

PENERAPAN METODE WAVELET NEURO-FUZZY SYSTEM (WNFS) DALAM MEMPREDIKSI HARGA BERAS DUNIA (Studi Kasus: Harga Beras Thailand sebagai Harga Acuan Dunia)

Sri Endah Moelya Artha¹, Hasbi Yasin², Budi Warsito³

^{1,2,3}Departemen Statistika FSM Universitas Diponegoro

seimaartha@gmail.com, hasbiyasin@live.undip.ac.id, budiwrst2@gmail.com

ABSTRACT

Rice trade is one of the food resistance components in terms of its availability. The comprehensive integration between international commodity rice prices and domestic prices encourage the prediction of world rice prices, using the Thai rice price as the world's reference price. In this study, the wavelet neuro-fuzzy system which combines the wavelet transform and the neuro-fuzzy technique has been applied to monthly predict the world rice price. The observed monthly rice price data are decomposed into some sub-series components by maximal overlap discrete wavelet transform (MODWT), and then the appropriate sub-series that have higher correlation to the real data are used as inputs of the neuro-fuzzy model for monthly predicting world rice prices for six months in advance. The neuro-fuzzy model is begun with determining the membership value of each data using Fuzzy C-Means, followed by fuzzy inference procedure of the Sugeno zero-order model. Obtained results showed that the WNFS method can be used to predict the world rice price, with the error value resulted from learning process of MSE 20,69097 and MAPE 0,65584%. While the error measurement results for the six months in advance prediction shows the acquisition of MSE 3610,14847 and MAPE 13,62334%.

Keywords : Prediction of Monthly World Rice Price, Maximal Overlap Discrete Wavelet Transform, Neuro-fuzzy System.

1. PENDAHULUAN

Indonesia merupakan negara yang penduduknya sangat bergantung pada sektor pertanian. Hal ini berkaitan dengan peran dari sektor tersebut yaitu sebagai penyedia bahan pangan. Salah satu komoditas terkait ketahanan pangan yang menjadi bahan pangan pokok utama dan strategis di dunia baik negara maju maupun negara berkembang adalah beras. Beras juga merupakan komoditi yang memiliki arti strategis bagi Indonesia karena komoditi ini merupakan makanan pokok hampir di seluruh wilayah di Indonesia.

Perdagangan beras menjadi salah satu komponen ketahanan pangan dari sisi ketersediaan pangan. Beberapa sifat yang dimiliki oleh pasar beras menunjukkan bahwa pasar beras sangat sensitif terhadap guncangan harga. Indonesia sebagai negara yang bergantung pada komoditas beras, perlu menetapkan suatu pendekatan yang dapat diprediksi untuk memitigasi dampak guncangan harga. Adanya integrasi sepenuhnya antara harga beras komoditas internasional dengan harga domestik menjadi hal yang mendorong dilakukannya prediksi harga beras dunia, dengan harga beras Thailand sebagai harga acuan dunia.

Pada penelitian ini, model *Wavelet Neuro-Fuzzy System* (WNFS) yang mengkombinasikan antara transformasi wavelet dan teknik *neuro-fuzzy* diterapkan untuk memprediksi harga beras dunia secara bulanan. Penggunaan metode ini didasarkan atas tingkat keakuratan dari peramalan atau prediksi yang dihasilkan, selain itu metode WNFS ini mampu menganalisis fungsi yang tidak mulus. Dengan demikian metode WNFS sangat cocok untuk memodelkan data-data yang berfluktuasi.

Data harga beras bulanan yang terobservasi didekomposisikan kedalam beberapa komponen *sub-series* dengan *Maximal Overlap Discrete Wavelet Transform* (MODWT), kemudian *sub-series* yang bersesuaian yang memiliki korelasi yang tinggi dengan data sebenarnya digunakan sebagai input model *neuro-fuzzy* untuk memprediksi harga beras

bulanan pada enam bulan kedepan. Pemilihan komponen *sub-series* yang dominan akan memberikan nilai kesalahan yang tidak terlalu besar pada model (Setiaji, 2014). Model *neuro-fuzzy* diawali dengan penentuan nilai keanggotaan setiap data menggunakan *Fuzzy C-Means*, kemudian dilanjutkan dengan prosedur inferensi *fuzzy* model Sugeno orde-nol.

2. TINJAUAN PUSTAKA

2.1. Integrasi Pasar Domestik dengan Pasar Dunia

Pasar provinsi di Indonesia untuk komoditas-komoditas seperti kedelai, jagung, beras, gula, dan minyak goreng dapat dianggap sangat terintegrasi dengan pasar dunia (The World Bank, 2011). Hal ini ditunjukkan dengan hasil yang diperoleh melalui tiga pengukuran integrasi yang berbeda (The World Bank, 2011):

- a) Perbandingan sederhana terhadap tingkat pertumbuhan harga domestik dan harga dunia. Pengukuran yang dilakukan *The World Bank* menunjukkan bahwa rata-rata perubahan harga domestik sama dengan jumlah rata-rata perubahan harga dunia dan rata-rata perubahan nilai tukar.
- b) Koefisien korelasi antara harga domestik dengan harga dunia
Hasil kajian *The World Bank* tentang korelasi antara harga komoditas domestik dan dunia memperlihatkan korelasi yang signifikan, yaitu dengan korelasi di atas sembilan puluh persen.
- c) Pengujian pergerakan bersama secara sistematis (*systematic co-movement*) dan pangsa kecenderungan jangka panjang bersama dengan menggunakan model koreksi kesalahan (*error corection model*)
Hasil kajian tentang kecenderungan harga memperlihatkan bahwa harga domestik menimbulkan kecenderungan jangka panjang dengan harga dunia atas komoditas-komoditas tersebut.

2.2. Wavelet

Wavelet adalah suatu fungsi matematika yang mempunyai sifat-sifat tertentu di antaranya berosilasi di sekitar nol (seperti fungsi sinus dan cosinus) dan terlokalisasi dalam domain waktu artinya pada saat nilai domain relatif besar, fungsi wavelet akan bernilai nol (Percival dan Walden, 2000). Fungsi wavelet dibedakan atas dua jenis yaitu wavelet ayah (ϕ) dan wavelet ibu (ψ) yang mempunyai sifat yang dapat dilihat pada persamaan (1).

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

Dengan dilatasi diadik dan translasi integer, wavelet ayah dan wavelet ibu melahirkan keluarga wavelet baru yaitu:

$$\phi_{j,k}(x) = 2^{j/2} \phi(2^j x - k) \text{ dan } \psi_{j,k}(x) = 2^{j/2} \psi(2^j x - k) \quad (2)$$

Indeks dilatasi j akan berpengaruh terhadap perubahan *support* dan daerah hasil (*range*) secara berkebalikan, artinya jika *support* menyempit maka *range* melebar. Indeks translasi k berpengaruh terhadap pergeseran posisi wavelet pada sumbu datar tanpa mengubah lebar *support*. *Support* suatu fungsi adalah *closure* dari himpunan titik-titik domain yang memberikan nilai fungsi tidak sama dengan nol (Simatupang dkk., 2014).

Definisi 1

Didefinisikan $f \in L^2[a,b]$ dengan $L^2[a,b] = \left\{ f : \int_a^b f(x)^2 dx < \infty \right\}$. Dua fungsi $f_1, f_2 \in L^2[a,b]$ dikatakan orthogonal jika $\langle f_1, f_2 \rangle = 0$, dengan hasil kali dalam $\langle f_1, f_2 \rangle = \int_a^b f_1(x)f_2(x)dx$ (Ogden, 1997).

Definisi 2

Sebuah barisan fungsi $\{f_j\}$ dikatakan orthonormal jika f_j merupakan pasangan orthogonal dan $\|f_j\| = 1$ untuk semua j dengan $\|f_j\| = \sqrt{\langle f_j, f_j \rangle} = \sqrt{\int_a^b f_j(x)f_j(x)dx}$ (Ogden, 1997).

Contoh wavelet paling sederhana dan memenuhi sifat orthogonal dan orthonormal tersebut adalah wavelet Haar yang dirumuskan pada persamaan (3).

$$\psi(x) = \begin{cases} 1 & 0 \leq x < 0,5 \\ -1 & 0,5 \leq x < 1 \\ 0 & x \text{ yang lain} \end{cases} \quad \text{dan} \quad \phi(x) = \begin{cases} 1 & 0 \leq x < 1 \\ 0 & x \text{ yang lain} \end{cases} \quad (3)$$

2.3. Maximal Overlap Discrete Wavelet Transform (MODWT)

Percival dan Walden (2000) mendefinisikan *Maximal Overlap Discrete Wavelet Transform* (MODWT) sebagai modifikasi dari *Discrete Wavelet Transform* (DWT). Transformasi ini menghasilkan orthogonalitas dari DWT. Pada DWT orthonormal, koefisien wavelet dihitung dengan selisih dari rata-rata terbobot yang tidak saling tumpang tindih (*non-overlapping differences*). Hal ini berbeda dengan MODWT yang memungkinkan perhitungan dari setiap pergeseran interval waktu. Dengan menggunakan MODWT, informasi yang terdapat pada nilai variabilitas dari sinyal dapat diperoleh dengan mempertimbangkan selisih pada setiap skalanya, hal inilah yang disebut dengan *overlapping differences* (Haghpanahan, 2014).

Dengan mendefinisikan \tilde{V} yang merupakan matriks $N \times N$ yang berisikan filter \tilde{g} dan \tilde{W} adalah matriks $N \times N$ yang berisikan filter \tilde{h} . Misalnya untuk *level* pertama didefinisikan \tilde{W}_1 sebagai matriks filter wavelet, sehingga diperoleh:

$$\tilde{W}_1 = \begin{bmatrix} \tilde{h}_0 & 0 & 0 & \dots & 0 & 0 & 0 & \tilde{h}_1 \\ \tilde{h}_1 & \tilde{h}_0 & 0 & \dots & 0 & 0 & 0 & 0 \\ 0 & \tilde{h}_1 & \tilde{h}_0 & \dots & 0 & 0 & 0 & 0 \\ 0 & 0 & \tilde{h}_1 & \dots & 0 & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \dots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & \dots & \tilde{h}_1 & \tilde{h}_0 & 0 & 0 \\ 0 & 0 & 0 & \dots & 0 & \tilde{h}_1 & \tilde{h}_0 & 0 \\ 0 & 0 & 0 & \dots & 0 & 0 & \tilde{h}_1 & \tilde{h}_0 \end{bmatrix} \quad (4)$$

Sedangkan matriks filter skala \tilde{V}_1 strukturnya sama dengan \tilde{W}_1 namun \tilde{h}_i diganti dengan \tilde{g}_i , sehingga langkah pertama dari MODWT dapat dituliskan dalam persamaan (5).

$$\begin{bmatrix} \tilde{W}_1 \\ \tilde{V}_1 \end{bmatrix} = \begin{bmatrix} \tilde{W}_1 \\ \tilde{V}_1 \end{bmatrix} X = \tilde{P}_1 X, \text{ dengan } \tilde{P}_1 = \begin{bmatrix} \tilde{W}_1 \\ \tilde{V}_1 \end{bmatrix} \quad (5)$$

dan \tilde{P}_1^T adalah matriks orthonormal. Dengan demikian untuk merekonstruksi data X dari koefisien MODWT jika dekomposisi dilakukan pada *level* pertama, dapat dilihat pada persamaan (6).

$$X = \tilde{P}_1^{-1} \begin{bmatrix} \tilde{W}_1 \\ \tilde{V}_1 \end{bmatrix} = \tilde{P}_1^T \begin{bmatrix} \tilde{W}_1 \\ \tilde{V}_1 \end{bmatrix} = \begin{bmatrix} \tilde{W}_1 \\ \tilde{V}_1 \end{bmatrix}^T \begin{bmatrix} \tilde{W}_1 \\ \tilde{V}_1 \end{bmatrix} \quad (6)$$

2.4. Filter Wavelet dan Skala

Menurut Percival dan Walden (2000), untuk menjelaskan hubungan filter wavelet dan filter skala antara DWT dengan MODWT, dapat didefinisikan filter wavelet MODWT $\{\tilde{h}_l\}$ terbentuk dari $\tilde{h}_l = h_l/\sqrt{2}$ dan filter skala MODWT $\{\tilde{g}_l\}$ terbentuk dari $\tilde{g}_l = g_l/\sqrt{2}$. Sehingga syarat suatu filter wavelet MODWT harus memenuhi persamaan (7).

$$\sum_{i=0}^{L-1} \tilde{h}_i = 0 \quad \sum_{i=0}^{L-1} \tilde{h}_i^2 = 1/2 \quad \text{dan} \quad \sum_{i=0}^{L-1} \tilde{h}_i \tilde{h}_{i+2m} = 0 \quad (7)$$

dan filter skala harus memenuhi rumus berikut:

$$\sum_{i=0}^{L-1} \tilde{g}_i = 1 \quad \sum_{i=0}^{L-1} \tilde{g}_i^2 = 1/2 \quad \text{dan} \quad \sum_{i=0}^{L-1} \tilde{g}_i \tilde{g}_{i+2m} = 0 \quad (8)$$

dengan $m=1, 2, \dots, (L/2)-1$. Masing-masing filter MODWT memiliki lebar

$$L_j \equiv (2^j - 1)(L - 1) + 1 \quad (9)$$

Dalam hal ini *quadrature mirror relationship* pada DWT juga dapat diterapkan pada MODWT untuk menyatakan keterhubungan antara $\{\tilde{h}_l\}$ dan $\{\tilde{g}_l\}$ (Percival dan Walden, 2000).

$$\tilde{g}_l = (-1)^{l+1} \tilde{h}_{L-1-l} \quad \text{dan} \quad \tilde{h}_l = (-1)^{l+1} \tilde{g}_{L-1-l} \quad (10)$$

Pada filter wavelet Haar $\{\tilde{h}_{j,t} : t = 0, \dots, L_{j-1}\}$ (untuk $j=1, 2, \dots$) dapat dirumuskan:

$$\tilde{h}_{j,t} \equiv \begin{cases} \frac{1}{2^j} & \text{untuk } t = 0, \dots, 2^{j-1} - 1 \\ -\frac{1}{2^j} & \text{untuk } t = 2^{j-1}, \dots, 2^j - 1 \end{cases} \quad (11)$$

dan untuk filter skala $\{\tilde{g}_{j,t} : t = 0, \dots, L_{j-1}\}$ (untuk $j=1, 2, \dots$) dapat dirumuskan:

$$\tilde{g}_{j,t} \equiv \frac{1}{2^j} \quad \text{untuk } t = 0, \dots, 2^j - 1 \quad (12)$$

Secara sederhana, pada persamaan (13) dan (14) dekomposisi *level* 1 dengan MODWT Haar adalah:

$$a^1 = \left(\frac{x_N + x_1}{2}, \frac{x_1 + x_2}{2}, \dots, \frac{x_{N-1} + x_N}{2} \right) \quad (13)$$

$$d^1 = \left(\frac{x_1 - x_N}{2}, \frac{x_2 - x_1}{2}, \dots, \frac{x_N - x_{N-1}}{2} \right) \quad (14)$$

a merupakan *approximation* (nilai koefisien skala) dan d merupakan hasil dekomposisi MODWT (nilai koefisien wavelet). Dengan perhitungan dekomposisi tersebut, maka f dapat direkonstruksi pada persamaan (15).

$$f = \left(\frac{a_1^1 + d_1^1}{2}, \frac{a_2^1 + d_2^1}{2}, \frac{a_3^1 + d_3^1}{2}, \frac{a_4^1 + d_4^1}{2}, \dots, \frac{a_N^1 + d_N^1}{2} \right) \quad (15)$$

2.5. Wavelet Neuro Fuzzy System (WNFS)

Langkah-langkah pembentukan model wavelet adalah sebagai berikut:

1) Proses Transformasi Data

Proses transformasi data wavelet jenis *Maximal Overlap Discrete Wavelet Transform* (MODWT) dilakukan dengan menggunakan *wavelet mother Haar* dengan *level* tertentu. Kemudian, MODWs yang memiliki korelasi yang tinggi dengan data sebenarnya akan digunakan sebagai *input* dari *neuro fuzzy*. Hasil penjumlahan dari beberapa MODWs yang signifikan berdasarkan nilai korelasinya tersebut, akan digunakan sebagai *input* model (Partal dan Kisi, 2011).

2) Penentuan Banyaknya Input Model

Dalam hal ini, penentuan banyaknya *input* model dilakukan dengan melihat grafik *Partial Autocorrelation Function* (PACF).

Langkah-langkah pembentukan sistem inferensi fuzzy model Sugeno melalui pengendali jaringan syaraf adalah sebagai berikut (Lin, 1996):

1) Pemilihan variabel *input-output* dan data pelatihan

Pemilihan *input* $x_j = 1, 2, \dots, m$ yang berhubungan dengan *output* $y_i = 1, 2, \dots, N$, dengan menggunakan jaringan *backpropagation*. Hal ini dilakukan dengan menggunakan metode eliminasi *backward*, dengan fungsi biaya *Sum Squared Error* (SSE).

2) Pengelompokan (*clustering*) data pelatihan

Pengelompokan dilakukan dengan membagi data menjadi r kelas dengan menggunakan metode pengklasteran *Fuzzy C-Means* (FCM). Algoritma FCM diberikan sebagai berikut (Zimmerman, 2001):

a. Tentukan:

- Matriks X berukuran $n \times m$, dengan n = banyaknya data yang akan di kluster, dan m = banyaknya variabel.
- Banyaknya kluster yang akan dibentuk = $C (\geq 2)$
- Pangkat (pembobot) = $w (> 1)$
- Maksimum iterasi
- Kriteria penghentian = ξ (nilai positif yang sangat kecil)
- Iterasi awal, $t = 1$, dan $\Delta = 1$

b. Bentuk matriks partisi awal U

$$U = \begin{bmatrix} \mu_{11}(x_1) & \mu_{12}(x_2) & \dots & \mu_{1n}(x_n) \\ \mu_{21}(x_1) & \mu_{22}(x_2) & \dots & \mu_{2n}(x_n) \\ \vdots & & & \vdots \\ \mu_{c1}(x_1) & \mu_{c2}(x_2) & \dots & \mu_{cn}(x_n) \end{bmatrix} \quad (16)$$

c. Hitung pusat kluster, V , untuk setiap kluster:

$$v_{ij} = \frac{\sum_{k=1}^n (\mu_{ik})^w x_{kj}}{\sum_{k=1}^n (\mu_{ik})^w} \quad (17)$$

dengan:

v_{ij} = Pusat kluster variabel ke- j pada kluster ke- i

μ_{ik} = nilai keanggotaan data ke- k pada kluster ke- i

w = Pangkat atau pembobot

x_{kj} = data ke- k pada variabel ke- j

- d. Perbaiki derajat keanggotaan setiap data pada setiap klaster, dapat dilihat pada persamaan (18).

$$\mu_{ik} = \frac{\left[\sum_{j=1}^m (x_{kj} - v_{ij})^2 \right]^{-1}}{\sum_{i=1}^c \left[\sum_{j=1}^m (x_{kj} - v_{ij})^2 \right]} \quad (18)$$

- e. Tentukan kriteria berhenti, yaitu perubahan matriks partisi pada iterasi sekarang dengan iterasi sebelumnya.

$$\Delta = \|U^t - U^{t-1}\| \quad (19)$$

Apabila $\Delta \leq \xi$, maka iterasi dihentikan, namun apabila $\Delta > \xi$, maka naikkan iterasi ($t = t + 1$) dan kembali ke langkah (a).

Hasil yang diperoleh yaitu r buah aturan R^s , $s = 1, 2, \dots, r$. Pasangan *input-output* pada cluster ke- s (aturan ke- s) direpresentasikan sebagai (x_i^s, y_i^s) , $i = 1, 2, \dots, N_s$; dengan N_s adalah jumlah data yang masuk pada kelas ke- s .

- 3) Pembelajaran jaringan syaraf yang berhubungan dengan bagian anteseden (bagian IF) pada aturan-aturan inferensi fuzzy

Pada setiap vektor *input*, ditentukan $m_i = (m_i^1, m_i^2, \dots, m_i^r)$, $i = 1, 2, \dots, N$ yang dirumuskan pada persamaan (20) (Lin, 1996).

$$m_i^k = \begin{cases} 1 & k = s \\ 0 & k \neq s \end{cases} \quad (20)$$

Kemudian derajat keanggotaan setiap data dapat diperoleh sebagai *output* jaringan yang telah dilatih sebagai berikut (Lin, 1996):

$$\mu_{AS}(x_i) = \hat{m}_i^s; i = 1, 2, \dots, N; s = 1, 2, \dots, r. \quad (21)$$

- 4) Pembelajaran jaringan syaraf yang berhubungan dengan bagian konsekuen (bagian THEN) pada aturan-aturan inferensi fuzzy

Pembelajaran jaringan syaraf pada bagian THEN dari R^s dengan *input* $x = (x_{i1}^s, x_{i2}^s, \dots, x_{im}^s)$ dan target *output* y_i^s , $i = 1, 2, \dots, N_s$. Dengan estimasi $f_s(x_i)$ diperoleh dari *output* jaringan. Selanjutnya *error* dengan pembobotan dapat dihitung sebagai berikut (Lin, 1996):

$$E_m^s = \sum_{i=1}^N \mu_{AS}(x_i) [y_i - f_s(x_i) \mu_{AS}(x_i)]^2 \quad (22)$$

dimana,

r = banyaknya kelas

y_i = target *output* ke- i

$\mu_{AS}(x_i)$ = derajat keanggotaan tiap x_i dalam himpunan *fuzzy* A pada aturan *fuzzy* ke- s bagian anteseden.

$f_s(x_i)$ = *Output* jaringan hasil pembelajaran tiap x_i pada setiap aturan inferensi *fuzzy* R^s pada bagian konsekuen.

- 5) Penentuan *output* akhir

Menurut Lin (1996) nilai *output* akhir y_i^* dapat diperoleh dengan persamaan (23).

$$y_i^* = \frac{\sum_{s=1}^r f_s(x_i) \mu_{AS}(x_i)}{\sum_{s=1}^r \mu_{AS}(x_i)} \quad (23)$$

dengan $i = 1, 2, \dots, N$.

y_i = target *output* ke- i

$\mu_{AS}(x_i)$ = derajat keanggotaan tiap x_i dalam himpunan *fuzzy* A pada aturan *fuzzy* ke- s bagian anteseden.

$f_s(x_i)$ = *output* jaringan hasil pembelajaran tiap x_i pada setiap aturan inferensi *fuzzy* R^s pada bagian konsekuen.

2.6. Pengukuran Kesalahan Peramalan

Menurut Makridakis dkk. (1999), berikut ini adalah cara pengukuran kesalahan peramalan untuk mengetahui besarnya kesalahan dari model peramalan:

a) *Mean Squared Error* (MSE)

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y - \hat{Y})^2 \quad (24)$$

dengan,

n = banyaknya data

Y = data sebenarnya

\hat{Y} = data hasil peramalan

b) *Mean Absolute Percentage Error* (MAPE)

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y - \hat{Y}|}{Y} \times 100\% \quad (25)$$

dengan,

n = banyaknya data

Y = data sebenarnya

\hat{Y} = data hasil peramalan

3. METODE PENELITIAN

3.1. Sumber Data dan Variabel Penelitian

Jenis data yang digunakan dalam penelitian ini adalah data sekunder dari harga beras giling dalam satuan US Dollars per ton yang tercatat di pusat perdagangan beras Thailand dengan tingkat kecacatan beras (*broken milled*) yaitu 5%. Data ini diperoleh dari alamat www.indexmundi.com dengan mengambil data bulanan dari bulan Mei 2005 sampai bulan Desember 2015. Jumlah data yang digunakan sebanyak 128 data.

3.2. Tahapan Analisis Data

Adapun langkah-langkah analisis data yang dilakukan adalah sebagai berikut:

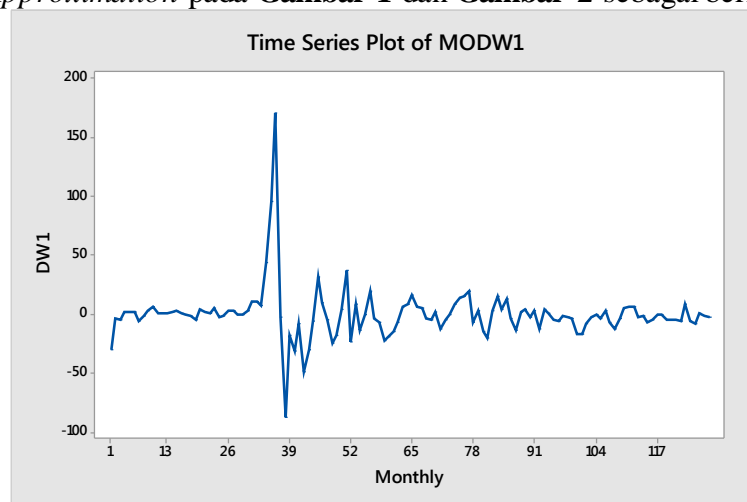
1. Melakukan *input* data harga beras ke *software Matlab*
2. Membuat program *Wavelet Neuro Fuzzy System* (WNFS) pada *software Matlab*
3. Langkah pengolahan yang dilakukan di dalam program WNFS adalah sebagai berikut:
 - a. Melakukan dekomposisi MODWT menggunakan *Haar* level 1.
 - b. Nilai skala proyeksi hasil transformasi wavelet diskrit dan sejumlah *lag* yang signifikan menjadi *input* untuk *neural network*. Dalam hal ini *lag* yang signifikan ditunjukkan oleh grafik PACF hasil pengolahan dengan *software Minitab*.

- c. Melakukan eliminasi *backward* pada variabel *lag* yang digunakan.
- d. Menentukan jumlah neuron optimal pada lapisan tersembunyi (*hidden layer*) berdasarkan nilai MSE yang dihasilkan.
- e. Melakukan klusterisasi data dengan *Fuzzy C-Means* kemudian mengkonversi hasil klusterisasi ke himpunan *fuzzy* 0 dan 1 (bagian *IF*).
- f. Melakukan pembelajaran menggunakan neural network (bagian *THEN*).
- g. Menghitung *output* akhir untuk melakukan prediksi dan menghitung tingkat kesalahan prediksi.

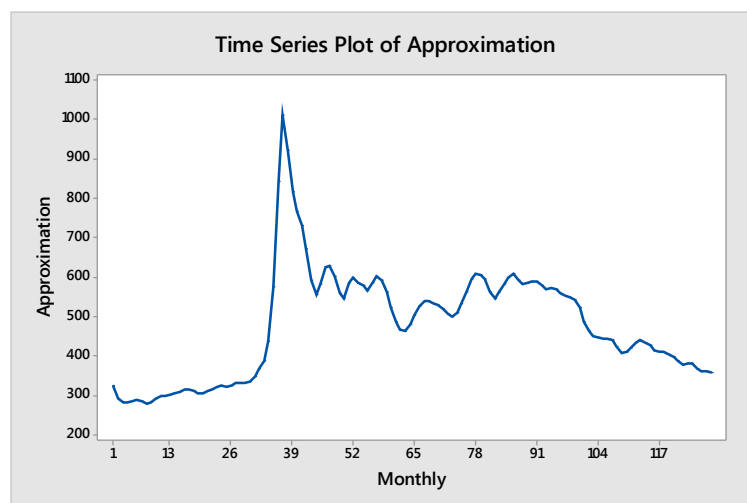
4. HASIL DAN PEMBAHASAN

4.1. Proses Wavelet

Hasil perhitungan *Approximation* dan MODW1 melalui *Maximal Overlap Discrete Wavelet Transform* (MODWT) menunjukkan grafik plot dari hasil perhitungan nilai MODW1 dan *Approximation* pada **Gambar 1** dan **Gambar 2** sebagai berikut:



Gambar 1. Grafik Data MODW1 Hasil MODWT Haar Level 1



Gambar 2. Grafik Data *Approximation* Hasil MODWT Haar Level 1

Dalam hal ini *lag* pada setiap MODWs yang akan dilihat korelasinya terhadap data sebenarnya, ditentukan dengan plot fungsi autokorelasi parsial (PACF) dari setiap MODWs yang dihasilkan. Data *lag* MODW1 dan *Approximation* yang diperoleh, masing-masing memiliki nilai korelasi terhadap data sebenarnya. Di antara keduanya, yang memiliki nilai

korelasi yang paling signifikan terletak pada data *Approximation* yang dapat dilihat pada **Tabel 1**.

Tabel 1. Koefisien Korelasi antara MODWs dengan Data Sebenarnya

| MODWs | Koefisien Korelasi terhadap Data Sebenarnya | MODWs | Koefisien Korelasi terhadap Data Sebenarnya |
|--------|---|----------------------|---|
| MODW1 | | <i>Approximation</i> | |
| D(t-1) | -0,038 | A(t-1) | 0,989 |
| D(t-2) | -0,036 | A(t-2) | 0,988 |
| D(t-3) | -0,033 | A(t-3) | 0,988 |
| D(t-4) | -0,038 | | |
| D(t-5) | -0,041 | | |
| D(t-6) | -0,035 | | |

Berdasarkan korelasi nilai MODWs terhadap data sebenarnya yang ditunjukkan pada **Tabel 1**, maka model *neuro-fuzzy* akan dibangun menggunakan 3 variabel *input* dari data *Approximation* dengan 125 pasangan data. *Input* yang digunakan di antaranya $A_{t-1}(x_1), A_{t-2}(x_2), A_{t-3}(x_3)$.

4.2. Proses Neuro-Fuzzy System

Langkah penyusunan sistem inferensi *fuzzy* model Sugeno orde-nol melalui pengendali jaringan syaraf adalah sebagai berikut:

- a. Pemilihan variabel *input-output* pada data pelatihan

Pemilihan *input* dan *output* ditetapkan dengan memilih variabel *input* dari x_j , $j=1, 2, 3$ yang berhubungan dengan y_i , $i = 1, 2, \dots, 128$ menggunakan jaringan *backpropagation* dengan metode eliminasi *backward*. Pasangan *input-output* yang terpilih setelah dilakukan *lag* data adalah sebanyak 123 data. Berdasarkan pencarian neuron *hidden layer* optimal melalui perhitungan MAPE terkecil, diperoleh banyaknya neuron *hidden layer* dengan MAPE terkecil adalah sebanyak 20 neuron, sehingga jaringan akan dibangun menggunakan 20 neuron pada lapisan tersembunyi.

Input yang diperoleh adalah x_1, x_2, x_3 akan digunakan pada proses pembelajaran dengan target *output* y_i dan menggunakan algoritma *backpropagation levenberg marquardt* dengan satu lapisan tersembunyi dan 20 neuron pada lapisan tersembunyi. Parameter yang digunakan adalah maksimum *epoch* = 1000, laju pembelajaran = 1, dan toleransi error = 10^{-6} . Proses pembelajaran dilakukan dengan semua *input* dan mengeliminasi variabel x_1 hingga variabel x_3 . Nilai SSE yang diperoleh pada proses pembelajaran pada *neural network* dapat dilihat pada **Tabel 2**.

Tabel 2. Hasil SSE dari Eliminasi Setiap Variabel

| Variabel yang dieliminasi | SSE | | | Rata-rata |
|---------------------------|--------|--------|--------|-----------|
| | 1 | 2 | 3 | |
| -* | 0,1334 | 0,2554 | 0,1774 | 0,1887333 |
| x_1 | 1,2501 | 0,5848 | 0,5547 | 0,7965333 |
| x_2 | 0,8632 | 0,6583 | 0,6256 | 0,7157 |
| x_3 | 0,7022 | 0,7559 | 0,3505 | 0,6028667 |

*) model bagian *IF* terbaik

Berdasarkan nilai SSE yang diperoleh dari eliminasi *backward* yang dilakukan, nilai terkecil adalah pada saat semua variabel dimasukkan sebagai *input neuro-fuzzy*, sehingga dalam hal ini tidak dilakukan eliminasi variabel dan semua variabel berpartisipasi sebagai *input* pada bagian anteseden (bagian *IF*).

b. Pengelompokan (*clustering*) data pelatihan

Pada bagian ini, data *input* akan dikelompokkan menjadi tiga buah kelas dengan menggunakan metode pengklasteran FCM dan diperoleh tiga buah aturan R^s , $s = 1, 2, 3$. Pasangan *input* dan *output* pada aturan ke- s direpresentasikan sebagai (x_i^s, y_i^s) , $i = 1, 2, \dots, N_s$. Proses *clustering* dengan program Matlab, pada bagian ini dilakukan dengan langkah-langkah sebagai berikut:

1) Menentukan matriks partisi awal

Matriks partisi awal ini dipilih secara random menggunakan sistem *neural network* dan diperoleh matriks partisi awal seperti pada persamaan (16)

2) Menghitung matriks pusat kluster untuk setiap kluster

Matriks pusat kluster merupakan matriks yang berukuran $i \times j$, dengan baris i sesuai dengan banyaknya kluster yang ditentukan dan kolom j sesuai dengan banyaknya variabel yang di *input*-kan ke dalam jaringan.

3) Melakukan perbaikan derajat keanggotaan setiap data pada setiap kluster dengan memperbaiki matriks partisi

Perbaikan derajat keanggotaan dilakukan dengan menghitung kembali derajat keanggotaan yang dirumuskan pada persamaan (18). Perhitungan ini berlangsung selama kriteria pemberhentian kluster belum dipenuhi.

Dengan menggunakan jaringan *neuro-fuzzy*, diperoleh matriks pusat *cluster* akhir dari setiap variabel adalah sebagai berikut:

$$V = \begin{bmatrix} 595,0204 & 596,4205 & 595,8808 & 588,0494 \\ 324,2384 & 322,4286 & 322,2230 & 328,9832 \\ 479,2924 & 481,4902 & 486,7246 & 428,7276 \end{bmatrix}$$

Matriks pusat kluster ini berukuran 3×4 dengan baris sesuai dengan banyaknya kluster sedangkan kolom sesuai dengan banyaknya variabel *input* yang digunakan, dalam hal ini variabel *input* yang digunakan adalah variabel x_1, x_2, x_3 beserta variabel target y_i .

c. Pembelajaran jaringan syaraf yang berhubungan dengan bagian anteseden (bagian *IF*) pada aturan-aturan inferensi *fuzzy*

Setiap hasil *cluster* yang diperoleh, ditentukan m_i yaitu $(m_i^1, m_i^2, \dots, m_i^r)$ untuk $i = 1, 2, 3, \dots, 123$. Hasilnya berupa konversi nilai keanggotaan dari himpunan *fuzzy* ke himpunan tegas 0 dan 1. Langkah konversi dari himpunan *fuzzy* ke himpunan tegas [0 1] dijelaskan melalui perhitungan sebagai berikut:

$$m_i^k = \begin{cases} 1 & k = s \\ 0 & k \neq s \end{cases}$$

dengan,

m_i^k = derajat keanggotaan tiap data (x_i) pada kluster ke- k ($k \leq r$)

s = banyaknya aturan inferensi *fuzzy*

Selanjutnya hasil konversi yang diperoleh, dilatih pada jaringan syaraf tiruan dengan variabel *input* x_1, x_2, x_3 dengan target *output* m_i menggunakan jaringan *backpropagation levenberg marquardt* dengan satu lapisan tersembunyi dan 20 neuron pada lapisan tersembunyi dan parameter yang digunakan adalah maksimum *epoch* = 1000, laju pembelajaran = 1, dan toleransi error = 10^{-6} . Hasil pembelajaran berupa suatu nilai keanggotaan setiap data pada himpunan *fuzzy* A pada aturan *fuzzy* ke- s bagian anteseden $\mu_{A_s}(x_i)$.

- d. Pembelajaran jaringan syaraf yang berhubungan dengan bagian konsekuen (bagian *THEN*) pada aturan-aturan inferensi *fuzzy*

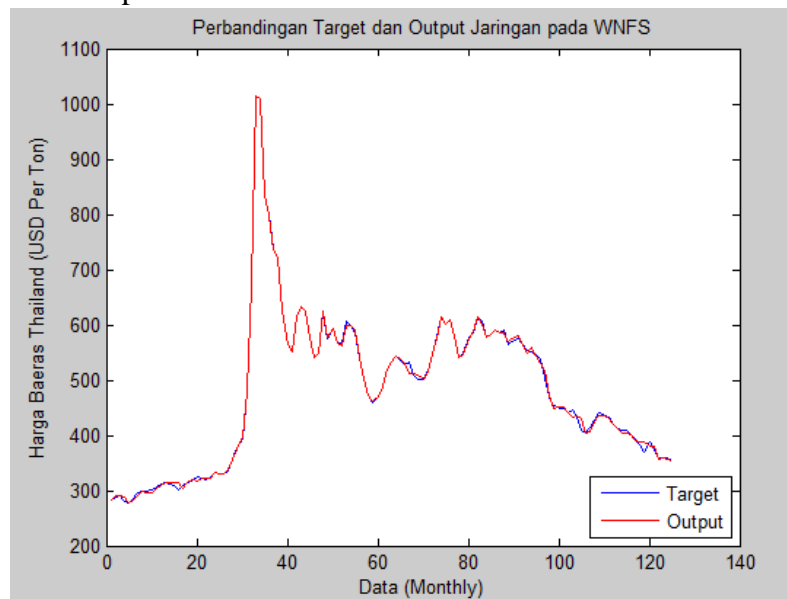
Pada bagian ini, aturan fuzzy yang digunakan pada bagian *THEN* adalah *R*, dengan format aturan fuzzy (*R*) adalah:

$$R : IF x = x_1, x_2, x_3 THEN y = f$$

Proses selanjutnya adalah pembelajaran *neural network* menggunakan jaringan *backpropagation levenberg marquardt* dengan satu lapisan tersembunyi, dengan banyaknya neuron pada lapisan tersembunyi sebanyak 20, dan parameter yang digunakan yaitu maksimum *epoch* = 1000, laju pembelajaran = 1, serta toleransi error = 10^{-6} . Fungsi aktivasi yang digunakan antara lapisan *input* dengan lapisan tersembunyi adalah fungsi sigmoid biner, sedangkan antara lapisan tersembunyi dan lapisan *output* menggunakan fungsi linear.

- e. Penentuan *output* akhir

Nilai y_i^* akhir dapat diperoleh dengan menggunakan perhitungan pada persamaan (23). Berikut adalah grafik kesesuaian dari *output* jaringan dan target *output* dapat dilihat pada **Gambar 3**.



Gambar 3. Plot Hasil *Output* Jaringan WNFS dengan Target *Output*

- f. Perhitungan kesalahan pada proses pembelajaran

Kesalahan pembelajaran jaringan dapat dihitung dengan selisih antara nilai asli dengan nilai *output* akhir hasil pembelajaran. Pengukuran kesalahan yang digunakan diantaranya MSE dan MAPE. Perhitungan kesalahan dengan menggunakan MSE dan MAPE adalah sebagai berikut:

$$\begin{aligned} MSE &= \frac{1}{n} \sum_{t=1}^n (Y - \hat{Y})^2 \\ &= \frac{1}{125} \left((283,4800 - 284,1650)^2 + (287,4100 - 292,0571)^2 \right. \\ &\quad \left. + \dots + (354,3500 - 349,0356)^2 \right) \\ &= 20,69097 \end{aligned}$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y - \hat{Y}|}{Y} \times 100\%$$

$$= \frac{1}{125} \left(\frac{|283,4800 - 284,1650|}{283,4800} + \frac{|287,4100 - 292,0571|}{287,4100} + \dots + \frac{|354,3500 - 349,0356|}{354,3500} \right) \times 100\%$$

$$= 0,65584\%$$

4.3. Prediksi Harga Beras Dunia

Dengan metode *Wavelet Neuro-Fuzzy System* (WNFS), maka dilakukan prediksi harga beras Thailand untuk data bulan Januari 2016 sampai dengan bulan Juni 2016 dengan skala data bulanan. Hasil prediksi harga beras Thailand yang ditunjukkan pada **Tabel 3**.

Tabel 3. Prediksi Harga Beras Thailand (USD Per Ton)

| Prediksi Harga Beras Dunia | | | | |
|----------------------------|-----------|-------------------|-------------|----------|
| Tanggal | Data Asli | Harga Beras Dunia | | |
| | | Output Jaringan | SSE | APE (%) |
| Januari 2016 | 359,48 | 326,04982 | 1117,57705 | 9,29959 |
| Februari 2016 | 373,19 | 346,19313 | 728,83103 | 7,23408 |
| Maret 2016 | 370,48 | 438,17961 | 4583,23657 | 18,27348 |
| April 2016 | 376,05 | 408,33804 | 1042,51727 | 8,58610 |
| Mei 2016 | 408,82 | 355,62442 | 2829,76971 | 13,01198 |
| Juni 2016 | 420,68 | 527,25842 | 11358,95917 | 25,33480 |
| | | Rata-rata | 3610,14847 | 13,62334 |

5. KESIMPULAN

Berdasarkan analisis dan pembahasan yang telah dilakukan, maka dapat diambil kesimpulan sebagai berikut :

1. Dengan menggunakan MODWT Haar *level 1*, pembelajaran jaringan menggunakan *backpropagation Levenberg Marquardt*, dan penggunaan fungsi aktivasi sigmoid biner antara lapisan *input* dan lapisan tersembunyi serta fungsi aktivasi linear antara lapisan tersembunyi dan lapisan *output*, maka sistem *wavelet neuro-fuzzy* yang dibangun dapat digunakan untuk memprediksi harga beras Thailand sebagai harga acuan dunia.
2. Data transformasi *wavelet* yang digunakan sebagai *input* adalah data *Approximation* yang merupakan komponen skala dari transformasi MODWT *level 1*, dengan variabel *input* yang digunakan di antaranya $X_{t-1}(x_1), X_{t-2}(x_2), X_{t-3}(x_3)$.
3. Jumlah kluster yang digunakan sebanyak 3 kluster. Metode pengklasteran yang digunakan adalah *Fuzzy C-Means* dimana proses *clustering* didasarkan dari nilai keanggotaan masing-masing data.
4. Aturan inferensi *fuzzy* dibangun dengan satu buah aturan yaitu (*R*) dengan format aturan $R: IF x = x_1, x_2, x_3 THEN y = f$
5. Hasil prediksi menggunakan WNFS menunjukkan rata-rata kesalahan dalam MSE sebesar 3610,14847 dan MAPE sebesar 13,62334%.

DAFTAR PUSTAKA

- Haghpanahan, H. 2014. *Essays on Exchange Rates Behaviour*. Disertasi University of Leicerster.
- Lin, C. T., dan Lee, C. S. G. 1996. *Neural Fuzzy Systems: A Neuro-Fuzzy Synergism to Intelligent Systems*. New Jersey: Prentice Hall.
- Makridakis, S., Wheelwright, S. C., dan McGee, V. E. 1999. *Metode dan Aplikasi Peramalan*. Jakarta: Binarupa Aksara.
- Ogden, R.T. 1997. *Essential Wavelets for Statistical Applications and Data Analysis*. Boston: Birkhauser.
- Partal, T., dan Kisi, O. 2011. *Wavelet and Neuro-Fuzzy Conjunction Model for Streamflow Forecasting*. Journal of Hidrology, 447-456.
- Percival, D. B, dan Walden, A. T. 2000. *Wavelet Methods for Time Series Analysis 1st Published*. New York: Cambrige University Press.
- Setiaji, A. 2014. *Aplikasi Model Wavelet Neuro Fuzzy untuk Memprediksi Nilai Tukar Euro terhadap Dollar Amerika*. Jurnal Matematika Universitas Negeri Yogyakarta, Edisi V, Volume III.
- Simatupang, E. D, Suparti, dan Rahmawati, R. 2014. *Kajian Model Inflasi Tahunan Kota Sibolga dengan ARIMA dan Pendekatan Regresi Polinomial pada Analisis Multiresolusi Wavelet*. Jurnal Gaussian, Volume 3, Nomor 2, 213-222.
- The World Bank. 2011. *Perkembangan, Pemicu, dan Dampak Harga Komoditas: Implikasinya terhadap Perekonomian Indonesia*. Laporan Pengembangan Sektor Perdagangan.
- Zimmermann, H. J. 2001. *Fuzzy Set Theory and Its Applications, 4th Edition*. Massachusetts: Kluwer Academic Publisher.