

---

## Penerapan *Neural Network Backpropagation* dengan Transformasi *Wavelet Morlet* Pada Data Pasang Surut Air Laut Di Pantai Ulee Lheue

Novira Iswani<sup>1\*</sup>, Ichsan Setiawan<sup>2</sup> dan Miftahuddin<sup>3</sup>

<sup>1,3</sup> Jurusan Statistika, Universitas Syiah Kuala, Banda Aceh, Indonesia, <sup>2</sup>Jurusan Kelautan dan Perikanan, Ilmu Kelautan, Universitas Syiah Kuala, Banda Aceh

E-mail: novira.iswani@students.stat.unsyiah.ac.id\*, ichsansetiawan@unsyiah.ac.id, miftah@unsyiah.ac.id ,

---

### Abstrak

Pasang surut berpengaruh terhadap pengoptimalan dan pemanfaatan potensi laut dan segala aktifitas yang akan dilakukan di laut, terutama aktifitas di tepi pantai. Sehingga diperlukan pendeteksian fenomena alam yang mungkin terjadi terutama di daerah yang rawan bencana seperti Aceh. Penelitian ini menggunakan metode *Neural network backpropagation* yang difokuskan pada pemodelan kondisi pasang surut. Pemodelan dilakukan dengan menerapkan teori *markov chain* dan untuk memperoleh model terbaik data di transformasi menggunakan transformasi *wavelet morlet*. Penerapan *neural network backpropagation* dalam menggunakan data pasang surut di pantai Ulee Lheue, Banda Aceh periode tahun 2013-2017. Terdapat 5 variabel yang digunakan dalam penelitian, yaitu pasang surut yang terjadi di pagi, siang, sore, malam dan dini hari. Tujuan dari penelitian adalah untuk memperoleh model terbaik dari pasang surut air laut di pantai Ulee Lheue menggunakan *neural network backpropagation*. Hasil yang diperoleh menunjukkan bahwa model jaringan dengan *input 1, hidden 2 dan output 1* atau model jaringan 1-2-1 merupakan model terbaik *neural network backpropagation*.

---

### Abstract

Tides affect the optimization and utilization of the potential of the sea and all activities that will be carried out at sea, especially activities on the beach. So that it is possible to detect natural phenomena that might occur especially in disaster-prone areas such as in Acehness. This research uses the neural network backpropagation method which is focused on modeling. Modeling is done by applying the Markov Chain theory and to obtain the best model the data is transformed using the morlet wavelet transform. Application of neural network backpropagation in uses tidal data on the coast of Ulee Lheue, Banda Aceh for the 2013-2017 period. There are five variables used in research are tide that occur in the morning, afternoon, evening, night and early morning. The purpose of research is to obtain the best model from tides of Ulee Lheue use neural network backpropagation. The results obtained show that the network model with input 1, hidden 2 and output 1 or 1-2-1 network model is the best model of backpropagation neural network.

---

### Informasi Artikel

#### *Sejarah Artikel:*

Diajukan 18 Desember 2018

Diterima 23 Desember 2018

---

#### *Kata Kunci:*

Pasang Surut,  
Neural Network,  
Markov Chain,  
Wavelet Morlet.

---

#### *Keyword:*

Tides,  
Neural Network,  
Markov Chain,  
Wavelet Morlet

---

## 1. Pendahuluan.

### 1.1. Latar Belakang


Provinsi Aceh berada di antara  $01^{\circ} 58' 37,2''$  -  $06^{\circ} 04' 33,6''$  LU dan  $94^{\circ} 57' 57,6''$  -  $98^{\circ} 17' 13,2''$  BT dengan ketinggian rata-rata 125 meter di atas permukaan laut. Pasang surut merupakan suatu fenomena pergerakan naik turun permukaan air laut secara berkala yang diakibatkan oleh kombinasi gaya gravitasi dan gaya tarik-menarik benda-benda langit, terutama Matahari, Bumi, dan Bulan. Seperti fenomena gerhana yang memengaruhi pasang surut air laut maksimum, sehingga mengakibatkan terjadi banjir rob atau air pasang maksimum terjadi. Kondisi pasang surut air laut memengaruhi alam dan aktifitas masyarakat, tidak hanya nelayan namun juga masyarakat yang ingin memancing atau berenang di laut. Kenaikan pasang surut yang berlangsung lama dan tinggi dapat menyebabkan genangan secara permanen atau episodik. Area dengan kenaikan pasang surut yang besar sangat rentan terhadap genangan yang permanen dan juga rentan terhadap banjir berkala.

Penelitian pemanfaatan data pasang surut di pantai Ulee Lheue pernah dilakukan pada periode Januari– Desember 2016 menggunakan metode regresi semiparametrik dengan model regresi kubik spline. Hasil penelitian menyatakan bahwa rata-rata tinggi gelombang pasang paling rendah yaitu pagi hari sebesar 0,8 m sedangkan rata-rata tertinggi untuk tinggi gelombang terjadi di siang dan malam hari yaitu 1,1 m. [1]. Pada penelitian ini, peneliti terfokus pada pemodelan menggunakan *neural network backpropagation* yang mana model tersebut nantinya akan dapat meramalkan pasang surut air laut. Kegiatan pemodelan yang dilakukan pada data pasang surut disebabkan oleh banyaknya manfaat dari pengolahan data pasang surut bagi masyarakat pesisir pantai seperti pembangunan sumber daya pesisir dan lautan, riset hingga pendeteksian fenomena alam yang mungkin akan terjadi terutama di daerah rawan bencana seperti Aceh. Oleh karena itu dibutuhkan analisa ke depan sebagai antisipasi awal bencana banjir rob. Metode *neural network backpropagation* (NN-BP) bersifat fleksibel tanpa harus mengklasifikasikan atau menginterpretasikan terlebih dahulu pola data historik pada saat pembentukan jaringan, termasuk pada historik *time series* yang terdapat didalam data.

## 2. Tinjauan Kepustakaan

### 2.1. Algoritma Neural Network


*Neural network* (NN) adalah berbagai usaha untuk mengikuti cara kerja otak manusia. [2]. *Neural network* terdiri atas kumpulan *node* dan relasi. Ada tiga tipe *node* (neuron) yaitu, *input*, *Hidden* dan *output*.



Gambar 1 Struktur dari sebuah neuron [3].

Komponen utama setiap neuron adalah (lihat Gambar1):

1. *Dendrit* : Titik masuk pada setiap neuron yang mengambil masukan dari neuron lain di jaringan dalam bentuk impuls listrik
2. Tubuh Sel : Ini menghasilkan kesimpulan dari *input dendrit* dan menentukan tindakan apa yang harus dilakukan pada terminal
3. *Axon* : mengirimkan keluaran dalam bentuk impuls listrik ke neuron berikutnya.  
Jaringan syaraf memiliki kerangka kerja sebagai berikut:



**Gambar 2** Model jaringan *neural network backpropagation* [3].

### 2.2. *Neural Network Backpropagation*

Algoritma *backpropagation Neural network* pertama kali dirumuskan oleh Paul Werbos pada tahun 1974, kemudian di populerkan oleh Rumelhart dan McClelland. Metode multilayer *neural network* adalah algoritma back-propagasi yang menggunakan *learning rule gradient descent*. Algoritma ini sangat bermanfaat, cukup handal dan mudah dipahami. [2]. Tujuan dari *backpropagation* adalah untuk memperbaiki bobot pada setiap lapisan dan meminimalkan keseluruhan kesalahan pada lapisan *output*. [3]. Penentuan desain lapisan tersembunyi (*hidden layer*) dapat dilakukan dengan dua pendekatan yaitu secara coba-coba (*trial and error*) atau secara pencarian cerdas (*Intelligent searching*). Banyaknya lapisan tersembunyi (*Hidden Layer*) pada suatu desain model jaringan *neural* tidak meningkatkan proses kerja model jaringan neural dan nilai korelasinya. Menentukan jumlah neuron pada masing-masing lapisan dilakukan dengan coba-coba atau pencarian cerdas dan yang kesalahannya dianggap paling kecil dan memberikan koefisien korelasi paling besar adalah yang digunakan sebagai model dalam penelitian. [4]. Proses *backpropagation* menggunakan nilai *error* dalam menyesuaikan nilai bobot-bobotnya dengan arah mundur (*backward*). [5]. Arsitektur jaringan pada Gambar 2. terdiri dari tiga unit (neuron) pada lapisan *input* yaitu,  $X_1$ ,  $X_2$  dan  $X_3$ ; lapisan tersembunyi (*hidden layer*) dengan 1 neuron yaitu  $f(\sum_{i=1}^n W_i X_i)$  atau biasa disebut  $Z_1$ ; serta 1 unit lapisan *output* yaitu  $Y$ . Bobot yang menghubungkan neuron *input* dengan lapisan tersembunyi adalah  $W_1$ ,  $W_2$  dan  $W_3$  sedangkan bobot yang menghubungkan lapisan tersembunyi dengan neuron *input* adalah  $V$ . [3]. Berikut langkah-langkah *backpropagation* secara umum:

#### *Feedforward*:

- a. Setiap unit *input* menerima sinyal dan meneruskan sinyal tersebut ke semua lapisan tersembunyi (*hiddenlayer*).
- b. Setiap lapisan tersembunyi ( $Z_j, j=1, 2, 3, \dots, p$ ) menjumlahkan sinyal-sinyal *input* yang sudah terboboti.

$$Z_{in_j} = b1_j + (\sum_{i=1}^n W_i X_i) \tag{1}$$

Untuk menghitung sinyal *output* digunakan fungsi aktivasi yang sesuai.

$$Z_j = f(Z_{in_j}) \tag{2}$$

Kemudian sinyal-sinyal tersebut dikirimkan ke semua unit *output*.

- c. Pada unit *output* semua sinyal tiap-tiap dijumlahkan ( $Y_k, k = 1, 2, 3, \dots, m$ ) dengan sinyal-sinyal *input* terbobot.

$$Y_{in_k} = b2_k + (\sum_{i=1}^{np} Z_j W_{jk}) \tag{3}$$

Kemudian sinyal-sinyal tersebut dikirimkan ke semua unit *output*.

$$Y_k = f(Y_{in_k}) \quad (4)$$

dimana:

- $Z_j$  : Setiap lapisan tersembunyi pada saat ke- $j$
- $b1_j$  : Bias *input* pada saat ke- $j$
- $W_i$  : Bobot pada saat proses ke- $i$
- $X_i$  : *Input* ke- $i$
- $Z_{in_j}$  : Sinyal *output*
- $b2_j$  : Bias *output* pada saat ke- $j$

*Backpropagation*:

- a. Setiap unit *output*  $Y_k$  menerima target pola, menghitung *error*, menghitung koreksi bobot dan bias.
- b. Menjumlahkan delta *input* pada tiap-tiap lapisan tersembunyi ( $Z_j, j=1, 2, 3, \dots, p$ ). Hasil jumlah delta *input* dikalikan dengan turunan fungsi aktivasi untuk menghitung *error*. Kemudian menghitung koreksi bobot dan bias.
- c. Terakhir, setiap unit *output* dan unit lapisan tersembunyi memperbaiki bias dan bobotnya. [6].

### 2.3. Transformasi *Wavelet Morlet*

Pada awalnya transformasi *wavelet* digunakan menganalisis sinyal bergerak (*non-stationary signal*). Transformasi sinyal merupakan suatu proses perubahan data dalam bentuk lain dengan tidak mengubah isi informasi dalam sinyal tersebut agar lebih mudah di analisis. [7]. Berikut beberapa sifat transformasi *wavelet* :

- 1) Transformasi *wavelet* dapat dilakukan dengan sempurna karena memiliki waktu kompleksitas.
- 2) Koefisien-koefisien *wavelet* cenderung bernilai kecil atau nol, sehingga memberi keuntungan dalam bidang kompresi dan pemampatan data.
- 3) *Wavelet* mampu beradaptasi dengan berbagai jenis fungsi, seperti fungsi tidak kontinu dan fungsi yang didefinisi dengan domain yang dibatasi. [8]

Transformasi *wavelet* memiliki beberapa kelebihan yaitu:

- 1) Lebih deskriptif dan informatif dalam mempresentasikan sinyal yang reguler dan nonreguler
- 2) Dapat menggabungkan representasi sinyal secara visual dan grafik
- 3) Dapat digunakan untuk mengkompresi dan memfilter sinyal secara efisien.


Transformasi *wavelet* dibedakan menjadi dua macam yaitu *Continous Wavelets Transform* dan *Discrete Wavelets Transform*. Setelah dilakukan transformasi dengan *wavelet* untuk mendapatkan kembali sinyal asli, maka digunakan *Inverse Wavelet Transform*. Salah satu dari *Discrete Wavelets Transform* adalah *wavelet morlet*. *Wavelet morlet* tidak memiliki fungsi penskalaan, tetapi bersifat eksplisit. [9]. Berikut fungsi dan bentuk *wavelet morlet*:

$$\Psi(x) = e^{-x^2/2} \cos(5x) \quad (5)$$

dimana:

- $\Psi(x)$  : *Wavelet mother function*
- $e$  : Konstanta (2,711828)

Bentuk dari *wavelet morlet* (Gambar 3):



**Gambar 3** Bentuk *wavelet morlet* (O'Flynn dan Moriarty, 1987).

### 3. Metode Penelitian

Data yang digunakan pada penelitian ini adalah data sekunder . Unit observasi yang digunakan adalah data pasang surut harian di pantai Ulee Lheue Banda Aceh pada tahun 2013-2017. Sumber data penelitian ini diperoleh dari *website www.ukho.gov.uk*. Adapun data yang digunakan terdiri dari 5 variabel (lihat Tabel 1). Jumlah data yang digunakan yaitu sebanyak 9.125 observasi.

**Tabel 1** Variabel penelitian

$X_1$ (m) (06:00-10:00)	$X_2$ (m) (11:00-14:00)	$X_3$ (m) (15:00-18:00)	$X_4$ (m) (19:00-23:00)	$X_5$ (m) (00:00-05:00)
Rata-rata pasang 1 (Pasang pada pagi hari)	Rata-rata pasang 2 (Pasang pada siang hari)	Rata-rata pasang 3 (Pasang pada sore hari)	Rata-rata pasang 4 (Pasang pada malam hari)	Rata-rata pasang 5 (Pasang pada Dini hari)

### 4. Hasil dan Pembahasan

Karakteristik dari data rata-rata pasang surut air laut di pantai Ulee Lheue, Banda Aceh dapat disajikan dalam bentuk ringkasan statistik dan *scatterplot matrix* (lihat Tabel2).

**Tabel 2** Ringkasan statistik pasang surut pantai Ulee Lheue Banda Aceh tahun 2013-2017

Waktu	Minimum	Maksimum	Median	Rata-Rata
Pagi	-0,306	0,342	-0,061	-0,057
Siang	-0,315	0,385	0,011	0,021
Sore	-0,287	0,378	0,040	0,050
Malam	-0,328	0,324	-0,068	-0,066
Dini Hari	-0,184	0,375	0,040	0,057

Pasang tertinggi atau *Highest Astronomical Tide* (HAT) adalah sebesar 0,385 meter yang terjadi pada siang hari tahun 2014 dan pada kondisi surut terendah atau *Lowest Astronomical Tide* (LAT) adalah sebesar -0,328 meter yang terjadi pada malam hari tahun 2015. Lima tahun terakhir rata-rata pasang terjadi pada waktu siang, sore dan dini hari dengan ketinggian yang bernilai positif yaitu berkisar 0,05 meter dan rata-rata surut terjadi pada waktu pagi dan malam hari dengan ketinggian yang bernilai negatif yaitu berkisar -0,06 meter atau terjadi surut pada waktu pagi dan malam hari. Selisih antara rata-rata pasang yang terjadi dengan pasang tertinggi mengalami perbedaan yang jauh yaitu sebesar 0,30. Artinya pada tahun 2014 kondisi pasang surut dalam kondisi pasang naik yang tinggi. Sama halnya dengan rata-rata surut terendah memiliki selisih yang jauh dengan surut terendah. Hal ini dapat disebabkan karena terdapat data yang *extrim* pada saat kondisi pasang dan surut.

#### 4.1. Normalisasi dengan transformasi wavelet morlet

Transformasi merupakan proses perubahan data atau sinyal ke dalam bentuk lain agar mudah di analisis, namun tidak mengubah informasi yang terdapat dalam data. Tujuan dilakukannya transformasi *wavelet* dalam penelitian ini adalah untuk memperoleh hasil peramalan yang memiliki nilai akurasi yang baik. Data asli ditransformasi menggunakan salah satu jenis fungsi *discrete wavelet* yaitu *wavelet morlet* (Tabel 3). Transformasi ini cocok digunakan pada data yang bergelombang *sinusoidal*. Transformasi secara manual dapat dilakukan dengan menggunakan rumus pada persamaan 5, namun peneliti melakukan transformasi menggunakan *software R*. Berikut pada Tabel3. hasil transformasi data menggunakan *wavelet morlet* dimensi 3 (3-D *wavelet*). Hal ini dikarenakan pada saat tahap transformasi 3-D pola data lebih *smooth* daripada saat transformasi 1-D dan 2-D.

**Tabel 3** Data hasil transformasi *wavelet morlet*

No	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>	X <sub>4</sub>	X <sub>5</sub>
1	0,051	-0,172	0,131	0,074	-0,048
2	0,095	-0,177	0,041	0,141	-0,094
3	0,115	-0,143	-0,051	0,170	-0,114
⋮	⋮	⋮	⋮	⋮	⋮
1825	-0,009	-0,126	0,194	-0,015	0,013

Setelah proses transformasi, tahap selanjutnya mengelompokkan data kedalam 2 kelompok yaitu data *training* dan data *testing*. Dalam penelitian ini rasio dataset dibagi menjadi 50:50, artinya 50% data digunakan untuk proses *training* jaringan dan 50% sebagai proses *testing* jaringan yang mana rasio tersebut di tentukan sendiri oleh peneliti. Berikut Tabel 4. yang menunjukkan kelompok data *training* dan data *testing*.

**Tabel 4** Kelompok data *training* hasil tranformasi *wavelet morlet*

Rata-rata ketinggian pasang surut di pantai Ulee Lheue (m)					
No	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>	X <sub>4</sub>	X <sub>5</sub>
1	-0,033	0,115	-0,062	0,044	-0,102
2	-0,174	0,116	0,376	-0,264	0,086
3	0,073	-0,002	-0,178	0,077	-0,010
⋮	⋮	⋮	⋮	⋮	⋮
912	-0,229	-0,062	0,080	-0,1767	0,324

**Tabel 5** Kelompok data *testing* hasil tranformasi *wavelet morlet*

Rata-rata ketinggian pasang surut di pantai Ulee Lheue (m)					
No	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>	X <sub>4</sub>	X <sub>5</sub>
1	-0,067	-0,010	0,288	-0,131	-0,010
2	-0,010	-0,058	0,249	0,081	-0,040
3	0,055	-0,083	0,186	-0,030	-0,080
⋮	⋮	⋮	⋮	⋮	⋮
913	-0,115	0,360	0,007	-0,203	-0,011

Pada Tabel 4 dan 5 terdapat 2 kelompok data yaitu kelompok data *testing* dan data *training*. Data *testing* digunakan untuk peramalan, sedangkan data *training* digunakan untuk pemodelan.

#### 4.2. Inisialisasi Parameter dan Pemodelan

Pada penelitian ini dikonstruksi model yang terdiri dari 1 lapisan masukan (*input layer*), 2 dan 3 lapisan tersembunyi (*hidden layer*) dan 1 lapisan keluaran (*output layer*) atau jaringan model 1-2-1 atau 1-3-1. Peneliti memilih *hidden layer* 2 dan 3 dikarenakan menurut Notodiputro (2018) biasanya di dalam praktek paling banyak digunakan *hidden layer* 3, karena semakin banyak *hidden layer* maka akan semakin sulit untuk diinterpretasikan serta menimbulkan *over-parametrisasi*. Adapun parameter dalam pemilihan model terbaik adalah sebagai berikut:

<i>Hidden layer</i>	: 2 dan 3
<i>Threshold</i>	: 0,01

Pemodelan dilakukan berdasarkan teori rantai *markov chain*. Rantai *markov chain* merupakan salah satu metode *modeling* yang mempelajari sifat-sifat suatu variabel pada waktu sekarang yang didasarkan pada sifat-sifatnya pada waktu sebelumnya, guna untuk mengestimasi sifat-sifat variabel tersebut pada masa yang akan datang. [10]. Model rantai *Markov* dikemukakan oleh seorang ahli dari Rusia yang bernama A.A. Markov di tahun 1906. Berikut teori rantai *Markov Chain*:

“Untuk setiap waktu  $t$ , ketika kejadian adalah  $K$  dan seluruh kejadian sebelumnya adalah  $K_{t(j)}$ , ...,  $K_{t(j-n)}$  yang terjadi dari proses yang diketahui, probabilitas seluruh kejadian yang akan datang  $K_{t(j)}$  hanya bergantung pada kejadian  $K_{t(j-1)}$  dan tidak bergantung pada kejadian-kejadian sebelumnya yaitu  $K_{t(j-2)}, K_{t(j-3)}, \dots, K_{t(j-4)}$ .” [107].

Berikut hasil pemodelan *neural network backpropagation* dapat dilihat pada tabel 4.5. di bawah ini.


**Tabel 6** Hasil pemodelan data dengan *hidden* 2 dan 3

<i>Waktu</i>	<i>Hidden</i>	<i>Epoch (Iterasi)</i>	<i>AIC</i>	<i>BIC</i>	<i>Error</i>
<b>X<sub>1</sub></b>	2	38	17,572	51,281	1,786
	3	53	23,572	71,723	1,787
<b>X<sub>2</sub></b>	2	1826	20,239	53,948	3,119
	3	87	26,235	74,391	3,117
<b>X<sub>3</sub></b>	2	28	21,997	55,707	3,999
	3	38	27,997	76,153	3,998
<b>X<sub>4</sub></b>	2	462	18,733	52,442	2,366
	3	381	24,795	72,951	2,397
<b>X<sub>5</sub></b>	2	41	15,518	49,227	0,759
	3	872	21,521	69,678	0,761

Berdasarkan Tabel 6. hasil pemodelan, dapat diketahui bahwa pemodelan dengan *hidden* 2 memiliki nilai *AIC* dan *BIC* terkecil daripada beberapa model lainnya. Pemilihan model terbaik berdasarkan kriteria nilai *AIC*, *BIC*, dan *error*. Sehingga dapat dilanjutkan proses pemodelan pembentukan jaringan menggunakan *hidden* 2 dan *threshold* 0,01.


#### 4.3. Visualisasi Arsitektur Model Jaringan

Arsitektur model jaringan yang terbentuk pada jaringan *neural network* bertujuan untuk memudahkan dalam peng-interpretasian model jaringan. Berikut arsitektur masing-masing model jaringan yang dihasilkan dari model terbaik.



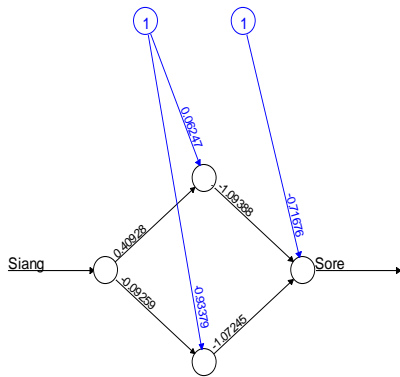
Error: 1.790395 Steps: 37

(a)




Error: 3.119506 Steps: 1826

(b)




Error: 3.998649 Steps: 28

(c)



Error: 2.366433 Steps: 462

(d)



Error: 0.758991 Steps: 41

(e)

**Gambar 4** Visualisasi arsitektur model jaringan *neural network backpropagation* 1-2-1; (a) Pagi hari, (b) Siang hari, (c) Sore hari, (d) Malam hari dan (e) Dini hari.



*Intercept* pada arsitektur model jaringan *backpropagation* siang hari memiliki pengaruh positif terhadap pasang surut siang hari yang akan diramalkan yaitu bernilai sebesar 0,709. *Intercept* pada *hidden layer* 1 bernilai -0,601 dan *hidden layer* 2 bernilai 0,978. Pembobot dari masing-masing *hidden layer* ke *output* dan pembobot dari *input* ke *hidden layer* pada waktu siang hari dapat diketahui pada arsitektur model jaringan Gambar 4(b). Dari pembobotan dapat diketahui seberapa besar *input* mempengaruhi proses pada *hidden layer* atau seberapa besar *hidden layer* mempengaruhi *output*. Arsitektur model jaringan dari pembobotan dapat diketahui seberapa besar *input* mempengaruhi proses pada *hidden layer* atau seberapa besar *hidden layer* mempengaruhi *output*. Misal pada Gambar 4(b). Pagi hari berpengaruh sebesar -0,907 pada proses *hidden layer* 1, sedangkan pada proses *hidden layer* 2 pagi berpengaruh sebesar 0,977. Setelah di proses pada *hidden layer*, selanjutnya proses akan dilanjutkan untuk mendapatkan *output*. Berdasarkan tahap proses *hidden layer*, *hidden layer* 1 mempengaruhi *output* siang hari sebesar 0,748 dan berpengaruh positif. Sedangkan pada proses *hidden layer* 2, *hidden layer* berpengaruh negatif terhadap *output* yaitu sebesar 0,409. Pada pemodelan ini, *input* yang memiliki pengaruh besar terhadap *hidden layer* adalah *input* pasang surut sore hari. Besarnya pengaruh pasang surut sore hari terhadap pasang surut malam hari adalah 6,289 yang terjadi pada proses *hidden layer* 1, sehingga dapat diperkirakan bahwa banjir rob dapat terjadi pada malam hari. Sebaliknya, *input* yang memiliki pengaruh yang kecil terhadap *hidden layer* adalah *input* pasang surut malam hari.

Pengaruh yang besar pada proses *hidden layer* 1 terhadap masing-masing *output* model terjadi pada pembentukan model pasang surut pagi, siang, malam dan dini hari yaitu sebesar 1,043; 0,748; -0,146 dan -1,682. Proses *hidden layer* 1 pada pembentukan model pagi dan siang memiliki pengaruh yang positif, sedangkan pada pembentukan model malam dan dini hari memiliki pengaruh negatif. Berikut pada Tabel 7. ringkasan *intercept* dan bobot-bobot dari model yang dihasilkan dari masing-masing variabel.

**Tabel 7** Ringkasan *intercept* dan bobot model

	Pagi (X <sub>1</sub> )	Siang (X <sub>2</sub> )	Sore (X <sub>3</sub> )	Malam (X <sub>4</sub> )	Dini Hari (X <sub>5</sub> )
<i>Intercept to hidden 1</i>	-0,196	-0,601	0,062	-0,044	-0,266
<i>Input to Hidden 1</i>	-0,519	-0,907	0,409	6,289	1,279
<i>Intercept to hidden 2</i>	-0,545	0,978	-0,934	0,878	0,349
<i>Input to Hidden 2</i>	-0,868	0,622	-0,092	-1,337	-1,665
<i>Intercept to Output</i>	0,441	0,709	-0,717	0,209	-0,159
<i>Hidden 1 to Output</i>	1,044	0,748	-1,094	-0,148	-1,682
<i>Hidden 2 to Output</i>	0,489	-0,409	-1,072	-0,307	-0,829

## 5. Kesimpulan

Model terbaik rata-rata pasang surut air laut di pantai Ulee Lheue adalah model jaringan *neural network backpropagation* dengan *input* 1, *hidden* 2, dan *output* 1 atau model jaringan *neural network backpropagation* 1–2–1. Hal ini karena memiliki nilai *epoch* (Iterasi), *AIC*, *BIC* dan *error* minimum pada setiap waktu (Dini hari, pagi, siang, sore dan malam) pasang surut.

**Referensi**

- [1] Amalia, C.S., Fadhil, M., Akbar, Ali R., dan Miftahuddin. 2017. *Pemanfaatan Data Pasang Surut Air Laut Dalam Identifikasi Aktifitas Ekonomi Masyarakat Pesisir Di Pantai Ulee Lheue Banda Aceh*. PKM-AI. Belmawa Ristekdikti, Jakarta.
- [2] Purnomo, M. H. dan Kurniawan, A. 2006. *Supervised Neural Network dan Aplikasinya*. Graha Ilmu, Yogyakarta.
- [3] Ciaburro, G. dan Venkateswaran, B. 2017. *Neural Network With R*. Packt Publishing Ltd, Birmingham.
- [4] Gencay, R. dan Liu, T. 1996. Nonlinear modeling and Prediction with Feedforward and Recurrent Network. *Physica Letters. A* (187): 397-403.
- [5] Kusrini. dan Luthfi, E. T. 2009. *Algoritma Data mining*. Andi, Yogyakarta.
- [6] Kusumadewi, S. dan Hartati, S. 2010. Neuro-Fuzzy integrasi sistem fuzzy dan jaringan syaraf. Graha Ilmu, Yogyakarta.
- [7] Polikar, R. 1998. *Multi Resolution Analysis: The Discrete Wavelets Transform*. Durham Computation Center, Iowa State.
- [8] Sutarno. 2010. Analisis Perbandingan Transformasi *Wavelet* pada Pengenalan Citra Wajah. *Jurnal Generic*. Yogyakarta, Vol.5: 15-21.
- [9] Darussalam, U. 2009. *Wavelets Transform: Overview Teknis*. Artificial, ICT Research Center UNAS. 3(1):1-18.
- [10] Siagian, P. 2006. *Penelitian Operasional Teori dan Praktek*. UIP, Jakarta.