

Peramalan Data Runtun Waktu Menggunakan Metode Wavelet-VAR

(Forecasting Time Series Data Using the Wavelet-VAR Method)

Siti Nur Azizah^{1*}, Julan Hernadi²

Matematika, Universitas Ahmad Dahlan, Jalan Ring Road Selatan, Tamanan, Bantul, Daerah Istimewa Yogyakarta, 55191

E-mail: sitnurazizah271@gmail.com

* Corresponding Author

ARTICLE INFO

Kata Kunci

Trnsformasi Wavelet
Vektor Autoregressive
Denoising

Keywords

Wavelet Transformation
Vector Autoregressive
Denoising

ABSTRACT

Peramalan adalah kegiatan meramalkan kejadian yang akan datang berdasarkan data dari kejadian sebelumnya. Data yang digunakan dalam penelitian ini adalah data deret waktu. Penelitian ini mengembangkan metode peramalan yang menggabungkan penggunaan wavelet dalam vector autoregressive (VAR). Wavelet digunakan sebagai alat denoising sebelum dimasukkan ke dalam persamaan regresi menggunakan vektor autoregresif. Metode ini disebut metode Wavelet-VAR. Dalam implementasinya, data deret waktu ditransformasikan menggunakan transformasi wavelet diskrit (DWT) untuk mendapatkan koefisien perkiraan dan koefisien detail. Selanjutnya noise yang terdapat pada koefisien detail dihilangkan dengan menggunakan metode thresholding tertentu. Melalui inversi transformasi wavelet diskrit (IDWT), data baru bebas noise diperoleh. Selanjutnya data bersih ini digunakan dalam peramalan dengan metode vector autoregressive. Dalam implementasinya, diterapkan data curah hujan di Kabupaten Sleman mulai Desember 2019 hingga April 2020 yang diperoleh dari situs resmi Badan Meteorologi, Klimatologi, dan Geofisika (BMKG). Untuk mengukur kualitas peramalan digunakan mean square error (MSE). Metode Wavelet-VAR menghasilkan MSE 0,354 sedangkan metode VAR menghasilkan MSE 0,838. Dalam hal ini, metode Wavelet-VAR lebih baik daripada metode VAR.

Forecasting is the activity of predicting future events based on data from previous events. The data used in this research is time-series data. This study develops a forecasting method that combines the use of wavelets in vector autoregressive (VAR). Wavelets are used as a denoising tool before being built into the regression equation using vector autoregressive. This method is called the Wavelet-VAR method. In its implementation, the time series data is transformed using a discrete wavelet transform (DWT) to obtain the approximate coefficients and the detail coefficients. Furthermore, the noise contained in the detail coefficient is removed by using certain thresholding methods. Through inverse the discrete wavelet transform (IDWT), the new data of noise-free is obtained. Furthermore, this clean data is used in forecasting by vector autoregressive method. In the implementation, it's applied to rainfall data in Sleman Regency from December 2019 to April 2020 which was obtained from the official website of the Meteorology, Climatology, and Geophysics Agency (BMKG). To measure the quality of forecasting quality, the mean square error (MSE) is used. The Wavelet-VAR method produces MSE 0.354, while the VAR method produces MSE 0.838. In this case, the Wavelet-VAR method is better than the VAR method.

This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.



PENDAHULUAN

Permasalahan yang dialami dalam kehidupan sehari-hari dapat dimodelkan kedalam bentuk matematika atau sering disebut dengan permodelan matematika. Salah satu penggunaan model matematika adalah untuk peramalan suatu peristiwa. Peramalan merupakan kegiatan memperkirakan kejadian dimasa yang akan datang berdasarkan data dari kejadian-kejadian pada masa lalu [1]. Misalnya, untuk memprediksi harga saham, level curah hujan, tinggi gelombang serta yang lainnya.

Data yang digunakan untuk peramalan yaitu berupa data runtun waktu (*time series*) yang merupakan himpunan pengamatan yang dibangun secara berurutan berdasarkan waktu pengumpulannya. Syarat yang harus dipenuhi dalam analisis runtun waktu yaitu data harus stasioner. Suatu data dikatakan stasioner apabila rata-rata dan varian dari variabel-variabel tersebut seluruhnya tidak dipengaruhi oleh waktu atau dengan kata lain konstan. Analisis data deret waktu dapat dihitung menggunakan beberapa metode salah satunya adalah dengan metode analisis domain waktu seperti *Vector Autoregressive* (VAR) dan juga dapat menggunakan metode analisis domain frekuensi seperti wavelet.

Wavelet sendiri merupakan sebuah nama untuk gelombang kecil yang naik dan turun pada periode waktu tertentu [2]. Wavelet juga mempunyai peranan penting dan memiliki dampak yang substansial dalam tiga bidang aplikasi umum, yaitu wavelet berperan dalam pemrosesan sinyal, analisis gambar, dan kompresi data [3]. Fungsi Wavelet merupakan fungsi dekomposisi dari wavelet ayah dan wavelet ibu. Wavelet Ayah mempunyai sifat *Smooth* sedangkan Wavelet Ibu mempunyai sifat detail yang mengakibatkan data dapat dipisahkan dalam komponen yang berbeda, sehingga dapat menghasilkan estimasi yang lebih mulus dan dapat mengurangi gangguan atau *noise*.

Pada penelitian ini akan dilakukan peramalan data runtun waktu dengan menggunakan Metode Wavelet-VAR. Metode Wavelet digunakan untuk menghilangkan noise pada data yang kemudian dilanjutkan dengan metode *Vector Autoregressive* (VAR) untuk peramalan serta data yang akan digunakan yaitu data curah hujan dan kecepatan angin. Curah hujan merupakan ketinggian air yang terkumpul dalam tempat yang datar, tidak menguap, tidak meresap serta tidak mengalir. Informasi data curah hujan sangat berguna dalam berbagai bidang diantaranya perairan, perhubungan, dan pertanian. Besarnya curah hujan yang terjadi tidak dapat ditentukan secara pasti, akan tetapi dapat di prediksi atau diperkirakan. Peramalan dapat membantu permasalahan yang akan timbul, seperti kekurangan air ataupun kekeringan. Secara umum manfaat informasi data curah hujan yaitu untuk meningkatkan kewaspadaan terhadap akibat negatif yang dapat ditimbulkan oleh curah hujan, sehingga dapat mengantisipasi jika terjadi bencana.

METODE

1. Wavelet

Wavelet adalah sebuah nama untuk gelombang kecil (*small wave*) yang terkonsentrasi dalam waktu tertentu dan naik turun pada periode tertentu. Wavelet memiliki karakteristik jika fungsinya diintegrasikan pada interval $(-\infty, \infty)$ hasilnya nol dan integral dari fungsi kuadratnya sama dengan 1 [4][5], atau dapat dikatakan:

$$\int_{-\infty}^{\infty} \psi(x) dx = 0 \quad \text{dan} \quad \int_{-\infty}^{\infty} \psi^2(x) dx = 1$$

Pada umumnya ψ digunakan sebagai simbol wavelet ibu dan φ digunakan sebagai simbol wavelet ayah. Wavelet ayah juga sering disebut dengan fungsi skala sedangkan wavelet ibu disebut juga fungsi wavelet. wavelet ayah dan wavelet ibu memiliki sifat sebagai berikut:

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

Dengan gabungan proses dilatasi atau penyekatan dan proses translasi atau pergeseran, wavelet ayah (φ) dan wavelet ibu (ψ) menghasilkan sebuah keluarga wavelet, yaitu:

$$\varphi_{j,k}(x) = (2^j)^{\frac{1}{2}} \varphi(2^j x - k) \quad \text{dan} \quad \psi_{j,k}(x) = (2^j)^{\frac{1}{2}} \psi(2^j x - k)$$

Dari persamaan diatas menghasilkan beberapa keluarga wavelet yang memiliki berbagai karakter dan siat yang berbeda-beda. Contoh keluarga wavelet diantaranya adalah Wavelet Haar, Daubechies, Symmlets, Coiflet, dan lain sebagainya.

2. Filter Wavelet dan Skala

Ada dua jenis filter pada transformasi wavelet yaitu filter wavelet (filter detail) dinotasikan dengan h dan filter skala yang dinotasikan dengan g serta panjang suatu filter dinotasikan dengan L . Filter skala merupakan filter yang diperoleh dari pergeseran-pergeseran wavelet ayah serta filter wavelet merupakan filter yang diperoleh dari penyekalaan dan pergeseran wavelet ibu. Fungsi skala $\varphi(x)$ atau wavelet ayah yang mengalami peregangan dan pergeseran, dinotasikan dengan:

$$\varphi(x) = \sqrt{2} \sum_{l=0}^{L-1} g_l \varphi(2x - k)$$

dimana fungsi $\varphi(2x - k)$ adalah fungsi skala dari $\varphi(x)$ yang mengalami pergeseran sepanjang k dengan koefisien filter skala g_l , sedangkan fungsi wavelet $\psi(x)$ atau wavelet ibu didefinisikan sebagai:

$$\psi(x) = \sqrt{2} \sum_{l=0}^{L-1} (-1)^l h_l \varphi(2x - k)$$

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

$$\begin{aligned} \sum_{l=0}^{L-1} g_l &= \sqrt{2} \\ \sum_{l=0}^{L-1} g_l^2 &= 1 \end{aligned} \tag{2.1}$$

serta filter wavelet harus memenuhi kondisi dasar sebagai berikut[4]:

$$\begin{aligned} \sum_{l=0}^{L-1} h_l &= 0 \\ \sum_{l=0}^{L-1} h_l^2 &= 1 \end{aligned} \tag{2.2}$$

3. Wavelet Daubechies

Wavelet Daubechies merupakan salah satu keluarga wavelet orthogonal. Nama Daubechies diambil dari nama penemu wavelet daubechies itu sendiri yakni Ingrid Daubechies. Selain itu, Wavelet ini sering digunakan karena baik untuk kompresi data. Wavelet Daubechies biasanya disimbolkan dengan dbN, dengan N merupakan angka indeks dari 2 sampai 20. Pada penelitian ini digunakan Daubechies 4 atau db4 yaitu dengan panjang bandwidth $L=4$. Filter Wavelet Daubechies (db4) yang digunakan ini dinyatakan dalam bentuk matriks yang memiliki empat koefisien filter skala dan empat koefisien filter wavelet. Berdasarkan syarat yang harus dipenuhi dari persamaan (2.1) dan (2.2) maka diperoleh koefisien filter skala dan filter wavelet sebagai berikut:

$$\begin{aligned} g_0 &= \frac{1 - \sqrt{3}}{4\sqrt{2}}, g_1 = \frac{3 - \sqrt{3}}{4\sqrt{2}}, g_2 = \frac{3 + \sqrt{3}}{4\sqrt{2}}, g_3 = \frac{1 + \sqrt{3}}{4\sqrt{2}} \\ h_0 &= \frac{-1 - \sqrt{3}}{4\sqrt{2}}, h_1 = \frac{3 + \sqrt{3}}{4\sqrt{2}}, h_2 = \frac{-3 + \sqrt{3}}{4\sqrt{2}}, h_3 = \frac{1 - \sqrt{3}}{4\sqrt{2}} \end{aligned}$$

4. Transformasi Wavelet Diskrit

Transformasi wavelet adalah fungsi transfer (*transform*) yang digunakan untuk menguraikan data atau fungsi atau operator menjadi komponen frekuensi yang berbeda-beda dan kemudian mempelajarinya dengan resolusi yang disesuaikan dengan skalanya [6]. *Discret wavelet transform* (DWT) memiliki sifat transformasi orthonormal linear yang digunakan dalam analisis runtun waktu $\{X_t\}$ dengan panjang $N = 2^J$, dengan J adalah integer. Dari data runtun waktu X dapat dilakukan pembentukan koefisien DWT yang dihasilkan dari perkalian matriks filter dengan data runtun waktu X sebagai berikut:

$$\omega X = \begin{bmatrix} \omega_1 \\ \omega_2 \\ \vdots \\ \omega_N \end{bmatrix} X = \begin{bmatrix} \omega_1 X \\ \omega_2 X \\ \vdots \\ \omega_N X \end{bmatrix} = \begin{bmatrix} W_1 \\ W_2 \\ \vdots \\ W_N \end{bmatrix} = W$$

dengan:

W = matrik dengan ukuran $N \times 1$ dengan elemen ke- n adalah koefisien DWT ke- n

X = data runtun waktu berbentuk matriks dengan ukuran $N \times 1$

N = banyaknya data

ω = matriks filter berukuran $N \times N$

Matriks transformasi w dibentuk dari translasi dan dilatasi filter g dan h yang diberikan, dengan tetap mempertahankan sifat-sifat filter pada setiap operasi translasi dan dilatasi. Sifat-sifat filter wavelet terdapat pada persamaan (2.1) dan (2.2). Pembentukan wavelet dari X yang diasumsikan memiliki sifat orthonormal. Sifat orthonormal mengakibatkan inverse dari suatu matriks sama dengan transformasi dari matriks tersebut, maka sifat orthonormal dapat membangun ulang X sebagai berikut:

$$X = w^{-1}W = w^T W$$

Pada dasarnya, DWT mengijinkan penguraian/dekomposisi ke dalam jumlah elemen aproksimasi (skala-tinggi, komponen frekuensi rendah) dan elemen detail (skala-rendah, komponen frekuensi tinggi). Hasil dari proses dekomposisi atau penguraian tersebut dapat digunakan untuk merekonstruksi ulang data asal. Kemudian dengan menggunakan invers dari DWT dapat digunakan untuk mengembalikan data hasil transformasi ke data asli tanpa menghilangkan informasi yang ada.

5. Fungsi dan Parameter Thresholding

Koefisien thresholding dapat dibentuk dengan menggunakan fungsi Thresholding yang sesuai. Terdapat dua jenis fungsi *thresholding* yaitu fungsi *thresholding* keras (*Hard Thresholding*) dan fungsi *thresholding* lunak (*Soft Thresholding*). Menurut Donoho, dkk [7] fungsi *thresholding* dapat didefinisikan sebagai berikut:

- a. Hard Thresholding

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

- b. Soft Thresholding

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

dengan x sebagai data time series dan λ merupakan koefisien atau nilai *thresholding*. Nilai *threshold* ini digunakan untuk menentukan sebuah nilai x apakah termasuk kedalam sebuah sinyal atau noise. Salah

satu yang mempengaruhi tingkat kemulusan estimator yaitu berdasarkan pemilihan parameter *threshold*. Jika ingin mendapatkan estimasi yang optimal maka harus memilih parameter yang juga optimal. Parameter yang biasa digunakan untuk mengestimasi yaitu *Global Thresholding*. Menurut Odgen [3] terdapat dua pilihan *Global Threshold* yang bergantung pada banyaknya data pengamatan x yaitu:

a. *Minimax Threshold*

Donoho, dkk[7] telah menentukan nilai *Minimax Threshold* λ^M dengan N menunjukkan jumlah data dan λ^M merupakan nilai *threshold* yang ditunjukkan sebagai berikut :

Tabel 1 Nilai *Minimax Thresholding*

N	λ^M	N	λ^M
2	0	512	2,084
4	0	1024	2,232
8	0	2048	2,414
64	1,474	4096	2,594
128	1,5031	8192	2,773
256	1,860	16384	2,952

b. *Universal Threshold* (λ^u)

Menurut Donoho, dkk [7] parameter *Universal Threshold* yaitu:

$$\lambda^u = \sigma \sqrt{2 \log(N)}$$

σ harus diestimasi dari data melalui fungsi *Median Deviasi Absolut* yaitu[8]:

$$\hat{\sigma} = \frac{M}{0,6745}$$

Dimana $M = \text{median} \{|x_k - x_m|, k = 0, 1, \dots, N - 1\}$ dan x_m median dari data runtun waktu.

6. Vector Autoregressive

Vector Autoregressive (VAR) menjelaskan bahwa setiap variabel yang ada dalam model tergantung pada pergerakan masalah dari variabel itu sendiri dan juga pergerakan masalah seluruh variabel lainnya yang ada dalam model. Pada analisis VAR semua variabel dianggap sebagai variabel endogen (variabel terikat). Misal Y_t adalah deret waktu, bentuk umum model VAR lag p adalah sebagai berikut[9]:

$$Y_t = \alpha_0 + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \varepsilon_t$$

dengan:

Y_t = Vektor berukuran $N \times 1$ yang berisi n data yang digunakan dalam model VAR pada waktu t

Y_{t-1} = Vektor berukuran $N \times 1$ yang berisi n data yang digunakan dalam model VAR pada waktu $t - i$, $i = 1, 2, \dots, p$.

α = Vektor intersep berukuran $N \times 1$

β_i = matriks koefisien berukuran $N \times 1$

p = lag VAR

t = waktu pengamatan

7. Stasioneritas

Asumsi yang harus dipenuhi dari data *time series* agar terbentuk model VAR adalah data harus stasioner. Data *time series* dikatakan stasioner jika rata-rata dan varian dari variabel-variabel tersebut seluruhnya tidak dipengaruhi oleh waktu atau dengan kata lain konstan[1]. Ada beberapa cara yang dapat dilakukan untuk mengatasi ketidakstasioneran. Jika data tersebut tidak stasioner dalam rata-rata maka

dilakukan *differencing* dan untuk data yang tidak stasioner dalam variansi maka dilakukan transformasi *Box-Cox*.

8. Uji Dickey Fuller

Pengujian stasioneritas terhadap rata-rata dapat dilakukan dengan Uji Akar Unit Dickey Fuller (DF). Hipotesis untuk Uji DF adalah sebagai berikut:

$H_0: \delta = 0$ (Data tidak stasioner)

$H_0: \delta < 0$ (Data stasioner)

statistik uji dapat ditulis sebagai berikut:

$$t = \frac{\hat{\delta}}{Se(\hat{\delta})}$$

Dengan

$$\hat{\delta} = \frac{\sum_{t=1}^n Z_{t-1} Z_t}{\sum_{t=1}^n Z_{t-1}^2}$$

dan

$$Se(\hat{\delta}) = \sqrt{\frac{\hat{\sigma}_a^2}{\sum_{t=1}^n Z_{t-1}^2}},$$

dimana

$$\hat{\sigma}_a^2 = \frac{\sum_{t=1}^n (Z_t - \hat{\delta} Z_{t-1})^2}{n - 1}$$

dengan:

$\hat{\delta}$ = nilai dugaan parameter *Autoregressive*

$Se(\hat{\delta})$ = Standar Error dari $\hat{\delta}$

Kaidah pengambilan keputusan, H_0 diterima jika statistik uji $t_{hitung} < t_{\alpha, n-1}$ atau dapat dikatakan bahwa data tidak stasioner terhadap rata-rata

9. Penentuan Lag Optimal

Penentuan orde VAR dilakukan dengan menentukan panjang lag yang diperoleh dari nilai *Akaike Information Criterion* dengan rumus sebagai berikut[10]:

$$AIC = \ln(\det(\Sigma_p)) + \frac{2M^2 p}{T}$$

dengan :

Σ_p = Matriks Varian Kovarian dari residual model dengan lag p

M = Banyaknya Variabel

p = Panjang Lag

T = Banyaknya data

10. Mean Square Error (MSE)

Pengukuran kualitas sinyal yang paling sederhana adalah *Mean Squared Error (MSE)*. *MSE* merupakan ukuriran kontrol kualitas yang digunakan untuk mengetahui kualitas dari suatu proses. *MSE* menghitung seberapa besar pergeseran data antara sinyal sumber dan sinyal hasil keluaran, dimana sinyal sumber dan sinyal hasil keluaran memiliki ukuran yang sama. Nilai *MSE* yang baik adalah nilai yang mendekati nol ($MSE \approx 0$)

Rumus dari perhitungan *MSE* adalah [11] :

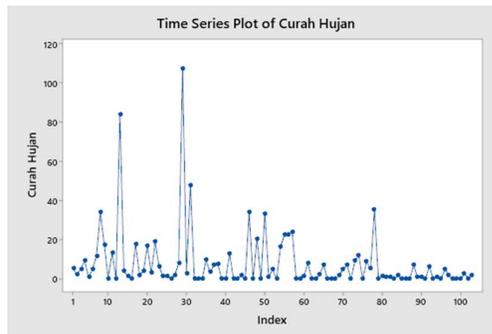
$$MSE = \frac{1}{N} \sum_{n=1}^N (Y_t - \hat{Y}_t)^2$$

Dengan:

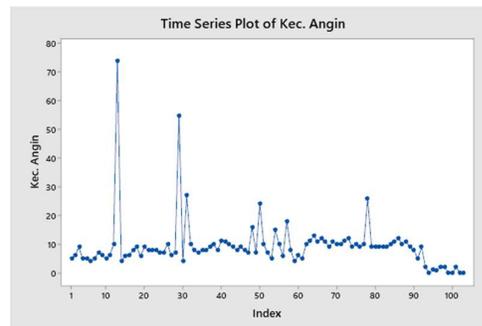
- N = Banyaknya data
- Y_t = Data actual dari observasi
- \hat{Y}_t = Data estimasi dari model VAR

HASIL DAN PEMBAHASAN

Data yang digunakan yaitu data curah hujan dan kecepatan angin yang sudah ditambah dengan *noise*. Setelah data bersih dari noise, langkah awal dalam peramalan menggunakan VAR yaitu dengan membuat plot untuk mengetahui gerakan perubahan curah hujan. Berikut adalah plot time series dari data curah hujan dan Kecepatan angin.



Gambar 1. Plot Data Curah Hujan



Gambar 2. Plot Data Kecepatan Angin

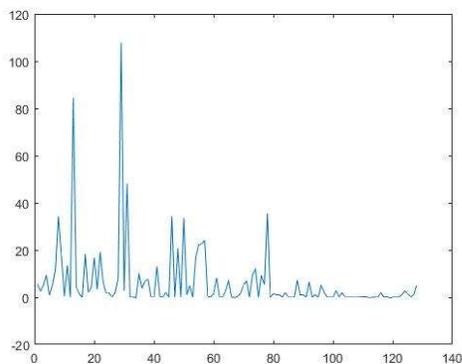
Diketahui curah hujan maksimum dan Kecepatan angin maksimum adalah 107.5655 dan 74.0853, serta rata-rata curah hujan sebesar 6.3846 dan rata-rata kecepatan angin sebesar 7.9457. Pada Gambar 4.1 terlihat bahwa data curah hujan dan kecepatan angin mengalami kenaikan dan penurunan data dari hari ke hari sehingga data tersebut tidak stastoner.

Denoising sinyal dengan filter wavelet Daubechies4 dilakukan menggunakan 4 jenis fungsi Thresholding yang kemudian akan dipilih nilai thresholding yang menghasilkan jumlah error paling kecil antara data asli dan data hasil denoising. Setelah dilakukan penelitian diperoleh nilai error untuk masing-masing nilai threshold pada Tabel 2.

Tabel 2 Error Data Setelah Thresholding

Universal Threshold Hard Thresholding	Universal Threshold Soft Thresholding	Minimax Threshold Hard Thresholding	Minimax Threshold Soft Thresholding
9.3425	33.2169	29.0757	95.8576

Pada Tabel 2 dapat dilihat bahwa fungsi threshold yang menghasilkan jumlah error paling kecil yaitu menggunakan *Universal Threshold* dengan fungsi *Hard Thresholding*. Plot data setelah denoising dapat dilihat pada Gambar 2.

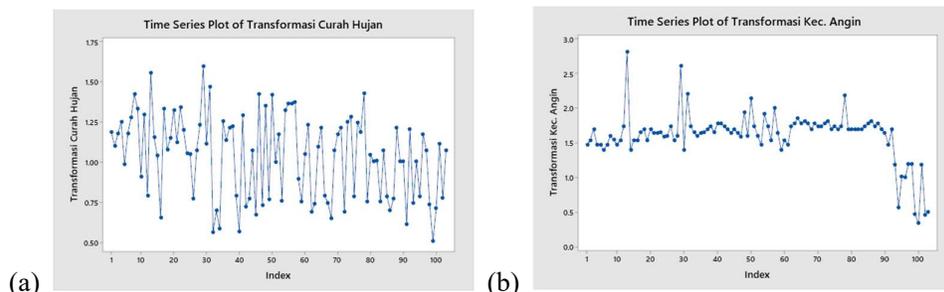


Gambar 2 Hasil Denoising menggunakan Filter Daubechies 4 menggunakan Universal Threshold dengan fungsi hard thresholding

Langkah awal dalam menstasionerkan variansi dengan melakukan transformasi data menggunakan *software* minitab. Pada tahap ini diperoleh nilai $\lambda = 0,1$ untuk data curah hujan dan $\lambda = 0,24$ untuk data kecepatan angin . Maka langkah selanjutnya melakukan transformasi data ke dalam bentuk $X_t^{0,1}$ untuk data curah hujan dan $X_t^{0,24}$ untuk data kecepatan angin. Setelah dilakukan transformasi diperoleh data yang sudah stasioner terhadap variansi. Kemudian, Untuk mengetahui apakah data runtun waktu hasil transformasi telah stasioner terhadap rata-rata maka dilakukan pengujian dengan menggunakan Uji *Dickey Fuller* untuk masing-masing variable.

Tabel 3 Uji Stasioneritas

Variabel	T Hitung	T Tabel	Kesimpulan
Curah Hujan	71.327906	1.983495259	Data Stasioner
kec. Angin	121.868709	1.983495259	Data Stasioner



Gambar 3 Plot Data (a) Curah Hujan (b) Kec.Angin yang sudah stasioner

Penentuan orde model VAR dengan cara menentukan *lag* optimum berdasarkan pemilihan nilai *AIC* terkecil. Nilai *AIC* untuk model Wavelet-VAR ditunjukkan pada Tabel 4 dan nilai *AIC* untuk model VAR ditunjukkan pada Tabel 5.

Tabel 4 Nilai AIC Untuk Model Wavelet-VAR

Lag	AIC	Lag	AIC
1	-5.071	5	-5.175
2	-5.120	6	-5.113
3	-5.249*	7	-5.089
4	-5.206	8	-5.011

Berdasarkan Tabel 4 dapat dilihat bahwa nilai AIC terkecil terletak pada lag 3 dengan nilai -5.249, sehingga dipilih model Wavelet-VAR(3).

Pada tahap estimasi parameter Wavelet-VAR akan dicari estimasi dari parameter. Pada uji sebelumnya diperoleh panjang optimal lag adalah 3 yang terdiri dari 2 variabel sehingga model yang dihasilkan untuk estimasi parameter adalah Wavelet-VAR(3). Adapun persamaan dari model tersebut adalah sebagai berikut:

$$\hat{C}_t = \hat{\alpha}_{10} + \hat{\beta}_{11}C_{t-1} + \hat{\beta}_{12}A_{t-1} + \hat{\beta}_{13}C_{t-2} + \hat{\beta}_{14}A_{t-2} + \hat{\beta}_{15}C_{t-3} + \hat{\beta}_{16}A_{t-3}$$

$$\hat{C}_t = 0,9795 + 0,0162C_{t-1} + 0,0433A_{t-1} + 0,0327C_{t-2} - 0,1238A_{t-2} + 0,1252C_{t-3} - 0,0550A_{t-3}$$

Setelah diperoleh model peramalan Wavelet-VAR yaitu model Wavelet-VAR(3) dengan dua variabel, maka model dapat digunakan untuk peramalan. Data yang digunakan merupakan data *testing* untuk menguji model yang sudah diperoleh dari data *training*. Dalam penelitian ini menggunakan data *testing*. Hasil Peramalan pada 5 hari terakhir sebagai berikut:

Tabel 5 Hasil Peramalan

t	Hasil Peramalan
124	0,9845
125	1,3897
126	1,0578
127	0,6407
128	0,8173

Untuk melihat baik tidaknya suatu peramalan, diperlukan uji eror data asli dengan data peramalan. Uji yang akan digunakan dengan menggunakan MSE sehingga diperoleh nilai error 0.3540.

SIMPULAN

Berdasarkan hasil dan pembahasan dari bab sebelumnya, dapat disimpulkan bahwa:

1. Transformasi wavelet diskrit (TWD) digunakan untuk merekonstruksi ulang data runtun waktu X yang mengandung noise ke dalam bentuk koefisien wavelet dengan menggunakan filter wavelet daubechies4 untuk memperoleh koefisien TWD. Kemudian koefisien TWD tersebut diestimasi dengan menggunakan estimasi *thresholding*. Hal yang paling berpengaruh dalam proses estimasi adalah pemilihan fungsi dan jenis *thresholding* untuk menghasilkan data yang bersih dari noise.
2. Peramalan dengan menggunakan Metode Wavelet-VAR diperoleh nilai MSE sebesar 0.3540 sedangkan peramalan dengan menggunakan metode VAR diperoleh nilai MSE sebesar 0.83859. Berdasarkan perbandingan nilai MSE dari hasil peramalan dengan menggunakan Metode Wavelet-VAR dan Metode VAR dapat disimpulkan bahwa metode Wavelet-VAR lebih efektif untuk diaplikasikan dalam studi kasus peramalan curah hujan di Kabupaten Sleman, DIY.

DAFTAR PUSTAKA

- [1] S. Makridakis, S. C. Wheelwright, and V. E. McGee, "Metode dan aplikasi peramalan," Jakarta: Erlangga, 1999.
- [2] I. Daubechies and B. J. Bates, "Ten lectures on wavelets." Acoustical Society of America, 1993.
- [3] T. Ogden, *Essential wavelets for statistical applications and data analysis*. Springer Science & Business Media, 2012.
- [4] D. B. Percival and A. T. Walden, *Wavelet methods for time series analysis*, vol. 4. Cambridge

- university press, 2000.
- [5] L. Debnath and F. A. Shah, *Wavelet transforms and their applications*. Springer, 2002.
 - [6] D. F. Walnut, *An introduction to wavelet analysis*. Springer Science & Business Media, 2013.
 - [7] D. L. Donoho and J. M. Johnstone, "Ideal spatial adaptation by wavelet shrinkage," *Biometrika*, vol. 81, no. 3, pp. 425–455, 1994.
 - [8] D. Sundararajan, *Discrete wavelet transform: a signal processing approach*. John Wiley & Sons, 2016.
 - [9] D. N. Gujarati, D. C. Porter, and S. Gunasekar, *Basic econometrics*. Tata McGraw-Hill Education, 2012.
 - [10] J. Dinardo, J. Johnston, and J. Johnston, "Econometric methods," *Forth Ed. McGraw-Hill Companies, Inc*, pp. 204–326, 1997.
 - [11] A. Chuang, "Time series analysis: univariate and multivariate methods." Taylor & Francis, 1991.