

Peramalan Harga Saham Index Nasdaq Composite dengan Metode *Convolutional Neural Network – Long Short-Term Memory*

Muhammad Dafa Ardiansyah¹, Anggraini Puspita Sari², Andreas Nugroho Sihananto³

1. UPN “Veteran” Jawa Timur, Indonesia | 19081010094@student.upnjatim.ac.id
2. UPN “Veteran” Jawa Timur, Indonesia | anggraini.puspita.if@upnjatim.ac.id
3. UPN “Veteran” Jawa Timur, Indonesia | andreas.nugroho.iarkom@upnjatim.ac.id

Abstrak

Pada era setelah pandemi COVID-19, banyak individu berinvestasi dalam saham sebagai sarana untuk pemulihan finansial. Namun, banyak dari masyarakat Indonesia tidak memahami cara kerja pasar saham dan bagaimana melakukan prediksi harga saham di masa depan. Penelitian ini bertujuan untuk mengembangkan model peramalan harga saham indeks Nasdaq Composite dengan menggunakan metode gabungan *deep learning*, yaitu *Convolutional Neural Network – Long Short-Term Memory* (CNN-LSTM). Uji coba model yang dikembangkan pada penelitian melewati berbagai alur seperti pengambilan data yang diambil dari *Yahoo Finance*, lalu melakukan penyaringan dan pembersihan data sehingga bisa digunakan untuk melatih sebuah model. Dalam pembuatan model terdapat banyak variasi konfigurasi, semua hal tersebut dilakukan akan dapat menghasilkan model yang optimal, dengan model yang optimal maka hasil yang diberikan pun akan menjadi lebih akurat, model akan bisa menangani data set sesuai kasus. Hasil dari uji coba ini menunjukkan bahwa metode CNN-LSTM mampu memberikan prediksi yang akurat dengan tingkat galat yang minimal menggunakan pengukuran evaluasi MAE sebesar 0,0005 dan MSE sebesar 0,0192 dan memakan waktu eksekusi sebesar 69673,15 ms. Algoritma CNN-LSTM terbukti dapat dijadikan sebagai salah satu opsi dalam pertimbangan mengambil keputusan *trading*.

Kata Kunci

Nasdaq Composite, *1D-CNN*, *Bi-LSTM*, *CNN-LSTM*, Peramalan Harga Saham

1. Pendahuluan

Pada masa setelah pandemi, banyak orang yang telah mengalami kebangkrutan secara finansial maupun mental karena telah menghadapi badai pandemi, karena beberapa orang banyak juga yang beralih profesi maupun kehilangan profesi. Berdasarkan hasil penelitian yang dilakukan oleh Kementerian Keuangan, Covid-19 telah menimbulkan ancaman terhadap pendapatan rumah tangga, yang mengakibatkan kesulitan dalam mencukupi kebutuhan dasar masyarakat Indonesia tidak dapat bekerja. Di sisi lain, korporasi juga menghadapi dampak negatif terhadap perekonomian masyarakat Indonesia akibat virus korona. Sebagai hasilnya, sektor-sektor seperti manufaktur, perdagangan, transportasi, serta industri akomodasi seperti restoran dan perhotelan, menjadi sangat rentan (Fauziyanti et al., 2020). Saham adalah bukti kepemilikan modal atau dana dalam suatu perusahaan, terwujud dalam bentuk kertas dengan nilai nominal, nama perusahaan, hak, tanggung jawab pemegang saham, serta persediaan yang bisa dijual (Suryaman and Hindriari, 2021). Jika seseorang memiliki saham dalam sebuah perusahaan, ia juga memiliki hak kepemilikan atas perusahaan tersebut dalam jumlah yang proporsional (Maulana and Kumalasari, 2019). Ada beberapa jenis *trading* populer dalam dunia keuangan, seperti *trading forex*, *trading saham*, *trading binary*, *trading emas*, dan *trading bitcoin* (Pratama et al., 2022).

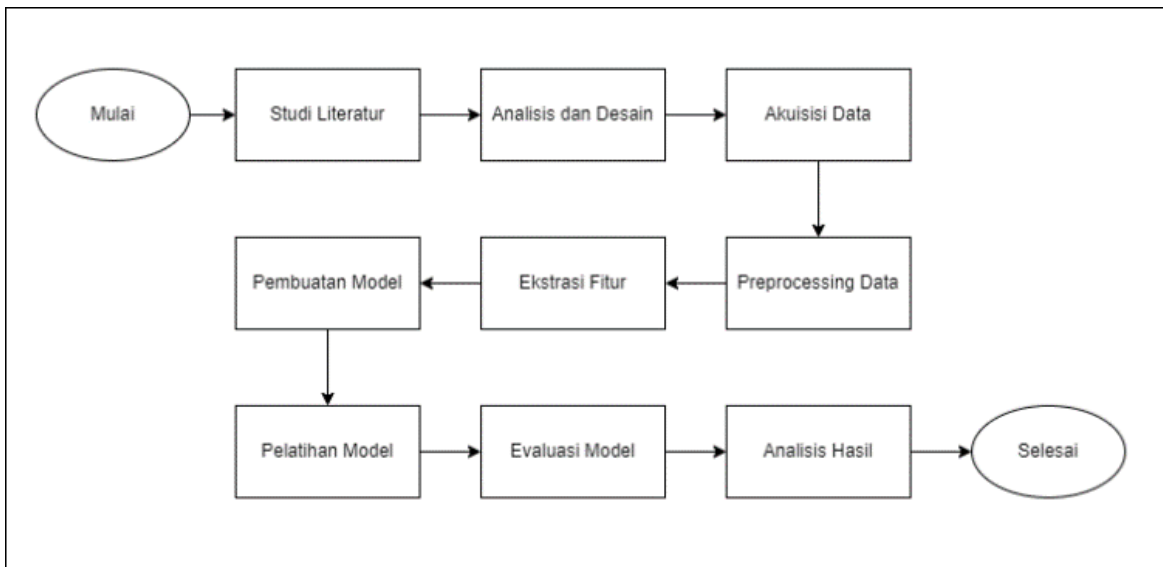
Cara untuk melakukan pengecekan harga saham dunia, dapat dilihat di [investing.com](https://www.investing.com) atau <https://www.investing.com/> yang menjadi salah satu alternatif yang dapat digunakan (Cahyo and Witono, 2021). Peramalan atau *forecasting* melibatkan seni dan ilmu untuk memprediksi peristiwa masa depan dengan memanfaatkan data historis dan berbagai model matematis (Nasution, 2019). Dari data yang tersedia, terlihat bahwa harga saham dapat berubah-ubah setiap harinya dan cenderung tidak stabil. Oleh karena itu, untuk menghindari kerugian, perlu menambahkan opsi untuk menentukan keputusan untuk memprediksi harga pasar, salah satunya dengan menggunakan Jaringan Saraf Tiruan (JST).

JST atau *Neural Network* (NN) merupakan teknologi komputasi yang terinspirasi dari cara kerja jaringan saraf biologi manusia. Seperti otak manusia, JST mampu memproses informasi dan belajar dari suatu objek melalui proses *learning*. Dalam proses belajar ini, JST mampu menyimpan pengetahuan yang didapat dan mengaplikasikannya untuk melakukan prediksi atau pengambilan keputusan pada data baru (Sinaga, 2020). *Long Short-Term Memory* LSTM merupakan solusi yang efektif untuk data urutan waktu dan sering digunakan dalam sistem percakapan dan pembangkitan kalimat (A. Puspita Sari et al., 2020). JST juga dilengkapi dengan satu atau beberapa lapisan terhubung penuh yang bertindak sebagai lapisan standar. CNN memungkinkan proses pembelajaran mesin pada data yang kompleks dan terstruktur seperti gambar dan suara (Fonda, 2020). CNN dan LSTM sudah diterapkan oleh peneliti lain untuk memprediksi deret waktu (Arwansyah et al., 2024) dan mendiagnosis penyakit skizofrenia (Cahyadi et al., 2022). Dari penelitian-penelitian tersebut, CNN-LSTM cocok untuk menyelesaikan masalah di atas karena kombinasi CNN yang efektif dalam mengekstraksi fitur-fitur kompleks dan LSTM yang mampu memahami dependensi temporal dalam data harga saham

memberikan alat yang dapat memproses data yang kompleks dan berubah seiring waktu, membantu para investor dan analis keuangan dalam pengambilan keputusan yang lebih baik dalam menghadapi tantangan ekonomi pasca-pandemi.

2. Metode

Metode penelitian yang dilakukan dalam penelitian ini dapat dilihat dalam Gambar 1. Langkah pertama yang dilakukan adalah melakukan studi literatur, yaitu mencari berbagai sumber yang relevan untuk metode CNN-LSTM dan bagaimana cara menggunakannya pada kasus baru yang akan dipakai pada penelitian ini. Langkah berikutnya adalah melakukan analisis dan desain metode yang digunakan yaitu CNN_LSTM. Selanjutnya dilakukan akuisisi data dari Yahoo Finance. Dalam data yang diakuisisi terdapat beberapa macam informasi seperti harga bukaan (*open price*), harga tertinggi (*high price*), harga terendah (*low price*), harga penutup (*close price*), dan volume. Setelah data kotor diperoleh, maka selanjutnya adalah melakukan pembersihan data atau *data cleaning yang ada* dalam tahap *data preprocessing* dimana dilakukan penyaringan data dengan hanya menggunakan harga bukaan atau *open price* untuk melakukan analisis harga pasar. Langkah berikutnya adalah mengekstraksi fitur dari data yang sudah disaring menggunakan metode 1D-CNN, yang dilanjutkan dengan pembuatan model dengan menambahkan layer LSTM, sehingga disebut CNN-LSTM karena pembuatan model menggabungkan kedua metode tersebut dalam prosesnya. Setelah itu melakukan pelatihan terhadap model dan data set yang sudah bersih, serta melakukan evaluasi model yang sudah direncanakan. Pada langkah terakhir dilakukan analisis hasil dari berbagai macam skema yang telah dilakukan dan mencari kesimpulan serta hasil yang baik dari berbagai macam skema.



Gambar 1. Alur tahapan uji coba

2.1. Studi Literatur, Analisis, dan Desain Model CNN-LSTM

JST adalah alat kecerdasan buatan yang kuat yang mampu memecahkan masalah sulit dengan cara yang menyerupai kecerdasan manusia. JST tidak memerlukan pengetahuan sebelumnya tentang hubungan antara data yang terlibat dalam masalah sebelum menyelesaikannya, tidak seperti pendekatan statistik dan probabilistik lainnya. Proses JST dapat diringkas dalam persamaan sederhana seperti yang disajikan dalam Persamaan (1) (Lawal and Idris, 2020).

$$Y_j = f(\theta_j + \sum_{i=1}^n w_{ji} X_i) \quad \text{Pers. (1)}$$

Keterangan:

- Y_j : elemen dari hasil matriks tunggal pada operasi konvolusi
- f : fungsi aktivasi
- θ_j : nilai bias pada *layer*
- n : jumlah *neuron* pada *hidden layer*
- w_{ji} : bobot dari matriks citra
- X_i : matriks dari kernel

Lalu, untuk melakukan suatu hal yang berurutan, *one Dimensional Convolutional Neural Network* (1D CNN) merupakan yang terbaik saat ini seperti *dilated convolution* seringkali memiliki performa yang setara atau bahkan lebih baik dari arsitektur *Recurrent Neural Network* (RNN). CNN adalah kelas dari jaringan saraf *feed-forward* yang terdiri dari beberapa tahap konvolusi yang melakukan tugas ekstraksi fitur dan tahap luaran tunggal yang menggabungkan fitur-fitur tingkat tinggi yang diekstraksi untuk memprediksi luaran yang diinginkan (Shenfield and Howarth, 2020).

LSTM adalah metode pembelajaran berdasarkan informasi urutan waktu dan memori selektif. Selanjutnya LSTM adalah sebuah tipe dari RNN yang telah dimodifikasi dengan menambahkan sel memori yang dapat menyimpan informasi dalam jangka waktu yang lama (Aprian et al., 2020). Berikut penjelasan dari setiap aspek LSTM beserta persamaannya.

1. *Forget gate* dalam model LSTM bertujuan untuk menilai relevansi informasi yang ada dalam *cell state*. *Output* dari *forget gate* adalah nilai antara 0 dan 1, dimana 1 menandakan informasi masih relevan dan perlu dipertahankan, sedangkan 0 menandakan informasi tidak relevan dan harus diabaikan. Persamaan (2) adalah persamaan yang mendefinisikan nilai *forget gate*.

$$f_t = \sigma (W_f \cdot [s_{t-1}, x_t] + b_f) \quad \text{Pers. (2)}$$

Keterangan:

- f_t : nilai *forget gate*
- σ : fungsi aktivasi *sigmoid*
- W_f : nilai bobot untuk nilai input pada waktu ke t
- $[s_{t-1}, x_t]$: operasi konkatenasi
- b_f : nilai bias pada *forget gate*

2. *Input gate* berfungsi mengatur berapa banyak informasi dari *input* yang akan dimasukkan ke dalam *cell state*. *Output* dari *input gate* adalah vektor skalar antara 0 dan 1 untuk setiap elemen input. Persamaan (3) dan (4) adalah persamaan yang mendefinisikan *input gate*.

$$i_t = \sigma (W_i \cdot [s_{t-1}, x_t] + b_i) \quad \text{Pers. (3)}$$

Keterangan:

- i_t : nilai *input gate*
- σ : fungsi aktivasi *sigmoid*
- W_i : nilai bobot untuk nilai *input* pada waktu ke t
- $[s_{t-1}, x_t]$: operasi konkatenasi
- b_i : nilai bias pada *input gate*

$$\tilde{C}_t = \tanh (W_c \cdot [s_{t-1}, x_t] + b_c) \quad \text{Pers. (4)}$$

Keterangan:

- \tilde{C}_t : nilai kandidat *cell state*
- \tanh : fungsi aktivasi *tan* (*hyperbolic tangent*)
- W_c : nilai bias pada *input gate* pada *cell* ke *cell state*
- $[s_{t-1}, x_t]$: operasi konkatenasi
- b_c : nilai bias pada *cell* ke *cell state*

3. *Cell gate* memungkinkan sel LSTM untuk mengingat dan mengendalikan aliran informasi sebelumnya. *Cell gate* memiliki dua jenis gerbang, yaitu *forget gate* dan *input gate*. *Cell gate* memainkan peran penting dalam mengontrol aliran informasi masuk ke dalam sel dan mempertahankan informasi penting dari waktu ke waktu. Nilai *cell state* diperbarui dengan mempertimbangkan nilai dari *forget gate* dan *input gate*. Persamaan (5) merupakan rumus dari *cell gate*.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad \text{Pers. (5)}$$

Keterangan:

- C_t : nilai *memory cell state*

- f_t : nilai *forget gate*
- C_{t-1} : nilai *memory cell state* pada *cell* sebelumnya
- i_t : nilai *input gate*
- \tilde{C}_t : nilai kandidat *cell state*

4. *Output gate* menentukan *output* berdasarkan *cell state* dan *input*. *Output* ini melalui filter berupa fungsi sigmoid yang menentukan elemen mana yang diaktifkan dalam *output*. Selanjutnya, *cell state* akan melalui fungsi tanh dan hasilnya dikalikan dengan *output* dari gerbang sigmoid. Hasil akhirnya adalah nilai *output* yang dihasilkan oleh model LSTM. Persamaan (6) dan (7) adalah persamaan yang mendefinisikan *input gate*

$$o_t = \sigma (W_o \cdot [s_{t-1}, x_t] + b_o) \quad \text{Pers. (6)}$$

Keterangan:

- o_t : nilai *output gate*
- σ : fungsi aktivasi *sigmoid*
- W_o : bobot untuk nilai input pada waktu ke t
- $[s_{t-1}, x_t]$: operasi konkatenasi
- b_o : nilai *output* dari waktu ke t-1

$$S_t = o_t * \tanh (C_t) \quad \text{Pers. (7)}$$

Keterangan:

- S_t : kandidat nilai *output*
- o_t : nilai *output gate*
- \tanh : fungsi aktivasi tanh (*hyperbolic tangent*)
- C_t : nilai *cell state* yang terbaru

Model *Bi-directional LSTM* biasanya digunakan untuk data yang kompleks seperti bahasa alami, namun pada data urutan getaran pada bantalan *rolling* yang memiliki struktur sederhana tanpa logika kompleks, penggunaan Bi-LSTM tunggal memerlukan sejumlah besar data konteks untuk mengklasifikasikan jenis kerusakan. Ketergantungan pada memori jangka panjang sangat penting dalam hal ini, sementara memori jangka pendek yang hanya memanfaatkan informasi terdekat tidak cukup untuk mengidentifikasi jenis kerusakan. Oleh karena itu, model yang disebut Bi-LTM hanya menggunakan memori jangka panjang dalam pengklasifikasian. Bi-LTM memiliki dua lapisan jaringan memori jangka panjang yang bergerak ke arah maju dan mundur, masing-masing terdiri dari beberapa sel memori jangka panjang. Hubungan antara sel-sel ini dijaga oleh nilai memori jangka panjang yang terus diperbarui, yang mengandung informasi dari sel

sebelumnya dan sel selanjutnya. Dibandingkan dengan model Bi-LSTM standar, kompleksitas model Bi-LTM lebih rendah karena tidak memproses memori jangka pendek (Qiu et al., 2019).

Dengan menggunakan komponen-komponen ini, model LSTM dapat mengatasi masalah jangka panjang dan mempertahankan informasi relevan dalam urutan data, membuatnya cocok untuk berbagai tugas yang melibatkan data sekuensial.

CNN-LSTM adalah sebuah arsitektur JST yang menggabungkan CNN dan LSTM untuk mengolah data dengan dimensi spasial dan temporal. Kombinasi kedua jenis jaringan ini membuat CNN-LSTM cocok digunakan pada berbagai macam aplikasi seperti pengenalan gambar bergerak, prediksi cuaca, dan prediksi harga saham. Dalam struktur CNN-LSTM yang diajukan, lapisan CNN digunakan untuk mengambil fitur dari data *input* waktu, sedangkan lapisan LSTM dimanfaatkan untuk meramalkan nilai penutupan indeks pasar saham pada hari berikutnya (Iman and Wulandari, 2023; Widiputra et al., 2021).

2.2. Akuisisi Data

Data set diambil dari *Yahoo Finance* yang berisi seperti pada Tabel 1 dan terdapat beberapa fitur seperti *date* (tanggal perdagangan), *open* (harga bukaan), *high* (harga tertinggi), *low* (harga terendah), *close* (harga penutup), *adj. close* (harga penutup adjektif), dan *volume*. Dalam penelitian ini hanya akan digunakan *date* dan *open* sebagai fitur untuk menganalisis hasil akhir metode yang dikembangkan dalam penelitian ini.

Tabel 1. Data saham Nasdaq Composite

Date	Open	High	Low	Close	Adj Close	Volume
9/7/2017	6402.93	6413.06	6379.81	6397.87	6397.87	2000910000
...
7/25/2023	14093.24	14201.91	14092.52	14144.56	14144.55	411920000

2.3. Pre Processing Data

Setelah mendapatkan data, langkah selanjutnya adalah melakukan *pre processing data* agar sesuai untuk tahapan berikutnya. Proses *pre processing data* melibatkan berbagai langkah, seperti penyaringan data, pengisian data yang hilang, perubahan bentuk data, normalisasi, pembagian data, dan persiapan data latih. Proses ini dijalankan dengan alur sebagai berikut, Langkah pertama adalah memilih variabel atau kolom yang akan digunakan dari data harga saham. Data harga pembukaan harian dipilih untuk model prediksi. Penyaringan data membantu memfokuskan pelatihan model dan mempermudah proses ekstraksi fitur dengan menggunakan CNN. Kedua, pengisian data yang hilang. Tindakan selanjutnya adalah mengatasi data yang hilang atau *missing value*. Dalam penelitian ini digunakan format *time series*, di mana setiap data harian berpengaruh pada hasil akhir. Namun, data yang tersedia hanya berlangsung sampai hari Jumat, sedangkan *time series* memerlukan data berurutan. Oleh karena itu, langkah ini mengisi data yang hilang dengan rata-rata nilai sebelumnya, untuk menjaga kelengkapan *time series*.

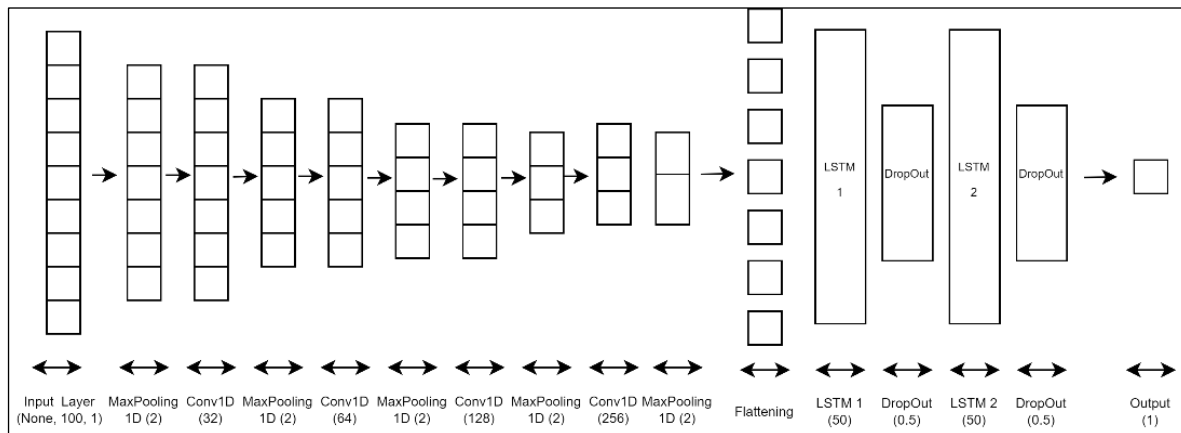
Ketiga, pengubahan bentuk data yang diubah bentuknya agar sesuai dengan kebutuhan model. Ini penting karena data yang dimasukkan ke dalam model harus sesuai dengan *input layer model*. Melalui tahap ini, dimensi data disesuaikan agar model dapat melakukan pelatihan dan prediksi secara akurat. Setelah pengubahan bentuk, normalisasi data dilakukan untuk membawa rentang variabel ke dalam skala yang seragam. Dalam uji coba ini, skala data diatur antara 0 hingga 1. Data set dibagi menjadi dua bagian, yakni data latih dan data uji. Pada uji coba ini, data set dibagi menjadi 70% untuk pelatihan dan 30% untuk pengujian. Data latih disiapkan untuk pelatihan model. Data ini dibagi menjadi dua bagian, yaitu x_{train} dan y_{train} , yang digunakan dalam tahap pelatihan selanjutnya.

2.4. Ekstraksi Fitur

Langkah selanjutnya adalah melakukan ekstraksi fitur dengan CNN. Proses ini melibatkan beberapa langkah, seperti data dimasukkan ke dalam model CNN dengan layer konvolusi dan *pooling* untuk mengeluarkan fitur-fitur penting dari data. Setelah melalui serangkaian layer, hasil dari CNN adalah *feature map* berisi informasi yang diekstrak dari data. *Feature map* kemudian diolah oleh layer LSTM untuk memprediksi data *time series*. LSTM mempertahankan informasi temporal pada data, sesuai untuk prediksi *time series*. *Feature map* diubah menjadi vektor satu dimensi sebelum dimasukkan ke dalam model LSTM. Hasil akhir dari model LSTM adalah prediksi harga saham keesokan harinya. *Flattening* adalah proses mengubah matriks dengan dimensi tinggi menjadi vektor satu dimensi. Setelah ekstraksi fitur menggunakan CNN, *feature map* yang memiliki dimensi tinggi diubah menjadi vektor. Langkah ini memungkinkan output CNN masuk ke dalam *layer fully connected* pada model LSTM tanpa perlu mengubah struktur data dari CNN. Melalui alur ini, data disiapkan dan diproses agar dapat digunakan untuk melatih dan menguji model prediksi harga saham menggunakan kombinasi teknik CNN dan LSTM.

2.5. Pembuatan dan Pelatihan Model CNN-LSTM

Setelah proses ekstraksi fitur, tahap selanjutnya adalah pemodelan dan pelatihan model untuk mencapai prediksi yang akurat. Langkah-langkah pelatihan meliputi seperti melakukan *input feature map* yang dihasilkan dari ekstraksi fitur menggunakan CNN akan menjadi *input awal* untuk proses LSTM. *Learning rate* model diatur sebagai *hyperparameter* untuk mengendalikan perubahan bobot pada setiap iterasi pelatihan. Nilai *learning rate* yang tepat sangat penting untuk menghindari *overfitting* atau *underfitting*. Beberapa nilai *learning rate* diuji, pada penelitian ini akan menggunakan 0,001. Layer LSTM disesuaikan dengan jumlah unit dan lapisan yang akan digunakan. Beberapa percobaan dilakukan dengan variasi unit dan jumlah lapisan untuk menemukan konfigurasi yang optimal. Model dilatih dengan berbagai konfigurasi yang telah ditentukan sebelumnya. Penggunaan *optimizer*, *batch size*, dan jumlah *epoch* ditentukan, serta dilakukan *tuning learning rate* untuk mencapai hasil yang optimal. Arsitektur Model CNN-LSTM yang dibuat dalam penelitian ini dapat dilihat dalam Gambar 2.



Gambar 2. Gambar arsitektur model CNN-LSTM

2.6. Evaluasi Model CNN-LSTM

Tahap terakhir yaitu melakukan proses evaluasi model melalui beberapa tahap minor seperti, data testing dibuat dan diproses serupa dengan data latih. Data dibagi menjadi x_{test} dan y_{test} untuk pengujian. Data tes diubah bentuknya menjadi *array* tiga dimensi, sesuai format yang diterima oleh model CNN-LSTM. Model tersebut digunakan untuk memprediksi data uji. Prediksi dibandingkan dengan nilai target yang sebenarnya. Data prediksi yang masih dalam skala 0 hingga 1 dikembalikan ke skala semula menggunakan fungsi *inverse_transform*. Metode MSE dan MAE digunakan untuk mengukur perbedaan rata-rata antara nilai prediksi dan nilai aktual. Hasil prediksi dan nilai aktual ditampilkan dalam bentuk grafik untuk analisis visual. Melalui serangkaian langkah ini, model LSTM dievaluasi dan hasil prediksi dievaluasi dengan menggunakan berbagai metrik.

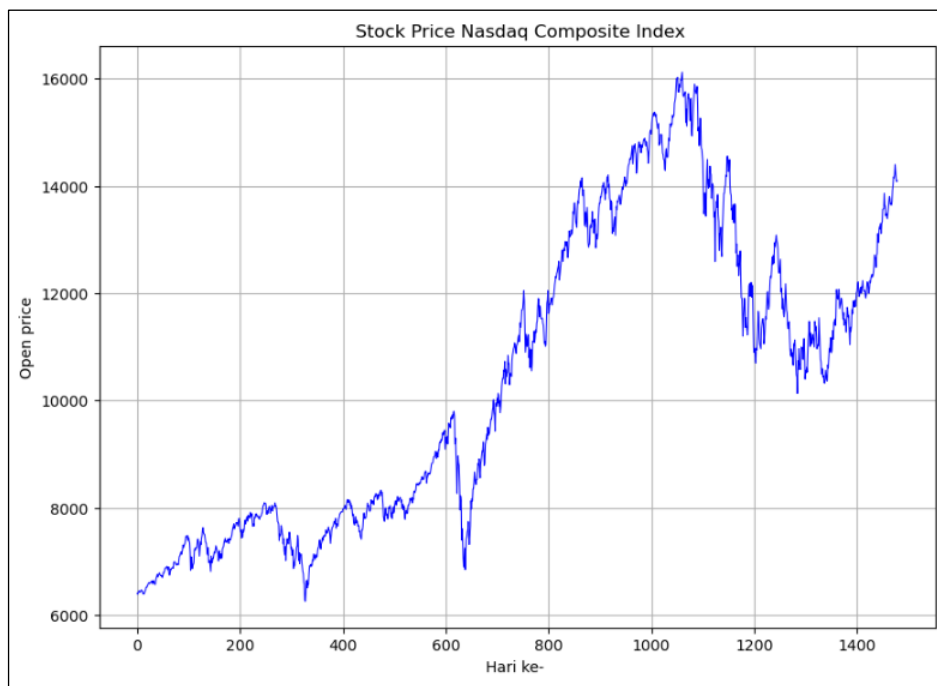
3. Hasil dan Pembahasan

Langkah pertama yang dilakukan untuk melakukan pengujian data tentu saja membersihkan data set Index Nasdaq Composite dan melakukan *feature selection*. Data set dari pengujian data yang telah dibersihkan bentuknya akan seperti Tabel 2. Langkah berikutnya adalah mengubah setiap tanggal histori perdagangan per hari menjadi *timestamp* yang mewakili pengurutan dari 7 September 2017 hingga 25 Juli 2023 yang mematok harga bukaan saham sebagai fitur untuk analisisnya.

Tabel 2. Data index Nasdaq Comsposite setelah *filtering feature*

<i>Timestamp</i>	<i>Open Price</i>
0	6402.93
...	...
1478	14093.24

Dari Tabel 2 dapat dilakukan visualisasi menjadi gambar grafik harga saham Index Nasdaq Composite yang akan dilakukan analisisnya seperti Gambar 3. Gambar 3 merupakan data lengkap sebelum dilakukan pemecahan data latih dan data tes, yang nantinya akan dilakukan *splitting data set* dengan perbandingan 7:3. Data latih dimulai dari rentang 7 September 2017 hingga 13 Oktober 2021, sedangkan data tes dimulai dari 14 Oktober 2021 hingga 25 Juli 2023. Dapat dilihat bahwa pada Gambar 2, menunjukkan *x-axis* adalah *time stamp* atau hari ke- dari setiap harga perdagangan harian sedangkan *y-axis* merupakan harga dari perdagangan saham pada hari saat itu dari harga bukaan.



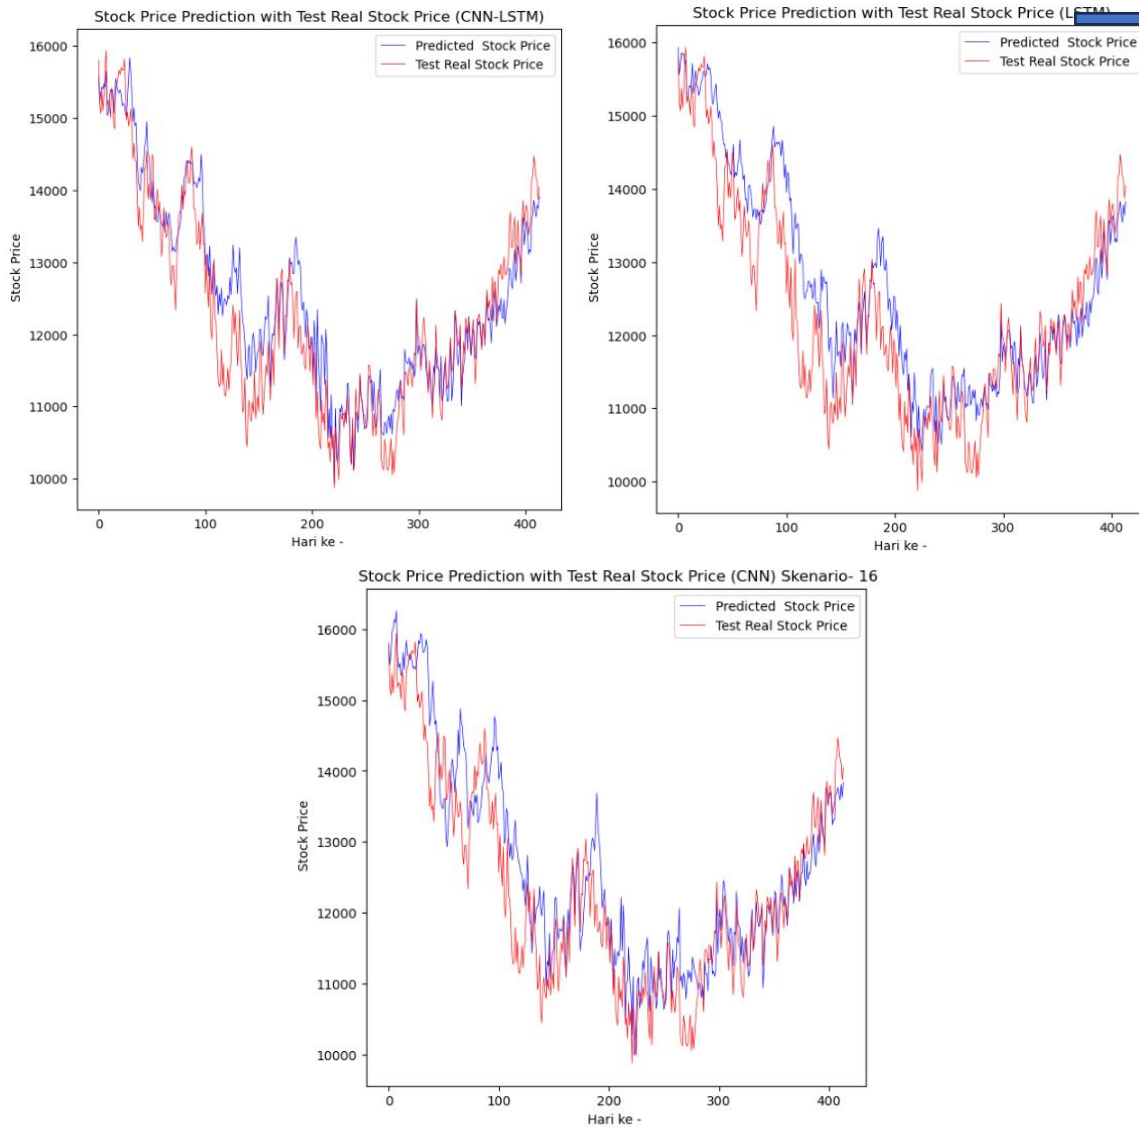
Gambar 3. Gambar Index Nasdaq Composite Index

Konfigurasi skema akan melakukan pengujian dengan cara melakukan *tuning* pada *hyperparameter* seperti *learning rate*, *epoch*, *hidden layer*, *neuron*, dan *metrics error* (MAE dan MSE). Tabel 3 menunjukkan percobaan *tuning hyperparameter* dari Model CNN-LSTM, LSTM, dan CNN yang dijalankan pada piranti yang sama. Dapat diketahui jika MSE dan MAE semakin kecil nilainya, maka model tersebut lebih optimal untuk menangani data kasus tersebut. Jika dilihat dengan cermat maka dapat dilihat bahwa konfigurasi dari *tuning hyperparameter* percobaan ini memiliki nilai MSE dan MAE yang rendah yaitu 0,0005 dan 0,0192.

Gambar 4 menunjukkan perbandingan grafik hasil harga prediksi dan aktual dengan menggunakan 3 metode yang berbeda. Tabel 3 telah menunjukkan bahwa CNN-LSTM pada pengujian memperlihatkan hasil yang optimal. Grafik CNN-LSTM memiliki tingkat kemiripan antara grafik harga prediksi dan grafik harga aktual dari pada grafik LSTM dan grafik CNN.

Tabel 3. Performance analysis comparison

Metode	LR	Layer		Metric Error		Runtime (ms)
		Hidden Layer	Node	MSE	MAE	
CNN-LSTM	0.001	4	(16,32,64,128)	0.0005	0.0192	69673.15
LSTM		4	(16, 32, 64, 128)	0.0012	0.0238	702503.92
CNN		4	(8, 8, 16, 32)	0.0008	0.0212	18527.60



Gambar 4. Grafik hasil perbandingan harga prediksi dan aktual setiap metode

4. Kesimpulan

Dari hasil penelitian dapat ditunjukkan bahwa tujuan penelitian telah tercapai dan memenuhi ekspektasi. Konfigurasi dari melakukan *tuning hyperparameter* pada model CNN-LSTM ternyata sangat berpengaruh terhadap hasil yang optimal yaitu terhadap proses pelatihan dan melakukan prediksi harga saham. Metode gabungan CNN-LSTM juga memiliki nilai galat yang lebih kecil dari pada metode yang berdiri sendiri seperti LSTM dan CNN. Metode CNN-LSTM yang dikembangkan dalam penelitian ini memiliki model CNN-LSTM tingkat hasil yang optimal dengan nilai MSE sebesar 0,0005 dan nilai MAE sebesar 0,00192 yang memiliki nilai galat yang rendah yang secara tidak langsung berarti memiliki akurasi yang tinggi serta memiliki waktu komputasi yang lebih cepat dari LSTM saja walaupun di bawah waktu eksekusi model CNN sebesar 69673.15 ms. Dengan adanya penelitian ini, investor dapat membuat keputusan yang lebih tepat dan informasi saat berinvestasi di pasar saham.

Daftar Rujukan

- Aprian, B.A., Azhar, Y., Nastiti, V.R.S., 2020. Prediksi Pendapatan Kargo Menggunakan Arsitektur Long Short Term Memory. JKT 6, 148–157. <https://doi.org/10.35143/jkt.v6i2.3621>
- Arwansyah, A., Suryani, S., Sy, H.S.H., Ahyuna, A., Usman, U., Alam, S., 2024. Model Prediksi Deret Waktu Menggunakan Deep Convolutional LSTM. SISITI : Seminar Ilmiah Sistem Informasi dan Teknologi Informasi 13, 21–25.
- Cahyadi, G.E.H., Sukemi, S., Rini, D.P., 2022. Peningkatan Akurasi Prediksi Cnn-Lstm Dan Cnn-Gru Untuk Mendiagnosa Skizofrenia Melalui Sinyal Eeg. JSI 14. <https://doi.org/10.18495/jsi.v14i2.19071>
- Cahyo, I.D., Witono, B., 2021. Pengaruh Harga Emas Dunia, DOW JONES Industrial Average dan Inflasi Terhadap Indeks Harga Saham Gabungan (Studi Pada Saham dalam Indeks IDX30 di Bursa Efek Indonesia Periode 2018-2020). Jurnal British 2, 67–81. <https://doi.org/10.51170/jb.v2i1.197>
- Fauziyanti, W., Sundari, P., Sarbullah, 2020. Analisa Perekonomian Indonesia Triwulan III Akibat Covid 19. Prosiding Seminar Nasional ITB AAS Indonesia Tahun 2020 3.
- Fonda, H., 2020. Klasifikasi Batik Riau dengan Menggunakan Convolutional Neural Networks (CNN). jik 9, 7–10. <https://doi.org/10.33060/JIK/2020/Vol9.Iss1.144>
- Iman, F.N., Wulandari, D., 2023. Prediksi Harga Saham Menggunakan Metode Long Short Term Memory. LOGIC : Jurnal Ilmu Komputer dan Pendidikan 1, 601–616. <https://journal.mediapublikasi.id/index.php/logic/article/view/1855>
- Lawal, A.I., Idris, M.A., 2020. An artificial neural network-based mathematical model for the prediction of blast-induced ground vibrations. International Journal of Environmental Studies 77, 318–334. <https://doi.org/10.1080/00207233.2019.1662186>
- Maulana, R., Kumalasari, D., 2019. Analisis dan Perbandingan Algoritma Data Mining dalam Prediksi Harga Saham GGRM. Jurnal Informatika Kaputama (JIK) 3. <https://doi.org/10.59697/jik.v3i1.393>
- Nasution, A., 2019. Metode Weighted Moving Average dalam M-Forecasting. JURTEKSI 5, 119–124. <https://doi.org/10.33330/jurteksi.v5i2.355>

- Pratama, E.G., Purbasari, I.Y., Syaifullah, W.J., 2022. Prediksi Harga Saham Menggunakan Metode Long Short Term Memory Saat Kondisi Pandemi. *Jurnal Informatika dan Sistem Informasi (JIFOSI)* 3. <https://doi.org/10.33005/jifosi.v3i2.471>
- Qiu, D., Liu, Z., Zhou, Y., Shi, J., 2019. Modified Bi-Directional LSTM Neural Networks for Rolling Bearing Fault Diagnosis, in: *ICC 2019 - 2019 IEEE International Conference on Communications (ICC)*. Presented at the ICC 2019 - 2019 IEEE International Conference on Communications (ICC), pp. 1–6. <https://doi.org/10.1109/ICC.2019.8761383>
- Shenfield, A., Howarth, M., 2020. A Novel Deep Learning Model for the Detection and Identification of Rolling Element-Bearing Faults. *Sensors* 20, 5112. <https://doi.org/10.3390/s20185112>
- Sinaga, D., 2020. Jaringan Saraf Tiruan Infeksi Mata Dengan Menggunakan Metode Berarsitektur Multi Layer Perceptron. *Informasi dan Teknologi Ilmiah (INTI)* 7, 189–192. <https://stmik-budidarma.ac.id/ejurnal/index.php/inti/article/view/2385>
- Suryaman, A.H., Hindriari, R., 2021. Pengaruh Earning Per Share (EPS) dan Price Earning Ratio (PER) terhadap Harga Saham pada PT Bumi Serpong Damai TBK Periode 2011 – 2020. *Jur. Neraca.Peradaban.* 1, 199–204. <https://doi.org/10.55182/jnp.v1i3.58>
- Widiputra, H., Adele Mailangkay, Elliana Gautama, 2021. Prediksi Indeks BEI dengan Ensemble Convolutional Neural Network dan Long Short-Term Memory. *RESTI* 5, 456–465. <https://doi.org/10.29207/resti.v5i3.3111>