasi yang hampir setara dengan saham emas. MAE dan RMSE yang rendah menunjukkan kesalahan prediksi yang kecil, dan MAPE yang rendah menandakan bahwa model dapat memprediksi harga perak dengan persentase kesalahan yang minimal.

Namun, untuk saham Apple, model BiLSTM mengalami penurunan kinerja dengan MAE sebesar 6.44, RMSE 7.25, dan MAPE 4.97%. Nilai-nilai ini menunjukkan bahwa model kesulitan dalam memprediksi harga saham Apple dengan akurasi yang sama baiknya dengan saham emas dan perak. Kesalahan yang lebih tinggi dan MAPE yang lebih besar menunjukkan bahwa model mungkin tidak sepenuhnya berhasil menangkap pola harga saham teknologi ini, yang mungkin disebabkan oleh volatilitas atau faktor khusus lainnya yang mempengaruhi harga saham Apple.

Saham minyak juga menunjukkan hasil yang kurang memuaskan dengan MAE 3.69, RMSE 4.48, dan MAPE 4.47%. Metrik ini menunjukkan bahwa model BiLSTM mengalami kesulitan dalam memprediksi harga minyak dengan akurasi yang tinggi. Kesalahan yang lebih besar dan MAPE yang lebih tinggi menunjukkan bahwa model kurang efektif dalam menangkap pola harga minyak, yang mungkin terkait dengan faktor-faktor pasar yang lebih kompleks atau fluktuasi harga yang lebih tajam di sektor energi.

V. KESIMPULAN

Dalam penelitian ini digunakan BiLSTM model untuk memprediksi harga penutupan saham. Dengan beberapa saham yang digunakan diantaranya: Apple, Silver, Oil dan Gold. Analisis kinerja model BiLSTM menunjukkan bahwa model ini efektif dalam memprediksi harga saham emas dan perak, dengan MAE, RMSE, dan MAPE yang rendah, menandakan akurasi prediksi yang tinggi dan kesalahan yang minim. Untuk saham emas dan perak, model berhasil memberikan prediksi yang sangat mendekati nilai sebenarnya. Namun, model menghadapi tantangan dalam memprediksi harga saham Apple dan minyak, dengan MAE, RMSE, dan MAPE yang lebih tinggi. Ini menunjukkan bahwa model kesulitan dalam menangkap pola harga di sektor teknologi dan energi, yang mungkin disebabkan oleh volatilitas atau faktor pasar spesifik. Secara keseluruhan, meskipun BiLSTM menunjukkan performa yang baik pada beberapa saham, penyesuaian lebih lanjut dan data tambahan

diperlukan untuk meningkatkan akurasi prediksi pada saham yang lebih kompleks.

REFERENSI

- [1] M. Vijh, D. Chandola, V. A. Tikkiwal, and A. Kumar, "Stock Closing Price Prediction using Machine Learning Techniques," *Procedia Comput. Sci.*, vol. 167, no. 2019, pp. 599–606, 2020, doi: 10.1016/j.procs.2020.03.326.
- [2] W. Jiang, "Applications of deep learning in stock market prediction: Recent progress," *Expert Syst. Appl.*, vol. 184, no. March 2020, p. 115537, 2021, doi: 10.1016/j.eswa.2021.115537.
- [3] N. M. H. Masoud, "The impact of stock market performance upon economic growth," *Int. J. Econ. Financ. Issues*, vol. 3, no. 4, pp. 788–798, 2013.
- [4] C. Chikwira and J. I. Mohammed, "The Impact of the Stock Market on Liquidity and Economic Growth: Evidence of Volatile Market," *Economics*, vol. 11, no. 6, 2023, doi: 10.3390/economics11060155.
- [5] W. Khan, M. A. Ghazanfar, M. A. Azam, A. Karami, K. H. Alyoubi, and A. S. Alfakheh, "Stock market prediction using machine learning classifiers and social media, news," *J. Ambient Intell. Humaniz. Comput.*, vol. 13, no. 7, pp. 3433–3456, 2022, doi: 10.1007/s12652-020-01839-w.
- [6] X. Tang, N. Lei, M. Dong, and D. Ma, "Stock Price Prediction Based on Natural Language Processing1," *Complexity*, vol. 2022, 2022, doi: 10.1155/2022/9031900.
- [7] J. Guo and B. Tuckfield, "News-based Machine Learning and Deep Learning Methods for Stock Prediction," *J. Phys. Conf. Ser.*, vol. 1642, no. 1, pp. 0–7, 2020, doi: 10.1088/1742-6596/1642/1/012014.
- [8] T. T. Teoh et al., "From Technical Analysis to Text Analytics: Stock and Index Prediction with GRU," *Proc. IEEE 2019 9th Int. Conf. Cybern. Intell. Syst. Robot. Autom. Mechatronics, CIS RAM 2019*, pp. 496–500, 2019, doi: 10.1109/CIS-RAM47153.2019.9095772.
- [9] H. N. Bhandari, B. Rimal, N. R. Pokhrel, R. Rimal, K. R. Dahal, and R. K. C. Khatri, "Predicting stock market index using LSTM," *Mach. Learn. with Appl.*, vol. 9, no. May, p. 100320, 2022, doi: 10.1016/j.mlwa.2022.100320.
- [10] M. A. Istiaque Sunny, M. M. S. Maswood, and A. G. Alharbi, "Deep Learning-Based Stock Price Prediction Using LSTM and Bi-Directional LSTM Model," *2nd Nov. Intell. Lead. Emerg. Sci. Conf. NILES 2020*, pp. 87–92, 2020, doi: 10.1109/NILES50944.2020.9257950.
- [11] L. Xu, W. Xu, Q. Cui, M. Li, B. Luo, and Y. Tang, "Deep Heuristic Evolutionary Regression Model Based on the Fusion of BiGRU and BiLSTM," *Cognit. Comput.*, pp. 1672–1686, 2023, doi: 10.1007/s12559-023-10135-6.
- [12] K. H. Lee and G. S. Jo, "Expert system for predicting stock market timing using a candlestick chart," vol. 16, pp. 357–364, 1999.
- [13] S. Siامي-Namini, N. Tavakoli, and A. S. Namin, "The Performance of LSTM and BiLSTM in Forecasting Time Series," *Proc. - 2019 IEEE Int. Conf. Big Data, Big Data 2019*, pp. 3285–3292, 2019, doi: 10.1109/BigData47090.2019.9005997.
- [14] M. Rahimzad, A. Moghaddam, and N. Hosam, "Performance Comparison of an LSTM - based Deep Learning Model versus Conventional Machine Learning Algorithms for Streamflow Forecasting," *Water Resour. Manag.*, pp. 4167–4187, 2021, doi: 10.1007/s11269-021-02937-w.
- [15] W. Lu, "A CNN-BiLSTM-AM method for stock price prediction," *Neural Comput. Appl.*, vol. 33, no. 10, pp. 4741–4753, 2021, doi: 10.1007/s00521-020-05532-z.
- [16] T. Cho, U. Sunarya, M. Yeo, B. Hwang, and Y. S. Koo, "Deep-ACTINet: End-to-End Deep Learning Architecture for Automatic Sleep-Wake Detection Using Wrist Actigraphy," doi: 10.3390/electronics8121461.
- [17] J. Kim and N. Moon, "BiLSTM model based on multivariate time series data in multiple field for forecasting trading area," *J. Ambient Intell. Humaniz. Comput.*, no. 0123456789, 2019, doi: 10.1007/s12652-019-01398-9.
- [18] S. Zaheer et al., "A Multi Parameter Forecasting for Stock Time Series Data Using LSTM and Deep Learning Model," *Mathematics*, vol. 11, no. 3, pp. 1–24, 2023, doi: 10.3390/math11030590.
- [19] Z. Zou and Z. Qu, "Using LSTM in Stock prediction and Quantitative Trading," *CS230 Deep Learn.*, 2020.
- [20] C. Y. Lai, R. C. Chen, and R. E. Caraka, "Prediction Stock Price Based on Different Index Factors Using LSTM," *Proc. - Int. Conf. Mach. Learn. Cybern.*, vol. 2019-July, pp. 1–6, 2019, doi: 10.1109/ICMLC48188.2019.8949162.
- [21] D. Singh and B. Singh, "Investigating the impact of data normalization on classification performance," *Appl. Soft Comput.*, vol. 97, p. 105524, 2020.
- [22] Y. Liu, Y. Zhou, S. Wen, and C. Tang, "A Strategy on Selecting Performance Metrics for Classifier Evaluation," *Int. J. Mob. Comput. Multimed. Commun.*, vol. 6, no. 4, pp. 20–35, 2014, doi: 10.4018/IJMMCMC.2014100102.