

OPTIMASI JARINGAN SYARAF TIRUAN BACKPROPAGATION DENGAN PARTICLE SWARM OPTIMIZATION UNTUK PREDIKSI PASANG SURUT AIR LAUT

Nerfita Nikentari¹, Hendra Kurniawan², Nola Ritha³, Denny Kurniawan⁴

^{1,2,3,4}Universitas Maritim Raja Ali Haji

Email: ¹nerfita.nikentari@umrah.ac.id, ²hendra@umrah.ac.id, ³nola.ritha@umrah.ac.id,
⁴dennyumrah@gmail.com

(Naskah masuk: 14 Agustus 2018, diterima untuk diterbitkan: 30 Oktober 2018)

Abstrak

Indonesia merupakan negara maritim yang lebih dari 70 % wilayahnya adalah lautan. Lautan memiliki banyak fenomena alam yang mempengaruhi kehidupan sehari-hari masyarakat bahari atau masyarakat yang hidup tergantung pada laut. Salah satu fenomena alam dari laut adalah pasang surut. Pasang surut air laut dalam hal ini tinggi memegang peranan penting pada masyarakat diberbagai aspek seperti transportasi, pariwisata dan ekonomi. Prediksi tinggi pasang surut air dapat bermanfaat untuk memudahkan segala aktifitas masyarakat bahari. Penelitian ini menggunakan metode *Particle Swarm Optimization (PSO)* dan *Jaringan Syaraf Tiruan (JST)* untuk prediksi tinggi pasang surut air laut, dimana PSO digunakan untuk mengoptimasi nilai minimum *error* pada jaringan sehingga didapat bobot jaringan JST yang ideal. PSO dan JST memiliki beberapa parameter inputan seperti, jumlah neuron input, *learning rate*, *swarm*, *c1*, *c2* *inertia min*, *inertia max*. Data yang digunakan sebanyak 1000 yang terbagi menjadi 700 data training dan 300 data testing. Hasil pengujian menunjukkan akurasi prediksi adalah 91.56 % dengan menggunakan 90 *swarm*, *learning rate* 0,9 dan iterasi sebanyak 20 kali.

Kata kunci: *particle swarm optimization*, jaringan syaraf tiruan, prediksi, pasang surut air laut, *minimum error*

OPTIMIZATION OF BACKPROPAGATION ARTIFICIAL NEURAL NETWORK WITH PARTICLE SWARM OPTIMIZATION TO PREDICT TIDE LEVEL

Abstract

Indonesia is a maritime country where 70% of its territory is the ocean. Oceans have many natural phenomena that affect the daily lives of maritime communities or people who live dependent on the sea. One of the natural phenomena of the sea is tide level. Tide level plays an important role in the community both directly and indirectly such as transportation, tourism and the economy. Predictions of tide level can be useful to facilitate all marine activities. This study uses *Particle Swarm Optimization (PSO)* and *Artificial Neural Networks (ANN)* to forecast tide level. PSO is used to optimize the minimum error value on the network in order to get the ideal ANN network. The *Particle Swarm Optimization* and *Neural Network* methods have several input parameters such as number of input neurons, *learning rate*, *swarm*, *c1*, *c2* *inertia min*, *inertia max*. The number of data being used in this reseach is 1000 which divided into 700 training data and 300 testing data. The test results shows the prediction accuracy level is 0. 078373 using 90 swarms, learning rate is 0.9 and iteration is 20 times.

Keywords: *particle swarm optimization*, neural network, forecast, tide level, *minimum error*

1. PENDAHULUAN

Pasang surut merupakan suatu kejadian fenomena alam proses terjadinya naik turun air laut, yang di sebabkan oleh gaya tarik benda langit. seperti matahari, bulan dan bumi. Meskipun massa bulan lebih kecil dari pada massa matahari akan tetapi jarak bulan ke bumi lebih dekat dari pada jarak matahari ke bumi. Oleh karena itu pengaruh gaya tarik bulan ke bumi lebih besar bila dibandingkan dengan pengaruh gaya tarik matahari

ke bumi (Fadilah, 2013). Pemanfaatan laut ini dikarenakan banyaknya sumber daya perairan yang terkandung di dalamnya yang dibutuhkan untuk kesejahteraan hidup mereka.

Adapun sumber daya perairan yang dimanfaatkan seperti menangkap ikan, bongkar muat kapal di pelabuhan, sebagai transportasi penyeberangan, sebagai sumber tenaga listrik, dan sebagainya. Proses terjadinya pasang surut tidaklah sama, sehingga diperlukan prediksi pasang surut air laut. Prediksi mengenai pasang surut air laut ini

menggunakan data pasang surut yang telah berlalu. Metode yang dilakukan untuk prediksi pasang surut air laut ini menggunakan PSO dan JST. Untuk studi kasus prediksi, metode yang sering digunakan dalam jaringan syaraf tiruan (*neural network*) yaitu *backpropagation*, algoritma ini memiliki kemampuan dalam pemecahan masalah di dunia nyata dengan membangun metode terlatih yang menunjukkan kinerja yang baik dalam skala data yang luas dan mampu mengatasi pengenalan pola-pola yang rumit.

Namun metode *backpropagation* ini memiliki beberapa kelemahan antara lain laju konvergensi yang lambat dan terjebak dalam minimum lokal, hal ini dapat menyebabkan kegagalan dalam mencari solusi yang optimal untuk pemilihan fitur pada bobot atribut yang digunakan (Suhendra, 2015). Dalam permasalahan ini dapat diatasi dengan dioptimalkan menggunakan algoritma PSO.

Penelitian ini algoritma PSO digunakan untuk mengoptimasi jaringan pada JST untuk mendapatkan bobot yang ideal, bobot tersebut dilatih menggunakan algoritma *neural network backpropagation*. Optimasi dalam hal ini adalah tercapainya nilai *error* minimum dari JST.

Penelitian menggunakan PSO untuk prediksi telah dilakukan sebelumnya yaitu untuk prediksi kelulusan mahasiswa, dimana data yang digunakan adalah 30 data nilai matakuliah dari semester 1 hingga semester 4. Didapatkan nilai *learning rate* terbaik 0.2 dengan RMSE 0.048 dan tingkat akurasi 87.31 % (Kusumawati et al, 2015).

Raharjo melakukan penelitian dengan judul Model *Artificial Neural Network* Berbasis *Particle Swarm Optimization* untuk Prediksi Laju Inflasi. Penelitian ini menguji tingkat akurasi penerapan model PSO-ANN melalui *attribute weight (aw)* atau awPSO-ANN dengan obyek data inflasi bulanan Indonesia dari Januari 1979 - Mei 2011. Pengujian model dilakukan terhadap empat kelompok data yang didasarkan pada perubahan jumlah neuron yaitu satu dengan menggunakan satu *hidden layer* dengan satu *neuron*, lima *neuron* dengan sepuluh *neuron* dan lima belas *neuron*, kemudian penelitian ini melihat perbandingan kinerja AAN dan kinerja awPSO-ANN untuk menghasilkan nilai pelatihan yang optimal (Raharjo, 2013).

JST *Backpropagation* digunakan untuk pengambilan keputusan dalam prediksi penerima beasiswa di Universitas Amikom. Parameter yang digunakan dalam penelitian ini adalah IPK (Indeks Prestasi Kumulatif), jumlah sks, status dan pendapatan orang tua. Data yang digunakan sejumlah 3000. Arsitektur JST yang digunakan adalah 1 *input layer* dengan 4 buah *neuron input* yang merepresentasikan 4 buah parameter yang digunakan, 1 *hidden layer* dengan 20 *neuron hidden*, dan 1 *output layer* dengan 1 *neuron output* untuk menampilkan hasil “diterima” atau “ditolak” untuk pengambilan keputusan penerima beasiswa.

Penelitian ini menghasilkan akurasi sebesar 99,00% dengan menggunakan *learning rate* sebesar 0,2 dan *momentum* 0,2 (Pujianto et al, 2018).

Prediksi menggunakan JST *Backpropagation* dan PSO dilakukan oleh Badrul dengan studi kasus adalah hasil pemilu legislatif DKI Jakarta tahun 2009 dengan total data adalah 2267. Penelitian ini membandingkan hasil prediksi dengan menggunakan JST *Backpropagation* dengan JST *Backpropagation* yang bobotnya dioptimasi dengan PSO. Hasil prediksi menunjukkan bahwa JST dengan PSO lebih baik yaitu dengan akurasi 98.85 % sedangkan prediksi dengan JST *Backpropagation* memiliki akurasi 98.50 % (Badrul, 2013).

Penelitian lain dengan menggunakan JST *Backpropagation* untuk prediksi distribusi air PDAM di kota Malang. Parameter yang digunakan dalam prediksi adalah jumlah kehilangan air dan jumlah air yang terjual. Nilai parameter optimal yang didapatkan dari pelatihan adalah *learning rate* 0.1, jumlah node pada lapisan tersembunyi 5, dan minimum error adalah 0.00001, dan dengan jumlah iterasi sebanyak 2000 kali. Keakuratan prediksi adalah sebesar 97,99% (Jauhari, 2016).

Berdasarkan penelitian-penelitian sebelumnya JST *Backpropagation* menghasilkan prediksi yang sangat baik dengan nilai prediksi diatas 90 %. PSO diimplementasikan untuk mengoptimasi JST agar menghasilkan hasil prediksi yang lebih akurat untuk prediksi pasang surut air laut.

2. METODE

2.1 Data

Data yang digunakan dalam penelitian ini adalah data sekunder, yaitu data yang sudah diolah sebelumnya oleh pihak pengumpul data primer dan data berbentuk laporan historis dari BMKG kota Tanjungpinang yaitu data pasang surut perjam dari tanggal 1 Januari 2015 sampai dengan 11 Februari 2015 berjumlah 1000 data. 1000 data akan dibagi menjadi 2 bagian 700 data *training* dan 300 data *testing*. Data training dapat dilihat pada tabel 1.

Tabel 1. Data Pelatihan Prediksi Pasang Surut Air Laut

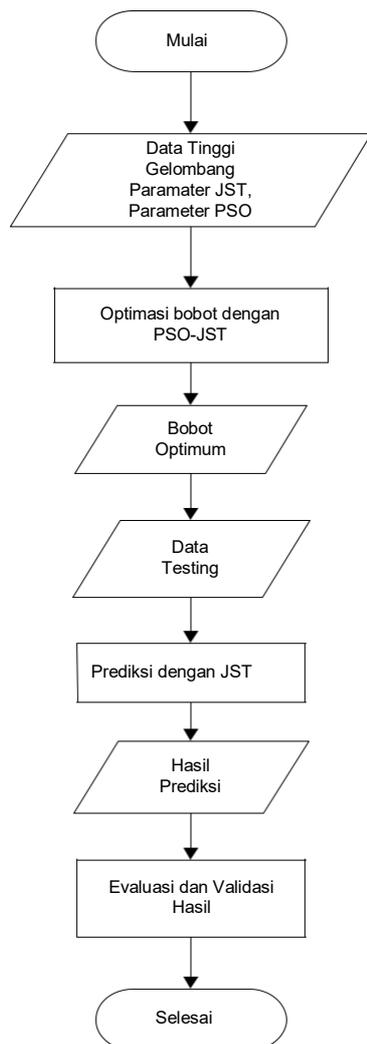
No	Tanggal	Jam	Tinggi (m)
1	2015-01-01	1	1,3
2	2015-01-01	2	1,3
3	2015-01-01	3	1,2
4	2015-01-01	4	1,2
5	2015-01-01	5	1
6	2015-01-01	6	0,9
7	2015-01-01	7	0,7
8	2015-01-01	8	0,6
9	2015-01-01	9	0,5
10	2015-01-01	10	0,5
11	2015-01-01	11	0,5
12	2015-01-01	12	0,7
13	2015-01-01	13	0,9
14	2015-01-01	14	1,1

No	Tanggal	Jam	Tinggi (m)
15	2015-01-01	15	1,3
16	2015-01-01	16	1,4
17	2015-01-01	17	1,5
18	2015-01-01	18	1,6
19	2015-01-01	19	1,6
:	:	:	:
700	2015-01-30	4	1

Data yang digunakan pada penelitian ini berupa data time series bulanan pemakaian air PDAM mulai dari Januari 2008 sampai dengan Desember 2013. Hasil prediksi pasang surut air laut yang akan diprediksi dijadikan sebagai variabel Y yang juga merupakan output JST. Input JST berjumlah 5 . Kelima data input merepresentasikan pasang surut air laut pada jam sebelumnya sebelumnya ($x, x-1, x-2, x-3, x-4$).

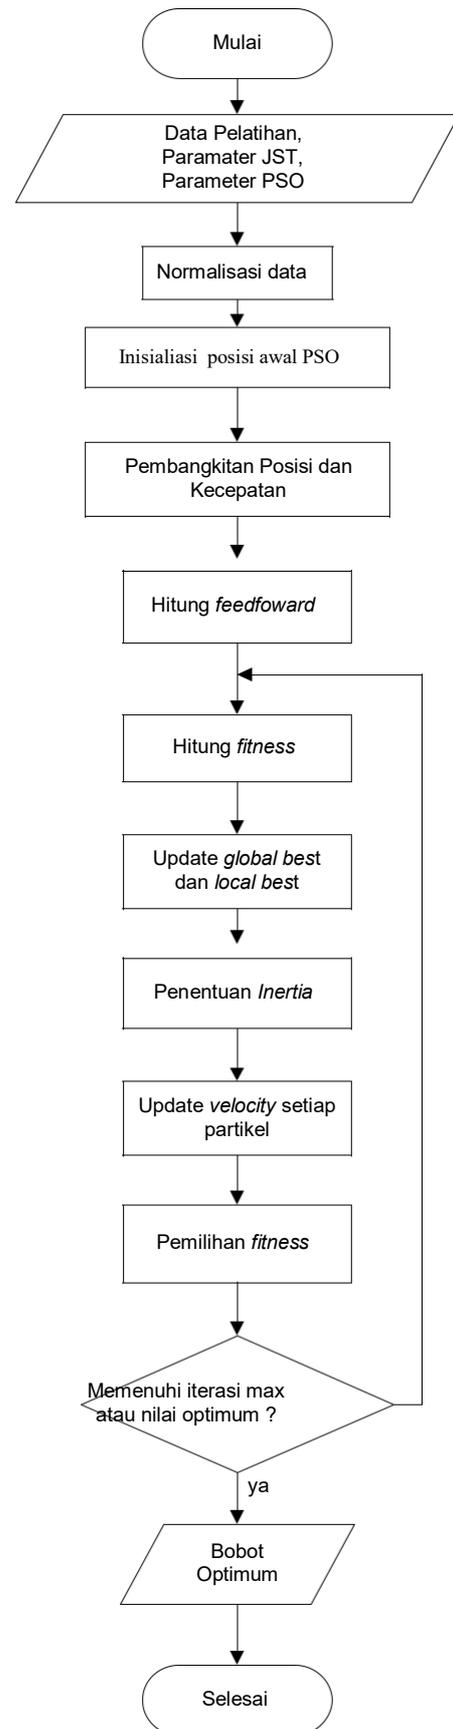
2.2 Flowchart Prediksi

Proses alur kerja proses prediksi pasang surut air laut dengan algoritma PSO dan JST secara umum dapat dilihat pada gambar 1.



Gambar 1. Flowchart Prediksi Pasang Surut Air Laut

2.3 Flowchart Optimasi Bobot JST

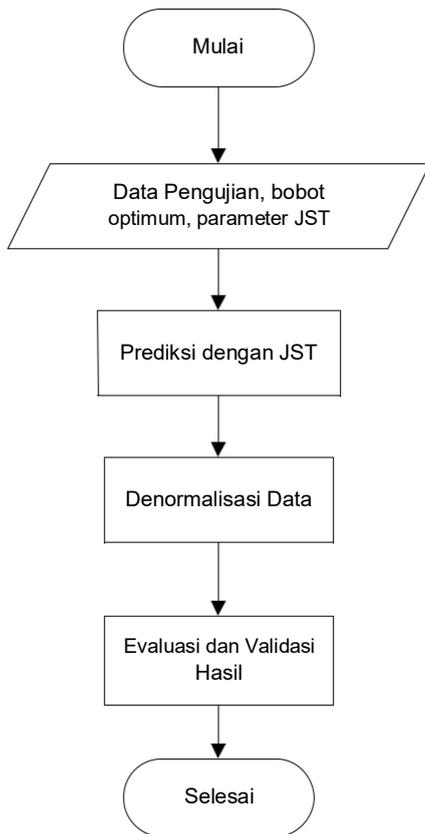


Gambar 2. Flowchart Optimasi Bobot dengan PSO-JST

Gambar 2 memperlihatkan tahapan-tahapan yang dilakukan untuk memperoleh bobot JST yang telah optimum menggunakan PSO-JST. Data tinggi pasang surut yang digunakan untuk pelatihan dinormalisasi terlebih dahulu. Normalisasi data merubah datanya ke dalam spesifik *range* seperti [0..1]. Tujuan dari normalisasi data adalah menjamin kualitas data sebelum data tersebut menjadi input dalam suatu algoritma (Nayak et. Al, 2014). Pelatihan pada JST dapat menjadi lebih efisien dengan melakukan normalisasi data input. Data yang tidak dinormalisasi dapat menyebabkan proses pelatihan pada JST menjadi lebih lambat (Jayalakshmi, 2011).

2.3 Flowchart Prediksi dengan JST

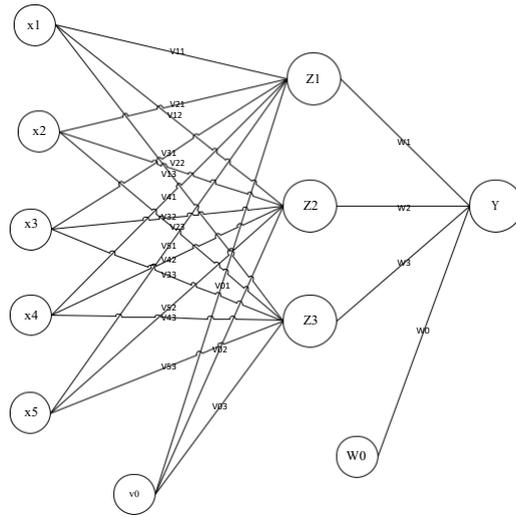
Proses prediksi dengan menggunakan data pengujian dengan bobot yang telah optimum dapat dilihat pada gambar 3.



Gambar 3. Flowchart Prediksi dengan JST

2.4 Arsitektur JST dengan PSO

Pemodelan arsitektur JST untuk prediksi pasang surut air laut terdiri dari 5 *input node* (X1,X2,X3,X4 dan X5), 3 *hidden node* (Z1,Z2 dan Z3) dan 1 *output node*(Y). Lima input node merepresentasikan 5 data pasang surut terdahulu dan 1 output node merepresentasikan hasil prediksi.



Gambar 4. Arsitektur JST

2.5 Parameter PSO dan JST

JST dengan PSO dalam penelitian ini menggunakan parameter antara lain :

- c1 : 1
- c2 : 1
- Inertia max : 0.9
- Inertia min : 0.4

2.6 Fungsi Objektif

Permasalahannya dalam penelitian ini adalah optimasi untuk mencari nilai minimum, dalam hal ini meminimalkan error pada JST. Berdasarkan nilai fungsi objektifitas yang telah ditetapkan maka didapatkan nilai *fitness* untuk setiap partikel. Nilai *fitness* dari setiap partikel berdasarkan masalah optimasi yang ditentukan. Nilai *fitness* berkisar antara dari nilai 0 (nol) sampai 1 (satu). Nilai yang di dapat berfungsi untuk menandakan seberapa optimal solusi yang di peroleh. Pada penelitian ini, nilai yang di hasilkan pada fungsi *fitness* untuk mempresentasikan nilai error pada bobot jaringan. Fungsi *fitness* yang digunakan untuk menghitung nilai *fitness* suatu partikel:

$$Fitness = \frac{1}{(1 + error)} \tag{1}$$

3. PEMBAHASAN DAN HASIL

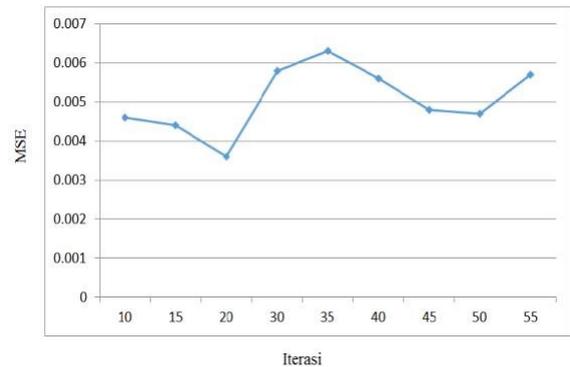
Nilai parameter yang sesuai pada PSO memberikan pengaruh besar kepada kinerja dari algoritma, oleh karena itu sangat penting untuk melakukan pencarian nilai paramater yang optimal (Juneja, 2016). Pengujian terhadap parameter yang dilakukan terdiri atas uji coba banyaknya iterasi, nilai *learning rate* dan banyaknya *swarm*. Pengujian ini bertujuan untuk mencari nilai *Mean Squared Error* (MSE) terkecil. Hasil pengujian dapat dilihat pada tabel berikut :

Tabel 2. Pengujian Nilai Parameter

No	Iterasi	Learning Rate	Jumlah Swarm	MSE
1	10	0,1	10	0,043618
2	10	0,2	20	0,048769
3	10	0,3	30	0,009557
4	10	0,4	40	0,008882
5	10	0,5	50	0,010515
6	10	0,6	60	0,004941
7	10	0,7	70	0,004672
8	10	0,8	80	0,006281
9	10	0,9	90	0,004631
10	15	0,1	10	0,027657
11	15	0,2	20	0,008585
12	15	0,3	30	0,007154
13	15	0,4	40	0,007918
14	15	0,5	50	0,006801
15	15	0,6	60	0,008077
16	15	0,7	70	0,005271
15	15	0,8	80	0,004403
16	15	0,9	90	0,006585
17	20	0,1	10	0,025304
18	20	0,2	20	0,011332
19	20	0,3	30	0,006692
20	20	0,4	40	0,005711
21	20	0,5	50	0,009726
22	20	0,6	60	0,006721
23	20	0,7	70	0,005092
24	20	0,8	80	0,007821
25	20	0,9	90	0,004283
26	30	0,1	10	0,009262
27	30	0,2	20	0,008243
28	30	0,3	30	0,006634
29	30	0,4	40	0,007604
30	30	0,5	50	0,006153
:	:	:	:	:
73	55	0,1	10	0,054084
74	55	0,2	20	0,048993
75	55	0,3	30	0,049729
76	55	0,4	40	0,303776
77	55	0,5	50	0,00570
78	55	0,6	60	0,036237
79	55	0,7	70	0,054626
80	55	0,8	80	0,054656
81	55	0,9	90	0,054475

3.1 Hasil dan Analisa Uji Coba Dengan Banyak Iterasi

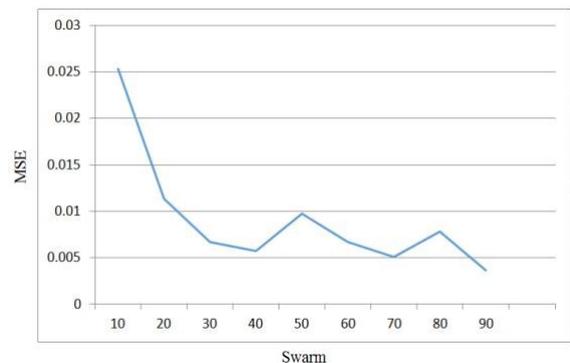
Uji coba banyaknya iterasi dilakukan untuk meliha pengaruh nilai *error* terhadap banyaknya iterasi yang dilakukan. Percobaan jumlah iterasi dilakukan percobaan sebanyak 9 kali (10,15,20,30,35,40,45,50 dan 55). Pada gambar 5 adalah uji coba banyak iterasi terhadap error, dimana error dalam hal ini MSE. Dari grafik pada gambar 3 terlihat pada nilai error paling rendah diperoleh pada jumlah iterasi ke 20.



Gambar 5. Hasil Uji Coba Jumlah Iterasi Terhadap Nilai *Error*

3.2 Hasil dan Analisa Uji Coba Dengan Jumlah Swarm

Uji coba dengan jumlah *swarm* yang bervariasi memiliki tujuan yang sama dengan uji coba pada banyaknya iterasi yaitu mencari error terkecil. Hasil uji coba tersebut dapat dilihat pada gambar 6.



Gambar 6. Hasil Uji Coba Nilai *Error* Terhadap Jumlah Swarm

Uji coba pada jumlah *swarm* dengan menggunakan learning rate 0.9. Dari gambar 6 dapat dilihat nilai error terkecil diperoleh dengan jumlah *swarm* adalah 90.

3.3 Hasil dan Analisa Uji Coba Sistem

Dari tabel 2 dan gambar 5 dan 6 dapat dilihat bahwa MSE (*mean squared error*) terendah diperoleh dari nilai iterasi = 20, *learning rate* = 0.9 dan jumlah *swarm* = 90. Nilai parameter optimum tersebut digunakan untuk pengujian, berikut hasil data *testing* dapat dilihat pada tabel 3.

Tabel 3. Hasil Prediksi dengan menggunakan JST dengan PSO

Data ke	Tanggal	Jam	Prediksi
1	2015-01-30	10	0,639218
2	2015-01-30	11	0,710632
3	2015-01-30	12	0,828006
4	2015-01-30	13	0,995104
5	2015-01-30	14	1,199168
6	2015-01-30	15	1,375203
7	2015-01-30	16	1,499549
8	2015-01-30	17	1,541944
9	2015-01-30	18	1,548077

Data ke	Tanggal	Jam	Prediksi
10	2015-01-30	19	1,528548
:	:	:	:
300	2015-02-11	16	1,355404

Perbandingan data hasil prediksi dengan data asli (aktual) dapat dilihat pada tabel 4 dan gambar 7. Akurasi hasil prediksi dihitung dengan menggunakan MAPE (*Mean Absolut Percent*).

Tabel 4. Perbandingan Hasil Prediksi dengan Data Aktual

Data ke	Data Aktual/Target	Prediksi	MAPE
1	0,6	0,639218	5,55559884 %
2	0,7	0,710632	0,827199767 %
3	0,8	0,828006	3,80895895 %
4	1	0,995104	0,166604442 %
5	1,2	1,199168	0,393202319 %
6	1,4	1,375203	1,499697356 %
7	1,5	1,499549	0,053652954 %
8	1,6	1,541944	3,683579376 %
9	1,6	1,548077	3,313233836 %
10	1,6	1,528548	4,59258619 %
:	:	:	:
300	0.589214	0.413797646	29.77124496 %

Rata-rata nilai akurasi prediksi dari 300 data pengujian adalah 92.56 %.



Gambar 7. Grafik Perbandingan Data Hasil Prediksi dengan Data Target

4. KESIMPULAN DAN SARAN

Berdasarkan hasil pengujian dan analisis pada jaringan syaraf tiruan menggunakan *Particle Swarm Optimization* untuk prediksi tinggi pasang surut air laut didapatkan nilai parameter terbaik adalah dengan iterasi sebanyak 20, jumlah swarm 90 dan nilai learning rate adalah 0.9 dimana dengan nilai-nilai tersebut didapat akurasi prediksi sebesar 91.56 %. Saran untuk pengembangan lebih lanjut dari penelitian ini adalah menggunakan nilai parameter yang lebih bervariasi pada pengujian parameter metode Jaringan Syaraf Tiruan dan *Particle Swarm Optimization* agar dapat menghasilkan akurasi prediksi yang lebih baik.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Lembaga Penelitian Pengabdian dan Penjaminan Mutu (LP3M) Universitas Maritim Raja Ali Haji (UMRAH) yang telah memberi dukungan keuangan terhadap penelitian ini.

DAFTAR PUSTAKA

BADRUL, M., 2013. Prediksi Hasil Pemilu Legislatif DKI Jakarta Dengan Metode Neural Network Berbasis Particle Swarm Optimization. *Techno Nusa Mandiri*, 9(1), pp. 37-47.

FADILAH., SURIPIN., dan SASONGKO. D.P.,2014. Menentukan Tipe Pasang Surut Dan Muka Air Rencana Perairan Lat Kabupaten Bengkulu Tengah Menggunakan Metode Admiralty. *Maspari Journal*. 6(1). pp. 1-12.

JAUHARI, D., HIMAWAN, A., dan DEWI, C. 2016. Prediksi Disribusi Air PDAM Menggunakan Metode Jaringan Syaraf Tiruan Backpropagation di PDAM Kota Malang. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 3(2), pp. 83-87.

JUNEJA, M., dan NAGAR, S. K. 2016. Particle Swarm Optimization Algorithm and Its Parameters: A review, *2016 International Conference on Control, Computing, Communication and Materials (ICCCCM)*. pp. 1-5.

KUSUMAWATI, D., WINARNO, W.W., dan ARIF, M.R., 2015. Prediksi Kelulusan Mahasiswa Menggunakan Metode Neural Network Dan Particle Swarm Optimization, *Seminar Nasional Teknologi Informasi dan Multimedia, STMIK AMIKOM Yogyakarta*, 6-8 Februari 2015.

NAYAK , S. C., MISRA, B.b., dan BEHERA, H.S., 2014. Impact of Data Normalization on Stock Index Forecasting, *International Journal of Computer Information Systems and Industrial Management Applications*, 6, pp. 257-269

PUJANTO, A., KUSRINI., dan SUNYOTO, ADI. 2018. Perancangan Sistem Pendukung Keputusan Untuk Prediksi Penerima Beasiswa Menggunakan Metode Neural Network Backpropagation. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 5(2), pp. 157-162.

RAHARJO, J.S.D., 2013. Model artificial Neural Network Berbasis Particle Swarm Optimization Untuk Prediksi Laju Inflasi. *Jurnal Sistem Komputer*, 3(1), pp. 10-21.

SAKINAH, N. P., CHOLISSODIN, I., dan WIDODO. A.W., 2017. Prediksi Jumlah Permintaan Koran Menggunakan Metode Jaringan Syaraf Tiruan Backpropagation. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 2(7), pp. 2612-2618

SUHENDRA, C.D., dan WARDOYO, R. 2015. Penentuan Arsitektur Jaringan Syaraf Tiruan Backpropagation (Bobot Awal dan Bias Awal) Menggunakan Algoritma Genetika. *International Journal of Computing and Cybernatics Systems*, 9(1), pp. 77-88.

Halaman ini sengaja dikosongkan