

## ANALISIS PERBANDINGAN HASIL MODEL *AUTOREGRESIVE INTEGRATED MOVING AVERAGE* DAN *LONG SHORT TERM MEMORY* DALAM PERAMALAN INDEKS SAHAM SYARIAH INDONESIA

Hertoto Eko Prasetyotomo\*, Sitta Alief Farihati  
Program Studi Matematika FST Universitas Terbuka

\*Penulis korespondensi: 023920502@ecampus.ut.ac.id

### ABSTRAK

Artikel ini menyajikan perbandingan hasil peramalan Indeks Saham Syariah Indonesia (ISSI) menggunakan dua model analisis data deret waktu, yaitu *Autoregressive Integrated Moving Average* (ARIMA) dan *Long Short Term Memory* (LSTM). Data analisis yang digunakan adalah harga penutupan yang disesuaikan (*adjusted closing price*) dari ISSI selama periode 1 Januari 2021 hingga 29 Desember 2023. Hasil analisis menunjukkan bahwa model ARIMA memiliki rata-rata kesalahan yang lebih rendah dibandingkan model LSTM, baik dalam hal besaran kesalahan maupun persentase kesalahan. Hal ini menunjukkan bahwa model ARIMA lebih efektif dalam memprediksi ISSI untuk dataset yang digunakan.

**Kata Kunci:** ARIMA, indeks saham syariah, LSTM, peramalan saham, *time series*

### 1 PENDAHULUAN

Salah satu instrumen investasi yang menarik bagi banyak investor adalah instrumen saham. Investasi saham menarik karena banyak keuntungan, seperti kemungkinan keuntungan besar, likuiditas yang membantu penjualan kembali, dan kesempatan untuk diversifikasi portofolio. Selain itu, saham memberi investor kesempatan untuk menerima dividen sebagai pendapatan tambahan dan memungkinkan mereka untuk berpartisipasi dalam perusahaan yang lebih besar. Investasi saham juga memberikan pemahaman lebih dalam tentang bisnis dan ekonomi serta melindungi investor dari inflasi. Dengan strategi yang tepat, saham bisa menjadi investasi yang menguntungkan, meskipun ada risiko seperti volatilitas pasar dan kemungkinan kehilangan modal. Oleh sebab itu penting bagi investor untuk dapat memprediksi harga saham sehingga investor dapat mengambil keputusan apakah membeli, menahan, atau menjual suatu saham.

Sekumpulan harga saham dalam waktu tertentu membentuk himpunan data yang dapat dianalisis sesuai kebutuhan. Dalam hal ini, pola fluktuasi harga saham merupakan deret waktu (*time series*). Adapun deret waktu adalah serangkaian  $xt$  yang setiap pengamatannya direkam pada waktu tertentu  $t$  (Brockwell & Davis, 2016). Dengan memahami deret waktu, investor saham akan mampu mengidentifikasi atau meramalkan harga saham sehingga dapat membuat keputusan yang sangat menguntungkan dalam pembelian saham tertentu (Woodward dkk., 2022).

Analisis deret waktu sudah banyak dilakukan oleh para peneliti maupun praktisi. Model yang paling sering digunakan adalah *Autoregressive Integrated Moving Average* (ARIMA). Model ini menggabungkan tiga komponen yaitu *Autoregressive* (AR), yang menunjukkan bahwa nilai masa depan bergantung pada nilai-nilai masa lalu; *Integrated* (I), yang melibatkan penurunan data untuk membuatnya stasioner dan menghilangkan tren atau musiman; serta *Moving Average* (MA), yang memodelkan kesalahan prediksi berdasarkan kesalahan di masa lalu (Shumway & Stoffer, 2017).

Model ARIMA sering digunakan dalam memprediksi harga saham di pasar saham Indonesia. Sebagai contoh, Rezaldi & Sugiman (2021) melakukan analisis deret waktu menggunakan model ARIMA untuk meramalkan harga saham PT. Telekomunikasi Indonesia. Kurniasi dkk. (2021) juga melakukan analisis deret waktu terhadap indeks harga saham menggunakan data saham BCA. Karena harga saham cenderung fluktuatif setiap harinya, kecenderungan adanya pencilaan menimbulkan kebutuhan untuk melakukan deteksi guna memperbaiki model analisis ARIMA, seperti yang ditemukan Trydini & Huda (2023). Meskipun ARIMA telah terbukti sebagai model yang efektif dalam memprediksi harga saham secara umum, penelitian yang dilakukan oleh Malik dkk. (2020) menunjukkan bahwa metode *double exponential smoothing* mungkin lebih optimal. Hasil penelitian mengindikasikan bahwa PT. Indofood CBP Sukses Makmur Tbk (ICBP) sebaiknya menggunakan metode *double exponential smoothing* karena menghasilkan tingkat error yang lebih rendah. Sedangkan PT. Indofood Sukses Makmur Tbk (INDF) lebih cocok menggunakan metode ARIMA (3.1.0) karena metode ini menghasilkan tingkat *error* yang lebih rendah.

Selain model ARIMA, saat ini telah berkembang model Mesin Belajar (*Machine Learning*) yang dapat digunakan untuk melakukan analisis deret waktu. Salah satunya adalah *Long Short Term Memory* (LSTM). Model LSTM ini merupakan pengembangan dari *Recurrent Neural Network* (RNN). Arsitektur RNN pertama kali diperkenalkan oleh Hochreiter dan Schmidhuber pada tahun 1997. RNN memiliki keterbatasan dalam menyimpan informasi jangka panjang karena hanya memiliki memori jangka pendek, sehingga informasi yang diperoleh sebelumnya tidak dapat dibawa ke proses berikutnya. Untuk mengatasi masalah ini, LSTM digunakan sebagai solusi. LSTM adalah unit khusus dari RNN yang dirancang untuk mengatasi ketergantungan jangka panjang. LSTM memiliki mekanisme internal yang disebut *cell states* dan *gates* yang berfungsi mengatur memori pada setiap input. Ada empat jenis *gates* dalam LSTM, yaitu *forget gate*, *input gate*, *cell gate*, dan *output gate*. Dengan diperkenalkannya model LSTM ini, banyak peneliti yang terus mengembangkan arsitektur LSTM untuk digunakan dalam berbagai bidang (Arfan & ETP, 2020).

Model LSTM pernah digunakan untuk memprediksi harga saham Tesla di Amerika Serikat. Hasilnya adalah LSTM dapat memprediksi harga saham dengan angka keakuratan prediksi tertinggi yaitu 99% (Setiawan dkk., 2023). Dalam kasus saham di Indonesia, model LSTM juga dapat digunakan untuk memprediksi harga saham secara akurat karena memberikan nilai MAPE (*Mean Absolute Percentage Error*) yang mendekati 0, seperti yang dilakukan Budiprasetyo dkk. (2022).

Pada tahun 2023, Setiawan dkk. melakukan penelitian yang membandingkan antara ARIMA dan LSTM pada data saham di Indonesia. Dalam penelitiannya, mereka mengkaji harga saham individual Bank BCA, Bank BTN, dan Bank BRI. Berdasarkan nilai RMSE (*Root Mean Square Error*), ditunjukkan bahwa LSTM lebih baik dalam meramalkan harga saham Bank BCA, sementara ARIMA lebih baik dalam memprediksi harga saham Bank BTN dan Bank BRI. RMSE merupakan akar kuadrat dari rata-rata perbedaan kuadrat antara hasil yang diprediksi dan hasil yang diamati (Box dkk., 2016). Penggunaan model ARIMA dan LSTM juga telah dilakukan para peneliti pada Indeks Saham Syariah Indonesia (ISSI). Pada tahun 2020, Muthahharah menghasilkan model ARIMA yang menunjukkan harga saham hari ini tidak dipengaruhi oleh harga saham sebelum dan setelahnya. Adapun Anandita & Wahyuningsih (2024) menunjukkan bahwa model LSTM dapat digunakan dengan baik untuk memprediksi ISSI karena menghasilkan nilai RMSE yang cukup kecil.

Berdasarkan hasil survei literatur, hingga saat ini belum ada penelitian yang membandingkan model ARIMA dan LSTM pada ISSI. Oleh karena itu, artikel ini akan mengkaji perbandingan hasil peramalan antara model ARIMA dan model LSTM pada ISSI.

## 2 METODE PENELITIAN

### 2.1 Jenis Data

Jenis data yang digunakan untuk penelitian ini adalah data sekunder yaitu *adjusted closing price* ISSI. Sumber data diperoleh dari situs <https://finance.yahoo.com/>. Rentang periode datanya adalah 1 Januari 2021 hingga 29 Desember 2023.



**Gambar 1.** Data indeks harga ISSI

### 2.2 Model Analisis Data

#### 2.2.1 Model ARIMA

Dalam menggunakan model ARIMA, maka syarat yang harus dipenuhi adalah stasioneritas. Stasioneritas data dapat diuji dengan menggunakan *Augmented Dicky Fuller* (ADF). Persamaan ADF adalah sebagai berikut:

$$w_t = \delta z_{t-1} + \sum_{i=1}^k \alpha_i w_{t-1} + e_t \quad (1)$$

Uji ADF dengan tahap pengujian hipotesis sebagai berikut:

$$H_0 : \delta = 0 \text{ (data tidak stasioner)}$$

$$H_0 : \delta < 0 \text{ (data stasioner)}$$

Jika pengujian ADF menunjukkan data tidak stasioner maka harus dilakukan *differencing* dengan menggunakan rumus sebagai berikut:

$$W_t = z_t - z_{t-1} \quad (2)$$

Selanjutnya jika data sudah dalam keadaan stasioner, maka langkah berikutnya adalah mencari model ARIMA, yaitu *autoregressive order* ( $p$ ), *degree of differencing* ( $d$ ), dan *moving average order* ( $q$ ), dilakukan dengan menggunakan *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Perhitungan akan dilakukan menggunakan Python code dengan *library statsmodels* dengan *function statacf* dan *pacf*.

Model ARIMA ( $p, d, q$ ) akan diperoleh berdasarkan plot PACF (untuk nilai  $p$ ), derajat *differencing* pada (2), dan nilai  $q$  akan didapat dari plot ACF. Keseluruhan parameter dinyatakan signifikan jika keseluruhan parameter memiliki nilai  $p$ -value < taraf signifikan (5%).

### 2.2.2 Model LSTM

LSTM merupakan turunan dari metode RNN. Bedanya, LSTM menggunakan sel memori untuk mengatasi masalah *vanishing gradient* yang terdiri dari *input layer*, *hidden layer*, *forget gate*, *cell state*, dan *output layer*. Adapun RNN hanya menggunakan *input layer*, *hidden layer* dan *output layer*. Hal tersebut menjadi masalah ketika RNN mencoba untuk belajar dari urutan yang sangat panjang, dengan informasi penting dari langkah-langkah awalnya hilang.

Untuk melakukan training, model LSTM akan digunakan *library* dari Python yaitu *Library Sklearn* dengan fungsi *MinMaxScaler*: Fungsi ini sangat berguna untuk normalisasi data, membantu meningkatkan kinerja algoritma *machine learning* dengan memastikan bahwa semua fitur memiliki skala yang sama. *Libray Keras Layers* dengan fungsi *LSTM* yang digunakan untuk melakukan training dan testing sehingga terbentuk model LSTM.

Pada penelitian ini dilakukan tahapan-tahapan *training* LSTM sebagai berikut:

1. Melakukan normalisasi data. Hal ini perlu dilakukan untuk mengatasi perbedaan nilai yang cukup besar pada data. Normalisasi akan dilakukan dengan menggunakan *library sklearn* dengan fungsi *MinMaxScaler*.
2. Membagi data *adjusted closing price* saham ISSI menjadi data *training* sebanyak 80% dan data pengujian 20%
3. Melakukan *training* model LSTM dengan menghitung semua gerbang secara berurut. Gerbang yang akan dihitung adalah *forget gate*, fungsi *input gate*, fungsi *cell state*, dan yang terakhir fungsi *output gate*. *Training* model LSTM akan dilakukan dengan menggunakan Python code dengan *library keras layers* dengan fungsi *LSTM*. Hasil training akan diagram *Model Loss*. Diagram *Model Loss* akan menunjukkan *train loss*, *validation loss*, seiring dengan siklus *epoch*. *Train loss* adalah metrik yang mengukur kesalahan prediksi model pada data pelatihan. *Train loss* dihitung selama proses pelatihan model dan menunjukkan seberapa baik model menyesuaikan diri dengan data yang dilatihkan. *Validation loss* adalah metrik yang mengukur kesalahan prediksi model pada data validasi, yaitu data yang tidak digunakan selama pelatihan tetapi digunakan untuk mengevaluasi kinerja model. *Validation loss* digunakan untuk memantau kinerja model pada data yang belum pernah dilihatnya, membantu mendeteksi *overfitting*. *Overfitting* terjadi ketika model terlalu menyesuaikan diri dengan data pelatihan sehingga menangkap noise atau detail yang tidak relevan. Model yang *overfit* memiliki kinerja yang sangat baik pada data pelatihan tetapi tidak mampu mengeneralisir pola untuk data yang belum tersedia. (Chollet, 2021)

### 2.2.3 Peramalan dan Analisis Perbandingan Hasil

Secara umum, notasi dan teori yang digunakan untuk analisis perbandingan hasil dalam artikel ini merujuk pada Hanke dan Wichern (2014). Setelah didapatkan model terbaik dari ARIMA dan LSTM, tahap selanjutnya adalah melakukan peramalan *adjusted closing price* saham ISSI untuk membandingkan model ARIMA dan LSTM. Teknik evaluasi model yang digunakan adalah *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Square Error* (RMSE).

MAPE dihitung sebagai rata-rata dari kesalahan persentase absolut dari nilai-nilai yang diprediksi. MAPE mengungkapkan akurasi dalam bentuk persentase, sehingga mudah untuk diinterpretasikan. Nilai MAPE yang lebih rendah menunjukkan bahwa peramalan tersebut lebih akurat. Rumus dari MAPE adalah sebagai berikut:

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{z_t - \hat{z}_t}{z_t} \right|}{n} \times 100\% \quad (3)$$

RMSE merupakan ukuran yang sering digunakan untuk menilai perbedaan antara nilai-nilai yang diprediksi oleh suatu model atau estimator dengan nilai-nilai yang sebenarnya diamati. Rumus dari RMSE adalah sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Z_i - z_1)^2} \quad (4)$$

### 3 HASIL DAN PEMBAHASAN

#### 3.1 Uji stationeritas model ARIMA

Pengujian stationeritas data menggunakan ADF. Hasil pengujiannya adalah sebagai berikut:

**Tabel 1.** ADF sebelum *differencing*.

| Data                          | <i>p-value</i> |
|-------------------------------|----------------|
| <i>adjusted closing price</i> | 0,1881         |

Hasil *p-value* pada data *adjusted closing price* lebih besar dari taraf signifikan 5%. Hal ini menunjukkan bahwa data tersebut tidak stasioner. Oleh sebab itu perlu dilakukan *differencing* untuk membuat data menjadi stasioner. Uji ADF setelah dilakukan *differencing* adalah sebagai berikut:

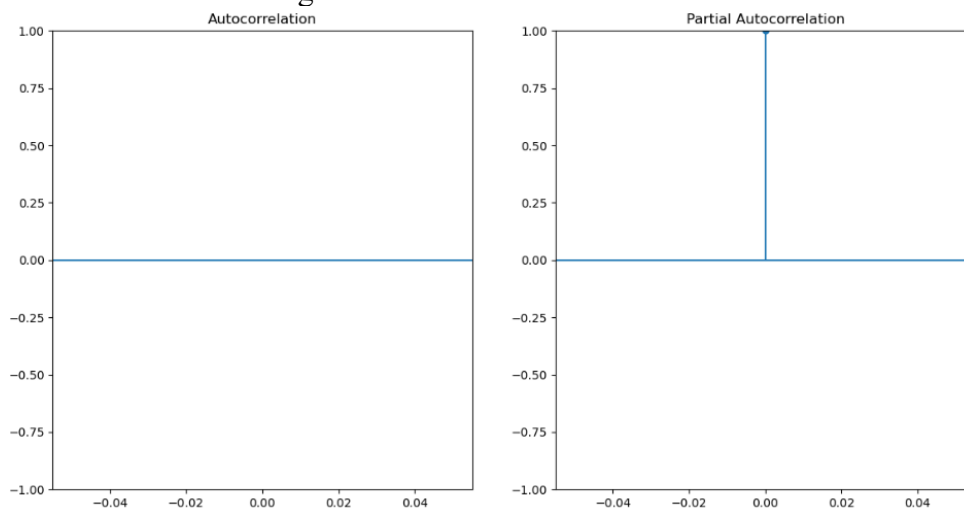
**Tabel 2.** ADF setelah *differencing*.

| Data                          | <i>p-value</i> |
|-------------------------------|----------------|
| <i>adjusted closing price</i> | 0,000          |

Setelah dilakukan *differencing*, maka *p-value* lebih kecil dari taraf signifikan *p-value* yaitu 5%.

#### 3.2 Identifikasi Model ARIMA

Uji plot ACF dan PACF adalah sebagai berikut:



**Gambar 1.** ACF dan PACF saham ISSI

ACF menunjukkan semua autokorelasi dekat dengan nol untuk semua lag. Hal ini menunjukkan tidak ada korelasi yang signifikan antara nilai seri pada lag yang berbeda. Dengan demikian, hasil ini menunjukkan bahwa mungkin tidak diperlukan *moving average* (MA) dalam model ARIMA. Sementara itu, PACF menunjukkan lonjakan signifikan pada lag 1 kemudian dipotong tajam hampir ke nol untuk lag berikutnya. Hal ini menunjukkan komponen autoregresif yang kuat pada lag 1. Oleh karena itu, berdasarkan kedua hasil tersebut jelas bahwa nilai  $p = 1$  sedangkan nilai  $q = 0$ . Adapun nilai  $d = 1$  dikarenakan data awal tidak

stasioner dan perlu dilakukan *differencing*. Dengan demikian, dapat disimpulkan bahwa model ARIMA yang digunakan adalah ARIMA(1,1,0).

### 3.3 Penaksiran dan Uji Signifikansi Model ARIMA

Berdasarkan hasil sebelumnya, diperoleh bahwa model ARIMA dalam kasus ini adalah ARIMA(1,1,0). Hasil uji signifikansi pada model menunjukkan bahwa model memiliki parameters yang signifikan

**Tabel 3.** Penaksiran parameter Model ARIMA

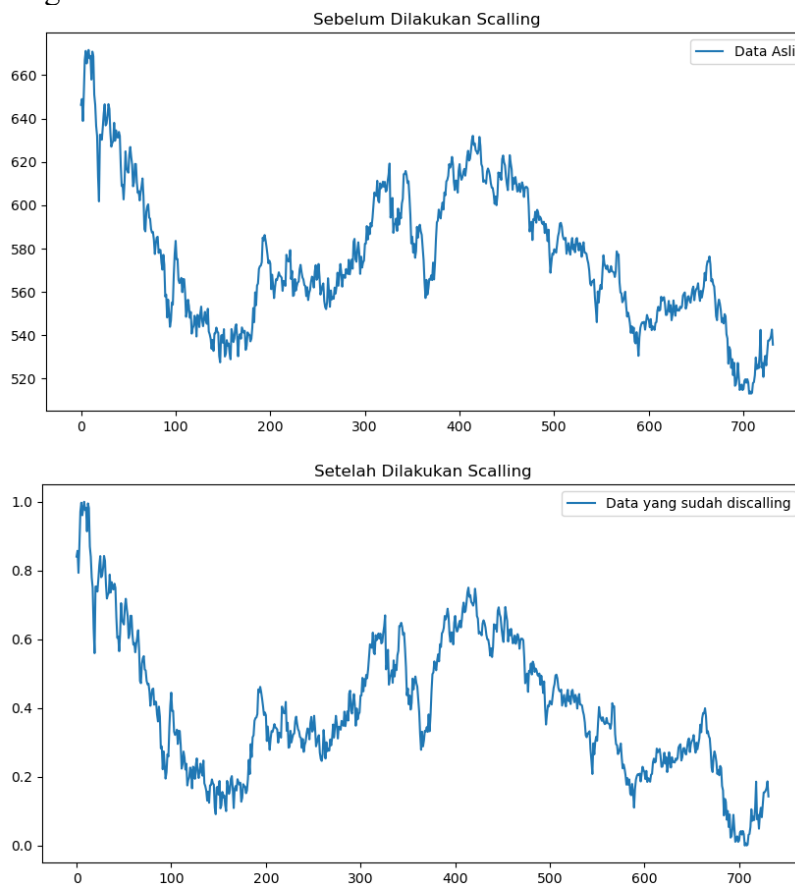
| Parameter   | Koefisien | p-value |
|-------------|-----------|---------|
| $\varphi_1$ | -0,5114   | 0,0000  |
| $\phi_1$    | 49,5779   | 0,0000  |

Berdasarkan parameter tersebut kita juga mengetahui bahwa fungsi matematika dari model ARIMA (1,1,0) pada data indeks harga saham ISSI adalah

$$X_t = X_{t-1} - 0,5114(X_{t-1} - X_{t-2}) + \varepsilon_t \quad (4)$$

### 3.4 Normalisasi data untuk LSTM

Salah satu alasan untuk melakukan normalisasi data atau penskalaan adalah agar setiap fitur memiliki bobot yang sama dalam kontribusi ke model, sehingga menghindari bias terhadap fitur dengan skala yang lebih besar. Penskalaan memastikan bahwa input lebih cocok dengan fungsi aktivasi yang digunakan dalam model, yang sering kali sensitif terhadap skala data. Secara keseluruhan, penskalaan adalah langkah penting untuk memastikan bahwa model LSTM bekerja dengan efektif dan efisien.



**Gambar 2.** Plot data asli dan data setelah dilakukan penskalaan


### 3.4 Training Model LSTM

Data dibagi yang ada dibagi menjadi 80% sebagai *training* dan 20% sebagai data tes. Optimisasi *hyperparameters* dilakukan dengan bantuan *Python Code library Keras Tune*. *Hyperparameters* yang didapat adalah sebagai berikut:

**Tabel 4.** Optimum Hyperparameters LSTM

| <i>Hyperparameters</i> | <i>Spesifikasi/Value</i> |
|------------------------|--------------------------|
| Timesteps              | 70                       |
| Units                  | 50                       |
| LSTM Layers            | 2                        |
| Learning Rate          | 0.0064                   |

Berdasarkan *hyperparameters* yang telah optimum, maka model LSTM dapat difinalisasi. *Train Loss* dan *Validation Loss* ditunjukkan pada gambar berikut:



**Gambar 3.** Train Loss dan Validation Loss Model LSTM

Gambar 3 menunjukkan bahwa *training* pada model LSTM sudah efektif. Terlihat bahwa *train loss* dan *validation loss* menurun secara tajam pada epoch awal. Hal ini menunjukkan model mesin belajar dengan cepat dari data yang ada. *Train loss* dan *validation loss* tersebut kemudian stabil dan tetap dekat, menunjukkan tidak ada *overfitting* yang signifikan.

### 3.5 Peramalan dan Analisis Perbandingan Hasil Model ARIMA dan LSTM

Berdasarkan proses sebelumnya, telah diperoleh model ARIMA dan LSTM. Hasil perbandingannya disajikan dalam tabel berikut ini:

**Tabel 5.** Perbandingan Hasil Peramalan ARIMA dan LSTM

| Tanggal        | Aktual | Peramalan model ARIMA | Peramalan Model LSTM |
|----------------|--------|-----------------------|----------------------|
| 2-Januari-2024 | 545,38 | 535.68                | 527,42               |
| 3-Januari-2024 | 543,10 | 539.23                | 527,41               |
| 4-Januari-2024 | 546,98 | 534.27                | 527,17               |
| 5-Januari-2024 | 541,06 | 535.44                | 527,09               |
| 8-Januari-2024 | 533,83 | 533.46                | 527,06               |
| 9-Januari-2024 | 525,75 | 536.48                | 527,07               |

Hasil perhitungan RMSE dan MAPE berdasarkan data peramalan dan data aktual disajikan pada tabel berikut.

**Tabel 6.** Hasil RMSE dan MAPE

| Model        | RMSE  | MAPE  |
|--------------|-------|-------|
| ARIMA(1,1,0) | 8.34  | 1.33% |
| LSTM         | 14.16 | 2.31% |

Hasil ini menunjukkan bahwa model ARIMA memiliki rata-rata kesalahan yang relatif rendah baik dalam besaran kesalahan maupun dalam persentase. Hal ini mengindikasikan bahwa model ARIMA cukup efektif untuk dataset dan skenario peramalan spesifik yang digunakan. Model LSTM menunjukkan nilai RMSE dan MAPE yang lebih tinggi dibandingkan dengan model ARIMA. Hal ini mengimplikasikan bahwa LSTM meskipun memiliki kemampuan untuk menangani pola yang kompleks dan ketergantungan jangka panjang dalam data, tidak diatur sebaik atau seefektif model ARIMA untuk dataset atau jenis masalah peramalan tertentu ini.

#### 4. KESIMPULAN

Berdasarkan hasil yang diperoleh, dapat disimpulkan bahwa:

1. Penelitian ini membandingkan kinerja model *Autoregressive Integrated Moving Average* (ARIMA) dan *Long Short Term Memory* (LSTM) pada ISSI menggunakan data harga penutupan yang disesuaikan dari 1 Januari 2021 hingga 29 Desember 2023. Hasil analisis menunjukkan bahwa model ARIMA lebih efektif dibandingkan dengan model LSTM dalam meramalkan ISSI untuk dataset yang digunakan, ditunjukkan oleh rata-rata kesalahan yang lebih rendah baik dalam besaran kesalahan maupun persentase kesalahan.
2. Model ARIMA lebih cocok untuk memprediksi ISSI karena efektivitasnya dalam menangani pola yang tidak kompleks yaitu saat musiman dan tren lebih dapat diprediksi dan tidak memerlukan penangkapan ketergantungan jangka panjang yang mampu ditangani oleh LSTM.
3. Dalam kasus ISSI, LSTM memiliki kemampuan untuk menangani pola yang lebih kompleks dan ketergantungan jangka panjang. Performanya dalam kasus ini kurang optimal, yang mungkin disebabkan oleh *tuning hyperparameter* yang kurang tepat atau karakteristik data yang lebih cocok untuk model ARIMA. Temuan ini juga ternyata sejalan dengan temuan penelitian sebelumnya terhadap peramalan harga saham secara individu. Model ARIMA masih bisa mengungguli LSTM pada saham-saham tertentu.
4. Untuk penelitian selanjutnya, dapat mempertimbangkan proses optimasi *hyperparameter* yang lebih ketat, dengan menggunakan teknik seperti *grid search* atau *random search* untuk menyempurnakan pengaturan model.

#### DAFTAR PUSTAKA

- Anandita, & Wahyuningsih. (2024). Prediksi Indeks Saham Syariah Menggunakan Model Long Short-Term Memory (LSTM). *Jurnal Ilmu Manajemen*, 9(1).
- Arfan, A., & ETP, L. (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>
- Chollet, F. (2021). *Deep Learning with Python* (2nd Ed). New York: Simon and Schuster.
- Box, G., Jenkins, G., Reinsel, G., & LJung, G. (2016). *Time Series Analysis: Forecasting and Control* (5th ed.). Hoboken: Wiley.



- Brockwell, P. J., & Davis, R. A. (2016). *Introduction to Time Series and Forecasting*. New York City: Springer.
- Budiprasetyo, Hani'ah, & Aflah. (2022). Prediksi Harga Saham Syariah Menggunakan Algoritma Long Short-Term Memory (LSTM). *Jurnal Nasional Teknologi Dan Sistem Informasi*, 8(3), 164–172.
- Hanke, J., & Wichern, D. (2014). *Business Forecasting* (9th ed.). Harlow: Pearson Education Limited.
- Kurniasi, A. A., Saptari, M. A., & Ilhadi, V. (2021). Aplikasi Peramalan Harga Saham Perusahaan Lq45 Dengan Menggunakan Metode Arima. *Sisfo: Jurnal Ilmiah Sistem Informasi*, 5(1). <https://doi.org/10.29103/sisfo.v5i1.4849>
- Malik, Juliana, & Widyasella. (2020). Perbandingan Metode Eksponential Smoothing dan Arima: Studi pada Perusahaan Barang Konsumsi di Indonesia. *Moneter: Jurnal Akuntansi Dan Keuangan*, 7(2), 180–185.
- Muthahharah. (2020). Peramalan Indeks Saham Syariah Indonesia Menggunakan Autoregressive Integrated Moving Average (ARIMA). *Jurnal Matematika Dan Statistika Serta Aplikasinya (MSA)*, 7(2).
- Rezaldi, D. A., & Sugiman. (2021). Peramalan Metode ARIMA Data Saham PT. Telekomunikasi Indonesia. *PRISMA, Prosiding Seminar Nasional Matematika 4*, 611-620
- Setiawan, D., Stefani, K., Shandy, Y. J., & Patra, C. A. F. (2023). Sistem Analisa Harga Saham Menggunakan Algoritma Long Short Term Memory (LSTM). *Media Informatika*, 21(3), 264–279. <https://doi.org/10.37595/mediainfo.v21i3.159>
- Setiawan, L., Susanti, D., & Riaman, R. (2023a). Analisis Perbandingan Hasil Peramalan Harga Saham Menggunakan Model Autoregressive Integrated Moving Average dan Long Short Term Memory. *Jurnal Matematika Integratif*, 19(2), 223. <https://doi.org/10.24198/jmi.v19.n2.42164.223-234>
- Shumway, R. H., & Stoffer, D. S. (2017). *ARIMA Models*. Springer Texts in Statistics. (75–163). Springer. [https://doi.org/10.1007/978-3-319-52452-8\\_3](https://doi.org/10.1007/978-3-319-52452-8_3)
- Trydini & Huda. (2023). Prediksi Harga Saham Menggunakan Model Autoregressive Integrated Moving Average dengan Innovational Outlier. *Buletin Ilmiah Math. Stat. dan Terapannya*, 12(1), 1–10.
- Woodward, W. A., Sadler, B. P., & Robertson, S. (2022). *Time Series for Data Science*. Boca Raton: CRC Press.