

PREDIKSI HARGA SAHAM JII MENGGUNAKAN TRANSFORMASI WAVELET DISKRIT DAUBECHIES

Sari Setia Ningrum, Helmi, Fransiskus Fran

INTISARI

Prediksi harga saham di dunia investasi menjadi hal yang sangat penting untuk kegiatan jual-beli saham. Harga saham berubah-ubah secara tidak pasti dipengaruhi beberapa faktor internal dan eksternal. Pergerakan harga saham dapat diprediksi dengan berbagai metode analisis runtun waktu. Pada umumnya, sebagian besar data runtun waktu bersifat tidak stasioner, sehingga proses analisis dapat menggunakan transformasi wavelet diskrit. transformasi wavelet diskrit ini mengubah data asli ke dalam domain wavelet untuk dianalisis. Filter wavelet yang digunakan berbasis wavelet Daubechies. Pada penelitian ini dilakukan analisis penerapan dari transformasi wavelet diskrit pada data runtun waktu dan memprediksi harga saham JII (Jakarta Islamic Index) menggunakan transformasi wavelet diskrit Daubechies. Langkah dalam proses memprediksi ini yaitu melakukan estimasi thresholding untuk mendapatkan model terbaik. Hasil penelitian menunjukkan bahwa parameter minimax dengan fungsi hard thresholding maupun soft thresholding memperoleh model terbaik pada level resolusi pertama dan parameter adaptive dengan fungsi soft thresholding memperoleh model terbaik pada level kedua. Namun, model terbaik untuk memprediksi harga penutupan saham harian JII adalah dengan menggunakan parameter adaptive dengan nilai MAPE (Mean Absolute Percentage Error) sebesar 0,188662%.

Kata Kunci : *estimasi thresholding, parameter minimax, parameter adaptive*

PENDAHULUAN

Kondisi pasar modal Indonesia dalam beberapa tahun terakhir menjadi perhatian banyak pihak, khususnya para pelaku bisnis. Hal ini disebabkan meningkatnya keinginan masyarakat untuk berinvestasi atau menjadi seorang investor. Hal ini berpengaruh pada minat para investor untuk mengamati pergerakan harga saham di masa-masa mendatang. Pergerakan harga saham dapat diprediksi dengan metode analisis runtun waktu.

Pada umumnya sebagian besar data runtun waktu bersifat tidak stasioner. Oleh karena itu, proses analisis dapat menggunakan metode wavelet. Wavelet merupakan fungsi dekomposisi dari *father wavelet* dan *mother wavelet* yang masing-masing bersifat ortogonal. Salah satu jenis wavelet yang bersifat ortogonal adalah wavelet Daubechies [1]. Wavelet Daubechies memiliki kelebihan dibandingkan dengan wavelet lainnya ialah mendapatkan hasil yang lebih *smooth* ketika digunakan dalam kompresi data [1]. Oleh karena itu, jenis wavelet Daubechies sering digunakan untuk proses analisis menggunakan transformasi wavelet.

Dalam kasus ini transformasi wavelet Daubechies digunakan untuk memprediksi pergerakan harga saham JII. *Jakarta Islamic Index* (JII) di bentuk pada tanggal 3 Juli 2000 yang merupakan respon akan kebutuhan informasi mengenai investasi secara Islami [2].

Pada penelitian ini dilakukan analisis penerapan dari transformasi wavelet diskrit Daubechies pada data runtun waktu sehingga diperoleh hasil prediksi harga saham JII. Dalam memprediksi harga saham JII dengan menggunakan transformasi wavelet diskrit berbasis wavelet Daubechies menggunakan filter D4 serta seluruh perhitungan dalam memprediksi menggunakan bantuan *software R*, dan data yang digunakan pada penelitian ini adalah data penutupan harga saham harian JII selama 1 tahun mulai dari tanggal 13 Oktober 2017 sampai dengan 1 November 2018 [3].

Langkah pertama dalam memprediksi harga saham ialah menuntukan ukuran data, dengan disyaratkan data berukuran $N = 2^J$ dengan J merupakan bilangan bulat non negatif. Langkah kedua melakukan pemilihan filter wavelet Daubechies yang berfungsi dalam proses *smoothing* data. Langkah ketiga melakukan pemilihan filter skala Daubechies yang berfungsi dalam mencari detail data. Selanjutnya pada langkah keempat, membagi data menjadi beberapa tingkatan level resolusi dengan menggunakan algoritma piramida kemudian menghitung nilai koefisien wavelet pada setiap tingkatan level resolusi. Perhitungan ini adalah untuk mentransformasi data runtun waktu X dengan $N = 2^J$ kedalam tingkatan level-level resolusi. Langkah kelima estimasi dengan proses *threshold* yang diawali dengan memilih fungsi *threshold* yang digunakan. Pada langkah ini ada dua fungsi yang digunakan untuk proses *thresholding* yaitu *hard thresholding* dan *soft thresholding*. Langkah keenam pemilihan parameter *thresholding*. Parameter *thresholding* (λ) merupakan salah satu yang menentukan kemulusan fungsi. Pemilihan parameter harus teliti agar fungsi optimal. Langkah ketujuh melakukan invers data yang telah dilakukan transformasi wavelet diskrit, kemudian di *thresholding* untuk mengembalikan data ke bentuk aslinya. Selanjutnya pemilihan estimasi terbaik, model wavelet terbaik dipilih dengan melihat nilai MAPE yang paling terkecil. Kemudian memprediksi data harga saham dengan menggunakan model wavelet terbaik yang dipilih berdasarkan nilai MAPE.

WAVELET

Wavelet adalah sebuah fungsi yang bergerak naik turun secara periode waktu tertentu. Fungsi wavelet merupakan fungsi matematika yang mempunyai sifat-sifat tertentu, antara lain berosilasi disekitar nol, terlokalisasi dalam domain waktu dan frekuensi serta membentuk sebuah basis ortogonal dalam $L^2(\mathbb{R})$. Fungsi wavelet dibedakan atas dua fungsi, yaitu *father wavelet* (ϕ) dan *mother wavelet* (Ψ) yang memiliki sifat sebagai berikut [4]:

$$\int_{-\infty}^{\infty} \phi(x) dx = 1 \text{ dan } \int_{-\infty}^{\infty} \Psi(x) dx = 0$$

Dengan gabungan proses dilatasi penskalaan dan proses translasi atau pergeseran posisi menghasilkan jenis wavelet ortogonal, yaitu:

$$\phi_{j,k}(x) = (p2^j)^{\frac{1}{2}} \phi(p2^j x - k) \text{ dan } \Psi_{j,k}(x) = (p2^j)^{\frac{1}{2}} \Psi(p2^j x - k)$$

dengan $j, k \in \mathbb{Z}^+$ dan skalar $p > 0$. Indeks j menunjukkan skala atau banyak komponen level transformasi sedangkan k menunjukkan banyak koefisien dalam suatu level transformasi. Beberapa jenis wavelet ortogonal adalah Haar, Daubechies, Coiflets, Symlets, Discrete Meyer, dan Morlet [4].

FILTER WAVELET DAN SKALA

Jika fungsi skala $\phi(t)$ yang mengalami peregangan dan pergeseran, maka $\phi(t) = \sqrt{2} \sum_{l=0}^L g_l \phi(2t - l)$, dengan $\phi(2t - l)$ adalah fungsi skala $\phi(t)$ yang mengalami pergeseran sepanjang sumbu waktu dan langkah l dengan koefisien filter skala g_l dan fungsi *mother wavelet* $\psi(t)$ didefinisikan sebagai $\psi(t) = \sqrt{2} \sum_{l=0}^{L-1} (-1)^l h_l \psi(2t - l)$, begitu juga fungsi wavelet $\psi(t)$ mengalami pergeseran sepanjang sumbu waktu dengan langkah l dengan koefisien filter skala h_l . Filter wavelet harus memenuhi tiga kondisi dasar sebagai berikut [4]:

$$\begin{aligned} \sum_{l=0}^{L-1} h_l &= 0 \\ \sum_{l=0}^{L-1} h_l^2 &= 1 \\ \sum_{l=0}^{L-1} h_l h_{l+2n} &= 0, \quad n \in \mathbb{Z}^+ \end{aligned}$$

Filter skala memenuhi tiga kondisi dasar sebagai berikut [4]:

$$\begin{aligned} \sum_{l=0}^{L-1} g_l &= \sqrt{2} \\ \sum_{l=0}^{L-1} g_l^2 &= 1 \\ \sum_{l=0}^{L-1} g_l g_{l+2m} &= 0, \text{ dengan } m \neq 0, m \in \mathbb{Z}^+ \end{aligned}$$

WAVELET DAUBECHIES

Wavelet Daubechies merupakan salah satu jenis dari wavelet ortogonal. Wavelet Daubechies ini diambil dari nama belakang penemunya yaitu Ingrid Daubechies. Pada penelitian ini, digunakan Daubechies 4 disingkat $D(4)$ yaitu dengan panjang *bandwith* $L = 4$. Berdasarkan syarat yang harus dipenuhi maka koefisien filter waveletnya sebagai berikut [4]:

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

Sedangkan untuk koefisien filter skalanya sebagai berikut [3]:

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

TRANSFORMASI WAVELET DISKRIT

Transformasi Wavelet Diskrit (TWD) memiliki sifat transformasi linear ortonormal. TWD dari sebuah deret waktu X dengan panjang $N = 2^J$, dengan J adalah *integer* positif, dengan pembentukan W dari koefisien TWD per level dari perkalian matriks filter atas X sebagai berikut:

$$WX = \begin{bmatrix} W_1 \\ W_2 \\ \vdots \\ W_j \\ V_j \end{bmatrix} X = \begin{bmatrix} W_1 X \\ W_2 X \\ \vdots \\ W_j X \\ V_j X \end{bmatrix} = \begin{bmatrix} W_1 \\ W_2 \\ \vdots \\ W_j \\ V_j \end{bmatrix} = W$$

dengan X adalah data runtun waktu, W adalah matriks filter bernilai rill dengan ukuran $N \times N$ dan W adalah matriks koefisien TWD (level 1,2, ... , J) [4].

ALGORITMA PIRAMIDA

Proses TWD menerapkan pola multiskala menggunakan algoritma piramida untuk menghitung nilai koefisien transformasi wavelet diskrit $\{W_{j,l} = W_{1,l}, W_{2,l}, \dots, W_{j_0,l}, V_{j_0,l}\}$ per level resolusi. Berikut langkah-langkah algoritma piramida untuk TWD yang menghasilkan output koefisien wavelet dan skala disetiap levelnya [5].

1. Algoritma Piramida Level 1

Transformasi awal ini bertujuan untuk mengurangi data runtun waktu X menjadi koefisien W_1 dan V_1 yang sama besar. Masing-masing koefisien terdiri dari $\frac{N}{2}$ koefisien Wavelet W_1 dan $\frac{N}{2}$ koefisien skala V_1 . Jika P_1 adalah matriks filter wavelet dan skala level pertama dikalikan data X maka:

$$P_1 X = \begin{bmatrix} W_1 \\ V_1 \end{bmatrix} X = \begin{bmatrix} W_1 X \\ V_1 X \end{bmatrix} = \begin{bmatrix} W_1 \\ V_1 \end{bmatrix}$$

Karena P_1 merupakan matriks ortonormal, maka untuk membentuk X dapat menggunakan persamaan berikut:

$$X = P_1^T \begin{bmatrix} W_1 \\ V_1 \end{bmatrix} = [W_1^T \ V_1^T] \begin{bmatrix} W_1 \\ V_1 \end{bmatrix} = W_1^T W_1 + V_1^T V_1$$

dengan $D_1 = W_1^T W_1$ disebut nilai detail level pertama dan $S_1 = V_1^T V_1$ disebut nilai aproksimasi atau *smooth* level pertama, sehingga $X = D_1 + S_1$ [5].

2. Algoritma Piramida Level Terakhir ($j = J_0$)

Algoritma terus berjalan hingga level terakhir dengan langkah yang sama seperti algoritma sebelumnya, menghasilkan koefisien wavelet dan skala sampai level terakhir yaitu W_{J_0} dan V_{J_0} merupakan dua koefisien TWD terakhir, yaitu:

$$\begin{aligned} X &= W^T W = \sum_{j=1}^J W_j^T W_j + V_{J_0}^T V_{J_0} \\ &= D_1 + S_1 \\ &= D_1 + (D_1 + S_1) \\ &= D_1 + D_2 + (D_3 + S_3) \\ &= D_1 + D_2 + \dots + D_{(J_0)-1} (D_{J_0} + S_{J_0}) \\ &= \sum_{j=1}^{J_0} D_j + S_{J_0} \end{aligned}$$

Sehingga nilai aproksimasi S_j merupakan analisis multiresolusi (MRA) dari X , dengan $j = 1, 2, \dots, J_0$ [5].

ESTIMASI THRESHOLDING

Misalkan data runtun waktu membentuk model $X = A + \varepsilon$ yang akan dilakukan TWD. Notasi A adalah hasil estimasi dari data dan ε adalah residual, maka [6]:

$$W \equiv WX = WA + W\varepsilon \equiv a + e \text{ maka } W_{j,l} = a_{j,l} + e_{j,l}$$

$a_{j,l}$ dan $e_{j,l}$ adalah elemen ke l dari masing-masing $a \equiv WA$ dan $e \equiv W\varepsilon$. Untuk mengestimasi $A^{(t)}$ mengikuti pola persamaan analisis multiresolusi maka diperoleh:

$$A^{(t)} = W^T \cdot W^{(t)} = \sum_{j=1}^J W_j^T \cdot W_j^{(t)} + V_j^T \cdot V_j^{(t)}$$

Persamaan tersebut menyatakan pendefinisian koefisien dari detail $F_j^{(t)}$ dan koefisien aproksimasi $G_j^{(t)}$ dengan $F_j^{(t)} \equiv \sum_{j=1}^J W_j^T \cdot W_j^{(t)}$ dan $G_j^{(t)} \equiv \sum_{j=1}^J V_j^T \cdot V_j^{(t)}$, maka dapat dituliskan:

$$A^{(t)} = \sum_{j=1}^J F_j^{(t)} + G_j^{(t)}$$

Tingkat kelulusan estimasi ditentukan oleh pemilihan fungsi wavelet, jenis fungsi *thresholding*, level resolusi dan parameter *threshold*, yang paling dominan ditentukan parameter *threshold* yang optimal [6].

Sehingga langkah-langkah *thresholding* untuk mengestimasi A terdiri dari tiga langkah dasar yaitu [6]:

1. Menghitung koefisien wavelet melalui TWD, yaitu $W = WX$.
2. Membentuk koefisien *thresholding* $W^{(t)}$, dilakukan sesuai fungsi yang diinginkan (fungsi *soft* atau *hard thresholding*).
3. Mengestimasi A melalui $A^{(t)} = W^T \cdot W^{(t)}$ atau invers dari koefisien DWT yang telah di-*thresholding*.

FUNGSI THRESHOLDING

Pembentukan koefisien *thresholding* dapat dilakukan dengan menggunakan fungsi *thresholding* yang sesuai. Fungsi *thresholding* tersebut ada dua jenis yaitu fungsi *soft thresholding* dan fungsi *hard thresholding* [7]:

1. *Hard Thresholding*

Fungsi *hard thresholding* dinyatakan sebagai berikut:

$$H(x) = \begin{cases} |x|, & x \geq \lambda \\ 0, & x \text{ yang lainnya} \end{cases}$$

2. *Soft Thresholding*

Fungsi *soft thresholding* dinyatakan sebagai berikut:

$$S(x) = \begin{cases} x - \lambda, & x > \lambda \\ 0, & x \leq \lambda \\ x + \lambda, & x < -\lambda \end{cases}$$

PARAMETER THRESHOLDING

Ada dua kategori dalam pemilihan parameter yaitu memilih suatu nilai *threshold* yang digunakan untuk semua level resolusi yang disebut *global thresholding* dan memilih suatu nilai *threshold* untuk setiap level resolusi yang disebut juga *level-dependent thresholding*. Parameter yang termasuk dalam kategori *global thresholding* yaitu *minimax threshold* sedangkan parameter yang termasuk dalam *level-dependent thresholding* adalah *adaptive threshold* [7].

1. *Minimax Thresholding*

Minimax threshold dapat digunakan untuk mendapatkan hasil optimal baik dengan fungsi *soft thresholding* atau fungsi *hard thresholding*. Nilai *minimax threshold* (λ^M), dengan N menunjukkan jumlah data dan λ^M merupakan nilai *threshold* yang di lihat pada Tabel 1 sebagai berikut [7]:

Tabel 1. Nilai *Minimax Threshold*

N	λ^M	N	λ^M
2	0	512	2,048
4	0	1024	2,232
8	0	2048	2,414
64	1,474	4096	2,594
128	1,669	8192	2,773
256	1,860	16384	2952

2. *Adaptive Thresholding*

Adaptive threshold yang mensyaratkan bahwa residual dari estimasi tidak berdistribusi *white noise* dan hanya digunakan dengan fungsi *soft thresholding*. Pemilihan *threshold* ini dengan prinsip untuk meminimalkan *Stein Unbiased Risk Estimator* (SURE) di setiap level resolusinya. Jika diketahui $W_{j,l}$ merupakan himpunan koefisien *detail* dari transformasi wavelet dengan jumlah anggota koefisien adalah L maka *adaptive threshold* didefinisikan sebagai berikut [8]:

$$\lambda^A = \arg \min_{\lambda \geq 0} SURE (W_{j,l} : \lambda)$$

dengan,

$$SURE (W_{j,l} : \lambda) = L - 2 \cdot \# \{l: |W_{j,l}| \leq \lambda\} + \sum_{l=1}^L (|W_{j,l}| \wedge \lambda)^2$$

Keterangan:

L = jumlah koefisien wavelet

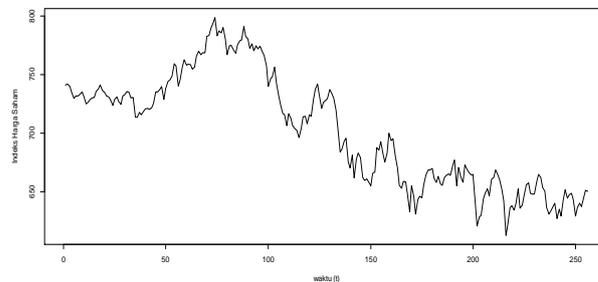
λ = parameter *threshold*

$W_{j,l}$ = koefisien wavelet

$\#$ = banyaknya komponen ke- l

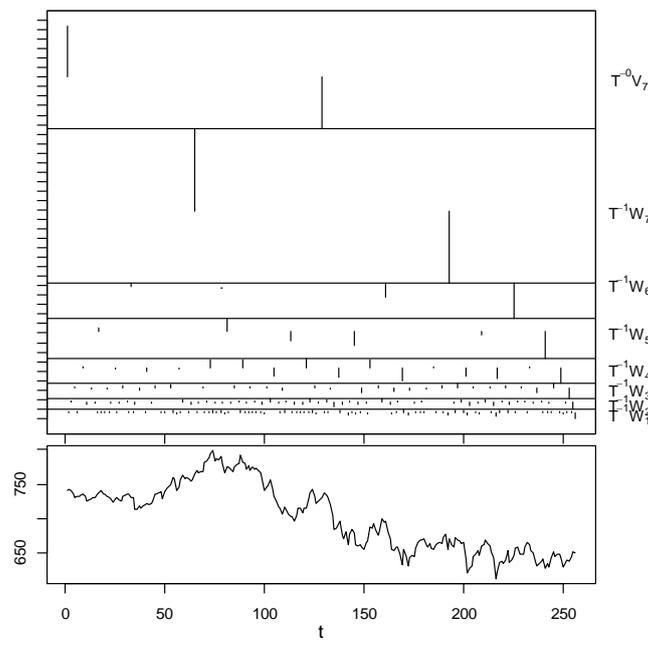
STUDI KASUS

Data yang digunakan yaitu data penutupan harga saham *Jakarta Islamic Index (JII)* pada tanggal 13 Oktober 2017 sampai dengan 1 November 2018 yang diperoleh dari www.yahoo.finance. Gambar 1 merupakan gambaran data yang digunakan pada penelitian ini.



Gambar 1. Grafik Harga Saham JII

Selanjutnya, langkah kedua dalam melakukan prediksi ialah menghitung banyaknya koefisien Wavelet dan koefisien skala disetiap level dengan bantuan *software R*. Berdasarkan jumlah data runtun waktu sebanyak 256, maka proses TWD menggunakan filter skala Daubechies dan filter Wavelet Daubechies menghasilkan 7 level, sehingga dapat dilihat pada Gambar 2 sebagai berikut:



Gambar 2. DWT dari data harga saham JII

Pada level pertama sebanyak 128 koefisien TWD, pada level kedua sebanyak 64 koefisien TWD, pada level ketiga sebanyak 32 koefisien TWD, pada level keempat sebanyak 16 koefisien TWD, pada level kelima sebanyak 8 koefisien TWD, pada level keenam sebanyak 4 koefisien TWD, dan pada level ketujuh sebanyak 2 koefisien TWD. Kemudian akan dilakukan *estimasi thresholding*.

Estimasi data harga saham JII menggunakan transformasi wavelet diskrit Daubechies dengan filter Daubechies 4 (D4), fungsi *soft* dan *hard thresholding* dan dua parameter *threshold* (λ) yaitu parameter *minimax* dan parameter *adaptive* sebagai berikut:

1. Estimasi menggunakan parameter *minimax* dengan nilai $\lambda^M = 1,860$ dan fungsi *soft thresholding* didapatkan model terbaik pada level resolusi pertama dengan nilai MAPE sebesar 0,3495516%
2. Estimasi menggunakan parameter *minimax* dengan nilai $\lambda^M = 1,860$ dan fungsi *hard thresholding* didapatkan model terbaik pada level resolusi pertama dengan nilai MAPE sebesar 0,346109%.

- Estimasi dengan menggunakan parameter *adaptive* dan fungsi *soft thresholding* didapatkan model terbaik pada level resolusi kedua dengan nilai 0,2205571 dan MAPE sebesar 0,2848345%

Dari ketiga hasil analisis tersebut dapat disimpulkan bahwa nilai MAPE hasil analisis dengan fungsi *soft thresholding* dan parameter *adaptive* pada level resolusi kedua adalah yang paling terkecil. Oleh karena itu estimasi dengan fungsi *soft thresholding* dan parameter *adaptive* merupakan model terbaik.

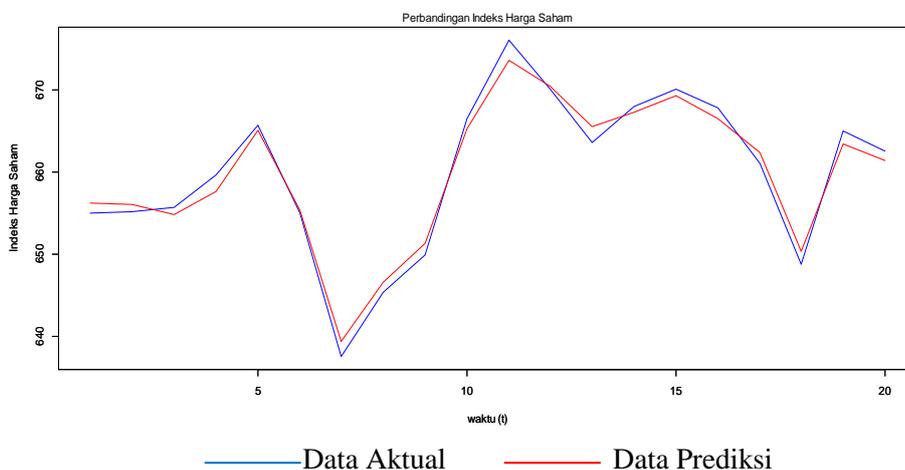
PREDIKSI HARGA SAHAM JAKARTA ISLAMIC INDEX (JII)

Berdasarkan hasil analisis dengan fungsi *soft thresholding* dan parameter *adaptive* pada level resolusi kedua, maka dilakukan prediksi terhadap nilai indeks harga saham harian *Jakarta Islamic Index* (JII). Hasil prediksi dapat dilihat pada Tabel 2.

Tabel 2. Perbandingan nilai indeks harga saham JII

Date	Aktual	Prediksi
02 November 2018	655	656,2214
05 November 2018	655,210022	656,0768
06 November 2018	655.75	654,8378
07 November 2018	659,690002	657,6835
08 November 2018	665,710022	665,1399
09 November 2018	655	655,3889
12 November 2018	637,580017	639,4385
13 November 2018	645,380005	646,6246
14 November 2018	649,919983	651,3111
15 November 2018	666,530029	665,3261
16 November 2018	676,090027	673,6275
19 November 2018	670,090027	670,4899
21 November 2018	663,612976	665,5532
22 November 2018	668,030029	667,3304
23 November 2018	670,130005	669,3253
26 November 2018	667,799988	666,5276
27 November 2018	661,080017	662,4131
28 November 2018	648,799988	650,3775
29 November 2018	665,059998	663,4728
30 November 2018	662., 90027	661,4526

Gambar 3 menunjukkan hasil perbandingan pergerakan harga saham JII menggunakan transformasi wavelet diskrit Daubechies.



Gambar 3. Grafik Data Aktual dan Data Prediksi JII

Pada Gambar 3 terlihat bahwa pola pergerakan harga saham prediksi saham dari tanggal 02 November 2018 sampai dengan 30 November 2018 menggunakan transformasi wavelet diskrit Daubechies mengikuti pergerakan harga saham yang sebenarnya. Dari hasil prediksi diperoleh nilai MAPE (*Mean Absolute Percentage Error*) sebesar 0,188662%. Dapat disimpulkan data prediksi hampir mendekati data aktual.

KESIMPULAN

Berdasarkan hasil dari penelitian diperoleh beberapa kesimpulan sebagai berikut:

1. Transformasi wavelet diskrit digunakan untuk merekonstruksi ulang data runtun waktu X ke dalam bentuk koefisien wavelet, dengan menggunakan filter wavelet Daubechies untuk mendapatkan koefisien transformasi wavelet diskrit. Kemudian, koefisien transformasi wavelet diskrit *thresholding* diestimasi menggunakan estimasi *thresholding*. Hal yang paling berpengaruh dalam proses estimasi adalah pemilihan fungsi *thresholding* dan pemilihan parameter *threshold*.
2. Berdasarkan grafik prediksi harga saham JII menggunakan transformasi wavelet diskrit Daubechies menunjukkan bahwa data prediksi hampir mendekati data aktual dengan nilai MAPE (*Mean Absolute Percentage Error*) sebesar 0,188662%.

SARAN

Penelitian ini membahas tentang Transformasi Wavelet Diskrit yang mempunyai syarat jumlah data $N = 2^j$, disarankan peneliti selanjutnya menggunakan metode wavelet lainnya seperti *Maximal Overlap Discret wavelet Transform* (MODWT).

DAFTAR PUSTAKA

- [1]. Joni, F. *Prediksi Data Time Series Menggunakan Transformasi Wavelet Diskrit*, Institut Teknologi Sepuluh November, Program Studi Magister Jurusan Matematika, Surabaya; 2006.
- [2]. Suyomurti, Wiku. *Supercerdas Inverstasi Syariah*. Jakarta: Qultum Media; 2011.
- [3]. Closing Price [Internet]. 2018. [Update 2018 Nov 1; cited 2018 Nov 5]. Available from: <http://www.yahoofinance.com>.
- [4]. Daubechies I. *Ten Lectures on Wavelets*. Phildelpia, Capital City Press; 1992.
- [5]. Lestari, V. N. Transformasi Wavelet Diskrit untuk Data Time Series. *Prosiding Seminar Nasional*; 2015: 6(1): 163-170.
- [6]. Wibowo, Y. A., Suparti, dan Tarno. Analisis Runtun Waktu Menggunakan Metode Wavelet Thresholding. *Jurnal Gaussian*. 2012; 1(1): 249-258.
- [7]. Donoho, D. L. And Johnstone, I. M. Ideal Spatial by Wavelet Shrinkage. *Biometrika*. 1994; 81: 425-455.
- [8]. Donoho, D. L. And Johnstone, I. M. Adapting to Unknown Smoothness via Wavelet Shrinkage. *Journal of the American Statistical Association*. 1995; (90): 1200-1224.

SARI SETIA NINGRUM : Jurusan Matematika FMIPA UNTAN, Pontianak,
setianingrumsari@gmail.com

HELMI : Jurusan Matematika FMIPA UNTAN, Pontianak,
helmi132205@yahoo.co.id

FRANSISKUS FRAN : Jurusan Matematika FMIPA UNTAN, Pontianak,
fransiskusfran@math.untan.ac.id