



PREDIKSI HARGA SAHAM PADA SEKTOR PERBANKAN MENGGUNAKAN ALGORITMA *LONG SHORT-TERM MEMORY*

I Nyoman Cerdas Janastu*, Dhoriva Urwatul Wutsqa*

Program Studi Statistika, Universitas Negeri Yogyakarta

*e-mail: inyoman.2019@student.uny.ac.id, dhoriva_uw@uny.ac.id

Abstrak. Saham pada sektor perbankan merupakan salah satu pilihan yang banyak diminati oleh para investor. Pergerakan harga saham cepat berubah, sehingga untuk meminimalisir risiko kerugian perlu dilakukan prediksi harga saham. Tujuan penelitian ini adalah (1) mengetahui model *Long Short-Term Memory* (LSTM) dalam memprediksi harga saham pada sektor perbankan dan (2) mengetahui kinerja atau performa dari model *Long Short-Term Memory* (LSTM) dalam melakukan prediksi harga saham pada sektor perbankan. Data yang digunakan merupakan data harian harga penutupan saham pada sektor perbankan dari tanggal 4 Januari 2021 sampai 28 Maret 2023. Tahapan penelitian mencakup (1) input data untuk mengambil data harga penutupan saham; (2) *pre-processing* data untuk memeriksa nilai data yang hilang; (3) pembagian data untuk membagi data menjadi data *training* dan data *testing* dengan rasio 80:20; (4) normalisasi data untuk mengubah data menjadi skala yang sama; (5) rekonstruksi data untuk mengubah data menjadi bentuk *sequence*; (6) pelatihan model yang terdiri dari dua layer LSTM dan satu layer Dense menggunakan data *training*; dan (7) pengujian model pada data *testing* serta evaluasi hasil prediksi menggunakan MAPE dan RMSE. Hasil penelitian menunjukkan kinerja atau performa model yang sangat baik dalam melakukan prediksi harga saham pada sektor perbankan. Nilai MAPE *testing* pada BBKA, BBNI, BBRI, BBTN, dan BMRI masing-masing adalah 1,47%, 1,77%, 1,69%, 3,02%, dan 2,00%.

Kata kunci: *long short-term memory, prediksi, saham*

Abstract. Stocks in the banking sector are one of the choices that many investors are interested in. The movement of stock prices changed very quickly, so to minimize the risk of losing, it is necessary to predict the stock prices. This study aims to (1) know the *Long Short-Term Memory* (LSTM) model in predicting stock prices in the banking sector and (2) know the performance of the *Long Short-Term Memory* (LSTM) model in predicting stock prices in the banking sector. The data used is stock daily close price from 4 January 2023 to 28 March 2023. Research stages consist of (1) data input to retrieve stock closing price data; (2) *pre-processing* data to check for missing value; (3) data splitting to split data into training and testing with 80:20 ratio; (4) data normalization to change data into the same scale; (5) data reconstruction to convert data into sequence form; (6) training model that consist of two layers LSTM and one layer Dense using training data; and (7) testing the model on testing data and evaluating the prediction result using MAPE and RMSE. The study results show that the performance of the model is excellent in predicting stock prices in the banking sector. MAPE testing scores on BBKA, BBNI, BBRI, BBTN, and BMRI are 1,47%, 1,77%, 1,69%, 3,02%, and 2,00% respectively.

Keywords: *long short-term memory, prediction, stock*

PENDAHULUAN

Pasar modal merupakan sarana pertemuan bagi suatu pihak yang memerlukan dana dalam jangka waktu panjang dengan pihak lain yang akan menginvestasikan dana. Perkembangan jumlah investor pasar modal di Indonesia mengalami peningkatan yang signifikan dari tahun 2019 sampai 2022. Berdasarkan data dari Kustodian Sentral Efek Indonesia (2022), jumlah investor pasar modal di Indonesia pada tahun 2020 adalah 3,88 juta orang, mengalami kenaikan sebesar 56,21% dari tahun 2019 yang sebanyak 2,48 juta orang. Jumlah investor pasar modal di Indonesia naik kembali sebesar 92,99% menjadi 7,48 juta orang pada tahun 2021, dan pada bulan Desember 2022, jumlah investor pasar modal di Indonesia mencapai 10,31 juta orang.

Salah satu bentuk dari pasar modal yang banyak investor minati adalah saham. Pasar saham dalam Bursa Efek Indonesia (BEI) diklasifikasikan dalam beberapa sektor, dan sektor keuangan menjadi salah satu sektor yang banyak diminati oleh para investor. Berdasarkan data dari Laporan Statistik Mingguan direktorat statistik dan informasi pasar modal minggu ke-4 2022 (Otoritas Jasa Keuangan, 2022), sektor keuangan pada tahun 2022 memiliki kapitalisasi pasar terbesar jika dibandingkan dengan sektor yang lain, yakni sebesar 35,71% dari Indeks Harga Saham Gabungan (IHSG). Oleh sebab itu, pengaruh sektor keuangan cukup besar dalam kegiatan pasar modal di Indonesia. Perbankan yang merupakan bagian dari sektor keuangan menjadi salah satu pilihan bagi investor. Sektor perbankan menunjukkan kinerja yang bagus dilihat dari segi fundamental maupun likuiditas dan memberikan *return* yang besar setiap tahunnya (Utami & Kartika, 2020).

Dalam sektor perbankan, terdapat beberapa perusahaan yang tergabung dalam indeks saham LQ45. Indeks saham LQ45 merupakan ukuran statistik kinerja atau performa dari 45 saham perusahaan dengan likuiditas yang tinggi, memiliki kapitalisasi pasar yang besar, dan memiliki fundamental perusahaan yang baik. Adapun 5 bank yang tergabung dalam indeks LQ45, yaitu, Bank Central Asia (BBCA), Bank Negara Indonesia (BBNI), Bank Rakyat Indonesia (BBRI), Bank Tabungan Indonesia (BBTN), dan Bank Mandiri (BMRI).

Pergerakan dari harga saham tidak stabil atau konstan, namun bersifat fluktuatif, cepat berubah (*volatile*), dan kompleks sehingga membuatnya sulit untuk diprediksi (Chandola et al., 2022). Terdapat dua faktor yang dapat memengaruhi turun atau naiknya harga saham perusahaan, yaitu faktor eksternal dan internal. Faktor eksternal meliputi kondisi ekonomi makro, kurs mata uang, kebijakan pemerintah, dan manipulasi pasar. Sedangkan faktor internal meliputi fundamental dari perusahaan, kebijakan yang diambil perusahaan, dan kinerja atau performa dari perusahaan (Otoritas Jasa Keuangan, 2019).

Untuk memperoleh keuntungan yang maksimal dengan risiko sekecil mungkin, investor memerlukan pengetahuan mendalam mengenai tren pasar saham maupun dengan membuat alat pengambilan keputusan jual beli saham yang akurat terhadap waktu (Das et al., 2022). Seiring bertambah besarnya data dengan pola yang semakin kompleks dan tidak biasa, maka model klasik seperti *Autoregressive Integrated Moving Average* (ARIMA) menjadi semakin rumit dan menyebabkan berkurangnya kinerja model (Viadinugroho & Rosadi, 2021). Maka dari itu, *deep learning* digunakan untuk mengatasi masalah kompleksitas data tersebut. Perkembangan teknologi diiringi dengan bertambahnya kekuatan komputasi komputer membuat sektor sains data semakin berkembang dan mampu memperoleh informasi yang berguna dari data dengan ukuran besar dan kompleks (Shi, 2022).

Dalam *deep learning*, terdapat arsitektur model bernama *Recurrent Neural Network* (RNN). RNN merupakan bagian dari *neural network* (jaringan syaraf tiruan) untuk memproses *input* data yang berbentuk *sequential* (berurutan) seperti data *time series* (runtun waktu), teks, DNA, dan suara. Namun RNN memiliki beberapa masalah atau kelemahan seperti masalah pada panjang memori (*long term dependency*) dan masalah gradien yang menghilang (*gradient vanishing*) (Ayitey Junior et al., 2022; Wang et al., 2021; Yıldırım et al., 2021), sehingga untuk

mengatasi masalah tersebut dibuat model baru oleh Hochreiter dan Schmidhuber (1997) yang bernama *Long Short-Term Memory* (LSTM).

LSTM unggul dalam mempelajari interaksi jangka panjang, dapat mengumpulkan informasi dari langkah waktu sebelumnya, dan dapat secara selektif memilih kapan untuk melupakan beberapa informasi yang tidak relevan demi beberapa informasi baru yang lebih relevan (Bernico, 2018). Unit komputasi dari jaringan LSTM disebut *memory cell*, *memory block*, atau *cell* yang lebih singkat. Struktur *cell* LSTM yang kompleks digunakan sebagai pengganti dari *neuron* yang sederhana pada RNN (Ekman, 2021). LSTM tidak hanya menggunakan input saat ini dan output sebelumnya (*hidden state*), tetapi juga menggunakan *cell state* yang membawa informasi dari satu *cell* ke *cell* lainnya (Atienza, 2020).

Cell LSTM terdiri dari pembobot (*weights*) dan gerbang (*gate*). Parameter bobot meliputi *input weights* (bobot pada input saat ini) dan *recurrent weights* (bobot pada output langkah waktu sebelumnya) yang berinteraksi dengan input tiap langkah waktu dan output dari langkah waktu sebelumnya. Sedangkan gerbang LSTM yang merupakan pengatur aliran informasi dalam *cell* meliputi *forget gate* (menentukan informasi yang dibuang dari *cell*), *input gate* (menentukan nilai mana dari input untuk diperbarui pada *cell state*), dan *output gate* (menentukan output berdasarkan input dan *cell state*). *Forget gate* dan *input gate* digunakan untuk memperbarui *cell state*, dan *output gate* sebagai pembatas akhir output dari *cell*.

Penerapan LSTM dilakukan oleh Agusta, Ernawati, dan Muliawati (2021) menggunakan LSTM untuk prediksi harga saham pada sektor farmasi dengan berbagai kombinasi parameter untuk memperoleh hasil yang optimal. Arfan dan Lussiana (2020) melakukan prediksi harga saham perusahaan Unilever, Kimia Farma, dan Gudang Garam menggunakan algoritma LSTM. Hansun & Young (2021) melakukan prediksi harga saham sektor finansial pada indeks LQ45 menggunakan RNN-LSTM. Viadinugroho dan Rosadi (2021) menggunakan LSTM untuk memprediksi harga saham Indeks Harga Saham Gabungan (IHSG) selama pandemi Covid-19. Chandola dkk. (2022) menggunakan LSTM untuk memprediksi harga saham Amazon, Google, Ball Corporation, dan Qualcomm.

Julian dan Pribadi (2021) dengan LSTM melakukan peramalan harga saham pada sektor pertambangan yaitu perusahaan Aneka Tambang (ANTM), Timah (TINS), dan Vale Indonesia (INCO). Umaidah (2018) menggunakan *artificial neural network* (ANN) untuk memprediksi harga saham bank BRI. Gumelar, Adha, Rafi, dan Pontoh (2022) melakukan peramalan harga saham empat Bank BUMN di Indonesia dengan menggunakan LSTM. Sofi, Sunge, Riady, dan Kamalia (2021) membandingkan regresi linear, LSTM, dan GRU (*Gated Recurrent Unit*) dalam memprediksi harga saham PT Mulia Boga Raya (KEJU).

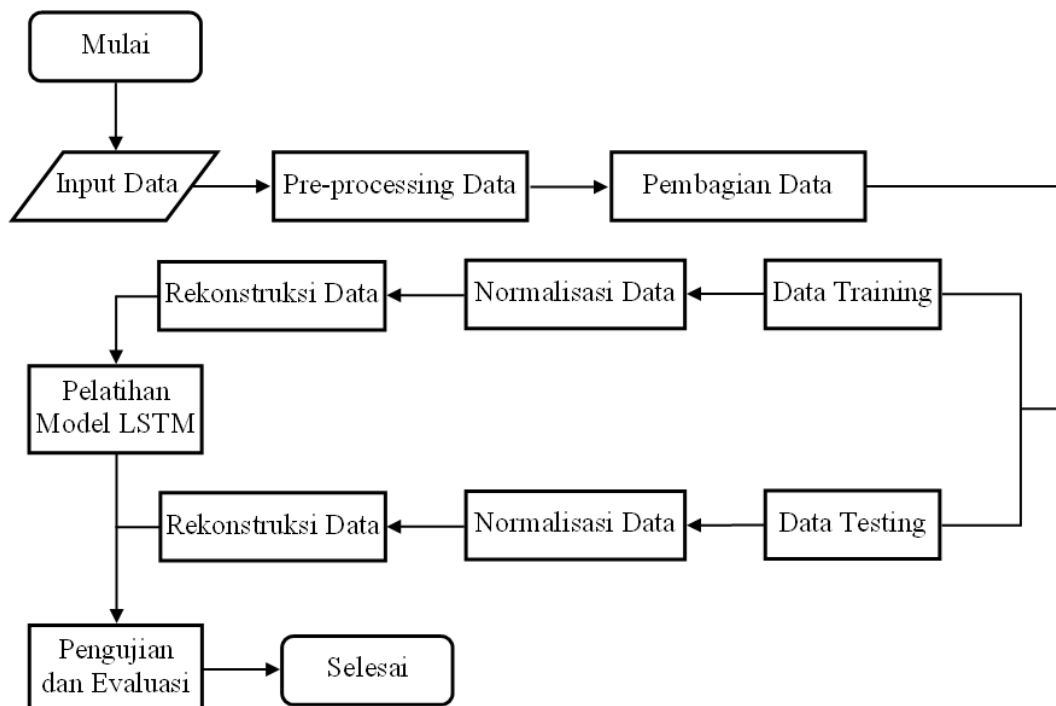
Penelitian sebelumnya dengan LSTM pada bank di Indonesia oleh Hansun dan Young (2021) menggunakan LSTM satu *layer* dengan data maksimal yang tersedia sampai bulan Juli 2021, penelitian oleh Gumelar dkk. (2022) juga menggunakan LSTM satu *layer* dengan data dari 11 Juni 2012 sampai 6 Juni 2022. Sedangkan penelitian ini menerapkan model *Long Short-Term Memory* (LSTM) dengan dua *layer* untuk memprediksi harga saham sektor perbankan yang termasuk dalam indeks LQ45, yaitu BBKA, BBNI, BBRI, BBTN, dan BMRI menggunakan data harga penutupan saham (*close*) dari tanggal 4 Januari 2021 sampai 28 Maret 2023.

METODE

1. Data

Data saham yang digunakan adalah lima perusahaan perbankan yang tergabung dalam indeks LQ45. Lima perusahaan tersebut yaitu Bank Central Asia Tbk., Bank Negara Indonesia (Persero) Tbk., Bank Rakyat Indonesia (Persero) Tbk., Bank Tabungan Indonesia (Persero) Tbk., dan Bank Mandiri (Persero) Tbk. Data merupakan data sekunder yang diperoleh dari website Yahoo Finance dengan kode untuk masing-masing bank tersebut yaitu BBKA.JK,

BBNI.JK, BBRI.JK, BBTN.JK, dan BMRI.JK. Data yang diambil adalah data harian harga penutupan saham (*Close*) dalam satuan rupiah yang setiap harinya mengalami perubahan. Periode data yang digunakan dari tanggal 4 Januari 2021 sampai 28 Maret 2023.



Gambar 1. Ilustrasi Tahapan Penelitian

2. *Pre-processing Data*

Pre-processing data dilakukan untuk mengecek nilai yang hilang (*missing value*) dari data. Jika terdapat nilai yang hilang, maka data tersebut akan diisi dengan nilai dari data harga penutupan saham hari sebelumnya atau data harga penutupan saham hari setelahnya.

3. *Pembagian Data*

Pembagian data dilakukan untuk memisahkan data menjadi data latih (*training*) dan data uji (*testing*) dengan rasio 80:20. Karena data merupakan data *time series*, maka pembagian data dilakukan secara berurutan (tidak diacak) dan hanya dilakukan sekali saja, dengan kata lain 80% data pertama untuk *training*, dan 20% data terakhir untuk *testing*. Data *training* akan digunakan dalam pelatihan model LSTM, sedangkan data *testing* akan digunakan untuk menguji bagaimana performa atau kinerja dari model LSTM.

4. *Normalisasi Data*

Normalisasi data digunakan untuk mengubah data dalam skala yang sama. Salah satu metode normalisasi adalah *min-max normalization* atau *min-max scaler*. *Min-max scaler* mengubah data menjadi rentang nilai [0, 1]. Rumus *min-max scaler* ditunjukkan pada persamaan berikut.

$$v = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

dengan v adalah nilai hasil normalisasi, x adalah nilai data lama, x_{\min} adalah nilai minimum dari data awal, dan x_{\max} adalah nilai maksimum dari data awal.

Untuk mengubah nilai dalam bentuk skala ternormalisasi menjadi bentuk tidak ternormalisasi dilakukan dengan denormalisasi. Denormalisasi dapat dilakukan dengan menggunakan rumus berikut.

$$P = v(x_{\max} - x_{\min}) + x_{\min} \quad (2)$$

dengan P adalah hasil denormalisasi, v adalah nilai dalam bentuk ternormalisasi, x_{\min} adalah nilai minimum dari data awal, dan x_{\max} adalah nilai maksimum dari data awal.

Nilai prediksi data ke- i , \hat{y}_i masih dalam bentuk ternormalisasi, sehingga diperlukan denormalisasi untuk mengubahnya menjadi nilai dalam bentuk tidak ternormalisasi. Menggunakan Persamaan (2) dengan $v = \hat{y}_i$, maka dapat diperoleh nilai prediksi dalam bentuk tidak ternormalisasi sebagai berikut

$$M_i = \hat{y}_i(x_{\max} - x_{\min}) + x_{\min} \quad (3)$$

dengan M_i adalah nilai denormalisasi prediksi data ke- i , \hat{y}_i adalah nilai prediksi data ke- i , x_{\min} nilai minimum dari data awal, dan x_{\max} adalah nilai maksimum dari data awal.

5. Rekonstruksi Data dan Inisialisasi Parameter

Data harga penutupan saham yang sudah dinormalisasi diubah bentuknya menjadi *array* 3 dimensi yang sesuai dengan format input dalam *package* TensorFlow pada bahasa pemrograman Python. Jumlah unit dalam layer LSTM dan jumlah *epoch* dapat dipilih secara bebas terlepas dari jumlah input (Ekman, 2021). Tergantung dari arsitektur model, jumlah unit dan jumlah *epoch* yang terlalu kecil dapat menyebabkan *underfitting* (model tidak dapat menentukan hubungan yang berarti antara *input* dan *output*), sedangkan jumlah unit dan *epoch* yang terlalu tinggi dapat mengakibatkan terjadinya *overfitting* (terlalu detail dalam menganalisis hubungan *input* dan *output* saat pelatihan data, sehingga akurasi rendah saat pengujian model).


Gumelar et al. (2022) menggunakan jumlah unit 7, 10, dan 20, sementara jumlah *epoch* yaitu 20 dan 80. Viadinugroho dan Rosadi (2021) menggunakan jumlah unit LSTM sebanyak 50 dengan 150 *epoch*. Kedua penelitian tersebut menggunakan arsitektur model yang berbeda, ada yang menggunakan satu layer LSTM dan ada yang tiga layer LSTM ditambah layer Dropout. Karena arsitektur model yang berbeda dan jumlah *timestep* yang berbeda dibandingkan penelitian sebelumnya, penelitian ini memilih variasi dua parameter berikut

1. Jumlah unit dalam layer LSTM: 8, 16, 32, 64
2. Jumlah *epoch*: 10, 25, 50, 75

6. Pelatihan Model

Model terdiri dari dua *layer Long Short-Term Memory (LSTM)* dan satu *layer Dense* sebagai *output*. LSTM dirancang untuk mengatasi masalah *short-term memory* dan gradien yang hilang dari RNN. Pertama kali diperkenalkan oleh Hochreiter dan Schmidhuber (1997) dan terus dikembangkan oleh peneliti-peneliti dalam berbagai bidang. Inti dari LSTM merupakan sebuah unit yang kompleks, dikenal dengan istilah *cell*. *Cell LSTM* dapat menyimpan suatu nilai dan mengingatkannya untuk waktu yang lama. Selain dapat mengingat nilai dari sepanjang *timestep*, *cell LSTM* dapat mengontrol kapan untuk menghapusnya dan kapan untuk memperbarui nilai pada memori *cell* (Ekman, 2021).

LSTM mengenalkan sebuah mekanisme kontrol aliran informasi yang bernama *gate* (gerbang). Terdapat 3 *gate* pada *cell LSTM*, yaitu *forget gate*, *input gate*, dan *output gate*.



Gambar 2. Struktur *Cell LSTM*

Dalam struktur *cell* LSTM pada Gambar 2, simbol σ melambangkan aktivasi sigmoid dan \tanh melambangkan fungsi aktivasi *hyperbolic tangent*. Garis melengkung dari x_t merepresentasikan penggabungan dari elemen h_{t-1} (output dari *timestep* sebelumnya) dan x_t (input *timestep* saat ini). Simbol \oplus menunjukkan penjumlahan matriks, sedangkan simbol \otimes (simbol \odot pada Persamaan (7) dan (9)) merupakan perkalian *hadamard product* (*element-wise product* atau *entrywise product*, atau *Schur product*). *Hadamard product* merupakan operasi perkalian elemen-elemen matriks yang bersesuaian dari dua matriks dengan ukuran yang sama (Horn & Johnson, 2013).

Adapun persamaan pada mekanisme *cell* LSTM adalah sebagai berikut (Ekman, 2021).

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (4)$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (5)$$

$$\tilde{C}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (6)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (7)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (8)$$

$$h_t = o_t \odot \tanh(C_t) \quad (9)$$

dengan f_t, i_t, \tilde{C}_t , dan o_t masing-masing adalah *forget gate*, *input gate*, calon kandidat *cell state*, dan *output gate*. W_f, W_i, W_c , dan W_o masing-masing adalah matriks *weight* (bobot) input untuk *forget gate*, *input gate*, calon kandidat *cell state*, dan *output gate*. U_f, U_i, U_c , dan U_o masing-masing adalah matriks bobot input dari *timestep* sebelumnya untuk *forget gate*, *input gate*, calon kandidat *cell state*, dan *output gate*. b_f, b_i, b_c , dan b_o masing-masing adalah *bias* untuk *forget gate*, *input gate*, calon kandidat *cell state*, dan *output gate*. Simbol σ menunjukkan fungsi aktivasi sigmoid pada Persamaan (10), dan \tanh adalah fungsi aktivasi *hyperbolic tangent* pada Persamaan (11). Notasi \odot menunjukkan perkalian *element-wise* atau *Hadamard product*. h_{t-1} adalah *output* dari *timestep* sebelumnya, x_t adalah input dari *timestep* ke- t (saat ini), C_t adalah *cell state*, dan h_t adalah *output* pada *timestep* ke- t .

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (10)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (11)$$

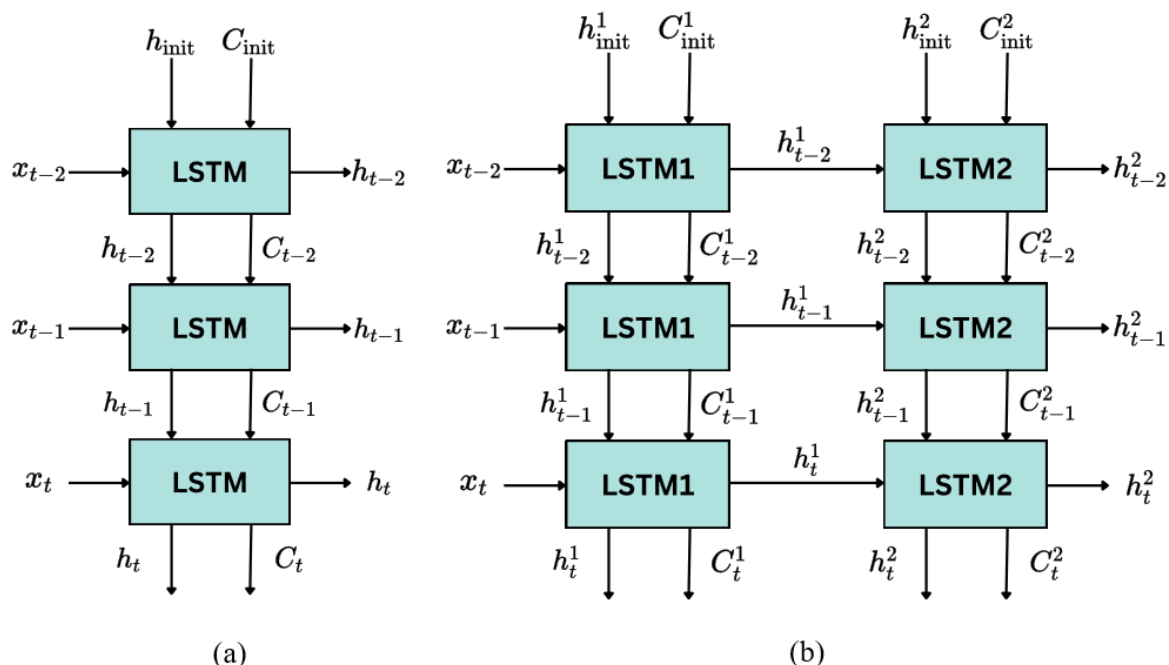
Untuk memperoleh *output* prediksi dari model LSTM, diperlukan satu *layer Dense* yang dihubungkan dengan jaringan LSTM. Fungsi aktivasi dari *layer Dense* adalah fungsi aktivasi linier. *Layer Dense* dapat dihitung dengan menggunakan rumus berikut.

$$\hat{y}_i = W_d h_t + b_d \quad (12)$$

dengan \hat{y}_i adalah prediksi data latih ke- i . W_d adalah bobot dari *layer Dense*, h_t adalah *output* dari *layer* LSTM pada *timestep* ke- t , dan b_d adalah *bias* dari *layer Dense*.

Penentuan bobot input W pada *layer* LSTM dan *layer Dense* menggunakan inisialisasi Glorot Uniform oleh Glorot dan Bengio (2010), sedangkan penentuan bobot *recurrent* U menggunakan inisialisasi *Orthogonal* oleh Saxe, McClelland, dan Ganguli (2013). Inisialisasi *bias* di awal bernilai 0, namun penambahan *bias* pada *forget gate* bernilai 1 lebih bagus digunakan (Jozefowicz et al., 2015).

Gambar 3 masing-masing menunjukkan contoh jaringan LSTM satu layer dengan tiga *timestep* dan jaringan LSTM dua layer dengan tiga *timestep* yang masing-masing ditunjukkan pada, dengan h_{init} dan C_{init} yang bernilai nol.



Gambar 3. (a) Jaringan LSTM Satu Layer dengan Tiga *Timestep*,
 (b) Jaringan LSTM Dua Layer dengan Tiga *Timestep*

7. Pengujian dan Evaluasi Model

Pengujian dilakukan dengan melakukan prediksi menggunakan data *testing*. Hasil prediksi masih dalam bentuk ternormalisasi, sehingga dilakukan denormalisasi menggunakan Persamaan (2) untuk mengubah nilai menjadi bentuk harga penutupan saham. Selanjutnya evaluasi model menggunakan yaitu *Mean Average Percentage Error* (MAPE) dan *Root Mean Squared Error* (RMSE). MAPE memberikan tingkat kesalahan akurasi dalam bentuk persentase, sedangkan RMSE memberikan tingkat kesalahan akurasi dalam bentuk nilai satuan. Perhitungan MAPE dan RMSE menggunakan rumus berikut

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - P_i}{y_i} \right| \times 100\% \quad (13)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - P_i)^2} \quad (14)$$

dengan n adalah banyak data, y_i adalah nilai aktual, dan P_i adalah nilai prediksi yang sudah dilakukan denormalisasi.

HASIL DAN PEMBAHASAN

1. Hasil

Data yang digunakan dalam penelitian adalah data saham 5 perbankan yang tergabung dalam indeks LQ45. Tabel 1 menunjukkan 5 saham beserta kode saham pada Bursa Efek Indonesia (BEI) dan *Yahoo Finance*. Data diunduh dari *website Yahoo Finance*, <https://finance.yahoo.com/>, dengan bantuan package *yfinance* pada bahasa pemrograman Python. Data merupakan data harga penutupan harian saham kelima bank dari 4 Januari 2021 sampai 28 Maret 2023. Grafik harga penutupan saham kelima bank ditunjukkan pada Gambar 4.

Pada langkah *pre-processing* data, dilakukan pengecekan nilai data yang hilang dari masing-masing harga penutupan saham bank. Tabel 2 menunjukkan bahwa tidak ada data yang hilang dari harga penutupan saham pada masing-masing bank.

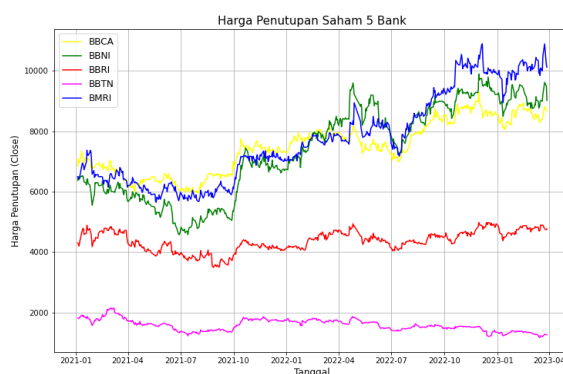
Tabel 1. Daftar Nama Bank dan Kode Saham

| No | Nama Bank | Kode Saham di BEI | Kode Saham di Yahoo Finance |
|----|--|-------------------|-----------------------------|
| 1 | Bank Central Asia Tbk. | BBCA | BBCA.JK |
| 2 | Bank Negara Indonesia (Persero) Tbk. | BBNI | BBNI.JK |
| 3 | Bank Rakyat Indonesia (Persero) Tbk. | BBRI | BBRI.JK |
| 4 | Bank Tabungan Indonesia (Persero) Tbk. | BBTN | BBTN.JK |
| 5 | Bank Mandiri (Persero) Tbk. | BMRI | BMRI.JK |

Tabel 2. Jumlah Nilai Hilang Data Masing-masing Bank

| Bank | Jumlah Nilai Hilang |
|------|---------------------|
| BBCA | 0 |
| BBNI | 0 |
| BBRI | 0 |
| BBTN | 0 |
| BMRI | 0 |

Data pada masing-masing bank berjumlah 552, dibagi menjadi data training dan data testing dengan rasio 80:20, sehingga data training berjumlah 442, sedangkan jumlah data testing ditambah sebanyak *timestep*, yaitu 5, karena data akan diubah menjadi bentuk *sequence*, sehingga jumlah data testing yaitu $110 + 5 = 115$ data. Data *training* dan data *testing* kemudian dinormalisasi menggunakan rumus *min-max scaler* pada Persamaan (1).



Gambar 4. Harga Penutupan Saham 5 Bank

Data *training* dan *testing* yang telah dinormalisasi kemudian diubah menjadi bentuk *sequence* dengan panjang *sequence* atau *timestep* sebanyak 5 untuk input LSTM di *package* TensorFlow pada bahasa pemrograman python. Pelatihan data dengan TensorFlow pada bahasa pemrograman python menggunakan variasi parameter jumlah unit dalam layer LSTM dan jumlah epoch. Variasi kedua parameter dalam pengujian ini, yaitu:

1. Jumlah *unit* pada layer LSTM: 8, 16, 32, 64
2. Jumlah *epoch*: 10, 25, 50, 75

Package TensorFlow pada bahasa pemrograman Python digunakan dalam pelatihan model yang terdiri dari dua layer LSTM dan satu *layer Dense* untuk *output*. Pelatihan model dilakukan pada masing-masing kombinasi parameter jumlah *unit* layer LSTM dan jumlah *epoch* (terdapat 16 kombinasi) untuk setiap bank. Parameter lain seperti *batch size* digunakan

sebesar 8, *loss* menggunakan *mean squared error* (MSE), dan *optimizer* menggunakan Adam. Inisialisasi bobot input layer LSTM dan Dense menggunakan Glorot Uniform, sedangkan inisialisasi bobot *recurrent* layer LSTM menggunakan inisialisasi bobot *orthogonal*.

Langkah selanjutnya yaitu pengujian model dengan melakukan prediksi pada data *testing*. Hasil prediksi yang masih dalam bentuk ternormalisasi kemudian diubah menjadi bentuk harga penutupan saham menggunakan denormalisasi pada Persamaan (3). Selanjutnya, evaluasi kinerja model menggunakan MAPE dan RMSE pada Persamaan (13) dan (14). Evaluasi model dilakukan pada masing-masing kombinasi parameter dan hasil evaluasi model terbaik yang diperoleh pada masing-masing bank ditunjukkan pada Tabel 3.

Tabel 3. Hasil Evaluasi pada Model Terbaik Masing-masing Bank

| Bank | Banyak Unit Hidden | Epoch | MAPE training (%) | MAPE testing (%) | RMSE training | RMSE testing | Waktu (detik) |
|------|--------------------|-------|-------------------|------------------|---------------|--------------|---------------|
| BBCA | 8 | 75 | 1,49 | 1,47 | 142,42 | 165,83 | 9,59 |
| BBNI | 8 | 75 | 2,58 | 1,77 | 230,88 | 217,50 | 7,90 |
| BBRI | 8 | 75 | 2,01 | 1,69 | 117,21 | 100,17 | 10,21 |
| BBTN | 64 | 75 | 2,51 | 3,02 | 55,35 | 54,26 | 14,10 |
| BMRI | 8 | 75 | 2,07 | 2,00 | 97,82 | 140,57 | 8,94 |

Persamaan akhir pada model terbaik untuk BBCA, BBNI, BBRI, BBTN, dan BMRI yaitu

$$\hat{y}_{BBCA} = [-0,613 \quad \dots \quad 0,531] h_{5_{BBCA}}^{<2>} + 0,008 \quad (12)$$

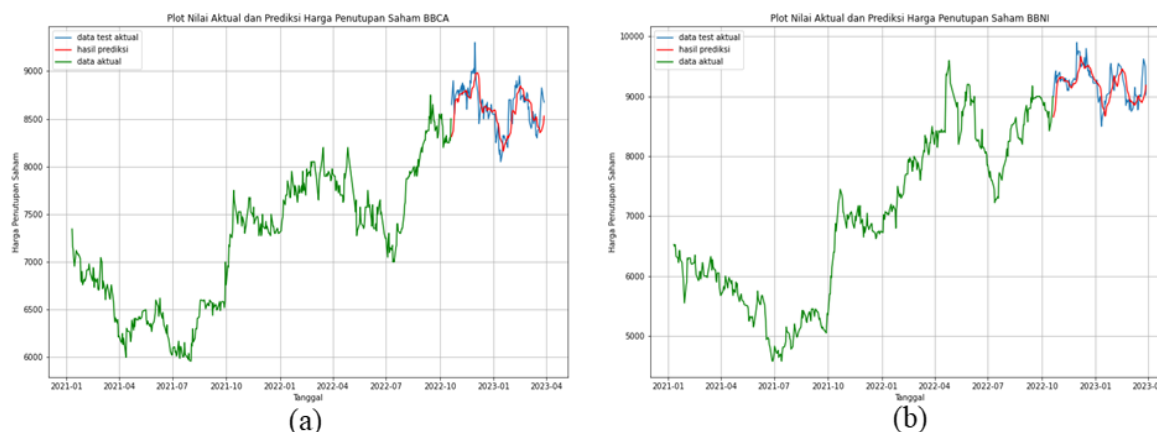
$$\hat{y}_{BBNI} = [-0,683 \quad \dots \quad -0,529] h_{5_{BBNI}}^{<2>} + 0,015 \quad (13)$$

$$\hat{y}_{BBRI} = [-0,715 \quad \dots \quad -0,825] h_{5_{BBRI}}^{<2>} + 0,012 \quad (14)$$

$$\hat{y}_{BBTN} = [-0,003 \quad \dots \quad 0,086] h_{5_{BBTN}}^{<2>} + 0,009 \quad (15)$$

$$\hat{y}_{BMRI} = [0,345 \quad \dots \quad 0,555] h_{5_{BMRI}}^{<2>} + 0,009 \quad (16)$$

dengan $h_{5_{bank}}^{<2>}$ adalah *output* dari layer kedua LSTM pada *timestep* 5 untuk masing-masing bank.




Gambar 5. (a) Grafik Nilai Aktual dan Hasil Prediksi BBCA;
 (b) Grafik Nilai Aktual dan Hasil Prediksi BBNI

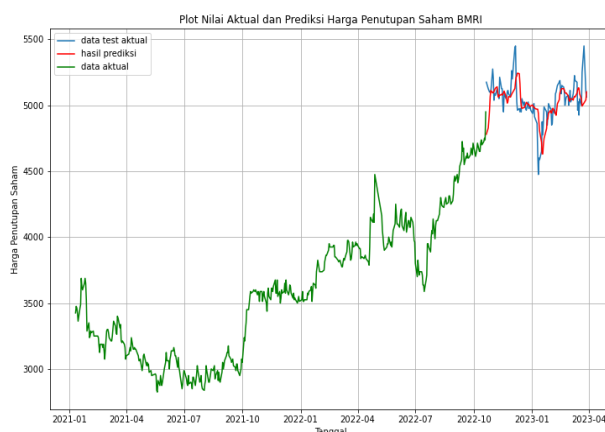
Grafik nilai aktual harga penutupan saham BBCA dan BBNI serta hasil prediksinya menggunakan model terbaik dari kombinasi parameter jumlah unit layer LSTM dan jumlah *epoch* pada Tabel 3 ditunjukkan pada Gambar 5. Nilai MAPE *testing* BBCA dan BBNI adalah 1,47% dan 1,77%, sedangkan nilai RMSE *testing* BBCA dan BBNI adalah 142,42 dan 230,88.

Rendahnya nilai MAPE mengindikasikan performa model yang sangat baik dalam melakukan prediksi harga penutupan saham BBKA dan BBNI

Grafik nilai aktual harga penutupan saham BBRI, BBTN, dan BMRI serta hasil prediksinya menggunakan model terbaik dari kombinasi parameter jumlah unit layer LSTM dan jumlah *epoch* pada Tabel 3 ditunjukkan pada Gambar 6 dan Gambar 7. Hasil prediksi harga penutupan saham BBRI, BBTN, dan BMRI yang ditunjukkan dengan nilai MAPE dan RMSE *testing* yang rendah. Nilai MAPE *testing* BBRI, BBTN, dan BMRI secara berturut-turut yaitu 1,69%, 3,02%, dan 2,00%, sedangkan RMSE *testing* masing-masing bernilai 100,17, 54,26, dan 140,57.



Gambar 7. (a) Grafik Nilai Aktual dan Hasil Prediksi BBRI;
(b) Grafik Nilai Aktual dan Hasil Prediksi BBTN



Gambar 6. Grafik Nilai Aktual dan Hasil Prediksi BMRI

2. Pembahasan

Prediksi harga saham pada penelitian ini hanya berupa analisis secara teknikal yang menggunakan data historis harga penutupan saham dan belum mempertimbangkan faktor-faktor lain. Faktor lain ini berpengaruh besar terhadap pergerakan dari harga saham, seperti pada bulan Januari 2021 sampai Juli 2021, pergerakan harga saham perbankan mengalami tren penurunan, walaupun terdapat kenaikan sementara dan kembali mengalami penurunan. Pada awal tahun 2021, saham sektor perbankan mengalami koreksi harga dan mengakibatkan guncangan di pasar saham (Sembiring, 2021). Pada pertengahan bulan Maret 2021, penurunan harga saham perbankan disebabkan karena terdapat antisipasi para investor terhadap kebijakan bank sentral yang diperkirakan berdampak pada pasar sektor keuangan menjelang adanya Rapat Dewan Gubernur (RDG) Bank Indonesia (BI) dan The Federal Open Market Committee (FOMC) (Wulandhari, 2021).

Bank BRI (BBRI) pada bulan Juni 2021, berencana melakukan kebijakan *right issue* atau pemberian Hak Memesan Efek Terlebih Dahulu (HMETD) untuk menambah modal perusahaan, namun pasar tidak bersikap positif terhadap rencana tersebut dan harga saham BBRI kemudian mengalami penurunan (Malik, 2021). Pada bulan September 2021, saham sektor perbankan mengalami kenaikan yang tajam. Kenaikan harga saham ini salah satunya disebabkan karena adanya aliran data asing yang masuk ke pasar saham Indonesia (Olavia et al., 2021). Investor asing masuk karena masih murahnya valuasi saham domestik, adanya penurunan kasus Covid-19, kinerja dari perekonomian nasional yang membaik. Di samping itu, Bank BCA (BBCA) berencana untuk melakukan *stock split* (pemecahan harga saham menjadi lebih kecil dengan rasio tertentu) yang didasarkan perkembangan pasar modal saat itu, menyebabkan harga saham BBCA lebih terjangkau (Yulian, 2021). Sementara itu, kenaikan saham Bank BNI (BBNI) pada bulan September dan Oktober 2021 dibantu oleh efek dari BBNI yang mengakuisisi bank kecil untuk dijadikan bank digital, serta kinerja dari perusahaan yang baik (Hariani, 2021).

Dari akhir bulan April 2022, harga saham perbankan mengalami penurunan yang disebabkan karena para investor lebih fokus dalam memulihkan perekonomian dalam negeri serta terdapat aksi korporasi dari emiten (tindakan dari perusahaan penerbit saham yang memberikan dampak terhadap saham terbitannya), sehingga investor memilih untuk menunggu dan melihat momentum saat ingin membeli saham (Wijayanti, 2022). Kemudian, saham Indeks Harga Saham Gabungan (IHSG) mengalami penurunan dari bulan Juni 2022 yang disebabkan karena sentimen pasar terhadap adanya inflasi serta terdapat kebijakan dari bank sentral Amerika Serikat (Federal Reserve) yang menaikkan suku bunga, sehingga berdampak langsung terhadap penurunan harga saham perbankan di Indonesia (Azka, 2022; Putra, 2022).

Banyak faktor yang mempengaruhi pergerakan harga saham dan penelitian ini belum memasukkan aspek lain selain data historis harga penutupan saham. Kombinasi antara data historis harga saham dengan sentimen pasar dimungkinkan, namun ini memerlukan data sentimen pasar yang dapat berupa berita. Keterbatasan data sentimen pasar menjadi salah satu pertimbangan jika melakukan analisis dengan kombinasi data tersebut. Sementara itu, prediksi harga saham hanya dengan data historis saham dapat digunakan sebagai alat bantu pengambilan keputusan dan investor perlu memiliki pengetahuan lebih dalam saham, kebijakan-kebijakan tertentu yang dapat mempengaruhi pergerakan saham, maupun dari segi fundamental perusahaan penerbit saham.

SIMPULAN

Prediksi harga penutupan saham pada sektor perbankan yang tergabung dalam indeks LQ45, yaitu BBCA, BBNI, BBRI, BBTN, dan BMRI menunjukkan kinerja yang sangat baik menggunakan model dengan dua layer LSTM dan satu layer Dense. Menggunakan model terbaik, diperoleh nilai MAPE *testing* pada BBCA, BBNI, BBRI, BBTN, dan BMRI masing-masing adalah 1,47%, 1,77%, 1,69%, 3,02%, dan 2,00%. Sementara itu, nilai RMSE *testing* pada BBCA, BBNI, BBRI, BBTN, dan BMRI masing-masing adalah 165,83, 217,50, 100,17, 54,26, dan 140,57. Nilai MAPE dan RMSE yang kecil ini menunjukkan kinerja atau performa model yang sangat baik dalam melakukan prediksi harga penutupan saham pada sektor perbankan, serta grafik menunjukkan hasil prediksi mendekati nilai aktual.

DAFTAR PUSTAKA

Agusta, A., Ernawati, I., & Muliawati, A. (2021). Prediksi pergerakan harga saham pada sektor farmasi menggunakan algoritma long short-term memory. *Jurnal Informatik*, 17(2), 164–173. <https://doi.org/10.52958/iftk.v17i2.3651>

- Arfan, A., & Lussiana, E. (2020). Perbandingan algoritma long short-term memory dengan SVR pada prediksi harga saham di Indonesia. *PETIR*, 13(1), 33–43. <https://doi.org/10.33322/petir.v13i1.858>
- Atienza, R. (2020). *Advanced deep learning with tensorflow 2 and keras: Apply DL, GANS, VAES, deep RL, unsupervised learning, object detection and segmentation, and more* (2nd ed.). Packt Publishing.
- Ayitey Junior, M., Appiahene, P., & Appiah, O. (2022). Forex market forecasting with two-layer stacked long short-term memory neural network (LSTM) and correlation analysis. *Journal of Electrical Systems and Information Technology*, 9(14), 1–24. <https://doi.org/10.1186/s43067-022-00054-1>
- Azka, R. M. (2022, July 1). Penyebab IHSG anjlok menyambut Juli 2022: Lonjakan inflasi hingga data covid-19. *Bisnis*. <https://market.bisnis.com/read/20220701/7/1550353/penyebab-ihsg-anjlok-menyambut-juli-2022-lonjakan-inflasi-hingga-data-covid-19>
- Bernico, M. (2018). *Deep learning quick reference: Useful hacks for training and optimizing deep neural networks with tensorflow and keras*. Packt Publishing.
- Chandola, D., Mehta, A., Singh, S., Tikkiwal, V. A., & Agrawal, H. (2022). Forecasting directional movement of stock prices using deep learning. *Annals of Data Science*. <https://doi.org/10.1007/s40745-022-00432-6>
- Das, S., Sahu, T. P., Janghel, R. R., & Sahu, B. K. (2022). Effective forecasting of stock market price by using extreme learning machine optimized by PSO-based group oriented crow search algorithm. *Neural Computing and Applications*, 34(1), 555–591. <https://doi.org/10.1007/s00521-021-06403-x>
- Ekman, M. (2021). *Learning deep learning: Theory and practice of neural networks, computer vision, natural language processing, and transformers using tensorflow* (1st ed.). Addison Wesley.
- Glorot, X., & Bengio, Y. (2010). Understanding the difficulty of training deep feedforward neural networks. In Y. W. Teh & M. Titterton (Eds.), *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics* (Vol. 9, pp. 249–256). PMLR. <https://proceedings.mlr.press/v9/glorot10a.html>
- Gumelar, F., Adha, F. Z., Rafi, F. A., & Pontoh, R. S. (2022). Peramalan harga saham bank BUMN Indonesia menggunakan long short-term memory (LSTM). *E-Journal BIAStatistics | Departemen Statistika FMIPA Universitas Padjadjaran*. <https://doi.org/10.1234/bias.v2022i1.152>
- Hansun, S., & Young, J. C. (2021). Predicting LQ45 financial sector indices using RNN-LSTM. *Journal of Big Data*, 8(104), 1–13. <https://doi.org/10.1186/s40537-021-00495-x>
- Hariani, A. (2021, October 31). IHSG naik 4,76 persen, ini saham top gainer Oktober. *Pajak*. <https://www.pajak.com/keuangan/ihsg-naik-476-persen-ini-saham-top-gainer-oktober/>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Horn, R. A., & Johnson, C. R. (2013). *Matrix analysis* (2nd ed.). Cambridge University Press.
- Jozefowicz, R., Zaremba, W., & Sutskever, I. (2015). An empirical exploration of recurrent network architectures. In F. Bach & D. Blei (Eds.), *Proceedings of the 32nd International Conference on Machine Learning* (Vol. 37, pp. 2342–2350). PMLR. <https://proceedings.mlr.press/v37/jozefowicz15.html>
- Julian, R., & Pribadi, M. R. (2021). Peramalan harga saham pertambangan pada bursa efek indonesia (BEI) menggunakan long short term memory (LSTM). *Jurnal Teknik Informatika Dan Sistem Informasi*, 8(3), 1596–1606. <https://doi.org/10.35957/jatisi.v8i3.1159>

- Kustodian Sentral Efek Indonesia. (2022). *Statistik pasar modal Indonesia: Desember 2022*. Kustodian Sentral Efek Indonesia.
- Malik, A. (2021, June 18). Saham BRI turun pasca umumkan right issue, namun reksadana schroders tetap melesat. *Redaksa*. <https://www.bareksa.com/berita/reksa-dana/2021-06-18/saham-bri-turun-pasca-umumkan-right-issue-namun-reksadana-schroders-tetap-melesat>
- Olavia, L., Daelami, M., & Harefa, T. (2021, October 11). Dana asing masih mengalir ke pasar saham. *Investor*. <https://investor.id/market-and-corporate/266619/dana-asing-masih-mengalir-ke-pasar-saham>
- Otoritas Jasa Keuangan. (2019). *Penyebab naik turun harga saham suatu perusahaan*. <https://sikapiuangmu.ojk.go.id/FrontEnd/CMS/Article/10507>
- Otoritas Jasa Keuangan. (2022). *Laporan statistik mingguan: Minggu ke-4 Desember 2022*. <https://www.ojk.go.id/id/kanal/pasar-modal/data-dan-statistik/statistik-pasar-modal/Pages/Statistik-Mingguan-Pasar-Modal---Desember-2022.aspx>
- Putra. (2022, June 17). Ketika IHSG anjlok, investor asing justru melakukan ini. *CNBC Indonesia*. <https://www.cnbcindonesia.com/market/20220617104100-17-347940/ketika-ihsg-anjlok-investor-asing-justru-melakukan-ini>
- Saxe, A. M., McClelland, J. L., & Ganguli, S. (2013). Exact solutions to the nonlinear dynamics of learning in deep linear neural networks. *ArXiv Preprint ArXiv:1312.6120*. <https://doi.org/10.48550/arXiv.1312.6120>
- Sembiring, L. J. (2021, April 14). Ini alasan saham-saham bank kakap belum pulih, saat serok. *CNBC Indonesia*. <https://www.cnbcindonesia.com/mymoney/20210414111226-72-237723/ini-alasan-saham-saham-bank-kakap-belum-pulih-saatnya-serok>
- Shi, Y. (2022). *Advances in big data analytics: Theory, algorithms and practices*. Springer. <https://doi.org/https://doi.org/10.1007/978-981-16-3607-3>
- Sofi, K., Sunge, A. S., Riady, S. R., & Kamalia, A. Z. (2021). Perbandingan algoritma linear regression, LSTM, dan GRU dalam memprediksi harga saham dengan model time series. *SEMINASTIKA*, 3(1), 39–46. <https://doi.org/10.47002/seminastika.v3i1.275>
- Umaidah, Y. (2018). Penerapan algoritma artificial neural network dalam prediksi harga saham LQ45 PT. Bank Rakyat Indonesia, Tbk. *Jurnal Gerbang*, 8(1), 57–64.
- Utami, V. W., & Kartika, R. (2020). Investasi saham pada sektor perbankan adalah pilihan yang tepat bagi investor di pasar modal. *Jurnal Sains Sosio Humaniora*, 4(2), 894–897. <https://doi.org/10.22437/jssh.v4i2.11596>
- Viadinugroho, R. A. A., & Rosadi, D. (2021). Long short-term memory neural network model for time series forecasting: Case study of forecasting ihsg during covid-19 outbreak. *Journal of Physics: Conference Series*, 1863(1), 1–11. <https://doi.org/10.1088/1742-6596/1863/1/012016>
- Wang, H., Wang, J., Cao, L., Li, Y., Sun, Q., & Wang, J. (2021). A stock closing price prediction model based on CNN-BILSTM. *Complexity*, 2021(1), 1–12. <https://doi.org/10.1155/2021/5360828>
- Wijayanti, R. I. (2022, May 10). Simak, ini penyebab saham perbankan turun meski kinerja bagus. *IDXChannel*. <https://www.idxchannel.com/market-news/simak-ini-penyebab-saham-perbankan-turun-meski-kinerja-bagus>
- Wulandhari, R. (2021, March 21). Saham bank BUMN terkoreksi jelang RDG BI dan FOMC. *Republika*. <https://ekonomi.republika.co.id/berita//qq3tqj370/saham-bank-bumn-terkoreksi-jelang-rdg-bi-dan-fomc?>
- Yıldırım, D. C., Toroslu, I. H., & Fiore, U. (2021). Forecasting directional movement of forex data using LSTM with technical and macroeconomic indicators. *Financial Innovation*, 7(1), 1–36. <https://doi.org/10.1186/s40854-020-00220-2>

Yulian, E. (2021, October 13). Saham bank BCA mulai diperdagangkan dengan harga baru. *Info Bank News*. <https://infobanknews.com/saham-bank-bca-mulai-diperdagangkan-dengan-harga-baru/>