

Uji Performa Prediksi Metode Autoregressive Fractionally Integrated Moving Averages Dan Long Short-Term Memory Dengan Data Saham Dua Perusahaan Bank

Berli Suharmanto¹, Iin Ernawati²

Program Studi S1 Informatika / Fakultas Ilmu Komputer
Universitas Pembangunan Nasional Veteran Jakarta

Jl. RS. Fatmawati Raya, Pd. Labu, Kec. Cilandak, Kota Depok, Daerah Khusus Ibukota Jakarta 12450
berls@upnvj.ac.id¹, iinernawati@upnvj.ac.id²

Abstrak. Saham adalah salah satu cara untuk orang berinvestasi untuk jangka panjang. Data saham dapat digunakan untuk analisa algoritma untuk memperoleh informasi nilai prediksi. Dalam penelitian ini algoritma yang digunakan untuk untuk mendapatkan model prediksi adalah metode *Auto Regressive Fractionally Integrated Moving Averages* (ARFIMA) dan *Long Short-Term Memory* (LSTM). Data saham yang digunakan adalah data saham dari IDX dengan data saham Bank Raya Indonesia Tbk. dan Bank IBK Indonesia Tbk. dalam periode September 2019 sampai Desember 2022 dengan data *Closing* atau penutupan sebagai fiturnya. Hasil pengolahan dari model ARFIMA terbaik adalah model ARFIMA(8,0.5,0) dari data BRI dengan SMAPE sebesar 5.57% dan model ARFIMA(4,0.5,0) dari data Bank IBK Indonesia dengan SMAPE sebesar 23.31%. Untuk hasil terbaik LSTM BRI adalah 1.61% dengan 150 *epoch* dan LSTM Bank IBK Indonesia adalah 2.22% dengan 300 *epoch*. Model terbaik yang dihasilkan adalah model LSTM dengan 150 *epoch* untuk BRI dan model LSTM dengan 300 *epoch*. Dari hasil penelitian tersebut model LSTM lebih optimal dan akurat dibandingkan dengan model ARFIMA.

Kata Kunci: Saham, *Forecasting*, ARFIMA, LSTM, Prediksi

1 Pendahuluan

Investasi saham adalah cara untuk memasukkan uang ke dalam sesuatu dengan harapan menghasilkan keuntungan di kemudian hari. Ada kemungkinan bagi investor untuk mengalami kerugian atau kehilangan uangnya, karena imbalan yang diprediksi bukan tanpa risiko dan ukurannya tidak dapat ditentukan [1].

Tindakan berinvestasi dalam instrumen keuangan (surat berharga), seperti saham, obligasi, reksa dana, derivatif, berjangka, dan opsi, dikenal sebagai pasar modal. Mengingat beragamnya investasi yang tersedia, sangat penting bagi setiap investor untuk menyadari bahaya saat ini dan potensi masa depan. Tabungan harus diganti dengan investasi agar setiap investor pasar saham dapat menggunakan kekayaannya sebagai jaminan untuk masa depan [2].

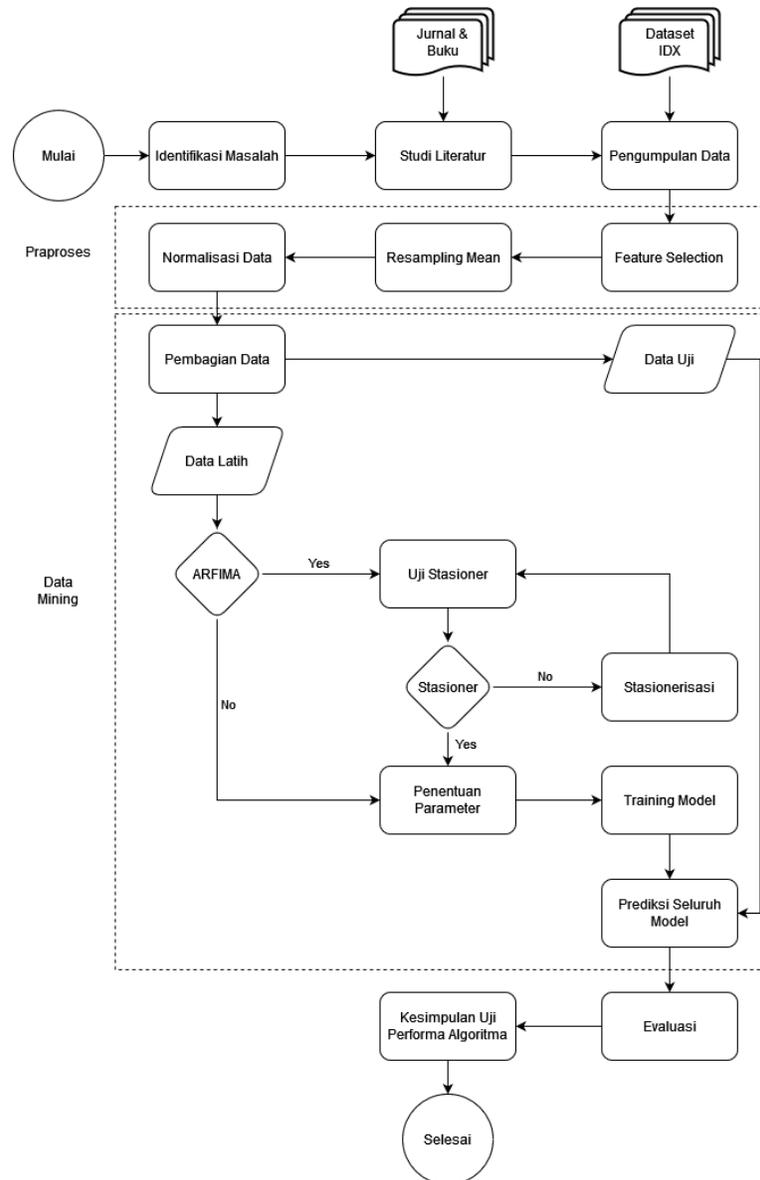
Investor saham harus memiliki pertimbangan yang matang dalam bertransaksi saham di pasar modal. Membuat keputusan investasi adalah tugas yang membutuhkan dua pertimbangan signifikan bagi setiap investor, serta eksekusi yang cermat. Untuk membuat pilihan terbaik dalam investasi saham, perlu untuk sepenuhnya menganalisis semua elemen yang relevan. Investor harus selalu mewaspadai elemen kunci yang mempengaruhi investasi pasar modal. Behavioral finance adalah salah satu ilmu yang dapat digunakan investor untuk membantu mereka memilih pasar saham yang baik dengan bijak [3]

Memprediksi saham adalah salah satu masalah yang paling sulit dalam analisis data time series. Dari sektor keuangan suatu perusahaan bagaimana cara memperkirakan perubahan kinerja saham secara akurat. Karena kompleksitas pasar dan sifatnya yang dinamis, serta banyak elemen implisit yang saling berhubungan yang ikut berperan, memprediksi kinerja saham adalah tugas yang menantang [4].

Deep learning banyak digunakan di berbagai domain akademik dan situasi dunia nyata seperti prediksi saham sebagai hasil dari kemajuan berkelanjutan di bidang kecerdasan buatan. Karena popularitas neural network seperti deep learning yang digunakan dalam pembuatan model prediksi saham juga telah berkembang dan ditingkatkan [5]. Dalam penelitian terdahulu yang dilakukan oleh Fajar Akbardi-pura yang menghasilkan akurasi prediksi data saham ICBP dengan menggunakan ARIMA(0,1,0) dan LSTM sebesar 0,8% [6]. Penelitian lainnya adalah prediksi saham farmasi dengan LSTM oleh Ardiyan Augusta dengan RMSE sebesar 1,9879 [7]. Penelitian yang dilakukan oleh

Puspita Kartikasari dengan data Bank Indonesia algoritma ARFIMA (0,0.499,5) memiliki nilai SMAPE 1,23% [8].

2 Metode Penelitian



Gambar. 1. Tahapan Metode Penelitian

2.1 Identifikasi Masalah

Penelitian ini akan dibatasi dengan mempersempit ruang lingkup lebih spesifiknya karena subjek permasalahan dari penelitian ini adalah data saham, maka data saham yang digunakan hanya data saham dari Bank Rakyat Indonesia Tbk. dan Bank IBK Indonesia Tbk. dengan membandingkan hasil dari evaluasi menggunakan metode ARFIMA dan LSTM.

2.2 Studi Literatur

Tahapan penelitian ini mencari teori-teori berdasarkan buku dan jurnal yang terkait mengenai saham, deep learning, LSTM, ARFIMA, sampai dengan SMAPE dan RMSE mengenai informasi dan rumusan dari teori yang telah dijabarkan untuk melakukan perhitungan sebagai hasil dari evaluasi dari metode yang digunakan dalam pembuatan model deep learning. Tahapan ini merupakan tahapan yang penting sebagai acuan penelitian mulai dari mengetahui bagaimana suatu metode bekerja dan bagaimana metode tersebut dan cara evaluasinya itu dilakukan komputasi untuk mendapatkan angka yang menjadi acuan dari proses prediksi suatu model [9]. Dari studi literatur ini didapatkan informasi untuk menopang metode penelitian.

2.3 Pengumpulan Data

Proses pengumpulan data adalah komponen penting pertama dari sistem yang akan dibangun. Data dapat diperoleh dari sumber luar, melalui penyedia data, atau melalui penelitian internal. Data yang digunakan adalah data saham yang diambil dari situs IDX Indonesia yang menyediakan data saham perusahaan-perusahaan di Indonesia yang diperbaharui setiap ada transaksi saham yang berlangsung. Dari data saham ini dapat diperoleh bahwa bentuk datanya adalah *time series*.

Tahapan penelitian ini adalah melakukan pencarian terhadap data saham yang akan dilakukan pembuatan model prediksi. Pada tahapan ini digunakan data time series menggunakan data saham dari IDX untuk mendapatkan data saham dari perusahaan-perusahaan yang ada di Indonesia. Data saham yang diambil dari IDX ini adalah data saham perusahaan yang terdapat di Indonesia pada Periode Januari 2022 sampai dengan Oktober 2022 berdasarkan harian transaksi saham.

Dalam pengumpulan data ini, data yang akan digunakan adalah data dari perusahaan Bank Rakyat Indonesia (Persero) Tbk. dan Bank IBK Indonesia Tbk. dengan kolom-kolom antara lain Kode Saham, Nama Perusahaan, Remarks, Sebelumnya, Open Price, First Trade, Tertinggi, Terendah, Penutupan, Selisih, Volume, Nilai, Frekuensi, Index Individual, Listed Shares, Offer, Offer Volume, Bid, Bid Volume, Last Trading Date, Tradeable Shares, Weight for Index, Foreign Sell, Foreign Buy, Non Regular Volume, Non Regular Value, dan Non Regular Frequency.

2.4 Praproses Data

Tahapan penelitian ini melakukan beberapa proses data sebelum dilakukan pembuatan model dengan melakukan resampling mean, uji stasioner, stasionerisasi, dan normalisasi data dengan MinMaxScaler. Tahapan ini akan memudahkan proses latih data serta dapat mengurangi waktu komputasi dari model.

2.4.1 Feature Selection

Setelah ditelaah dari jurnal penelitian terdahulu, atribut yang akan digunakan pada penelitian ini adalah Penutupan karena merupakan harga terakhir pada pasar di hari tersebut [11]. Fitur penutupan digunakan sebab harga penutupan saham adalah harga yang tidak akan berubah lagi dan akan menjadi harga pembuka pada hari transaksi saham selanjutnya.

2.4.2 Resampling Mean

Tahapan ini dilakukan dengan mengubah data yang perhari transaksi jual beli saham menjadi rata-rata transaksi perbulan. Diubahnya data menjadi mean bertujuan untuk mendapatkan insight laju penjualan saham pada bulan tertentu karena data yang digunakan merupakan atribut penutup [12].

2.4.3 Normalisasi Data

Untuk mengubah beberapa variabel selama pemrosesan data sehingga memiliki rentang nilai yang disesuaikan untuk tujuan penyederhanaan analisis statistik, normalisasi sangat penting. MinMax Scaling adalah metode normalisasi yang paling sederhana, dan digunakan untuk mengubah data menjadi informasi dengan rentang nilai antara 0 dan 1. Teknik ini membuat hubungan antara informasi historis dan prosedur yang sedang berjalan sehingga data menjadi

seragam [13].

2.4.4 Pembagian Data

Pada tahapan ini dilakukan pembagian data antara data latih dan data uji dengan penentuan target dan atributnya. Pembagian data akan menggunakan metode hold out cara memisahkan data uji dan data latih berdasarkan tanggal sebagai index [14].

2.4.5 Uji stasioner

Tahapan ini dilakukan dengan tujuan mengetahui apakah data saham yang digunakan sudah stasioner atau belum stasioner. Tahapan ini dilakukan untuk penggunaan metode ARFIMA karena metode ini perlu data yang stasioner. Stasioner yang dimaksud adalah bentuk garis lurus pada plot grafik dataset saham. Apabila grafik tidak berada di garis lurus, maka perlu dilakukan stasionerisasi. Jika sudah ada pada garis lurus, maka data saham sudah stasioner. Perlu diketahui juga, untuk uji stasioner hanya dilakukan pada metode ARFIMA saja karena uji stasioner bertujuan untuk menentukan parameter ARFIMA yang digunakan [8].

2.4.6 Stasionerisasi

Dalam pembuatan model ARFIMA, data time series yang tidak stasioner harus dilakukan stasionerisasi dengan cara differencing. Tahapan ini menghitung nilai selisih dari nilai observasi dari data time series. Selisih ini perlu dilihat dengan augmented dickey fuller test pada tahapan uji stasioner untuk melihat apakah sudah kurang dari 0.05. Apabila masih belum stasioner, maka masih perlu dilakukan differencing kembali. Apabila sudah stasioner, maka bisa langsung dilakukan pembagian data untuk dilatih pada model yang akan dibuat [15].

2.5 Penentuan Parameter

Tahapan ini dilakukan dengan menentukan parameter yang sekiranya sesuai untuk mendapatkan hasil yang optimal dari metode ARFIMA dan LSTM. Metode ARFIMA dapat menggunakan parameter nilai desimal $0 < p < 1$ dan $p > 1$. Parameter ARFIMA ini sendiri didapatkan berdasarkan plot PACF dan ACF untuk dilihat lag yang signifikan pada saat stasioner untuk p (jumlah autoregresif) dan q (jumlah differensi non-seasonal) [8]. Apabila dilakukan differencing sekali untuk stasionerisasi, maka parameter d adalah 1 dan begitu juga seterusnya. Metode LSTM dapat menggunakan parameter fungsi LSTM epoch. Berdasarkan penelitian-penelitian terkait sebelumnya, parameter yang digunakan akan mempengaruhi hasil dan waktu komputasi dalam proses latih data dari pembuatan suatu model [9].

2.6 Training Model

Untuk pemodelan ARFIMA sendiri, hanya perlu melakukan fractional differencing pada data yang akan digunakan kemudian dilatih dengan metode SARIMAX dengan parameter sesuai yang telah didapatkan pada penentuan parameter. Untuk pemodelan LSTM dilakukan dengan inisialisasi parameter berupa epoch. Model LSTM akan berjalan di atas gates, yaitu forget gate layer, input layer, dan tanh layer. Dari pengujian ini data akan berhenti pada epoch yang ditentukan pada parameter sebelumnya. Pembuatan model akan dilakukan untuk melihat hasil penggunaan parameter yang paling optimal dan pencatatan waktu komputasi yang diperlukan pada model yang menggunakan LSTM.

2.7 Prediksi Kedua Model

Setelah proses latih, dilakukan prediksi dengan menggunakan kedua model terbaik yang sudah dibuat. Prediksi dilakukan dengan melihat plot grafik data saham uji dibandingkan hasil forecasting dari model prediksi yang dibuat [5].

2.8 Evaluasi

Tahapan ini bertujuan melihat perbandingan antara kedua model yang dibuat karena dari plot grafik saja tidak akan mendapat insight dari informasi hasil prediksi dari model. Tahapan ini dilakukan dengan melihat metrik SMAPE dari kedua model [8].

2.9 Kesimpulan Uji Performa Algoritma

Tahapan terakhir ini, yaitu melihat hasil dari evaluasi yang telah dilakukan dan mempertimbangkan model terbaik berdasarkan metrik SMAPE dengan memperhatikan juga plot grafik yang membandingkan pertumbuhan sebenarnya

dengan pertumbuhan yang diramal oleh model. Metode yang memiliki SMAPE yang lebih kecil dari metode yang satunya akan menjadi metode yang paling optimal untuk menyelesaikan masalah prediksi saham dengan data time series jangka panjang.

3 Hasil dan Pembahasan

Data yang digunakan dalam penelitian ini adalah data saham yang diperoleh dari website IDX. Website ini merupakan website resmi regulator dan pengurus perdagangan pada Pasar Modal Indonesia yang dimiliki oleh Bursa Efek Indonesia [16]. Penelitian ini menggunakan 2 data saham perusahaan bank yang digunakan dalam 3 tahun terakhir yaitu data Bank Rakyat Indonesia Tbk. dan Bank IBK Indonesia Tbk. Data kedua bank tersebut memiliki 27 kolom, yaitu Kode Saham, Nama Perusahaan, Remarks, Sebelumnya, Open Price, First Trade, Tertinggi, Terendah, Penutupan, Selisih, Volume, Nilai, Frekuensi, Index Individual, Listed Shares, Offer, Offer Volume, Bid, Bid Volume, Last Trading Date, Tradeable Shares, Weight for Index, Foreign Sell, Foreign Buy, Non Regular Volume, Non Regular Value, dan Non Regular Frequency. Data berjumlah masing-masing 1029 dan 862.

3.1 Praproses Data

Setelah data didapatkan, dilakukan praproses data dengan beberapa langkah-langkah. Untuk pengerjaan praproses data ini berupa rentetan proses yang berurutan berupa antara lain:

3.1.1 Normalisasi Data

Sebelum data dibagi, data yang digunakan harus dilakukan perubahan terlebih dahulu. Perubahan ini adalah berupa mengubah data yang berdasarkan satu hari menjadi satu bulan. Data diubah menjadi data penutup perbulan dengan isian rata-rata karena yang akan diobservasi adalah laju pendapatan bukan jumlah pendapatan [17]. Berikut merupakan 5 data pertama yang telah diubah ke dalam bentuk perbulan terlihat pada Tabel 3-4.

Tabel 3. Data Bank Rakyat Indonesia (Persero) Tbk. Perbulan.

Tanggal Perdagangan Terakhir	Penutupan
9/30/2019	4202.380952
10/31/2019	4053.043478
11/30/2019	4125.714286
12/31/2019	4290.000000
1/31/2020	4550.000000

Tabel 4. Data Bank IBK Indonesia Tbk. Perbulan

Tanggal Perdagangan Terakhir	Penutupan
9/30/2019	191.067
10/31/2019	181.435
11/30/2019	174.095

12/31/2019	141.789
1/31/2020	156.045

Setelah data diubah menjadi format perbulan, data memiliki jumlah total 40 data tiap dataset dan akan dilakukan normalisasi dengan MinMax Scaler. Normalisasi ini dilakukan dengan cara menghitung selisih data dengan data terendah dibagi selisih data tertinggi dengan data terendah [13]. Berikut merupakan hasil normalisasi data dari kedua data bank dapat dilihat pada Tabel 5-6.

Tabel 5. Data Bank Rakyat Indonesia (Persero) Tbk. normalisasi

Tanggal Perdagangan Terakhir	Close
2019-09-30	0.707417
2019-10-31	0.644223
2019-11-30	0.674974
2019-12-31	0.744493
2020-01-31	0.854514

Tabel 6. Data Bank IBK Indonesia Tbk. normalisasi

Tanggal Perdagangan Terakhir	Close
9/30/2019	0.17704
10/31/2019	0.16
11/30/2019	0.14701
12/31/2019	0.08986
1/31/2020	0.11508

3.1.2 Uji Stasioner dan Stasionerisasi

Tahapan ini dilakukan dengan melakukan Augmented Dickey Fuller Test dan mengecek apakah nilai p-value sudah lebih kecil dari 0.05 dengan menggunakan persamaan (20). Apabila tidak, maka perlu dilakukan differencing pada data latihnya. Berikut merupakan tabel p-value kedua data bank dapat dilihat pada tabel 7-9.

Tabel 7. P-value metode pembagian data pertama.

Diffensiasi ke-N	BRI	Bank IBK Indonesia
------------------	-----	--------------------

0	0.5710386815654017	0.4894135557466029
1	0.023722727478323914	0.001439254938209262

Tabel 8. *P-value* metode pembagian data kedua.

Diffensiasi ke-N	BRI	Bank IBK Indonesia
0	0.006325424864391016	0.2963657640402307
1	Sudah stasioner	0.9935911006407631
2	Sudah stasioner	0.04419979997246791

Tabel 9. *P-value* metode pembagian data ketiga

Diffensiasi ke-N	BRI	Bank IBK Indonesia
0	0.21881147863093942	0.734207518448737
1	0.15511181849993977	0.037153189746917115
2	0.3111154660090656	Sudah stasioner

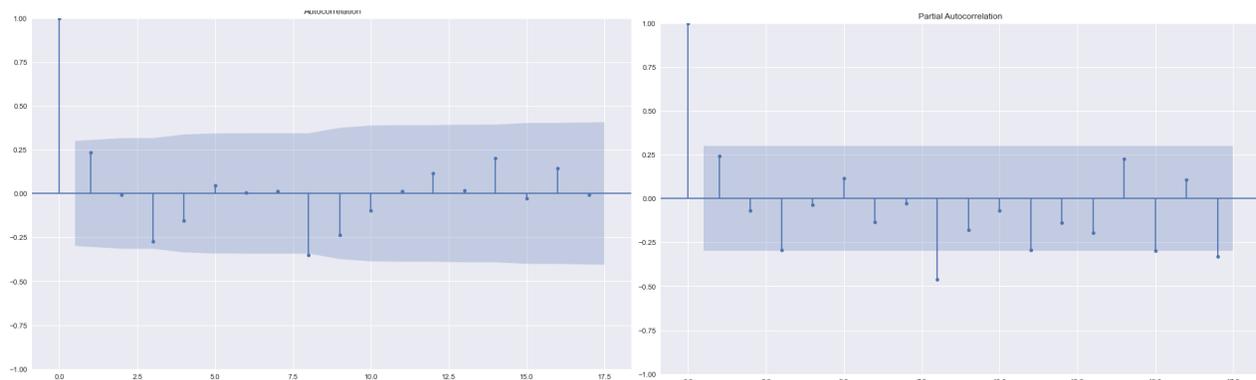
3.2 Penentuan Parameter

Pada tahapan ini untuk setiap metode berbeda cara menentukan parameternya. Untuk tahapan penentuan parameter dapat menjadi antara lain:

3.2.1 Parameter ARFIMA

Setelah dilakukan uji stasioneritas, dapat dilihat bahwa kedua data tidak ada yang stasioner dan perlu dilakukan proses differencing. Pada tahapan stasioneritas inilah penelitian ini mendapatkan parameter d untuk parameter ARFIMA nya. Nilai parameter d dapat ditentukan dengan menghitung berapa kali data di-differencing hingga menjadi stasioner.

Setelah itu, melakukan plotting PACF dan ACF untuk melihat lag pada data latih. Berikut merupakan plot PACF dan ACF data latih dapat dilihat pada Gambar 2.



Gambar 2. ACF dan PACF BRI pembagian pertama

3.2.2 Parameter LSTM

Pada metode LSTM, penelitian ini akan membagi model dari tiap pembagian data berapa epoch yang digunakan dan pada seberapa besar pengaruh epoch atau iterasi pelatihan model. Untuk penggunaan epoch terkecil adalah 50 karena menyesuaikan ukuran data dan mempermudah dalam pengamatan pengaruh penambahan epoch. Pembagian parameter LSTM dapat dilihat sesuai Tabel 10.

Tabel 10. Parameter LSTM

<i>Parameter</i>	Model 1	Model 2	Model 3	Model 4	Model 5
<i>unit</i>	64	64	64	64	64
<i>dense</i>	32	32	32	32	32
<i>dense</i>	32	32	32	32	32
<i>dense</i>	1	1	1	1	1
<i>optimizer</i>	adam	adam	adam	adam	adam
<i>learning rate</i>	0.001	0.001	0.001	0.001	0.001
<i>loss</i>	<i>mse</i>	<i>mse</i>	<i>mse</i>	<i>mse</i>	<i>mse</i>
<i>epoch</i>	50	100	150	200	300
<i>batch size</i>	64	64	64	64	64

4.6. Evaluasi Model

Berikut merupakan hasil dari pemodelan ARFIMA dan LSTM.

Tabel 11. Perbandingan hasil SMAPE prediksi harga penutupan saham

Model	SMAPE	SMAPE(%)	Waktu(detik)
BRI ARFIMA(8,0.5,0)	0.0557	5.57%	1.2
Bank IBK ARFIMA(4,0.5,0)	0.2331	23.31%	1.2
BRI LSTM 50 <i>epoch</i>	0.1119	11.19%	1.7
BRI LSTM 100 <i>epoch</i>	0.1141	11.41%	2.3
BRI LSTM 150 <i>epoch</i>	0.0161	1.61%	2.9
BRI LSTM 200 <i>epoch</i>	0.0178	1.78%	3.3
BRI LSTM 300 <i>epoch</i>	0.0174	1.74%	4.4
Bank IBK LSTM 50 <i>epoch</i>	0.5670	5.67%	1.7
Bank IBK LSTM 100 <i>epoch</i>	0.5409	54.09%	2.3
Bank IBK LSTM 150 <i>epoch</i>	0.4695	46.95%	2.9
Bank IBK LSTM 200 <i>epoch</i>	0.3715	37.15%	3.3
Bank IBK LSTM 300 <i>epoch</i>	0.0222	2.22%	4.4

Berdasarkan Tabel 11 dapat dilihat setiap model memiliki nilai SMAPE yang berbeda-beda. Dapat dilihat juga berdasarkan hasil perhitungan SMAPE tersebut nilai SMAPE model ARFIMA lebih besar daripada model LSTM baik data penutupan BRI maupun Bank IBK. Hasil pengujian yang paling optimal adalah BRI LSTM 150 epoch pembagian data latih 80% dengan SMAPE sebesar 1,61% dan Bank IBK LSTM 300 epoch pembagian data latih 80% dengan SMAPE sebesar 2,22%.

4 Kesimpulan dan Saran

4.1 Kesimpulan

Hasil terbaik model ARFIMA untuk BRI adalah model ARFIMA(8,0.5,0) pada pembagian data latih 80% dengan hasil SMAPE sebesar 0,0557 atau sekitar 5,57%. Hasil terbaik model ARFIMA untuk Bank IBK Indonesia adalah model ARFIMA(8,0.5,0) pada pembagian data latih 80% dengan hasil SMAPE sebesar 0,2331 atau sekitar 23,31%. Hasil terbaik model LSTM untuk BRI adalah model LSTM menggunakan 150 epoch pada pembagian data latih 80% dengan hasil SMAPE sebesar 0,0161 atau sekitar 1,61%. Hasil terbaik model LSTM untuk Bank IBK Indonesia adalah model LSTM menggunakan 300 epoch pada pembagian data latih 80% dengan hasil SMAPE sebesar 0,0222 atau sekitar 2,22%. Hal ini mengindikasikan algoritma LSTM merupakan model terbaik pada penelitian menggunakan data saham tersebut.

4.2 Saran

Menggunakan variasi kombinasi parameter seperti menambahkan unit LSTM dan menambah batch size menyesuaikan bentuk data yang digunakan untuk menentukan model optimal yang dapat menghasilkan harga prediksi saham dan nilai SMAPE yang lebih rendah dan akurat dengan menggunakan LSTM. Prediksi menggunakan ARFIMA disarankan hanya untuk digunakan pada jangka 2-3 waktu kedepan, karena setelah deret waktu tersebut hasil prediksi ARFIMA akan tidak begitu akurat jika dibandingkan dengan LSTM.

Referensi

- [1] A. Mustafa, "Analisis Keputusan Investasi Saham Dengan Dengan Pendekatan Price Earning Ratio (Per) Pada Pt Unilever Indonesia Tbk .," *Univ. Negeri Makassar*, pp. 1–13, 2020.
- [2] I. Nuzula Agustin and F. Lysion, "Isnaini Nuzula Agustin 1 Fiona Lysion 2," *Univ. Int. Batam*, vol. 1, no. 1, 2021, [Online]. Available: <https://journal.uib.ac.id/index.php/combinas>
- [3] D. A. Fauzi, "Faktor Penentu Pengambilan Keputusan Investasi Saham," *Univ. Islam Indones.*, vol. 2507, no. 1, pp. 1–9, 2020, [Online]. Available: <https://doi.org/10.1016/j.solener.2019.02.027%0Ahttps://www.golder.com/insights/block-caving-a-viable-alternative/%0A???>
- [4] Y. Gu, T. Shibukawa, Y. Kondo, S. Nagao, and S. Kamijo, "Prediction of stock performance using deep neural networks," *Appl. Sci.*, vol. 10, no. 22, pp. 1–20, 2020, doi: 10.3390/app10228142.
- [5] Z. Hu, Y. Zhao, and M. Khushi, "A survey of forex and stock price prediction using deep learning," *Appl. Syst. Innov.*, vol. 4, no. 1, pp. 1–30, 2021, doi: 10.3390/ASI4010009.
- [6] F. Akbardipura, "Perbandingan Performa Peramalan Harga Saham 5 Perusahaan Pada Indeks LQ45 Menggunakan Autoregressive Integrated Moving Average Dan Long Short – Term Memory," *Univ. Pembang. Nas. Veteran Jakarta*, pp. 1–60, 2021.
- [7] A. Agusta, "Prediksi Pergerakan Harga Saham Pada Sektor Farmasi Menggunakan Algoritma Long Short-Term Memory," *Univ. Pembang. Nas. Veteran Jakarta*, vol. D, no. 2, pp. 1–58, 2021.
- [8] P. Kartikasari, "Prediksi Harga Saham PT. Bank Negara Indonesia dengan Menggunakan Model Autoregressive Fractional Integrated Moving Average (ARFIMA)," *J. Stat.*, vol. 8, no. 1, pp. 1–7, 2020.
- [9] N. Jing, Z. Wu, and H. Wang, "A hybrid model integrating deep learning with investor sentiment analysis for stock price prediction," *Expert Syst. Appl.*, vol. 178, no. May 2020, p. 115019, 2021, doi: 10.1016/j.eswa.2021.115019.
- [10] V. D. Ta, C. M. Liu, and D. A. Tadesse, "Portfolio Optimization-Based Stock Prediction Using Long-Short Term Memory Network in Quantitative Trading Van-Dai," *Appl. Sci.*, vol. 10, no. 2, 2020.
- [11] W. Lu, J. Li, J. Wang, and L. Qin, "A CNN-BiLSTM-AM method for stock price prediction," *Neural Comput. Appl.*, vol. 33, no. 10, pp. 4741–4753, 2021, doi: 10.1007/s00521-020-05532-z.
- [12] T. A. Borges and R. Neves, *Financial Data Resampling for Machine Learning Based Trading Application to Cryptocurrency Markets*. Warsaw: SpringerBriefs in Applied Sciences and Technology, 2021. [Online]. Available: <https://doi.org/10.1007/978-3-030-68379-5%0A©>
- [13] T. Agrawal, *Hyperparameter Optimization in Machine Learning: Make Your Machine Learning and Deep*

- Learning Models More Efficient*. Bangalore: Apress, 2021. doi: <https://doi.org/10.1007/978-1-4842-6579-6> ISBN-13.
- [14] S. Chen and C. Zhou, "Stock Prediction Based on Genetic Algorithm Feature Selection and Long Short-Term Memory Neural Network," *IEEE Access*, vol. 9, pp. 9066–9072, 2021, doi: 10.1109/ACCESS.2020.3047109.
- [15] D. Ambach and O. Ambach, "Forecasting the Oil Price with a Periodic Regression ARFIMA-GARCH Process," *Proc. 2018 IEEE 2nd Int. Conf. Data Stream Min. Process. DSMP 2018*, pp. 212–217, 2018, doi: 10.1109/DSMP.2018.8478447.
- [16] "IDX Data Services Portal," 2022. <https://data.idx.co.id/> (accessed Jan. 24, 2023).
- [17] M. Saleh, E. Grivel, and S. M. Omar, "Jeffrey's divergence between ARFIMA processes," *Digit. Signal Process. A Rev. J.*, vol. 82, pp. 175–186, 2018, doi: 10.1016/j.dsp.2018.06.013.