AITI: Jurnal Teknologi Informasi, Volume 23 No. 2 Juni 2026, 231-244
ISSN 1693-8348 E-ISSN 2615-7128
DOI: 10.24246/aiti.v23i2.231-244

JURNAL TEKNOLOGI INFORMASI

Pengembangan model prediksi saham perbankan Indonesia dengan optimasi algoritma *Long Short-Term Memory* (LSTM)

Didik Nugroho, Eka Ardhianto
Magister Teknologi Informasi, Fakultas Teknologi Informasi dan Industri
Universitas Stikubank
Jl. Trilomba Juang No. 1, Semarang, Jawa Tengah, Indonesia
Email: *didiknugr@gmail.com

Riwayat Artikel

Diterima:	Direvisi:	Disetujui:
04-07-2025	20-07-2025	21-07-2025

Abstract

Banking stocks have attracted public attention because they are often perceived as relatively stable and capable of reflecting the current economic conditions. However, in reality, banking stocks are quite volatile for various reasons. Investors need an accurate stock prediction model to make investment decisions and reduce risk. This study proposes a stock prediction model based on the Long Short-Term Memory (LSTM) deep learning algorithm. The dataset consists of ten years of historical stock market data from banking companies listed on the Indonesia Stock Exchange (IDX), covering the period from 2014 to 2023. LSTM was chosen because it is known to be effective at predicting time-series data and can capture long-term dependencies and patterns. The results of this model were optimized using the Adam optimizer and hyperparameter tuning. These findings suggest that the proposed approach can serve as a reliable tool for stock price forecasting and support more informed investment strategies in the banking sector.

Keywords: *stock prediction, banking stocks, algorithm optimization, Long Short-Term Memory*

Abstrak

Saham perbankan telah menarik perhatian publik karena sering dianggap relatif stabil dan mampu mencerminkan kondisi perekonomian saat ini. Namun, pada kenyataannya, saham perbankan menunjukkan volatilitas yang cukup tinggi karena berbagai faktor, baik internal maupun eksternal, seperti suku bunga dan kondisi ekonomi. Oleh karenanya, diperlukan model prediksi saham yang akurat untuk membantu investor dalam mengambil keputusan investasi dan mengurangi risiko kerugian. Penelitian ini mengusulkan sebuah model prediksi saham menggunakan algoritma *deep learning Long Short-Term Memory* (LSTM). *Dataset* yang digunakan adalah data saham selama 10 tahun dari Bank Indonesia yang terdaftar di Bursa Efek Jakarta, dari tahun 2014 sampai 2023. LSTM dipilih karena algoritma ini dikenal cukup efektif dalam memprediksi data deret waktu dan memiliki kemampuan untuk menangkap hubungan jangka panjang dan pola dalam data. Hasil dari model ini dioptimalkan *optimizer Adam* dan teknik *hyperparameter tuning*. Hasil penelitian menunjukkan bahwa Model LSTM

yang dioptimasi memiliki nilai *Mean Absolute Error* 3,42%, yang menunjukkan tingkat akurasi prediksi yang tinggi dan dapat diandalkan.

Kata kunci: prediksi saham, saham perbankan, optimasi algoritma, *Long Short-Term Memory*

Pendahuluan

Model investasi saham saat ini sudah berkembang pesat. Walau demikian, semua menyadari bahwa investasi ini penuh dengan risiko. Ketidakpastian pasar seringkali menyebabkan pergerakan harga saham berubah tajam dalam waktu yang relatif singkat. Penyebabnya bisa faktor, seperti perubahan kondisi ekonomi, laporan keuangan perusahaan, dan sentimen pasar [1]. Volatilitas ini dapat menyebabkan nilai investasi naik atau turun secara drastis. Belum lagi risiko sistematik dan non sistematik. Risiko sistematik adalah risiko yang mempengaruhi seluruh pasar atau segmen pasar tertentu dan tidak dapat dihindari melalui diversifikasi [2]. Contoh risiko sistematik termasuk resesi ekonomi, perubahan kebijakan pemerintah, atau krisis keuangan global. Risiko ini berdampak pada semua saham, tidak peduli seberapa baik kinerja perusahaan individual. Risiko non-sistematik adalah risiko yang spesifik terhadap perusahaan atau industri tertentu. Faktor seperti kinerja perusahaan, manajemen yang buruk, skandal, atau perubahan dalam industri dapat berdampak negatif pada harga saham tertentu. Meskipun risiko ini dapat dikurangi melalui diversifikasi namun tidak dapat sepenuhnya dihilangkan [3].

Salah satu saham yang dikenal fluktuatif adalah saham bidang perbankan [4]. Peristiwa ekonomi dan politik global, seperti krisis keuangan atau perubahan kebijakan perdagangan, dapat memengaruhi stabilitas pasar keuangan dan harga saham perbankan. Demikian juga dengan inflasi, suku bunga, dan kebijakan moneter lainnya dapat memengaruhi kinerja harga saham perbankan. Suku bunga yang ditetapkan oleh bank sentral sangat mempengaruhi keuntungan bank dari kredit dan simpanan. Perubahan suku bunga dapat menyebabkan volatilitas harga saham perbankan. Di samping itu, pergerakan harga saham bank nasional dengan kapitalisasi besar sangat menarik dan menjadi perhatian publik. Banyak publik beranggapan bahwa pergerakan harga saham perbankan cenderung stabil, tetapi pada kenyataannya tidak selalu demikian karena banyak faktor yang mempengaruhi pergerakan tersebut. Pergerakan harga saham perbankan juga memiliki pengaruh besar terhadap Indeks Harga Saham Global (IHSG) dan ekonomi nasional. Dengan demikian pergerakan harga saham bank nasional dengan kapitalisasi lima besar mencerminkan kondisi perekonomian terkini.

Dengan berbagai latar belakang tersebut, diperlukan alat bantu yang baik agar investor dapat memperkirakan hasil yang terbaik dalam investasinya dalam bidang saham. Salah satunya adalah dengan mengembangkan model prediksi pergerakan saham. Informasi hasil prediksi saham dapat mendukung investor dalam mengambil keputusan investasi yang lebih rasional. Ketepatan prediksi memungkinkan investor

menentukan momen terbaik untuk melakukan transaksi jual beli saham guna mengoptimalkan profit dan mengurangi potensi kerugian.

Berbagai penelitian tentang prediksi harga saham sebenarnya sudah dilakukan oleh beberapa peneliti. Zapar, dkk. melakukan penelitian tentang penerapan model regresi linear untuk prediksi harga saham pada Bursa Efek Indonesia [5]. Riset tersebut bertujuan untuk melakukan peningkatan akurasi dalam memprediksi harga saham serta mengevaluasi stabilitas performa model menggunakan teknik validasi silang *K-Fold Cross-Validation*. Pendekatan ini dipilih untuk memastikan bahwa model tidak hanya bekerja dengan baik pada data *training*, tetapi juga mampu memberikan hasil prediksi yang konsisten pada data yang belum pernah dilihat sebelumnya. Dari proses evaluasi yang dilakukan, diperoleh nilai *Root Mean Square Error* (RMSE) sebesar 0,032, yang mengindikasikan bahwa tingkat kesalahan prediksi model tergolong sangat rendah, serta menunjukkan konsistensi yang baik dalam performa keseluruhan.

Sebagai pembanding, penelitian oleh Lubis dan Mulyati menerapkan metode regresi linear berganda dalam memprediksi harga saham Pfizer (FPE) [6]. Studi tersebut menghasilkan nilai RMSE sebesar 0,074, yang juga mencerminkan tingkat galat yang rendah. Meskipun metode regresi linear sering menunjukkan performa yang cukup baik dari segi *error* kuantitatif, metode ini memiliki keterbatasan mendasar. Salah satu kelemahannya terletak pada asumsi linearitas hubungan antara variabel independen dan dependen. Ketika pola hubungan antar variabel bersifat non-linear, model regresi linear cenderung gagal menangkap kompleksitas hubungan tersebut, sehingga mengurangi akurasi hasil prediksi. Oleh karena itu, dalam konteks data saham yang sering bersifat fluktuatif dan kompleks, pendekatan non-linear seperti *Long Short-Term Memory* (LSTM) menjadi alternatif yang lebih fleksibel dan adaptif terhadap dinamika data historis.

Salah satu pendekatan lain yang cukup populer untuk memodelkan dan meramalkan deret waktu, khususnya data harga saham, adalah *Moving Average* (MA). Teknik ini menghitung *average* dari sekumpulan data dalam jendela waktu tertentu, dan kemudian menggeser jendela tersebut secara bertahap sehingga pola tren dan fluktuasi jangka pendek dapat dihaluskan. Dengan cara itu, *trader* maupun analis dapat mengenali kecenderungan naik-turun harga tanpa terlalu terganggu oleh "*noise*" harian. Studi yang dilakukan oleh Cahyani, dkk. berfokus pada penerapan metode MA untuk memprediksi pergerakan saham-saham yang tergabung di indeks LQ45 Bursa Efek Indonesia [7]. Dalam penelitian tersebut dievaluasi kemampuan MA dalam menebak arah gerak harga apakah naik atau turun dan memverifikasi hasilnya melalui uji non-parametrik *Mann–Whitney*. Uji ini dipilih karena tidak bergantung pada asumsi distribusi normal, sehingga cocok untuk data pasar yang sering kali tidak terdistribusi secara normal. Temuan penelitian menunjukkan tidak terdapat perbedaan signifikan

antara arah yang diprediksi oleh MA dan arah aktual pergerakan harga. Dengan demikian MA berhasil mereplikasi kecenderungan pasar secara memadai; tingkat akurasi yang dicapai mengindikasikan bahwa metode ini efektif sebagai alat bantu pengambilan keputusan, terutama bagi investor yang mencari sinyal sederhana dan mudah diinterpretasikan.

Walaupun dalam penelitian sebelumnya MA cukup bagus untuk melakukan prediksi, namun metode ini memiliki beberapa kelemahan. MA adalah metode sederhana dan sering digunakan untuk meratakan fluktuasi jangka pendek dan mengidentifikasi tren jangka panjang dalam data *time-series*. MA memiliki kelemahan dalam menangkap tren kompleks atau perubahan struktural dalam data. Jika tren data berubah secara signifikan, maka MA mungkin tidak dapat memberikan sinyal yang tepat waktu, karena hanya berfokus pada data masa lalu dan tidak memperhitungkan perubahan mendadak atau pola yang lebih rumit. MA juga cenderung tidak efektif dalam menangkap pola musiman atau siklus dalam data, terutama jika pola tersebut terjadi di luar jendela waktu yang digunakan untuk menghitung rata-rata. Penelitian Cahyani [7] juga mencatat bahwa MA memiliki keterbatasan dalam hal keterlambatan sinyal ketika terjadi perubahan tren yang sangat cepat, sehingga penggunaannya kerap dikombinasikan dengan indikator lain atau dilekatkan pada kerangka analisis yang lebih canggih guna meningkatkan keandalan prediksi.

Mengacu pada berbagai penelitian sebelumnya, studi ini mengusulkan pemodelan prediksi saham perbankan nasional dengan pendekatan LSTM. *Dataset* yang dianalisis merupakan data historis saham Bank Nasional Indonesia selama satu dekade terakhir, yaitu dari 2014 sampai 2023. Metode LSTM dipilih karena algoritma ini dikenal cukup efektif dalam memprediksi data deret waktu dan memiliki kemampuan untuk menangkap hubungan jangka panjang dan pola dalam data [8]. LSTM dirancang untuk menyimpan informasi penting dalam periode waktu yang panjang dan secara selektif mengabaikan data yang sudah tidak dibutuhkan. Algoritma ini efektif dalam mengolah, memprediksi, dan mengklasifikasikan data yang bergantung pada urutan waktu [9].

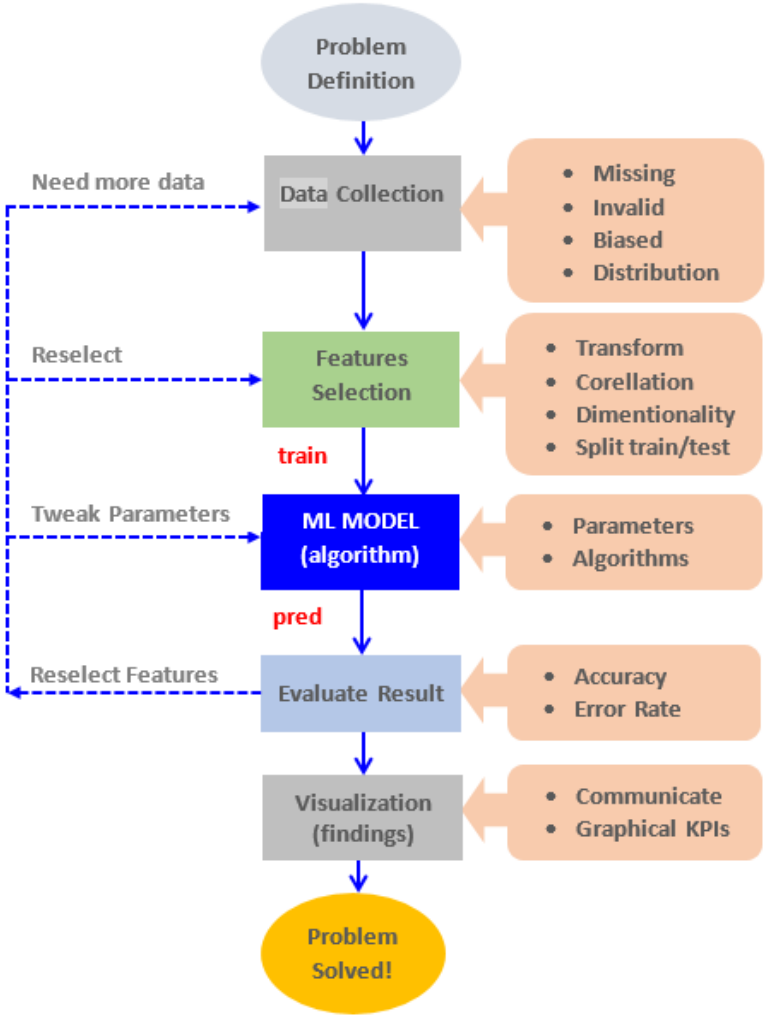
Metode Penelitian

Penelitian pengembangan model prediksi saham perbankan Indonesia dengan optimasi algoritma LSTM ini memiliki rangkaian proses tahapan penelitian yang dapat dilihat seperti pada Gambar 1. Berikut adalah penjelasan dari tahapan-tahapan tersebut.

a. *Dataset Collection*

Tahap ini adalah tahap pengumpulan data yang akan diolah sebagai data *training* dan *testing machine learning*. *Dataset* yang digunakan adalah data pergerakan saham Bank Nasional Indonesia selama 10 tahun, dari tahun 2014-2023. Data tersebut

secara original terdiri dari 10 variabel yaitu Kode Emiten, Tanggal, Nilai *Prev*, *Open*, *High, Low, Close, Volume, Value, dan Frequency.*



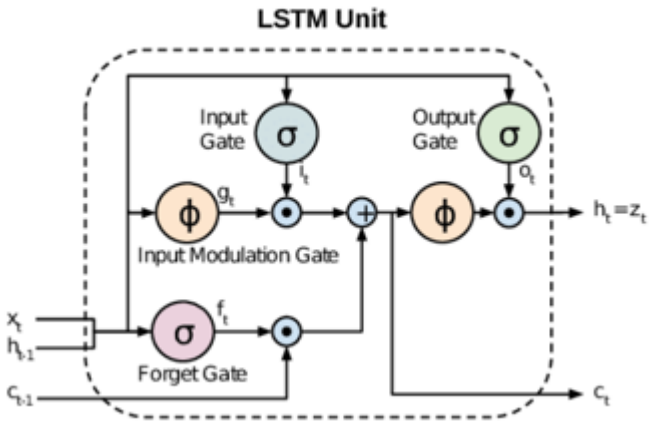
Gambar 1 Tahapan pengembangan model ML/DL

b. *Feature Selection*

Feature selection berfokus pada pemilihan sejumlah fitur atau variabel *input* yang paling relevan dan signifikan terhadap variabel target. Tujuan utama dari tahap ini adalah untuk meningkatkan kinerja model secara keseluruhan, baik dari segi akurasi prediksi maupun efisiensi komputasi. Dengan menghilangkan fitur-fitur yang kurang informatif, redundan, atau tidak relevan, proses *training* model menjadi lebih cepat dan risiko *overfitting* dapat dikurangi. Selain itu, *feature selection* juga membantu menyederhanakan interpretasi model, sehingga hasil analisis dapat lebih mudah dipahami oleh pengguna akhir, termasuk pengambil keputusan non-teknis [10] [11]. Dari 10 variabel, nantinya hanya akan dipilih beberapa variabel saja yang benar-benar akan digunakan untuk *training* dan *testing*. Data tersebut diantaranya adalah *Open, High, Low, Close*, dan *Volume*.

c. *Model Deep Learning*

Model yang akan diusulkan adalah model *deep learning* dengan menggunakan LSTM. Model ini dipilih sebagai salah satu model yang dikenal cukup mumpuni untuk pengolahan data yang bersifat *time series,* di mana kedua model ini memiliki kelebihan dalam menyajikan informasi berdasarkan penyimpanan sebelumnya [9][12].



Gambar 2 Model LSTM

LSTM merupakan salah satu arsitektur jaringan saraf tiruan yang dikembangkan sebagai penyempurnaan dari *Recurrent Neural Network* (RNN). RNN dikenal sebagai model yang andal dalam memproses data berurutan, seperti deret waktu atau urutan kata dalam kalimat. Namun, RNN memiliki kelemahan dalam mempertahankan informasi dari urutan yang jauh di masa lalu karena masalah *vanishing gradient*, yang menyebabkan kontribusi informasi lama semakin kecil saat bobot model diperbarui [13].

Untuk mengatasi keterbatasan tersebut, LSTM diperkenalkan sebagai solusi yang mampu mengelola *long-term dependencies* secara lebih efektif. LSTM dilengkapi dengan struktur internal yang terdiri dari unit memori dan gerbang-gerbang pengontrol (seperti *input, forget,* dan *output gate*) yang memungkinkan model secara selektif mempertahankan informasi yang relevan dalam jangka panjang dan secara otomatis membuang informasi yang tidak lagi dibutuhkan. Hal ini membuat LSTM unggul dalam memahami konteks yang bergantung pada urutan waktu, seperti dalam prediksi harga saham, pengenalan suara, atau penerjemahan bahasa alami. Dengan kemampuan tersebut, LSTM menjadi pilihan utama dalam banyak penelitian dan aplikasi *machine learning* yang memerlukan pemahaman terhadap pola data temporal yang kompleks dan dinamis. Algoritma ini sangat efektif dalam mengolah, memprediksi, dan mengklasifikasikan data deret waktu (*time series*) [14].

d. *Evaluation*

Dalam proses evaluasi performa model prediksi, salah satu metriks yang digunakan adalah *Mean Absolute Error* (MAE). MAE merupakan ukuran kesalahan prediksi yang diperoleh melalui perhitungan rata-rata dari selisih nilai hasil prediksi dengan nilai aktual pada setiap observasi dalam dataset. Metriks ini sering digunakan karena sifatnya yang mudah dipahami dan tidak terlalu sensitif terhadap *outlier*, jika dibandingkan dengan metriks lain seperti *Mean Squared Error* (MSE). MAE memberikan informasi seberapa besar rata-rata deviasi dari prediksi model terhadap nilai yang sebenarnya terjadi, sehingga semakin kecil nilai MAE yang diperoleh, maka semakin baik pula kualitas prediksi model tersebut [15]. Secara matematis, MAE didefinisikan pada Persamaan (1).

$$\text{MAE} = \frac{1}{n}\sum_{i=1}^{n}|y_i - \hat{y}_i| \tag{1}$$

di mana n menyatakan jumlah total observasi, y_i menyatakan nilai aktual (observasi ke- i), $\hat{y}_i$ adalah nilai hasil prediksi yang dilakukan model pada observasi ke- i.

Secara umum, semakin kecil nilai MAE, semakin baik kinerja model. MAE yang lebih kecil berarti model menghasilkan prediksi yang lebih akurat. Ini menunjukkan bahwa model berhasil meminimalkan kesalahan prediksi dan memberikan estimasi yang lebih dekat dengan data aktual. Penggunaan MAE dalam evaluasi model sangat relevan terutama pada masalah regresi, karena metriks ini memberikan interpretasi langsung dalam satuan yang sama dengan variabel target. Selain itu, MAE tidak memperbesar kesalahan seperti MSE, sehingga cocok digunakan apabila tidak ingin penalti tinggi terhadap *error* besar. Dalam konteks prediksi harga saham atau data time series lainnya, MAE membantu untuk menilai seberapa dekat hasil prediksi model terhadap pergerakan nilai sebenarnya secara rata-rata dan konsisten.

Evaluasi model berikutnya menggunakan koefisien determinasi atau yang dikenal sebagai R^2 *Score*. Metriks ini berperan penting dalam mengukur sejauh mana model regresi mampu menjelaskan variasi data target yang diamati. R^2 digunakan untuk menilai performa model, termasuk model berbasis LSTM, dalam memodelkan hubungan antara input dan output. Dalam konteks penerapan pada data deret waktu (*time-series*), R^2 memberikan indikasi seberapa dekat hasil prediksi model terhadap nilai aktual, dibandingkan dengan prediksi sederhana yang hanya menggunakan rata-rata nilai target sebagai referensi (*baseline*). R^2 *Score* dihitung dengan Persamaan (2).

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y})^2} \tag{2}$$

di mana y_i merupakan nilai aktual untuk observasi ke- i, $\hat{y}_i$ merupakan hasil prediksi model pada observasi ke- i, $\bar{y}$ adalah rata-rata nilai aktual, n adalah jumlah observasi.

Dari hasil evaluasi menggunakan R^2 *score*, nilai yang tinggi (mendekati 1) menunjukkan bahwa model LSTM mampu menangkap pola dalam data dengan baik dan memberikan prediksi yang akurat. Sementara itu, R^2 *score* yang rendah (mendekati 0 atau negatif) menunjukkan bahwa model LSTM kurang efektif dalam memprediksi dan tidak mampu menjelaskan variabilitas dalam data.

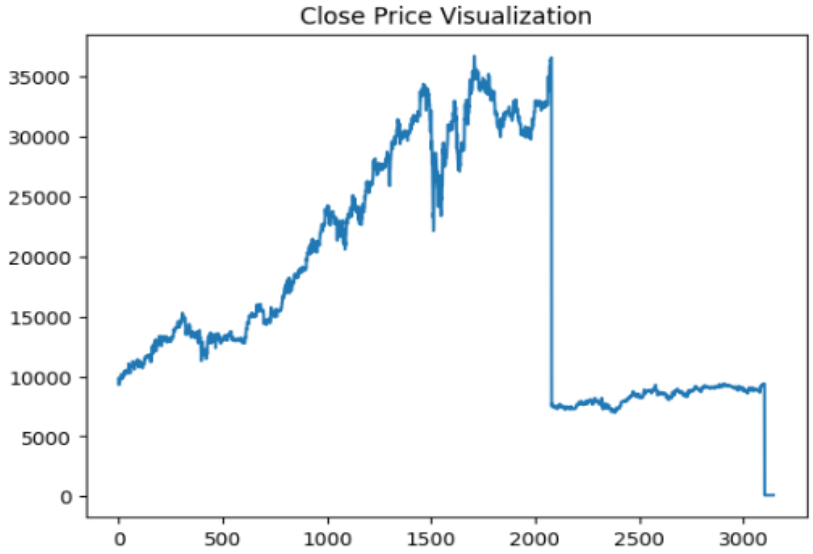
Hasil dan Pembahasan

a. Gambaran *Dataset*

Penelitian pengembangan model prediksi saham perbankan Indonesia dengan optimasi algoritma LSTM ini menggunakan dataset yang berisikan data pergerakan saham Bank Nasional Indonesia selama 10 tahun, dari tahun 2014-2023. Jika divisualisasikan salah satu variabel dalam *dataset* tersebut yaitu nilai *Close* (*close price visualization*) maka dapat dilihat visualisasi grafik seperti yang dapat dilihat pada Gambar 3.

Tabel 1 Gambaran *dataset*

	Date	*Open*	*High*	*Low*	*Close*	*Volume*
0	2014-01-02	9700	9850	9800	9800	6613000
1	2014-01-03	9700	9750	9500	9500	14382500
2	2014-01-06	9500	9500	9350	9350	11638000
3	2014-01-07	9350	9450	9375	9375	7230400
4	2014-01-08	9400	9450	9325	9325	11175500



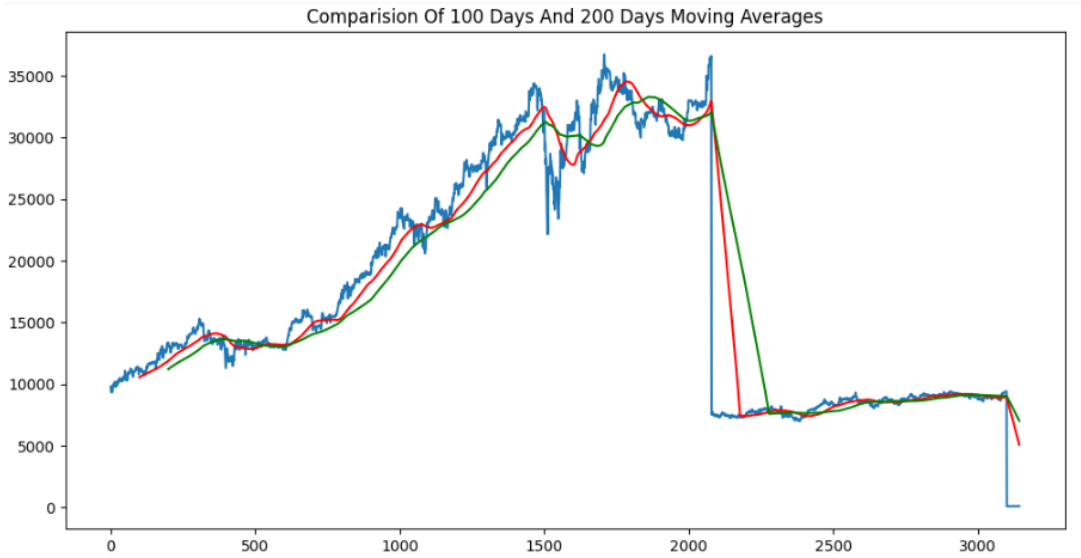
Gambar 3 Visualisasi grafik *Close Price*

Dari Gambar 3 terlihat bahwa pergerakan saham Bank Nasional Indonesia sangat fluktuatif. Terutama pada tahun 2020, terjadi penurunan nilai saham yang sangat

signifikan. Hal itu terjadi karena adanya kasus pandemi COVID-19 yang menyebabkan menurunnya perekonomian global. Pandemi menyebabkan gangguan rantai pasokan global, penurunan perdagangan internasional, dan kebijakan ekonomi yang berubah-ubah dari berbagai negara turut menambah ketidakpastian dan volatilitas di pasar saham. Pandemi COVID-19 menciptakan ketidakpastian besar di pasar global. Investor menjadi khawatir tentang dampak jangka panjang pada ekonomi, termasuk kemungkinan resesi, sehingga banyak yang menjual saham untuk mengurangi risiko.

b. Analisis *Moving Average*

Selanjutnya akan dilakukan analisis *Moving Average* (MA) untuk mengidentifikasi tren pergerakan saham yang sudah terjadi, serta memprediksi pergerakan harga di masa depan. Gambar 4 menunjukkan perbandingan 100 *days* MA dengan 200 *days moving average* pada data pergerakan saham tersebut.



Gambar 4 Perbandingan antara hasil MA menggunakan 100 hari dan 200 hari

MA adalah salah satu metode yang populer dalam peramalan data *time series*, namun memiliki beberapa kelemahan yang cukup signifikan. *Moving average* adalah indikator tertunda karena didasarkan pada data historis. Oleh karena itu, metode ini seringkali terlambat memberikan sinyal perubahan tren, sehingga bisa kurang responsif terhadap perubahan cepat di pasar. Hal itu dapat diamati pada Gambar 4, di mana MA tidak efektif untuk mengidentifikasi perubahan tren yang tiba-tiba atau untuk merespons pergerakan harga yang cepat. Metode ini lebih cocok untuk data yang stasioner, di mana *mean* dan variansinya konstan sepanjang waktu. Untuk data non-stasioner, performa MA bisa menurun, sehingga dapat dikatakan bahwa peramalan *time series* dengan data yang menunjukkan tren atau pola berubah seiring waktu bisa kurang akurat jika hanya menggunakan MA.

c. Penerapan Metode LSTM

Penelitian ini mengusulkan penerapan metode LSTM untuk pengembangan model prediksi pergerakan harga saham. LSTM adalah jenis RNN yang mampu menangkap hubungan jangka panjang dalam data *time series*. LSTM dapat menangani pola *non-linear* dan kompleks dalam data. Jika sebelumnya MA hanya mampu menangkap pola sederhana seperti tren umum, sehingga tidak bisa menangani pola musiman atau siklus yang kompleks, maka LSTM mampu menangkap pola yang kompleks termasuk musiman, siklus, dan hubungan non-linear dalam data *time series*.



Gambar 5 Grafik hasil prediksi dengan *basic* LSTM

Gambar 5 memperlihatkan bahwa model *Basic LSTM* yang diterapkan untuk memprediksi pergerakan harga saham memperoleh MAE sebesar 6,12 % pada set pengujian. MAE sendiri merupakan metriks evaluasi regresi dimana semakin kecil angkanya, semakin akurat pula prediksi yang dihasilkan. Dengan kata lain, MAE sebesar 6,12 % menandakan bahwa prediksi model, secara rata-rata, menyimpang sekitar 6,12 % dari harga saham sebenarnya hasil yang tergolong cukup baik sebagai titik awal.

Meskipun demikian, nilai tersebut masih menyisakan ruang untuk peningkatan performa. Oleh karena itu, studi ini melanjutkan dengan penyetelan atau *hyperparameter tuning* guna mencari kombinasi arsitektur dan parameter pelatihan yang lebih optimal, misalnya jumlah neuron pada *hidden layer*, ukuran *batch*, serta jumlah *epoch.* Selain itu, proses optimasi model diarahkan menggunakan optimizer Adam (*Adaptive Moment Estimation*). Adam dipilih karena menggabungkan keunggulan AdaGrad yang menyesuaikan laju belajar (*learning rate*) berdasarkan frekuensi pembaruan tiap parameter, dengan RMSProp yang menstabilkan pembelajaran pada data deret waktu, sekaligus memperkenalkan estimasi momen pertama dan kedua (*mean* dan *varians gradien*) secara adaptif. Dengan

mengintegrasikan teknik *hyperparameter tuning* dan *optimizer* Adam, diharapkan nilai MAE dapat ditekan lebih rendah lagi, sehingga model LSTM mampu memodelkan pola harga saham secara lebih tepat dan konsisten.



Gambar 6 Grafik hasil prediksi dengan *optimize* LSTM

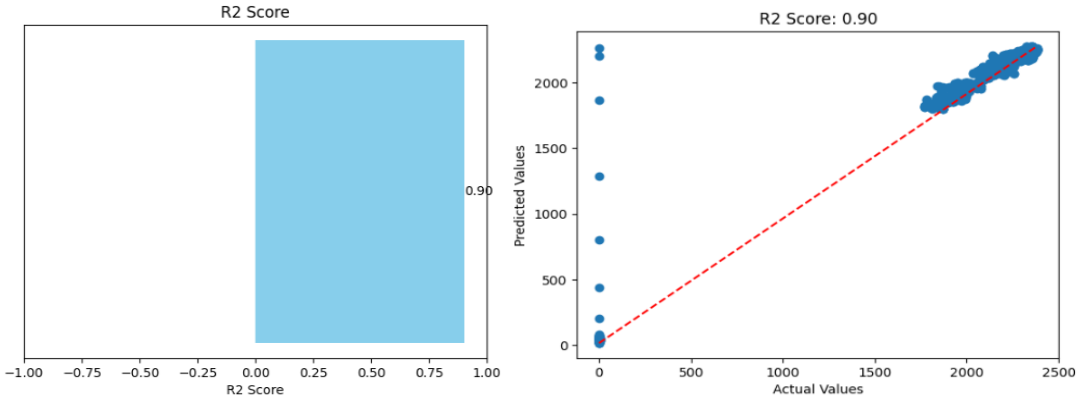
Optimalisasi metode LSTM dengan menggunakan optimizer Adam serta pengaturan *hyperparameter*, menghasilkan nilai *Mean Absolute Error on test set* sebesar 3,42% seperti yang ditunjukkan pada Gambar 6. Pada grafik tersebut dapat dilihat adanya peningkatan kinerja dibanding dengan model yang menggunakan *Basic* LSTM. MAE yang rendah dapat diartikan bahwa prediksi model sangat dekat dengan nilai aktualnya. Dalam kasus ini, nilai 3,42% adalah nilai yang cukup rendah, yang menunjukkan bahwa model memiliki akurasi prediksi yang baik.

d. Evaluasi Model

Gambar 7 menampilkan hasil pengujian model regresi dengan menggunakan koefisien determinasi (R^2) sebagai tolok ukurnya. Metriks ini dirancang untuk mengevaluasi seberapa besar proporsi ragam (variasi) pada variabel dependen yang berhasil dijelaskan oleh variabel - variabel independen dalam model. Skor R^2 berada pada rentang 0 hingga 1, di mana nilai 0 menandakan bahwa model tidak mampu menangkap pola apa pun dan prediksi tidak lebih baik daripada sekadar menebak rata rata, sedangkan nilai 1 mengindikasikan bahwa seluruh variasi pada data target dapat dijelaskan secara sempurna oleh model.

Dalam konteks penelitian ini, terlihat R^2 sebesar 0,90 yang bisa diartikan bahwa 90% fluktuasi harga saham (variabel dependen) berhasil dijelaskan oleh rangkaian fitur input yang digunakan. Dengan kata lain, hanya 10% variasi yang masih disebabkan

oleh faktor-faktor di luar model, seperti kejadian makroekonomi mendadak, sentimen pasar, atau *noise* acak lainnya. Pencapaian R^2 yang tinggi tersebut menandakan bahwa model tidak hanya mampu menyesuaikan diri dengan data pelatihan, tetapi juga memiliki potensi generalisasi yang kuat ketika dihadapkan pada data baru.



Gambar 7 Grafik R^2 *score*

Gambar 7 menunjukkan performa model yang sangat baik dalam memprediksi data yang ada. Meskipun perlu diingat bahwa R^2 *score* yang tinggi tidak selalu menjamin model yang benar-benar optimal atau bebas dari *overfitting*. Penelitian ini menyarankan agar evaluasi model tidak hanya bergantung pada satu metriks saja. Sebagai langkah lanjutan, perlu dilakukan pemeriksaan terhadap berbagai metriks evaluasi tambahan serta penerapan teknik validasi silang (*cross-validation*). Hal ini bertujuan untuk memastikan bahwa model memiliki kemampuan generalisasi yang baik, yaitu mampu mempertahankan performa saat diterapkan pada data baru yang belum pernah dilibatkan dalam proses pelatihan. Dengan pendekatan tersebut, risiko *overfitting* dapat diminimalkan dan keandalan model dalam situasi dunia nyata akan meningkat secara signifikan.

Simpulan

Pergerakan harga saham Bank Nasional dengan kapitalisasi besar sangat menarik dan menjadi perhatian publik dan mencerminkan kondisi perekonomian terkini. Ketika banyak publik yang beranggapan bahwa pergerakan harga saham perbankan cenderung stabil, tetapi pada kenyataannya tidak selalu demikian karena banyak faktor yang memengaruhi pergerakan tersebut. Untuk itu adanya alat bantu untuk memprediksi pergerakan harga saham yang akurat sangat diperlukan investor agar dapat berinvestasi dengan lebih tenang. Penelitian ini merekomendasikan model prediksi saham dengan menggunakan algoritma *deep learning* yaitu LSTM yang terbukti menghasilkan performa yang lebih baik dalam memprediksi dibandingkan dengan metode lain (yang dalam penelitian ini adalah MA). Optimasi model dapat

dilakukan dengan melakukan konfigurasi parameter, dan terbukti dapat meningkatkan performa model tersebut.

Hasil dari penelitian ini diharapkan dapat menjadi kontribusi dalam merumuskan strategi investasi yang lebih tepat dan efisien bagi sektor perbankan di Indonesia. Penelitian selanjutnya merekomendasikan perlunya penambahan fitur untuk variabel prediksi, optimasi model dengan *hybrid* atau *ensemble learning*, serta pentingnya memeriksa metriks lain dan melakukan validasi silang untuk memastikan model tersebut umum (*generalize*) dengan baik pada data yang belum pernah dilihat sebelumnya.

Daftar Pustaka

[1] Z. Hu, Y. Zhao, dan M. Khushi, "A Survey of Forex and Stock Price Prediction Using Deep Learning," *Applied System Innovation*, vol. 4, no. 9, hlm. 1–30, Feb 2021, doi: 10.3390/asi4010009.

[2] M. Nabipour, P. Nayyeri, H. Jabani, A. Mosavi, E. Salwana, dan S. Shahab, "Deep learning for stock market prediction," *Entropy*, vol. 22, no. 8, Agu 2020, doi: 10.3390/E22080840.

[3] N. N. M. Cahyani dan L. P. Mahyuni, "Akurasi Moving Average dalam Prediksi Saham LQ45 di Bursa Efek Indonesia," *E-Jurnal Manajemen Universitas Udayana*, vol. 9, no. 7, hlm. 2769, Jul 2020, doi: 10.24843/ejmunud.2020.v09.i07.p15.

[4] Vinnilya, "Fluktuatif Beberapa Pekan Terakhir, Kapan Saham Bank Big Caps Kembali All Time High," *Berita Satu*, Jakarta, 10 Oktober 2024.

[5] R. Zapar, D. Pratama, dan C. Lukaman Rohmat, "Penerapan Model Regresi Linier untuk Prediksi Harga Saham Bank BCA pada Bursa Efek Indonesia," 2024. [Daring]. Tersedia pada: https://www.yahoofinance.com,

[6] T. A. Lubis, "Prediksi Harga Saham Pfizer Inc (FPE) menggunakan Metode Regresi Linear Berganda," *Jurnal Aplikasi Bisnis dan Komputer*, vol. 4, hlm. 1–8, Feb 2024, doi: https://doi.org/10.33751/jubikom.v4i1.9715.

[7] T. J. Strader, J. J. Rozycki, T. H. ROOT, dan Y.-H. J. Huang, "Machine Learning Stock Market Prediction Studies: Review and Research Directions," *Journal of International Technology and Information Management*, vol. 28, no. 4, hlm. 63–83, Jan 2020, doi: 10.58729/1941-6679.1435.

[8] T. Wahyono, Y. Heryadi, H. Soeparno, dan B. S. Abbas, "Enhanced lstm multivariate time series forecasting for crop pest attack prediction," *ICIC Express Letters*, vol. 14, no. 10, hlm. 943–949, Okt 2020, doi: 10.24507/icicel.14.10.943.

[9] T. Wahyono, Y. Heryadi, H. Soeparno, dan B. S. Abbas, "Crop pest prediction using climate anomaly model based on deep-lstm method," *ICIC Express Letters, Part B: Applications*, vol. 12, no. 4, hlm. 395–401, 2021, doi: 10.24507/icicelb.12.04.395.

[10] N. Pudjihartono, T. Fadason, A. W. Kempa-Liehr, dan J. M. O'Sullivan, "A Review of Feature Selection Methods for Machine Learning-Based Disease Risk Prediction," 2022, *Frontiers Media SA*. doi: 10.3389/fbinf.2022.927312.

[11] D. Pradip dan C. Azad, "A comprehensive survey on feature selection in the various fields of machine learning.," *Applied Intelligence* , vol. 52, no. 4, hlm. 4543–4581, Jul 2022.

[12] Al-Selwi dan Safwan Mahmood, "RNN-LSTM: From applications to modeling techniques and beyond—Systematic review," *Journal of King Saud University-Computer and Information Sciences* , vol. 36, no. 5, Jun 2024.

[13] D. G. Da Silva dan Anderson Alvarenga de Moura Meneses, "Comparing Long Short-Term Memory (LSTM) and bidirectional LSTM deep neural networks for power consumption prediction," *Energy Reports*, vol. 10, hlm. 3315–3334, Nov 2023.

[14] F. Z. H. Zhou dan Changhong Zhang, "Carbon price forecasting based on CEEMDAN and LSTM," *Appl Energy*, vol. 311, no. 118601, Apr 2022.

[15] T. O. Hodson, "Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not," 19 Juli 2022, *Copernicus GmbH*. doi: 10.5194/gmd-15-5481-2022.