

Perbandingan Metode *Reccurent Neural Network* dan *Long Short Term Memory* Untuk Prediksi Harga Saham Bank Mandiri

Nailatul Fitriani A.J¹, Ghufron²

Teknik Informatika, Universitas Islam Sultan Agung^{1,2}
nailatulfitrianiaj@gmail.com¹, ghufron@unissula.ac.id²

ABSTRAK

Saham merupakan jenis investasi yang mencerminkan kepemilikan suatu perusahaan dan menjadi indikator utama dalam menilai kinerja pasar keuangan. Fluktuasi harga saham dipengaruhi oleh beragam aspek, di antaranya keadaan perekonomian, kinerja perusahaan, dan persepsi pasar. Dalam sektor perbankan, saham Bank Mandiri menjadi salah satu bank yang sahamnya paling stabil dan strategis di Indonesia sehingga harga saham Bank Mandiri menjadi objek kajian yang menarik, terutama dalam menganalisis pola dan prediksi. Banyak sekali metode yang digunakan dalam memprediksi harga saham, salah satunya menggunakan RNN dan LSTM. Pada penelitian ini dilakukan perbandingan model RNN dan LSTM untuk memprediksi harga saham pada Bank Mandiri dengan menggunakan data penutupan saham dalam rentang waktu 2018 hingga 2024. Dalam beberapa pengujian didapatkan bahwa model LSTM memberikan hasil yang lebih baik dengan nilai RMSE sebesar 94,22 dan MAPE sebesar 1,56%, sementara RNN memperoleh nilai RMSE sebesar 191,91 dan MAPE 1,53%.

Kata-kata kunci : Prediksi saham, RNN, LSTM

A. Pendahuluan

Perkembangan teknologi dan digitalisasi telah membawa dampak cukup besar pada sektor keuangan (Tsakila dkk., 2024). Salah satu aspek penting dalam keuangan adalah pasar saham yang tidak hanya berfungsi sebagai tempat transaksi tetapi juga sebagai indikator kesehatan suatu negara (Fitrirahmawati, 2019). Harga saham yang fluktuatif mencerminkan dinamika pasar yang kompleks, dipengaruhi oleh berbagai faktor seperti kondisi ekonomi, kebijakan pemerintah, hingga sentimen investor (Dinda dkk., 2017). Ada beberapa sektor industri saham yang tersedia di pasar modal, namun sektor perbankan masih menjadi sektor yang paling menarik bagi para investor (Tumbelaka dkk., 2023). Salah satu bank terbesar di Indonesia yang memiliki reputasi yang kuat pada sektor perbankan dan pasar keuangan adalah bank mandiri. Pergerakan sahamnya kerap menjadi perhatian investor dan analisis keuangan karena mencerminkan stabilitas serta prospek kinerja perusahaan dalam jangka panjang. Oleh sebab itu, memahami pola dan prediksi harga saham Bank Mandiri menjadi penting untuk membantu mengembalikan keputusan investasi yang lebih akurat.

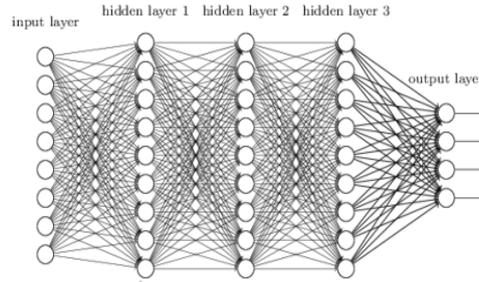
Dalam beberapa dekade terakhir, telah berkembang berbagai pendekatan untuk memprediksi harga saham, salah satunya dengan *Deep Learning*. *Reccurent Neural Network* (RNN) dan *Long Sort Term Memory* (LSTM) merupakan algoritma *deep learning* yang digunakan untuk prediksi berbasis data berurutan seperti data saham dari waktu ke waktu. (Alkahfi dkk., 2024) menggunakan RNN dan LSTM untuk memprediksi data ekonomi dan keuangan dengan menghasilkan kinerja LSTM lebih baik daripada RNN karena mampu mengatasi masalah *vanishing gradient* yang sering terjadi pada RNN. (Al Kiramy dkk., 2024) juga menggunakan RNN dan LSTM untuk meramalkan jumlah jamaah umroh dengan hasil terbaik diperoleh dari model LSTM. Selain itu (Selle dkk., 2022) mengimplementasikan model RNN dan LSTM untuk memprediksi penggunaan listrik dengan hasil performa yang lebih unggul diperoleh dari model LSTM untuk prediksi data deret waktu yang panjang daripada model RNN.

Berdasarkan permasalahan yang ada dan hasil penelitian sebelumnya, maka penelitian ini akan dilakukan perbandingan hasil prediksi harga saham pada Bank Mandiri menggunakan metode RNN dan LSTM. Kedua model ini sering diterapkan dalam prediksi data deret waktu. Namun, pada penelitian ini, akan dilakukan pengujian dengan menggunakan beberapa parameter yang disesuaikan dengan data yang digunakan untuk menghasilkan prediksi yang lebih akurat dan membangun model terbaik, Penelitian ini diharapkan mampu menghasilkan model dengan tingkat akurasi yang tinggi dalam memprediksi harga saham serta membandingkan hasil evaluasi dari kedua metode yang diterapkan.

B. Landasan Teori

1. *Deep Learning*

Deep Learning merupakan bagian dari *machine learning* yang berfungsi untuk mempelajari data yang tersedia menggunakan algoritma tertentu (Schmidhuber, 2015). Perbedaan utama antara *Deep Learning* dan *neural network* terletak pada jumlah *hidden layer*. *Deep Learning* memiliki lebih banyak *hidden layer* dibandingkan *neural network* biasa. Sebuah jaringan dikategorikan sebagai "*deep learning*" jika memiliki lebih dari tiga lapisan (termasuk lapisan *input* dan *output*). Secara teknis, *Deep Learning* dapat didefinisikan sebagai bentuk *machine learning* dengan lebih dari satu *hidden layer*. Sebagai contoh, pada Gambar 7.1, terlihat ilustrasi *Deep Learning* yang memiliki 4 lapisan, dengan jumlah node yang bervariasi di setiap lapisan (Rizki dkk., 2020)



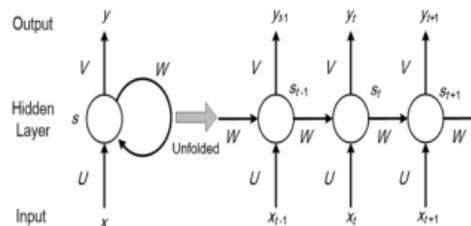
Gambar 1 Ilustrasi deep learning

Deep learning berbagai project besar algoritma yang terdapat antara lain Convolutional Neural Network (CNN), Recurrent Neural Network (RNN), Long Short Term Memory (LSTM), dan lain sebagainya. Beberapa penerapannya digunakan dalam produk sehari-hari yaitu deteksi gambar, pengenalan suara, deteksi anomali, mesin rekomendasi, prediksi, hingga pemrosesan bahasa alami. Maka dari itu, dalam penelitian ini menggunakan RNN dan LSTM untuk memprediksi saham Bank Mandiri

banyak diterapkan dalam maupun kecil. Jenis pada deep learning yaitu

2. Recurrent Neural Network

RNN (Recurrent Neural network) merupakan algoritma yang dikembangkan untuk memproses data sequensial. RNN memiliki memori internal yang dapat mengingat informasi dari data sebelumnya dan memanfaatkannya untuk memprediksi data di masa mendatang. Cara kerjanya melibatkan pengalihan informasi dari setiap data sampel ke data sampel berikutnya, di mana informasi tersebut disimpan dalam memori internal RNN. Memori ini kemudian digunakan untuk membantu memproses sampel data berikutnya. Proses ini berlangsung secara berulang hingga seluruh rangkaian data berurutan selesai diproses (Schmidhuber, 2015).



Gambar 2. Struktur RNN

Gambar 2 arsitektur RNN yang lapisan utama, terdiri dari

layer, dan output layer. Perbedaan utama terletak pada cara proses komputasi berlangsung di hidden layer, yang merupakan isi dari memory cell. Langkah pertama pada model RNN disajikan pada Persamaan (2) yaitu menghitung hidden state baru h_t melalui fungsi tanh dari input saat ini X_t dan hidden state sebelumnya H_{t-1} . Selanjutnya, untuk output numerik maka nilai keluaran dari model RNN diperoleh langsung melalui Persamaan (3) yaitu total nilai hidden state baru berdasarkan bobot masing-masing unitnya.

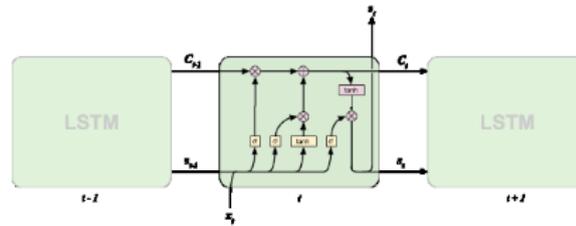
merupakan terdiri dari tiga input layer, hidden

$$h_t = \tau(W_x X_t + W_h h_{t-1}) + b_h \quad (2)$$

$$O_t = W_o h_t + b_o \quad (3)$$

3. Long Short Term Memory

Long Short Term Memory (LSTM) adalah sebuah variasi dari Recurrent Neural Network (RNN) yang dirancang untuk mengatasi masalah pada hidden layer. Algoritma LSTM berfokus pada penggabungan kontrol non-linear dan hubungan antar data dalam sel RNN sekaligus memastikan gradien fungsi tujuan tetap terjaga agar sinyal tidak hilang. LSTM dirancang untuk mengatasi permasalahan vanishing gradient, yaitu kondisi di mana gradien bernilai nol atau mendekati nol, dengan menggunakan mekanisme gate (Rezk dkk., 2020)



Gambar 3. Arsitektur LSTM

Pada Gambar 3 menunjukkan struktur dan

diatas aliran dari *memory cell*

yang berfungsi mirip dengan *neuron* dalam jaringan syaraf tiruan lainnya. LSTM terdiri dari *memory cell* dan *gate unit* yang memiliki peran penting dalam pengaturan memori setiap *neuron*. *Memory cell* ini menjalankan empat proses utama dengan fungsi aktivasi sigmoid yang digunakan atau tanh untuk setiap input yang diterima oleh *neuron* yang dikenal sebagai *gate unit*. *Gate unit* ini memiliki tiga komponen *input gate*, *forget gate*, dan *output gate*. Selain itu, terdapat *cell gate* yang bertanggung jawab untuk memperbarui nilai dalam cell dengan nilai baru yang relevan.

ada *forget gate*, setiap informasi dari data masukan diproses untuk menentukan data apa saja yang akan disimpan atau dihapus dari *memory cell*. Proses ini menggunakan fungsi aktivasi sigmoid yang menghasilkan keluaran rentang 0 hingga 1. apabila hasilnya mendekati 1, maka seluruh data akan disimpan. Sedangkan apabila hasilnya mendekati 0, maka data akan dihapus. Proses ini terdapat pada persamaan berikut: (Roondiwala et al., 2017)

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

Pada *input gate*, terdapat dua tahapan proses. Pertama, fungsi aktivasi sigmoid digunakan untuk memilih nilai yang akan diperbarui. Selanjutnya fungsi tanh digunakan untuk membuat vektor nilai baru yang akan disimpan dalam *memory cell*. Kedua proses ini digabungkan untuk memperbarui *memory cell*. Proses ini terdapat pada persamaan berikut: (Roondiwala et al., 2017)

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

$$C_t = \tanh(W_c x_t + W_{hc} h_{t-1} + b_c) \quad (6)$$

Nilai *Memory cell* diperbarui dengan nilai *memory* terbaru pada *cell gate* sebelumnya. Nilai baru diperoleh dengan mengkombinasi *output* dari *forget gate* dan *input gate*. Proses ini terdapat pada persamaan berikut: (Roondiwala et al., 2017)

$$C_t = f_t * C_{t-1} + i_t * C_t \quad (7)$$

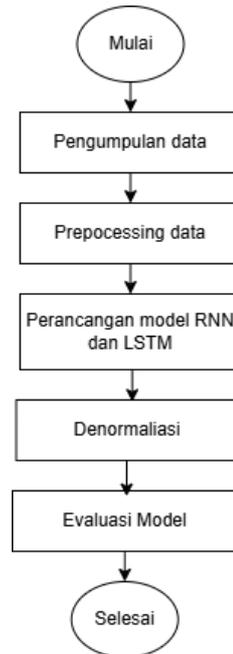
Pada *output gate* terdapat dua tahapan proses. Yang pertama merupakan Fungsi aktivasi sigmoid digunakan untuk menentukan bagian dari *memory cell* yang akan dihasilkan. Selanjutnya, fungsi aktivasi tanh dilakukan untuk memproses nilai pada *memory cell*. Selanjutnya kedua *gate* tersebut dikalikan untuk menghasilkan nilai *output*. Proses tersebut dapat dijelaskan pada persamaan berikut: (Roondiwala et al., 2017)

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

$$h_t = \sigma * \tanh(C_t) \quad (9)$$

C. Metode Penelitian

Penelitian ini menggunakan metode RNN dan LSTM untuk memprediksi harga saham bank Mandiri, serta membandingkan metode mana yang memberikan hasil terbaik dalam memprediksi harga saham. Berikut merupakan tahapan yang akan dilakukan pada penelitian ini yang dapat ditemukan pada gambar 4.



Gambar 4. Tahapan proses penelitian

1. Pengumpulan data

Pada penelitian ini menggunakan data penutupan saham harian Bank Mandiri yang diambil dari sumber resmi seperti *Yahoo Finance* dengan periode data dari tahun 2018 hingga 2024.

2. Preprocessing data

Pada tahap ini dilakukan *cleansing* data (pembersihan data), normalisasi, dan transformasi data. Dengan cara mengubah nilai harga penutupan saham yang sebenarnya menjadi nilai dengan rentang 1 hingga 0 untuk proses normalisasi menggunakan *min-max normalization* (Wiranda & Sadikin, 2019) yang dapat dilihat pada persamaan (1).

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

X' merujuk pada skala data dalam rentang baru, Dimana X merupakan nilai data yang akan dinormalisasi, Xmax adalah nilai maksimum dari variabel, Xmin adalah nilai minimum dari variabel. Setelah data sudah diproses, kemudian data dibagi data menjadi *data testing* dan *data training* dengan presentase 80% data training 20% data testing.

3. Perancangan Model

Setelah tahap *preprocessing data* selesai dilakukan, selanjutnya dilakukan pembentukan model RNN dan LSTM dengan arsitektur sequensial dengan 2 lapisan yang berisi 128 dan 64 units neuron, 2 lapisan dense ditambahkan dengan lapisan pertama 25 neuron dan lapisan terakhir 1 neuron sebagai output model. Untuk mendapatkan model dengan kemampuan terbaik, maka diperlukan pengujian parameter yang disesuaikan dengan data. Berikut pengujian parameter kedua model yang terdapat pada tabel 1.

Tabel 1. Pengujian parameter RNN dan LSTM

Optimizer	Batch size	Epoch
Adam	16	30
Adam	16	50
Adam	16	100
Adam	32	30
Adam	32	50
Adam	32	100

4. Denormalisasi

Proses ini dilakukan untuk mengubah data data prediksi yang awalnya berada dalam rentang interval 0-1 kembali ke nilai aktual harga saham.

$$d = d' (max - min) + min \quad (10)$$

Dengan d nilai denormalisasi, d' nilai data normalisasi, max adalah nilai maksimum data aktual, dan min adalah nilai minimum data aktual (Selle et al., 2022).

5. Evaluasi model

Evaluasi model bertujuan untuk mengukur akurasi dari model yang telah dikembangkan. Dalam penelitian ini, evaluasi tersebut dilakukan dengan menggunakan dua metrik, yaitu *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE)..

RMSE merupakan metrik yang mengukur seberapa akurat hasil perhitungan dibandingkan dengan tingkat kesalahan (Febrianti et al., 2016). Berikut persamaan untuk menghitung RMSE :

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

MAPE adalah ukuran persentase kesalahan yang mengukur perbedaan antara nilai aktual dan nilai prediksi (Maricar dkk., 2017). Berikut persamaan untuk menghitung MAPE :

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

Berikut skala nilai akurasi prediksi berdasarkan nilai MAPE yang dapat dilihat pada tabel 2

Tabel 2. Skala nilai akurasi MAPE

Skala MAPE	Interpretasi
<10%	Hasil prediksi sangat tepat
10-20%	Hasil prediksi tepat
20-25%	Hasil prediksi cukup
>50%	Hasil prediksi tidak akurat

D. Hasil Dan Pembahasan

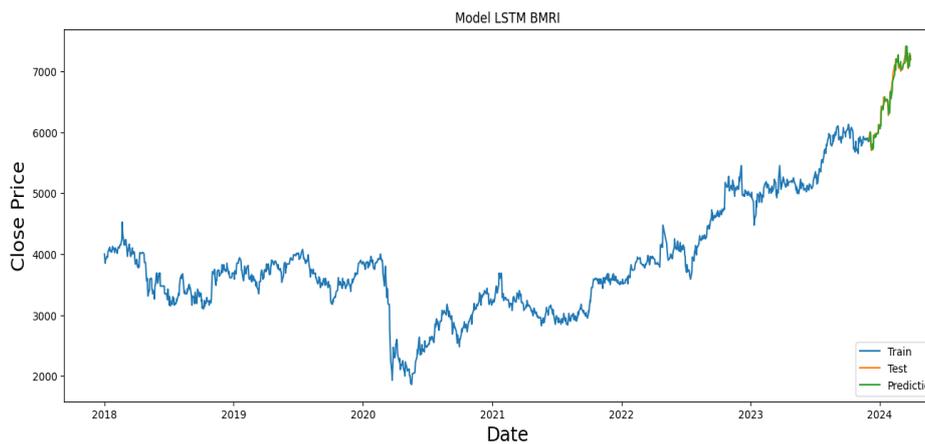
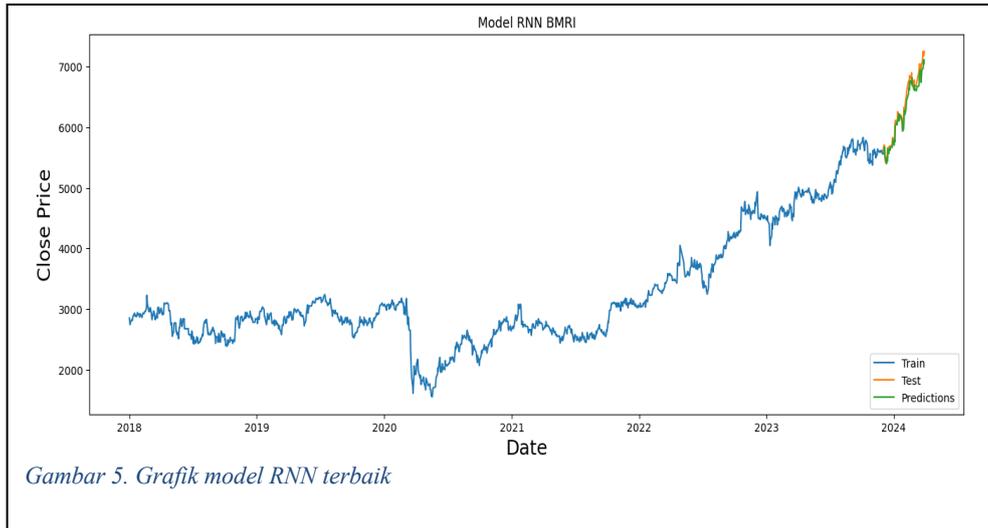
Setelah beberapa percobaan yang sudah dilakukan, model terbaik untuk RNN diperoleh dengan menggunakan batch size 16 dan epoch 100, menghasilkan nilai RMSE sebesar 191,91 dan MAPE sebesar 1,53%. Sementara itu, model terbaik untuk LSTM dicapai dengan batch size 32 dan epoch 30, dengan nilai RMSE sebesar 94,22 dan MAPE sebesar 1,56%. Hasil tersebut ditemukan pada tabel 3

Tabel 3. Hasil Evaluasi Model

Perbandingan evaluasi model RNN dan LSTM						
Optimizer	Batch size	Epoch	RMSE RNN	MAPE RNN	RMSE LSTM	MAPE LSTM
Adam	16	30	198,01	2,78%	108,24	1,43%
Adam	16	50	182,69	2,55%	119,43	1,56%
Adam	16	100	119,91	1,53%	99,69	1,25%
Adam	32	30	170,93	2,24%	94,22	1,15%
Adam	32	50	121,42	1,61%	118,23	1,56%
Adam	32	100	228,39	3,34%	116,79	1,53%

Tabel 3 menampilkan hasil evaluasi model dengan membandingkan performa RNN dan LSTM. Berdasarkan beberapa konfigurasi parameter, yaitu optimizer (Adam), batch size, dan epoch. Evaluasi ini menggunakan metrik utama yaitu RMSE dan MAPE. Hasil tersebut menunjukkan bahwa batch size memiliki pengaruh signifikan terhadap performa kedua mode. Dengan batch size 16, baik RNN dan LSTM cenderung memberikan hasil yang lebih baik dibandingkan batch size 32. Hasil ini menunjukkan bahwa ukuran batch size yang kecil dapat membantu model belajar lebih efektif dari data. Selain itu, LSTM menunjukkan keunggulan RNN, terutama dalam hal stabilitas performa terhadap perubahan batch size. Selain itu pengaruh epoch juga terlihat jelas khususnya pada RNN. Saat jumlah epoch meningkat dari 30 ke 50, performa RNN membaik dengan menurun nilai RMSE dan MAPE. Namun, pada epoch 100, performa RNN justru menurun dengan meningkatnya nilai RMSE dan MAPE secara signifikan, menunjukkan potensi overfitting. Sebaliknya, LSTM menunjukkan hasil yang lebih stabil di semua konfigurasi epoch dengan nilai RMSE dan MAPE yang tetap rendah, menjadikannya lebih unggul dalam menangani data sekuensial.

Setiap data saham yang diuji menghasilkan model terbaik dengan nilai RMSE dan MAPE terendah pada model RNN dan LSTM. Perbandingan antara hasil prediksi dengan harga aktual untuk kedua model tersebut terdapat dalam bentuk grafik pada gambar 5 dan 6.



Pada gambar 5 dan gambar 6 merupakan grafik prediksi harga penutupan saham BMRI menggunakan model RNN tahun 2018 hingga 2024 dibagi yaitu data pelatihan yang ditunjukkan oleh garis biru, dan data pengujian yang ditampilkan dengan garis oranye. Model ini menghasilkan prediksi, yang direpresentasikan oleh garis hijau. Hasil prediksi menunjukkan bahwa model LSTM mampu mengikuti pola data aktual, terutama pada periode 2023-2024. Tren harga saham cenderung meningkat signifikan sejak tahun 2021, dan prediksi model hampir sesuai dengan nilai sebenarnya, menandakan akurasi yang tinggi dalam memprediksi tren saham. Berikut perbandingan hasil dari data aktual dengan data prediksi pada model RNN dan LSTM yang terdapat pada tabel 4

Tabel 4 Perbandingan hasil prediksi RNN dan LSTM

Perbandingan hasil prediksi model RNN dan LSTM			
Date	Close Price	RNN Predictions	LSTM Predictions
2023-12-04	5708.076172	5577.522949	5639.217773
2023-12-05	5684.292480	5677.386230	5695.154297
2023-12-06	5517.807129	5658.785645	5729.231934
2023-12-07	5470.239746	5499.580078	5670.375000
...
2024-03-22	7050.000000	6959.452637	7050.314453
2024-03-25	7250.000000	6966.256836	7076.135742
2024-03-26	7175.000000	7039.624023	7179.932129
2024-03-28	7250.000000	7104.952637	7225.011230

Tabel 4 menunjukkan perbandingan hasil prediksi harga saham Bank Mandiri menggunakan model RNN dan LSTM terhadap harga penutupan (Close Price). Data menunjukkan bahwa hasil prediksi yang dihasilkan oleh model LSTM lebih mendekati data harga penutupan dibandingkan data harga prediksi yang dihasilkan oleh RNN, hal ini selaras dengan Hasil RMSE dan MAPE yang rendah sehingga memberikan kesalahan prediksi yang lebih kecil dibandingkan dengan model RNN. Analisis secara menyeluruh dari kedua model untuk memprediksi harga saham Bank Mandiri dengan nilai rata-rata RMSE dan MAPE ditujukan pada tabel 5

Tabel 5 Nilai rata-rata evaluasi pada masing-masing model

Nilai rata-rata evaluasi masing-masing model		
Metode	RMSE	MAPE
RNN	170,22	2,34%
LSTM	109,43	1,41%

Berdasarkan nilai rata-rata evaluasi model pada tabel 5 menunjukkan bahwa metode LSTM lebih unggul dibandingkan RNN dalam memprediksi harga saham Bank Mandiri. Rata-rata RMSE LSTM sebesar 109,43 lebih kecil daripada RNN yang mencapai 170,22. Hal ini menunjukkan kesalahan prediksi yang lebih rendah. Selain itu, MAPE LSTM sebesar 1,41% juga lebih baik dibandingkan RNN yang memiliki MAPE 2,34%. Hasil ini menegaskan bahwa LSTM lebih efektif dalam menangkap pola data sekuensial dan menghasilkan prediksi yang lebih akurat berdasarkan penjelasan interpretasi dari nilai MAPE yang dihasilkan.

E. Kesimpulan Dan Saran

Dari hasil implementasi dan pembahasan yang telah dilakukan, metode LSTM terbukti lebih efektif dibandingkan dengan RNN dalam memprediksi harga saham Bank Mandiri. Hal ini dibuktikan dengan nilai rata-rata RMSE dan MAPE LSTM yang lebih rendah, masing-masing sebesar 109,43 dan 1,41%, dibandingkan dengan RNN yang mencatat rata-rata RMSE 170,22 dan MAPE 2,34%. Hasil prediksi LSTM juga lebih mendekati nilai aktual, menunjukkan kemampuannya dalam menangkap pola data sekuensial yang kompleks. Dengan demikian, LSTM menjadi metode yang lebih andal untuk menghasilkan prediksi harga saham yang akurat, dapat membantu investor dalam pengambilan keputusan investasi. Disarankan untuk prediksi selanjutnya menggunakan dataset yang lebih besar dan beragam yang mencakup data dari sektor lain atau periode waktu yang panjang untuk meningkatkan generalisasi model.

DAFTAR PUSTAKA

- Al Kiramy, R., Permana, I., Marsal, A., Munzir, M. R., & Megawati, M. (2024). Perbandingan Performa Algoritma RNN dan LSTM dalam Prediksi Jumlah Jamaah Umrah pada PT. Hajar Aswad. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 4(4), 1224–1234. <https://doi.org/10.57152/malcom.v4i4.1373>
- Alkahfi, C., Kurnia, A., & Saefuddin, A. (2024). Perbandingan Kinerja Model Berbasis RNN pada Peramalan Data Ekonomi dan Keuangan Indonesia. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 4(4), 1235–1243. <https://doi.org/10.57152/malcom.v4i4.1415>
- Dinda, O., Dan, A. A., Andarini, S., Administrasi, P., Fisip-Upnv, B., & Timur, J. (2017). PENGARUH PROFITABILITAS TERHADAP HARGA SAHAM PADA PERUSAHAAN MAKANAN DAN MINUMAN YANG TERDAFTAR DI BURSA EFEK INDONESIA. In *Jurnal Bisnis Indonesia* (Vol. 8, Issue 1).
- Febrianti, F., Hafiyusholeh, M., & Asyhar, A. H. (2016). *PERBANDINGAN PENGKLUSTERAN DATA IRIS MENGGUNAKAN METODE K-MEANS DAN FUZZY C-MEANS*. 02(01).
- Fitrirahmawati, M. (2019). *ANALISIS PENGARUH PASAR SAHAM TERHADAP PERTUMBUHAN EKONOMI DI NEGARA BERKEMBANG (SUATU KAJIAN LITERATUR)*. 4(1).
- Maricar, M. A., Widiadnyana, P., & Arta Wijaya, I. W. (2017). Analysis of Data Mining for Forecasting Total Goods Delivery with Moving Average Method. *International Journal of Engineering and Emerging Technology*, 2(1), 7. <https://doi.org/10.24843/ijeet.2017.v02.i01.p02>
- Rezki, N. M., Purnaprajna, M., Nordstrom, T., & UI-Abdin, Z. (2020). Recurrent Neural Networks: An Embedded Computing Perspective. In *IEEE Access* (Vol. 8, pp. 57967–57996). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ACCESS.2020.2982416>
- Rizki, M., Basuki, S., & Azhar, Y. (2020). Implementasi Deep Learning Menggunakan Arsitektur Long Short Term Memory Untuk Prediksi Curah Hujan Kota Malang. *REPOSITOR*, 2(3), 331–338.
- Roondiwala, M., Patel, H., & Varma, S. (2017). Predicting Stock Prices Using LSTM. *International Journal of Science and Research (IJSR)*, 6(4), 1754–1756. <https://doi.org/10.21275/ART20172755>
- Schmidhuber, J. (2015). Deep Learning in neural networks: An overview. In *Neural Networks* (Vol. 61, pp. 85–117). Elsevier Ltd. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Selle, N., Yudistira, N., & Dewi, C. (2022). *PERBANDINGAN PREDIKSI PENGGUNAAN LISTRIK DENGAN MENGGUNAKAN METODE LONG SHORT TERM MEMORY (LSTM) DAN RECURRENT NEURAL NETWORK (RNN)*. 9(1), 155–162. <https://doi.org/10.25126/jtiik.202295585>
- Tsakila, N. F., Wirahadi, M. A., Fadilah, A. A., & Simanjuntak, H. (2024). Analisis Dampak Fintech terhadap Kinerja dan Inovasi Perbankan di Era Ekonomi Digital. *Indonesian Journal of Law and Justice*, 1(4), 11. <https://doi.org/10.47134/ijlj.v1i4.2787>
- Wiranda, L., & Sadikin, M. (2019). *PENERAPAN LONG SHORT TERM MEMORY PADA DATA TIME SERIES UNTUK MEMPREDIKSI PENJUALAN PRODUK PT. METISKA FARMA* (Vol. 8).