



PERBANDINGAN *HYBRID* ARIMA-NNAR DAN ARIMA-SVR PADA PERAMALAN NILAI IMPOR MIGAS DAN NON-MIGAS INDONESIA

Fariskika Aulia Mukhtiar*, Universitas Negeri Yogyakarta

Sri Andayani, Universitas Negeri Yogyakarta

*e-mail: fariskikaaulia.2021@student.uny.ac.id

Abstrak. Peramalan nilai impor migas dan non-migas berperan penting dalam pengambilan keputusan ekonomi dan perdagangan. Model *AutoRegressive Integrated Moving Average* (ARIMA) sering digunakan dalam peramalan deret waktu, tetapi memiliki keterbatasan dalam menangkap pola non-linear. Penelitian ini mengevaluasi performa model *hybrid* ARIMA-NNAR dan ARIMA-SVR dalam peramalan nilai impor migas dan non-migas Indonesia, menentukan model terbaik berdasarkan metrik keakuratan, serta menganalisis pola residual untuk menilai perlunya pendekatan *hybrid*. Data impor migas dan non-migas Indonesia dari Januari 2011 hingga Desember 2024 digunakan dengan pembagian 80% untuk pelatihan dan 20% untuk pengujian. Model *hybrid* menggabungkan ARIMA dengan *Neural Network AutoRegression* (NNAR) dan *Support Vector Regression* (SVR), menggunakan residual ARIMA sebagai input tambahan. Evaluasi menggunakan RMSE, MAE, dan MAPE menunjukkan bahwa ARIMA-NNAR lebih akurat untuk impor migas, sedangkan ARIMA-SVR lebih unggul untuk impor non-migas. Residual ARIMA untuk impor migas sudah bersifat *white noise*, sehingga pendekatan *hybrid* tidak diperlukan, sedangkan residual ARIMA untuk impor non-migas belum *white noise*, sehingga pendekatan *hybrid* ARIMA-SVR terbukti lebih efektif dalam meningkatkan akurasi peramalan.

Kata kunci: ARIMA-NNAR, ARIMA-SVR, *Hybrid*, *Impor Migas*, *Impor Non-Migas*.

Abstract. Forecasting oil and non-oil import values plays a crucial role in economic and trade decision-making. The *AutoRegressive Integrated Moving Average* (ARIMA) model is widely used in time series forecasting but has limitations in capturing non-linear patterns. This study evaluates the performance of *hybrid* ARIMA-NNAR and ARIMA-SVR models in forecasting Indonesia's oil and non-oil import values, identifies the best-performing model based on accuracy metrics, and analyzes residual patterns to assess the necessity of a *hybrid* approach. Import data from January 2011 to December 2024 is utilized, with 80% allocated for training and 20% for testing. The *hybrid* models combine ARIMA with *Neural Network AutoRegression* (NNAR) and *Support Vector Regression* (SVR), incorporating ARIMA residuals as additional inputs. Model evaluation using RMSE, MAE, and MAPE indicates that ARIMA-NNAR performs better for oil imports, while ARIMA-SVR outperforms for non-oil imports. The ARIMA residuals for oil imports exhibit *white noise*, making a *hybrid* approach unnecessary, whereas the residuals for non-oil imports do not exhibit *white noise*, demonstrating that the ARIMA-SVR *hybrid* model effectively improves forecasting accuracy.

Keywords: *ARIMA-NNAR, ARIMA-SVR, Hybrid, Oil Imports, Non-Oil Imports.*

PENDAHULUAN

Peramalan nilai impor migas dan non-migas Indonesia menjadi aspek penting dalam perekonomian nasional, mengingat volatilitas harga komoditas global yang dapat berdampak signifikan terhadap stabilitas ekonomi. Model *AutoRegressive Integrated Moving Average* (ARIMA) merupakan salah satu metode klasik yang banyak digunakan dalam analisis deret waktu, terutama dalam memodelkan pola linear pada data historis. Namun, ARIMA memiliki keterbatasan dalam menangkap pola non-linear yang sering muncul dalam data ekonomi. Untuk mengatasi permasalahan ini, pendekatan *hybrid* seperti ARIMA-NNAR (*Neural Network Autoregression*) dan ARIMA-SVR (*Support Vector Regression*) dikembangkan. Kombinasi model statistik tradisional dengan metode pembelajaran mesin ini diharapkan mampu meningkatkan akurasi peramalan dengan menangkap pola data yang lebih kompleks. Model *hybrid* telah terbukti efektif dalam berbagai studi sebelumnya, yang menunjukkan keunggulan dalam menangkap pola musiman, linearitas, dan kompleksitas data dibandingkan dengan model tunggal (Büyükşahin dan Ertekin, 2019).

Berbagai penelitian terdahulu telah membuktikan efektivitas model *hybrid* dalam berbagai bidang. Perone (2021) mengombinasikan ARIMA dengan NNAR, TBATS, dan ETS dalam memprediksi penyebaran COVID-19 di Italia dan menemukan bahwa model *hybrid* mampu menangkap pola data yang lebih akurat dibandingkan model tunggal. Dalam konteks pasar saham, Pramudhitasari (2016) meneliti *hybrid* ARIMA-SVR untuk peramalan Indeks Harga Saham Gabungan (IHSG) dan menemukan bahwa kombinasi ARIMA (2,1,1) dengan SVR menggunakan kernel RBF/Gaussian menghasilkan RMSE lebih kecil dibandingkan ARIMA murni. Hal serupa juga ditemukan oleh Sihombing et al. (2022), yang menunjukkan bahwa ARIMA-SVR memiliki nilai MAPE lebih kecil dalam peramalan IHSG selama periode 1 Januari 2020 hingga 31 Oktober 2021. Sementara itu, dalam sektor pertanian, Palupi (2023) membandingkan ARIMA-NNAR dan ARIMA-SVM untuk memprediksi produksi cabai rawit di enam provinsi sentra produksi di Indonesia. Hasil penelitian tersebut menunjukkan bahwa ARIMA-SVM memiliki performa lebih baik dibandingkan ARIMA-NNAR, meskipun ARIMA tetap efektif dalam menangkap pola musiman yang jelas.

Meskipun berbagai penelitian telah mengonfirmasi keunggulan model *hybrid* dalam peramalan, kajian yang secara spesifik membandingkan performa ARIMA-NNAR dan ARIMA-SVR dalam konteks nilai impor migas dan non-migas Indonesia masih terbatas. Hal ini menjadi kesenjangan penelitian yang perlu diisi untuk menguji efektivitas kedua model dalam menangkap volatilitas harga komoditas global. Nilai impor migas dan non-migas dipilih sebagai objek penelitian karena memiliki dampak signifikan terhadap stabilitas ekonomi nasional serta fluktuasi yang cukup tinggi di pasar internasional. Volatilitas ini mencerminkan risiko dan ketidakpastian di pasar, di mana perubahan harga yang besar dan tidak terduga dapat memengaruhi kebijakan perdagangan dan strategi bisnis (Hull, 2015). Oleh karena itu, penelitian ini akan mengevaluasi performa model *hybrid* ARIMA-NNAR dan ARIMA-SVR dalam memprediksi nilai impor migas dan non-migas Indonesia, dengan tujuan memberikan informasi yang lebih akurat bagi pengambil kebijakan dan pelaku industri.

Penelitian ini akan menggunakan data nilai impor migas dan non-migas Indonesia pada periode Januari 2011 hingga Desember 2024, dengan evaluasi performa model berdasarkan metrik keakuratan seperti *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). Hasil penelitian ini diharapkan dapat memberikan kontribusi teoritis dalam pengembangan metode peramalan, khususnya terkait pemanfaatan model *hybrid* dalam menangani data ekonomi yang bersifat linear dan non-linear. Secara

praktis, penelitian ini dapat membantu pemerintah dalam menyusun kebijakan perdagangan berbasis data serta memberikan wawasan bagi pelaku bisnis dalam strategi impor dan pengelolaan stok bahan baku. Selain itu, penelitian ini juga dapat menjadi referensi bagi akademisi dan praktisi *data science* dalam mengembangkan model prediksi yang lebih baik untuk berbagai sektor ekonomi dan industri.

METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan metode komparatif untuk membandingkan performa model *hybrid* ARIMA-NNAR dan ARIMA-SVR dalam meramalkan nilai impor migas dan non-migas Indonesia. Data sekunder diperoleh dari Badan Pusat Statistik (BPS) dan dianalisis menggunakan berbagai teknik statistika serta *machine learning*. Model ARIMA-NNAR merupakan kombinasi antara ARIMA dan *Neural Network Autoregression* (NNAR), sedangkan ARIMA-SVR menggabungkan ARIMA dengan *Support Vector Regression* (SVR). Evaluasi model dilakukan berdasarkan metrik *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE).

Data penelitian yang digunakan mencakup nilai impor migas dan non-migas bulanan Indonesia dari Januari 2011 hingga Desember 2024, dengan total data masing-masing variabel adalah 168 observasi. Teknik pengumpulan data dilakukan dengan metode dokumentasi melalui pengunduhan data dari BPS dan dianalisis menggunakan perangkat lunak *RStudio*. Berikut adalah langkah-langkah analisis peramalan data menggunakan model *hybrid* ARIMA-NNAR dan ARIMA-SVR:

1. Eksplorasi Data dilakukan untuk memahami karakteristik data melalui analisis statistik deskriptif seperti rata-rata, median, standar deviasi, serta minimum dan maksimum nilai impor, serta visualisasi menggunakan plot time series untuk mengidentifikasi tren dan pola musiman.
2. Subset Data dilakukan dengan membagi data menjadi 80% untuk data latih (*train*) dan 20% untuk data uji (*test*), di mana 134 observasi pertama digunakan untuk pelatihan dan 34 observasi terakhir digunakan untuk pengujian agar model diuji dengan data yang belum pernah digunakan selama pelatihan.
3. Uji Stasioneritas dilakukan untuk menguji kestasioneran data menggunakan uji *Box-Cox* untuk varians dan uji *Augmented Dickey-Fuller* (ADF) untuk rata-rata, serta menerapkan *differencing* atau transformasi jika data tidak stasioner.
 - a) Untuk data yang tidak stasioner dalam varians dilakukan transformasi data dengan *box-cox transformation* (Wei, 2006).

$$T(Z_t) = \frac{Z_t^{(\lambda)} - 1}{\lambda} \quad (1)$$

dengan Z_t adalah data penelitian periode ke- t , λ adalah parameter transformasi, dan $T(Z_t)$ adalah hasil transformasi *box-cox* periode ke- t .

- b) Untuk data yang tidak stasioner dalam rata-rata dilakukan *differencing* dengan perhitungan pada persamaan (2) (Enders, 2014).

$$Z'_t = Z_t - Z_{t-1} \quad (2)$$

dengan Z_t adalah data penelitian periode ke- t , Z_{t-1} adalah data penelitian periode ke- $t - 1$, Z'_t adalah Hasil *differencing* periode ke- t .

4. Melakukan pemodelan ARIMA dengan data *train* nilai impor migas dan non-migas Indonesia. Adapun model ARIMA dituliskan pada persamaan (3) (Wei, 2006).

$$\phi_p(B)(1-B)^d Z_t = \theta_0 + \theta_q(B)e_t \quad (3)$$

dengan Z_t adalah data penelitian periode ke- t , B adalah operator *backshift*, e_t adalah nilai kesalahan (residual) pada periode ke- t , p adalah orde *autoregressive* (AR), d adalah orde *differencing*, q adalah orde *moving average* (MA), ϕ_p adalah koefisien AR pada orde ke- p , θ_q adalah koefisien MA pada orde ke- q , $\phi_p(B)$ adalah polinomial AR yaitu $\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p$, $\theta_q(B)$ adalah polinomial MA yaitu $\theta_q(B) = 1 + \theta_1 B + \dots + \theta_p B^p$.

Langkah-langkah pemodelan ARIMA adalah sebagai berikut:

- a) Melakukan identifikasi model ARIMA menggunakan *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF).
 - b) Melakukan estimasi parameter dan menguji parameter model ARIMA.
 - c) Menentukan model ARIMA terbaik berdasarkan nilai *Akaike Information Criterion* (AIC)
 - d) Pengecekan asumsi *white noise* residual model ARIMA.
 - e) Residual dari model ARIMA akan menjadi input untuk metode *hybrid* ARIMA-NNAR dan ARIMA-SVR.
5. Melakukan pemodelan *hybrid* ARIMA-NNAR dengan data residual dari model ARIMA data *train* nilai impor migas dan non-migas Indonesia. Untuk menghitung output pada arsitektur *Neural Network Autoregression* (NNAR) dengan fungsi aktivasi sigmoid dihitung dengan persamaan (4) (Dietz, 2010).

$$\hat{Z}_t = b_{k+1} + \sum_{j=1}^k \frac{w_{j,k+1}}{1 + \exp(-(b_j + \sum_{i=1}^p w_{i,j} Z_{t-i}))} \quad (4)$$

dengan b_{k+1} adalah bias antara *hidden layer* dan *output layer*, $w_{j,k+1}$ adalah bobot antara *hidden layer* dan *output layer*, b_j adalah bias antara *input layer* dan *hidden layer*, $w_{i,j}$ adalah bobot antara *input layer* dan *hidden layer*, $\hat{Z}_t$ adalah nilai peramalan pada periode ke- t .

Langkah-langkah pemodelan *hybrid* ARIMA-NNAR adalah sebagai berikut:

- a) Menentukan parameter p (jumlah node pada *input layer*) yang dilakukan secara eksploratif menggunakan plot PACF nilai residual ARIMA.
- b) Menentukan parameter k (jumlah node pada *hidden layer*) yang dilakukan secara intuitif divariasikan dengan mengikuti aturan praktis (*rule of thumb*) yaitu nilai k harus tidak lebih besar dari $\left(\frac{N_s}{\gamma(N_i + N_o)}\right)$ dengan N_s adalah jumlah data, N_i adalah jumlah node pada *input layer*, N_o adalah jumlah node pada *output layer*, dan γ adalah konstanta bernilai 2 sampai 10.
- c) Model NNAR diuji dengan berbagai kombinasi (p, k) untuk mencari konfigurasi terbaik.
- d) Menentukan model NNAR terbaik dengan mempertimbangkan *Mean Absolute Percentage Error* (MAPE)
- e) Melakukan peramalan dengan model NNAR terbaik.
- f) Menjumlahkan hasil peramalan model ARIMA dengan peramalan residual dengan

model NNAR.

6. Melakukan pemodelan *hybrid* ARIMA-SVR dengan data residual dari model ARIMA data *train* nilai impor migas dan non-migas Indonesia. SVR menggunakan fungsi regresi untuk melakukan peramalan. Fungsi regresi SVR ditunjukkan pada persamaan (5) (Cahyono et al., 2019).

$$f(x) = \sum_{i=1}^n (a_i - a_i^*) K(x_i, x_j) + b \quad (5)$$

adalah a_i , a_i^* adalah koefisien *lagrange*, $K(x_i, x_j)$ adalah fungsi kernel dengan kernel RBF $K(x_i, x_j) = \exp\left(-\frac{1}{2\sigma^2} \|x_i - x_j\|^2\right)$, b adalah bias, x_i adalah variabel prediktor, dan x_j adalah variabel target

Langkah-langkah pemodelan *hybrid* ARIMA-SVR adalah sebagai berikut:

- a) Menentukan jumlah lag dilakukan berdasarkan analisis plot *Partial Autocorrelation Function* (PACF).
 - b) Transformasi data residual ARIMA menjadi data Multivariat dengan lag hasil analisis plot PACF.
 - c) Menentukan rentang parameter untuk model SVR dengan *loose grid search*.
 - d) Membangun Model SVR dengan *loose grid search*.
 - e) Menentukan rentang parameter untuk model SVR dengan *finer grid search* berdasarkan hasil kombinasi parameter *loose grid search*.
 - f) Membangun Model SVR dengan *finer grid search*.
 - g) Membangun Model SVR terbaik berdasarkan hasil kombinasi parameter *finer grid search*.
 - h) Melakukan peramalan dengan model SVR terbaik.
 - i) Menjumlahkan hasil peramalan model ARIMA dengan peramalan residual dengan model SVR.
7. Perbandingan performa model dilakukan dengan membandingkan ARIMA-NNAR dan ARIMA-SVR menggunakan metrik RMSE, MAE, dan MAPE untuk menentukan model yang paling optimal dalam meramalkan nilai impor migas dan non-migas Indonesia. Persamaan untuk menghitung nilai RMSE, MAE dan MAPE ditunjukkan pada persamaan (6), (7), dan (8).

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (Z_t - \hat{Z}_t)^2}{n}} \quad (6)$$

(Chai & Draxler, 2014)

$$MAE = \frac{1}{n} \sum_{t=1}^n |Z_t - \hat{Z}_t| \quad (7)$$

(Sutoyo & Almaarif, 2020)

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Z_t - \hat{Z}_t}{Z_t} \right| \times 100 \quad (8)$$

(Wulandari et al., 2015)

dengan Z_t adalah data aktual, $\hat{Z}_t$ adalah data hasil peramalan, dan n adalah jumlah observasi.

HASIL DAN PEMBAHASAN


Eksplorasi Data

Eksplorasi data dilakukan untuk memahami karakteristik dan pola yang terkandung dalam data. Tahap ini diawali dengan analisis statistik deskriptif, yang mencakup perhitungan rata-rata, median, standar deviasi, serta nilai minimum dan maksimum untuk mendapatkan gambaran awal mengenai distribusi dan variasi nilai impor.

Tabel 1. Statistika deskriptif


Statistik	Nilai Impor Migas	Nilai Impor Non-Migas
Jumlah Observasi	168	168
Minimum	657,5	7511
Kuartil 1 (Q1)	1820,6	10584
Median	2654,2	12212
Rata-rata	2641,2	12597
Kuartil 3(Q3)	3442,3	14072
Maksimum	4455,3	18470
Standar Deviasi	899,3	2524
Koefisien Variasi	0,34	0,2

Impor migas memiliki distribusi yang relatif simetris, sementara impor nonmigas menunjukkan sedikit *skewness* ke kanan. Fluktuasi nilai impor nonmigas lebih besar dibandingkan migas, sebagaimana ditunjukkan oleh standar deviasi dan koefisien variasinya. Rentang dan kuartil impor nonmigas juga lebih luas, mengindikasikan tingkat variasi yang lebih tinggi. Statistik ini menjadi dasar dalam memahami pola data sebelum dilakukan analisis lebih lanjut. Setelah itu, dilakukan visualisasi data menggunakan grafik *time series* untuk melihat tren jangka panjang, fluktuasi, serta kemungkinan adanya pola musiman.



Gambar 1. Grafik data *time series*

Nilai impor migas menunjukkan volatilitas tinggi tanpa tren pertumbuhan yang jelas. Sebaliknya, impor non-migas cenderung meningkat dalam jangka panjang dengan fluktuasi yang lebih terkendali.



Gambar 2. Grafik subseri musiman


Grafik subseri musiman impor migas Indonesia dari 2011 hingga 2024 menunjukkan bahwa data tidak memiliki pola musiman yang konsisten. Perubahan nilai impor pada bulan yang sama tiap tahun cenderung acak dan tidak berulang secara teratur, mencerminkan ketidakpastian dalam faktor-faktor yang memengaruhi impor migas.

Subset Data

Dalam penelitian ini, data dibagi menjadi dua bagian yaitu data *training* sebesar 80% dan data *testing* 20% dari total 168 data. Dengan demikian, data *training* terdiri dari 134 observasi, sedangkan data *testing* terdiri dari 34 observasi. Data *training* digunakan untuk membangun model ARIMA, di mana hasil pemodelan ini menghasilkan residual yang kemudian digunakan sebagai input dalam metode *hybrid* ARIMA-NNAR dan ARIMA-SVR.

Uji Stasioneritas

Uji stasioneritas dalam varians dapat dilakukan menggunakan metode *Box-Cox* pada variabel dengan grafik yang ditunjukkan pada Gambar 3.



Gambar 3. Grafik uji *Box-Cox*

Gambar 3 menunjukkan uji *Box-Cox* pada data impor migas dan non-migas, di mana nilai lambda masing-masing 0,59 dan 0,22, yang tidak mendekati 1. Hal ini menunjukkan bahwa kedua data tidak stasioner dalam varians, sehingga diperlukan transformasi *Box-Cox* untuk menstabilkan varians dan meningkatkan kualitas model.

Sedangkan uji stasioneritas dalam rata-rata dilakukan menggunakan uji *Augmented Dickey-Fuller* (ADF). Dalam uji ADF, hipotesis nol dan alternatif dinyatakan sebagai berikut:
Hipotesis nol (H_0): Data memiliki akar unit (non-stasioner) ($H_0: \phi = 1$)
Hipotesis alternatif (H_1): Data tidak memiliki akar unit (stasioner) ($H_0: \phi < 1$)
Keputusan uji ADF didasarkan pada *p-value* dibandingkan dengan tingkat signifikansi 0,05. Jika $p\text{-value} \leq 0,05$ hipotesis nol ditolak. Dengan hasil uji ADF sebelum dan sesudah *differencing* ditunjukkan pada Tabel 2.


Tabel 2. Tabel uji ADF

<i>P-value</i> Uji ADF	Nilai Impor Migas	Nilai Impor Non-Migas
Sebelum <i>Differencing</i>	0,7412	0,8023
Setelah <i>Differencing</i> Pertama	0,01	0,01

Uji ADF menunjukkan data impor migas dan non-migas tidak stasioner dalam rata-rata, sehingga diperlukan *differencing*. Setelah *differencing* pertama, *p-value* turun menjadi 0,01, menunjukkan data sudah stasioner dalam rata-rata.


Pemodelan ARIMA

Setelah data stasioner, orde $AR(p)$ dan $MA(q)$ diidentifikasi menggunakan plot ACF dan PACF, dengan plot ACF digunakan untuk menentukan $MA(q)$ disajikan pada Gambar 4.



Gambar 4. Plot Autocorrelation Function (ACF)

Plot ACF menunjukkan impor migas *cut-off* setelah lag ke-2 dengan kata lain memiliki kemungkinan model $MA(1)$ atau $MA(2)$, sementara impor non-migas *cut-off* setelah lag ke-1 dengan kata lain memiliki kemungkinan model $MA(1)$.



Gambar 5. Plot Partial Autocorrelation Function (PACF)

Plot PACF pada gambar 5 menunjukkan impor migas *cut-off* setelah lag ke-2 dengan kata lain memiliki kemungkinan model $AR(1)$ atau $AR(2)$, sementara impor non-migas *cut-off* setelah lag ke-1 dengan kata lain memiliki kemungkinan model $AR(1)$ dan $AR(2)$.

Dari identifikasi orde $AR(p)$ dan $MA(q)$ menggunakan plot ACF dan PACF, diperoleh beberapa kandidat model ARIMA untuk data nilai impor migas, yaitu $ARIMA(1,1,0)$, $ARIMA(1,1,1)$, $ARIMA(1,1,2)$, $ARIMA(2,1,0)$, $ARIMA(2,1,1)$, $ARIMA(2,1,2)$, $ARIMA(0,1,1)$, dan $ARIMA(0,1,2)$. Sementara itu, untuk data nilai impor non-migas, model yang diestimasi mencakup $ARIMA(1,1,0)$, $ARIMA(1,1,1)$, $ARIMA(2,1,0)$, $ARIMA(2,1,1)$, dan $ARIMA(0,1,1)$. Setelah estimasi parameter model ARIMA, langkah selanjutnya adalah

menguji signifikansi parameter AR (ϕ) dan MA (θ) menggunakan uji statistik z. Hipotesis nol menyatakan bahwa parameter tidak signifikan, sedangkan hipotesis alternatif menyatakan bahwa parameter signifikan. Jika $p\text{-value} < 0,05$, maka hipotesis nol ditolak, yang berarti parameter signifikan.

Tabel 3. Uji signifikansi parameter ARIMA

Model	Parameter	Estimasi	$P\text{-value}$	Keputusan
Data Nilai Impor Migas				
ARIMA(1,1,1)	$\hat{\phi}_1$	0,348	0,05047	Tidak Signifikan
	$\hat{\theta}_1$	-0,633	0,0000003	Signifikan
ARIMA(1,1,2)	$\hat{\phi}_1$	-0,381	0,17125	Tidak Signifikan
	$\hat{\theta}_1$	0,122	0,64841	Tidak Signifikan
	$\hat{\theta}_2$	-0,331	0,00046	Signifikan
ARIMA(1,1,0)	$\hat{\phi}_1$	-0,216	0,01172	Signifikan
ARIMA(2,1,1)	$\hat{\phi}_1$	-0,564	0,0455	Signifikan
	$\hat{\phi}_2$	-0,326	0,00032	Signifikan
	$\hat{\theta}_1$	0,323	0,27	Tidak Signifikan
ARIMA(2,1,2)	$\hat{\phi}_1$	1,594	$< 0,01$	Signifikan
	$\hat{\phi}_2$	-0,662	$< 0,01$	Signifikan
	$\hat{\theta}_1$	-1,869	$< 0,01$	Signifikan
	$\hat{\theta}_2$	0,93	$< 0,01$	Signifikan
ARIMA(2,1,0)	$\hat{\phi}_1$	-0,263	0,0018	Signifikan
	$\hat{\phi}_2$	-0,266	0,0021	Signifikan
ARIMA(0,1,1)	$\hat{\theta}_1$	-0,344	0,00039	Signifikan
ARIMA(0,1,2)	$\hat{\theta}_1$	-0,248	0,00723	Signifikan
	$\hat{\theta}_2$	-0,22	0,02293	Signifikan
Data Nilai Impor Non-Migas				
ARIMA(1,1,1)	$\hat{\phi}_1$	-0,195	0,085	Tidak Signifikan
	$\hat{\theta}_1$	-0,561	$< 0,01$	Signifikan
ARIMA(1,1,0)	$\hat{\phi}_1$	-0,507	$< 0,01$	Signifikan
ARIMA(2,1,1)	$\hat{\phi}_1$	-0,491	0,0035	Signifikan
	$\hat{\phi}_2$	-0,302	0,0129	Signifikan
	$\hat{\theta}_1$	-0,2902	0,0808	Tidak Signifikan
ARIMA(2,1,0)	$\hat{\phi}_1$	-0,727	$< 0,01$	Signifikan
	$\hat{\phi}_2$	-0,418	$< 0,01$	Signifikan
ARIMA(0,1,1)	$\hat{\theta}_1$	-0,655	$< 0,01$	Signifikan

Setelah uji signifikansi parameter, pemilihan model terbaik dilakukan dengan membandingkan nilai *Akaike Information Criterion* (AIC).

Tabel 4. Pemilihan model terbaik ARIMA

Variabel	Model	Log Likelihood	AIC
Nilai Impor Migas	ARIMA(1,1,0)	-986,52	1977,04
	ARIMA(2,1,2)	-981,7	1973,4
	ARIMA(2,1,0)	-981,97	1969,94
	ARIMA(0,1,1)	-984,39	1972,78
	ARIMA(0,1,2)	-982,07	1970,14
Nilai Non-Impor Migas	ARIMA(1,1,0)	-1153,63	2311,26
	ARIMA(2,1,0)	-1141,61	2289,22
	ARIMA(0,1,1)	-1144,25	2292,5

Berdasarkan tabel 4 perbandingan nilai AIC model terbaik yang dipilih adalah ARIMA(2,1,0) untuk meramalkan nilai impor migas dan ARIMA(2,1,0) untuk meramalkan nilai impor non-migas. Setelah uji signifikansi parameter, dilakukan diagnostik model ARIMA dengan uji *Ljung-Box* untuk memastikan residual bersifat *white noise* (acak dan tanpa pola).


Tabel 5. Uji *Ljung-Box*

Variabel	Lag	Nilai Q	p-value	Keputusan
Nilai Impor Migas	12	11,171	0,5143	White Noise
	24	25,271	0,3911	White Noise
	36	43,412	0,1848	White Noise
	48	57,045	0,1741	White Noise
Nilai Impor Non-Migas	12	51,441	<0,01	Tidak White Noise
	24	89,695	<0,01	Tidak White Noise
	36	130,31	<0,01	Tidak White Noise
	48	151,14	<0,01	Tidak White Noise

Hasil uji *Ljung-Box* menunjukkan bahwa residual dari model ARIMA untuk nilai impor migas bersifat *white noise*, artinya tidak ada pola autokorelasi yang signifikan, sehingga model ARIMA sudah cukup baik untuk peramalan. Namun, untuk nilai impor non-migas uji *Ljung-Box* menunjukkan bahwa residual masih memiliki autokorelasi (tidak *white noise*), yang berarti model ARIMA sendiri belum cukup optimal dalam menangkap pola pada data.

Pemodelan *Hybrid* ARIMA-NNAR

Hasil uji diagnostik menunjukkan bahwa ARIMA cukup baik untuk nilai impor migas, tetapi kurang optimal untuk nilai impor non-migas karena masih memiliki pola non-linear. Untuk meningkatkan akurasi, diterapkan pendekatan *hybrid* ARIMA-NNAR, di mana residual ARIMA digunakan sebagai input NNAR guna menangkap pola non-linear yang tidak terdeteksi oleh ARIMA.



Gambar 6. Plot PACF nilai residual ARIMA

Plot PACF residual nilai impor migas pada gambar 6 menunjukkan tidak ada lag signifikan, menandakan ARIMA sudah cukup baik. Namun, *hybrid* ARIMA-NNAR tetap diterapkan untuk meningkatkan performa, dengan nilai $p = 4$ dan $p = 8$. Sementara itu, residual nilai impor non-migas menunjukkan *lag* signifikan pada *lag* ke-10 dan ke-12, sehingga nilai p yang dipilih adalah $p = 10$ dan $p = 12$.

Nilai k ditentukan secara intuitif dan divariasikan untuk mencegah *overfitting* dengan mempertimbangkan aturan praktis. Berdasarkan perhitungan, diperoleh batas maksimum nilai k untuk masing-masing p , yaitu 13,4 untuk $p = 4$, 7,44 untuk $p = 8$, 6,09 untuk $p = 10$, dan 5,15 untuk $p = 12$. Untuk memastikan model tetap optimal tanpa *overfitting*, nilai k divariasikan dalam rentang 1, 2, 3, dan 4 guna mengeksplorasi kombinasi terbaik yang menghasilkan performa peramalan optimal.

Tabel 6. Estimasi model NNAR terbaik

Variabel	p	k	Model	MAPE	Variabel	p	k	Model	MAPE
Nilai Impor Migas	4	1	NNAR(4,1)	13,39%	Nilai Impor Non-Migas	10	1	NNAR(10,1)	8,25%
		2	NNAR(4,2)	12,41%			2	NNAR(10,2)	9,20%
		3	NNAR(4,3)	13,64%			3	NNAR(10,3)	8,46%
		4	NNAR(4,4)	14,02%			4	NNAR(10,4)	9,15%
	8	1	NNAR(8,1)	13,20%		12	1	NNAR(12,1)	7,89%
		2	NNAR(8,2)	14,45%			2	NNAR(12,2)	8,49%
		3	NNAR(8,3)	13,38%			3	NNAR(12,3)	7,61%
		4	NNAR(8,4)	14,46%			4	NNAR(12,4)	8,06%

Model NNAR(4,2) dipilih sebagai model terbaik untuk nilai impor migas dengan MAPE 12,41%, karena memiliki kesalahan lebih rendah dan arsitektur lebih sederhana. Sementara itu, untuk nilai impor non-migas, model NNAR(12,3) dengan MAPE 7,61% menunjukkan performa terbaik dalam meminimalkan kesalahan prediksi.

Pemodelan *Hybrid* ARIMA-SVR

Pendekatan *hybrid* ARIMA-SVR digunakan untuk meningkatkan akurasi peramalan dengan mengombinasikan ARIMA dalam menangkap pola linier dan SVR dalam menangani pola non-linier. Pemodelan diawali dengan penerapan ARIMA pada data impor migas dan non-migas, kemudian residualnya digunakan sebagai input untuk SVR. Penentuan lag dilakukan dengan melihat plot PACF, di mana pada data impor migas lag signifikan ditemukan pada lag ke-4 dan ke-8, sedangkan pada data impor non-migas lag signifikan terdapat pada lag ke-10 dan ke-12. Oleh karena itu, variabel prediktor untuk impor migas adalah Z_{t-4} dan Z_{t-8} ,

sedangkan untuk impor non-migas adalah Z_{t-10} dan Z_{t-12} . Dalam penelitian ini, setiap variabel memiliki dua variabel prediktor (X) dan satu variabel target (Y), dengan variabel target Y berupa residual masa kini (Z_t).

Pada tahap awal pembangunan model *Support Vector Regression* (SVR), dilakukan tuning parameter menggunakan *loose grid search* untuk menentukan kombinasi optimal dari *cost* (C), *gamma* (γ), dan *epsilon* (ϵ) dalam pemodelan residual ARIMA. Model ini menggunakan kernel *Radial Basis Function* (RBF). Rentang parameter yang digunakan adalah *epsilon* (ϵ) dari 0,01 hingga 0,1 dengan kenaikan 0,005, *cost* (C) dari 2^{-7} hingga 2^7 , dan *gamma* (γ) dari 2^{-3} hingga 2^3 .

Tabel 7. Hasil *Loose Grid Search* model SVR

Variabel	Jumlah Lag	Parameter			Jumlah Support Vector
		C	γ	ϵ	
Residual nilai impor migas	4	2^{-2}	2^0	0,065	127
	8	2^{-3}	2^{-2}	0,1	114
Residual nilai impor non-migas	10	2^{-1}	2^1	0,085	116
	12	2^{-1}	2^{-3}	0,095	116

Setelah mendapatkan parameter terbaik dari *loose grid search*, *finer grid search* dilakukan dengan mempersempit rentang *cost* (C), *gamma* (γ), dan *epsilon* (ϵ) untuk meningkatkan presisi model SVR.

Tabel 8. Hasil *Finer Grid Search* model SVR

Variabel	Jumlah Lag	Parameter			Jumlah Support Vector	MAPE
		C	γ	ϵ		
Residual nilai impor migas	4	$2^{-2,75}$	$2^{-0,25}$	0,069	126	13,22%
	8	$2^{-3,25}$	$2^{-1,75}$	0,12	114	13,37%
Residual nilai impor non-migas	10	2^{-1}	$2^{1,25}$	0,083	116	8,11%
	12	$2^{-0,25}$	$2^{-3,75}$	0,099	114	8,26%

Setelah memperoleh parameter terbaik dari *finer grid search*, model SVR digunakan untuk membangun model final dalam peramalan. Model terbaik dipilih berdasarkan *Mean Absolute Percentage Error* (MAPE). Untuk residual impor migas, model dengan lag 4 dipilih karena memiliki MAPE lebih rendah yaitu 13,22% dibanding lag 8. Sementara itu, untuk residual impor non-migas, model dengan lag 10 dipilih dengan MAPE 8,11%, lebih baik dibanding lag 12.

Perbandingan Performa Model

Perbandingan performa model *hybrid* ARIMA-NNAR dan ARIMA-SVR dilakukan menggunakan tiga metrik evaluasi yaitu RMSE, MAE, dan MAPE.

Tabel 9. Tabel hasil performa model

Variabel	Model	RMSE	MAE	MAPE
Nilai Impor Migas	ARIMA-NNAR	532,8414	421,0535	12,68%
	ARIMA-SVR	535,9437	433,8291	13,2213%
Nilai Impor Non-Migas	ARIMA-NNAR	1761,904	1375,629	8,4572%
	ARIMA-SVR	1718,718	1325,358	8,1087%

Pada peramalan data nilai impor migas, ARIMA-NNAR menunjukkan performa terbaik dengan RMSE (532,84), MAE (421,05), dan MAPE (12,68%) yang lebih rendah dibandingkan ARIMA-SVR dan model dasar ARIMA. Namun, karena residual ARIMA sudah bersifat *white noise*, model *hybrid* tidak diperlukan.

Sebaliknya, pada peramalan nilai impor non-migas, ARIMA-SVR lebih unggul dalam aspek MAE (1325,36) dan MAPE (8,11%), meskipun model dasar ARIMA memiliki RMSE lebih kecil (1663,72). Karena residual ARIMA belum sepenuhnya *white noise*, masih terdapat pola yang belum tertangkap, sehingga penggunaan model *hybrid* tetap diperlukan untuk meningkatkan akurasi prediksi.

SIMPULAN

Berdasarkan hasil penelitian, model *hybrid* ARIMA-NNAR lebih efektif dalam meramalkan nilai impor migas, tetapi keberadaannya tidak esensial karena model dasar ARIMA sudah cukup baik dalam menangkap pola data. Sebaliknya, untuk nilai impor non-migas, model ARIMA-SVR lebih unggul dalam beberapa metrik evaluasi, menunjukkan bahwa pola non-linier dalam data masih signifikan dan membutuhkan pendekatan *hybrid*.

Temuan ini mengindikasikan bahwa efektivitas model *hybrid* bergantung pada karakteristik residual ARIMA. Jika residual masih memiliki pola yang dapat dieksplorasi, pendekatan *hybrid* dapat meningkatkan akurasi peramalan. Ke depan, penelitian lebih lanjut dapat mengeksplorasi metode optimasi parameter yang lebih canggih atau mengembangkan model *hybrid* lain yang lebih adaptif terhadap karakteristik data ekonomi yang kompleks. Selain itu, aplikasi model serupa dapat diperluas ke sektor lain yang memiliki pola data kombinasi linier dan non-linier, seperti harga komoditas atau indikator makroekonomi lainnya.

DAFTAR PUSTAKA

- Badan Pusat Statistik. (2024). Nilai impor migas & nonmigas [Data set]. Badan Pusat Statistik Indonesia. <https://www.bps.go.id/id/statistics-table/2/MTc1NCMy/nilai-impor-migas-nonmigas.html>
- Büyüksahin, Ü. Ç., & Ertekin, Ş. (2019). Improving forecasting accuracy of time series data using a new ARIMA-ANN hybrid method and empirical mode decomposition. *Elsevier Preprint*. Retrieved from <https://arxiv.org/abs/1812.11526>
- Cahyono, R. E., Sugiono, J. P., & Tjandra, S. (2019). Analisis kinerja metode Support Vector Regression (SVR) dalam memprediksi indeks harga konsumen. *JTIM: Jurnal Teknologi Informasi dan Multimedia*, 1(2), 106–116.
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7, 1247–1250.
- Dietz, S. (2010). *Autoregressive neural network process: Univariate, multivariate, and cointegrated models with application to the German automobile industry*. University of Passau.

- Enders, W. (2014). *Applied econometric time series* (4th ed.). Wiley.
- Palupi, S. P. (2023). *Perbandingan performa metode hybrid ARIMA-SVM dan ARIMA-NNAR pada peramalan data deret waktu* [Tesis Magister, Institut Pertanian Bogor]. Institut Pertanian Bogor Repository.
- Perone, G. (2021). Comparison of ARIMA, ETS, NNAR, TBATS and hybrid models to forecast the second wave of COVID-19 hospitalizations in Italy. *The European Journal of Health Economics*, 1–24.
- Pramudhitasari, L., & Utami, H. (2016). *Model hybrid ARIMA-SVR untuk peramalan data runtun waktu* [Skripsi, Universitas Gadjah Mada]. UGM Repository. Retrieved from <http://etd.repository.ugm.ac.id/>
- Sihombing, C. V. M., & Martha, S. (2022). Analisis metode hybrid ARIMA–SVR pada indeks harga saham gabungan. *Bimaster: Buletin Ilmiah Matematika, Statistika dan Terapannya*, 11(3).
- Sutoyo, E., & Almaarif, A. (2020). Educational data mining for predicting student graduation using the Naïve Bayes classifier algorithm. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 4(1), 95–101.
- Wei, W. (2006). *Time series: Univariate and multivariate methods* (2nd ed.). Addison Wesley.
- Wulandari, N. L. P., Sarja, S. T., Yuniastari, N. L. A. K., Saryanti, S., & Desi, I. G. A. (2015). Prediksi jumlah pelanggan dan persediaan barang menggunakan metode regresi linier berganda pada Bali orchid. *Jurnal Online Sistem Informasi*, 1(1), 243–347.