

Peramalan Nilai Impor Non-Migas Indonesia Menggunakan Metode *Hybrid Ensemble Empirical Mode Decomposition-Autoregressive Fractionally Integrated Moving Average* (EEMD-ARFIMA)

Sintia Nur Abdul^{1*}, Emli Rahmi², La Ode Nashar³

¹ Mahasiswa Statistika, FMIPA, Universitas Negeri Gorontalo, Gorontalo

² Dosen Matematika, FMIPA, Universitas Negeri Gorontalo, Gorontalo

³ Dosen Statistika, FMIPA, Universitas Negeri Gorontalo, Gorontalo

tiaabdul0910@gmail.com

Diterima:20-06-2026; Direvisi:29-09-2026; Dipublikasi: 29-09-2026

Abstract

Non-oil and gas imports play a crucial role in meeting domestic demands that cannot yet be produced influx within the country. During the 2013–2022 period, Indonesia's non-oil and gas imports dominantly contributed an average of 83.61% annually. However, the characteristics of non-oil and gas import data tend to be non-stationary and complex, thereby requiring analytical techniques capable of decomposing data patterns at a deeper level. Ensemble Empirical Mode Decomposition (EEMD) is an adaptive decomposition method capable of breaking down data into several Intrinsic Mode Functions (IMFs), thus facilitating the modeling process. Furthermore, Autoregressive Fractionally Integrated Moving Average (ARFIMA) is utilized to model components exhibiting long-memory properties. This study aims to apply the hybrid EEMD-ARFIMA method to forecast the value of Indonesia's non-oil and gas imports, as well as to compare its accuracy with the standalone ARFIMA method without decomposition. Non-oil and gas import data from January 2000 to December 2023 were decomposed using EEMD into seven IMFs and one residual component. Each component was then modeled using ARFIMA, and their respective forecasting results were aggregated to obtain the final forecast of the non-oil and gas import value. The results indicate that the hybrid EEMD-ARFIMA approach yields better forecasting performance compared to the ARFIMA model without decomposition. This is demonstrated by the MAPE value of the EEMD-ARFIMA method at 14.29056, which is lower than the ARFIMA MAPE of 18.97699. Consequently, the EEMD-ARFIMA method is proven to be more effective in capturing the dynamics of non-oil and gas import data and improving forecasting accuracy.

Keywords: non-oil and gas imports; EEMD; ARFIMA; forecasting; time series.

Abstrak

Impor non-migas memiliki peran penting dalam memenuhi kebutuhan domestik yang belum dapat diproduksi di dalam negeri. Selama periode 2013–2022, impor non-migas Indonesia tercatat mendominasi dengan kontribusi rata-rata 83,61% per tahun. Namun, karakteristik data impor non-migas cenderung bersifat non stasioner dan kompleks, sehingga memerlukan teknik analisis yang mampu menguraikan pola data secara lebih mendalam. *Ensemble Empirical Mode Decomposition* (EEMD) merupakan metode dekomposisi adaptif yang mampu memecah data menjadi beberapa *Intrinsic Mode Functions* (IMF), sehingga memudahkan proses pemodelan. Selanjutnya, *Autoregressive Fractionally Integrated Moving Average* (ARFIMA) digunakan untuk memodelkan komponen-komponen yang memiliki sifat *long memory*. Penelitian ini bertujuan untuk menerapkan metode *hybrid EEMD-ARFIMA* dalam meramalkan nilai impor non-migas Indonesia, serta membandingkan akurasinya dengan metode ARFIMA tanpa dekomposisi. Data impor non-migas Indonesia periode Januari 2000 hingga Desember 2023 didekomposisi menggunakan EEMD menjadi tujuh IMF dan satu komponen residu. Setiap komponen kemudian dimodelkan menggunakan ARFIMA, dan hasil peramalannya dijumlahkan untuk memperoleh ramalan akhir nilai impor non-migas. Hasil penelitian menunjukkan bahwa pendekatan *hybrid EEMD-ARFIMA* memberikan kinerja peramalan

yang lebih baik dibandingkan model ARFIMA tanpa dekomposisi. Hal ini ditunjukkan oleh nilai MAPE metode EEMD-ARFIMA sebesar 14,29056, lebih rendah dibandingkan MAPE ARFIMA sebesar 18,97699. Dengan demikian, metode EEMD-ARFIMA terbukti mampu menangkap dinamika data impor non-migas secara lebih efektif dan meningkatkan akurasi hasil peramalan.

Kata Kunci: impor non-migas; EEMD; ARFIMA; peramalan; runtun waktu

1. PENDAHULUAN

Kegiatan mendatangkan barang dari luar negeri dilakukan ketika suatu kebutuhan belum dapat diproduksi di dalam negeri untuk memenuhi kebutuhan nasional (Sukirno, 2012). Nilai impor itu sendiri diartikan sebagai total harga barang yang dibeli dari luar negeri (Albab, 2022). Nilai impor merupakan indikator krusial dalam mengukur kondisi perekonomian serta menunjukkan stabilitas ekonomi suatu negara (Sedyaningrum, 2016). Berdasarkan data Badan Pusat Statistik Indonesia periode 2013-2022, impor non-migas menjadi sektor yang sangat dominan dengan kontribusi rata-rata mencapai 83,61% per tahun dibandingkan sektor migas yang hanya sebesar 16,39%. Mengingat besarnya pengaruh impor non-migas, fluktuasi nilai impor yang tidak terkendali dapat berdampak negatif terhadap produksi domestik, meningkatkan pengangguran, hingga menurunkan daya beli masyarakat (Kuswantoro, 2016). Oleh karena itu, peramalan (forecasting) nilai impor non-migas di masa mendatang menjadi instrumen perencanaan ekonomi yang sangat penting bagi pemerintah (Nur Rohman, 2018). Peramalan ini umumnya memanfaatkan pola perilaku data deret waktu masa lampau melalui pendekatan kuantitatif (Anita, 2017).

Namun, tantangan terbesar dalam memodelkan data ekonomi riil seperti impor non-migas adalah sifat datanya yang kompleks, berukuran besar, dan non-stasioner, di mana karakteristik statistiknya terus berubah seiring waktu sehingga pola pergerakannya sulit dipahami. Untuk mengatasi kompleksitas tersebut, data dapat diuraikan terlebih dahulu melalui proses dekomposisi menjadi komponen-komponen yang lebih sederhana. Salah satu teknik dekomposisi yang adaptif dan populer adalah Ensemble Empirical Mode Decomposition (EEMD). Metode ini dikembangkan oleh (Huang et al., 1998) dan disempurnakan oleh (Zhang et al., 2010) dengan menambahkan efek white noise untuk mengatasi kelemahan mode mixing pada metode EMD klasik. EEMD mengurai data deret waktu asli yang non-linier menjadi beberapa komponen tren independen yang disebut Intrinsic Mode Functions (IMF) dan satu residu. Melalui dekomposisi ini, setiap komponen IMF yang terbentuk dapat diramal secara individu sebelum akhirnya diakumulasikan kembali menjadi satu peramalan akhir yang utuh (Siregar et al., 2021).

Pemodelan komponen hasil dekomposisi memerlukan metode yang peka terhadap karakteristik data ekonomi jangka panjang. Metode konvensional seperti ARIMA seringkali gagal karena hanya mampu menangkap pola memori jangka pendek (short memory). Sebagai solusinya, (Granger & Joyeux, 1980) serta (Hosking et al., 2002) memperkenalkan *Autoregressive Fractionally Integrated Moving Average* (ARFIMA). Keunggulan utama model ARFIMA terletak pada fleksibilitas proses differencing

menggunakan bilangan pecahan fraksional d , yang membuatnya sangat kuat dan akurat dalam mengakomodasi karakteristik data yang memiliki memori jangka panjang (*long memory*). Penelitian terdahulu membuktikan efektivitas metode ini. Herawati dan Latif (2016) serta (Herawati & Djunaidy, 2014) menunjukkan bahwa integrasi EEMD dengan metode cerdas mampu meminimalkan nilai error (MSE dan RMSE) secara signifikan dibandingkan model tunggal. Di sisi lain, (Krismawanti et al., 2019) mengonfirmasi bahwa penggunaan ARFIMA pada data komoditas yang memiliki dependensi jangka panjang mampu menghasilkan nilai error (MAPE) terkecil hingga 1,37%.

Meskipun performa masing-masing metode telah diuji secara terpisah, penelitian yang mengintegrasikan EEMD dan ARFIMA secara hibrida (*hybrid ensemble*) untuk peramalan makroekonomi di Indonesia masih sangat terbatas. Gap analysis inilah yang menjadi kebaruan dalam penelitian ini. Penggabungan EEMD dan ARFIMA diharapkan mampu menjadi solusi komprehensif: EEMD bertugas mengurai kompleksitas fluktuasi non-linier data impor non-migas, sedangkan ARFIMA mengoptimalkan peramalan pada tiap-tiap komponen IMF yang memiliki efek *long memory*. Berdasarkan uraian tersebut, penelitian ini bertujuan untuk menerapkan metode hybrid EEMD-ARFIMA dalam meramalkan nilai impor non-migas di Indonesia, mengetahui hasil proyeksi lag di masa depan, serta menguji tingkat akurasi model yang dihasilkan berdasarkan kriteria evaluasi nilai galat (MAPE) dan *Akaike Information Criterion* (AIC).

2. METODE PELAKSANAAN

Penelitian ini merupakan penelitian kuantitatif dengan menggunakan pendekatan deret waktu (*time series*). Data yang digunakan adalah data sekunder berupa nilai impor nonmigas Indonesia periode Januari 2000 sampai dengan Desember 2023 yang diperoleh dari publikasi resmi Badan Pusat Statistik (BPS). Data terdiri atas 288 pengamatan bulanan. Pengolahan dan analisis data dilakukan di Laboratorium Komputasi Statistika Universitas Negeri Gorontalo dengan bantuan perangkat lunak RStudio. Penelitian ini menerapkan metode *Ensemble Empirical Mode Decomposition-Autoregressive Fractionally Integrated Moving Average* (EEMD-ARFIMA) untuk melakukan pemodelan dan peramalan data.

Tahapan penelitian diawali dengan menginput dan memvisualisasikan data deret waktu untuk mengidentifikasi pola tren, musiman, dan fluktuasi data. Selanjutnya dilakukan proses dekomposisi menggunakan metode EEMD sehingga diperoleh beberapa komponen *Intrinsic Mode Function* (IMF) dan residual. Setiap komponen IMF dan residual kemudian dianalisis sifat *long memory*-nya serta diuji kestasionerannya. Apabila data belum stasioner, dilakukan proses differencing. Nilai parameter pembeda fraksional (d) diestimasi menggunakan metode *rescaled range* (R/S), kemudian dilakukan proses fractional differencing. Tahap berikutnya adalah identifikasi model ARFIMA melalui plot ACF dan PACF untuk menentukan orde model terbaik. Pemilihan model dilakukan berdasarkan nilai *Akaike Information Criterion* (AIC) terkecil. Model terbaik kemudian digunakan untuk melakukan peramalan pada setiap IMF dan residual. Hasil peramalan seluruh komponen selanjutnya digabungkan melalui proses superposisi sehingga


diperoleh hasil peramalan akhir. Tingkat akurasi model dievaluasi menggunakan nilai *Mean Absolute Percentage Error* (MAPE).

3. HASIL DAN PEMBAHASAN

Penerapan metode *hybrid Ensemble Empirical Mode Decomposition - Autoregressive Fractionally Integrated Moving Average* (EEMD-ARFIMA) pada data nilai impor non-migas Indonesia diuraikan pada bagian ini. Data utama yang digunakan adalah data bulanan dengan rentang waktu dari Januari 2000 hingga Desember 2023 yang mencakup total 288 observasi. Sebelum pemodelan dilakukan, hasil dekomposisi dibagi ke dalam data train sebanyak 230 data pertama (Januari 2000 – Februari 2019) untuk pembentukan model, dan data testing sebanyak 58 data terakhir (Maret 2019 – Desember 2023) sebagai data pengujian untuk mengevaluasi hasil peramalan.

3.1 Dekomposisi Data Menggunakan EEMD

Dekomposisi menggunakan metode EEMD diimplementasikan dengan bantuan perangkat lunak RStudio melalui fungsi *eemd(x, ..)*. Langkah awal ini bertujuan untuk mengurai kompleksitas data riil nilai impor non-migas Indonesia yang fluktuatif menjadi beberapa komponen *Intrinsic Mode Function* (IMF) dan satu komponen sisaan (residual). Secara visual, hasil pemisahan komponen frekuensi data tersebut disajikan pada Gambar 1 berikut:



Gambar 1 Dekomposisi nilai impor non-migas Indonesia melalui metode EEMD

Berdasarkan Gambar 1, algoritma EEMD berhasil mengekstrak data asli secara adaptif menjadi 7 komponen IMF dan 1 komponen residual. Komponen IMF tersebut tersusun secara berurutan berdasarkan tingkat frekuensinya. Komponen IMF awal (IMF 1 dan IMF 2) menangkap fluktuasi acak berfrekuensi tinggi atau variasi jangka pendek. Semakin besar urutan nomor IMF, pola fluktuasi yang dihasilkan menjadi semakin lambat dan halus. Pada tahap akhir, komponen residual menangkap frekuensi paling rendah yang mencerminkan pola tren pertumbuhan jangka panjang nilai impor non-

migas di Indonesia yang cenderung terus meningkat dari tahun 2000 hingga 2023. Kedelapan komponen ini selanjutnya akan digunakan sebagai data masukan dalam proses pemodelan ARFIMA.

3.2 Identifikasi Pola Ketergantungan Jangka Panjang (*Long Memory*)

Karakteristik memori jangka panjang (*long memory*) pada 230 data train dari masing-masing komponen IMF diidentifikasi mula-mula secara visual menggunakan grafik *Autocorrelation Function* (ACF). Plot ACF pada IMF 1 dan IMF 2 menunjukkan penurunan nilai autokorelasi lag yang meluruh secara eksponensial dan cepat menuju nol, mengindikasikan karakteristik *short memory*. Sebaliknya, plot ACF pada IMF 3 hingga IMF 7, serta komponen residual, menunjukkan lag yang menurun sangat lambat membentuk pola hiperbolik, menandakan adanya sifat *long memory*. Selanjutnya, indikasi ini dikonfirmasi secara objektif melalui nilai statistik Hurst (*Hurst exponent*). Hasil perhitungan nilai Hurst untuk masing-masing komponen dapat dilihat pada **Tabel 1**:

No	Data	<i>Hurst Exponent</i>	Keterangan
1	IMF 1	0.35042	<i>Short Memory</i>
2	IMF 2	0.4347782	<i>Short Memory</i>
3	IMF 3	0.5818332	<i>Long Memory</i>
4	IMF 4	0.664934	<i>Long Memory</i>
5	IMF 5	0.8225327	<i>Long Memory</i>
6	IMF 6	0.8410478	<i>Long Memory</i>
7	IMF 7	0.8466072	<i>Long Memory</i>
8	Residual	0.8453966	<i>Long Memory</i>

Tabel 1 Nilai Hurst

Hasil **Tabel 1** mempertegas analisis visual plot ACF. Komponen IMF 1 dan IMF 2 terbukti masuk kategori *short memory* karena memiliki nilai *Hurst exponent* < 0.5 . Sementara itu, komponen IMF 3 hingga IMF 7 serta *residual* secara konsisten menghasilkan nilai > 0.5 , membuktikan bahwa data tersebut memiliki pola ketergantungan jangka panjang (*long memory*) yang kuat.

3.3 Uji Stasioneritas Data (Uji ADF)

Pengujian stasioneritas dalam rata-rata dilakukan pada 230 data *train* dari setiap komponen IMF dan *residual* menggunakan uji *Augmented Dickey-Fuller* (ADF). Data dinyatakan stasioner jika nilai *p-value* $< (0,05)$. Hasil uji ADF untuk masing-masing komponen dapat dilihat pada **Tabel 2**:

No	Data	<i>p-value</i> Awal	Status Awal	<i>p-value</i> Akhir	Status Akhir
1	IMF 1	0,01	Stasioner	-	Stasioner

2	IMF 2	0,01	Stasioner	-	Stasioner
3	IMF 3	0,01	Stasioner	-	Stasioner
4	IMF 4	0,01	Stasioner	-	Stasioner
5	IMF 5	0,03208	Stasioner	-	Stasioner
6	IMF 6	0,05746	Belum Stasioner	$< 0,05$	Stasioner
7	IMF 7	0,4932	Belum Stasioner	$< 0,05$	Stasioner
8	Residual	0,99	Belum Stasioner	$< 0,05$	Stasioner

Tabel 2 Hasil Uji ADF Masing-Masing IMF dan Residual sebelum dan sesudah *Differencing*

Berdasarkan Tabel 2, hasil uji awal menunjukkan bahwa komponen IMF 1 hingga IMF 5 sudah stasioner pada rata-rata karena memiliki nilai $p\text{-value} < 0,05$. Sementara itu, IMF 6, IMF 7, dan komponen residual memiliki $p\text{-value} > 0,05$ sehingga dinyatakan belum stasioner. Oleh karena itu, proses *differencing* diterapkan pada komponen yang belum stasioner tersebut hingga menghasilkan $p\text{-value} < 0,05$, yang berarti seluruh komponen data kini telah memenuhi syarat stasioneritas rata-rata untuk pemodelan selanjutnya.

3.4 Estimasi Parameter Pembeda (d)

Setelah seluruh komponen data dipastikan stasioner, langkah selanjutnya adalah menghitung nilai parameter pembeda fraksional (d) menggunakan pendekatan *Rescaled Range Statistics* (R/S). Nilai parameter d ini berfungsi untuk menangkap derajat memori jangka panjang pada data deret waktu. Hasil estimasi parameter pembeda d untuk masing-masing komponen IMF dan *residual* dirangkum dalam **Tabel 3**:

No	Komponen Data	dR/S	Keterangan Hubungan Jangka Panjang
1	IMF 1	-0,15	Proses stasioner dengan korelasi/ketergantungan negatif
2	IMF 2	-0,066	Proses stasioner dengan korelasi/ketergantungan negatif
3	IMF 3	0,081	Hubungan jangka panjang bersifat positif
4	IMF 4	0,164	Hubungan jangka panjang bersifat positif

5	IMF 5	0,322	Hubungan jangka panjang bersifat positif
6	IMF 6	0,341	Hubungan jangka panjang bersifat positif
7	IMF 7	0,346	Hubungan jangka panjang bersifat positif
8	Residual	0,345	Hubungan jangka panjang bersifat positif

Tabel 3 Estimasi Parameter Pembeda $d_{R/S}$ Masing-Masing Komponen

Berdasarkan **Tabel 3**, komponen IMF 1 dan IMF 2 memiliki nilai pembeda d di antara -0,5 hingga 0. Hal ini menunjukkan adanya karakteristik proses stasioner dengan korelasi negatif yang meluruh secara perlahan seiring bertambahnya lag. Sementara itu, komponen IMF 3 hingga IMF 7 beserta komponen *residual* menghasilkan nilai d positif yang berkisar di antara 0 hingga 0,5. Nilai tersebut mengonfirmasi adanya hubungan jangka panjang yang kuat dan bersifat positif antar pengamatan yang letaknya saling berjauhan, sehingga tepat untuk dimodelkan dengan ARFIMA pecahan.

3.5 Identifikasi Orde Model ARFIMA (p, d, q)

Identifikasi orde model ARFIMA (p, d, q) untuk masing-masing komponen ditentukan berdasarkan analisis visual terhadap grafik *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) setelah data ditransformasikan menggunakan nilai parameter pembeda fraksional (d). Orde *autoregressive* (p) diidentifikasi melalui lag yang melampaui batas signifikansi pada plot PACF, sedangkan orde *moving average* (q) ditentukan dari lag yang melewati batas signifikansi pada plot ACF.

Berdasarkan analisis plot tersebut, dibentuk beberapa kandidat model tentatif untuk setiap komponen masukan. Melalui prinsip parsimoni (*parsimony*) dan pengujian signifikansi parameter menggunakan nilai $p\text{-value} < (0,05)$, diperoleh daftar model ARFIMA yang memenuhi syarat kelayakan untuk setiap komponen. Ringkasan hasil identifikasi pasangan model potensial yang lolos uji kelayakan disajikan pada **Tabel 4**:

No	Komponen Data	Kandidat Model yang Memenuhi Syarat Kelayakan
1	IMF 1	ARFIMA(1,d,0), (3,d,0), (1,d,1), (3,d,1), (1,d,3), (3,d,3), (1,d,10), (0,d,1), (0,d,3), (0,d,10)
2	IMF 2	ARFIMA(1,d,0), (3,d,0), (1,d,1), (3,d,1), (1,d,3),

		(3,d,3), (1,d,10), (0,d,1), (0,d,3), (0,d,10)
3	IMF 3	ARFIMA(1,d,0), (2,d,0), (3,d,0), (1,d,1), (2,d,1), (3,d,1), (1,d,2), (2,d,2)
4	IMF 4	ARFIMA(0,d,1), (0,d,2), (0,d,3), (1,d,0), (1,d,1), (1,d,2), (1,d,3)
5	IMF 5	ARFIMA(0,d,1), (0,d,2), (1,d,0), (1,d,1), (1,d,2), (2,d,0), (2,d,1), (2,d,2)
6	IMF 6	ARFIMA(0,d,1), (0,d,2), (0,d,4), (1,d,0), (1,d,1), (1,d,2), (1,d,4), (2,d,0), (2,d,1), (2,d,2), (2,d,4)
7	IMF 7	ARFIMA(0,d,1), (0,d,2), (0,d,3), (1,d,0), (1,d,1), (1,d,2), (1,d,3)
8	Residual	ARFIMA(0,d,1), (0,d,3), (0,d,9), (1,d,0), (1,d,1), (1,d,3), (1,d,9), (2,d,0), (2,d,1), (2,d,3), (2,d,9)

Tabel 4 Kandidat Model ARFIMA (p,d,q) yang Layak untuk Setiap Komponen Data

Kumpulan kandidat model pada **Tabel 4** merupakan model-model parsimoni yang parameternya terbukti signifikan secara statistik. Seluruh kombinasi orde ini selanjutnya akan dievaluasi pada tahap pengujian *goodness-of-fit* untuk menentukan satu model terbaik yang menghasilkan nilai kriteria informasi terkecil untuk digunakan dalam proses peramalan nilai impor.

3.6 Pemilihan Model ARFIMA Terbaik berdasarkan Kriteria AIC

Setelah mendapatkan model-model kandidat yang parameternya signifikan pada tahap identifikasi, pemilihan model ARFIMA terbaik untuk setiap komponen ditentukan

berdasarkan nilai kriteria informasi terkecil menggunakan nilai *Akaike Information Criterion* (AIC). Model dengan nilai AIC terendah dipilih sebagai model performa terbaik yang akan digunakan untuk melakukan peramalan data secara independen. Hasil ringkasan pemilihan model terbaik beserta nilai AIC masing-masing komponen disajikan pada Tabel 5:

No	Komponen Data	Model Terbaik	Nilai AIC
1	IMF 1	ARFIMA (1, d, 1)	2801,084
2	IMF 2	ARFIMA (1, d, 2)	2199,637
3	IMF 3	ARFIMA (1, d, 0)	1905,011
4	IMF 4	ARFIMA (0, d, 1)	1556,337
5	IMF 5	ARFIMA (2, d, 1)	1040,561
6	IMF 6	ARFIMA (1, d, 0)	345,2127
7	IMF 7	ARFIMA (0, d, 0)	-1136,319
8	Residual	ARFIMA (1, d, 1)	779,3141

Tabel 5 Model ARFIMA Terbaik untuk Setiap Komponen Data

Berdasarkan **Tabel 5**, setiap komponen IMF dan *residual* memiliki spesifikasi model ARFIMA yang unik dengan struktur lag yang berbeda-beda menyesuaikan karakteristik fluktuasi datanya. Seluruh model terbaik ini telah memenuhi kriteria kelayakan model dan memiliki nilai AIC paling minimum di antara kandidat lainnya, sehingga dipastikan siap untuk digunakan dalam menghasilkan proyeksi peramalan pada tahap superposisi berikutnya.

3.7 Kombinasi Peramalan (Superposisi) dan Akurasi Peramalan

Setelah hasil peramalan diperoleh secara independen untuk setiap komponen IMF 1 hingga IMF 7 beserta komponen *residual* menggunakan model terbaik masing-masing, langkah akhir yang dilakukan adalah tahap penggabungan kembali atau kombinasi peramalan yang disebut dengan superposisi (*superposition*). Melalui prinsip superposisi, seluruh nilai prediksi dari masing-masing komponen dijumlahkan secara matematis untuk menghasilkan nilai prediksi total dari nilai impor non-migas Indonesia. Proses pengujian performa model total ini dilakukan dengan membandingkan nilai hasil superposisi terhadap 58 observasi data aktual pada data *testing* (Maret 2019 – Desember 2023).

Untuk mengukur tingkat keakuratan dan keandalan hasil peramalan model *hybrid* EEMD-ARFIMA secara menyeluruh, dilakukan evaluasi menggunakan indikator *Mean Absolute Percentage Error* (MAPE). Berdasarkan hasil perhitungan akurasi menggunakan *Mean Absolute Percentage Error* (MAPE), metode EEMD-ARFIMA menghasilkan nilai MAPE sebesar 14,29056 yang lebih kecil dibandingkan metode ARFIMA tanpa dekomposisi yaitu sebesar 18,97699. Nilai MAPE tersebut menunjukkan bahwa hasil peramalan memiliki tingkat akurasi yang baik. Dengan tingkat akurasi

tersebut, hasil peramalan dapat digunakan sebagai bahan pertimbangan dalam pengambilan keputusan, khususnya untuk mengantisipasi perubahan impor non-migas di masa mendatang.

4. SIMPULAN

Berdasarkan hasil analisis data nilai impor non-migas Indonesia periode Januari 2000–Desember 2023 (230 data *train* dan 58 data *testing*), dapat disimpulkan bahwa penerapan metode *hybrid* EEMD-ARFIMA secara signifikan meningkatkan akurasi model dalam melakukan proyeksi peramalan. Melalui proses *Ensemble Empirical Mode Decomposition* (EEMD), kompleksitas data riil yang bersifat non-linier dan non-stasioner berhasil terurai menjadi komponen yang lebih sederhana berupa 7 *Intrinsic Mode Function* (IMF) dan satu komponen *residual* untuk kemudian dimodelkan secara individual menggunakan pendekatan pecahan ARFIMA. Penggabungan kembali hasil prediksi setiap komponen melalui tahap superposisi (penjumlahan) terbukti mampu menangkap dinamika pola data perdagangan secara lebih efektif daripada model tunggal tanpa dekomposisi, yang ditunjukkan oleh nilai *Mean Absolute Percentage Error* (MAPE) metode *hybrid* EEMD-ARFIMA sebesar 14,29056%, jauh lebih kecil dibandingkan nilai MAPE metode ARFIMA data asli sebesar 18,97699%.

5. UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih yang sebesar-besarnya kepada dosen pembimbing, jurusan, serta seluruh pihak yang telah memberikan dukungan akademik, fasilitas laboratorium komputasi, bantuan diskusi teknis, dan motivasi selama pelaksanaan penelitian hingga penyusunan artikel ini selesai dengan baik.

6. REKOMENDASI

Tantangan utama yang ditemukan dalam penelitian ini adalah adanya nilai negatif pada beberapa komponen hasil dekomposisi serta keharusan untuk memenuhi asumsi stasioneritas yang ketat pada model ARFIMA. Kondisi tersebut menimbulkan hambatan tersendiri ketika diperlukan proses transformasi data (seperti transformasi *Box-Cox*) yang tidak selalu kompatibel dengan data bernilai negatif.

Berdasarkan hambatan tersebut, untuk ide penelitian selanjutnya disarankan untuk mempertimbangkan penggunaan metode *Complete Ensemble Empirical Mode Decomposition with Adaptive Noise* (CEEMDAN) guna meminimalisir efek *mode mixing* dan menghasilkan komponen dekomposisi yang lebih stabil. Selain itu, peneliti berikutnya juga direkomendasikan untuk mengeksplorasi metode peramalan alternatif yang tidak memerlukan asumsi stasioneritas secara ketat serta mampu mengolah data negatif secara langsung, seperti metode berbasis *machine learning* (misalnya *Gated Recurrent Unit*, SVR, atau LSTM) ataupun

metode statistik non-parametrik lainnya guna menyederhanakan proses pemodelan dan terus meningkatkan akurasi proyeksi.

7. REFERENSI

- Albab, A. U. (2022). *PENGARUH NILAI EKSPOR DAN IMPOR MIGAS DAN NON-MIGAS TERHADAP INFLASI DI INDONESIA*. 2, 116–132.
- Anita, S. (2017). *PERAMALAN NILAI IMPOR INDONESIA DENGAN METODE AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA) BERBANTUAN SOFTWARE STATA DAN R*. Universitas Negeri Semarang.
- Granger, C. W. J., & Joyeux, R. (1980). AN INTRODUCTION TO LONG-MEMORY TIME SERIES MODELS AND FRACTIONAL DIFFERENCING. *Journal Of Time Series Analysis*.
- Herawati, S., & Djunaidy, A. (2014). *MENGGUNAKAN GABUNGAN METODE ENSEMBLE EMPIRICAL MODE DECOMPOSITION (EEMD) DAN*. 4(1), 61–69.
- Hosking, L. K., Boyd, P. R., Xu, C. F., Nissum, M., Cantone, K., Purvis, I. J., Khakhar, R., Barnes, M. R., Liberwirth, U., Hagen-Mann, K., Ehm, M. G., & Riley, J. H. (2002). Linkage disequilibrium mapping identifies a 390 kb region associated with CYP2D6 poor drug metabolising activity. *The Pharmacogenomics Journal*, 2(3), 165–175.
- Huang, Shen, Zheng, Long, S. R., U, M. C. W., Shih, H. H., Zheng, Q., Yen, N. i-C., Tung, C. C., & Liu, H. H. (1998). *The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis*.
- Krismawanti, I. A., Martha, S., & Debatara, N. N. (2019). *PEMODELAN AUTOREGRESSIVE FRACTIONALLY INTEGRATED MOVING AVERAGE (ARFIMA) DALAM MEMREDIKSI HARGA CRUDE PALM OIL (CPO)* Ika Ayu Krismawanti, Shantika Martha, Naomi Nessyana Debatara *INTISARI*. 08(4), 721–728.
- Kuswanto, G. R. (2016). *Analisis pengaruh pdb riil, cadangan devisa dan nilai tukar rupiah terhadap impor nonmigas di indonesia*. 6(2), 166–190.
- Nur Rohman, B. A. (2018). *Peramalan Nilai Impor Migas di Jawa Timur dengan Menggunakan Metode Arima Box-jenkins*.
- Sedyaningrum, M. (2016). *DAYA BELI MASYARAKAT DI INDONESIA Studi Pada Bank Indonesia Periode Tahun 2006 : IV-2015 : III*. 34(1), 114–121.
- Siregar, R., Santoso, R., Kartikasari, P., Statistika, D., & Diponegoro, U. (2021). *Peramalan indeks harga saham menggunakan ensemble empirical mode decomposition (eemd)*. 10(1998), 211–220.
- Sukirno, S. (2012). *Makro Ekonomi Teori Pengantar*. Jakarta: PT Raja Grafindo.
- Zhang, J., Yan, R., Gao, R. X., & Feng, Z. (2010). *Sistem Mekanik dan Pemrosesan Sinyal Peningkatan kinerja dekomposisi mode empiris ansambel*. 24, 2104–2123. <https://doi.org/10.1016/j.ymssp.2010.03.003>