

## Peramalan Harga Minyak Mentah Dunia (*Crude Oil*) Menggunakan Metode *Radial Basis Function Neural Network* (RBFNN)

### *Crude Oil Price Forecasting Using Radial Basis Function Neural Network Method (RBFNN)*

Ayu Wulandari<sup>1</sup>, Sri Wahyuningsih<sup>2</sup>, dan Fidia Deny Tisna Amijaya<sup>3</sup>

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

<sup>2,3</sup>Jurusan Matematika FMIPA Universitas Mulawarman

<sup>1</sup>E – mail: ayuwanda27@gmail.com

#### Abstract

*Forecasting is a technique to estimate a value in the future with past data and current data. One of the forecasting method that includes neural network is Radial Basis Function Neural Network (RBFNN). In this research, RBFNN method is used to get the best model and to forecast world crude oil price (US\$) data. World crude oil prices forecasting is very important for many stakeholder, both from the government sector, business entities and investors so that all activities can go according to plan. In the RBFNN method, the network input and the number of hidden layers is very influential to get the best model from RBFNN and also the forecasting. To get the best model by using network input determination by identifying the Partial Autocorrelation Function (PACF) lag, and to determine the number of hidden layers by the K-Means cluster method. Results of the research showed that from the training data, the best model of RBFNN is using 2 network inputs  $X_{t-1}$  and  $X_{t-2}$  and 3 hidden layers with Mean Absolute Percentage Error (MAPE) accuracy level is 6,8150%. With the model, for the next period from June 2017 to December 2017 the world crude oil price (US \$) shows a downward trend.*

*Keywords : World crude oil price (US\$), K-Means cluster, forecasting, radial basis function neural network.*

#### Pendahuluan

Peramalan (*forecasting*) merupakan teknik untuk memperkirakan suatu nilai pada masa yang akan datang dengan memperhatikan data masa lalu maupun data pada saat ini. Salah satu metode prakiraan adalah metode kuantitatif, dimana metode kuantitatif merupakan metode yang membutuhkan informasi pada masa lampau yang dikuantitatifkan dalam bentuk data numerik. Metode perkiraan kuantitatif mendasarkan perkiraannya pada metode statistika dan matematika. Terdapat dua jenis prakiraan kuantitatif, yaitu model regresi dan model runtun waktu (Aswi & Sukarna, 2006).

Runtun waktu adalah himpunan observasi data terurut dalam waktu. Metode runtun waktu adalah metode peramalan dengan menggunakan analisa pola hubungan antar variabel yang akan diperkirakan dengan variabel waktu. Peramalan suatu data runtun waktu perlu memperhatikan tipe atau pola data. Secara umum terdapat empat macam pola data runtun waktu, yaitu horizontal, *trend*, musiman, dan siklis (Hanke & Wichern 2005).

Proses peramalan dapat dilakukan menggunakan banyak metode, antara lain metode pemulusan (*smoothing*), dekomposisi, regresi, dan *ARIMABox Jenkins*. Dalam perkembangan selanjutnya berkembang metode baru menggunakan sistem Jaringan Saraf Tiruan (JST) atau *Neural Network (NN)*. *NN* adalah sistem pemrosesan informasi yang memiliki karakteristik mirip dengan jaringan saraf biologis. Model *NN* efektif digunakan untuk peramalan pada model nonlinear (Fausett, 1994).

Metode peramalan *NN* terus dikembangkan dari tahun 1940-an sampai 40 tahun seterusnya sekitar tahun 1988 dikembangkan fungsi radial basis. Salah satu metode peramalan yang tergolong dalam model *NN* adalah model *Radial BasisFunction Neural Network* (RBFNN). Model RBFNN terdiri dari jaringan lapisan masukan (*input*), lapisan tersembunyi (*hidden*) dan lapisan keluaran (*output*). Jaringan *Radial Basis Function Neural Network* (RBFNN) adalah salah satu pembelajaran yang biasa digunakan untuk penyelesaian masalah *forecasting* (Palit & Popavic, 2005).

Menurut sejarah, minyak bumi telah digunakan oleh manusia sejak zaman kuno Minyak bumi (*petroleum*) sering dijuluki sebagai emas hitam, yaitu berupa cairan kental berwarna coklat gelap yang mudah terbakar. Biasanya minyak bumi dapat ditemukan di lapisan atas dari beberapa area di dalam kerak bumi. Komponen minyak bumi terdiri dari campuran kompleks berbagai hidrokarbon, sebagian besar berupa alkana yang bervariasi bentuknya, komposisi serta kemurniannya.

OPEC (*Organization of the Petroleum Exporting Countries*) adalah sebuah organisasi yang bertujuan menegosiasikan masalah-masalah mengenai produksi, harga dan hak konsesi minyak bumi dengan perusahaan-perusahaan minyak. Di samping itu, OPEC juga mempublikasikan data harga minyak mentah dunia mulai dari data harian, mingguan dan bulanan. Dapat kita ketahui bahwa harga minyak mentah dunia merupakan data runtun waktu, yaitu data yang disajikan dalam

kurun waktu tertentu. Sehingga, data harga minyak mentah dapat diprediksi atau diramalkan agar dapat membantu mengetahui harga minyak di waktu yang akan datang dan dapat diantisipasi apabila akan ada kenaikan atau penurunan harga minyak mentah.

**Peramalan**

Peramalan merupakan suatu teknik untuk memperkirakan suatu nilai pada masa yang akan datang dengan memperhatikan data masa lalu maupun data saat ini. Akan tetapi, tidaklah berarti bahwa setelah mempelajari teknik ini, dapat meramal apa saja dengan tepat.

Metode peramalan dapat dibagi dalam dua kategori utama, yaitu metode kualitatif dan metode kuantitatif. Metode kualitatif lebih banyak menuntut analisis yang didasarkan pada pemikiran intuitif, perkiraan logis dan informasi pengetahuan yang telah diperoleh peneliti sebelumnya. Peramalan seperti ini biasanya digunakan untuk ramalan jangka pendek, atau jika pengambil keputusan lebih mempercayai intuisinya dari pada rumus matematika. Satu ciri metode ini adalah faktor yang mempengaruhi ramalan dan cara menilainya sangat bersifat pribadi dan sulit ditirukan oleh orang lain. Berbeda dengan metode kualitatif, pada metode kuantitatif dibutuhkan informasi masa lalu yang dikuantitatifkan dalam bentuk numerik. Metode peramalan secara kuantitatif mendasarkan ramalannya pada metode statistika dan matematika. Terdapat dua jenis model peramalan kuantitatif, yaitu model runtun waktu (*time series*) dan model regresi (*regression*) (Aswi & Sukarna, 2006).

**Fungsi Autokorelasi Parsial**

Fungsi autokorelasi parsial adalah suatu fungsi yang menunjukkan besarnya korelasi parsial antara pengamatan pada waktu *t* (dinotasikan dengan  $X_t$ ) dengan pengamatan pada waktu-waktu yang sebelumnya (dinotasikan dengan  $X_{t-1}, X_{t-2}, \dots, X_{t-k}$ ).

Rumus autokorelasi parsial atau dinotasikan  $\phi_{kk}$  adalah

$$\phi_{kk} = corr(X_t, X_{t-k} | X_{t-1}, X_{t-2}, \dots, X_{t-k+1}) \quad (1)$$

(Aswi & Sukarna, 2006).

**Tingkat Kesalahan Peramalan**

Hasil peramalan dapat juga dikatakan sebagai hasil prediksi. Nilai prediksi di sini tidak dapat dipisahkan dengan ketidakpastian karena bukan hasil yang sebenarnya sehingga pasti ada kesalahan peramalan. Kesalahan peramalan dapat diukur dengan *Means Absolute Percentage Error (MAPE)*.

MAPE dihitung dengan mencari jumlah nilai *error* disetiap periode, kemudian membaginya dengan nilai pengamatan hasil peramalan. MAPE dinyatakan dengan persamaan sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|X_t - \hat{X}_t|}{X_t} \times 100\% \quad (2)$$

dengan:

$X_t$  : Nilai deret waktu pada periode ke *t*

$\hat{X}_t$  : Nilai ramalan pada periode ke-*t*

(Makridakis, 1999)

**K-Means cluster**

*K-Means* merupakan metode analisis kelompok yang mengarah pada pemartisian *N* objek pengamatan ke dalam *K cluster* di mana setiap objek pengamatan dimiliki oleh sebuah kelompok dengan rata-rata terdekat.

*K-Means* merupakan salah satu metode pengelompokan data nonhierarki yang berusahamempartisis data yang ada kedalam bentuk dua atau lebih kelompok. Metode ini mempartisi data kedalam kelompok sehingga data berkarakteristik sama dimasukkan kedalam kelompok yang lain. Pengelompokan data dengan metode *K-Means* secara umum dilakukan dengan algoritma sebagai berikut:

1. Menentukan jumlah *K cluster*.
2. Mengalokasikan data kedalam kelompok acak.
3. Menghitung pusat *cluster (centroid)* dari data yang ada dari masing-masing kelompok dengan menggunakan rumus *Euclidean* yaitu:
 
$$D_{(X,C)} = \sqrt{\sum (X - C)^2} \quad (3)$$
 di mana :  
 $X$ = data  
 $C$ = nilai pusat *cluster*
4. Mengalokasikan masing-masing data ke *centroid* terdekat.
5. Mengulangi ke langkah 3, apabila masih ada data yang berpindah kelompok, atau apabila ada perubahan nilai *centroid* diatas nilai ambang yang ditentukan, atau apabila perubahan nilai pada fungsi objektif yang digunakan msih diatas nilai ambang yang ditentukan.

(Prasetyo, 2012)

**Jaringan Syaraf Biologi**


Otak manusia terdiri dari 10 miliar sel saraf padat yang saling berhubungan yang disebut *neuron*. Masing-masing terhubung dengan sekitar 10.000 *neuron* lain, dengan 60 triliun *sinapsis (synapse)* yang menghubungkannya. Dengan menggunakan beberapa *neuron* secara bersamaan, otak dapat melakukan fungsinya jauh lebih cepat daripada komputer tercepat yang ada saat ini (Yeung *et al*, 1998).

Komponen-komponen utama dari sebuah *neuron* dikelompokkan menjadi 3 bagian, yaitu:

- a. *Dendrit*, bertugas menerima informasi.
- b. Badan sel (*soma*), berfungsi sebagai pengolah informasi.

c. Akson/axon (*neurite*), bertugas mengirim impuls-impuls ke sel saraf lainnya.

Secara umum, cara kerja sebuah *neuron* terhadap suatu informasi adalah berawal dari *dendrit* yang bertugas menerima informasi. Informasi ini dilewatkan melalui *sinapsis* yang pada perjalanan biologisnya terjadi proses kimiawi, pada jaringan saraf tiruan proses ini disebut pembentukan bobot. Informasi yang diterima diolah oleh *soma*. Untuk mengirim informasi ke sel lain, informasi dilewatkan melalui *akson*. Selanjutnya informasi akan melalui *sinapsis* dan disampaikan ke *soma* lain oleh *dendrite neuron* tersebut. Berikut adalah Gambar jaringan saraf secara biologi yang terdiri atas *neuron*, *soma*, *akson* dan *dendrite* (Fausett, 1994).



Gambar 1. Jaringan Saraf Biologi (Sumber: Fausett, 1994)

**Neural Network (NN)**

Menurut Zhang (2004), *neural network (NN)* atau jaringan saraf tiruan (JST) adalah model komputasi untuk pengolahan informasi. Jaringan ini berkembang dengan pemodelan jaringan saraf biologi, khususnya otak manusia. *Neural network* adalah sistem pemrosesan informasi yang memiliki karakteristik mirip jaringan saraf biologi. *NN* dibentuk sebagai generalisasi model matematika dari jaringan saraf biologi, dengan asumsi bahwa:

- a. Pemrosesan informasi terjadi pada banyak elemen sederhana (*neuron*).
- b. Sinyal dikirimkan di antara *neuron-neuron* melalui penghubung-penghubung.
- c. Penghubung antara *neuron* memiliki bobot yang akan memperkuat atau memperlemah sinyal.
- d. Untuk menentukan *output*, setiap *neuron* menggunakan fungsi aktivasi yang dikenakan pada jumlahan *input* yang diterima (Fausett, 1994).

**Radial Basis Function Neural Network (RBFNN)**

Model *RBFNN* terdiri dari 3 lapisan, yaitu lapisan *input (input layer)*, lapisan tersembunyi (*hidden layer*) dan lapisan *output (output layer)*. Lapisan *input* menerima suatu vektor *input x* yang kemudian dibawa ke lapisan tersembunyi yang akan memproses data *input* secara nonlinear dengan fungsi aktivasi. *Output* dari lapisan tersembunyi selanjutnya diproses di lapisan *output* secara linear (Wei, 2011).

Model *RBFNN* menggunakan fungsi basis sebagai fungsi aktivasi untuk setiap *neuron* pada lapisan tersembunyi. Beberapa fungsi radial basis adalah sebagai berikut (Sutijo, 2008):

1. Fungsi Multikuadratik 
$$\phi(x) = (x^2 + \sigma^2)^{1/2} \tag{4}$$

2. Fungsi Invers Multikuadratik 
$$\phi(x) = \frac{1}{(x^2 + \sigma^2)^{1/2}} \tag{5}$$

3. Fungsi Gaussian 
$$\phi(x) = e^{(-\frac{x^2}{2\sigma^2})} \tag{6}$$

dengan :

$$x = \|x - \mu\|$$

di mana:

$\sigma$  = jarak maksimum pada masing-masing *cluster*

$x$  = jarak *Euclidean*


$x$  = nilai vektor input

$\mu$  = nilai lapisan tersembunyi (pusat *cluster*)

Fungsi aktivasi yang biasa digunakan dalam *RBFNN* adalah fungsi Gaussian.

**Arsitektur RBFNN**

Arsitektur *RBFNN* dapat dilihat pada Gambar 2 berikut:



Gambar 2. Arsitektur *RBFNN* (Sumber: Orr, 1996)

Pada arsitektur Gambar 2 terdapat  $p$  komponen vektor *input x* buah fungsi basis sebagai fungsi aktivasi lapisan tersembunyi dan satu buah *output*. *Output y* yang dihasilkan dari model *RBFNN* merupakan kombinasi linear dari bobot  $\{w_j\}$  dengan fungsi aktivasi  $\phi_j(x)$  dan model *RBFNN* dapat dibentuk algoritma sebagai berikut:

1. Menentukan banyak input jaringan.
2. Menentukan banyak lapisan tersembunyi.
3. Menghitung fungsi aktivasi jaringan *Radial Basis Function* dengan menggunakan fungsi aktivasi *Gaussian*, dengan menggunakan Persamaan (5).
4. Menghitung nilai bobot dan bobot bias menggunakan metode *least square*.
5. Menghitung nilai output keseluruhan jaringan RBF yang dirumuskan sebagai berikut:

$$\hat{X} = \sum_{j=1}^m w_j \phi_j(x) + w_b \tag{7}$$

dengan:

$m$  = banyak fungsi aktivasi lapisan tersembunyi

$w_j$  = bobot *output* ke- $j$   
 $w_b$  = bobot bias  
 $\phi_j(x)$  = fungsi aktivasi *neuron* tersembunyi ke- $j$   
 $x = [x_1, x_2, \dots, x_p]$  yang merupakan vektor *input*  
 (Orr, 1996)

**Metode Kuadrat Terkecil (Least Square)**

Desain *RBFNN* membentuk pemetaan nonlinear dari variabel *input* ke lapisan tersembunyi dan pemetaan linear dari lapisan tersembunyi ke lapisan *output*. Oleh karena itu model *RBFNN* melakukan optimasi hanya pada lapisan *output* yang dapat dilakukan dengan metode kuadrat terkecil (*least square*). Nilai bobot dapat dicari dengan persamaan berikut:

$$\hat{w} = (\Phi^T \Phi)^{-1} \Phi^T \hat{X} \tag{8}$$

(Howlett & Jain, 2001)

**Faktor-Faktor yang Mempengaruhi Harga Minyak**

Stabilitas pasokan dan harga minyak dunia sangat diperlukan dunia untuk mendorong perumbuhan ekonomi. Karena itu estimasi atau peramalan harga minyak dunia sangat didambakan banyak pihak, baik dari sektor pemerintah, badan usaha maupun investor agar semua kegiatan dapat berjalan sesuai rencana.

Harga minyak dunia dipengaruhi oleh tiga faktor, yaitu:

1. Faktor pertama adalah faktor fundamental, yang terdiri atas permintaan minyak, pasokan minyak, stok minyak, kapasitas produksi cadangan dunia dan kemampuan kilang dunia.
2. Faktor kedua adalah faktor non fundamental, yang terdiri dari geopolitik, kebijakan pemerintah, cuaca, bencana alam, pemogokan, kerusakan instalasi ranai produksi, pelemahan nilai dollar dan spekulasi.
3. Faktor ketiga adalah pengaruh dari kebijakan pasokan OPEC.

(Fauzannisa, 2016)

**Hasil dan Pembahasan**


Data yang digunakan adalah data harga minyak mentah dunia bulanan dari bulan Januari 2007 sampai bulan Mei 2017.

Pada penelitian ini proporsi data *training* yang digunakan adalah 90 % dari 125 data dengan menggunakan data terurut, sehingga banyak data yang digunakan sebanyak 112 data dimulai dari data ke-1 sampai data ke-112 atau dari bulan Januari 2007 sampai bulan April 2016 dan proporsi data *testing* yang digunakan adalah 10 % dari 125 data dengan menggunakan data terurut, sehingga banyak data yang digunakan sebanyak 13 data yaitu dimulai dari data ke 113 sampai data ke 125 atau dari bulan Mei 2016 sampai bulan Mei 2017.

**Menentukan Model Network (RBFNN)**

1. Menentukan *Input* Jaringan

Untuk mengetahui banyaknya *input* jaringan digunakan identifikasi lag PACF dengan menggunakan data *training* dapat dilihat pada Gambar 3 Berikut ini:



Gambar 3. Identifikasi lag PACF data *training*

Berdasarkan identifikasi lag PACF pada Gambar 3 dapat dilihat bahwa lag yang signifikan adalah lag 1 dan lag 2. Dengan demikian diperoleh *input*  $X_{t-1}$  dan  $X_{t-2}$ .

2. Menentukan Banyak Lapisan Tersembunyi

Untuk menentukan banyaknya lapisan tersembunyi digunakan metode *K-Means cluster* agar dapat diketahui nilai setiap pusat dan jarak maksimum. Dalam model *RBFNN* khususnya pada peramalan banyaknya lapisan tersembunyi akan menentukan akurasi pada hasil peramalan. Oleh karena itu, untuk mendapatkan hasil peramalan yang baik digunakan metode *trial and error* dengan menggunakan 2 sampai 10 *cluster*. Contoh nilai pusat *cluster* dan jarak maksimum untuk 2 *cluster* dapat dilihat pada Tabel 1.

Tabel 1. Nilai Pusat dan Jarak Maksimum 2 *Cluster*

	Cluster 1	Cluster 2
$X_{t-1}$	60,3714	104,9742
$X_{t-2}$	60,5324	105,1086
Jarak Maksimum ( $\sigma$ )	46,4760	36,7560

3. Menghitung Nilai Aktivasi

Perhitungan nilai fungsi aktivasi akan digunakan untuk menentukan nilai bobot dengan menggunakan Persamaan (6). berikut contoh perhitungan fungsi aktivasi :

-Perhitungan Nilai Aktivasi 2 *Cluster*

$$\phi_{(1,1)}(x) = e^{-\frac{(X_{t-1}-\mu_1)^2 + (X_{t-2}-\mu_1)^2}{2\sigma_1^2}}$$

$$\phi_{(1,1)}(x) = e^{-\frac{(54,5600-60,3714)^2 + (50,7900-60,5324)^2}{2((60,3714)^2)}}$$

$$\phi_{(1,1)}(x) = e^{-\frac{(54,5600-60,3714)^2 + (50,7900-60,5324)^2}{4.320,0370}}$$

$$= 0,9706$$

Setelah dilakukan perhitungan nilai fungsi aktivasi maka didapatkan matriks Gaussian ( $\Phi$ ) dengan ordo 110x2.

4. Menghitung Nilai Bobot Dan Bobot Bias

Pada perhitungan nilai bobot menggunakan matriks Gaussian yang didapat pada perhitungan fungsi aktivasi, dan ditambahkan 1 kolom untuk bobot bias yang bernilai (1) menjadi:

$$\Phi = \begin{bmatrix} 0,9706 & 0,1309 & 1 \\ 0,9910 & 0,1752 & 1 \\ 0,9968 & 0,2379 & 1 \\ 0,9940 & 0,2876 & 1 \\ 0,9866 & 0,3174 & 1 \\ 0,9607 & 0,3884 & 1 \\ 0,9550 & 0,4086 & 1 \\ 0,9421 & 0,4312 & 1 \\ 0,8814 & 0,5501 & 1 \\ 0,7639 & 0,7100 & 1 \\ \vdots & \vdots & \vdots \\ 0,3158 & 0,9782 & 1 \\ 0,3352 & 0,9838 & 1 \\ 0,3672 & 0,9969 & 1 \\ \vdots & \vdots & \vdots \\ 0,6065 & 0,0118 & 1 \\ 0,6788 & 0,0815 & 1 \end{bmatrix}$$

$\underbrace{\hspace{10em}}_{\phi_1} \quad \underbrace{\hspace{10em}}_{\phi_2} \quad \underbrace{\hspace{10em}}_1$

Berikut perhitungan nilai bobot dan bobot bias untuk 2 cluster dengan menggunakan metode least square dengan mengikuti Persamaan (8). Sehingga,

$$\hat{w} = (\Phi^T \Phi)^{-1} \Phi^T X_t$$

$$= \left( \begin{bmatrix} 0,9706 & 0,9914 & \dots & 0,9940 \\ 0,1309 & 0,1752 & \dots & 0,2876 \\ 1 & 1 & \dots & 1 \end{bmatrix} \begin{bmatrix} 0,9706 & 0,1309 & 1 \\ 0,9914 & 0,1752 & 1 \\ \vdots & \vdots & \vdots \\ 0,9940 & 0,2876 & 1 \end{bmatrix} \right)^{-1} \begin{bmatrix} 58,5900 \\ \vdots \\ 37,8600 \end{bmatrix}$$

$$\hat{w} = \begin{bmatrix} -12,5968 \\ 58,3841 \\ 55,2095 \end{bmatrix} = \begin{pmatrix} w_1 \\ w_2 \\ w_b \end{pmatrix}$$

5. Menghitung Nilai Output

Pada tahap ini nilai output yang akan didapat merupakan nilai hasil peramalan menggunakan Persamaan (7). Periode peramalan adalah sebanyak data testing yaitu 13 periode. Berikut contoh perhitungan output peramalan untuk 2 cluster.

Peramalan periode 1 menggunakan 2 data input yaitu  $X_{t-1} = 37,8600$  dan  $X_{t-2} = 34,6500$  dengan 2 lapisan tersembunyi dan nilai bobot  $w_1 = -12,5968$ ,  $w_2 = 58,3840$ , dan  $w_b = 55,2095$ .

$$\hat{X}_t = \sum_{j=1}^2 w_j \phi_j(x) + w_b$$

$$= -12,5986(0,7616) + 58,384(0,0300) + 55,2095$$

$$= 47,3716$$

Dengan perhitungan  $\phi_j(x)$ ,  $j=1,2$  sebagai berikut:

$$\phi_1(x) = e^{-\frac{(X_{t-1}-\mu_1)^2+(X_{t-2}-\mu_1)^2}{2\sigma_1^2}}$$

$$= e^{-\frac{(37,8600-60,3714)^2+(34,6500-60,5324)^2}{4.320,0370}}$$

$$= 0,7616$$

$$\phi_2(x) = e^{-\frac{(X_{t-1}-\mu_2)^2+(X_{t-2}-\mu_2)^2}{2\sigma_2^2}}$$

$$= e^{-\frac{(37,8600-104,9742)^2+(34,6500-105,1086)^2}{2.702,0070}}$$

$$= 0,0300$$

Dengan menggunakan perhitungan yang sama dihitung nilai output peramalan 13 periode dari 2 cluster sampai 10 cluster.

6. Menghitung Akurasi Peramalan

Perhitungan akurasi peramalan digunakan untuk menentukan banyaknya lapisan tersembunyi dalam model RBFNN dimana cluster yang memiliki error peramalan terkecil akan digunakan dalam model peramalan seluruh data. Perhitungan akurasi peramalan menggunakan MAPE dapat dilihat pada Tabel 2 berikut ini:

Tabel 2. Hasil Perhitungan MAPE


Banyak Cluster	MAPE (%)
2 Cluster	7,4684
3 Cluster	6,8150
4 Cluster	20,9376
5 cluster	20,1619
6 Cluster	24,7863
7 Cluster	27,1738
8 Cluster	27,4737
9 Cluster	27,1192
10 Cluster	24,5555

Dari Tabel 2 dapat dilihat bahwa nilai MAPE terkecil terletak pada 3 cluster dengan nilai 6,8150%. Oleh karena itu, dapat diambil kesimpulan bahwa banyaknya lapisan tersembunyi yang akan digunakan untuk peramalan pada model RBFNN seluruh data yaitu menggunakan 3 lapisan tersembunyi.

Meramalkan Seluruh Data

1. Menentukan Input Jaringan

Untuk mengetahui banyaknya input jaringan digunakan identifikasi lag dengan hasil sebagai berikut:



Gambar 4 Identifikasi lag PACF seluruh data

Berdasarkan identifikasi lag PACF pada Gambar 4 dapat dilihat bahwa lag yang signifikan adalah lag 1 dan lag 2. Dengan demikian diperoleh 2 input  $X_{t-1}$  dan  $X_{t-2}$

2. Menentukan Banyak Lapisan Tersembunyi  
 Banyaknya lapisan tersembunyi ini menggunakan nilai MAPE terkecil pada percobaan data *training* adalah menggunakan 3 *cluster*. Sehingga untuk menentukan banyaknya lapisan tersembunyi untuk seluruh data mengacu pada hasil data *training* dapat dilihat pada Tabel 3.

Tabel 3. Nilai Pusat dan JarakMaksimum 3 Cluster Seluruh Data

	Cluster 1	Cluster 2	Cluster 3
$X_{t-1}$	46,2808	75,2531	107,9020
$X_{t-2}$	46,5733	75,2042	107,7186
JarakMaksimum ( $\sigma$ )	26,6710	22,9740	31,1220

3. Menghitung Nilai Fungsi Aktivasi  
 Perhitungan nilai fungsi aktivasi akan digunakan untuk menentukan nilai bobot dengan menggunakan Persamaan (6). Berikut contoh perhitungan fungsi aktivasi :

$$\phi_{(1,1)}(x) = e^{-\frac{(X_{t-1}-\mu_1)^2+(X_{t-2}-\mu_1)^2}{2\sigma_1^2}}$$

$$\phi_{(1,1)}(x) = e^{-\frac{(54,5600-46,2808)^2+(50,79-46,573)^2}{1.422,6840}} = 0,9411$$

Setelah dilakukan perhitungan nilai fungsi aktivasi maka didapatkan matriks Gaussian ( $\Phi$ ) dengan ordo 123x3

4. Menghitung Nilai Bobot Dan Bobot Bias  
 Pada perhitungan nilai bobot menggunakan matriks Gaussian yang didapat pada perhitungan fungsi aktivasi, dan ditambahkan 1 kolom untuk bobot bias yang bernilai (1). Berikut perhitungan nilai bobot dan bobot bias untuk dengan menggunakan Persamaan (8):

$$\Phi = \begin{bmatrix} 0,9411 & 0,3789 & 0,0432 & 1 \\ 0,8595 & 0,5133 & 0,0662 & 1 \\ 0,7326 & 0,6762 & 0,1042 & 1 \\ 0,6470 & 0,7877 & 0,1380 & 1 \\ \vdots & \vdots & \vdots & \vdots \\ 0,0032 & 0,0965 & 0,9919 & 1 \\ 0,0040 & 0,1141 & 0,9908 & 1 \\ 0,0057 & 0,1482 & 0,9989 & 1 \\ \vdots & \vdots & \vdots & \vdots \\ 0,9425 & 0,3881 & 0,0443 & 1 \\ 0,9570 & 0,3532 & 0,0393 & 1 \\ 0,9723 & 0,3240 & 0,0350 & 1 \end{bmatrix}$$

$\underbrace{\hspace{1.5cm}}_{\phi_1}$      $\underbrace{\hspace{1.5cm}}_{\phi_2}$      $\underbrace{\hspace{1.5cm}}_{\phi_3}$      $\underbrace{\hspace{1.5cm}}_{\mathbf{1}}$


Sehingga,

$$\hat{w} = (\Phi^T \Phi)^{-1} \Phi^T X_t$$

$$= \begin{pmatrix} \begin{bmatrix} 0,9411 & 0,8595 & \dots & 0,9723 \\ 0,3789 & 0,5133 & \dots & 0,3240 \\ 0,3789 & 0,0662 & \dots & 0,0350 \\ 1 & 1 & \dots & 1 \end{bmatrix} \begin{bmatrix} 0,9411 & 0,3789 & 0,0432 & 1 \\ 0,8595 & 0,5133 & 0,0662 & 1 \\ \vdots & \vdots & \vdots & \vdots \\ 0,9723 & 0,3240 & 0,0350 & 1 \end{bmatrix} \end{pmatrix}^{-1} x$$

$$= \begin{bmatrix} -2,3996 \\ 9,8187 \\ 61,2966 \\ 46,3908 \end{bmatrix} = \begin{pmatrix} w_1 \\ w_2 \\ w_3 \\ w_b \end{pmatrix}$$

5. Menghitung Nilai Output Model RBFNN  
 Berdasarkan penentuan *input* jaringan menggunakan lag PACF didapat 2 *input* yaitu  $X_{t-1}$  dan  $X_{t-2}$  dan 3 lapisan tersembunyi dan dapat dibuat arsitektur RBFNN seperti Gambar 5:



Gambar 5. Arsitektur jaringan RBFNN data harga minyak mentah dunia

Selanjutnya, nilai *output* yang akan didapat merupakan nilai hasil peramalan, dan dengan menggunakan Persamaan (7) dan banyaknya perhitungan periode peramalan yang diinginkan adalah 7 periode ke depan.

Peramalan periode 1 menggunakan 2 data *input* yaitu  $X_{t-1} = 49,2000$  dan  $X_{t-2} = 51,3700$  dengan 3 lapisan tersembunyi dan nilai bobot  $w_1 = -2,3996$ ,  $w_2 = 9,8187$ ,  $w_3 = 61,2966$  dan  $w_b = 44,3906$ .

$$\hat{X}_t = \sum_{j=1}^3 w_j \phi_j(x) + w_b$$

$$= -2,3996(0,9780) + 9,8187(0,3069) + 61,296(0,0327) + 46,3908 = 49,0666$$

Dengan perhitungan  $\phi_j(x)$ ,  $j=1,2,3$  sebagai berikut:

$$\phi_1(x) = e^{-\frac{(X_{t-1}-\mu_1)^2+(X_{t-2}-\mu_1)^2}{2\sigma_1^2}} = e^{-\frac{(49,2000-46,2808)^2+(51,3700-46,5733)^2}{1.422,6840}} = 0,9780$$

$$\phi_2(x) = e^{-\frac{(X_{t-1}-\mu_2)^2+(X_{t-2}-\mu_2)^2}{2\sigma_2^2}} = e^{-\frac{(49,2000-75,2531)^2+(51,3700-75,2042)^2}{1.055,6090}} = 0,3069$$

$$\begin{aligned} \phi_3(\mathbf{x}) &= e^{-\frac{(X_{t-1}-\mu_3)^2+(X_{t-2}-\mu_3)^2}{2\sigma_3^2}} \\ &= e^{-\frac{(49,2000-107,9020)^2+(51,3700-107,7186)^2}{1.937,1580}} \\ &= 0,0327 \end{aligned}$$

Berikut hasil peramalan 7 periode yang disajikan dalam Tabel 4 sebagai berikut:

Tabel 4. Hasil Peramalan dari Bulan Juni 2017 – Desember 2017

Periode	Harga Minyak Mentah (US \$)
Juni 2017	49,0666
Juli 2017	48,4705
Agustus 2017	48,2913
September 2017	48,1086
Oktober 2017	48,0253
November 2017	47,9651
Desember 2017	47,9329

Dari Tabel 4 dapat dilihat nilai hasil peramalan harga minyak mentah dunia 7 periode yaitu bulan Juni 2017 sebesar 49,0666 US\$, bulan Juli 2017 sebesar 48,4705 US\$, bulan Agustus 2017 sebesar 48,2913 US\$, bulan September 2017 sebesar 48,1086 US\$, bulan Oktober 2017 sebesar 48,0253 US\$, bulan November sebesar 47,9651 US\$ dan bulan Desember sebesar 47,9329 US\$. Dapat dilihat bahwa hasil peramalan menunjukkan kecendrungan menurun untuk harga minyak mentah dunia dari bulan Juni 2017 sampai Desember 2017.

**Kesimpulan**

Dari hasil penelitian dapat diambil kesimpulan bahwa:

1. Proses pembentukan model *Radial Basis Function Neural Network* (RBFNN) pada data runtun waktu harga minyak mentah dunia memiliki model terbaik dengan 2 input jaringan yaitu  $X_{t-1}$  dan  $X_{t-2}$  dan 3 lapisan tersembunyi.
2. Peramalan harga minyak mentah dunia dengan menggunakan metode RBFNN yang memiliki tingkat akurasi paling baik adalah menggunakan 2 input jaringan dan 3 lapisan tersembunyi dengan nilai MAPE sebesar 6,8150 %.

3. Hasil peramalan minyak mentah dunia dengan menggunakan metode RBFNN yang diperoleh selama 7 periode dari bulan Juni 2017 sampai Desember 2017 menunjukkan kecendrungan menurun.

**.Daftar Pustaka**

Aswi & Sukarna. (2006). *Analisis Deret Waktu Aplikasi dan Teori*. Makassar :Andira Publisher.

Fausett, L. (1994). *Fundamentals of Neural Networks (Architectures, Algorithms, and Applications)*. Upper Saddle River, New Jersey: Prentice.

Fauzannisa, R. A (2016). *Peramalan Harga Minyak Mentah Dunia Menggunakan Metode RBFNN*. Jurnal Gaussian: UNDIP. Vol. 5 No.1 PP 193-202

Hanke, J. E. & Wichern, D. W. (2005). *Business Forecasting*. 8th Edition. Upper Saddle River, New Jersey: Prentice Hall.

Howlett, R J. & Jain, L. (2001). *Radial Basis Function Networks 2*. Heidelberg: Springer.

Makridakis. (1999). *Metode Dan Aplikasi Peramalan Edisi 2*. Jakarta : Binarupa Aksara

Orr, M. J. L. (1996). *Introduction to Radial Basis Function Neural Networks*. Edinburgh: University of Edinburgh.

Palit, A. K. & Popavic, D. (2005). *Computational Intelligence in Time Series Forecasting*. Glasgow: Springer.

Prasetyo, Eko. 2012. *Data Mining Konsep Dan Aplikasi Menggunakan MATLAB, Ed. 1*. Yogyakarta: Andi Offset.

Sutijo, B. (2008). *Jaringan Saraf Tiruan Fungsi Radial Basis untuk Pemodelan Data Runtun Waktu*. Jurnal: UGM.

Wei, W. W. S. (2006). *Time Series Analysis Univariate and Multivariate Method* (2<sup>nd</sup> ed). New York: Pearson Education.

Yeung, D. S., Cloete, I., Shi, D., & Wing W. Y. (1998). *Sensitivity Analysis for Neural Network*. London: Springer.

Zhang, G. P. (2004). *Neural Network in Bussines Forecasting*. Hershy: Idea Group Publishing.

