


Implementasi CNN-BiLSTM untuk Prediksi Harga Saham Bank Syariah di Indonesia

Mushliha




Volume 6, Issue 2, Pages 195–203, August 2024

Diterima 8 Juni 2024, Direvisi 26 Juli 2024, Disetujui 30 Juli 2024, Diterbitkan 2 Agustus 2024

To Cite this Article : M. Mushliha, "Implementasi CNN-BiLSTM untuk Prediksi Harga Saham Bank Syariah di Indonesia", *Jambura J. Math*, vol. 6, no. 2, pp. 195–203, 2024, <https://doi.org/10.37905/jjom.v6i2.26509>

© 2024 by author(s)

JOURNAL INFO • JAMBURA JOURNAL OF MATHEMATICS




	Homepage	:	http://ejurnal.ung.ac.id/index.php/jjom/index
	Journal Abbreviation	:	Jambura J. Math.
	Frequency	:	Biannual (February and August)
	Publication Language	:	English (preferable), Indonesia
	DOI	:	https://doi.org/10.37905/jjom
	Online ISSN	:	2656-1344
	Editor-in-Chief	:	Hasan S. Panigoro
	Publisher	:	Department of Mathematics, Universitas Negeri Gorontalo
	Country	:	Indonesia
	OAI Address	:	http://ejurnal.ung.ac.id/index.php/jjom/oai
	Google Scholar ID	:	iWLjgaUAAAAJ
	Email	:	info.jjom@ung.ac.id


JAMBURA JOURNAL • FIND OUR OTHER JOURNALS




Jambura Journal of Biomathematics



Jambura Journal of Mathematics Education



Jambura Journal of Probability and Statistics



EULER : Jurnal Ilmiah Matematika, Sains, dan Teknologi



Implementasi CNN-BiLSTM untuk Prediksi Harga Saham Bank Syariah di Indonesia

Mushliha^{1,*}

¹Jurusan Teknologi Informasi, Universitas Bina Sarana Informatika, Jakarta, Indonesia

ARTICLE HISTORY

Diterima 8 Juni 2024

Direvisi 26 Juli 2024

Disetujui 30 Juli 2024

Diterbitkan 2 Agustus 2024

KATA KUNCI

Prediksi
Deret Waktu
Harga Saham
CNN-BiLSTM

KEYWORDS

Forecasting
Time Series
Stock Price
CNN-BiLSTM

ABSTRAK. Prediksi harga saham memiliki peran yang sangat penting dalam investasi saham. Keakuratan dalam memprediksi harga saham dapat memberikan keuntungan finansial yang signifikan serta membantu mengurangi risiko investasi. Data harga saham bersifat deret waktu dengan karakteristik frekuensi tinggi, non-linearitas, dan memori panjang, yang membuat prediksi harga saham menjadi tantangan yang kompleks. Penelitian ini mengusulkan metode untuk prediksi harga saham bank syariah di Indonesia menggunakan CNN-BiLSTM. Metode ini bertujuan untuk meningkatkan akurasi prediksi dengan memanfaatkan kemampuan CNN dalam ekstraksi fitur dan kemampuan BiLSTM dalam memahami urutan temporal dari data saham. Data yang digunakan dalam penelitian ini adalah harga penutupan saham Bank Syariah Indonesia (BSI), Bank Tabungan Pensiunan Negara Syariah (BTPN Syariah), Bank Panin Dubai Syariah (PDSB) dari 02 Januari 2020 sampai 4 Juli 2024. Pengujian ketiga saham tersebut memiliki nilai MAPE berturut-turut 2.376%, 2.092%, dan 0.629%. Hasil penelitian menunjukkan model prediksi CNN-BiLSTM yang dihasilkan memiliki akurasi yang sangat baik dalam memprediksi harga saham.

ABSTRACT. Stock price forecasting plays a crucial role in stock investment. Accuracy in predicting stock prices can provide significant financial benefits and help reduce investment risks. Stock price data are time series with high-frequency characteristics, non-linearity, and long memory, which makes stock price prediction a complex challenge. This research proposes a method for predicting the stock prices of Islamic banks in Indonesia using CNN-BiLSTM. This method aims to improve prediction accuracy by utilizing the feature extraction capabilities of CNN and the ability of BiLSTM to understand the temporal sequences of stock data. The data used in this research are the closing stock prices of Bank Syariah Indonesia (BSI), Bank Tabungan Pensiunan Negara Syariah (BTPN Syariah), and Bank Panin Dubai Syariah (PDSB) from January 2, 2020, to July 4, 2024. Testing these three stocks yielded MAPE values of 2.376%, 2.092%, and 0.629%, respectively. The study results show that the CNN-BiLSTM prediction model produced has very good accuracy in predicting stock prices.



This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution-NonCommercial 4.0 International License. *Editorial of JJBM:* Department of Mathematics, Universitas Negeri Gorontalo, Jln. Prof. Dr. Ing. B. J. Habibie, Bone Bolango 96554, Indonesia.

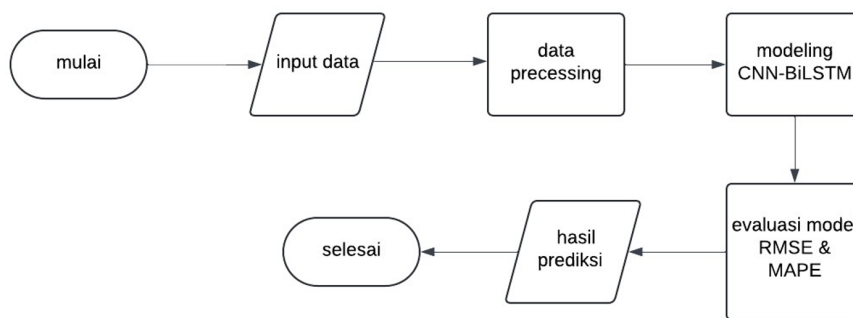
1. Pendahuluan

Selama beberapa dekade, prediksi harga saham telah menarik perhatian untuk investasi dan penelitian karena memiliki potensi yang besar. Tren harga saham mengacu pada pergerakan naik atau turun dari rangkaian harga di masa depan. Prediksi harga saham memungkinkan investor untuk membuat keputusan yang lebih terinformasi mengenai kapan harus membeli atau menjual saham [1, 2]. Memprediksi tren perubahan harga saham dimasa depan secara akurat dapat membantu investor menghindari risiko dan memperoleh keuntungan yang lebih tinggi di bursa saham [3]. Keuntungan maksimal dapat diperoleh dengan memprediksi tren perubahan harga saham dimasa depan serta mengurangi risiko kerugian [4]. Prediksi tren perubahan harga saham merupakan masalah yang cukup menantang karena sifatnya yang fluktuatif dan tidak stabil. Banyak faktor yang mempengaruhi harga saham seperti permintaan dan penawaran, ekonomi global, kebijakan pemerintah, sentimen pasar dan masih banyak faktor lain

yang ikut mempengaruhi [5].

Hingga saat ini, banyak teknik dan berbagai model telah diterapkan untuk memprediksi harga saham. Metode statistika klasik yang umum digunakan untuk prediksi harga saham yang memiliki data yang berupa runtun waktu berkala adalah *Autoregressive Integrated Moving Average* (ARIMA). ARIMA dirancang untuk data yang bersifat linear sehingga keakuratannya akan menurun untuk memprediksi data runtun waktu yang memiliki komponen nonlinear seperti data harga saham [6]. Data harga saham memiliki pola nonlinear yang kompleks sehingga ARIMA kurang efektif digunakan untuk prediksi harga saham sementara metode *machine learning* dapat menangani pola nonlinear lebih baik [7]. Metode *machine learning* merupakan metode yang banyak digunakan untuk prediksi harga saham. Kemampuan *machine learning* untuk mengelola data besar, meningkatkan akurasi prediksi, dan adaptasi cepat terhadap perubahan kondisi pasar membuatnya menjadi alat yang sangat berguna dalam prediksi harga saham [8]. Salah satu algoritma *machine learning* adalah *neural network*.

*Penulis Korespondensi.



Gambar 1. Proses pelatihan model CNN-BiLSTM

Algoritma ini telah menunjukkan kinerja yang baik dalam memprediksi harga saham berdasarkan data historis.

Algoritma *neural network* dapat digunakan untuk prediksi saham karena kemampuannya mengelola data kompleks, baik digunakan untuk data nonlinier dan data historis serta memiliki akurasi yang baik [9]. Algoritma *neural network* yang populer digunakan untuk prediksi harga saham antara lain ANN, RNN, LSTM, BiLSTM, CNN, GRU, dan BiGRU. Penelitian pada 2019 menggunakan metode *Recurrent Neural Network* (RNN) untuk prediksi saham dan menghasilkan akurasi sebesar 55% [10]. Penelitian lainnya di tahun 2023, melakukan analisis perbandingan prediksi harga saham menggunakan algoritma *Artificial Neural Network* (ANN) dan linear regression Dimana ANN sebagai model terbaik dengan RMSE 612.474 [11]. Beberapa penelitian yang menggunakan LSTM dan BiLSTM untuk prediksi seperti Prediksi Data *Time Series* Saham Bank BRI dengan Machine learning LSTM (*Long Short-Term Memory*) [12], Prediksi Harga Saham Menggunakan BiLSTM dengan Faktor Sentimen Publik [13], Implementasi *Long Short-Term Memory* (LSTM) dan *Bidirectional Long Short-Term Memory* (BiLSTM) Dalam Prediksi Harga Saham Syariah [14] menunjukkan bahwa baik LSTM dan BiLSTM baik digunakan untuk memprediksi beberapa saham. Penelitian menggunakan CNN untuk memprediksi harga saham menunjukkan bahwa CNN dapat memprediksi deret waktu, dan pembelajaran mendalam lebih cocok untuk menyelesaikan masalah deret waktu [15]. Berdasarkan penelitian sebelumnya diketahui bahwa CNN memiliki keunggulan dalam ekstraksi fitur sehingga dapat menangkap pola – pola penting dalam *time series* sedangkan LSTM dan BiLSTM memiliki kemampuan untuk memahami ketergantungan temporal dalam data deret waktu. BiLSTM, khususnya, dapat menangkap informasi dari kedua arah waktu, yang meningkatkan akurasi prediksi.

Penelitian ini bertujuan untuk mengkombinasikan CNN dan BiLSTM dengan CNN dapat menangkap informasi spasial dari data, sementara BiLSTM dapat menangkap pola temporal dari data dan melakukan prediksi. Kombinasi ini memungkinkan model untuk menangkap informasi dari berbagai aspek, termasuk konteks dan sekuensi, yang sangat penting dalam peramalan data deret waktu dan meningkatkan akurasi model. Penelitian ini mengusulkan metode CNN-BiLSTM untuk memprediksi harga saham bank syariah di Indonesia kemudian melakukan evaluasi nilai *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE).

2. Metode

Secara garis besar alur penelitian yaitu pra-pemrosesan data, proses data, implementasi model, evaluasi model, selanjutnya melakukan prediksi. Penelitian ini dilaksanakan dengan diagram alur pada Gambar 1.

2.1. Data Penelitian

Data penelitian yang digunakan dalam penelitian diperoleh dari *yahoo finance* dengan data saham bank syariah Indonesia yaitu Bank Syariah Indonesia (BRIS.JK), Bank BTPN Syariah (BTPS.JK) dan Bank Panin Dubai Syariah (PNBS.JK). Periode data saham yang digunakan 02 Januari 2020 sampai 4 Juli 2024 dengan data yang digunakan adalah data harga saham penutupan harian ('Close'). Total data yang digunakan dalam penelitian ini sebanyak 1087 data.

2.2. Data Preprocessing

Sebelum membangun model CNN-BiLSTM dilakukan data *preprocessing* terlebih dahulu. Pada tahap pertama dilakukan pembagian data menjadi data *training*, data *validation* dan data *testing*. Data *training* pada penelitian ini diambil 80% dari *dataset* berjumlah 869 data digunakan pada proses *training* untuk mengembangkan model prediksi. Data *validation* 10% dari seluruh *dataset* berjumlah 108 data digunakan untuk menguji model prediksi sebelum digunakan untuk memprediksi harga saham di masa depan. Sisanya, data *testing* berjumlah 110 data digunakan untuk menguji model prediksi yang telah diuji dengan data validasi.

Tahap kedua dilakukan normalisasi data untuk mendapatkan hasil model yang lebih baik. Pada penelitian ini digunakan *Min-Max Normalization* yang akan memetakan data dalam interval [0,1]. Normalisasi dilakukan dengan menggunakan persamaan berikut:

$$x_{norm,i} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad i = 1, 2, 3, \dots, t \quad (1)$$

dimana x_{norm} adalah hasil dari normalisasi, x_{min} adalah nilai terkecil dari data, dan x_{max} adalah nilai terbesar dari data [16].

Tahap selanjutnya menentukan *window size*. *Window size* yaitu banyak data sebelumnya yang digunakan untuk memprediksi. Penelitian ini menggunakan *window size* 5, 10, 15, 20, dan 30 untuk membangun model prediksi.

2.3. Modeling CNN-BiLSTM

Model CNN -BiLSTM yang dibangun adalah gabungan dari *convolutional neural networks* (CNN) dan *bi-directional long short-*

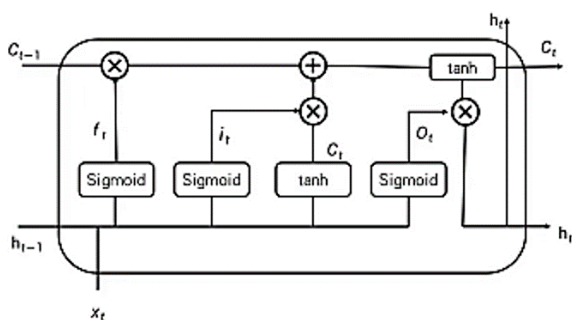
term Memory (BiLSTM). Pertama CNN digunakan untuk mengekstrak fitur dari data masukan. Selanjutnya, BiLSTM menggunakan data fitur yang diekstrak untuk memprediksi harga penutupan saham pada hari berikutnya.

2.3.1. Convolutional Neural Network (CNN)

CNN terdiri dari lima komponen utama: lapisan *input*, lapisan konvolusi, lapisan *fully connected*, dan lapisan *output* [17]. Lapisan konvolusi merupakan fokus dari seluruh struktur model, yang terutama digunakan untuk mengekstraksi fitur dan melakukan pengurangan dimensi pada fitur-fitur tersebut. Dengan kemampuan yang luar biasa dalam mengekstraksi dan mengenali fitur, CNN telah berhasil diterapkan dalam tugas-tugas klasifikasi gambar dan data deret waktu [18]. Studi ini berfokus pada ekstraksi fitur lokal nonlinear yang efektif untuk data saham menggunakan lapisan konvolusi dan ekstraksi fitur untuk menghasilkan informasi fitur yang lebih penting.

2.3.2. Long-Short Term Memory (LSTM)

LSTM pertama kali diusulkan oleh Hochreiter dan Schmidhuber pada tahun 1997 sebagai varian dari *Recurrent Neural Network* (RNN) yang telah mengalami pengembangan [19]. Dibandingkan dengan RNN tradisional, jaringan saraf LSTM memiliki karakteristik yang cocok untuk memproses dan memprediksi peristiwa penting dengan interval dan keterlambatan yang panjang dalam deret waktu [20]. LSTM meningkatkan struktur lapisan tersembunyi dari RNN dengan memperkenalkan sistem unit pengatur yang terdiri dari *input gate*, *forget gate*, dan *output gate*, yang secara efektif mengatasi *vanishing gradient* dalam pelatihan model. Struktur ini ditunjukkan pada Gambar 2. Diantara unit-unit tersebut, *forget gate* digunakan untuk memutuskan informasi mana yang perlu dihapus dari neuron dalam model, *input gate* digunakan untuk memperbarui status unit, dan *output gate* digunakan untuk mengontrol keluaran ke momen berikutnya dari neuron [21].



Gambar 2. Arsitektur memory cell LSTM

Struktur *memory cell* LSTM ditunjukkan pada Gambar 2. Dalam gambar tersebut, $h_{(t-1)}$ dan h_t adalah keluaran dari *cell state* sebelumnya dan *cell state* saat ini. x_t adalah *input* dari unit saat ini. Sigmoid dan \tanh adalah fungsi aktivasi, dan lingkaran dalam gambar menunjukkan aturan aritmetika antara vektor-vektor. C_t adalah keadaan neuron pada saat t . f_t adalah *forget gate*, yang mengontrol bagaimana *cell state* harus membuang informasi melalui fungsi aktivasi Sigmoid. i_t adalah *input gate* yang menentukan informasi yang perlu diperbarui oleh fungsi Sigmoid, yang kemudian menghasilkan memori baru menggunakan fungsi aktivasi

$\tanh(C_t)$ dan akhirnya mengontrol berapa banyak informasi baru yang ditambahkan ke keadaan neuron. O_t adalah *output gate*, yang menentukan keadaan keluaran neuron dari fungsi Sigmoid, dan akhirnya memproses keadaan neuron menggunakan fungsi aktivasi \tanh untuk memperoleh hasil akhir. Berikut proses perhitungan LSTM [22]:

$$f_t = \sigma [W_f (h_{(t-1)}, x_t) + b_f] \tag{2}$$

$$i_t = \sigma [W_i (x_t, h_{(t-1)}) + b_i] \tag{3}$$

$$C_t = \tanh [W_c (x_t, h_{(t-1)}) + b_c] \tag{4}$$

$$U_t = i_t \otimes C_t + f_t * C_{(t-1)} \tag{5}$$

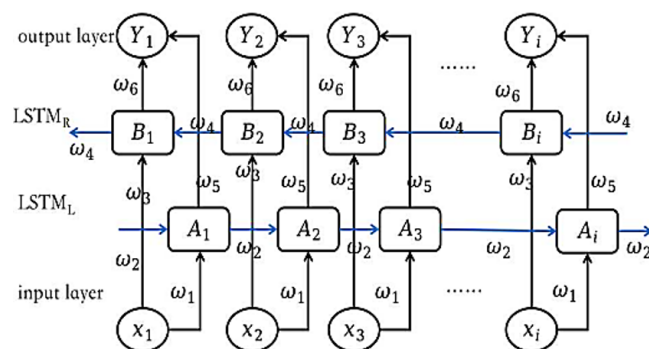
$$O_t = \sigma [W_o (x_t, h_{(t-1)}) + b_o] \tag{6}$$

$$h_t = O_t \otimes \tanh (U_t) \tag{7}$$

dengan W_f adalah bobot untuk *forget gate*, W_i adalah bobot untuk *input gate*, W_o adalah bobot untuk *output gate*. b_f adalah bias untuk *forget gate*, b_i adalah bias untuk *input gate*, b_o adalah bias untuk *output gate*. C_t adalah *memory cell state*, C_{t-1} adalah *memory cell state* di *cell state* sebelumnya, σ adalah fungsi Sigmoid, dan \otimes adalah Hadamard product.

2.3.3. Bidirectional Long Short-Term Memory (BiLSTM)

BiLSTM merupakan peningkatan optimalisasi dari LSTM. LSTM tradisional memprediksi keluaran momen berikutnya berdasarkan informasi deret waktu masa lalu, BiLSTM dapat sepenuhnya memperhitungkan informasi masa lalu dan masa depan dengan menghubungkan lapisan LSTM maju dan lapisan LSTM mundur, yang memfasilitasi *input* informasi urutan maju dan mundur, sehingga membuat model lebih kuat [16]. Oleh karena itu, penelitian ini menggunakan jaringan saraf BiLSTM untuk mempelajari fitur serial dua arah dari informasi fitur yang diekstraksi dari lapisan CNN, sepenuhnya memanfaatkan fitur dependen jangka panjang dari data sampel untuk pembelajaran, dan akhirnya menghasilkan hasil prediksi harga saham melalui lapisan *fully connected*. Struktur BiLSTM ditunjukkan pada Gambar 3.



Gambar 3. Arsitektur BiLSTM [23]

Berikut persamaan setiap bagian BiLSTM:

$$A_i = f_1 (\omega_1 x_i + \omega_2 A_{(i-1)}) \tag{8}$$

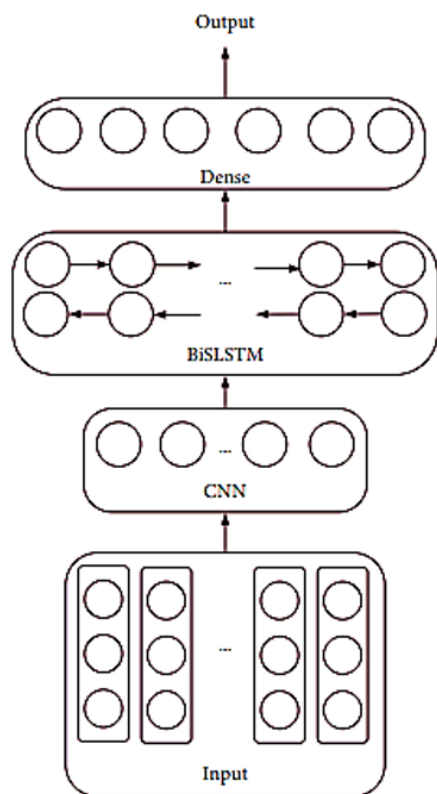
$$B_i = f_2 (\omega_3 x_i + \omega_4 B_{(i+1)}) \tag{9}$$

$$Y_i = f_3 (\omega_5 A_i + \omega_6 B_i) \tag{10}$$

dengan f_i adalah fungsi aktivasi disetiap layer.

2.3.4. Pemodelan CNN-BiLSTM

Seperti yang telah disebutkan sebelumnya, prediksi harga saham (atau aset lainnya) sangat penting sehingga banyak peneliti telah mencoba menggunakan berbagai metode untuk tujuan tersebut. Penelitian ini mengusulkan metode prediksi harga penutupan saham menggunakan model CNN-BiLSTM. Proses metode ini diilustrasikan pada Gambar 4.



Gambar 4. Arsitektur CNN-BiLSTM

- Langkah 1: Data saham yang dikumpulkan dinormalisasi dan dibagi menjadi tingkat pelatihan, validasi dan pengujian.
- Langkah 2: Pertama, lapisan CNN digunakan untuk mengekstraksi fitur internal dari data saham. Layer CNN terdiri dari layer konvolusi 1D.
- Langkah 3: lapisan BiLSTM dilatih pada fitur lokal yang diekstraksi oleh CNN untuk mempelajari pola perubahan dinamis internal. Akhirnya, keluaran dilewatkan melalui *dense layer*. Diagram struktur jaringannya ditunjukkan pada Gambar 4.
- Langkah 4: Hasil prediksi dinormalisasi untuk mendapatkan nilai yang diinginkan.

2.3.5. Evaluasi Model

Evaluasi model CNN-BiLSTM yang dibangun pada penelitian ini menggunakan *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). RMSE merupakan metrik yang digunakan untuk mengevaluasi akurasi prediksi model. RMSE dihitung dengan cara akar menghitung rata-rata dari persebaran antara nilai prediksi dan nilai aktual [13]. Persamaan yang digunakan untuk perhitungan RMSE adalah sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2}, \quad (11)$$

dengan \hat{y}_i adalah nilai prediksi dan y_i adalah nilai aktual, dan n adalah jumlah data.

RMSE menghitung rata-rata dari persebaran antara nilai prediksi dengan nilai aktual, sehingga memberikan indikasi tentang seberapa besar perbedaan antara prediksi dan hasil aktual.

MAPE menghitung rata-rata dari selisih persentase antara nilai prediksi dan nilai aktual. Dalam penggunaannya, MAPE digunakan untuk mengevaluasi performa model regresi linear multivariat, analisis peramalan, dan evaluasi model lainnya [16]. Persamaan yang digunakan untuk perhitungan RMSE adalah sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{y_i} \times 100\%. \quad (12)$$

Nilai MAPE dapat ditafsirkan menggunakan skala yang dikembangkan oleh Lewis. Skala ini mengkategorikan akurasi prediksi dapat dilihat pada Tabel 1.

Tabel 1. Kategori MAPE

Nilai MAPE	Keterangan
$MAPE < 10\%$	Sangat Akurat
$10\% \leq MAPE < 20\%$	Baik
$20\% \leq MAPE < 50\%$	Normal
$MAPE \geq 50\%$	Tidak Akurat

Sumber: [24]

Skala ini membantu dalam menilai seberapa baik model prediksi yang digunakan berdasarkan nilai MAPE yang dihasilkan. Nilai RMSE dan MAPE yang lebih kecil menunjukkan bahwa prediksi model lebih akurat dan lebih dekat dengan nilai aktual.

3. Hasil dan Pembahasan

Data penelitian yang digunakan dalam penelitian berasal dari *yahoo finance*. Gambar 5 menampilkan data yang digunakan dalam penelitian ditampilkan dalam grafik, yaitu data harga saham Bank Syariah Indonesia yang ditunjukkan pada Gambar 5a, data harga saham BTPN Syariah yang ditunjukkan pada Gambar 5b, dan data harga saham Bank Panin Dubai Syariah yang ditunjukkan pada Gambar 5c.

Periode data yang diambil pada penelitian ini dalam rentang 02 Januari 2020 sampai 4 Juli 2024 dengan jumlah data yang digunakan untuk masing – masing saham adalah sebanyak 1087 data. Selanjutnya dilakukan data *preprocessing* yaitu membagi data menjadi data *training*, data *validation* dan data *testing*. Sebanyak 869 data digunakan dalam proses pelatihan model, 108 data digunakan untuk validasi model dan 110 data digunakan untuk evaluasi model. Selanjutnya dilakukan normalisasi data dengan menggunakan *Min-Max Normalization*. Lima data sebelum dan setelah normalisasi disajikan pada Tabel 2.

Tabel 2. Perbandingan data sebelum dan setelah normaliasi data untuk saham BRIS.JK

Sebelum Normalisasi	Sesudah Normalisasi
1740	0.45365895
1705	0.44378658
1695	0.4409659
1680	0.43673489
1670	0.43391421



(a) Bank Syariah Indonesia (BRIS.JK)



(b) Bank BTPN Syariah (BTPS.JK)



(c) Bank Panin Dubai Syariah (PNBS.JK)

Gambar 5. Grafik harga saham

Setelah melakukan normalisasi selanjutnya dilakukan *window_size*. *Window size* mengacu pada jumlah data historis yang digunakan sebagai input untuk model. Tabel 3 merupakan penggunaan *window size* 5. *Window size* lima artinya lima data sebelumnya yang akan digunakan untuk prediksi data.

Pada tahap *modeling* dengan menggunakan CNN-BiLSTM data bank syariah Indonesia yaitu Bank Syariah Indonesia, Bank BPTN Syariah, Bank Panin Dubai Syariah akan dilatih menggunakan *window size* lima, sepuluh, lima belas, dua puluh, dua puluh lima dan tiga puluh. Banyak model yang dihasilkan dalam penelitian ini sebanyak 18 model. Penentuan parameter yang tepat sebelum proses *training* dapat meningkatkan efisiensi dan akurasi model, sedangkan evaluasi kinerja selama *training* dapat memberikan wawasan untuk penyetelan parameter lebih lanjut. Penentuan parameter dalam proses *training* model machine learning sangat krusial untuk mencapai performa optimal. Selanjutnya, pengaturan parameter CNN-BiLSTM pada penelitian ini disajikan pada Tabel 4

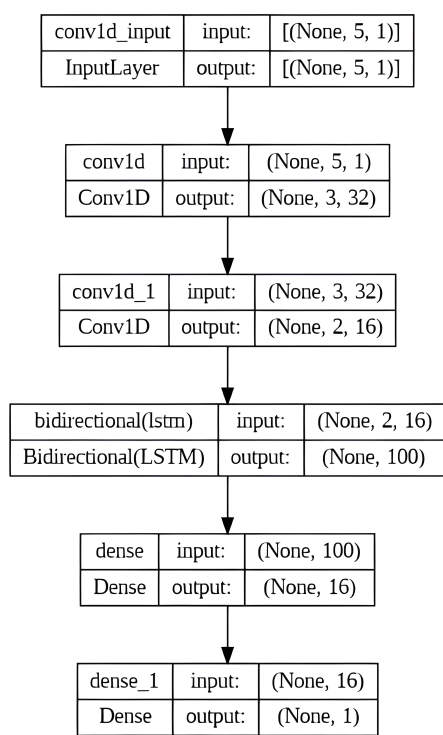
Berdasarkan pengaturan parameter CNN-BiLSTM pada Tabel 4, dapat diketahui bahwa model spesifik yang dibangun sebagai berikut: dataset pelatihan input merupakan vektor tiga dimensi ($none, 5, 1$) dimana 5 adalah ukuran *window size* dan 1 adalah fitur dari dimensi *input*. Pertama, data masuk ke lapisan kovolusi satu dimensi untuk mengekstrak fitur lebih lanjut dan mendapatkan vektor *output* ($none, 3, 32$), di mana 3 merupakan, 32 adalah ukuran kernel dan *filter* lapisan konvolusi. Kemudian, masuk ke lapisan konvolusi satu dimensi kedua dan mendapatkan vektor *output* ($none, 1, 16$). Selanjutnya, vektor tersebut masuk ke lapisan BiLSTM pertama untuk pelatihan dan menghasilkan vektor *output* ($none, 1, 128$). Dilanjutkan ke lapisan BiLSTM kedua menghasilkan vektor *output* ($none, 1, 64$). Proses *training* selanjutnya masuk ke lapisan *dense* dan menghasilkan vektor *output* ($none, 16$). Setelah proses *training* selesai masuk ke lapisan *fully connected* untuk mendapatkan nilai *output*, 16 adalah jumlah lapisan tersembunyi di BiLSTM. Arsitektur spesifik CNN BiLSTM dapat dilihat pada Gambar 6.

Tabel 3. Tampilan window size 5 untuk saham BRIS.JK

x ₁	x ₂	x ₃	x ₄	x ₅	y
0.05419532	0.05309491	0.0519945	0.05034388	0.04869326	0.05034388
0.05309491	0.0519945	0.05034388	0.04869326	0.05034388	0.04924347
0.0519945	0.05034388	0.04869326	0.05034388	0.04924347	0.05089408
0.43955556	0.43955556	0.43250387	0.43250387	0.43109353	0.42827285
0.43955556	0.43250387	0.43250387	0.43109353	0.42827285	0.42968319

Tabel 4. Parameter setting dari CNN-BiLSTM

Parameter	Value
Filter lapisan konvolusi	32, 16
Ukuran kernel lapisan konvolusi	3
Fungsi aktivasi lapisan konvolusi	Relu
Jumlah hidden layer unit di BiLSTM 1	64,50
Jumlah hidden layer unit di BiLSTM 2	32
Window size	5, 10, 15, 20, 25, 30
Batch size	100, 200
Epochs	37, 71,78, 40, 46, 68, 90, 114, 128, 370, 500, 562, 600
Learning rate	0.001
Optimizer	Adam
Fungsi Loss	MeanSquaredError



Gambar 6. Arsitektur model CNN Bi-LSTM

Pada tahap evaluasi model, hasil pengujian model CNN-BiLSTM untuk data saham Bank Syariah Indonesia (BRIS.JK) dengan parameter terbaik adalah *window size* = 10, layer pertama CNN1D dengan *filter* = 32, *kernel_size*=3, *activation*='relu', layer kedua CNN1D dengan *filter* = 16, *kernel_size*=3, *hidden layer unit* BiLSTM = 50, *optimizer* = Adam, *epoch* = 600, dan *batch size* = 200. Pada [Tabel 5](#), evaluasi model menghasilkan RMSE sebesar 0.0803 dengan MAPE sebesar 2.376%. [Gambar 7](#) menunjukkan bahwa hasil prediksi dan aktual tidak memiliki perbedaan yang jauh. Sehingga dapat disimpulkan bahwa model yang dihasilkan

sangat akurat.

Saham Bank Panin Dubai Syariah (PNBS.JK) pada pengujian model CNN-BiLSTM menghasilkan model terbaik dengan kombinasi parameter *window size* =5, lapisan pertama CNN1D dengan *filter* = 32, *kernel_size*=3, *activation*='relu', lapisan kedua CNN1D dengan *filter* = 16, *kernel_size*=3, *hidden layer unit* BiLSTM 1= 64, *hidden layer unit* BiLSTM 1 = 32, *optimizer* = Adam, *epoch* = 37, dan *batch size* = 100. Dari [Tabel 6](#) diketahui evaluasi model menghasilkan RMSE sebesar 0.0758 dengan MAPE sebesar 0.629%, selain itu dapat dilihat dari [Gambar 8](#) yang menunjukkan bahwa hasil prediksi dan aktual memiliki pola yang sama. Dari evaluasi dan penggambaran grafik dapat dikatakan bahwa model yang dihasilkan sangat akurat.

Sementara untuk saham Bank BTPN Syariah (BTPS.JK) model CNN-BiLSTM menghasilkan model terbaik dengan kombinasi parameter *window size* =5, lapisan pertama CNN1D dengan *filter* = 32, *kernel_size*=3, *activation*='relu', lapisan kedua CNN1D dengan *filter* = 16, *kernel_size*=3, *hidden layer unit* BiLSTM 1= 64, *hidden layer unit* BiLSTM 1 = 32, *optimizer* = Adam, *epoch* = 37, dan *batch size* = 100. [Tabel 7](#) menunjukkan evaluasi model menghasilkan RMSE sebesar 0.0490 dengan MAPE sebesar 2.092%. Hal ini juga sejalan dengan [Gambar 9](#) yang menunjukkan hasil prediksi dan aktual memiliki selisih yang sangat kecil sehingga diketahui model yang dihasilkan sangat akurat.

Dalam penelitian ini terdapat 6 *widow size* yaitu 5, 10, 15, 20, 25, dan 30. *Window size* memiliki pengaruh signifikan terhadap kinerja model dalam prediksi. *Window size* yang berbeda dapat mempengaruhi akurasi dari hasil prediksi. Penelitian menunjukkan bahwa ukuran *window size* yang tepat dapat meningkatkan akurasi model secara signifikan. Hal ini sejalan dengan hasil penelitian yang ditunjukkan pada [\[25\]](#). Untuk *window size* terbaik dalam penelitian ini adalah lima dan hal ini ditunjukkan oleh model yang dihasilkan untuk saham BTPN Syariah dan Bank Panin Dubai Syariah. Dari [Gambar 7, 8, dan 9](#), dapat dilihat bahwa harga saham hasil prediksi dan aktualnya tidak berbeda jauh dan ini dapat dilihat dari nilai RMSE dan MAPE yang dihasilkan. Ber-

Tabel 5. Hasil dan parameter dari model untuk saham BRIS.JK


Saham	Parameter				RMSE	MAPE
	Window Size	epoch	batch	Hidden layer unit		
BRIS.JK	5	562	200	50	0.0804	2.381%
	10	600	200	50	0.0803	2.376%
	15	500	200	50	0.0885	2.476%
	20	600	200	50	0.0817	2.339%
	25	370	200	50	0.0875	2.526%
	30	500	200	50	0.0889	2.539%

Tabel 6. Hasil dan parameter dari model untuk saham PNBS.JK

Saham	Parameter				RMSE	MAPE
	window size	epoch	batch	Hidden layer unit		
PNBS.JK	5	37	100	96	0.0758	0.629%
	10	71	100	96	0.0842	0.755%
	15	78	100	96	0.0779	0.631%
	20	40	100	96	0.0809	0.699%
	25	46	100	96	0.0832	0.718%
	30	55	100	96	0.0859	0.734%

Tabel 7. Hasil dan parameter dari model untuk saham BTPS.JK

Saham	Parameter				RMSE	MAPE
	Window Size	epoch	batch	Hidden layer unit		
BTPS.JK	5	114	100	96	0.0490	2.092%
	10	192	100	96	0.0509	2.169%
	15	114	100	96	0.0562	2.437%
	20	90	100	96	0.0561	2.468%
	25	128	100	96	0.0490	2.226%
	30	68	100	96	0.0586	2.815%

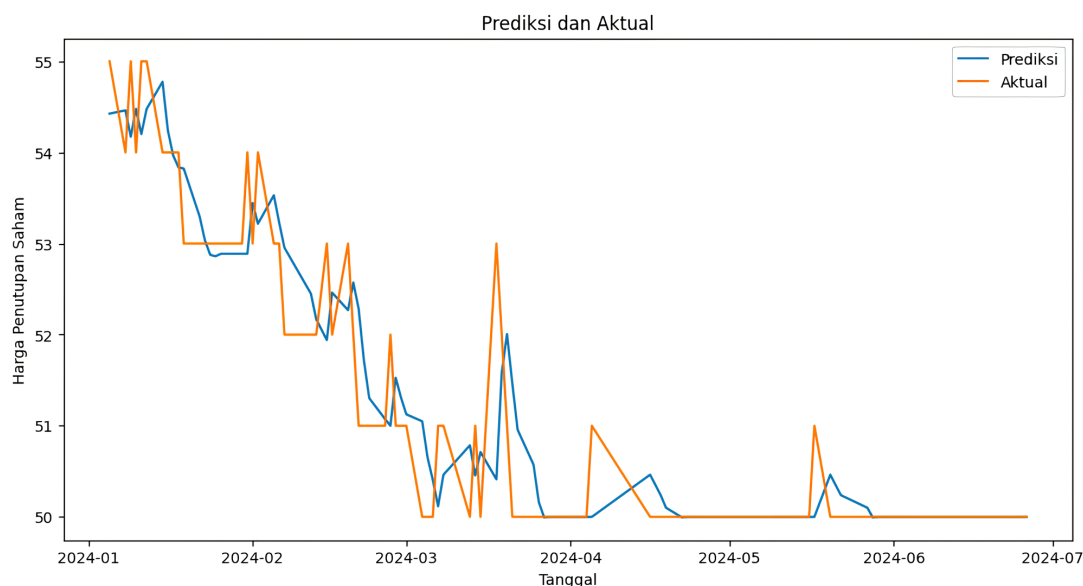


Gambar 7. Perbandingan harga hasil prediksi dan aktual saham (BRIS.JK)

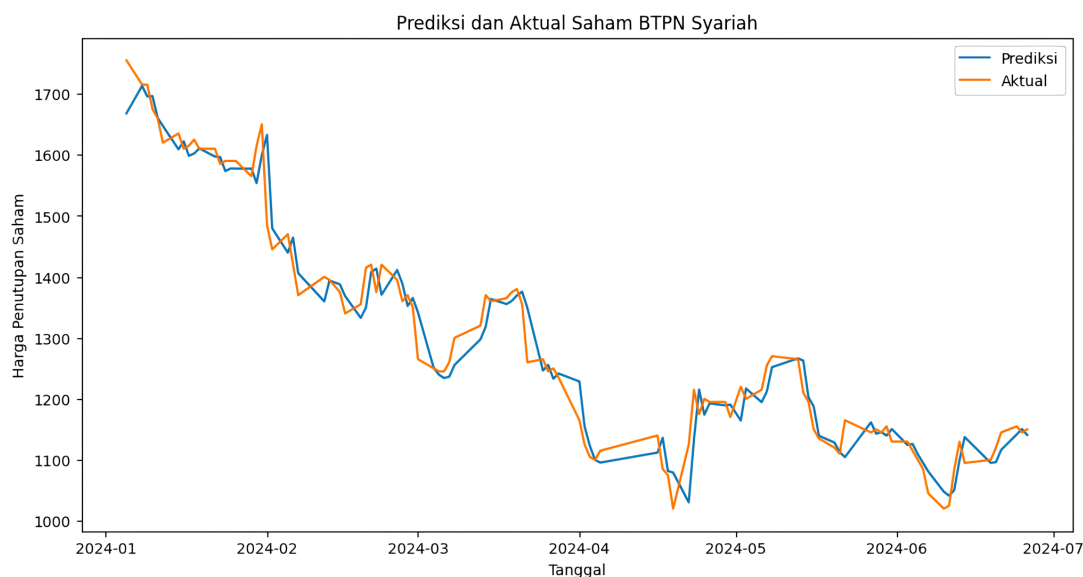
dasarkan Tabel 5, 6, dan 7, diketahui bahwa untuk model terbaik dihasilkan oleh CNN-BiLSTM pada saham Saham Bank Panin Dubai Syariah (PNBS.JK) dengan RMSE sebesar 0.0758 dengan MAPE sebesar 0.629%. Hal ini mendukung temuan pada penelitian sebelumnya yang menunjukkan bahwa CNN dan BiLSTM cocok untuk digunakan dalam prediksi data yang berupa rutin waktu.

Berdasarkan karakteristik deret waktu data harga saham,

penelitian ini mengusulkan metode CNN-BiLSTM untuk memprediksi harga penutupan saham pada hari berikutnya. Metode ini menggunakan harga penutupan saham sebagai *input* dan memanfaatkan sepenuhnya karakteristik urutan waktu dari data saham. CNN digunakan untuk mengekstraksi fitur dari data *input*. BiLSTM digunakan untuk mempelajari dan memprediksi data fitur yang diekstraksi dan melakukan prediksi. Hal ini dilakukan



Gambar 8. Perbandingan harga hasil prediksi dan aktual saham Bank Panin Dubai Syariah (PNBS.JK)



Gambar 9. Perbandingan harga hasil prediksi dan aktual saham Bank BTPN Syariah (BTPS.JK)

untuk meningkatkan akurasi prediksi metode tersebut. Penelitian ini menghasilkan performa model yang sangat baik. Evaluasi secara keseluruhan untuk setiap model CNN-BiLSTM menghasilkan RMSE di bawah 0.09 dan MAPE di bawah 3% yang berarti model prediksi yang dihasilkan memiliki performa sangat akurat karena nilai MAPE di bawah 10%.

4. Kesimpulan

Model CNN-BiLSTM yang dikembangkan menunjukkan kinerja yang lebih baik dalam memprediksi harga saham dibandingkan dengan model CNN, LSTM ataupun BiLSTM saja. Kombinasi CNN untuk ekstraksi fitur dan BiLSTM untuk menangkap dependensi jangka panjang dalam data saham terbukti efektif dalam menangani volatilitas dan kompleksitas data saham. Hasil evaluasi menunjukkan bahwa model ini memiliki akurasi prediksi yang lebih tinggi dan error yang lebih rendah. Hasil yang diperoleh untuk prediksi harga saham Bank Syariah Indonesia (BRIS.JK)

memperoleh menghasilkan RMSE sebesar 0.0803 dengan MAPE sebesar 2.376%, Bank Panin Dubai Syariah (PNBS.JK) menghasilkan RMSE sebesar 0.0758 dengan MAPE sebesar 0.629%, dan Bank BTPN Syariah (BTPS.JK) menghasilkan RMSE sebesar 0.0490 dengan MAPE sebesar 2.092%. Dari hasil penelitian dapat dilihat bahwa nilai MAPE yang diperoleh untuk setiap mode yang dihasilkan kurang dari 10% yang berarti bahwa model yang dihasilkan memiliki akurasi yang sangat baik. Penelitian selanjutnya dapat menggunakan model ini di lebih banyak bidang yang datanya berupa urutan waktu seperti prediksi cuaca, prediksi harga emas, prediksi penggunaan energi, dan lain sebagainya.

Kontribusi Penulis. Penulis telah membaca dan menyetujui versi naskrip yang diterbitkan.

Ucapan Terima Kasih. Penulis menyampaikan terima kasih kepada editor dan reviewer atas pembacaan yang cermat, kritik yang mendalam, dan

rekomendasi yang praktis untuk meningkatkan kualitas tulisan ini.

Pembiayaan. Penelitian ini tidak menerima pembiayaan eksternal.

Konflik Kepentingan. Para penulis menyatakan tidak ada konflik kepentingan yang terkait dengan artikel ini.

Referensi

- [1] Z. Hu, W. Liu, J. Bian, X. Liu, and T.Y. Liu, "Listening to Chaotic Whispers," in *Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining*, Feb. 2018, pp. 261–269, doi: [10.1145/3159652.3159690](https://doi.org/10.1145/3159652.3159690).
- [2] K. Adam, A. Marcet, and J. P. Nicolini, "Stock Market Volatility and Learning," *Journal of Finance*, vol. 71, no. 1, pp. 33–82, 2016, doi: [10.1111/jofi.12364](https://doi.org/10.1111/jofi.12364).
- [3] W. Nuij, V. Milea, F. Hogenboom, F. Frasinca, and U. Kaymak, "An Automated Framework for Incorporating News into Stock Trading Strategies," *IEEE Transactions on Knowledge and Data Engineering*, vol. 26, no. 4, pp. 823–835, Apr. 2014, doi: [10.1109/tkde.2013.133](https://doi.org/10.1109/tkde.2013.133).
- [4] M. Qiu and Y. Song, "Predicting the Direction of Stock Market Index Movement Using an Optimized Artificial Neural Network Model," *Plos One*, vol. 11, no. 5, p. e0155133, May 2016, doi: [10.1371/journal.pone.0155133](https://doi.org/10.1371/journal.pone.0155133).
- [5] R. Vanaga and B. Sloka, "Financial and capital market commission financing: Aspects and challenges," *Journal of Logistics, Informatics and Service Science*, vol. 7, no. 1, pp. 17–30, 2020, doi: [10.33168/LISS.2020.0102](https://doi.org/10.33168/LISS.2020.0102).
- [6] M. M. Kumbure, C. Lohrmann, P. Luukka, and J. Porras, "Machine learning techniques and data for stock market forecasting: A literature review," *Expert Systems with Applications*, vol. 197, p. 116659, Jul. 2022, doi: [10.1016/j.eswa.2022.116659](https://doi.org/10.1016/j.eswa.2022.116659).
- [7] T. Prasetyo et al., "Perbandingan Kinerja Metode Arima, Multi-Layer Perceptron, Dan Random Forest Dalam Peramalan Harga Logam Mulia Berjangka Yang Mengandung Pencilan," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 2, pp. 265–274, 2024, doi: [10.25126/jtiik.2024117392](https://doi.org/10.25126/jtiik.2024117392).
- [8] T. Phuoc, P. T. K. Anh, P. H. Tam, and C. V. Nguyen, "Applying machine learning algorithms to predict the stock price trend in the stock market – The case of Vietnam," *Humanities and Social Sciences Communications*, vol. 11, no. 1, Mar. 2024, doi: [10.1057/s41599-024-02807-x](https://doi.org/10.1057/s41599-024-02807-x).
- [9] A. Nilsen, "Perbandingan Model RNN, Model LSTM, dan Model GRU dalam Memprediksi Harga Saham-Saham LQ45," *Jurnal Statistika Dan Aplikasinya*, vol. 6, no. 1, pp. 137–147, Jun. 2022, doi: [10.21009/jsa.06113](https://doi.org/10.21009/jsa.06113).
- [10] M. A. D. Suyudi, E. C. Djamil, and A. Maspupah, "Prediksi Harga Saham menggunakan Metode Recurrent Neural Network," in *Seminar Nasional Aplikasi Teknologi Informasi (SNATI)*, Aug. 2019, pp. 34–38. [Online]. Available: <https://journal.uin.ac.id/Snati/article/view/13398>.
- [11] B. H. Mahendra, L. Chaerani, and G. Gumay, "Analisis Perbandingan Prediksi Harga Saham menggunakan Algoritma Artificial Neural Network dan Linear Regression," *Jurnal Ilmiah Komputasi*, vol. 22, no. 2, pp. 303–312, 2023, doi: [10.32409/jikstik.22.2.3357](https://doi.org/10.32409/jikstik.22.2.3357).
- [12] A. S. B. Karno, "Prediksi Data Time Series Saham Bank BRI Dengan Mesin Belajar LSTM (Long ShortTerm Memory)," *Journal of Informatic and Information Security*, vol. 1, no. 1, pp. 1–8, 2020, doi: [10.31599/jiforty.v1i1.133](https://doi.org/10.31599/jiforty.v1i1.133).
- [13] N. Afrianto, D. H. Fudholi, and S. Rani, "Prediksi Harga Saham Menggunakan BiLSTM dengan Faktor Sentimen Publik," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 1, pp. 41–46, 2022, doi: [10.29207/resti.v6i1.3676](https://doi.org/10.29207/resti.v6i1.3676).
- [14] D. I. Puteri, "Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah," *Euler : Jurnal Ilmiah Matematika, Sains dan Teknologi*, vol. 11, no. 1, pp. 35–43, May 2023, doi: [10.34312/euler.v11i1.19791](https://doi.org/10.34312/euler.v11i1.19791).
- [15] S. Chen and H. He, "Stock Prediction Using Convolutional Neural Network," *IOP Conference Series. Materials Science and Engineering*, vol. 435, p. 012026, Nov. 2018, doi: [10.1088/1757-899x/435/1/012026](https://doi.org/10.1088/1757-899x/435/1/012026).
- [16] M. Yang and J. Wang, "Adaptability of Financial Time Series Prediction Based on BiLSTM," in *Procedia Computer Science*, vol. 199, Jan. 2022, pp. 18–25, doi: [10.1016/j.procs.2022.01.003](https://doi.org/10.1016/j.procs.2022.01.003).
- [17] J. Luo and X. Zhang, "Convolutional neural network based on attention mechanism and Bi-LSTM for bearing remaining life prediction," *Applied Intelligence*, vol. 52, no. 1, pp. 1076–1091, 2022, doi: [10.1007/s10489-021-02503-2](https://doi.org/10.1007/s10489-021-02503-2).
- [18] S. Selvin, R. Vinayakumar, E. A. Gopalakrishnan, V. K. Menon, and K. P. Soman, "Stock price prediction using LSTM, RNN and CNN-sliding window model," in *2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, Sep. 2017, doi: [10.1109/icacci.2017.8126078](https://doi.org/10.1109/icacci.2017.8126078).
- [19] P. Qori, D. Oktafani, and I. Kharisudin, "Analisis Peramalan dengan Long Short Term Memory pada Data Kasus Covid-19 di Provinsi Jawa Tengah," *Prisma*, vol. 5, pp. 752–758, Feb. 2022.
- [20] Q. Wu, F. Guan, C. Lv, and Y. Huang, "Ultra-short-term multi-step wind power forecasting based on CNN-LSTM," *IET Renewable Power Generation*, vol. 15, no. 5, pp. 1019–1029, 2021, doi: [10.1049/rpg2.12085](https://doi.org/10.1049/rpg2.12085).
- [21] Y. Sun, Q. Sun, and S. Zhu, "Prediction of Shanghai Stock Index Based on Investor Sentiment and CNN-LSTM Model," *Journal of Systems Science and Information*, vol. 10, no. 6, pp. 620–632, 2022, doi: [10.21078/JSSI-2022-620-13](https://doi.org/10.21078/JSSI-2022-620-13).
- [22] W. Lu, J. Li, Y. Li, A. Sun, and J. Wang, "A CNN-LSTM-Based Model to Forecast Stock Prices," *Complexity*, vol. 2020, pp. 1–10, Nov. 2020, doi: [10.1155/2020/6622927](https://doi.org/10.1155/2020/6622927).
- [23] A. Staffini, "A CNN–BiLSTM Architecture for Macroeconomic Time Series Forecasting," in *Engineering Proceedings*, vol. 33, no. 1, Jun. 2023, p. 33, doi: [10.3390/engproc2023039033](https://doi.org/10.3390/engproc2023039033).
- [24] T. Mariyani and I. Rosyida, "Implementasi Metode Double Exponential Smoothing untuk Peramalan Luas Panen Padi di Kabupaten Pati dengan Bantuan Software Minitab 16", *Prisma*, vol. 6, pp. 707–713, Mar. 2023.
- [25] R. E. Wahyuni, "Optimasi Prediksi Inflasi dengan Neural Network Pada Tahap Windowing Adakah Pengaruh Perbedaan Window Size," *Technologia Jurnal Ilmiah*, vol. 12, no. 3, p. 176, Jul. 2021, doi: [10.31602/tji.v12i3.5181](https://doi.org/10.31602/tji.v12i3.5181).