

Prediksi Tingkat Inflasi di Kota Yogyakarta Menggunakan Model Hybrid ARIMA-GRU dengan Optimasi Grid Search

Herlambang Awan Irawan¹, Aviolla Terza Damaliana², Wahyu Syaifullah J. S³

^{1,2,3}Program Sains Data, Universitas Pembangunan Nasional “Veteran” Jawa Timur

¹22083010101@student.upnjatim.ac.id ²aviolla.terza.sada@upnjatim.ac.id ³wahyu.s.j.saputra.if@upnjatim.ac.id

Corresponding author email: 22083010101@student.upnjatim.ac.id

ABSTRAK

Abstrak— Penelitian ini bertujuan untuk memprediksi tingkat inflasi di Kota Yogyakarta menggunakan model *hybrid* ARIMA-GRU dengan optimasi *Grid Search*. Inflasi merupakan indikator penting dalam menilai kestabilan ekonomi daerah, sehingga prediksi yang akurat diperlukan untuk mendukung pengambilan keputusan ekonomi yang efektif. Data inflasi bulanan Kota Yogyakarta periode 1979 - 2025 diperoleh dari Badan Pusat Statistik dari perhitungan indeks harga konsumen. Model hybrid dikembangkan dengan menggabungkan kemampuan ARIMA dalam menangkap pola linear dan GRU (*Gated Recurrent Unit*) dalam memodelkan hubungan non-linear serta dependensi jangka panjang pada data deret waktu. Optimasi hiperparameter dilakukan menggunakan *Grid Search* untuk memperoleh konfigurasi terbaik pada model GRU. Hasil penelitian menunjukkan bahwa model hybrid ARIMA-GRU menghasilkan nilai MSE, RMSE, dan MAE masing-masing sebesar 0.114501, 0.338380, dan 0.235730, yang lebih baik dibandingkan model ARIMA konvensional dengan nilai 0.133588, 0.365497, dan 0.264622. Temuan ini membuktikan bahwa integrasi ARIMA dan GRU dengan optimasi *Grid Search* mampu meningkatkan akurasi prediksi inflasi, serta memberikan kontribusi empiris terhadap penerapan metode *hybrid* berbasis pembelajaran mesin dalam analisis ekonomi regional di Indonesia.

Keywords: ARIMA-GRU, *Grid Search*, Prediksi Inflasi, Deret Waktu, Yogyakarta

I. PENDAHULUAN

Inflasi merupakan salah satu indikator utama yang mencerminkan stabilitas ekonomi suatu daerah. Perubahan tingkat inflasi yang signifikan dapat memengaruhi daya beli masyarakat, kebijakan moneter, serta pertumbuhan ekonomi secara keseluruhan [1]. Oleh karena itu, analisis dan peramalan inflasi menjadi aspek penting dalam mendukung perencanaan ekonomi daerah, termasuk di Kota Yogyakarta sebagai salah satu pusat kegiatan ekonomi dan pendidikan di Indonesia [2]. Dengan karakteristik ekonomi yang unik didominasi oleh sektor pariwisata, pendidikan, dan konsumsi rumah tangga fluktuasi inflasi di Yogyakarta memiliki pola yang menarik untuk diteliti secara mendalam.

Selama beberapa dekade terakhir, metode statistik tradisional seperti *Autoregressive Integrated Moving Average* (ARIMA) banyak digunakan dalam memodelkan dan memprediksi deret waktu ekonomi, termasuk inflasi. Penelitian penerapan ARIMA telah

dilakukan pada studi prediksi penjualan mobil di salah satu showroom di Medan [3]. Model ARIMA memiliki keunggulan dalam menangkap pola linear pada data historis, namun sering kali kurang optimal dalam merepresentasikan hubungan non-linear yang kompleks, terutama ketika terdapat faktor eksternal atau dinamika musiman yang tidak stabil [4]. Berbagai studi menunjukkan efektivitas pendekatan *hybrid ARIMA-neural network*, perkembangan *deep learning* menawarkan pendekatan baru dalam analisis deret waktu. Salah satunya adalah *Gated Recurrent Unit* (GRU), yaitu varian dari *Recurrent Neural Network* (RNN) yang mampu mempelajari dependensi jangka panjang dalam data non-linear dengan efisiensi komputasi yang lebih baik dibandingkan *Long Short-Term Memory* (LSTM) [5].


Annadurai et al. menerapkan model ARIMA-GRU untuk mendeteksi dan memprediksi tren epidemi influenza [6], dan melaporkan bahwa model *hybrid* memiliki akurasi lebih tinggi dibandingkan model tunggal seperti ARIMA maupun LSTM. Pendekatan serupa juga digunakan oleh Pinastawa et al. dalam memprediksi harga *cryptocurrency* [5], yang menunjukkan bahwa GRU unggul dalam mempelajari pola non-linear jangka panjang, sedangkan ARIMA lebih baik untuk pola linier jangka pendek. Pada konteks komoditas, Kurniasari et al. menunjukkan bahwa hybrid ARIMA-GRU mampu mereduksi kesalahan prediksi harga minyak sawit secara signifikan dibandingkan model individual [7]. Sementara itu, penelitian Sunendar et al. dan Sinaga memperlihatkan bahwa ARIMA tetap relevan untuk pola linier yang stabil, namun model berbasis *deep learning* seperti LSTM dan GRU lebih unggul pada pola yang kompleks dan berfluktuasi tinggi [8].

Kombinasi antara model ARIMA dan GRU (ARIMA-GRU) menawarkan pendekatan hibrida yang menggabungkan kekuatan keduanya. ARIMA dalam menangani komponen linear dan GRU dalam menangkap pola non-linear residual yang tersisa. Pendekatan ini telah menunjukkan hasil yang menjanjikan dalam berbagai penelitian deret waktu, seperti peramalan harga energi, nilai tukar, dan indeks saham. Namun, penerapan metode hibrida ini untuk memodelkan inflasi daerah, khususnya di Kota Yogyakarta dengan rentang data panjang sejak tahun 1979 hingga 2025, masih jarang dilakukan.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk membangun model peramalan inflasi Kota Yogyakarta dengan menggunakan pendekatan hibrida ARIMA - GRU berdasarkan data bulanan periode 1979 - 2025. Penelitian ini diharapkan dapat memberikan gambaran yang lebih akurat mengenai dinamika inflasi di tingkat daerah serta berkontribusi pada pengembangan metode prediksi ekonomi berbasis data historis jangka panjang. Selain itu, hasil penelitian ini juga dapat menjadi masukan bagi pemerintah daerah dan lembaga keuangan dalam merumuskan kebijakan ekonomi dan strategi pengendalian inflasi yang lebih adaptif terhadap pola perubahan yang kompleks.

II. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif berbasis deret waktu dengan menggabungkan model statistik ARIMA dan model *deep learning* GRU. Tujuan metodologi ini adalah menangkap pola linier dan non-linier secara bersamaan sehingga menghasilkan prediksi inflasi yang lebih akurat. Tahapan penelitian dijelaskan pada gambar 1.



Gambar 1. Tahapan Penelitian

II.1. Data Penelitian

Data yang digunakan dalam penelitian ini adalah data inflasi bulanan Kota Yogyakarta periode Januari 1979 hingga Januari 2025 yang diperoleh dari Badan Pusat Statistik (BPS). Data disusun dalam bentuk deret waktu univariat sehingga setiap nilai inflasi direpresentasikan berdasarkan periode pengamatan bulanan. Rentang data yang panjang memungkinkan analisis pola linear maupun non-linear serta dinamika jangka panjang.

II.2. Pemrosesan Awal Data (*Preprocessing*)

Tahap preprocessing dilakukan untuk memastikan data memenuhi asumsi dasar pemodelan deret waktu.

a. Pemeriksaan *Missing Value*

Data diperiksa untuk memastikan tidak terdapat nilai hilang. Jika ditemukan, perbaikan dilakukan menggunakan interpolasi linier [9].

b. Uji Stasioneritas dalam Mean

Stasioneritas diuji menggunakan Augmented Dickey-Fuller (ADF). Apabila data tidak stasioner dalam mean, dilakukan *differencing* hingga mencapai kondisi stasioner [10].

c. Pemeriksaan Volatilitas

Varians data diamati melalui *rolling variance*. Pemeriksaan ini tidak bertujuan memenuhi asumsi ARIMA, tetapi untuk mengidentifikasi adanya pola non-linear atau volatilitas yang berpotensi dipelajari oleh GRU pada tahap hybrid [11].

II.3. ARIMA

Autoregressive Integrated Moving Average (ARIMA) merupakan permodelan dan peramalan deret waktu yang kompleks [12]. Model *Autoregressive Integrated Moving Average* (ARIMA) adalah model yang secara penuh mengabaikan independen variabel dalam membuat prediksi. Tahapan dalam model peramalan ini meliputi sepasang model yang memenuhi, mengestimasi parameter, dan memverifikasi model [13].

Model umum ARIMA terdiri dari orde p sebagai AR, orde d sebagai diferensiasi, dan q sebagai orde *moving average*. Model umum dengan operator backshift dari peramalan ARIMA (p, d, q) yaitu formula 2 dari formula 1 [13].

$$Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (1)$$

$$\phi_p(B)(1-B)^d Y_t = \theta_q(B) a_t \quad (2)$$

Dengan:

- ϕ : Parameter *Autoregressive*
- θ : Parameter *Moving Average*
- a_t : Nilai *error* ke- t
- Y_t : *Series* yang stasioner

Langkah-langkah permodelan ARIMA antara lain yaitu sebagai berikut:

- a. Identifikasi Orde
Nilai d ditentukan dari hasil *differencing*. Nilai p dan q ditentukan berdasarkan pola *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Penentuan orde dipilih dengan lag cut off signifikan pada plot ACF dan PACF [14].
- b. Pemilihan Model
Pemilihan model menggunakan *Akaike Criterion Information* (AIC), AIC dipilih dengan kriteria paling kecil [15].
- c. Diagnostik Model
Pemeriksaan residual menggunakan uji Ljung-Box untuk memastikan tidak terdapat autokorelasi. Uji normalitas residual menggunakan Jarque-Bera. Pemeriksaan heteroskedastisitas residual dilakukan melalui uji ARCH.
- d. Forecasting ARIMA Model
Setelah model dipastikan memenuhi asumsi residual dan model memiliki nilai AIC paling kecil.

Model ARIMA akan dievaluasi dengan menggunakan RMSE dan dilakukan model hibrida dengan menggunakan GRU untuk memperbaiki akurasi dari model konvensional ARIMA.


II.4. Preprocessing ARIMA-GRU

Sebelum residual ARIMA digunakan sebagai data pelatihan GRU, dilakukan beberapa langkah tambahan agar data sesuai dengan format masukan GRU.

- a. Normalisasi Residual
Residual dinormalisasi menggunakan MinMaxScaler agar berada dalam rentang 0 sampai 1. Normalisasi diperlukan untuk mempercepat konvergensi model GRU dan mencegah dominasi nilai tertentu [11].
- b. Pembagian Data Latih dan Uji
Data yang telah dibentuk menjadi sekuens kemudian dipisahkan menjadi *training set* dan *testing set* dengan proporsi tertentu, misalnya 80% untuk pelatihan dan 20% untuk pengujian.

II.5. GRU Modeling

Gated Recurrent Unit (GRU) adalah salah satu varian RNN yang diperkenalkan oleh Cho pada 2014 dengan tujuan menyederhanakan arsitektur *Long Short-Term Memory* (LSTM) sekaligus tetap mempertahankan kemampuan dalam mempelajari ketergantungan jangka panjang pada data sekuensial [8]. Penggambaran arsitektur GRU dijelaskan pada gambar 1.



Gambar 2. Arsitektur GRU

Arsitektur GRU dijabarkan pada Gambar 2. sebagai sebuah sel yang menerima input x_t dan hidden state sebelumnya h_{t-1} . Hasil akhirnya adalah *hidden state* baru h_t yang menjadi representasi memori pada langkah waktu ke- t . Tahapan permodelan GRU yaitu:

- Penentuan Arsitektur Jaringan**
Model GRU disusun dengan beberapa lapisan, terdiri dari lapisan GRU inti dan lapisan Dense sebagai output. Jumlah neuron, fungsi aktivasi, dan konfigurasi lapisan ditentukan melalui proses Grid Search [16]. Grid Search juga mengoptimalkan delapan algoritma machine learning dan hasilnya menunjukkan peningkatan signifikan pada akurasi prediksi setelah dilakukan optimasi hiperparameter [17].
- Proses Pelatihan**
Model dilatih menggunakan residual yang telah dinormalisasi. Proses pelatihan dilakukan menggunakan algoritma optimasi seperti Adam dan fungsi loss MSE untuk meminimalkan kesalahan prediksi.
- Generalisasi**
Model diuji pada data testing untuk mengevaluasi kemampuan GRU dalam mempelajari pola non-linear yang tidak tertangkap oleh ARIMA.

II.6. Evaluasi Model

Kinerja model dievaluasi menggunakan dua metrik utama: MAE dan RMSE. Kedua metrik ini digunakan untuk menilai performa model ARIMA, model GRU residual, dan model hybrid ARIMA–GRU.

- MAE mengukur rata-rata kesalahan absolut antara nilai aktual dan prediksi. *MAE dirumuskan dengan formula 7* [18]:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (7)$$

Dengan:

- y_i : nilai aktual pada waktu ke- i
 $\hat{y}_i$: nilai prediksi
 N : jumlah total observasi.

- RMSE mengukur kesalahan dengan memberi penalti lebih besar untuk error besar, sehingga sensitif terhadap outlier. RMSE lebih sensitif terhadap outlier dan digunakan secara luas ketika penalti terhadap kesalahan besar dianggap penting,

misalnya dalam perencanaan produksi dan manajemen risiko. RMSE dirumuskan dengan formula 8 [18]:


$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (8)$$

Dalam praktiknya, nilai RMSE yang lebih kecil menandakan bahwa prediksi model mendekati nilai aktual secara konsisten. RMSE sering digunakan bersamaan dengan MAE untuk memberikan gambaran evaluasi yang lebih menyeluruh terhadap kualitas model [19].

III. HASIL DAN ANALISIS

III.1 Analisis Deskriptif IHK di Yogyakarta

Pergerakan IHK bulanan Kota Yogyakarta dari tahun 1979 hingga 2025. Secara umum, pola inflasi menunjukkan fluktuasi yang relatif tinggi pada periode awal dan cenderung stabil pada periode setelah tahun 2000. Pola data IHK bulanan dijelaskan pada Gambar 3.



Gambar 3. Pola Data Inflasi di Yogyakarta


Beberapa karakteristik penting yang terlihat dari grafik:

1. **Fluktuasi Tinggi pada Periode 1980–1990**
Rentang ini menunjukkan variabilitas inflasi yang cukup besar, dengan nilai IHK bulanan sering berada pada kisaran 2–4 persen. Hal ini dapat dikaitkan dengan kondisi ekonomi nasional yang masih belum stabil pada masa itu.
2. **Lonjakan IHK yang Sangat Tinggi pada 1998 (Krisis Moneter)**
Grafik memperlihatkan puncak IHK yang ekstrem mencapai lebih dari 14% pada tahun 1998. Lonjakan ini merupakan dampak langsung dari krisis moneter Asia yang menyebabkan depresiasi rupiah dan kenaikan harga barang secara drastis.
3. **Periode Stabil Pasca Tahun 2000**
Setelah tahun 2000, IHK Yogyakarta terlihat jauh lebih stabil, umumnya berada di bawah 2%. Meskipun masih terdapat beberapa puncak lokal pada tahun tertentu (misalnya 2005 dan 2013), variasi inflasi jauh lebih terkendali dibandingkan periode sebelumnya.
4. **Stabilitas Tinggi pada 2015–2025**
Pada dua dekade terakhir, inflasi cenderung sangat rendah dengan fluktuasi kecil, mengindikasikan kondisi ekonomi regional yang relatif stabil.

Secara keseluruhan, pola data menunjukkan kombinasi antara komponen linear (tren penurunan variabilitas) dan komponen non-linear (lonjakan ekstrem dan fluktuasi acak) yang menjadi dasar pemilihan model hybrid ARIMA-GRU.

III.2 Model ARIMA

Pola pada grafik ACF dan PACF dianalisis untuk menentukan kandidat model ARIMA yang sesuai. Plot ACF menunjukkan penurunan cepat pada beberapa lag awal, sedangkan PACF memiliki spike signifikan pada lag 1 hingga 3. Berdasarkan karakteristik grafik pada gambar 4, model ARIMA(1,0,2) dipilih sebagai kandidat utama untuk dievaluasi lebih lanjut.



Gambar 4. Plot ACF dan PACF

Model ARIMA(1,0,2) menghasilkan parameter AR(1), MA(1), dan MA(2) yang seluruhnya signifikan secara statistik, sehingga menunjukkan bahwa dinamika inflasi dipengaruhi oleh ketergantungan linier terhadap periode sebelumnya serta shock error jangka pendek. Nilai konstanta yang signifikan mengindikasikan adanya kecenderungan dasar pergerakan inflasi dari waktu ke waktu. Pada gambar 5 menunjukkan nilai AIC sebesar 1582.8 dan BIC sebesar 1604.4 memperlihatkan bahwa model ini memiliki kecocokan yang baik dan mampu menangkap struktur linier utama dalam data. Dengan demikian, ARIMA(1,0,2) dinilai memadai sebagai model dasar sebelum dikombinasikan dengan GRU dalam pendekatan *hybrid*.

SARIMAX Results						
=====						
Dep. Variable:	Inflasi	No. Observations:	561			
Model:	ARIMA(1, 0, 2)	Log Likelihood	-786.401			
Date:	Fri, 10 Oct 2025	AIC	1582.802			
Time:	11:55:55	BIC	1604.450			
Sample:	01-01-1979	HQIC	1591.254			
	- 09-01-2025					
Covariance Type:	opg					
=====						
	coef	std err	z	P> z	[0.025	0.975]


const	0.7105	0.193	3.684	0.000	0.333	1.089
ar.L1	0.8798	0.025	35.115	0.000	0.831	0.929
ma.L1	-0.4483	0.034	-13.208	0.000	-0.515	-0.382
ma.L2	-0.1391	0.043	-3.242	0.001	-0.223	-0.055
sigma2	0.9655	0.023	42.088	0.000	0.921	1.010
=====						
Ljung-Box (L1) (Q):	0.00	Jarque-Bera (JB):	28503.45			
Prob(Q):	0.97	Prob(JB):	0.00			
Heteroskedasticity (H):	0.17	Skew:	3.77			
Prob(H) (two-sided):	0.00	Kurtosis:	37.10			
=====						

Gambar 5. Model Result ARIMA

III.3 Diagnostik Residual ARIMA

Evaluasi residual ARIMA dilakukan untuk memastikan apakah model telah menangkap seluruh pola linier dalam data. Plot dan histogram residual pada gambar 6, menunjukkan bahwa sebagian besar nilai residual tersebar di sekitar nol, namun terdapat beberapa spike ekstrem yang menunjukkan adanya pola yang belum ditangkap oleh

model. Histogram residual mengindikasikan distribusi yang mendekati normal, tetapi masih terdapat kemencengan positif yang menandakan adanya asimetri dalam error.



Gambar 6. Plot Residual dan Histogram ARIMA

Pada Tabel 1 nilai Jarque–Bera mengindikasikan bahwa residual tidak berdistribusi normal dan terdapat penyimpangan yang cukup besar dari bentuk distribusi normal ideal. Selain itu, uji Ljung–Box pada lag ke-10 memberikan nilai $lb_stat = 29.38$ dengan $p\text{-value} = 0.00108$, yang berarti masih terdapat autokorelasi signifikan pada residual.


Tabel 1. Uji Asumsi Residual

Uji Asumsi Residual	Nilai	P-Value
<i>Jarque-Bera Test</i>	28.394	0.000
<i>Ljung-Box Test</i>	29.38	0.00108

Temuan ini menunjukkan bahwa meskipun ARIMA mampu menjelaskan sebagian pola linier, residualnya masih mengandung pola non-linear, asimetri, maupun volatilitas yang tidak dapat ditangkap oleh model linier tersebut.

III.4 Model ARIMA-GRU

Hasil visualisasi pada gambar 7 menunjukkan bahwa model hybrid memiliki kinerja yang lebih mendekati nilai aktual inflasi dibandingkan ARIMA saja. Kurva prediksi hybrid tampak lebih halus dan stabil, namun tetap mampu mengikuti arah pergerakan inflasi aktual. Pada periode dengan fluktuasi moderat, hybrid menunjukkan performa yang sangat baik dengan kesalahan yang relatif rendah. Meskipun masih terdapat deviasi pada periode lonjakan inflasi yang ekstrem, model hybrid tetap memberikan prediksi yang lebih realistis dibandingkan model tunggal, karena GRU mampu mengoreksi error ARIMA pada pola non-linear.



Gambar 7. Hasil Prediksi Model Hybrid

III.5 Evaluasi Model

Hasil evaluasi menunjukkan bahwa model hybrid memiliki performa yang lebih baik dibandingkan model ARIMA-only. Secara khusus, nilai MSE, RMSE, dan MAE pada model hybrid lebih rendah, menandakan tingkat kesalahan prediksi yang lebih kecil. Tabel 2 memberikan ringkasan hasil evaluasi:

Tabel 2. Evaluasi Model			
Model	MSE	RMSE	MAE
ARIMA	0.133588	0.365497	0.264622
ARIMA-GRU	0.114501	0.338380	0.235730

Penurunan ketiga metrik kesalahan tersebut menunjukkan bahwa integrasi ARIMA dan GRU berhasil menggabungkan keunggulan pemodelan statistik linear dan pembelajaran sekuens non-linear. Dengan demikian, model hybrid lebih efektif dalam mempelajari dinamika kompleks pada pola deret waktu inflasi di Yogyakarta.

IV. KESIMPULAN

Penelitian ini bertujuan untuk menghasilkan model peramalan inflasi yang lebih akurat dengan mengombinasikan model ARIMA sebagai penangkap pola linier dan GRU sebagai pemodel pola non-linear pada residual. Hasil analisis menunjukkan bahwa ARIMA(1,0,2) mampu menangkap struktur linier dasar inflasi, namun diagnostik residual mengungkapkan adanya autokorelasi, ketidaknormalan distribusi, dan indikasi heteroskedastisitas yang menandakan bahwa pola non-linear masih tersisa dalam data. Model GRU kemudian berhasil mempelajari ketidakteraturan tersebut pada residual ARIMA, sehingga ketika keduanya digabungkan dalam model hybrid, performanya meningkat secara konsisten.

Evaluasi model menunjukkan bahwa pendekatan hybrid ARIMA–GRU memberikan hasil prediksi yang lebih baik dibandingkan model ARIMA saja, sebagaimana ditunjukkan oleh penurunan MSE, RMSE, dan MAE. Nilai MSE turun dari 0.133588 menjadi 0.114501, RMSE dari 0.365497 menjadi 0.338380, dan MAE dari 0.264622 menjadi 0.235730. Perbaikan ini menegaskan bahwa integrasi metode statistik dan *deep learning* mampu mengatasi keterbatasan model masing-masing secara individual, sehingga lebih efektif dalam mempelajari dinamika kompleks deret waktu inflasi bulanan di Yogyakarta. Dengan demikian, model hybrid ARIMA–GRU dapat dijadikan alternatif yang unggul untuk peramalan inflasi ataupun deret waktu ekonomi lain yang memiliki karakteristik serupa.

UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih kepada semua pihak yang telah memberikan bantuan, dukungan, dan kontribusi selama proses penyusunan penelitian ini. Penghargaan yang sebesar-besarnya diberikan kepada Badan Pusat Statistik (BPS) yang menyediakan data inflasi sebagai dasar penelitian. Penulis juga mengucapkan terima kasih kepada dosen pembimbing yang telah memberikan arahan, masukan, dan koreksi yang sangat berarti dalam penyempurnaan penelitian ini. Tidak lupa, apresiasi diberikan kepada tim DISCOVER dalam pembuatan template ini. Semoga penelitian ini dapat memberikan kontribusi yang bermanfaat bagi pengembangan ilmu pengetahuan dan penerapan metode peramalan deret waktu di masa mendatang.

REFERENSI

- [1] S. Oktaviani, K. Merdiyanti, N. Salsabilla, S. Syudaha, S. Rahma Yuda Apriyanto Pendidikan Ekonomi, and U. Jambi, "Kenaikan Harga Barang Pokok Mempengaruhi Inflasi dan Stabilitas Politik: Studi Ekonomi Politik di Pasar Aur Duri Jambi", doi: 10.22437/jeec.v4i1.45270.
- [2] Imambang Eka Sulistya, "Penentuan Pusat Pertumbuhan Ekonomi dan Analisis Interaksi Spasial Antarwilayah Di Provinsi Daerah Istimewa Yogyakarta," *Jurnal Dinamika Ekonomi Pembangunan*, vol. 8, no. 1, pp. 63–78, Mar. 2025, doi: 10.33005/jdep.v8i1.712.
- [3] S. Agustini Sinaga, "Implementasi Metode Arima (Autoregressive Moving Average) Untuk Prediksi Penjualan Mobil," *Journal Global Tecnology Computer*, vol. 2, no. 3, pp. 102–109, 2023.
- [4] S. Deviana, D. Azis, dan Pandri Ferdias, J. Ir Sumantri Brojonegoro No, G. Meneng, and B. Lampung, "Analisis Model Autoregressive Integrated Moving Average Data Deret Waktu Dengan Metode Momen Sebagai Estimasi Parameter," 2021.
- [5] I. W. R. Pinastawa, M. G. Pradana, D. S. Setiawan, and A. Izzety, "Comparison of ARIMA and GRU Methods in Predicting Cryptocurrency Price Movements," *sinkron*, vol. 9, no. 1, pp. 96–105, Jan. 2025, doi: 10.33395/sinkron.v9i1.14235.
- [6] K. Annadurai, A. Saravanan, S. Kayalvili, E. Muniyandy, I. Aswani, and T. Yousef ABaker El-Ebiary, "Early Detection and Forecasting of Influenza Epidemics Using a Hybrid ARIMA-GRU Model," 2025. [Online]. Available: www.ijacsa.thesai.org
- [7] D. Kurniasari, T. Shella, M. Usman, and Warsono, "A Hybrid ARIMA-GRU Model for Forecasting Palm Oil Prices at PT Sawit Sumbermas Sarana in Central Kalimantan," *Integra: Journal of Integrated Mathematics and Computer Science* 2(1) 7-14, Feb. 2025.
- [8] Nendi Sunendar, Harjono P. Putro, and Rizki Hesnananda, "Prediksi Penjualan Aerosol Menggunakan Algoritma ARIMA, LSTM Dan GRU," *INSOLOGI: Jurnal Sains dan Teknologi*, vol. 4, no. 1, pp. 113–126, Feb. 2025, doi: 10.55123/insologi.v4i1.4868.
- [9] M. Firdaus and Shedriko, "PERBANDINGAN MODEL ARIMA MANUAL DAN AUTO DALAM MEMPREDIKSI NILAI EKSPOR MENGGUNAKAN PYTHON," 2024.
- [10] Z. Guo, "Research on the Augmented Dickey-Fuller Test for Predicting Stock Prices and Returns," *Advances in Economics, Management and Political Sciences*, vol. 44, no. 1, pp. 101–106, Nov. 2023, doi: 10.54254/2754-1169/44/20232198.
- [11] A. A. Pierre, S. A. Akim, A. K. Semeny, and B. Babiga, "Peak Electrical Energy Consumption Prediction by ARIMA, LSTM, GRU, ARIMA-LSTM and ARIMA-GRU Approaches," *Energies (Basel)*, vol. 16, no. 12, Jun. 2023, doi: 10.3390/en16124739.
- [12] I. F. Amri, A. Wulandari, K. N. Abidah, A. C. Irawan, and M. Al Haris, "Pemodelan ARIMAX untuk Meramalkan Harga Minyak Mentah Dunia," *Square : Journal of Mathematics and Mathematics Education*, vol. 5, no. 1, pp. 47–58, Apr. 2023, doi: 10.21580/square.2023.5.1.17074.
- [13] F. A. Rizalde, S. Mulyani, and N. Bachtiar, "Forecasting Hotel Occupancy Rate in Riau Province Using ARIMA and ARIMAX," 2021.
- [14] M. A. Firmansyah and C. R. Oktarina, "Kinerja Peramalan Autoregressive Integrated Moving Average dan Seasonal Autoregressive Integrated Moving Average dalam Memprediksi Kejadian Gempa Bumi Sumatra," *ejournal.unib.ac.id*, pp. 1–16, Jun. 2025, doi: 10.3369/diophantine.v4i1.41099.

- [15] Y. Zhang and G. Meng, "Simulation of an Adaptive Model Based on AIC and BIC ARIMA Predictions," in *Journal of Physics: Conference Series*, Institute of Physics, 2023. doi: 10.1088/1742-6596/2449/1/012027.
- [16] L. D. Wowor, "Implementation of Grid Search Method for Optimization in Convolutional Neural network Model Penerapan Grid Search Method Untuk Optimasi pada Model Convolutional Neural network," *Jurnal Teknik Informatika*, 2025.
- [17] D. M. Belete and M. D. Huchaiah, "Grid search in hyperparameter optimization of machine learning models for prediction of HIV/AIDS test results," *International Journal of Computers and Applications*, vol. 44, no. 9, pp. 875–886, 2022, doi: 10.1080/1206212X.2021.1974663.
- [18] L. S. Ihzaniah, A. Setiawan, and R. W. N. Wijaya, "Perbandingan Kinerja Metode Regresi K-Nearest Neighbor dan Metode Regresi Linear Berganda pada Data Boston Housing," *Jambura Journal of Probability and Statistics*, vol. 4, no. 1, pp. 17–29, May 2023, doi: 10.34312/jjps.v4i1.18948.
- [19] A. V Tatachar, "Comparative Assessment of Regression Models Based On Model Evaluation Metrics," *International Research Journal of Engineering and Technology*, 2021, [Online]. Available: www.irjet.net