

Peramalan Jumlah Produksi Ikan dengan Menggunakan *Backpropagation Neural Network* (Studi Kasus: UPTD Pelabuhan Perikanan Banjarmasin)

Muhammad Azhar Razak dan Edwin Riksakomara

Jurusan Sistem Informasi, Fakultas Teknologi Informasi, Institut Teknologi Sepuluh Nopember (ITS)

Jl. Arief Rahman Hakim, Surabaya 60111, Indonesia

e-mail: azhar12@mhs.its.ac.id

Abstrak—Pelabuhan Perikanan Banjarmasin (UPTD dibawah binaan Dinas Perikanan dan Kelautan Kalimantan Selatan) mempunyai salah satu tugas pokok dan fungsi untuk memproduksi hasil tangkapan ikan dari kapal-kapal nelayan dan mendistribusikannya ke berbagai daerah untuk dipasarkan dalam setiap bulannya. Hasil pemasaran ini nantinya akan digunakan Pemerintah Daerah untuk meningkatkan Pendapatan Asli Daerah (PAD) dari provinsi itu sendiri. Permasalahan yang ada adalah jumlah produksi ikan ini umumnya tidak menentu pada setiap bulannya yang mungkin juga dapat berdampak pada kegiatan utama lainnya, seperti penyaluran es pendingin, penyediaan air bersih, dan kegiatan lainnya yang berkaitan dengan proses produksi. Hal seperti ini merupakan permasalahan lumrah dalam bidang peramalan, yaitu ketidakpastian suatu keadaan apabila dilihat fakta-fakta history yang telah lalu. Oleh karena itu, penulis mencoba mencari solusi dengan penggunaan metode peramalan ANN untuk melihat sistemasi dari kegiatan produksi pada instansi ini. Artificial Neural Network (ANN) merupakan sebuah sistem pemrosesan data dengan meniru cara kerja sistem saraf manusia. ANN merupakan sebuah sistem yang terdiri atas banyak elemen pemrosesan sederhana yang terhubung secara paralel. Backpropagation Neural Network (BPNN) dikatakan memiliki kelebihan dalam aspek pembelajaran sistem (adaptive) dan memiliki resiko kesalahan kecil (fault tolerance) terhadap pemecahan masalah. Diharapkan dari hasil penelitian ini didapatkan model, output, hasil analisis, dan aplikasi peramalan produksi ikan yang dapat digunakan oleh instansi terkait untuk memprediksi variabel produksi ikan pada periode-periode berikutnya.

Kata Kunci—UPTD Pelabuhan Perikanan Banjarmasin, *Production Forecasting, Backpropagation Neural Network*

I. PENDAHULUAN

PADA masa sekarang ini, peramalan merupakan hal yang lazim digunakan pada dunia perindustrian dan juga lembaga pemerintahan. Seperti contohnya adalah peramalan permintaan produksi kain, peramalan pemakaian internet pada suatu daerah, dan peramalan penjualan produk. Hal ini juga berlaku oleh lembaga pemerintahan, seperti peramalan penerimaan pajak suatu daerah, peramalan kecelakaan lalu lintas, peramalan kepadatan arus mudik, peramalan penyebaran suatu penyakit, dan lain sebagainya.

Peramalan merupakan seni ilmu untuk memprediksi peristiwa-peristiwa masa depan dengan menggunakan data terdahulu dan memproyeksikannya ke masa depan dengan menggunakan pendekatan-pendekatan matematis [1].

Pelabuhan Perikanan yang merupakan salah satu UPTD di

bawah binaan Dinas Perikanan dan Kelautan Provinsi Kalimantan Selatan memiliki salah satu tugas pokok untuk memproduksi hasil tangkapan ikan dan mendistribusikannya ke berbagai daerah untuk dipasarkan. Hasil pemasaran dari distribusi dan produksi ikan ini nantinya akan digunakan sebagai hasil pemasukan daerah (PAD).

Permasalahan yang ada adalah jumlah hasil produksi tangkapan ikan ini tidak menentu untuk setiap bulannya yang mungkin berdampak pada kegiatan penyediaan es pendingin dan penyediaan air bersih untuk proses produksi ikan. Jumlah produksi ikan ini akan diramalkan untuk beberapa periode kedepan dengan menggunakan data-data *history* yang sudah ada dengan menggunakan metode BPNN (*Backpropagation Neural Network*) yang hasil analisisnya dapat digunakan UPTD Pelabuhan Perikanan ini sendiri sebagai salah satu bahan acuan yang berhubungan dengan kegiatan ini.

II. TINJAUAN PUSTAKA

A. Penelitian Terkait

Menurut Anggit Nourislam, dkk. pada *paper*-nya yang berjudul “Analisis dan Implementasi Jaringan Syaraf Tiruan – Propagansi Balik Dalam Memprediksi Produksi dan Konsumsi Minyak Bumi, Gas Bumi, dan Batu Bara di Indonesia”. Pada *paper* ini ditarik kesimpulan bahwa:

- Semakin besar nilai *learning rate*, semakin cepat proses pembelajaran pada iterasi. Namun, apabila *learning rate* terlalu besar, maka dapat mengakibatkan kondisi homogen data sulit tercapai.
- Penggunaan bias dapat memperkecil MAPE, karena membantu dalam mencapai kondisi homogen data.
- Lebih baik menggunakan fungsi aktivasi linear dalam metode ANN.

Menurut Saeed Heravi, dkk. pada *paper*-nya mengenai perbandingan performa metode ARIMA dan ANN dalam memprediksi jumlah produksi barang-barang ritel di negara-negara Eropa menyimpulkan bahwa:

- Metode ARIMA lebih baik digunakan untuk meramalkan jumlah produksi barang-barang ritel di Eropa menggunakan *dataset* seperti pada penelitian tersebut
- Metode ARIMA akan berperang penting dalam kegiatan-kegiatan peramalan jumlah produksi barang-barang ritel di negara Eropa pada tahun-tahun mendatang.

B. Variabel Pendukung (Suhu Udara)

Menurut Hela dan Laevastu (1970), hampir semua populasi ikan yang hidup di laut mempunyai suhu optimum untuk kehidupannya [10], maka dengan mengetahui suhu optimum dari suatu spesies ikan, kita dapat menduga keberadaan kelompok ikan, yang kemudian dapat digunakan untuk tujuan perikanan.

Menurut Hela dan Laevastu (1970), pengaruh suhu terhadap ikan dapat dilihat dari proses pemijahan [10]. Suhu ekstrim pada suatu daerah tertentu selama musim pemijahan dapat memaksa ikan untuk bermigrasi mencari daerah dengan suhu optimum untuk dijadikan sebagai alternatif tempat memijah.

Menurut Nyabkken (1997), sebagian besar biota laut bersifat poikilometri (suhu tubuh dipengaruhi lingkungan), oleh karenanya pola penyebaran organisme di laut sangat mengikuti perbedaan suhu secara geografik [11].

C. Artificial Neural Network

Artificial Neural Network atau Jaringan Saraf Tiruan merupakan sebuah sistem pemrosesan data dengan meniru cara kerja sistem saraf manusia. Algoritma ANN lahir dari gagasan psikolog, Warren McCulloch dan Walter Pitts pada tahun 1943 yang menjelaskan cara kerja jaringan saraf dengan perangkat jaringan elektronik [12]. *Artificial Neural Network* adalah sebuah sistem yang terdiri atas banyak elemen pemrosesan sederhana yang terhubung secara paralel [13].


ANN (*Artificial Neural Network*) terdiri dari sejumlah satuan masukan (*input*) dan keluaran (*output*) yang terkoneksi, dan pada setiap koneksinya terdapat bobot (*weight*) tersendiri yang dapat diubah-ubah untuk mendapatkan hasil prediksi sesuai yang diinginkan. Lapisan-lapisan pada ANN adalah sebagai berikut:

- a. *Input Layer* (Lapisan Masukan): merupakan lapisan yang menghubungkan sumber data ke jaringan pemrosesan. Dalam artian, setiap masukan akan merepresentasikan variabel-variabel bebas yang berpengaruh terhadap keluaran (*output*)
- b. *Hidden Layer* (Lapisan Tersembunyi): merupakan lapisan perambat variabel-variabel input untuk mendapatkan hasil *output* yang lebih mendekati keinginan. Suatu ANN *Multi Layer* dapat memiliki satu atau lebih *hidden layer*.
- c. *Output Layer* (Lapisan Keluaran): merupakan hasil keluaran dari pemrosesan data ANN. Keluaran yang didapatkan bergantung pada bobot, jumlah lapisan tersembunyi (*hidden layer*), dan fungsi aktivasi yang ditetapkan.

D. Algoritma Backpropagation

Backpropagation merupakan salah satu algoritma yang digunakan pada ANN *Multi-Layer Network* dengan pembelajaran terawasi (nilai *output* sudah diketahui) dimana dilakukan penyesuaian bobot secara berulang untuk mendapatkan nilai *error* terendah antara hasil prediksi dengan

target yang diinginkan. ANN *Backpropagation* dikatakan memiliki kelebihan yang bersifat *adaptive* (dapat menyesuaikan terhadap *dataset*) dan *fault tolerance* (kesalahan *error* kecil) terhadap pemecahan masalah pada sistem.




Gambar 1. Arsitektur ANN Backpropagation

E. Fungsi Aktivasi

Fungsi aktivasi merupakan suatu fungsi perambat pada metode ANN yang digunakan untuk mentransformasikan suatu masukan menjadi keluaran bernilai tertentu. Fungsi Aktivasi yang digunakan pada penelitian ini adalah:

1) Tan-Sigmoid


Fungsi aktivasi ini merubah nilai input menjadi nilai keluaran bernilai -1, 0, atau 1. Input yang diberikan dapat berupa nilai riil negatif atau positif.



Gambar 2. Fungsi Aktivasi Tan-Sigmoid

2) Linear

Fungsi aktivasi ini umumnya digunakan untuk menghasilkan nilai output yang mendekati target yang diinginkan dengan formula $x = y$, yaitu nilai *output* sama dengan nilai *input*.



Gambar .3 Fungsi Aktivasi Linier

F. Parameter

Parameter-parameter pembantu peramalan yang digunakan pada penelitian ini adalah:

1) Learning Rate

Learning Rate digunakan untuk mendefinisikan lama proses pembelajaran model untuk setiap iterasi, skala penentuan parameter *learning rate* antara 0 hingga 1.

2) *Epoch*

Parameter *epoch* merupakan pendefinisian dari banyaknya jumlah iterasi yang digunakan.

3) *Momentum*

Parameter *momentum* digunakan untuk mendefinisikan kemiringan batas kesalahan maksimal yang boleh dihasilkan oleh model. Skala *momentum* yang dapat digunakan antara 0 hingga 0.9.

G. *Performa Peramalan*

Pengukuran hasil performa peramalan pada penelitian ini menggunakan perhitungan MAPE (*Mean Absolute Percentage Error*), yaitu menjumlahkan setiap kesalahan absolut pada setiap periode setelah mengurangi nilai peramalan dan nilai aktual pada setiap periode tersebut dengan formula:

$$MAPE = \left(\frac{100}{n}\right) \sum \left| \frac{At - Ft}{At} \right|$$

Keterangan:

- At : permintaan aktual pada periode ke-t
- Ft : peramalan permintaan pada periode ke-t
- n : jumlah periode peramalan yang terlibat

Skala hasil *error* peramalan yang digunakan pada penelitian ini, dijelaskan pada Tabel 1 dan Tabel 2.

Tabel 1. Skala Performa Peramalan

MAPE	Hasil Peramalan
<10%	Sangat Baik
10-20%	Baik
20-50%	Layak/ Cukup
>50%	Buruk

Tabel 2. Skala Performa Variabel Peramalan


Skala MAPE	Performa Variabel Peramalan
0.1% - 5%	Kurang mempengaruhi
5.1% - 10%	Cukup mempengaruhi
10.1 - 20%	Mempengaruhi
20.1% - 50%	Sangat mempengaruhi
> 50%	Amat sangat mempengaruhi

Menurut I Putu Agus Aditya, pada penelitiannya mengenai peramalan jumlah kasus demam berdarah [16], dikatakan bahwa hasil performa *error* dibagi menjadi empat, yaitu <10% (skala sangat baik), 10-20% (skala baik), 20-50% (skala layak), dan >50% (skala buruk).

Berdasarkan pada Tabel 2, dapat dikatakan suatu variabel kurang mempengaruhi hasil akhir peramalan apabila menghasilkan perbedaan MAPE antara 0.1%-5%, cukup mempengaruhi apabila menghasilkan perbedaan MAPE sebesar 5.1%-10%, mempengaruhi apabila menghasilkan perbedaan MAPE sebesar 10.1%-20%, dikatakan sangat mempengaruhi apabila menghasilkan perbedaan MAPE sebesar 20.1%-50%, dan dikatakan sangat mempengaruhi apabila menghasilkan perbedaan MAPE >50%.

III. METODOLOGI PENELITIAN

Penelitian dilakukan dengan tahapan pelaksanaan seperti dijelaskan pada Gambar 5.



Gambar 4. Medologi Penelitian

A. *Studi Literatur*

Tahap ini merupakan tahapan pembelajaran terkait dengan topik yang diangkat sebagai penelitian. Tahapan ini terkait dengan proses-proses seperti pembelajaran materi dan melakukan *review* paper-paper terkait topik penelitian.

B. *Pengambilan Data*

Tahapan ini adalah proses pengambilan data yang digunakan untuk penelitian. Data yang diambil merupakan data produksi ikan UPTD Pelabuhan Perikanan Banjarmasin, Dinas Perikanan dan Kelautan Provinsi Kalimantan Selatan dan rata-rata suhu udara per bulan pada stasiun Syamsudin Noor pada periode Januari 1988 hingga Agustus 2016.

C. *Pembuatan Model*

Tahapan ini merupakan penentuan parameter dan pembuatan model dengan menggunakan parameter tersebut pada data *training*.

D. *Pengujian Model*

Setelah proses pembuatan model pada tahapan sebelumnya, kemudian dilakukan tahap uji performa model menggunakan data *testing*.

E. *Implementasi Model Optimal*

Merupakan tahapan implementasi dan tahap perancangan aplikasi setelah model yang optimal didapat.


F. Penarikan Kesimpulan

Tahapan selanjutnya adalah penarikan kesimpulan akhir yang berdasarkan dari hasil implementasi dan hasil analisis melalui sudut pandang penulis.


IV. PERANCANGAN DAN IMPLEMENTASI

A. Data Masukan

Data yang digunakan diambil dari data laporan tahunan Dinas Perikanan dan Kelautan Prov. Kalsel, yaitu data jumlah produksi ikan instansi tersebut (sebagai variabel x) dan data yang diunduh secara online pada website National Center For Environmental Information (NCEI), yaitu data jumlah suhu udara pada stasiun Syamsudin Noor (sebagai variabel y). Data dibagi menjadi rasio 70% untuk data training dan 30% untuk data testing.



Gambar 5. Pola Data Jumlah Produksi Ikan PPKB



Gambar 6. Pola Data Rata-rata Suhu Udara Stasiun Syamsudin Noor

B. Pembuatan Model

Model ANN yang dibuat dibagi menjadi 10 model, yang masing-masingnya dijelaskan sebagai berikut:

- 1) Model 1
Model ini menggunakan 1 variabel input dengan neuron input (x-1)
- 2) Model 2
Model ini menggunakan 2 variabel input dengan neuron input (x-1) dan (y-1)
- 3) Model 3
Model ini menggunakan 1 variabel input dengan neuron input (x-1) dan (x-2)
- 4) Model 4
Model ini menggunakan 2 variabel input dengan neuron input (x-1), (x-2), (y-1) dan (y-2)

- 5) Model 5
Model ini menggunakan 1 variabel input dengan neuron input (x-1), (x-2), dan (x-3)
- 6) Model 6
Model ini menggunakan 2 variabel input dengan neuron input (x-1), (x-2), (x-3), (y-1), (y-2) dan (y-3)
- 7) Model 7
Model ini menggunakan 1 variabel input dengan neuron input (x-1), (x-2), (x-3) dan (x-4)
- 8) Model 8
Model ini menggunakan 2 variabel input dengan neuron input (x-1), (x-2), (x-3), (x-4), (y-1), (y-2), (y-3) dan (y-4)
- 9) Model 9
Model ini menggunakan 1 variabel input dengan neuron input (x-1), (x-2), (x-3), (x-4), dan (x-5)
- 10) Model 10
Model ini menggunakan 2 variabel input dengan neuron input (x-1), (x-2), (x-3), (x-4), (x-5), (y-1), (y-2), (y-3), (y-4), dan (y-5)

Keterangan:

$x - n$ = jumlah produksi ikan pada n periode sebelumnya
 $y - n$ = rata-rata suhu udara pada n periode sebelumnya

C. Parameter

Nilai parameter-parameter yang digunakan pada penelitian ini merupakan nilai parameter yang diambil dari acuan pada Matlab, yaitu:

- epoch = 1000**
- lr = 0.01**
- lr increase = 1.05**
- lr decrease = 0.7**
- mc = 0.9**
- maxfail = 6**

Keterangan:

- epoch = jumlah iterasi
- lr = learning rate
- lr increase = penambahan lr apabila error membaik
- lr decrease = pengurangan lr apabila error memburuk
- mc = momentum
- maxfail = jumlah batas validation check


V. HASIL DAN PEMBAHASAN

A. Test Error per Model

Hasil dari implementasi kesepuluh model melalui proses training dan testing yang dilakukan sebanyak tiga kali untuk penggunaan n , $2n$, dan $3n$ jumlah neuron hidden layer dijelaskan sebagai berikut:

1) *N-input neuron hidden layer*


Pada penggunaan *N-input neuron hidden layer* didapatkan nilai MAPE terkecil pada model 3 dengan rata-rata kesalahan absolut 23.13%.



Gambar 7. Test Error n-input neuron hidden layer

2) *2N-input neuron hidden layer*


Pada penggunaan *2N-input neuron hidden layer* didapatkan nilai MAPE terkecil pada model 3 dengan rata-rata kesalahan absolut adalah 24.85%.



Gambar 8. Test Error 2n-input neuron hidden layer

3) *3N-input neuron hidden layer*


Pada penggunaan *3N-input neuron hidden layer* didapatkan nilai MAPE terkecil pada model 1 dengan rata-rata kesalahan absolut adalah 24.85%.



Gambar 9. Test Error 3n-input neuron hidden layer

B. Model Optimal

Disimpulkan berdasarkan hasil implementasi bahwa model terbaik adalah model 3 apabila dibandingkan dengan kesepuluh model yang dibuat pada proses perancangan. dengan rata-rata kesalahan absolut adalah 23.13%. Model 3 menggunakan *neuron* masukan (x-1) dan (x-2) dengan jumlah *neuron hidden layer* sebanyak 2 *neuron*.



Gambar 10. Model Optimal

Keterangan

x = *neuron* masukan (jumlah produksi ikan)

h = *neuron hidden layer*

z = *neuron output*

C. Analisis Variabel Pendukung

Didapatkan dari hasil implementasi dari kesepuluh model yang digunakan untuk rata-rata kesalahan dari tiga kali proses pelatihan dan percobaan adalah dijelaskan seperti pada Tabel 3.

Tabel 3. Perbandingan Performa Variabel

Model ANN		MAPE Minimum Neuron Hidden Layer						Average MAPE
		N		2N		3N		
		train	test	train	test	train	test	
Tanpa Variabel Pendukung	Model 1	17.69%	24.54%	19.87%	26.03%	19.03%	24.85%	Train = 19.09% Test = 27.23%
	Model 3	19.83%	23.13%	17.77%	24.85%	18.85%	26.98%	
	Model 5	17.91%	23.90%	18.70%	27.25%	17.70%	27.64%	
	Model 7	18.67%	27.05%	22.41%	32.07%	18.32%	30.88%	
	Model 9	18.58%	24.81%	20.85%	28.47%	20.12%	35.93%	
Menggunakan Variabel Pendukung	Model 2	19.54%	28.64%	6.81%	30.25%	20.08%	24.74%	Train = 18.97% Test = 30.31%
	Model 4	18.75%	24.69%	19.14%	27.60%	17.73%	27.56%	
	Model 6	18.56%	27.05%	17.33%	32.27%	18.64%	27.15%	
	Model 8	23.64%	43.13%	24.78%	35.49%	17.63%	32.56%	
	Model 10	24.96%	31.75%	18.21%	25.82%	18.76%	36.00%	

Didapatkan nilai rata-rata kesalahan MAPE untuk model tanpa menggunakan variabel pendukung adalah pada proses *training* sebanyak 19.09% dan proses *testing* sebanyak 27.23%, sedangkan model dengan menggunakan variabel pendukung adalah untuk proses *training* sebanyak 18.97% dan proses *testing* sebanyak 30.31%. Sehingga dikatakan variabel suhu udara kurang mempengaruhi hasil akhir peramalan (perbedaan MAPE dalam skala 0.1%-5%)

D. Analisis Parameter

Menggunakan model optimal (model 3) dilakukan analisis lanjut pengaruh penentuan nilai parameter terhadap hasil akhir peramalan. Analisis ini berdasarkan dari nilai perbedaan MAPE yang dihasilkan pada setiap nilai *sample* parameter yang digunakan. Pengaruh penggunaan variasi nilai parameter *learning rate* dijelaskan pada Tabel 4. Pengaruh penggunaan variasi nilai parameter *epoch* dijelaskan pada Tabel 5.

Tabel 3. Perbandingan Performa Variasi *Learning Rate*

Learning Rate	Model 3 (x-1 dan y-1) 2 neuron hidden layer							
	Training MAPE				Testing MAPE			
	Train 1	Train 2	Train 3	average MAPE	Test 1	Test 2	Test 3	average MAPE
0.01 (default)	22.6307%	19.8293%	20.8003%	21.0868%	28.0854%	24.4519%	23.1304%	25.2106%
0.1	24.3905%	20.0797%	20.0795%	21.5165%	31.3770%	26.5950%	26.5950%	28.1890%
0.2	20.0795%	20.0795%	21.7079%	20.6223%	26.5950%	26.5950%	26.3053%	26.4984%
0.3	19.2817%	19.5685%	19.5685%	19.4729%	26.5063%	26.3131%	26.3132%	26.3776%
0.4	21.1444%	21.1452%	21.8896%	21.3931%	26.0804%	26.0805%	26.1030%	26.0880%
0.5	20.4905%	20.4899%	20.4899%	20.4901%	25.8505%	25.8505%	25.8505%	25.8505%
0.6	19.2237%	18.9743%	19.6132%	19.2704%	26.0077%	26.0882%	25.8869%	25.9943%
0.7	18.8869%	22.0167%	22.0165%	20.9734%	26.4062%	26.0012%	26.0013%	26.1362%
0.8	19.0846%	20.9832%	19.1156%	19.7278%	26.2669%	25.9181%	26.1901%	26.1250%
0.9	20.4869%	19.2449%	19.2449%	19.6589%	25.8890%	26.0526%	26.0526%	25.9981%
(average max) – (average min)				2.2461%	all test average			26.2468%

Dilihat pada Tabel 3, penggunaan variasi *learning rate* dinilai kurang mempengaruhi hasil akhir peramalan, dilihat dari rata-rata hasil *train error* tertinggi dan terendah hanya mencapai 2.2461% dan hasil *test error* untuk setiap variasi *learning rate* mendekati 26.2468% (0.1%-5% perbedaan MAPE) kecuali pada *test 1* (*learning rate* 0.2) yang menghasilkan perbedaan MAPE >5% dengan kemungkinan terjadinya hal ini adalah 1:30 kali percobaan (*test*).

Tabel 4. Perbandingan Performa Variasi *Epoch*

Epoch	Model 3 (x-1 dan y-1) 2 neuron hidden layer							
	Training MAPE				Testing MAPE			
	Train 1	Train 2	Train 3	average MAPE	Test 1	Test 2	Test 3	average MAPE
1000 dgn val. check 6 (default)	22.6307%	19.8293%	20.8003%	21.0868%	28.0854%	24.4519%	23.1304%	25.2226%
1000	18.9603%	18.9607%	18.0257%	18.6489%	25.4359%	25.4359%	25.6701%	25.5140%
1500	17.6317%	17.6317%	17.6317%	17.6317%	25.8752%	25.8751%	25.8751%	25.9339%
2000	17.7044%	17.2554%	17.4498%	17.4699%	26.2319%	24.6812%	24.6903%	25.2011%
2500	17.4760%	18.0575%	18.0480%	17.8605%	25.5355%	25.7256%	25.4722%	25.5777%
(average max) – (average min)				1.1790%	all test average			25.4899%

Dilihat pada Tabel 4, penggunaan variasi *epoch* juga dinilai kurang mempengaruhi hasil akhir peramalan, yaitu dilihat dari rata-rata hasil *train error* tertinggi dan terendah hanya mencapai 1.1790% dan hasil *test error* untuk setiap variasi *epoch* pada *sample* yang mendekati 25.4899% (perbedaan MAPE 0.1%-5%).

E. Analisis Rasio Dataset

Menggunakan model 3 dilakukan analisis terhadap penentuan rasio *dataset* pada saat proses perancangan, apakah variasi penggunaan rasio ini mempengaruhi hasil akhir peramalan ataukah tidak, hal ini dijelaskan pada Tabel 5.

Tabel 5. Perbandingan Performa Variasi Rasio *Dataset*

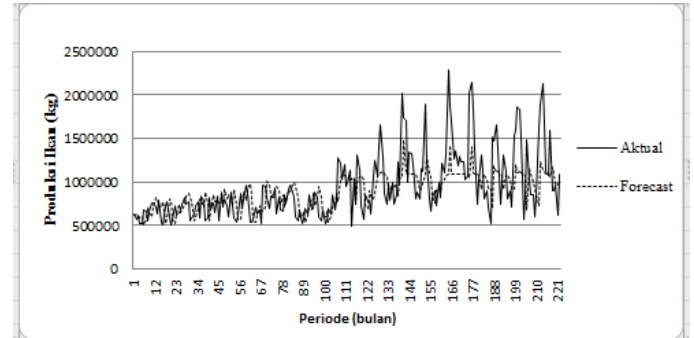
Rasio dataset (train:test)	Model 3 (x-1 dan y-1) 2 neuron hidden layer							
	Training MAPE				Testing MAPE			
	Train 1	Train 2	Train 3	Test 1	Test 2	Test 3	Average MAPE	
85%:15%	20.4001%	20.4002%	20.4002%	30.2930%	30.2930%	30.2930%	30.2930%	
80%:20%	28.5249%	28.5249%	19.6443%	28.6357%	28.6357%	27.8751%	28.3822%	
75%:25%	24.5641%	24.5641%	22.5883%	30.8724%	30.8724%	32.0431%	31.2626%	
70%:30% (default)	22.6307%	19.8293%	20.8003%	28.0854%	24.4519%	23.1304%	25.2226%	
60%:40%	23.1838%	22.4821%	22.4821%	47.6254%	37.4693%	37.4693%	40.8546%	
50%:50%	16.5616%	15.1525%	15.1525%	33.3118%	25.6820%	25.6820%	28.2252%	
40%:60%	15.2766%	15.2766%	16.0947%	31.6264%	31.6263%	30.8929%	31.3819%	
(average max) – (average min)								15.6320%
				all test average				30.8032%

Dilihat pada Tabel 5, penggunaan variasi penentuan rasio *dataset* berdasarkan *sample* yang digunakan dikatakan mempengaruhi hasil akhir peramalan, yaitu dilihat dari hasil

rata-rata *test error* terendah dan tertinggi yang mencapai 15.6320% dan beberapa perbedaan hasil *test error* yang berada dalam skala 5.1%-10% dan melebihi 10%.

F. Peramalan

Dengan menggunakan model optimal, yaitu model 3 dengan jumlah *neuron hidden layer* sebanyak *n-input*, dilakukan peramalan terhadap seluruh *data history* yang ada pada PPKB yang berjumlah 224 periode (Januari 1998 – Agustus 2016) dan peramalan untuk satu periode kedepan, yaitu periode September 2016.



Gambar 11. Hasil Ramalan

Didapatkan nilai hasil peramalan seperti pada Gambar 11 dengan nilai rata-rata kesalahan MAPE sebanyak 22.49% dan hasil peramalan untuk satu periode kedepan, yaitu periode September 2016 adalah 865753 kg hasil produksi ikan.

VI. KESIMPULAN DAN SARAN

A. Kesimpulan

Berdasarkan hasil implementasi dan hasil analisis pada penelitian ini, maka dapat ditarik kesimpulan bahwa:

1. Metode BPNN dengan masukan satu dan dua periode sebelum sekarang layak digunakan terhadap *dataset* seperti *dataset* jumlah produksi ikan pada UPTD Pelabuhan Perikanan Banjarmasin dengan melihat pada hasil *error* yang dihasilkan berkisar 20% pada proses *testing* maupun peramalan menggunakan seluruh *data history*.
2. Variabel pendukung, yaitu suhu udara dinilai kurang mempengaruhi terhadap hasil akhir peramalan, yaitu dilihat dari dekatnya hasil MAPE yang dihasilkan (<5%) oleh model yang menggunakan variabel pendukung maupun yang tidak menggunakan variabel pendukung.
3. Penggunaan variasi parameter *learning rate* dan *epoch* dinilai kurang mempengaruhi terhadap hasil akhir peramalan, sedangkan penggunaan variasi rasio pada *train set* & *test set* dinilai mempengaruhi hasil akhir peramalan.
4. Kekurangan yang seperti dijelaskan pada poin 1 dan poin 2 mungkin dikarenakan oleh pola data yang berbeda antara data *training* dan data *testing*. Pada

data *training* dapat dilihat berpola *horizontal* dan pada data *testing* berpola *seasonal*.

B. Saran

Berdasarkan hasil implementasi dan analisis yang didapat, maka penelitian selanjutnya disarankan untuk:

1. Gunakan dataset yang tidak memiliki nilai fluktuasi terlalu tinggi atau berpola acak atau memiliki pola lebih dari satu, karena mungkin dapat mempengaruhi hasil akhir penelitian.
2. Gunakan nilai parameter *learning rate* 0.01 dan *epoch* 1000 dengan *val. check* 6 dan untuk penentuan rasio *dataset* gunakan rasio 70:30 untuk data *train* dan *test* seperti acuan pada tool Matlab.
3. Untuk mendapatkan model optimal dapat juga menggunakan metode *trial & error*, yaitu menggunakan variasi parameter sebanyak mungkin dan kemudian dibandingkan hasil performanya.
4. Dapat menggunakan variabel pendukung lainnya, seperti kadar garam pada air laut, kecepatan arus, ataupun massa air laut (keadaan pasang/surut).
5. Metode BPNN dapat dikombinasikan dengan metode peramalan lainnya dan nantinya dibandingkan hasil kinerjanya.

DAFTAR PUSTAKA

- [1] Barry Render and Jay Heizer, *Prinsip-prinsip Manajemen Operasi*, PT. Salemba Emban Patria, Jakarta, 2001.
- [2] Szkuta, B. R., Sanabria, L. A., & Dillon, T. S. (1999). Electricity price short-term forecasting using artificial neural networks. *IEEE transactions on power systems*, 14(3), 851-857.
- [3] Mansur, A., & Kuncoro, T. (2012). Product inventory predictions at small medium enterprise using market basket analysis approach-neural networks. *Procedia Economics and Finance*, 4, 312-320.
- [4] Ihwan, A., 2013. Metode Jaringan Saraf Tiruan Propagasi Balik Untuk Estimasi Curah Hujan Bulanan di Ketapang Kalimantan Barat. *Prosiding SEMIRATA 2013*, 1(1).
- [5] Produksi, M. Analisis dan Implementasi Jaringan Syaraf Tiruan–Propagasi Balik Dalam Memprediksi Produksi dan Konsumsi Minyak Bumi, Gas Bumi, dan Batu Bara di Indonesia Analysis and Implementation of Artificial Neural Network–Back Propagation in Prediction of Crude Oil, Natural Gas, and Coal Production and Consumption in
- [6] Heravi, S., Osborn, D. R., & Birchenhall, C. R. (2004). Linear versus neural network forecasts for European industrial production series. *International Journal of Forecasting*, 20(3), 435-446.
- [7] Sridhar, V. N., Dadhwal, V. K., Chaudhari, K. N., Sharma, R., Bairagi, G. D., & Sharma, A. K. (1994). Wheat production forecasting for a predominantly unirrigated region in Madhya Pradesh (India). *TitleREMOTE SENSING*, 15(6), 1307-1316.
- [8] “Dinas Perikanan dan Kelautan.” [Online]. Available: <http://diskanlut.kalselprov.go.id/>. [Accessed: 25-May-2016].
- [9] “Profil Pelabuhan Perikanan Pantai Banjarmasin,” *Alam Ikan*. [Online]. Available: http://www.alamikan.com/2012/11/mengetahui-profil-pelabuhan-perikanan_99.html. [Accessed: 25-May-2016].
- [10] Hela, I. and Laevastu, T., 1970. Fisheries oceanography. *Fishing News (Books) LTD, London*.
- [11] Nybakken, J.W. and Nybakken, J.W., 1993. *Marine biology: an ecological approach* (No. QH 91. N93 1993).
- [12] McCulloch, W.S. and Pitts, W., 1943. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), pp.115-133.
- [13] DARPA Neural Network Study, AFCEA International Press, 1988
- [14] rezahaikal, “JARINGAN SARAF TIRUAN (ARTIFICIAL NEURAL NETWORK),” *rezkal*, 17-Jan-2013.
- [15] Makridakis, S., Wheelwright, S.C. and Hyndman, R.J., 2008. *Forecasting methods and applications*. John Wiley & Sons.
- [16] Pramana, I.P.A.A., 2016. Peramalan Jumlah Kasus Demam Berdarah di Kabupaten Malang Menggunakan Metode Fuzzy Inference System. *Jurnal Teknik ITS*, 5(1).
- [17] “Multilayer Neural Network Architecture - MATLAB & Simulink.” [Online]. Available: <https://www.mathworks.com/help/nnet/ug/multilayer-neural-network-architecture.html>. [Accessed: 05-Jan-2017].
- [18] “National Centers for Environmental Information | National Centers for Environmental Information (NCEI) formerly known as National Climatic Data Center (NCDC).” [Online]. Available: <https://www.ncdc.noaa.gov/news/national-centers-environmental-information>. [Accessed: 05-Jan-2017].
- [19] tutorialspoint.com, “Java Tutorial,” *www.tutorialspoint.com*. [Online]. Available: <http://www.tutorialspoint.com/java/>. [Accessed: 12-Jan-2017].
- [20] “JavaScript and HTML DOM Reference.” [Online]. Available: <http://www.w3schools.com/jsref/>. [Accessed: 12-Jan-2017].
- [21] “Overview (Java Platform SE 7).” [Online]. Available: <http://docs.oracle.com/javase/7/docs/api/>. [Accessed: 12-Jan-2017].