

# Transformasi Wavelet Diskrit Daubechies Fungsi Soft Thresholding untuk Prediksi Data Inflasi di Indonesia

Mohammad Reyfi Syahnaz Anugrah<sup>1</sup>, Ika Purnamasari<sup>1\*</sup>, Qonita Qurrota A'yun<sup>3</sup>

<sup>1</sup>Laboratorium Statistika Ekonomi dan Bisnis, FMIPA, Universitas Mulawarman

<sup>3</sup>Laboratorium Matematika Komputasi, FMIPA, Universitas Mulawarman

*Keywords:* Daubechies, Inflasi, MAPE, TWD, *Thresholding*

## Abstract:

Metode prediksi klasik pada umumnya mensyaratkan data harus bersifat stasioner, akan tetapi umumnya terdapat beberapa data runtun waktu yang bersifat nonstasioner. Salah satu metode yang mampu menganalisa data non-stasioner dengan baik adalah transformasi wavelet diskrit (TWD). Estimasi *thresholding* dilakukan untuk menghapuskan *noise* pada data, dengan menggunakan fungsi dan parameter *threshold* yang sangat berpengaruh pada kemulusan hasil estimasi. Penelitian ini bertujuan untuk memprediksi inflasi di Indonesia pada bulan Mei 2012 hingga Desember 2022 menggunakan TWD daubechies *soft thresholding* dan parameter *adaptive*, serta mengetahui level resolusi terbaik dari perolehan nilai akurasi prediksi menggunakan *Mean Absolute Percentage Error* (MAPE). Hasil penelitian menunjukkan bahwa nilai prediksi baik pada level 1 sampai dengan level 5 sangat mendekati pola data aktual, dengan MAPE kurang dari 5%. Nilai MAPE terkecil yaitu 2,81% terdapat pada level resolusi pertama, dengan kategori akurasi prediksi sangat baik.

## 1. Pendahuluan

Prediksi adalah upaya memperkirakan secara terstruktur peristiwa yang akan datang berdasarkan informasi masa lampau dan masa kini, sehingga perbedaan antara hasil dan perkiraan dan kejadian sebenarnya dapat diminimalkan (Prasetyo et al., 2023; Tursina et al., 2023). Metode statistika yang digunakan untuk melakukan prediksi pada data runtun waktu seperti ARIMA, SARIMA, dan Moving Average, mensyaratkan beberapa asumsi yang harus dipenuhi. Asumsi-asumsi tersebut yaitu kestasioneritas data dan beberapa metode memiliki syarat bahwa adanya pola tertentu pada data. Pada umumnya data runtun waktu berpola trend yang mengakibatkan data menjadi tidak stasioner. Oleh karena itu, diperlukan metode alternatif lain untuk menganalisis data non-stasioner.

(Song & Chissom, 1993) mengembangkan teori *Fuzzy Time Series*, sebuah metode yang ada asumsi tertentu dan mampu mengonversi data runtun waktu menjadi bentuk linguistik. Beberapa peneliti mencoba membandingkan metode Fuzzy Time Series dan metode ARIMA Box-Jenkins, dengan hasil yang menunjukkan bahwa metode Fuzzy Time Series memiliki nilai akurasi prediksi ataupun peramalan yang lebih baik daripada metode ARIMA Box-Jenkins (Ahsan & Rifai, 2023; Laskarjati & Ahmad, 2023; Prasetyo et al., 2023; Susilowati & Sulistijanti, 2018). Walaupun demikian, mengubah data runtun waktu ke dalam bahasa linguistik bukanlah hal yang mudah. Terkait hal ini, dikembangkan suatu metode baru yang lebih mudah dalam penggunaannya yaitu transformasi wavelet.

\* Corresponding author.

E-mail address: ika.purnamasari@fmipa.unmul.ac.id



Transformasi Wavelet yang umum digunakan yaitu Transformasi Wavelet Diskrit (TWD) (Priyandoko, 2021; Ramadhan & Setiyono, 2019). Menurut (Ulfiati & Sugiman, 2015), TWD dianggap lebih tepat digunakan karena adanya koefisien wavelet dan skala pada tiap level dekomposisinya. Selain itu TWD dianggap relatif lebih sederhana dalam pengimplementasiannya. TWD akan menghasilkan sejumlah koefisien yang nantinya akan mengestimasi suatu nilai yang diduga merupakan gangguan. Estimasi ini disebut estimasi *noise*. (Ari Wibowo et al., 2012; Fransiskus Fran, 2019; Kusumaningrum et al., 2017) menyatakan level resolusi, fungsi wavelet, jenis *thresholding*, dan parameter *threshold* yang digunakan pada TWD sangat berpengaruh terhadap hasil estimasi.

(Kusumaningrum et al., 2017) dalam penelitiannya mengemukakan bahwa prediksi harga penutupan harian saham JII, model terbaik didapatkan menggunakan parameter *adaptive* dan fungsi *soft thresholding* dengan MAPE sebesar 0,18%. Peneliti lainnya, (Mubarok & Wachidah, 2021) menunjukkan hasil penelitiannya yang mana diperoleh nilai MSE terkecil 234,8814 berdasarkan fungsi *soft thresholding* dengan parameter *adaptive threshold*. Berdasarkan uraian tersebut, akan dilakukan prediksi inflasi di Indonesia berdasarkan Transformasi Wavelet Daubechies *soft thresholding* dengan pemilihan parameter *adaptive*.

## 2. Tinjauan Pustaka

### 2.1 Wavelet Daubechies

Wavelet Daubechies dinamai berdasarkan penemunya, Ingrid Daubechies. Wavelet ini banyak dipakai karena kemampuannya yang baik dalam kompres data. Penulisan nama Wavelet Daubechies biasanya berupa dbN, di mana N menunjukkan orde yang mencerminkan koefisien filternya dan db adalah singkatan dari Daubechies. Analisis data dengan wavelet Daubechies umumnya melibatkan proses transformasi yang mencakup filter skala dan filter wavelet. Filter wavelet ( $h_l$ ) bersifat halus, sedangkan filter skala ( $g_l$ ) bersifat detail. Algoritma piramida digunakan untuk menghitung kedua koefisien tersebut (Daubechies, 1992).

### 2.2 Filter Skala

Filter skala ( $g_l$ ) merupakan filter yang sangat kompleks. Filter skala berisi deret bernilai real  $\{g_l; l = 0, 1, 2, \dots, L - 1\}$  dengan  $L$  menyatakan lebar filter yang merupakan bilangan bulat. Lebar filter pada umumnya sama dengan N yang berada pada dbN. Fiter skala akan digunakan untuk mencari nilai koefisien-koefisien skala. (Burrus & Gopinath, 1998) menyatakan bahwa transformasi daubechies db4 mempunyai filter skala yaitu  $g_0, g_1, g_2$ , dan  $g_3$  yang didapatkan dari persamaan berikut:

$$g_0 = \frac{(1 - \cos(\alpha) + \sin(\alpha))}{2\sqrt{2}} \quad (1.a)$$

$$g_1 = \frac{(1 + \cos(\alpha) + \sin(\alpha))}{2\sqrt{2}} \quad (1.b)$$

$$g_2 = \frac{(1 + \cos(\alpha) - \sin(\alpha))}{2\sqrt{2}} \quad (1.c)$$

$$g_3 = \frac{(1 - \cos(\alpha) - \sin(\alpha))}{2\sqrt{2}} \quad (1.d)$$

dengan  $\alpha = \frac{\pi}{L-1}$ .

Terdapat beberapa syarat kondisi harus terpenuhi pada filter skala, jika nilai filter yang didapatkan tidak memenuhi kondisi yang ada, dapat dipastikan nilai filter tersebut salah. Berikut ini merupakan kondisi yang harus dipenuhi oleh filter skala (Percival & Walden, 2000).

$$\sum_{l=0}^{L-1} g_l = \sqrt{2} \quad (2.a)$$

$$\sum_{l=0}^{L-1} g_l^2 = 1 \quad (2.b)$$

$$\sum_{l=0}^{L-1} g_l g_{l+2} = 0 \quad (2.c)$$

### 2.3 Filter Wavelet

Filter wavelet merupakan filter yang bersifat *smooth*, yang berguna untuk mencaari nilai koefisien wavelet pada saat transformasi. Filter wavelet ( $h_l : l = 0, 1, \dots, L - 1$ ), dimana  $L$  menyatakan banyak koefisien filter yang merupakan bilangan bulat, diasumsikan sebagai deret dari bilangan riil.

$$h_l = (-1)^l g_{L-1-l} \tag{3}$$

(Percival & Walden, 2000) menyebutkan bahwa terdapat beberapa asumsi yaitu:

$$\sum_{l=0}^{L-1} h_l = 0 ; \tag{4.a}$$

$$\sum_{l=0}^{L-1} h_l^2 = 1 ; \tag{4.b}$$

$$\sum_{l=0}^{L-1} h_l h_{l+2} = 0 \tag{4.c}$$

### 2.4 Transformasi Wavelet

Transformasi wavelet yaitu suatu fungsi transfer yang dipergunakan untuk melakukan penguraian pada data, fungsi maupun operator menjadi komponen frekuensi yang tidak sama, selanjutnya melakukan analisa dengan resolusi yang sesuai berdasarkan skala data (Daubechies, 1992). Koefisien wavelet merupakan deret bilangan riil yang diperoleh sebagai hasil dari perubahan input melalui transformasi. Ada dua jenis transformasi wavelet, yaitu transformasi wavelet kontinu (TWK) dan transformasi wavelet diskrit (TWD). Transformasi wavelet diskrit (TWD) merupakan metode untuk memasangkan data dari domain waktu ke domain wavelet, dengan hasil berupa vektor yang berukuran sama, dengan syarat banyak data haruslah  $n = 2^J$ , dengan  $J \in Z, J \neq 0$ .

### 2.5 Algoritma Piramida

Pola multiskala melalui algoritma piramida digunakan untuk menghitung koefisien TWD. Pada setiap level, data terbagi menjadi dua dengan ukuran yang sama, dan jumlah koefisien di setiap level sebesar  $\frac{n}{2^j}$ . Level koefisien ( $j$ ) diperoleh dari  $J - 1$ . Berikut tahapan untuk menghitung koefisien wavelet dan skala di setiap level berdasarkan algoritma piramida.

#### 2.5.1 Algoritma Piramida Level 1

Pada tahap awal, dilakukan perhitungan koefisien TWD level pertama. Transformasi tahap awal ditujukan untuk memecah data runtun waktu  $X$  menjadi koefisien  $W_1$  dan  $V_1$  dengan jumlah yang sama. Masing-masing koefisien terdiri dari  $\frac{n}{2^1}$  koefisien wavelet  $W_1$  dan  $\frac{n}{2^1}$  koefisien skala  $V_1$ . Untuk menghitung koefisien wavelet pada level pertama, maka digunakan persamaan (5) sebagai berikut.

$$W_{j,t} = \sum_{l=0}^{L-1} h_l X_{(2t-l) \bmod n}, \quad t = 1, 2, \dots, \frac{n}{2} \tag{5}$$

dengan

- $W_{j,t}$  : koefisien wavelet level ke- $j$  dan baris ke- $t$
- $X$  : data runtun waktu
- $h_l$  : filter wavelet ke- $l$
- $n$  : banyak data
- $L$  : lebar koefisien filter

Setelah diperoleh koefisien wavelet, berikutnya dihitung koefisien skala dengan bantuan filter skala sebagai pemulus detailnya, sebagaimana persamaan (6).

$$V_{j,t} = \sum_{l=0}^{L-1} g_l X_{(2t-l) \bmod n}, \quad t = 1, 2, \dots, \frac{n}{2} \tag{6}$$

dengan

- $V_{j,t}$  : koefisien skala pada level  $j$  dan baris  $t$
- $X$  : data runtun waktu
- $g_l$  : filter wavelet ke- $l$
- $L$  : lebar koefisien filter
- $n$  : banyak data

Setelah diperoleh koefisien wavelet ( $W_{1,t}$ ) dan koefisien detail ( $V_{1,t}$ ), berikutnya dapat ditentukan koefisien-koefisien sebagai berikut:

$$W_1 = [W_{1,1}, W_{1,2}, \dots, W_{1,\frac{n}{2}}]^T \quad (7)$$

$$V_1 = [V_{1,1}, V_{1,2}, \dots, V_{1,\frac{n}{2}}]^T \quad (8)$$

### 2.5.2 Algoritma Piramida Level 2

Proses pada tahap kedua sama halnya dengan tahap sebelumnya, di mana pada tahap ini data ( $V_{1,t}$ ) diproses dengan jalan yang sama saat mengubah ( $X_t$ ) menjadi dua bagian yang berukuran sama. Level kedua, ( $V_{1,t}$ ) diasumsikan sebagai rata-rata dari skala unit karena ( $V_{1,t}$ ) merupakan koefisien skala. Pada level kedua akan diperoleh koefisien wavelet yang baru, yaitu ( $W_{2,t}$ ) dan ( $V_{2,t}$ ).

$$W_{2,t} \equiv \sum_{l=0}^{L-1} h_l V_{1,(2t-l) \bmod n} \quad (9)$$

$$V_{2,t} \equiv \sum_{l=0}^{L-1} g_l V_{1,(2t-l) \bmod n} \quad (10)$$

selanjutnya pada level kedua, diperoleh koefisien yaitu:

$$W_2 = [W_{2,1}, W_{2,2}, \dots, W_{2,\frac{n}{4}}]^T \quad (11)$$

$$V_2 = [V_{2,1}, V_{2,2}, \dots, V_{2,\frac{n}{4}}]^T \quad (12)$$

Setelah diperoleh kedua koefisien tersebut, maka untuk selanjutnya dapat dilakukan rekonstruksi ulang ( $V_{j,t}$ ) dan proses tersebut berlanjut sehingga sampai pada level resolusi ke- $j$ . Perhitungan ini memproses koefisien skala ( $V_{j-1}$ ) untuk mendapatkan dua koefisien (wavelet dan skala) pada level  $j$ , sebagai berikut:

$$W_j = [W_{j,1}, W_{j,2}, \dots, W_{j,\frac{n}{2^j}}]^T \quad (13)$$

$$V_j = [V_{j,1}, V_{j,2}, \dots, V_{j,\frac{n}{2^j}}]^T \quad (14)$$

### 2.6 Estimasi Thresholding

Koefisien *thresholding* dapat dibentuk dengan menerapkan fungsi *thresholding* yang tepat. Ada dua jenis fungsi *thresholding* yaitu fungsi *hard thresholding* dan fungsi *soft thresholding*, yang didefinisikan sebagai berikut (Donoho & Johnstone, 1994):

#### a. Hard Thresholding

Dimana koefisien wavelet  $W_{j,l}$  menjadi  $W_{j,l}^{(HT)}$  dengan elemennya:

$$W_{j,l}^{(HT)} = \begin{cases} W_{j,l} & \text{jika } |W_{j,l}| \geq \lambda \\ 0 & \text{, } W_{j,l} \text{ yang lain} \end{cases} \quad (15)$$

#### b. Soft Thresholding

Dimana koefisien wavelet  $W_{j,l}$  menjadi  $W_{j,l}^{(ST_j)}$  dengan elemennya:

$$W_{j,l}^{(ST_j)} = \text{sign}\{W_{j,l}\} f(|W_{j,l}| - \lambda \times \sigma) \quad (16)$$

Dengan

$$\text{Sign}\{W_{j,l}\} = \begin{cases} +1, & \text{jika } W_{j,l} > 0 \\ 0, & \text{jika } W_{j,l} = 0 \\ -1, & \text{jika } W_{j,l} < 0 \end{cases} ;$$

$$f(|W_{j,t}| - \lambda_j^A \times \sigma) = \begin{cases} (|W_{j,t}| - \lambda_j^A \times \sigma), & \text{jika } (|W_{j,t}| - \lambda_j^A \times \sigma) \geq 0 \\ 0, & \text{jika } (|W_{j,t}| - \lambda_j^A \times \sigma) < 0 \end{cases} \quad (17)$$

$\lambda$  merupakan parameter *thresholding* (Percival & Walden, 2000). Fungsi-fungsi tersebut dipakai dalam proses estimasi *thresholding*. Fungsi *hard thresholding* dikenal karena sifat diskontinunya, yang megabaikan nilai  $x$  yang melebihi nilai  $\lambda$ , sedangkan *soft thresholding* dikenal sifat kontinuitasnya. *Wavelet thresholding* pada umumnya melibatkan nilai  $\sigma$  (simpangan baku) dalam perhitungannya dimana biasanya nilai simpangan baku ini tidak diketahui, namun dapat dihitung menggunakan persamaan (18).

$$\sigma = \frac{\text{median}(|W_{J-j_{\max}}|)}{0,6745} \quad (18)$$

dengan

$$J = \lceil 2 \log(n) \rceil$$

$j_{\max}$  = Indeks level terakhir

### 2.7 Adaptive Threshold

Pemilihan parameter yang optimal ditentukan oleh nilai *threshold*  $\lambda_j$  pada setiap level resolusi  $j$ , yang dikenal dengan *level-dependent thresholding*. *Adaptive threshold* ( $\lambda_j^A$ ) merupakan salah satu *threshold* optimal yang seringkali digunakan. Pada *threshold* tersebut terdapat asumsi yaitu residual  $\varepsilon$  tidak berdistribusi normal. (Donoho & Johnstone, 1994) merupakan pencetus *Adaptive threshold* yang bertujuan untuk meminimumkan *Stein Unbiased Risk Estimator* (SURE) pada tiap level.

$$\lambda_j^A = \arg \min_{\lambda \geq 0} \text{SURE}(W_{j,t}; \lambda) \quad (19)$$

### 2.8 Nilai Keakuratan Peramalan

Nilai keakuratan peramalan digunakan untuk mengukur seberapa akurat metode yang digunakan untuk memberikan hasil peramalan. Terdapat beberapa metode untuk mencari nilai keakuratan peramalan salah satunya *Mean Absolute Percentage Error* (MAPE). Menurut (Purwanti & Purwadi, 2019), peramalan akan sangat akurat jika memiliki MAPE kurang dari 10% dan dapat dikatakan akurat jika nilainya berada di antara 10% dan 20%.

Rumus MAPE:

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{X_t - X'_t}{X_t} \right| \times 100\% \quad (20)$$

Keterangan:

$n$  = banyak data

$X_t$  = data aktual ke- $t$

$X'_t$  = data hasil ramalan ke- $t$

## 3. Metode Penelitian

Pada dasarnya Penelitian ini menggunakan rancangan yang bersifat *ex post facto* atau data dikumpulkan setelah semua kejadian berlangsung. Populasi yang digunakan dalam penelitian ini adalah inflasi di Indonesia. Sampel yang dipilih pada penelitian ini adalah inflasi di Indonesia pada bulan Mei 2012 sampai dengan Desember 2022 yang diperoleh melalui situs resmi Badan Pusat Statistik Indonesia. Jumlah sampel yang digunakan sebanyak 128 data atau  $n = 2^7$  dan 16 data atau  $n = 2^4$ . Hal ini disesuaikan dengan syarat jumlah data pada metode Wavelet Diskrit yaitu  $n = 2^J$ .

Teknik analisis data dalam penelitian ini menggunakan Transformasi Wavelet Diskrit Daubechies (TWD). Tahapan yang dilakukan dalam analisis data yaitu:

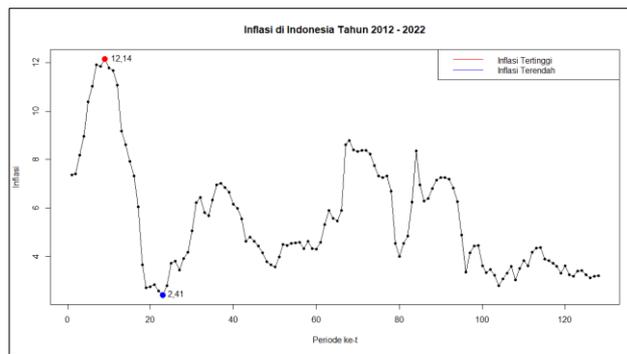
- 1) Deskripsi data
- 2) Menghitung nilai filter skala berdasarkan persamaan (1.a) sampai (1.d)
- 3) Menghitung nilai filter wavelet menggunakan persamaan (3).
- 4) Menghitung koefisien wavelet menggunakan Algoritma berdasarkan persamaan (5) dan persamaan (6)

- 5) Estimasi *Thresholding* berdasarkan fungsi *soft thresholding*
- 6) Pemilihan parameter *adaptive thresholding* berdasarkan persamaan (19)
- 7) Mencari nilai koefisien *thresholding* yang dihasilkan dari persamaan (16)
- 8) Merekonstruksi ulang koefisien *thresholding* sehingga didapatkan sejumlah koefisien-koefisien yang mana koefisien ini merupakan hasil prediksi
- 9) Pemilihan level resolusi terbaik berdasarkan kriteria nilai MAPE.

#### 4. Hasil dan Pembahasan

##### 4.1 Deskripsi Data

Data yang digunakan dalam penelitian adalah data inflasi di Indonesia periode Mei 2012 sampai dengan Desember 2022 sebanyak 128 data. Sebelum melakukan peramalan menggunakan metode transformasi wavelet diskrit, pembahasan akan diawali dengan menampilkan statistika deskriptif berupa grafik runtun waktu dari data inflasi yang ditampilkan pada Gambar 1.



**Gambar 1.** Deskripsi data inflasi di Indonesia

Berdasarkan Gambar 1 terlihat bahwa data inflasi di Indonesia pada periode Mei 2012 sampai dengan Desember 2022 menunjukkan adanya fluktuasi setiap bulan. Inflasi tertinggi terjadi pada periode ke-9 yaitu bulan Januari tahun 2013 dengan inflasi sebesar 12,14 dan inflasi terendah terjadi pada periode ke-23 yaitu bulan Maret tahun 2014 dengan inflasi sebesar 2,41. Berdasarkan plot *time series* pada Gambar 1, secara visual dapat dikatakan data runtun waktu tidak stasioner baik dalam variansi maupun rataan.

##### 4.2 Nilai Filter Wavelet dan Filter Skala

Berdasarkan hasil perhitungan menggunakan persamaan (1.a), (1.b), (1.c) dan (1.d) diperoleh filter skala untuk wavelet Daubechies db4 sebagai berikut:

$$g_0 = \frac{1 + \sqrt{3}}{4\sqrt{2}}, g_1 = \frac{3 + \sqrt{3}}{4\sqrt{2}}, g_2 = \frac{3 - \sqrt{3}}{4\sqrt{2}}, g_3 = \frac{1 - \sqrt{3}}{4\sqrt{2}}$$

Selanjutnya menghitung koefisien filter wavelet dengan menggunakan persamaan (3) dan menghasilkan nilai sebagai berikut:

$$h_0 = \frac{1 - \sqrt{3}}{4\sqrt{2}}, h_1 = \frac{-3 + \sqrt{3}}{4\sqrt{2}}, h_2 = \frac{3 + \sqrt{3}}{4\sqrt{2}}, h_3 = \frac{-1 - \sqrt{3}}{4\sqrt{2}}$$

Setelah mendapatkan nilai filter wavelet dan skala, maka dilakukan proses TWD tiap level sebanyak  $J - 1 = 7 - 1 = 6$  level resolusi, sebagaimana table 1.

**Tabel 1.** Nilai Koefisien Wavelet dan Skala Level 1-6

$j$	$t$	$W_{j,t}$	$V_{j,t}$
1	1	-1,46629923	10,036424
	2	-0,35515112	11,867896
	3	-0,20462130	14,961173
	:	:	:
	62	-0,11288325	4,783256
	63	0,08270429	4,533130
	64	-0,07692731	4,486939
2	1	-0,9134644	23,378119
	2	3,7803470	31,381877
	3	0,4573272	10,465828
	:	:	:
	14	-0,6099267	9,313787
	15	0,2346632	11,293715
	16	-0,4323004	9,128754
:	:	:	:
6	1	-11,957911	46,28702
	2	-7,403781	42,60048

**4.3 Estimasi Thresholding dengan Paramater Adaptive**

Proses estimasi dilakukan menggunakan persamaan (18), sebagai berikut:

$$\begin{aligned} \sigma &= \frac{\text{median}(|W_{7-6}|)}{0,6745} \\ &= \frac{\text{median}(|W_1|)}{0,6745} \\ &= \frac{0,1774146}{0,6745} \\ &= 0,2630313 \end{aligned}$$

Penelitian ini menggunakan parameter *adaptive* ( $\lambda_j^A$ ) *threshold* dengan fungsi *soft threshold*. Nilai  $\lambda_j^A$  didasarkan pada *Stein Unbias Risk Estimator* (SURE) pada tiap level resolusi. Untuk mendapatkan nilai SURE pada setiap level menggunakan persamaan (14). Dari persamaan (19) akan dilakukan perhitungan untuk mendapatkan nilai  $\lambda_j^A$  pada tiap level dengan hasil sebagaimana Tabel 2.

**Tabel 2.** Nilai Parameter Adaptive di Tiap Level Resolusi

Level (j)	$\lambda_j^A$
1	1,61039
2	0,9390695
3	0,9671881
4	1,016883
5	1,358072
6	7,403781

**4.4 Membentuk Koefisien Thresholding**

Berdasarkan persamaan (10) dan (11) dapat dihitung nilai koefisien *thresholding* pada level pertama hingga level ke enam. Perhitungan koefisien pertama dan kedua pada level pertama ( $W_{1,1}^{(ST1)}$  dan  $W_{1,2}^{(ST1)}$ ) sebagai berikut:

$$\begin{aligned}
 W_{1,1}^{(ST1)} &= \text{sign}\{W_{1,1}\}f(|W_{1,1}| - \lambda_1^A \times \sigma) \\
 &= -1 f(1,46629923 - 1,61039 \times 0,2630313) \\
 &= -1 f(1,042716) \\
 &= -1,042716
 \end{aligned}$$

$$\begin{aligned}
 W_{1,2}^{(ST1)} &= \text{sign}\{W_{1,2}\}f(|W_{1,2}| - \lambda_1^A \times \sigma) \\
 &= -1 f(-0,35515112 - 1,61039 \times 0,2630313) \\
 &= -1 f(-0,7787341) \\
 &= 0
 \end{aligned}$$

Perhitungan di atas akan terus berlanjut hingga  $W_{6,4}^{(ST6)}$ , dengan hasil sebagaimana tabel 3.

**Tabel 3.** Nilai Koefisien Thresholding Tiap Level

j	l	$W_{j,l}^{(ST1)}$	$W_{j,l}^{(ST2)}$	...	$W_{j,l}^{(ST6)}$
	1	-1,04271621	-1,21929453	...	0
	2	0	-0,10814642	...	0
	3	0	0	...	0
1	⋮	⋮	⋮	...	⋮
	62	0	0	...	0
	63	0	0	...	0
	64	0	0	...	0
⋮	⋮	⋮	⋮	⋮	⋮
6	1	-11,95791100	-11,95791100	...	-10,01048400
	2	-7,40378100	-7,40378100	...	-5,45635500

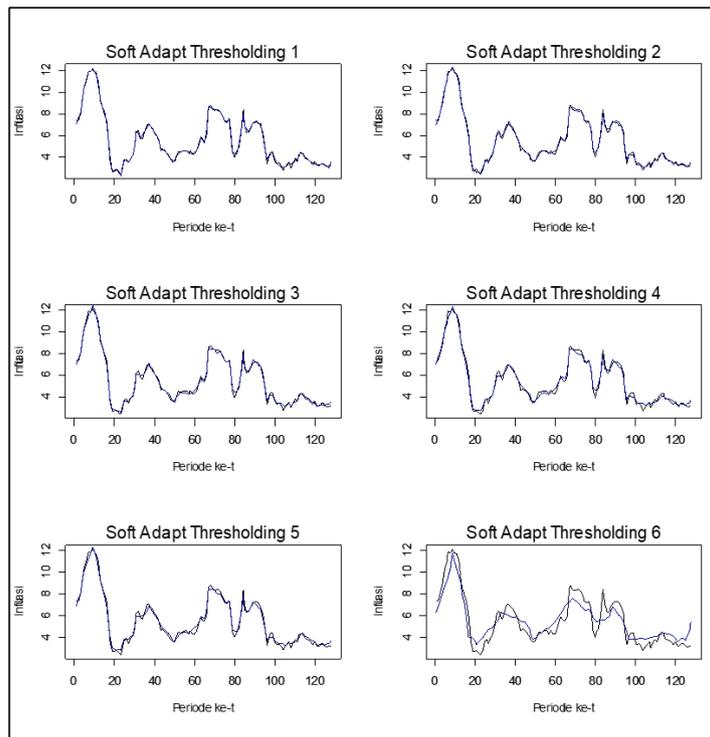
### 4.5 Mendapatkan Hasil Prediksi

Setelah koefisien *thresholding* didapatkan, selanjutnya dilakukan rekonstruksi ulang koefisien *thresholding* melalui invers koefisien *thresholding* yang disebut *inverse discrete wavelet transform* (IDWT). Menghitung IDWT melibatkan serangkaian operasi matematis yang menggunakan koefisien hasil DWT untuk merekonstruksi data. Hasil rekonstruksi ini yang merupakan nilai peramalan. Berikut adalah nilai prediksi per level resolusi.

**Tabel 4. Nilai Prediksi Inflasi per Level-Resolusi**

No	$X'_1$	$X'_2$	$X'_3$	$X'_4$	$X'_5$	$X'_6$
1	7,093532	7,016634	7,082041	7,093532	6,946444	6,328909
2	7,642274	7,529454	7,570072	7,642274	7,601378	6,905324
3	7,991571	8,153643	8,166252	7,991571	8,15622	7,461943
4	9,085209	9,197887	9,137349	9,085209	9,084613	8,09244
5	10,34032	10,42467	10,24591	10,34032	10,15231	8,796815
⋮	⋮	⋮	⋮	⋮	⋮	⋮
124	3,326208	3,232826	3,241358	3,326208	3,353214	3,877638
125	3,211385	3,113069	3,214878	3,211385	3,304955	3,665078
126	3,195054	3,206433	3,297437	3,195054	3,402865	4,204284
127	2,958182	3,256797	3,332856	2,958182	3,442801	4,64821
128	3,544379	3,467638	3,544202	3,544379	3,699097	5,447729

Selanjutnya akan dibuat plot data hasil estimasi dengan *soft thresholding* parameter *adaptive* tiap level resolusi ditunjukkan oleh Gambar 2.



**Gambar 2.** Plot Data Aktual dan Hasil Prediksi

Gambar 2 menunjukkan visual dari data hasil ramalan (garis plot berwarna biru) dan data aktual (garis plot berwarna hitam) yang diperoleh pada tiap-tiap level resolusi. Pada level pertama sampai dengan level ke-5 data hasil ramalan mengikuti plot dengan sangat baik namun pada level keenam terlihat data hasil ramalan mulai menyimpang dan tidak terlalu mengikuti plot data aktual. Nilai MAPE pada level 1-5 berada kurang dari 10%, yang berarti bahwa keakuratan

prediksi berada pada kategori sangat baik. Sedangkan pada level ke-6 keakuratan peramalan berada pada kategori baik, dengan nilai MAPE sebesar 15,6781%.

**Tabel 5.** Nilai MAPE Pada *Soft Thresholding* Parameter Adaptive perlevel

Level ( <i>j</i> )	MAPE (%)
1	2,8174
2	2,9552
3	3,3466
4	4,5001
5	4,6182
6	15,6781

## 5. Kesimpulan

Berdasarkan hasil analisis diperoleh nilai-nilai prediksi data Inflasi di Indonesia menggunakan transformasi wavelet diskrit daubechies fungsi *soft thresholding* dan parameter adaptive sangat mendekati data aktualnya. Jika dilihat dari plot perbandingan prediksi dan aktual, plot prediksi sangat mengikuti gerakan plot data aktual. Nilai akurasi MAPE seluruh level berada di bawah 10% dengan MAPE paling kecil yaitu 2,49% yang berada pada level pertama.

## References

- Ahsan, R. T., & Rifai, N. A. K. (2023). Perbandingan Metode Seasonal ARIMA dan Metode Fuzzy Time Series-Markov Pada Prediksi Inflasi di Indonesia. *Bandung Conference Series: Statistics*, 3(2). <https://doi.org/10.29313/bcss.v3i2.9138>
- Ari Wibowo, Y., Tarno, & Suparti. (2012). Analisis Data Runtun Waktu Menggunakan Metode Wavelet Thresholding. *Jurnal Gaussian*, 1(1).
- Burrus, C. S., & Gopinath, R. a. (1998). and H. Guo, Introduction to Wavelets and Wavelet Transformer: A Primer. *Prentice Hall*.
- Daubechies, I. (1992). Ten Lectures on Wavelets. In *Ten Lectures on Wavelets*. <https://doi.org/10.1137/1.9781611970104>
- Donoho, D. L., & Johnstone, J. M. (1994). Ideal spatial adaptation by wavelet shrinkage. *Biometrika*, 81(3). <https://doi.org/10.1093/biomet/81.3.425>
- Fransiskus Fran, S. S. N. H. (2019). PREDIKSI HARGA SAHAM JII MENGGUNAKAN TRANSFORMASI WAVELET DISKRIT DAUBECHIES. *Bimaster : Buletin Ilmiah Matematika, Statistika Dan Terapannya*, 8(4). <https://doi.org/10.26418/bbimst.v8i4.35876>
- Kusumaningrum, D. A., Suparti, & Maruddani, D. A. I. (2017). ANALISIS DATA RUNTUN WAKTU MENGGUNAKAN METODE WAVELET THRESHOLDING DENGAN MAXIMAL OVERLAP DISCRETE TRANSFORM. *JURNAL GAUSSIAN*, 6(1).
- Laskarjati, S. D., & Ahmad, I. S. (2023). Perbandingan Peramalan Harga Saham menggunakan Autoregressive Intergrated Moving Average (ARIMA) dan Fuzzy Time series Markov Chain (Studi Kasus: Saham PT Indofood CBP Sukses Makmur Tbk). *Jurnal Sains Dan Seni ITS*, 11(6). <https://doi.org/10.12962/j23373520.v11i6.91417>
- Mubarok, D. N., & Wachidah, L. (2021). Analisis Data Deret Waktu pada Nilai Tukar Rupiah Tahun 2021 Menggunakan Metode Wavelet Thresholding. *Prosiding Statistika*, 0(0).
- Percival, D. B., & Walden, A. T. (2000). Wavelet Methods for Time Series Analysis. In *Wavelet Methods for Time Series Analysis*. <https://doi.org/10.1017/cbo9780511841040>
- Prasetyo, H. R., Palupi, I., & Wahyudi, B. A. (2023). Prediksi Menggunakan Model Fuzzy Time Series Studi Kasus Curah Hujan di Kabupaten Bandung. *LOGIC: Jurnal Penelitian Informatika*, 1(1). <https://doi.org/10.25124/logic.v1i1.6405>
- Priyandoko, G. (2021). Klasifikasi Kerusakan Motor Induksi Menggunakan Metode Transformasi Wavelet Diskrit Dan K-Nearest Neighbor. *JOINTECS (Journal of Information Technology and Computer Science)*, 6(2). <https://doi.org/10.31328/jointecs.v6i2.2390>

- Purwanti, D., & Purwadi, J. (2019). Metode Brown's Double Exponential Smoothing dalam Peramalan Laju Inflasi di Indonesia. *Jurnal Ilmiah Matematika*, 6(2). <https://doi.org/10.26555/konvergensi.v6i2.19548>
- Ramadhan, M. D., & Setiyono, B. (2019). Pengolahan Citra untuk Mengetahui Tingkat Kesegaran Ikan Menggunakan Metode Transformasi Wavelet Diskrit. *Jurnal Sains Dan Seni ITS*, 8(1). <https://doi.org/10.12962/j23373520.v8i1.37715>
- Song, Q., & Chissom, B. S. (1993). Fuzzy time series and its models. *Fuzzy Sets and Systems*, 54(3). [https://doi.org/10.1016/0165-0114\(93\)90372-O](https://doi.org/10.1016/0165-0114(93)90372-O)
- Susilowati, & Sulistijanti, W. (2018). Perbandingan Metode Fuzzy Time Series dengan Metode Box-Jenkins untuk Memprediksi Jumlah Kunjungan Pasien Rawat Inap (Studi Kasus: Puskesmas Geyer Satu). *The 7th University Research Colloquium*.
- Tursina, T., Septiriana, R., & Varian, I. (2023). Prediksi Indeks Harga Konsumen Menggunakan Metode Fuzzy Time Series Cheng. *Jurnal Locus Penelitian Dan Pengabdian*, 2(1). <https://doi.org/10.58344/locus.v2i1.850>
- Ulfiati, L., & Sugiman. (2015). Peramalan Data Saham Dengan Transformasi Wavelet Haar. *Unnes Journal of Mathematics*, 4(2).