

Penerapan Model ARFIMA-LSTM Menggunakan Variasi Estimasi Parameter Pembeda Dalam Meramalkan data IHPBI

Trieka Nurfadilah Harun¹, Ismail Djakaria², Nisky Imansyah Yahya^{2*}, Salmun K. Nasib¹, and Isran K. Hasan¹

¹*Program Studi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Gorontalo, Gorontalo, Indonesia*

²*Program Studi Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Gorontalo, Gorontalo, Indonesia*

Abstrak

Indeks Harga Perdagangan Besar Indonesia (IHPBI) merupakan indikator penting dalam mengukur perkembangan ekonomi, khususnya pada sektor pertanian yang memiliki pengaruh besar terhadap daya beli masyarakat. Fluktuasi harga di sektor ini berdampak langsung pada kesejahteraan konsumen dan produsen, sehingga diperlukan metode peramalan yang akurat. Penelitian ini bertujuan untuk meramalkan IHPBI sektor pertanian menggunakan pendekatan *hybrid Autoregressive Fractionally Integrated Moving Average* (ARFIMA) dan *Long Short-Term Memory* (LSTM), serta membandingkan performa metode estimasi parameter pembeda terbaik. Model ARFIMA digunakan untuk menangani komponen stasioner dan pola jangka panjang melalui differensiasi pecahan, sedangkan LSTM digunakan untuk menangkap pola *nonlinier* dalam data. Keterbaruan dalam penelitian ini adalah membandingkan parameter pembeda terbaik yaitu *Local Whittle* dan *Rescaled Range Statistics* dalam *hybrid ARFIMA-LSTM*. Hasil dari penelitian yaitu peramalan menunjukkan tren naik IHPBI sektor pertanian selama 12 bulan ke depan. Metode estimasi parameter pembeda terbaik dalam model ARFIMA adalah *Rescaled Range Statistics* dengan nilai sebesar 0,322. Model *hybrid* ini menghasilkan nilai MAPE sebesar 0,6337853%, yang menunjukkan tingkat akurasi sangat tinggi.

Kata Kunci: ARFIMA; IHPBI; LSTM; Parameter Pembeda

Abstract

Indonesia's Wholesale Price Index (WPI) is an important indicator for measuring economic development, particularly in the agricultural sector, which significantly affects public purchasing power. Price fluctuations in this sector directly impact the welfare of both consumers and producers, thus requiring accurate forecasting methods. This study aims to forecast the WPI in the agricultural sector using a hybrid approach combining the *Autoregressive Fractionally Integrated Moving Average* (ARFIMA) and *Long Short-Term Memory* (LSTM), and to compare the performance of different differencing parameter estimation methods. The ARFIMA model is employed to handle stationary components and long-term dependencies through fractional differencing, while the LSTM model captures nonlinear patterns in the data. The novelty of this study lies in the comparison of two differencing parameter estimation methods: Local Whittle and Rescaled Range Statistics within the hybrid ARFIMA-LSTM framework. The forecasting results indicate an upward trend in the agricultural WPI over the next 12 months. The best-performing differencing parameter estimation method in the ARFIMA model is the *Rescaled Range Statistics* method with a value of 0.322. This hybrid model yields a MAPE value of 0.6337853%, indicating a very high level of forecasting accuracy, indicating a very high level of forecasting accuracy.

Keywords: ARFIMA; WPI; LSTM; Differencing Parameter

Copyright © 2025 by Authors, Published by JRMM Group. This is an open access article under the CC BY-SA License (<https://creativecommons.org/licenses/by-sa/4.0>)

*Corresponding author. E-mail: nisky@ung.ac.id

1 Pendahuluan

Pertumbuhan ekonomi di Indonesia menunjukkan perkembangan yang cukup pesat dan mempengaruhi cara pandang masyarakat dalam bidang ekonomi, khususnya terkait Indeks Harga Perdagangan Besar (IHPB) [1]. IHPB merupakan salah satu indikator ekonomi yang digunakan untuk mengamati perkembangan harga pada tingkat grosir terhadap komoditas yang diperdagangkan di suatu wilayah [2]. Salah satu komponennya adalah sektor pertanian yang memiliki pengaruh besar terhadap perekonomian Indonesia. Sektor ini berperan penting dalam pembangunan ekonomi, penstabil harga, serta sebagai sumber devisa nonmigas [3].

Badan Pusat Statistik (BPS) melaporkan bahwa rata-rata IHPBI sepanjang tahun 2023 mengalami kenaikan sebesar 4,20% dibandingkan tahun sebelumnya, yaitu dari 111,23 pada tahun 2022 menjadi 115,91 pada tahun 2023. Pada Agustus 2024, BPS juga mengumumkan bahwa terjadi kenaikan IHPB Umum Nasional secara tahunan sebesar 2,82% dibandingkan Agustus 2023. Kenaikan tertinggi tercatat pada sektor pertanian pada bulan Desember 2023 sebesar 1,57%. Perubahan harga di sektor pertanian ini dapat berdampak signifikan terhadap kesejahteraan konsumen dan produsen, terutama dalam kaitannya dengan daya beli masyarakat.

Berbagai penelitian telah dilakukan terkait peramalan IHPBI. Hartini dkk [4] menggunakan metode *Long Short-Term Memory* (LSTM) dan menemukan bahwa sektor pertanian memberikan hasil akurasi terbaik. Setyawan dkk [3] menggunakan model *Autoregressive Integrated Moving Average* (ARIMA) dan memprediksi adanya peningkatan harga pasar di sektor pertanian. Hasan dkk [5] membandingkan dua metode estimasi parameter pembeda (d), yaitu GPH dan R/S, dan menyimpulkan bahwa estimasi R/S memiliki akurasi lebih tinggi. Zulfikar [6] menggunakan algoritma *Backpropagation* dan memperoleh hasil bahwa IHPBI per sektor cenderung mengalami peningkatan yang stabil.

Namun, sebagian besar penelitian tersebut belum memperhatikan karakteristik *long memory*, non-linieritas, serta ketidakpastian yang terdapat dalam data IHPBI. Hal ini dapat mengurangi akurasi hasil peramalan. Oleh karena itu, diperlukan metode yang mampu menangani karakteristik tersebut secara simultan untuk menghasilkan prediksi yang lebih akurat.

Model *Autoregressive Fractionally Integrated Moving Average* (ARFIMA) merupakan pengembangan dari ARIMA yang memungkinkan parameter integrasi (d) bernilai pecahan (*fractional*) sehingga cocok untuk data dengan pola *long memory* [7]. Di sisi lain, LSTM adalah jenis jaringan saraf tiruan yang efektif dalam mempelajari hubungan nonlinier dan mengatasi masalah *vanishing gradient* dalam data deret waktu [8], [9].

Penggabungan (hybrid) antara ARFIMA dan LSTM menawarkan pendekatan yang lebih kuat untuk menangani data deret waktu kompleks. ARFIMA digunakan untuk menangkap pola linear dan komponen stasioner, sementara LSTM mampu mengenali pola nonlinier dari residual model ARFIMA. Oleh karena itu, penelitian ini bertujuan mengimplementasikan model *hybrid* ARFIMA-LSTM menggunakan variasi estimasi parameter d dalam meramalkan nilai IHPBI.

2 Metodologi

2.1 Data dan Sumber Data

Data pada penelitian ini berupa data sekunder tentang Indeks Harga Perdagangan Besar Indonesia (IHPB) yang diperoleh dari website BPS [2]. Data yang digunakan merupakan data bulanan dari sektor pertanian terdiri dari 300 data mulai dari bulan Januari tahun 2000 sampai bulan Desember tahun 2024. Pada penelitian ini data dibagi menjadi dua, yaitu data latih yang digunakan untuk menghasilkan model terdiri dari 210 data dimulai dari Januari 2000-Juli 2017 dan data uji yang digunakan sebagai validitas hasil peramalan terdiri dari 90 data dimulai dari bulan Juli 2017 sampai bulan Desember 2024. Data tersebut diolah menggunakan *software RStudio* [10].

2.2 ARFIMA

2.2.1 Identifikasi Long Memory

Long memory adalah proses stasioner yang menunjukkan adanya hubungan statistik yang mengkaji hubungan jangka panjang antara nilai terkini dan nilai pada periode berbeda dalam data seri waktu.[5]. Long memory diihat pada plot *Autocorrelation Function* (ACF) yang menurun dengan cara bertahap memiliki karakteristik *hiperbolic*. Selain plot ACF, adanya komponen jangka panjang melalui pengujian dengan statistik Hurst. Kriteria nilai statistik *Hurst* [11] :

- $H = 0.5$, menunjukkan data bersifat acak.
- $0 < H < 0.5$, menunjukkan data bersifat *short memory*.
- $0.5 < H < 1$, menunjukkan data bersifat *long memory*

2.2.2 Uji Stasioner

Model runtun waktu stasioner adalah rangkaian observasi dimana rata-rata (*mean*) dan variansi variabelnya tidak dipengaruhi oleh perubahan waktu. Dalam hal ini, rata-rata dan variansi runtun waktu tetap stabil, serta tidak menunjukkan fluktuasi secara berkala. Uji stasioner merupakan langkah awal yang penting dalam pemodelan data runtun waktu. Pengujian ini dilakukan untuk mengidentifikasi keberadaan akar unit dalam deret waktu. Uji *Dickey-Fuller* (ADF) merupakan salah satu pendekatan metode yang sering dipergunakan dalam menguji stasioneritas. Uji Box-Cox dapat digunakan untuk mengatasi ketidakstasioneran data, khususnya dalam hal varian, sehingga kedua metode ini saling melengkapi dalam proses analisis data runtun waktu [12]

2.2.3 Estimasi Parameter Pembeda

1. **Metode Local Whittle (LW).** Metode estimasi *Local Whittle* diusulkan oleh Kuensch (1987) dan dimodifikasi oleh Robinson (1995). Metode ini merupakan parameter yang sering digunakan untuk estimasi parameter d . Estimasi parameter d pada local whittle dinotasikan dengan d_{LW} . Berikut persamaan metode estimasi parameter d *local whittle* [13].

$$\Gamma(d) = -\frac{1}{2\pi m} \sum_{j=1}^m f(\omega_j; d) \quad (1)$$

Keterangan :	
$\Gamma(d)$	Fungsi parameter d <i>local whittle</i> .
$2\pi m$	Faktor normalisasi.
$f(\omega_j; d)$	Fungsi spektral model teoretik pada frekuensi ω_j .

2. **Metode Rescaled Range Statistics (R/S).** Parameter pendekatan lain yang dapat digunakan selain metode *Local Whittle* (LW) untuk pengestimasian parameter d yaitu menggunakan metode estimasi parameter *R/S* atau disebut dengan statsistik *Hurst*. Statistik *R/S* tidak hanya digunakan untuk melihat adanya *long memory* tetapi bisa juga digunakan untuk mengestimasikan parameter d yang diperoleh menggunakan persamaan berikut [14]:

$$d_{R/S} = H - 0.5 \quad (2)$$

2.2.4 Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF)

1. **ACF.** Berdasarkan suryono dkk autokorelasi (ACF) mengukur sejauh mana hubungan antara nilai suatu data pada waktu tertentu dengan nilai-nilai pada periode sebelumnya (*lag*)[15]. Pengamatan waktu ke- t atau (Z_t) yang telah dilakukan proses stasioner pada data maka akan mempunyai nilai $mean E[Z_t] = \mu$ dan variansinya yaitu $VAR(Z_t) = E(Z_t - \mu)^2 = \sigma^2$ yang memiliki nilai tetap, serta

fungsi waktu $(t - s)$ kovariansnya didefinisikan dengan $COV(Z_t, Z_s)$. Kovariansi Z_t dan $G_t - k$ dituliskan sebagai [16] :

$$\rho_k = \frac{\gamma_k}{\gamma_0} \quad (3)$$

2. PACF . PACF, atau fungsi autokorelasi parsial, menggambarkan tingkat korelasi murni antara observasi pada waktu ke- t dengan observasi sebelumnya, tanpa dipengaruhi oleh nilai-nilai diantaranya. Rumus PACF dapat dinyatakan sebagai berikut [17].

$$\phi_{kk} = \text{corr}(Z_t, Z_{t-k} | Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}) \quad (4)$$

Keterangan :

- ϕ_{kk} : Fungsi autokorelasi parsial.
 k : Lag.
 Z_t : Nilai aktual pada data ke- t .

2.2.5 Pembentukan Model (ARFIMA)

ARFIMA adalah metode analisis yang dikembangkan dari model ARIMA Box-Jenkins. Metode ini bertujuan untuk melakukan prediksi terhadap data urutan waktu yang memiliki ciri keterkaitan jangka panjang *long memory* [18].

Granger dan Joyeux pada tahun 1980 pertama kali memperkenalkan model ARFIMA sebagai bentuk pengembangan dari model ARIMA. Berbeda dengan ARIMA, ARFIMA lebih sesuai untuk menganalisis data jangka panjang karena memiliki fleksibilitas yang tinggi dalam pemodelannya [19]. Model ARFIMA dengan urutan p, d, q , yang dinotasikan sebagai ARFIMA (p, d, q) , memiliki p dan q sebagai bilangan bulat tidak negatif, serta $0 < d < 0,5$. Model ini digunakan untuk menganalisis runtun waktu yang bersifat stasioner. Model ARFIMA untuk runtun waktu Z_t didefinisikan sebagai [16]:

$$\phi_p(B)(1 - B)^d Z_t = \theta_q(B)a_t \quad (5)$$

Keterangan :

- $\phi_p(B)$: Polinomial *autoregresif* ke- p .
 $\theta_q(B)$: Polinomial *moving average* ke- q .
 d : Parameter pembeda (bilangan pecahan).
 B : Operator *backshift*.
 a_t : *White noise*.
 $(1 - B)^d Z_t$: Operator pembeda pecahan.

2.2.6 Pemilihan Model Terbaik

Pemilihan Model Terbaik menggunakan *Akaike's Information Criterion* (AIC). AIC pertama kali diperkenalkan oleh Akaike untuk mengidentifikasi model dari Sekumpulan data digunakan, dan suatu model dianggap optimal apabila nilai AIC yang dihasilkan semakin kecil [20]. Rumus AIC yang dipakai dalam proses pemilihan model dapat dituliskan sebagai berikut:

$$AIC = \log \hat{\sigma}^2 + \frac{2k}{n} \quad (6)$$

Keterangan :

- $\log \hat{\sigma}^2$: Ukuran *likelihood*.
 k : Jumlah parameter.
 n : Banyak pengamatan.

2.2.7 Pengujian Kelayakan Model

Pengujian kelayakan model diterapkan guna memastikan bahwa model yang dikembangkan layak dilakukan dalam proses peramalan. Tujuan uji kelayakan adalah untuk memeriksa apakah data runtun waktu tersebut memenuhi asumsi yang menunjukkan karakteristik *white noise* atau tidak [21]. Hipotesis yang digunakan yaitu [16]:

- H_0 : $\rho_1 = \rho_2 = \dots = \rho_k = 0$ (*residual* bersifat *white noise*).
 H_1 : Minimal ada satu $\rho_k \neq 0$ (*residual* tidak bersifat *white noise*).

Untuk mengevaluasi apakah *residual* memiliki sifat *white noise*, digunakan *Ljung-Box* untuk pengujinya, berikut persamaanya:

$$Q = m(m+2) \sum_{k=1}^K (m-k)^{-1} \hat{\rho}_k^2 \quad (7)$$

- Keterangan :
 $\hat{\rho}_k$: Autokorelasi *residual* pada *lag* ke- k .
 m : Banyak data.
 K : Banyak maksimum *lag*.

Kriteria berdasarkan uji *Ljung-Box* adalah tolak H_0 jika $p_{value} < \alpha$.

2.2.8 Uji Linearitas

Uji linearitas adalah salah satu metode pengujian yang dapat mengetahui apakah data runtun waktu memiliki hubungan yang linear atau *nonlinear*. Uji Ramsey RESET merupakan salah satu pendekatan yang digunakan untuk menilai linearitas atau *nonlinearitas* pada suatu data [22]. Rumus uji linear Ramsey Reset diuraikan di bawah ini untuk menghitung uji statistik *Ramsey Reset* [23].

$$\text{RESET} = \frac{(e_t^T e_t - v_t^T v_t)/(k-1)}{(v_t^T v_t)/(n-k)} \quad (8)$$

Hipotesis yang digunakan untuk uji Ramsey Reset adalah sebagai berikut:

- H_0 : $a_1 = a_2 = \dots = a_k = 0$ (Data runtun waktu *linear*).
 H_1 : $a_k \neq 0$ (Data runtun waktu *non-linear*).

Kriteria yang digunakan berdasarkan uji *RESET* adalah tolak H_0 jika statistik uji *RESET* $> F_{(k-1, n-k)}$, yang artinya data runtun waktu mengandung pola *nonlinear*.

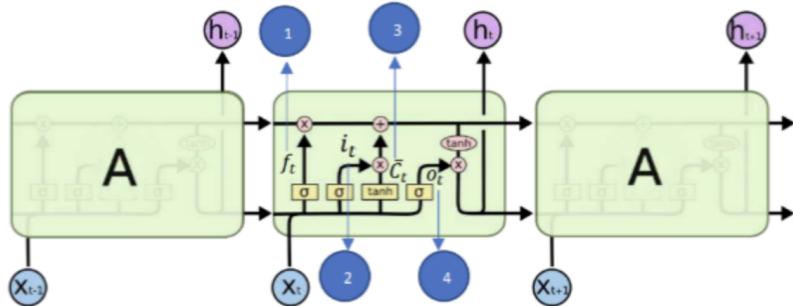
2.3 Long Short Term Memory(LSTM)

LSTM adalah perluasan arsitektur *Recurrent Neural Network* (RNN) yang dikenalkan oleh Sepp Hochreiter dan Jurgen Schmidhuber pada tahun 1997. Arsitektur ini dirancang khusus sebagai solusi atas masalah *vanishing gradient* yang sering terjadi pada RNN konvensional. LSTM termasuk dalam model non-linear karena setiap gerbangnya menggunakan fungsi aktivasi, seperti sigmoid dan tanh, yang menjadikan hubungan dalam model bersifat *nonlinear*. Empat *layer* utama pada LSTM adalah *forget gate*, *input gate*, *cell state*, dan *output gate*, sebagaimana ditampilkan pada gambar di bawah.

A merupakan unit blok LSTM, X_{t-1} merupakan nilai Input sebelum orde ke- t , X_t merupakan nilai Input pada orde ke- t , X_{t+1} merupakan Nilai Input setelah orde ke- t , h_{t-1} merupakan Nilai Output sebelum orde ke- t , h_t merupakan Nilai Output pada orde ke- t , h_{t+1} merupakan Nilai Output setelah orde ke- t , f_t merupakan Forget Gate, i_t merupakan Input Gate, C_t merupakan Nilai baru yang dapat ditambahkan ke cell state, o_t merupakan Output Gate, σ merupakan Fungsi Sigmoid dan \tanh merupakan Fungsi tanh.

2.3.1 Normalisasi Data

Normalisasi merupakan bagian terpenting dalam proses suatu prosedur untuk membangun model LSTM [25]. Dalam proses pembelajaran model LSTM biasanya akan dilakukan tahap normalisasi terlebih dahulu karena pada tahap ini dapat menghindari hasil yang tidak diperlukan dan agar algoritmanya dapat



Gambar 1: Arsitektur Model LSTM (Sumber gambar [24])

konvergen nantinya. Menurut [26] terdapat beberapa metode normalisasi contohnya *min-max scale*, berikut persamaannya:

$$x_{scaled} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (9)$$

dengan, x_{min} merupakan nilai minimum sedangkan x_{max} merupakan nilai maksimum. Ketika dilakukan peramalan akan ditransformasi balik sesuai dengan persamaan berikut:

$$x_{unscaled} = x_{scaled}(x_{max} - x_{min}) + x_{min} \quad (10)$$

2.3.2 Optimasi

Optimasi merupakan suatu proses dalam LSTM yang bertujuan untuk menemukan nilai pembobotan atau parameter yang optimal [26]. Bobot atau parameter dioptimalkan dengan cara diubah untuk meminimalisir *residual*, agar dapat memprediksi data runtun waktu seakurat mungkin selama proses pelatihan model LSTM [27]. Salah satu optimasi yang dapat dipakai dalam model LSTM adalah optimasi *Adaptive Moment Estimation* (Adam) yang merupakan metode perhitungan *adaptive learning rate* untuk setiap parameter.

2.4 Hybrid ARFIMA-LSTM

Pada penelitian ini akan dikombinasikan dua model, yaitu ARFIMA dan LSTM. ARFIMA akan digunakan untuk mendeteksi pola yang memiliki trend atau hubungan linier. ARFIMA akan mengalami kesulitan dalam memproses data yang berisifat *nonlinear*, oleh karena itu digunakan model LSTM sebagai sebuah model yang akan digabungkan dengan ARFIMA untuk mendeteksi pola *nonlinear* pada data dengan memproses *residual* dari ARFIMA [28]. Maka model persamaan dari kombinasi ARFIMA dan LSTM adalah sebagai berikut [26]:

$$\hat{Z}_t(\text{prediksi}) = \hat{L}_t(\text{trend}) + \hat{N}_t(\text{residual}) \quad (11)$$

2.5 Akurasi Model Peramalan

Tingkat akurasi model peramalan dapat dinilai menggunakan *Mean Absolute Percentage Error* (MAPE) untuk akurasi kinerja pada model peramalan. Persamaan dari MAPE dapat dituliskan dalam rumus berikut [11]:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Z_t - \hat{Z}_t}{Z_t} \right| \times 100\% \quad (12)$$

dengan,

n : banyak pengamatan

Z_t : data aktual

\hat{Z}_t : data ramalan

Kemampuan model peramalan dikatakan baik apabila, nilai MAPE yang diperoleh semakin kecil. Pengukuran kemampuan model peramalan ditampilkan pada tabel berikut [14]:

Tabel 1: Kemampuan pengukuran model peramalan

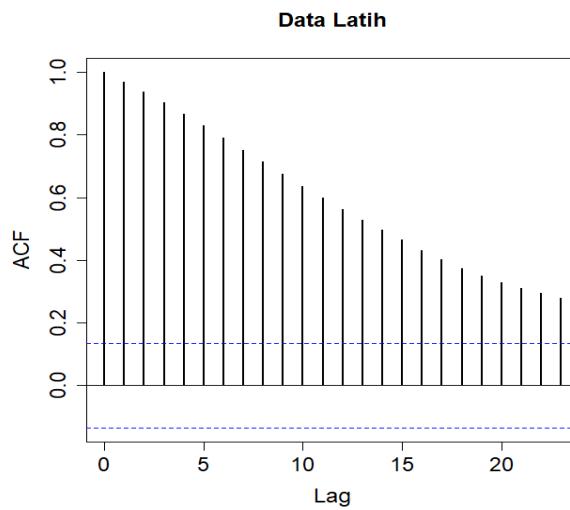
No	Nilai MAPE	Keterangan
1	$\leq 10\%$	Sangat baik
2	$10\% - 20\%$	Baik
3	$20\% - 50\%$	Cukup baik
4	$> 50\%$	Buruk

3 Hasil dan Pembahasan

Bagian ini menyajikan hasil analisis data serta penerapan metode yang digunakan dalam penelitian. Analisis dimulai dengan identifikasi pola memori jangka panjang (*long memory*), dilanjutkan dengan pengujian stasioneritas data, serta pemodelan menggunakan ARFIMA dan LSTM. Evaluasi terhadap hasil prediksi dilakukan untuk mengukur performa model.

3.1 Mengidentifikasi Pola *Long Memory*

Pola *long memory* pada suatu deret waktu dapat diidentifikasi melalui pengamatan terhadap plot *Autocorrelation Function* (ACF). Pola ini ditunjukkan oleh lambatnya penurunan nilai autokorelasi, yang mengindikasikan adanya ketergantungan jangka panjang dalam data.

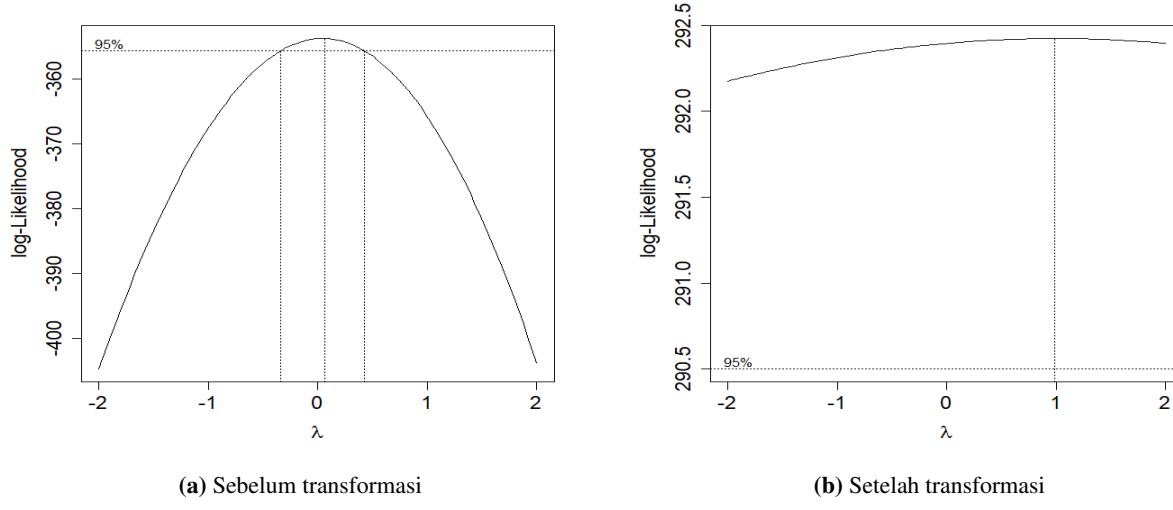


Gambar 2: Plot ACF Data Latih Indeks Harga Perdagangan Besar Indonesia

Berdasarkan [Gambar 2](#), terlihat bahwa nilai ACF dari data Indeks Harga Perdagangan Besar Indonesia (IHPBI) menurun secara perlahan mengikuti pola hiperbolik. Hal ini merupakan karakteristik dari data yang memiliki sifat *long memory*. Untuk memperkuat identifikasi ini, dilakukan perhitungan nilai statistik *hurst* menggunakan perangkat lunak *RStudio*, yang menghasilkan nilai sebesar $H = 0,822$. Berdasarkan kriteria bahwa jika $0,5 < H < 1$ maka data menunjukkan sifat *long memory*, maka dapat disimpulkan bahwa data IHPBI memenuhi kriteria tersebut.

3.2 Uji Stasioneritas Data

Pengujian stasioneritas data dilakukan dalam dua aspek, yaitu dalam varian dan dalam *mean*. Uji stasioneritas dalam varian menggunakan pendekatan transformasi Box-Cox, dengan asumsi bahwa data dikatakan stasioner dalam varian jika nilai parameter transformasi memenuhi $\lambda = 1$.



Gambar 3: Plot uji stasioneritas dalam varian: (a) sebelum transformasi, (b) setelah transformasi

Berdasarkan [Gambar 3](#), tampak bahwa sebelum transformasi, data belum memenuhi kriteria stasioner dalam varian karena $\lambda \neq 1$. Namun setelah dilakukan transformasi Box-Cox, nilai parameter transformasi menjadi $\lambda = 1$, yang menunjukkan bahwa data telah stasioner dalam varian.

Pengujian stasioneritas dalam *mean* dilakukan menggunakan uji Augmented Dickey-Fuller (ADF). Hasil awal uji ADF menunjukkan nilai *p*-value sebesar 0,33. Karena nilai ini lebih besar dari taraf signifikansi $\alpha = 0,05$, maka data belum stasioner dalam *mean*. Oleh karena itu, dilakukan proses *differencing* untuk menghilangkan tren dalam data.

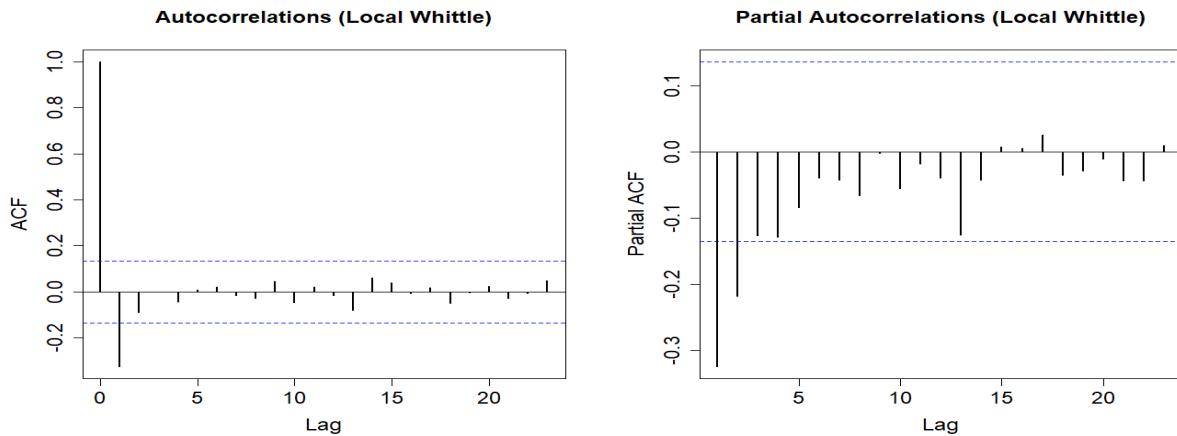
Setelah proses *differencing*, uji ADF kembali dilakukan dan menghasilkan nilai *p*-value sebesar 0,01. Nilai ini lebih kecil dari $\alpha = 0,05$, sehingga dapat disimpulkan bahwa data telah stasioner dalam *mean*. Dengan demikian, data telah memenuhi kedua aspek stasioneritas yang diperlukan sebelum dilakukan proses pemodelan lebih lanjut.

3.3 Estimasi Parameter Pembeda

Penentuan nilai estimasi parameter *diferensiasi fraksional* (d) dalam model ARFIMA dilakukan melalui dua parameter pembeda, yaitu metode *Local Whittle* (LW) dan metode *Rescaled Range Statistics* (R/S). Hasil dari proses estimasi tersebut yaitu $d_{LW} = 0,009$ dan $d_{R/S} = 0,322$ menunjukkan bahwa nilai parameter d yang terestimasi berada dalam rentang $0 < d < 0,5$. Kondisi ini mengindikasikan adanya korelasi positif yang signifikan dalam jangka panjang antar observasi yang terpisah jauh, atau yang dikenal sebagai *long memory* pada data.

3.4 Identifikasi model ARFIMA(p, d, q) Berdasarkan Plot ACF dan PACF

Model ARFIMA(p, d, q) diidentifikasi berdasarkan analisis plot ACF dan PACF terhadap data yang telah mengalami proses *differencing* sesuai dengan masing-masing nilai estimasi parameter pembeda d . Pemilihan orde p dan q dilakukan dengan mengamati jumlah *lag* yang berada di luar batas pada plot. Berikut visualisasi plotnya setelah *differencing* dengan $d_{LW} = 0,009$.



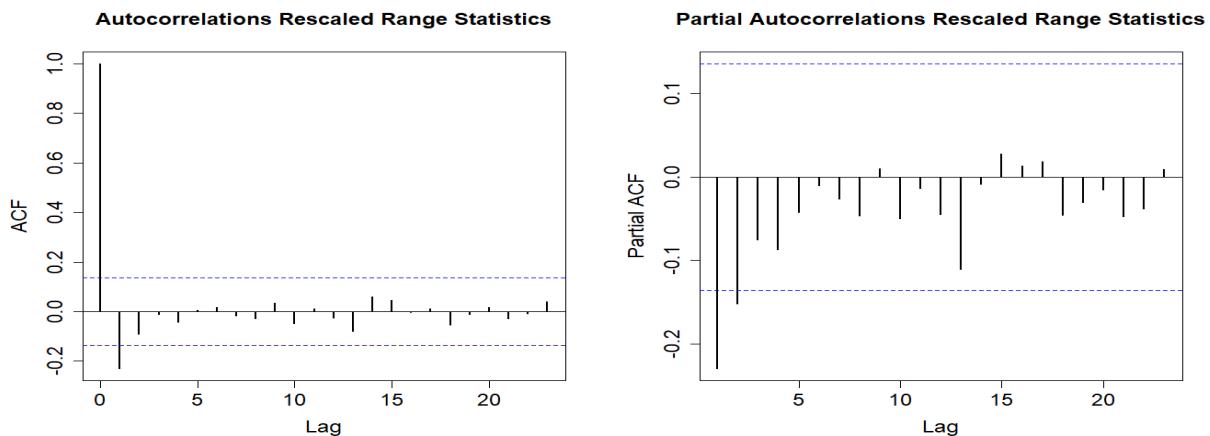
Gambar 4: Plot ACF dan PACF untuk $d_{LW} = 0,009$

Berdasarkan [Gambar 4](#), terdapat *lag-lag* yang melampaui batas plot. Menenerapkan prinsip *parcimony*, model ARFIMA $d_{LW} = 0,009$ sebanyak 8 model sebagai berikut.

Tabel 2: Pembentukan Model ARFIMA(p,d,q) $d_{LW} = 0,009$

Model	MA(0)	MA(1)	MA(2)
AR(0)	–	ARFIMA(0,d,1)	ARFIMA(0,d,2)
AR(1)	ARFIMA(1,d,0)	ARFIMA(1,d,1)	ARFIMA(1,d,2)
AR(2)	ARFIMA(2,d,0)	ARFIMA(2,d,1)	ARFIMA(2,d,2)

Visualiasi plot ACF dan PACF setelah differencing dengan $d_{R/S} = 0,322$ sebagai berikut.



Gambar 5: Plot ACF dan PACF untuk $d_{R/S} = 0,322$

Berdasarkan [Gambar 5](#), menunjukkan bahwa terdapat *lag-lag* yang melampaui batas plot. Menenerapkan prinsip *parcimony*, model ARFIMA $d_{R/S} = 0,322$ yang diperoleh yaitu terdiri dari 8 model sebagai berikut.

Tabel 3: Pembentukan Model ARFIMA(p,d,q) $d_{LW} = 0,009$

Model	MA(0)	MA(1)	MA(2)
AR(0)	–	ARFIMA(0,d,1)	ARFIMA(0,d,2)
AR(1)	ARFIMA(1,d,0)	ARFIMA(1,d,1)	ARFIMA(1,d,2)
AR(2)	ARFIMA(2,d,0)	ARFIMA(2,d,1)	ARFIMA(2,d,2)

3.5 Pemilihan Model Terbaik ARFIMA

Pemilihan model ARFIMA terbaik menggunakan kriteria nilai *Akaike's Information Criterion* (AIC) terkecil [20]. Nilai AIC dihitung dengan menggunakan *software RStudio*. Nilai AIC dari model ARFIMA dengan menggunakan $d_{LW} = 0,009$ disajikan pada tabel berikut:

Tabel 4: Pemilihan Model ARFIMA(p,d,q) $d_{LW} = 0,009$

No	Model	Parameter	Nilai AIC
1	ARFIMA(1,d,0)	Signifikan	-2357,23
2	ARFIMA(2,d,0)	Signifikan	-2348,16
3	ARFIMA(1,d,1)	Tidak Signifikan	-2355,31
4	ARFIMA(2,d,1)	Signifikan	-2353,23
5	ARFIMA(1,d,2)	Tidak Signifikan	-2353,31
6	ARFIMA(2,d,2)	Tidak Signifikan	-2351,49
7	ARFIMA(0,d,1)	Signifikan	-1852,52
8	ARFIMA(0,d,2)	Signifikan	-2005,95

Berdasarkan **Tabel 4** diatas, ARFIMA (p, d, q) dengan menggunakan estimasi parameter pembeda $d_{LW} = 0,009$ terbaik berdasarkan nilai AIC terkecil adalah model ARFIMA $(1, d, 0)$ dengan nilai AIC terkecil yaitu -2357,23. Nilai AIC dari model ARFIMA dengan menggunakan estimasi parameter pembeda $d_{R/S} = 0,322$ disajikan pada tabel berikut:

Tabel 5: Pemilihan Model ARFIMA(p,d,q) $d_{R/S} = 0,322$

No	Model	Parameter	Nilai AIC
1	ARFIMA(1,d,0)	Signifikan	-2345,82
2	ARFIMA(2,d,0)	Signifikan	-2351,10
3	ARFIMA(1,d,1)	Signifikan	-2353,30
4	ARFIMA(2,d,1)	Tidak Signifikan	-2352,99
5	ARFIMA(1,d,2)	Tidak Signifikan	-2352,97
6	ARFIMA(2,d,2)	Tidak Signifikan	-2351,02
7	ARFIMA(0,d,1)	Signifikan	-2163,44
8	ARFIMA(0,d,2)	Signifikan	-2228,73

Berdasarkan **Tabel 5** di atas model ARFIMA (p, d, q) dengan menggunakan estimasi parameter pembeda $d_{R/S} = 0,322$ terbaik berdasarkan nilai AIC terkecil adalah model ARFIMA $(1, d, 1)$ dengan nilai AIC terkecil yaitu -2353,230.

3.6 Uji Diagnostik Model ARFIMA (p, d, q)

Setelah mendapatkan model ARFIMA (p, d, q) terbaik, selanjutnya dilakukan uji diagnostik model. Uji diagnostik ini bertujuan untuk mengevaluasi apakah model yang diperoleh telah bersifat *white noise* atau tidak. Uji diagnostik model menggunakan uji *Ljung-Box* dengan persamaan **2.10**.

Tabel 6: Hasil Uji Diagnostik Model ARFIMA (p, d, q) Terbaik

Estimasi Parameter d	Model	Uji White Noise p_{value}
$d_{LW} = 0,009$	ARFIMA (1,d,0)	0,9042
$d_{R/S} = 0,322$	ARFIMA (1,d,1)	0,9031

Berdasarkan **Tabel 6** di atas, hasil pengujian *white noise* dengan menggunakan uji *Ljung-Box* diperoleh nilai $p_{value} > 0,05$, sehingga keputusan terima H_0 yang artinya *residual* model-model tersebut menunjukkan karakteristik *white noise*, sehingga asumsi keacakan terpenuhi dan model dapat digunakan untuk peramalan. Persamaan model ARFIMA $(1, d, 0)$ dengan $d_{LW} = 0,009$ adalah sebagai berikut:

$$\phi_1(B)(1-B)^{0,009}G_t = a_t \quad (13)$$

$$(1 - 0,99197201)(1-B)^{0,009}G_t = a_t \quad (14)$$

Persamaan model ARFIMA $(1,d,1)$ dengan $d_{R/S} = 0,322$ adalah sebagai berikut:

$$\phi_1(B)(1-B)^{0,322}G_t = \theta_1(B)a_t \quad (15)$$

$$(1 - 0,9457903)(1-B)^{0,322}G_t = (1 - 0,2657933)a_t \quad (16)$$

3.7 Uji Linieritas

Pemodelan dengan ARFIMA mengindikasikan adanya autokorelasi yang signifikan pada *residual* (sisaan), yang mengarah pada kemungkinan adanya pola hubungan *non-linear* dalam data. Hasil perhitungan Linieritas menggunakan Ramsey Reset sebagai berikut [22].

Tabel 7: Hasil Uji Linieritas Reset Model pada *Residual* ARFIMA

Parameter d <i>Residual</i> ARFIMA	Model	p_{value}
$d_{LW} = 0,009$	ARFIMA (1,d,0)	0,0001112
$d_{R/S} = 0,322$	ARFIMA (1,d,1)	0,0005014

Berdasarkan **Tabel 7** di atas, diperoleh nilai P_{value} ini lebih kecil dari tingkat signifikansi yang ditetapkan yaitu ($\alpha = 0,05$), Dengan demikian keputusan yang diambil adalah tolak H_0 . Dengan demikian, hasil uji menyimpulkan bahwa data IHPBI memiliki struktur autokorelasi yang *nonlinear*, sehingga perlu ditambahkan metode LSTM untuk mengatasi hal tersebut atau dengan kata lain dibentuk model ARFIMA-LSTM.

3.8 Normalisasi dan Pembentukan Model LSTM

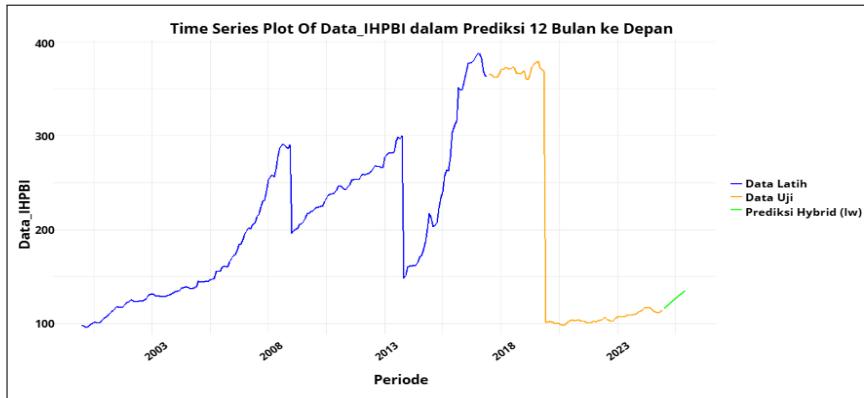
Normalisasi data adalah tahap pertama dan merupakan bagian terpenting yang dilakukan saat pemodelan LSTM [25]. Dalam melakukan analisis LSTM dilakukan normalisasi terlebih dahulu untuk meminimalkan *error* dengan mengubah *residual* ARFIMA menjadi range interval [0-1]. Tujuan dari normalisasi data ini adalah untuk mempercepat proses konvergensi serta membantu model dalam mencapai nilai minimum dari fungsi objektif secara lebih efisien dan stabil, dengan memanfaatkan transformasi skala pada data *input*. Pembentukan model LSTM dijalankan menggunakan *software* R, *Residual* dari model yang sudah dinormalisasi digunakan sebagai *input* LSTM. Pada tahap ini akan dibentuk model LSTM dengan menggunakan 50 unit sel LSTM dan *Dropout* serta *Recurrent Dropout* sebanyak 0,2. Banyak *timestep/timelag* yang digunakan adalah sebanyak 4 dan menggunakan aktivasi tanh. Pembentukan model ini menggunakan *Adam* sebagai *Optimizer* sesuai dengan metode penelitian.

3.9 Peramalan Residual dan Transformasi Balik Peramalan Residual

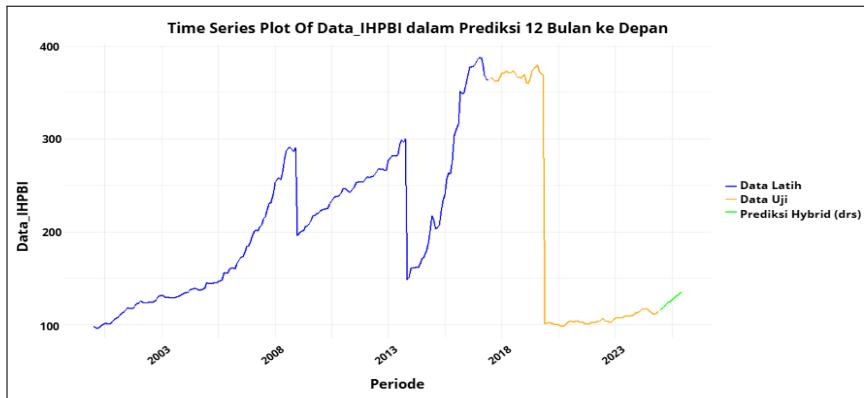
Setelah dilakukan pembentukan model LSTM, selanjutnya akan melakukan peramalan terhadap *residual* dari masing-masing parameter tersebut. Setelah model dilatih, dilakukan proses peramalan terhadap data *residual* pada bagian pelatihan, sehingga dihasilkan nilai *fitted* yang merepresentasikan estimasi LSTM terhadap pola-pola yang terkandung dalam sisaan. Transformasi balik dilakukan untuk mengembalikan hasil prediksi dan nilai *fitted* dari model LSTM ke skala asli data sebelum dilakukan proses normalisasi atau penskalaan. Proses ini penting agar hasil peramalan dapat dibandingkan secara langsung dengan data aktual dalam satuan yang sama, sehingga interpretasi terhadap hasil model menjadi lebih bermakna. Transformasi dilakukan dengan menggunakan parameter penskalaan yang sama seperti saat proses normalisasi sebelumnya. Dengan demikian, nilai hasil peramalan yang sebelumnya berada dalam skala terstandarisasi dapat dikonversi kembali ke bentuk aslinya.

3.10 Peramalan *Hybrid* ARFIMA-LSTM

Hasil peramalan didapatkan dari komponen linier ramalan ARFIMA yang ditambahkan dengan komponen *nonlinier* dari LSTM yaitu hasil dari transformasi balik ramalan *residual* [28]. Validasi hasil peramalan menggunakan data uji untuk meramalkan data IHPBI selama 12 bulan kedepan.



Gambar 6: Plot Peramalan *Hybrid* ARFIMA-LSTM $d_{LW} = 0,009$



Gambar 7: Plot Peramalan *Hybrid* ARFIMA-LSTM $d_{R/S} = 0,322$

Berdasarkan [Gambar 6](#) dan [Gambar 7](#), peramalan IHPBI selama 12 bulan kedepan ditandai dengan warna hijau menggunakan ARFIMA-LSTM d_{LW} dan $d_{R/S}$ menunjukkan bahwa hasil peramalan mengalami tren peningkatan nilai indeks. Kenaikan ini dapat menjadi indikator awal terjadinya inflasi, khususnya pada level harga grosir, sehingga diperlukan respons kebijakan yang tepat untuk mengantisipasi lonjakan harga komoditas pertanian di pasar besar.

3.11 Evaluasi Akurasi Model Peramalan

Peningkatan performa atau akurasi dibuktikan dan dievaluasi dengan melihat MAPE terkecil pada data uji untuk kedua parameter [14]. Hasil perhitungan MAPE dapat dilihat pada tabel berikut.

Tabel 8: Perbandingan Nilai MAPE untuk Berbagai Model dan Parameter

Parameter d	Model	Nilai MAPE
d_{LW}	ARFIMA (1,d,0)	0,9755254%
$d_{R/S}$	ARFIMA (1,d,1)	0,8891277%
d_{LW}	Hybrid ARFIMA-LSTM	0,633829%
$d_{R/S}$	Hybrid ARFIMA-LSTM	0,6337853%

Berdasarkan [Tabel 8](#) diperoleh perbandingan nilai MAPE dari beberapa kombinasi model dan metode estimasi parameter pembeda d , yaitu antara model ARFIMA murni dan model hybrid ARFIMA-LSTM.

Model ARFIMA dengan estimasi d_{LW} menghasilkan MAPE sebesar 0,9755254%, sementara model ARFIMA dengan estimasi $d_{R/S}$ memiliki MAPE yang sedikit lebih baik, yaitu 0,8891277%. Namun, ketika model ARFIMA digabungkan dengan LSTM dalam bentuk hybrid, akurasi peramalan meningkat secara signifikan. Hybrid ARFIMA-LSTM dengan estimasi d_{LW} menunjukkan MAPE sebesar 0,633829%, dan hybrid ARFIMA-LSTM dengan estimasi $d_{R/S}$ menghasilkan MAPE terendah sebesar 0,6337853%. Nilai MAPE ini menunjukkan bahwa model hybrid mampu menangkap pola data yang lebih kompleks dibandingkan model statistik murni. Dengan demikian, metode terbaik dalam penelitian ini adalah model Hybrid ARFIMA-LSTM dengan estimasi parameter pembeda d menggunakan metode *Rescaled Range Statistics* ($d_{R/S}$), karena memberikan hasil peramalan paling akurat dengan nilai MAPE terendah dan memberikan performa terbaik dalam hal akurasi prediksi.

4 Kesimpulan

Hasil peramalan Indeks Harga Perdagangan Besar Indonesia pada sektor Pertanian selama 12 bulan kedepan menggunakan ARFIMA-LSTM menunjukkan bahwa data IHPBI mengalami kenaikan yang berarti dapat menjadi sinyal awal inflasi, sehingga perlu dilakukan kebijakan untuk menekan potensi kenaikan harga-harga grosir dari barang-barang yang diperjual belikan di pasar besar khususnya pada sektor pertanian. Selain itu metode estimasi parameter pembeda d terbaik dalam meramalkan Indeks Harga Perdagangan Besar Indonesia pada sektor Pertanian adalah metode estimasi *Rescaled Range Statistics* ($d_{R/S} = 0,322$) dengan nilai MAPE sebesar 0,6337853% dengan tingkat akurasi peramalan sangat baik. Penelitian ini berkontribusi dengan menerapkan kombinasi ARFIMA dan LSTM untuk meramalkan data IHPBI. Namun demikian, perbedaan yang tipis ini menjadi salah satu keterbatasan penelitian, karena tidak dilakukan pengujian signifikan secara statistik.

Penelitian selanjutnya dapat mempertimbangkan penggunaan metode evaluasi tambahan dan uji statistik untuk memperkuat kesimpulan dan melakukan percobaan kombinasi parameter yang berbeda seperti banyak unit ataupun *timestep/timelag* yang digunakan agar model tidak mengalami *overfitting* dan bisa memiliki performa yang lebih baik pada LSTM.

Pernyataan Kontribusi Penulis (CRediT)

Trieke Nurfadilah Harun: Konseptualisasi, Metodologi, Perangkat Lunak, Analisis Formal, Investigasi, Kurasi Data, Penulisan–Draf Awal, Penulisan–Telaah dan Penyuntingan, Visualisasi. **Ismail Djakaria:** Konseptualisasi, Metodologi, Penulisan–Draf Awal, Penulisan–Telaah dan Penyuntingan, Supervisi **Nisky Imansyah Yahya:** Konseptualisasi, Metodologi, Penulisan–Draf Awal, Penulisan–Telaah dan Penyuntingan, Supervisi **Salmun K. Nasib:** Metodologi, Perangkat Lunak, Penulisan–Draf Awal, Penulisan–Telaah dan Penyuntingan, Supervisi **Isran K. Hasan:** Metodologi, Penulisan–Draf Awal, Penulisan–Telaah dan Penyuntingan, Supervisi

Deklarasi Konflik Kepentingan

Para penulis menyatakan tidak ada konflik kepentingan.

Ketersediaan Data dan Kode

Seluruh data dan kode program yang digunakan dalam penelitian ini tersedia secara terbuka dan dapat diakses oleh publik. Dataset terdiri dari indeks harga perdagangan besar indonesia yang terdapat pada website BPS Indonesia dan tidak mengandung informasi pribadi. Dokumentasi dan tautan untuk mengakses data dalam repositori BPS Indonesia¹.

¹<https://www.bps.go.id/id/statistics-table/2/MTcyMSMy/ihpb--november-2023.html>

Daftar Pustaka

- [1] S. Idris, R. Goejantoro, and Y. N. Nasution, “Pemodelan dan peramalan indeks harga perdagangan besar (ihpb) dengan menggunakan arfima (studi kasus: Ihpb provinsi kalimantan timur bulan januari 2002–desember 2006 dan januari 2009-september 2013),” *Jurnal Eksponensial*, vol. 5, no. 2, pp. 85–95, 2014.
- [2] Badan Pusat Statistik (BPS) Indonesia, *Indeks harga perdagangan besar indonesia tahun 2023*, Diakses pada November 2024, 2023.
- [3] B. Setyawan, N. I. Riwajanti, and S. Ismanu, “Analisis peramalan menggunakan arima pada indeks harga perdagangan besar indonesia kelompok komoditi pertanian tahun 2000-2019,” *Media Mahardhika*, vol. 18, no. 2, pp. 198–205, 2020. DOI: [10.29062/mahardika.v18i2.148](https://doi.org/10.29062/mahardika.v18i2.148).
- [4] Hartini, F. Insani, Novriyanto, and S. Sanjaya, “Implementasi Long Short Term Memory Neural Network Untuk Prediksi Indeks Harga Perdagangan Besar,” *Seminar Nasional Teknologi Informasi, Komunikasi dan Industri*, pp. 44–51, 2022.
- [5] I. K. Hasan, M. Janur, and N. Nurwan, “Penerapan model arfima-garch menggunakan variasi estimasi parameter pembeda d pada data long memory,” *J Statistika: Jurnal Ilmiah Teori dan Aplikasi Statistika*, vol. 16, no. 2, pp. 474–485, 2023. DOI: [10.36456/jstat.vol16.no2.a8041](https://doi.org/10.36456/jstat.vol16.no2.a8041).
- [6] Z. Zulfikar, A. Wanto, and Z. M. Nasution, “Analisis dalam melihat perkembangan indeks harga perdagangan besar menurut sektor di indonesia menggunakan algoritma backpropagation,” *Pros. Semin. Nas. Ris. Inf. Sci*, vol. 1, p. 359, 2019. DOI: [10.30645/senaris.v1i0.41](https://doi.org/10.30645/senaris.v1i0.41).
- [7] H.-H. Huang, N. H. Chan, K. Chen, and C.-K. Ing, “Consistent order selection for arfima processes,” *The Annals of Statistics*, vol. 50, no. 3, pp. 1297–1319, 2022. DOI: [10.1214/21-AOS2149](https://doi.org/10.1214/21-AOS2149).
- [8] A. Sherstinsky, “Fundamentals of recurrent neural network (rnn) and long short-term memory (lstm) network,” *Physica D: Nonlinear Phenomena*, vol. 404, p. 132306, 2020. DOI: [10.1016/j.physd.2019.132306](https://doi.org/10.1016/j.physd.2019.132306).
- [9] A. H. Bukhari, M. A. Z. Raja, M. Sulaiman, S. Islam, M. Shoaib, and P. Kumam, “Fractional neuro-sequential arfima-lstm for financial market forecasting,” *Ieee Access*, vol. 8, pp. 71326–71338, 2020. DOI: [10.1109/ACCESS.2020.2985763](https://doi.org/10.1109/ACCESS.2020.2985763).
- [10] G. Anuraga, A. Indrasetianingsih, and M. Athoillah, “Pelatihan pengujian hipotesis statistika dasar dengan software r,” *indonesian, BUDIMAS: Jurnal Pengabdian Masyarakat*, vol. 3, no. 2, 2021.
- [11] R. D. Hanifa, M. Mustafid, and A. R. Hakim, “Pemodelan autoregressive fractionally integrated moving average dengan efek exponential garch (arfima-egarch) untuk prediksi harga beras di kota semarang,” *Jurnal Gaussian*, vol. 10, no. 2, pp. 279–292, 2021. DOI: [10.14710/j.gauss.10.2.279-292](https://doi.org/10.14710/j.gauss.10.2.279-292).
- [12] T. Ardi, R. Santoso, and A. Prahutama, “Implementasi subset autoregressive menggunakan paket fitar,” *Jurnal Gaussian*, vol. 6, no. 4, pp. 510–519, 2017. DOI: [10.14710/j.gauss.6.4.510-519](https://doi.org/10.14710/j.gauss.6.4.510-519).
- [13] G. Bhardwaj and N. R. Swanson, “An empirical investigation of the usefulness of arfima models for predicting macroeconomic and financial time series,” *Journal of Econometrics*, vol. 131, no. 1, pp. 539–578, 2006. DOI: <https://doi.org/10.1016/j.jeconom.2005.01.016>.
- [14] M. J. I. Akbar and I. Kharisudin, “Model arfima untuk analisis data kecepatan angin di bandara internasional ahmad yani,” *Unnes Journal of Mathematics*, vol. 8, no. 2, pp. 89–101, 2019. DOI: [10.15294/ujm.v8i2.38037](https://doi.org/10.15294/ujm.v8i2.38037).
- [15] M. S. Suryono and R. Oetama, “Peramalan terhadap forex dengan metode arima studi kasus gbp/usd,” *Ultimatics: Jurnal Teknik Informatika*, vol. 11, no. 1, pp. 6–10, 2019. DOI: [10.31937/ti.v11i1.1238](https://doi.org/10.31937/ti.v11i1.1238).

- [16] W. Wei, *Time Series Analysis: Univariate and Multivariate Methods* (Time Series Analysis: Univariate and Multivariate Methods). Pearson Addison Wesley, 2006. [Available online](#).
- [17] S. Nurman, M. Nusrang, *et al.*, “Analysis of rice production forecast in maros district using the box-jenkins method with the arima model,” *ARRUS Journal of Mathematics and Applied Science*, vol. 2, no. 1, pp. 36–48, 2022. DOI: [10.35877/mathscience731](https://doi.org/10.35877/mathscience731).
- [18] N. D. L. Imani, T. Tarno, and B. A. Saputra, “Prediksi harga daging sapi di kabupaten brebes menggunakan pemodelan arfima dengan efek garch,” *Jurnal Gaussian*, vol. 12, no. 4, pp. 570–580, 2024. DOI: [10.14710/j.gauss.12.4.570-580](https://doi.org/10.14710/j.gauss.12.4.570-580).
- [19] L. Ding, Y. Luo, Y. Lin, and Y. Huang, “Revisiting the relations between hurst exponent and fractional differencing parameter for long memory,” *Physica A: Statistical Mechanics and its Applications*, vol. 566, p. 125603, 2021. DOI: [10.1016/j.physa.2020.125603](https://doi.org/10.1016/j.physa.2020.125603).
- [20] D. M. Putri and A. Aghsilni, “Estimasi model terbaik untuk peramalan harga saham pt. polychem indonesia tbk. dengan arima,” *MAP (Mathematics and Applications) Journal*, vol. 1, no. 2, pp. 1–12, 2019. DOI: [10.15548/map.v1i2.1176](https://doi.org/10.15548/map.v1i2.1176).
- [21] D. Christian and S. Halim, “Peramalan multivariat untuk menentukan harga emas global,” *Jurnal Teknik Industri*, vol. 18, no. 2, pp. 137–144, 2016. DOI: [10.9744/jti.18.2.137-144](https://doi.org/10.9744/jti.18.2.137-144).
- [22] J. B. Ramsey, “Tests for specification errors in classical linear least-squares regression analysis,” *Journal of the Royal Statistical Society: Series B (Methodological)*, vol. 31, no. 2, pp. 350–371, Dec. 2018. DOI: [10.1111/j.2517-6161.1969.tb00796.x](https://doi.org/10.1111/j.2517-6161.1969.tb00796.x). eprint: https://academic.oup.com/jrssb/article-pdf/31/2/350/49095363/jrssb_31_2_350.pdf. Available online.
- [23] D. I. Purnama, “Peramalan jumlah penumpang datang melalui transportasi udara di sulawesi tengah menggunakan support vector regression (svr),” *Jurnal Ilmiah Matematika dan Terapan*, vol. 17, no. 1, 2020. DOI: [10.22487/2540766X.2020.v17.i1.15186](https://doi.org/10.22487/2540766X.2020.v17.i1.15186).
- [24] C. Olah, *Understanding lstm networks*, <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>, Accessed: 2024-11-30, 2015.
- [25] G. Ciaburro and B. Venkateswaran, *Neural Networks with R: Smart models using CNN, RNN, deep learning, and artificial intelligence principles*. Packt Publishing, 2017. [Available online](#).
- [26] T. S. Wibawa, “Pemodelan hybrid arima-lstm dalam meramalkan harga saham (studi kasus: Harga penutupan saham bank bca),” Ph.D. dissertation, Universitas Brawijaya, 2021.
- [27] R. Yotenga and F. F. El Huda, “Implementasi long short-term memory pada harga saham perusahaan perkebunan di indonesia,” *UJMC (Unisda Journal of Mathematics and Computer Science)*, vol. 6, no. 01, pp. 9–18, 2020. DOI: [10.52166/ujmc.v6i01.1927](https://doi.org/10.52166/ujmc.v6i01.1927).
- [28] R. Rowan, L. Muflikhah, and I. Cholissodin, “Peramalan kasus positif covid-19 di jawa timur menggunakan metode hybrid arima-lstm,” *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, vol. 6, no. 9, pp. 4146–4153, 2022.