

## Peramalan Inflasi dan Harga Minyak Mentah dengan Pendekatan Hybrid Statistika-Machine Learning dan Statistika-Deep Learning

**Christopher Andreas<sup>1</sup>, Elizabeth Nathania Witanto<sup>2</sup>, Yohana Jocelyn Guntur<sup>3</sup>, Felicia Joshlyn Purnomo<sup>4</sup>**<sup>1,2,3,4</sup> Program Studi Informatika, School of Information Technology, Universitas Ciputra, Surabaya, IndonesiaEmail: <sup>1</sup>christopher.andreas@ciputra.ac.id, <sup>2\*</sup>elizabeth.nathania@ciputra.ac.id, <sup>3</sup>yjocelyn@student.ciputra.ac.id,<sup>4</sup>fjoshlyn@student.ciputra.ac.id

Email Penulis Korespondensi: elizabeth.nathania@ciputra.ac.id

### Abstrak

Inflasi dan harga minyak mentah merupakan dua indikator ekonomi strategis yang memengaruhi stabilitas ekonomi nasional dan arah kebijakan publik. Peramalan yang akurat terhadap kedua variabel ini sangat penting untuk mendukung perencanaan fiskal, moneter, serta strategi sektor industri dan perdagangan. Karakteristik keduanya berbeda, dimana inflasi cenderung memiliki pola tren dan musiman yang relatif stabil, sedangkan harga minyak mentah bersifat fluktuatif dengan pengaruh faktor eksternal global. Perbedaan ini menuntut metode peramalan yang adaptif dan mampu bekerja baik pada kondisi data yang berbeda. Penelitian ini memiliki keterkaitan dengan *Sustainable Development Goals* (SDG 8 dan SDG 9). Penelitian ini bertujuan mengembangkan metode time series forecasting berbasis pendekatan hybrid melalui model statistika-machine learning dan statistika-deep learning. Pendekatan statistika dengan model *Autoregressive Integrated Moving Average* (ARIMA) digunakan untuk menangkap pola linear, kemudian hasil prediksi atau residual dari model ARIMA diproses lebih lanjut menggunakan algoritma machine learning yaitu *Support Vector Regression* (SVR) dan model deep learning yaitu *Long Short-Term Memory* (LSTM) untuk mempelajari pola non-linear. Dalam hal ini, evaluasi akurasi model diukur dengan metrik *symmetric Mean Absolute Percentage Error* (sMAPE). Hasil penelitian menunjukkan bahwa model ARIMA-SVR memiliki akurasi lebih baik dalam meramalkan data inflasi dengan nilai sMAPE sebesar 0,2072. Sebaliknya, model ARIMA-LSTM lebih akurat dalam meramalkan data harga minyak dengan nilai sMAPE sebesar 0,0548. Dengan demikian, pendekatan hybrid statistika-machine learning dan statistika-deep learning memiliki akurasi yang baik dalam memprediksi data yang bersifat time series.

**Kata Kunci:** Deep Learning, Hybrid, Machine Learning, Statistika, Time Series.

### Abstract

*Inflation and crude oil prices are two strategic economic indicators that influence national economic stability and public policy direction. Accurate forecasting of these variables is essential to support fiscal and monetary planning, as well as industrial and trade strategies. Their characteristics differ, inflation generally follows a stable trend and seasonal pattern, while crude oil prices are volatile and affected by global external factors. This requires adaptive forecasting methods that can handle diverse data behaviors. This study aligns with the Sustainable Development Goals (SDG 8 and SDG 9). It develops a hybrid time series forecasting approach combining statistical methods with machine learning and deep learning. The Autoregressive Integrated Moving Average (ARIMA) model captures linear patterns, while its residuals or predictions are further processed using Support Vector Regression (SVR) and Long Short-Term Memory (LSTM) to learn non-linear components. Model accuracy is evaluated using the symmetric Mean Absolute Percentage Error (sMAPE). Results indicate that the ARIMA-SVR model achieves better accuracy for inflation forecasting, with an sMAPE of 0.2072. Meanwhile, the ARIMA-LSTM model performs better for crude oil price forecasting, with an sMAPE of 0.0548. These findings show that hybrid statistical-machine learning and statistical-deep learning approaches provide reliable forecasting performance for time series data.*

**Keywords:** Deep Learning, Hybrid, Machine Learning, Statistics, Time Series.

## 1. PENDAHULUAN

Inflasi dan harga minyak mentah merupakan dua indikator ekonomi yang sangat berpengaruh terhadap stabilitas ekonomi nasional dan pengambilan kebijakan publik. Inflasi mempengaruhi daya beli masyarakat, suku bunga, serta stabilitas sektor keuangan [1]. Di sisi lain, harga minyak mentah berdampak langsung pada biaya produksi, transportasi, dan perdagangan internasional [2]. Perubahan signifikan pada kedua indikator ini dapat memicu gejolak ekonomi yang berdampak luas, sehingga kemampuan memprediksi pergerakannya menjadi sangat penting bagi pemerintah, pelaku industri, dan investor.

Peramalan (forecasting) terhadap data inflasi dan harga minyak mentah menuntut metode yang mampu menangkap pola tren, musiman, dan fluktuasi tak terduga. Pendekatan tradisional berbasis statistika seperti Autoregressive Integrated Moving Average (ARIMA) telah terbukti efektif dalam memodelkan pola linear dan musiman [3-4], namun sering kurang optimal dalam menangkap hubungan non-linear yang kompleks. Di sisi lain, metode machine learning dan deep learning memiliki kemampuan menangani hubungan non-linear, tetapi sering memerlukan jumlah data besar dan rawan overfitting [5].

Kombinasi berbagai pendekatan ini melalui model hybrid diharapkan mampu memanfaatkan keunggulan masing-masing metode: ARIMA untuk komponen linear, dan machine learning atau deep learning untuk komponen non-linear. Hal ini menjadikan pengembangan metode time series forecasting multiparadigma relevan dan strategis, khususnya untuk

indikator ekonomi yang berbeda karakteristiknya seperti inflasi dan harga minyak mentah. Dalam penelitian ini, model ARIMA dibangun untuk memodelkan komponen linear pada data inflasi dan harga minyak mentah. Residual dari ARIMA atau prediksi awal digunakan sebagai masukan (input feature) untuk model Support Vector Regression (SVR) atau Long Short-Term Memory (LSTM). Model hybrid dilatih untuk mempelajari pola non-linear yang belum terwakili oleh ARIMA [6]. Pendekatan hybrid ini diharapkan menghasilkan metode yang lebih akurat, stabil, dan adaptif terhadap dua jenis data ekonomi yang memiliki pola berbeda [7].

Penelitian terdahulu banyak membandingkan metode statistika dan machine learning secara terpisah. Misalnya, ARIMA digunakan untuk memodelkan inflasi dan harga minyak mentah, sementara LSTM digunakan untuk harga minyak mentah [8-10]. Beberapa studi telah mencoba metode hybrid, seperti ARIMA-SVR atau ARIMA-LSTM, namun umumnya hanya fokus pada satu jenis data atau satu domain spesifik [11-13]. Kebaruan penelitian ini adalah menyajikan perbandingan model hybrid statistika-machine learning dan statistika-deep learning untuk menangani dua tipe data ekonomi yang berbeda karakteristiknya yaitu inflasi dan harga minyak mentah. Akurasi model diukur dengan metrik symmetric Mean Absolute Percentage Error (sMAPE). Metrik ini digunakan sebagai alternatif dari MAPE yang biasa digunakan sebagai alat evaluasi model time series. sMAPE mengatasi kelemahan MAPE yang bersifat tidak simetris, dimana kesalahan over-forecast dan under-forecast diperlakukan berbeda [14]. Melalui penelitian ini, penggunaan model hybrid dapat dimanfaatkan dalam memprediksi data sesuai dengan karakteristik dataset yang digunakan.

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan Penelitian

Variabel penelitian terdiri dari tingkat inflasi bulanan di Indonesia (dalam satuan persentase) dan harga minyak mentah dunia atau Europe Brent Spot FOB (dalam satuan USD per barel). Sumber data berasal dari website Bank Indonesia dan US Energy Information Administration. Tahapan penelitian meliputi analisis deskriptif, pemodelan, peramalan, hingga perbandingan hasil dan evaluasi yang disajikan pada Tabel 1. Dalam hal ini, tingkat kesalahan yang digunakan sebesar 5%.

Tabel 1. Tahapan Penelitian.

Tahapan	Penjelasan
Tahap 1. Analisis Deskriptif	Mengeksplorasi dan mendeskripsikan karakteristik data penelitian berdasarkan ukuran statistika deskriptif.
Tahap 2. Pemodelan	Model yang dikembangkan berbasis hybrid statistika-machine learning (ARIMA-SVR) dan statistika-deep learning (ARIMA-LSTM). Pada tahap awal, dikembangkan model ARIMA terbaik yang mampu memprediksi data dengan baik. Pemodelan ARIMA tersebut menghasilkan suatu nilai residual. Berdasarkan nilai residual tersebut, model SVR dan LSTM dilatih untuk memperbaiki akurasi model awal yang terbentuk. Hasil pemodelan ini membentuk suatu model hybrid. Tahapan setiap proses pemodelan tersebut dijelaskan pada sub bab 2.2 hingga sub bab 2.4.
Tahap 3. Peramalan	Pada tahap pemodelan, diperoleh model ARIMA, ARIMA-SVR, dan ARIMA-LSTM. Setiap model yang terbentuk tersebut digunakan untuk melakukan peramalan selama 5 periode waktu selanjutnya.
Tahap 4. Perbandingan Hasil dan Evaluasi	Hasil peramalan dibandingkan terhadap data testing dan diukur akurasinya menggunakan sMAPE. Berdasarkan nilai sMAPE tersebut, dilakukan evaluasi hasil peramalan terhadap setiap model yang dihubungkan dengan karakteristik data penelitian.

### 2.2 Pendekatan Statistika untuk Data Time Series

Metode ARIMA dipilih sebagai pendekatan statistika time series dalam penelitian ini. Komponen AR dan MA dalam ARIMA mengasumsikan data bersifat stasioner, dimana nilai mean, variansi, dan kovariansnya tetap konstan seiring waktu. Sementara itu, komponen integrated (I) menunjukkan difference dari data tersebut [15]. Secara garis besar, model ARIMA untuk besar pengamatan Z pada waktu ke-t dapat dilihat pada persamaan (1).

$$\phi_p(\square)(1 - \square_1 \square - \square_2 \square_2 - \dots - \square_q \square_q) = \square_t(\square) \quad (1)$$

Dengan,

$$\phi_p(\square) = 1 - \square_1 \square - \square_2 \square_2 - \dots - \square_q \square_q,$$

$$\theta_q(\square) = 1 - \square_1 \square - \square_2 \square_2 - \dots - \square_q \square_q$$

Pada persamaan (1),  $\square_t$  merepresentasikan nilai galat atau error pada pengamatan t. Sementara p, d, dan q secara berurutan menggambarkan orde komponen *autoregressive*, *difference*, dan *moving average*. Untuk memenuhi syarat, prosedur pemodelan ARIMA dimulai dengan memastikan stasioneritas data sebagai asumsi dasar. Apabila ditemukan

data tidak stasioner, akan dilakukan transformasi data dan *differencing*. Selanjutnya, dilakukan estimasi model ARIMA menggunakan pendekatan *Least Square* berdasarkan kombinasi model yang sesuai. Kombinasi model ini ditinjau berdasarkan nilai *autocorrelation function* (ACF) dan *partial autocorrelation function* (PACF). Kedua nilai tersebut berguna dalam mengidentifikasi ketepatan komponen AR dan MA pada sebuah kombinasi model berdasarkan residual yang dihasilkan model tersebut. Jika residual kombinasi model tidak menunjukkan autocorrelation, nilai ACF dan PACF akan menunjukkan hasil yang rendah [16]. Model ARIMA secara tunggal terikat pada asumsi residual, dimana residual harus berdistribusi normal dan bersifat white noise atau tidak memiliki autocorrelation yang signifikan. Pemilihan model ARIMA terbaik didasarkan pada nilai error terendah sehingga dapat menghasilkan akurasi yang baik dalam memprediksi data.

### 2.3 Pendekatan Machine Learning untuk Data Time Series

SVR adalah pengaplikasian Support Vector Machine (SVM) yang paling umum. Model yang diproduksi oleh SVR hanya bergantung pada subset data karena *cost function* untuk model tidak menghiraukan training data yang dekat (dalam suatu batasan) dengan prediksi model [17]. SVM pada awalnya digunakan untuk klasifikasi, namun dikembangkan untuk regresi menjadi SVR. Fungsi dari SVR dapat dilihat pada persamaan (2).

$$\hat{y}(x) = \phi(x)^T w + b \quad (2)$$

Pada Persamaan (2),  $w$  merupakan vektor pembobotan model,  $b$  merepresentasikan bias, dan  $\phi(x)$  merupakan fungsi yang memetakan  $x$  dalam sebuah dimensi untuk hubungan yang non-linier [18]. Model SVR digunakan untuk mengembangkan model hybrid berdasarkan hasil pemodelan ARIMA yang telah dilakukan sebelumnya. Untuk itu, model SVR dilatih berdasarkan data residual model ARIMA dengan nilai rentang parameter yang sudah ditetapkan. Pemilihan parameter dilakukan dengan proses *Grid Search*, model dengan nilai error terendah dipilih dan digabungkan dengan model ARIMA sebelumnya untuk membentuk model hybrid ARIMA-SVR. Model hybrid tidak terikat pada asumsi residual sehingga penggunaan model ini dapat mengatasi pelanggaran asumsi yang dapat terjadi pada model dasar ARIMA.

### 2.4 Pendekatan Deep Learning untuk Data Time Series

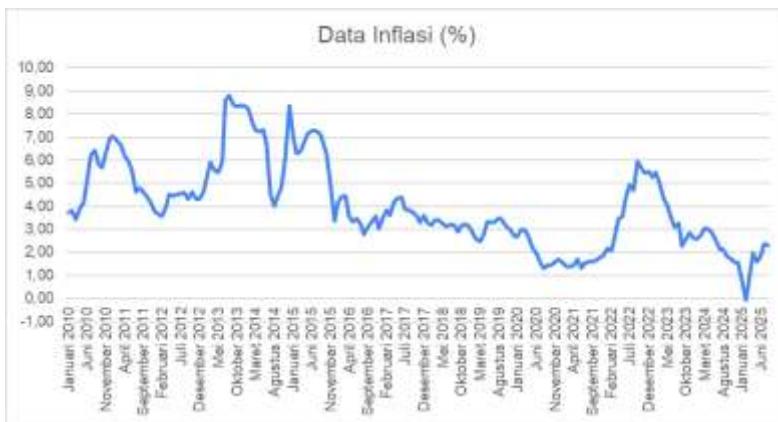
Model LSTM merupakan salah satu jenis *recurrent neural system* yang kuat, model ini dirancang secara khusus untuk menyelesaikan permasalahan *exploding* dan *vanishing gradient* yang sering terjadi saat mempelajari ketergantungan jangka panjang, sekaligus ketika *minimum time lag* sangat panjang. Masalah tersebut dapat diatasi dengan menggunakan mekanisme *constant error carousel* (CEC), yang berfungsi mempertahankan sinyal eror di dalam setiap sel unit. Setiap sel ini pada dasarnya juga merupakan jaringan rekuren dengan arsitektur menarik, dimana CEC dilengkapi dengan fitur tambahan berupa *input gate* dan *output gate* yang bersama-sama membentuk *memory cell*. Koneksi *self recurrent* pada sel ini menunjukkan adanya umpan balik dengan jeda satu langkah waktu.

Arsitektur model terdiri dari sekumpulan sub-jaringan yang terhubung secara rekuren (*memory block*). Ide utama dari *memory block* adalah untuk mempertahankan *state*-nya seiring waktu dan mengatur aliran informasi melalui *unit gating* non-linear [19]. Seperti model SVR, pemilihan parameter model LSTM dilakukan melalui proses *Grid Search* berdasarkan rentang nilai parameter yang sudah ditetapkan. Model dengan nilai error terendah dipilih dan digabungkan dengan model ARIMA untuk membentuk model hybrid ARIMA-LSTM.

## 3. HASIL DAN PEMBAHASAN

### 3.1 Analisis Deskriptif

Pergerakan data inflasi dan harga minyak mentah secara umum memiliki karakteristik yang berbeda. Nilai mean dari kedua data berturut-turut adalah 4,01 dan 77,83. Di sisi lain, standar deviasi dari inflasi dan harga minyak mentah berturut-turut adalah 1,89 dan 24,25. Nilai koefisien variasi dari data inflasi sebesar 46,32, sedangkan data harga minyak mentah memiliki nilai koefisien variasi sebesar 31,41. Hal ini mengindikasikan bahwa data inflasi memiliki variabilitas yang lebih besar seperti yang ditunjukkan pada Gambar 1 dan Gambar 2.



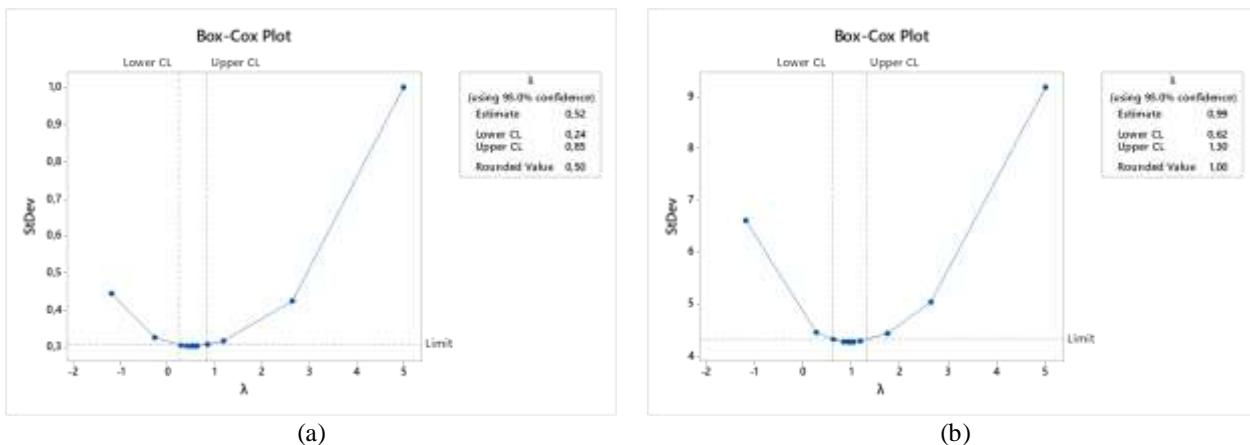
Gambar 1. Pergerakan Inflasi.



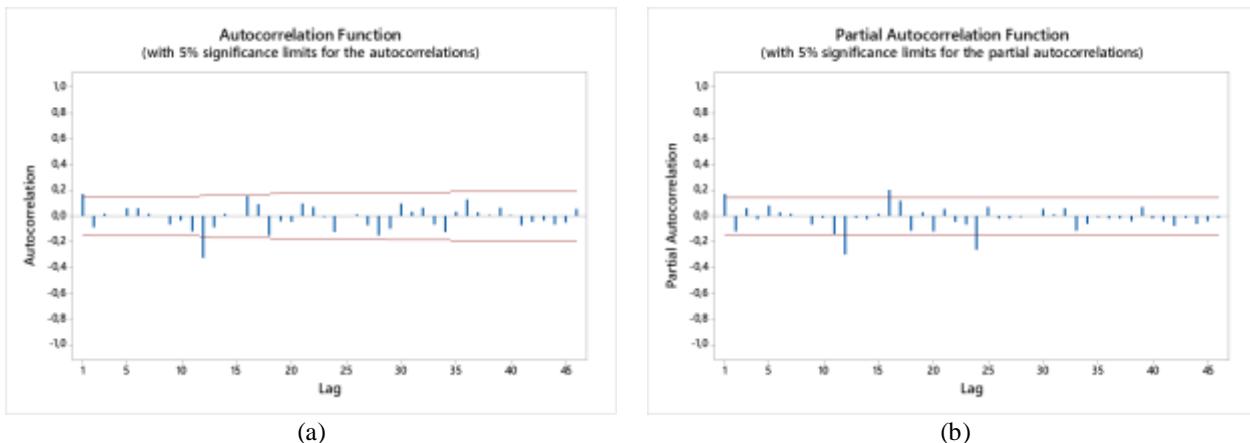
Gambar 2. Pergerakan Data Harga Minyak Mentah.

### 3.2 Penerapan Model Statistika untuk Data Time Series

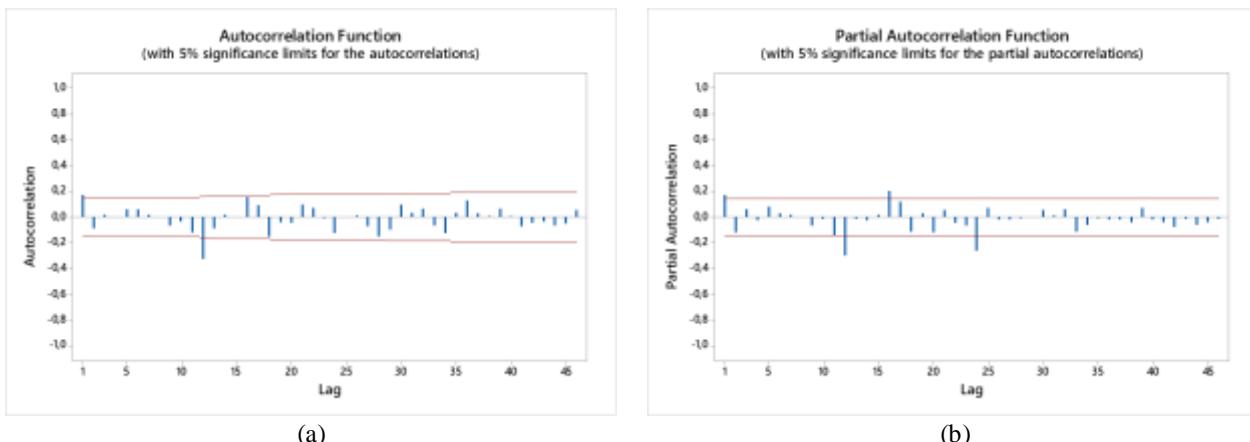
Pada tahap awal, dilakukan proses transformasi data agar data bersifat stasioner secara variansi, dengan menggunakan transformasi Box-Cox. Hasil transformasi untuk data inflasi dan harga minyak mentah disajikan pada Gambar 3. Setelah itu, data didifferencing 1 kali agar bersifat stasioner secara mean. Data yang sudah stasioner telah memenuhi syarat untuk dimodelkan dengan ARIMA. Penentuan orde model ARIMA pada setiap dataset ditelusuri menggunakan kurva ACF dan PACF seperti pada Gambar 4 dan Gambar 5. Berdasarkan Gambar 4, terlihat bahwa kurva ACF dan PACF signifikan pada lag 1. Dengan mempertimbangkan model deterministik (D) dan probabilistik (P), maka terdapat 6 kombinasi model ARIMA yang dapat dibentuk untuk pemodelan inflasi secara statistika yaitu  $ARIMA(1,1,0)D$ ,  $ARIMA(1,1,0)P$ ,  $ARIMA(0,1,1)D$ ,  $ARIMA(0,1,1)P$ ,  $ARIMA(1,1,1)D$ , dan  $ARIMA(1,1,1)P$ . Di sisi lain, berdasarkan Gambar 5, kurva ACF signifikan pada lag 1, sedangkan kurva PACF signifikan hingga lag 2. Oleh sebab itu, terdapat 12 kombinasi model ARIMA yang layak dipertimbangkan untuk pemodelan harga minyak mentah diantaranya  $ARIMA(2,1,1)D$ ,  $ARIMA(2,1,1)P$ ,  $ARIMA(2,1,0)D$ ,  $ARIMA(2,1,0)P$ ,  $ARIMA(1,1,1)D$ ,  $ARIMA(1,1,1)P$ ,  $ARIMA(1,1,0)D$ ,  $ARIMA(1,1,0)P$ ,  $ARIMA(0,1,1)D$ , dan  $ARIMA(0,1,1)P$ . Setiap kombinasi model dipertimbangkan untuk memperoleh model ARIMA terbaik. Model terbaik ditandai dengan parameter yang bersifat signifikan dan nilai Mean Square Error (MSE) terendah.



Gambar 3. Hasil Transformasi Box-Cox untuk (a) Data Inflasi dan (b) Data Harga Minyak Mentah.



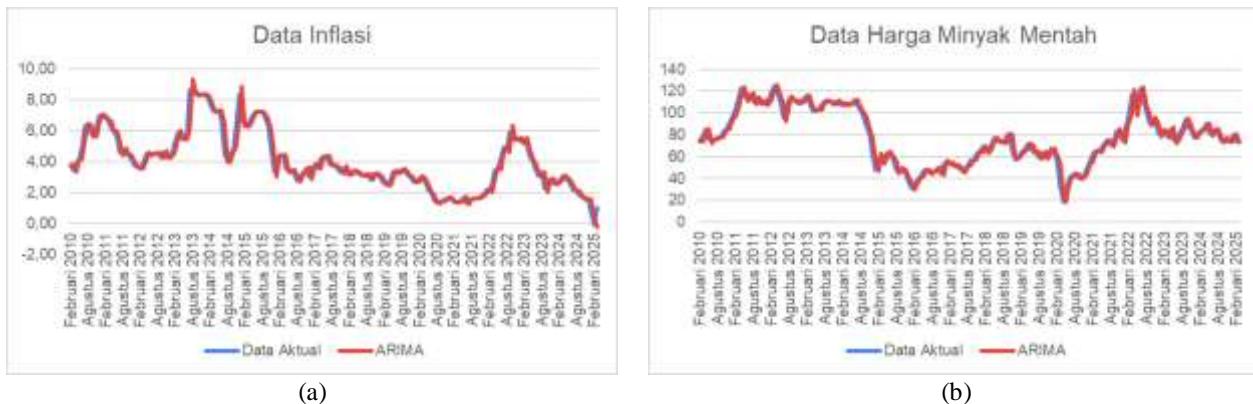
Gambar 4. Kurva (a) ACF dan (b) PACF dari Data Inflasi.



Gambar 5. Kurva (a) ACF dan (b) PACF dari Data Harga Minyak Mentah.

Untuk data inflasi, terdapat 2 model dengan parameter signifikan yaitu model  $\text{ARIMA}(1,1,0)$  dan  $\text{ARIMA}(0,1,1)$ . Jika dibandingkan, nilai MSE dari model  $\text{ARIMA}(0,1,1)$  lebih kecil dibandingkan model  $\text{ARIMA}(1,1,0)$ . Hal ini menunjukkan bahwa model  $\text{ARIMA}(0,1,1)$  probabilistik merupakan model terbaik dalam memprediksi data inflasi di Indonesia. Nilai sMAPE dari model ini mencapai 11,71% pada data train yang menunjukkan performa yang baik. Untuk data harga minyak mentah, terdapat 3 model dengan parameter signifikan yaitu  $\text{ARIMA}(2,1,0)$ ,  $\text{ARIMA}(1,1,0)$ , dan  $\text{ARIMA}(0,1,1)$ . Dari ketiga model tersebut, model  $\text{ARIMA}(2,1,0)$  probabilistik memiliki nilai MSE paling minimum dan nilai sMAPE sebesar 6,73% terhadap data train. Secara umum, pendekatan statistika untuk mampu memberikan prediksi yang baik, karena sudah mampu menangkap pola pergerakan data seperti pada Gambar 6. Namun, jika dianalisis lebih lanjut, residual dari model ARIMA untuk pemodelan inflasi ini

tidak bersifat white noise berdasarkan hasil pengujian Ljung-Box. Selain itu, residual model ARIMA untuk pemodelan inflasi dan harga minyak mentah juga tidak berdistribusi normal berdasarkan hasil pengujian Kolmogorov-Smirnov. Secara teori, jika residual tidak bersifat white noise atau tidak berdistribusi normal pada model ARIMA yang sudah terbentuk, maka pemodelan harus dianalisis lebih lanjut dengan teknik lanjutan, salah satunya adalah dengan membentuk model hybrid. Pada penelitian ini, model ARIMA yang sudah diperoleh dilanjutkan dengan menggabungkan model machine learning (SVR) dan deep learning (LSTM) sehingga membentuk model hybrid berupa ARIMA-SVR dan ARIMA-LSTM.



Gambar 6. Perbandingan Hasil Prediksi ARIMA dengan Data Aktual untuk Data (a) Inflasi dan (b) Harga Minyak Mentah.

### 3.3 Penerapan Model Hybrid Statistika-Machine Learning

Pada bagian ini, hasil pemodelan dengan ARIMA dilanjutkan dengan pemodelan machine learning menggunakan SVR. Estimasi parameter dilakukan dengan proses Grid Search. Rentang nilai parameter yang digunakan untuk parameter C adalah 0.1, 1, 10, dan 100, parameter gamma adalah scale, auto, 0.1, dan 1, sedangkan parameter kernel berupa rbf. Pemilihan parameter terbaik dipilih berdasarkan model dengan nilai MSE paling minimum. Pada data inflasi, parameter terpilih untuk C adalah 0.1, dengan parameter gamma berupa scale, dan kernel rbf. Di sisi lain, pada data harga minyak mentah, parameter terpilih untuk C adalah 0.1, dengan parameter gamma berupa 0.1, dan kernel rbf. Dengan model hybrid tersebut, diperoleh nilai akurasi terhadap data train yang baik dengan nilai sMAPE masing-masing sebesar 10.71% dan 13.13% pada data inflasi dan harga minyak mentah. Gambar 7 menunjukkan perbandingan hasil akurasi dari model ARIMA-SVR dengan data train.

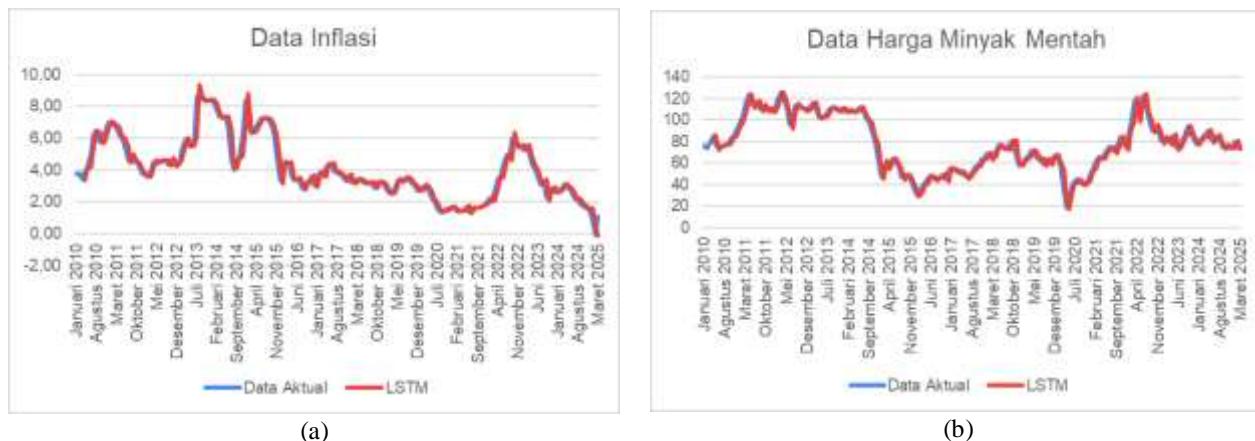


Gambar 7. Perbandingan Hasil Prediksi ARIMA-SVR dengan Data Aktual untuk Data (a) Inflasi dan (b) Harga Minyak Mentah.

### 3.4 Penerapan Model Hybrid Statistika-Deep Learning

Seperti pada bagian sebelumnya, bagian ini menggabungkan model ARIMA dengan LSTM. Parameter model LSTM dipilih dengan metode Grid Search dengan rentang parameter untuk model units sebesar 32 dan 64, batch size sebesar 8

dan 16, epochs sebesar 50 dan 100, serta model optimizer menggunakan adam dan rmsprop. Untuk data inflasi, diperoleh parameter terbaik dengan model units 32, batch size 8, epochs 100, dan model optimizer adam. Model ini mampu meraih nilai sMAPE sebesar 11.48% terhadap data train. Di sisi lain, parameter terbaik untuk model harga minyak mentah adalah model dengan model units 32, batch size 16, epochs 100, dan model optimizer rmsprop. Model ini mampu meraih nilai sMAPE sebesar 6.89% terhadap data train.



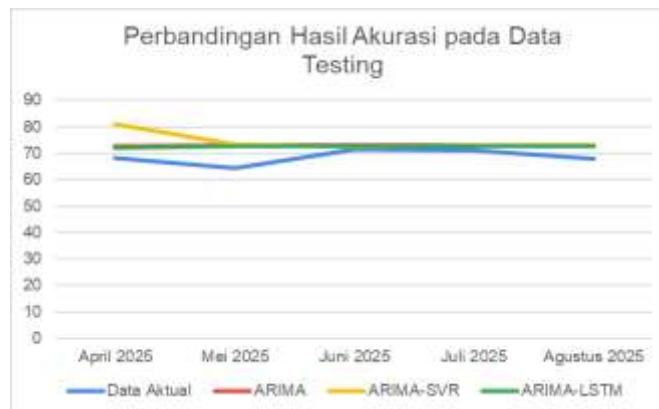
Gambar 8. Perbandingan Hasil Prediksi ARIMA-LSTM dengan Data Aktual untuk Data (a) Inflasi dan (b) Harga Minyak Mentah.

### 3.5 Perbandingan Model Hybrid Statistika-Machine Learning dan Statistika-Deep Learning

Pada data train, model hybrid ARIMA-SVR dan ARIMA-LSTM menunjukkan performa yang baik. Pada data testing, performa model dalam melakukan peramalan disajikan pada Gambar 9 dan Gambar 10. Gambar 9 menunjukkan bahwa model ARIMA-SVR memiliki kemampuan prediktif paling baik terhadap data inflasi dengan nilai sMAPE sebesar 0.2072. Sebaliknya, pada data harga minyak mentah, model ARIMA-LSTM mampu memperoleh akurasi tertinggi dengan nilai sMAPE sebesar 0.0569 (lihat Gambar 10). Perbandingan akurasi antar model disajikan pada Tabel 2.



Gambar 9. Perbandingan Hasil Akurasi Peramalan untuk Data Inflasi.



Gambar 10. Perbandingan Hasil Akurasi Peramalan untuk Data Harga Minyak Mentah.

Tabel 2. Perbandingan Nilai sMAPE pada Setiap Model.

Model	Data Inflasi	Data Harga Minyak Mentah
ARIMA	0,3012	0,0626
ARIMA-SVR	0,2072	0,0920
ARIMA-LSTM	0,3375	0,0569

Tabel 2 menunjukkan bahwa model hybrid yang tepat dapat meningkatkan akurasi model. Pada data inflasi yang memiliki karakteristik nilai standar deviasinya hampir setengah kali dari meannya, model hybrid antara statistika dan machine learning memiliki performa yang lebih baik dibandingkan dengan model hybrid statistika dengan deep learning. Sebaliknya, model hybrid statistika-deep learning lebih sesuai untuk data dengan karakteristik variabilitas yang lebih kecil. Dengan demikian, karakteristik data dapat dipertimbangkan dalam menentukan metode peramalan yang lebih sesuai.

#### 4. KESIMPULAN

Dengan indikator akurasi berupa sMAPE, diperoleh bahwa model hybrid statistika-machine learning memiliki akurasi lebih baik dalam meramalkan data inflasi, sedangkan model hybrid statistika-deep learning memiliki akurasi lebih baik dalam meramalkan data harga minyak mentah. Secara umum, model hybrid yang tepat mampu meningkatkan akurasi model, dibandingkan dengan penggunaan model tunggal. Penelitian lebih lanjut dapat dilakukan dengan menerapkan model hybrid pada data yang bersifat multivariat seperti penggunaan VAR-SVR, dan sebagainya.

#### UCAPAN TERIMAKASIH

Tim peneliti menyampaikan terima kasih pada pihak yang telah mendukung kegiatan penelitian ini.

#### DAFTAR PUSTAKA

- [1] A. Bilalli, M. Sadiku, and L. Sadiku, “The impact of inflation on financial sector performance: Evidence from OECD countries,” *Economics*, vol. 12, pp. 263–276, 2024, doi: 10.2478/eoik-2024-0028.
- [2] G. Brancaccio, M. Kalouptsidi, and T. Papageorgiou, “The impact of oil prices on world trade,” *Review of International Economics*, 2022, doi: 10.1111/roie.12632.
- [3] W. Juraphanthong and K. Kesorn, “Autoregressive integrated moving average with semantic information: An efficient technique for intelligent prediction of dengue cases,” *Engineering Applications of Artificial Intelligence*, vol. 143, p. 109985, 2025, doi: 10.1016/j.engappai.2024.109985.
- [4] C. Andreas, I. A. Rahmayanti, and S. M. Ulyah, “The impact of US-China trade war in forecasting the gold price using ARIMAX model,” in *AIP Conference Proceedings*, vol. 2329, no. 1, p. 060011, Feb. 2021, doi: 10.1063/5.0043277.
- [5] P. Bartlett, A. Montanari, and A. Rakhlin, “Deep learning: a statistical viewpoint,” *Acta Numerica*, vol. 30, pp. 87–201, 2021, doi: 10.1017/S0962492921000027.
- [6] Y. Zhao and Z. Chen, “Forecasting stock price movement: New evidence from a novel hybrid deep learning model,” *Journal of Asian Business and Economic Studies*, 2021, doi: 10.1108/jabes-05-2021-0061.
- [7] M. Ahmadi, S. Jafarzadeh-Ghoushchi, R. Taghizadeh, and A. Sharifi, “Presentation of a new hybrid approach for forecasting economic growth using artificial intelligence approaches,” *Neural Computing and Applications*, vol. 31, pp. 8661–8680, 2019, doi: 10.1007/s00521-019-04417-0.
- [8] S. Jafarian-Namin, S. Ghomi, M. Shojai, and S. Shavvalpour, “Annual forecasting of inflation rate in Iran: Autoregressive integrated moving average modeling approach,” *Engineering Reports*, vol. 3, 2021, doi: 10.1002/eng2.12344.
- [9] I. A. Rahmayanti, C. Andreas, and S. M. Ulyah, “Does US-China trade war affect the Brent crude oil price? An ARIMAX forecasting approach,” in *AIP Conference Proceedings*, vol. 2329, no. 1, p. 060010, Feb. 2021, doi: 10.1063/5.0042003.
- [10] A. Altan and S. Karasu, “Crude oil time series prediction model based on LSTM network with chaotic Henry gas solubility optimization,” *Energy*, 2021, doi: 10.1016/j.energy.2021.122964.
- [12] C. Zhang and X. Zhou, “Forecasting value-at-risk of crude oil futures using a hybrid ARIMA-SVR-POT model,” *Heliyon*, vol. 10, p. e23358, 2023, doi: 10.1016/j.heliyon.2023.e23358.
- [13] D. Fan, H. Sun, J. Yao, K. Zhang, X. Yan, and Z. Sun, “Well production forecasting based on ARIMA-LSTM model considering manual operations,” *Energy*, vol. 220, p. 119708, Mar. 2021, doi: 10.1016/j.energy.2020.119708.
- [14] C. Andreas, “Perbandingan Pendekatan Statistika dan Machine Learning dalam Peramalan Data Time Series,” *Jurnal Sistem Informasi Triguna Dharma (JURSI TGD)*, vol. 4, no. 4, pp. 778–785, Jul. 2025.
- [15] J. Tayman and D. Swanson, “On the validity of MAPE as a measure of population forecast accuracy,” *Population Research and Policy Review*, vol. 18, pp. 299–322, 1999, doi: 10.1023/a:1006166418051.

# JURNAL SISTEM INFORMASI TGD

Volume 5, Nomor 1, Januari 2026, Hal 140-148

P-ISSN : 2828-1004 ; E-ISSN : 2828-2566

<https://ojs.trigunadharma.ac.id/index.php/jsi>



- [16] A. S. Panjaitan, M. R. Maretha, Hilmiah, and B. Mardhotillah, "Optimalisasi Penerapan Metode ARIMA dalam Mengestimasi Harga Emas di Negara Indonesia", JESI, vol. 3, no. 2, pp. 136-146, Oct. 2023.
- [17] P. Visutsak, R. Wongpanti and P. Netisopakul, "FORECASTING CBOE OPENING VALUES: AN EFFECTIVE ARIMA APPROACH WITH TRANSFORMATION AND MODEL DIAGNOSTICS," Suranaree Journal of Science and Technology, vol. 31, no. 4, pp. 1-11, 2024.
- [18] D. Basak, S. Pal and D. C. Patranabis, "Support Vector Regression," Neural Information Processing - Letters and Reviews, vol. 11, no. 10, 2007.
- [19] I. R. Sudarmin, and Z. Rais, "Analisis Support Vector Regression (SVR) dengan Kernel Radial Basis Function (RBF) untuk Memprediksi Laju Inflasi di Surabaya," VARIANSI: Journal of Statistics and Its Application on Teaching and Research, vol. 4, no. 1, pp. 30-28, 2022.
- [20] G. Van Houdt, C. Mosquera, and G. Nápoles, "A review on the long short-term memory model," Artificial Intelligence Review, vol. 53, no. 8, May 2020, doi: <https://doi.org/10.1007/s10462-020-09838-1>.