

# **BACKPROPAGATION NEURAL NETWORK BERBASIS PARTICLE SWARM OPTIMIZATION UNTUK PREDIKSI HARGA KARET SPESIFIK TEKNIS**

**Misrawati Aprilyana Puspa\***

*\*)*Tenaga Pengajar pada Sekolah Tinggi Manajemen Informatika & Komputer  
( STMIK ) Ichsan Gorontalo

E-mail : [watie.aprilyana@gmail.com](mailto:watie.aprilyana@gmail.com)

***Abstract:** Rubber is the commodity of the results of demand levels and agricultural production always has increased significantly from time to time. This is due to the high demand of the company's suppliers are the result of processed rubber to meet the needs of production. However, due to the influence of the conditions of the global economy so that it appears the instability of prices. The data used in this research in the form of a Univariate time series data is converted into the multivariate. The method used is the method of Back propagation Neural Network (BPNN) is applied to the data time series technical specific rubber commodity prices with the help of weighted optimization Particle Swarm Optimization (PSO) which hopefully may help to improve the performance of the prediction so that results of the RMSE for the prediction of rubber prices gained can be more accurate. Of research results obtained the best model on a back propagation neural network with the parameters for the training cycle 600, the learning rate and momentum 0.1 0.2, as well as neuron size 3 whereas in particle swarm optimization value of population size 8, max value. of generation 100, the value of inertia weight 0.3, the value of the local best weight 1.0 and global best value weight of 1.0 produces a better RMSE value i.e. 0.040 compared to just using the BPNN alone i.e. 0.043. This proves that the PSO method able to give better results.*

***Keywords:** Prediction of Time series, the technical specific rubber commodity prices, BPNN, PSO, RMSE*

## **PENDAHULUAN**

### **A. Latar Belakang**

**I**ndonesia adalah salah satu Negara yang dikenal dengan sumber kekayaan alamnya. Kekayaan alam yang dimiliki oleh Negara Indonesia terdapat pada beberapa sektor, antara lain sektor pertanian, sektor pertambangan dan sektor perkebunan. Hasil dari sektor yang ada merupakan primadona yang menjadi salah satu komoditas unggulan dimana memberikan kontribusi besar terhadap Negara Indonesia. Salah satu sektornya adalah sektor perkebunan berupa komoditi tebu, karet, jeruk, kelapa sawit, minyak kelapa, kopi dan masih banyak lagi. Sektor usaha yang ada sangat diharapkan dapat memberikan berkontribusi terhadap pertumbuhan ekonomi, pembukaan kesempatan lapangan kerja, serta

mengurangi kemiskinan yaitu sektor pertanian secara umum termasuk didalamnya sektor perkebunan. Keberadaan dan pengembangan sektor ini memiliki peran yang penting dan strategis sehingga memerlukan upaya revitalisasi dan pengembangan di berbagai aspek.

Menurut Direktorat Jenderal Perkebunan karet merupakan salah satu komoditas yang selama ini menjadi primadona dan andalan ekspor di Indonesia. Produksi karet alam Indonesia cukup besar dan layak untuk diperhitungkan dalam pasar Internasional. Indonesia merupakan negara penghasil karet alam terbesar di dunia setelah Thailand [DIRJEN Perkebunan, Ekspor dan Import, 2011]. Karet merupakan komoditi dari hasil pertanian dimana tingkat permintaan dan produksinya selalu mengalami peningkatan secara signifikan dari waktu ke waktu. Hal ini diakibatkan karena tingginya permintaan dari perusahaan pemasok hasil dari olahan karet untuk memenuhi kebutuhan produksinya. Komoditas karet sangat dikenal dan sudah dibudidayakan dalam jangka waktu yang relatif lebih lama dibandingkan dengan beberapa komoditas perkebunan lainnya. Agroindustri karet alam ini memiliki peran yang sangat penting karena bisa menjadi sumber devisa negara, sumber lapangan kerja, dan sebagai pemasok dari bahan baku industri barang jadi yang terbuat dari karet.

Berdasarkan keadaan diatas untuk harga karet spesifik teknis pada spot Palembang mengalami fluktuasi harga yang naik turun dikarenakan adanya pengaruh dari kondisi perekonomian global, dimana tingkat fluktuasi baik karena kelebihan maupun kekurangan produksi sehingga sangat berpengaruh terhadap perubahan harga karet spesifik teknis di pasar Internasional.

Fluktuasi harga merupakan suatu resiko dalam dunia perdagangan. Oleh karena itu diperlukan adanya suatu sistem yang dapat memprediksi harga karet spesifik teknis, sehingga dapat membantu petani dan pedagang maupun pihak yang terkait dalam mengambil keputusan untuk melakukan proses transaksi jual beli harga komoditi karet spesifik teknis agar dapat meminimalisir kerugian dan memaksimalkan pendapatan. Untuk menyikapi fluktuasi tersebut maka diperlukan suatu metode untuk memprediksi harga karet spesifik teknis. Metode yang diusulkan adalah model prediksi dengan menggunakan *backpropagation neural network* berbasis *particle swarm optimization* untuk optimasinya. Kemampuan ANN dalam pembelajaran terhadap data training dilakukan melalui *backpropagation*, namun ada beberapa kelemahan antara lain laju konvergensi yang lambat dan terjebak dalam minimum local. Untuk mengatasi permasalahan ada beberapa pendekatan optimasi seperti *genetic algoritma (GA)*, *ant colony optimization (ACO)*, dan *particle swarm optimization*. Untuk mengatasi masalah optimalisasi bobot jaringan maka digunakan *Particle Swarm Optimization (PSO)*, karena merupakan salah satu teknik AI terbaik untuk optimasi dan perkiraan

parameter dan menggabungkan ANN dan algoritma PSO meningkatkan kinerja dibandingkan dengan ANN saja [Joko, 2013: 10].

Berdasarkan uraian di atas penelitian ini akan membuat model yang diharapkan mampu untuk memprediksi harga komoditi karet spesifik teknis pada spot Palembang kedepan dengan menghasilkan nilai RMSE yang lebih baik.

## **B. Rumusan Masalah**

Tampak terlihat pada permasalahan prediksi harga karet yang perlu mendapatkan perhatian khusus. Hal ini terkait dengan pengambilan keputusan untuk melakukan pembelian ataupun penjualan karet spesifik teknis. Sementara itu algoritma prediksi yang ada saat ini cukup bervariasi dengan tingkat akurasi yang relatif masih rendah. Untuk itu dirumuskan permasalahan bagaimana meningkatkan akurasi prediksi dengan memanfaatkan penggunaan *particle swarm optimization* untuk melakukan optimasi bobot pada *backpropagation neural network*.

## **C. Tujuan Penelitian**

Tujuan pada penelitian untuk melakukan prediksi harga komoditi karet spesifik teknis dengan menggunakan model *Backpropagation Neural Network* berbasis *particle swarm optimization* agar dapat digunakan sebagai bahan pertimbangan dalam pengambilan keputusan bagi pihak yang terkait serta untuk mengetahui pengaruh optimasi *particle swarm optimization* dalam menghasilkan nilai RMSE lebih baik.

## **TINJAUAN PUSTAKA**

### **A. Prediksi Time Series**

Pada umumnya, prediksi dengan menggunakan metode *time series* merupakan suatu langkah agar nilai dimasa yang akan datang dapat diketahui, dimana pengamatan pada metode *time series* dilakukan berdasarkan urutan waktu. Metode *time series* dibangun berdasarkan proses determinasi yang mempunyai kemampuan prediksi yang tinggi, dimana nilai yang akan datang dapat diketahui dengan melihat nilai dari masa lalu. Hasil prediksi dapat dilihat secara keseluruhan.

### **B. Particle Swarm Optimization**

*Particle swarm optimization* (PSO), merupakan algoritma yang didasarkan pada perilaku pada sebuah kawanan serangga, seperti semut, rayap, lebah atau burung. Algoritma ini menirukan perilaku sosial organisme ini. Perilaku sosial ini terdiri atas tindakan individu sertaberdasarkan signal yang kuat pada komponen determinan [Aris, 2005]. Pengaruh dari individu-individu lain dalam suatu kelompok. Metode optimasi ini didasarkan pada *swarm intelligence* yang disebut

dengan algoritma *behaviorally inspired* dimana sebagai alternatif dari algoritma genetika, yang sering disebut dengan *evolution-based procedures*. Algoritma PSO ini awalnya diusulkan oleh [Kennedy, 1995].

Dalam PSO, pencarian solusi optimal akan dilakukan sampai semua partikel memiliki skema solusi yang sama atau ketika iterasi maksimum sudah tercapai. Formulasi untuk *update* kecepatan dan posisi pada iterasi selanjutnya adalah sebagai berikut:

$$V_{k+1} = V_k + c_1 \cdot R_1 \cdot (Pbest_k - X_k) + c_2 \cdot R_2 \cdot (Gbest_k - X_k) \quad (1)$$

dengan,  $k : 1, 2, 3, \dots, N$ ;  $V_{k+1}$ : kecepatan untuk posisi yang dituju;  $V_k$ : kecepatan untuk posisi sekarang (awal);  $Pbest_k$ : *Personal best*;  $Gbest_k$ : *Global best*;  $c_1, c_2$ : *learning rates*. Untuk kemampuan individu dan pengaruh sosial group yang menunjukkan bobot dari memori sebuah partikel terhadap memori dari kelompoknya, nilai dari  $c_1, c_2$  biasanya merupakan konstanta dengan nilai  $c_1 = 2$  dan  $c_2 = 2$ ;  $R_1, R_2$ : angka acak antara 0 dan 1;  $X_{k+1}$ : Posisi yang dituju;  $X_k$ : Posisi sekarang. Selanjutnya, konsep bobot inersia (*inertia weight*) dikembangkan oleh Shi dan Eberhart pada tahun 1998 [Eberhart, 2001] untuk pengendalian yang lebih baik pada eksplorasi dan eksploitasi. Motivasinya adalah untuk dapat menghilangkan kebutuhan  $V_{max}$ . Sehingga *update* persamaan kecepatan menjadi:

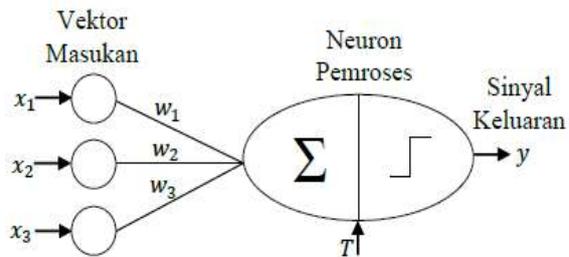
$$V_{k+1} = \omega \cdot V_k + c_1 \cdot R_1 \cdot (Pbest_k - X_k) + c_2 \cdot R_2 \cdot (Gbest_k - X_k) \quad (2)$$

Untuk setiap partikel pada PSO akan dinilai posisi terbaiknya dengan mengimplementasikannya pada *Neural Network*. Data yang ditraining dilakukan secara bertahap yakni dimulai dari 1 variabel periode sampai pada tingkat atau jumlah variabel periode yang menghasilkan performa dengan nilai *error* terkecil untuk membandingkan data mana yang menghasilkan prediksi paling baik. Didalam tahap ini parameter – parameter yang ada dilakukan secara *trial and error* dengan menentukan *population size*, *maximum number*, *inertia weight*, *local best weight*, *global best weight*, *min weight*, dan *max weight*, dan nilai validasi yang disesuaikan.

### C. Neural Network

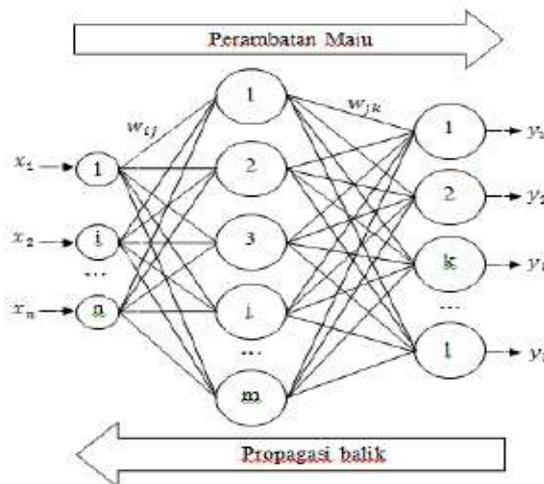
Kelemahan pada metode *Neural Network* terdiri dari layar tunggal membuat perkembangan metode *Neural Network* ini menjadi terhenti pada sekitar tahun 1970 an. Penemuan *backpropagation* yang terdiri dari beberapa layar membuka kembali cakrawala. Terlebih setelah berhasil ditemukan berbagai aplikasi yang dapat diselesaikan dengan *backpropagation*, membuat metode *Neural Network* ini semakin diminati orang [Siang, 2009]. Metode *Neural Network* dengan layar tunggal memiliki keterbatasan didalam pengenalan pola. Kelemahan ini bisa diselesaikan dengan menambahkan satu ataupun beberapa layar tersembunyi diantara layar masukan dan keluaran. Meskipun penggunaan

penggunaan lebih dari satu layar tersembunyi memiliki kelebihan manfaat untuk beberapa kasus, tapi pelatihnannya memerlukan waktu yang lama. Maka umumnya orang mulai mencoba dengan sebuah layar tersembunyi lebih dahulu [Hsieh, 2011] Ada banyak proses pelatihan pada *Neural Network*, antara lain *Perceptron*, *Backpropagation*, *Self-Organizing Map (SOM)*, *Delta*, *Associative Memory*, *Learning Quantization*, dan sebagainya [Joko, 2013].



#### D. Backpropagation

Backpropagation banyak digunakan untuk menyelesaikan permasalahan, salah satunya adalah prediksi. Cara pelatihan metode ini sama dengan *Perceptron* yaitu sejumlah data latih sebagai pola masukan diberikan pada jaringan kemudian dihitung pola keluaran dan jika terdapat *error* maka bobot dalam jaringan akan diperbarui untuk mengurangi *error* tersebut. *Error* disini adalah perbedaan antara target keluaran yang diinginkan dengan nilai keluaran. BP (*Backpropagation*) menggunakan pendekatan *steepest descent* dengan performansi indexnya adalah *mean square error* (MSE) [Joko, 2013]. *Backpropagation* merupakan penurunan gradien dengan meminimalkan kuadrat eror *output* atau keluaran. Ada tiga tahapan dalam pelatihan jaringan yaitu : *forward propagation* atau perambatan maju, tahap perambatan balik dan tahap perubahan bobot dan bias. Jaringan ini mempunyai arsitektur yang terdiri dari *input layer*, *hidden layer* dan *output layer* [Hsieh, 2011].



Gambar 2 Arsitektur ANN Backpropagation [Joko, 2013]

## METODE PENELITIAN

### A. Pengumpulan Data

Pengumpulan data merupakan langkah awal pada suatu penelitian dimana data yang digunakan pada penelitian ini adalah data sekunder yaitu data yang di peroleh dari Badan Pengawas Perdagangan Berjangka Komoditi (BAPPEBTI). *Dataset* tersebut untuk hari sabtu dan minggu tidak terjadi transaksi serta tanggal merah setiap tahunnya kosong dan hanya terdiri satu variabel harga.

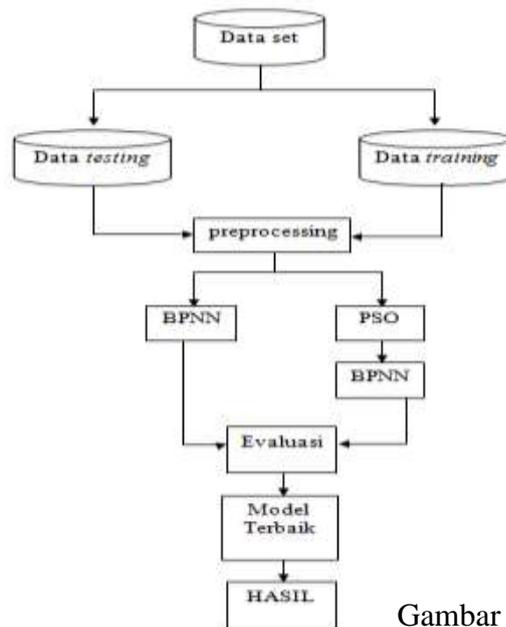
**Tabel 1.** Harga karet perminggu

<b>minggu ke -</b>	<b>Harga</b>
minggu 1 tahun 2005	9985
minggu 2 tahun 2005	9916
minggu 3 tahun 2005	9818
minggu 4 tahun 2005	9813
minggu 5 tahun 2005	9839
.....	.....
minggu ke 48 tahun 2015	15436
minggu ke 49 tahun 2015	15736
minggu ke 50 tahun 2015	15748
minggu ke 51 tahun 2015	15619
minggu ke 52 tahun 2015	15532

Data harga karet spesifik teknis ini merupakan data *time series* harian yang diubah menjadi mingguan. Data tersebut merupakan data *univariate*, yaitu data yang hanya memiliki 1 *attribute* (harga karet) tanpa ada *attribute* lain yang saling mempengaruhi.

### B. Desain Eksperimen

Eksperimen dan pengujian yang dilakukan pada penelitian ini menggunakan alat bantu software *Rapidminer* untuk mengimplementasikan algoritma *Neural Network* dengan optimasi *Particle Swarm Optimization* (PSO) dengan menentukan jumlah data training dan data testing. Langkah-langkah eksperimen dan pengujian dalam menentukan model prediksi pada penelitian ini dapat ditunjukkan pada Gambar 1.



Gambar 1. Desain Eksperimen

Berdasarkan dari model yang diusulkan di atas, dimana dari *data set* yang diperoleh akan dibagi menjadi dua buah *data set*, yaitu *data training* dan *data testing*. Setelah *data set* dibagi menjadi dua, langkah selanjutnya adalah tahap *preprocessing*. *Preprocessing data* dilakukan secara manual dengan menggunakan *Microsoft Excel*. Dimana *data* yang akan digunakan dirubah terlebih dahulu, dari *ascending* menjadi *descending* untuk menyesuaikan urutan hari yang ada dalam dataset, sehingga *data* dapat diolah untuk prediksi. *Data* yang diperoleh pada awalnya masih bersifat *univariate* dan diubah menjadi *multivariate*. Perubahan *data* dari *univariate* menjadi *multivariate* bertujuan agar dapat memberikan hasil akurasi yang lebih baik atau nilai error yang kecil. Kemudian *data training* dan *data testing* dijadikan dalam beberapa variabel *independent*, seperti 1 periode sampai beberapa periode dengan masing-masing 1 variabel *dependent*. Contoh *data* 1 periode seperti  $x_{t-1} : x_t$ , 2 periode seperti  $x_{t-2}, x_{t-1} : x_t$ , 3 periode seperti  $x_{t-3}, x_{t-2}, x_{t-1} : x_t$  dan 4 periode seperti  $x_{t-4}, x_{t-3}, x_{t-2}, x_{t-1} : x_t$ , dst. *Data training* diubah menjadi beberapa periode agar dapat mengetahui pola *data* paling baik untuk prediksi harga komoditi karet spesifik teknis.

Langkah selanjutnya adalah menentukan parameter pada *backpropagation neural network* dan *particle swarm optimization*. Penentuan parameter pada *Neural Network*, antara lain Training Cycle, Learning Rate, dan Momentum untuk mendapatkan model terbaiknya. Setelah mendapatkan model terbaik menggunakan BPNN proses selanjutnya yaitu mengoptimasi model terbaik tersebut dengan *particle swarm optimization* dengan melakukan *trial and error* dengan beberapa

parameter antara lain *population size, maximum number, inertia weight, local best weight, global best weight, min weight, dan max weight*. Tujuannya adalah untuk peningkatan kinerja metode dan mengetahui variabel yang paling baik dalam menghasilkan nilai prediksi. Untuk setiap partikel pada PSO akan dinilai posisi terbaiknya dengan mengimplementasikannya pada BPNN. Data yang ditraining dilakukan secara bertahap yakni dimulai dari 1 variabel periode sampai pada tingkat atau jumlah variabel periode yang menghasilkan performa dengan nilai error terkecil untuk membandingkan data mana yang menghasilkan prediksi paling baik

### C. Pengolahan Data

Dalam tahap ini data yang digunakan dan diolah merupakan data univariat *time series* yang hanya memiliki satu variabel yaitu variabel harga berupa data numerik. Pengolahan data dilakukan dengan mengubah data tersebut dari data univariat menjadi multivariat, yaitu mengubah data mulai dari 1 periode sampai 5 periode. *Time series multivariate* memodelkan peubah-peubah yang berkorelasi dan tercatat dari waktu ke waktu. Pola data yang digunakan dalam Tabel 1 mengubah data univariat menjadi multivariat, ditunjukkan pada pola atau modelnya, sebagai berikut:

**Tabel 2.** Pola data time series univariat [Purwanto, 2010]

Pola	Input lag	Output/ Target
1	$X_1, X_2, X_3, X_4, \dots, X_p$	$X_{p+1}$
2	$X_2, X_3, X_4, X_5, \dots, X_{p+1}$	$X_{p+2}$
3	$X_3, X_4, X_5, X_6, \dots, X_{p+2}$	$X_{p+3}$
...	...	
m-p	$X_{m-p}, X_{m-p+1}, X_{m-p+2}, \dots, X_{m-1}$	$X_m$

## HASIL DAN PEMBAHASAN

### A. Hasil Eksperimen

Pada eksperimen dan pengujian pada penelitian ini dilakukan *preprocessing*. Tahap pertama pada *preprocessing* yaitu pengolahan data dimana mengubah data harian menjadi data mingguan. Perubahan ini dikarenakan *weekend* (sabtu dan minggu) dan tanggal merah tidak terjadi transaksi. Perubahan ini juga dilakukan secara manual menggunakan *Microsoft Excel* dengan cara menjumlahkan harga pada minggu yang sama kemudian dirata-ratakan agar mendapatkan harga pada minggu tersebut.

Tabel 3 Contoh Data mingguan harga karet spesifik teknis

No	minggu ke -	Harga (Rp)
1	minggu 1	9985
2	minggu 2	9916
3	minggu 3	9818
4	minggu 4	9813
5	minggu 5	9839
6	minggu 6	9886
7	minggu 7	9956
8	minggu 8	9940
....	.....	.....

Tahap kedua adalah tahap normalisasi data yang digunakan untuk mengelompokkan data ke dalam skala atau jangkauan tertentu sehingga mempermudah dalam mengolah data. Normalisasi data pada penelitian ini menggunakan normalisasi data dalam jangkauan [0,1]. *Preprocessing data* dilakukan terlebih dahulu menggunakan *Microsoft Excel*. Untuk menghitung normalisasi data dalam jangkauan [0,1] dapat ditunjukkan pada persamaan (4)

$$newdata = \frac{(data-min) * (newmax-newmin)}{(max-min) + newmin} \quad (4)$$

Keterangan :

$$newmax = 1$$

$$newmin = 0$$

min = nilai minimum dari seluruh data

max = nilai maksimum dari seluruh data

data = harga karet spesifik data

Tabel 4. Contoh Hasil Normalisasi Data

No	minggu ke -	Harga (Rp)	harga (hasil normalisasi)
1	minggu 1	9985	0,053266352
2	minggu 2	9916	0,051863
3	minggu 3	9818	0,049869834
4	minggu 4	9813	0,049768142
5	minggu 5	9839	0,050296941
6	minggu 6	9886	0,051252847
7	minggu 7	9956	0,052676538
8	minggu 8	9940	0,052351123
..	.....	....	.....

Dari hasil normalisasi tersebut kemudian diubah menjadi bentuk data multivariate untuk menentukan jumlah variabel terbaik. Untuk penelitian ini

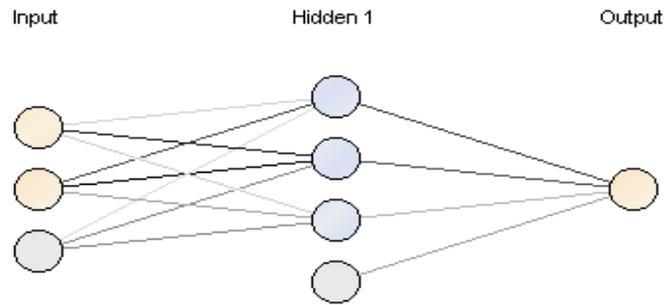
dilakukan uji coba dengan mengubah menjadi beberapa variabel. Setelah itu tahap selanjutnya adalah menentukan parameter BPNN dan *Particle Swarm Optimization* (PSO). Dalam menentukan parameter BPNN dan PSO dilakukan beberapa pengujian yaitu penentuan jumlah variabel input atau variabel periode  $x_{t-i}$  dan menetapkan nilai k-fold cross validation sebagai pembagian data, pengujian ini dilakukan untuk memperoleh model yang terbaik dengan melihat nilai *Root Mean Square Error* (RMSE) terkecil. Setelah melakukan tahapan – tahapan diatas, tahap selanjutnya yaitu mengaplikasikan model yang terbaik antara model yang dihasilkan algoritma BPNN atau BPNN berbasis *Particle Swarm Optimization* (PSO) terhadap data testing didalam melakukan prediksi.

Pada proses eksperimen, digunakan beberapa sampel data set untuk melakukan uji coba, kemudian diteruskan dengan penentuan parameter. Sebelum memulai proses uji coba, nilai parameter yang digunakan untuk proses uji coba sama dengan nilai parameter yang digunakan untuk training yaitu nilai variabel independen atau variabel periode  $x_{t-i}$  dari 1 sampai dengan beberapa variabel dimana 1 variabel dependen, number of validation 10, parameter defaultnya yakni training cycle 100 sampai dengan 2000, learning rate 0.1 sampai dengan 1, momentum 0 sampai dengan 1, penentuan *hidden layer* adalah 1 dengan menguji *neuron size* 1 sampai dengan 30 dan *neuro n size* 1 sampai 15 lalu dilakukan proses testing untuk mendapatkan *Root Mean Square Error* (RMSE).

## **B. Hasil Pengujian dengan BPNN**

Untuk menentukan model terbaik antara 1 variabel periode sampai dengan 5 variabel periode pada data karet spesifik teknis menggunakan number of validation 10 dan type kernel *numeric*, dimana hasil eksperimen model dari metode *neural network* dengan menggunakan *Rapidminer* yang diukur dengan menggunakan RMSE. Penentuan parameter pada *neural network* digunakan untuk menemukan model terbaik untuk melakukan prediksi, yaitu dengan mencari nilai terbaik dari setiap parameter yang ada.

Setelah mendapatkan model terbaik dari BPNN, maka model yang terpilih dilanjutkan pada eksperimen selanjutnya yaitu dengan menentukan parameter – parameternya antara lain training cycle, learning rate dan momentum serta hidden layer. Dengan hasil eksperimennya mendapatkan RMSE paling kecil yaitu 0.043 dengan satu hidden layer diperoleh nilai RMSE terkecil yaitu pada size 3, trining cycle 600, learning rate 0,1 dan momentum 0,2. Arsitektur BPNN terbaik yang diperoleh berdasarkan eksperiment yang telah dilakukan dapat dilihat pada gambar di bawah.



Gambar 4. Arsitektur BPNN karet spesifik teknis

Arsitektur terbaik ini menunjukkan terdiri tiga lapisan yaitu *input layer*, *hidden layer*, dan *output layer*. Dimana pada *input layer* memiliki dua *neuron input* yaitu  $X_{t-1}$ , dan  $X_{t-2}$  ditambah dengan bias; sedangkan pada *hidden layer* memiliki 3 *neuron hidden* di tambah dengan bias; dan *output layer* memiliki 1 *neuron output*.

Hidden 1  Node 1 (Sigmoid) ----- $X_{t-1}$ : -0.525 $X_{t-2}$ : 2.129 Bias: 0.440	Node 3 (Sigmoid) ----- $X_{t-1}$ : 0.578 $X_{t-2}$ : 1.088 Bias: -1.415
Node 2 (Sigmoid) ----- $X_{t-1}$ : -2.706 $X_{t-2}$ : 3.025 Bias: -1.418	Output  Node 1: 2.275 Node 2: -2.056 Node 3: 0.882 Threshold: -1.146

Keterangan :

Nilai – nilai bobot pada node 1 hingga node 3 pada 1 *hidden layer* tersebut merupakan nilai bobot dan bias penghubung pada *input* untuk mendapatkan nilai masing-masing neuron dalam hidden layer, sedangkan pada nilai bobot pada node 1 sampai node 3 dan nilai threshold pada output merupakan penghubung dari hidden layer untuk mendapatkan nilai pada output.

### C. Hasil Pengujian dengan BPNN dan PSO

Pada pengujian dengan menggunakan *backpropagation neural network* dan *particle swarm optimization* ini, model *backpropagation neural network* yang digunakan adalah model yang sudah dilakukan percobaan sebelumnya dengan parameter terbaik. Inisialisasi komponen-komponen pada *particle swarm optimization*, jumlah partikel pada *neural network* merupakan representasi dari partikel pada *particle swarm optimization*.

Pada tahap sebelumnya telah dihasilkan model terbaik dengan menggunakan BPNN untuk 1 variabel periode sampai dengan 5 variabel periode dimana nilai *training cycle*, *learning rate*, *momentum*, dan *neuron size* masing-masing sebesar 600, 0.1, 0.2, dan 3 dengan 2 variabel periode dan memperoleh hasil RMSE nya yaitu 0.043. Tahap ini merupakan hasil eksperimen model dari metode *backpropagation neural network* berbasis *particle swarm optimization* dengan menggunakan *Rapidminer* yang diukur dengan menggunakan RMSE. Eksperimen dilakukan *trial and error* dengan sejumlah parameter – parameter yang sudah ada baik untuk BPNN maupun untuk PSO. Hasil yang diperoleh dari eksperimen ini menyatakan bahwa nilai RMSE yang didapatkan lebih rendah. Berikut ini adalah hasil percobaan untuk menentukan model terbaik dari *backpropagation neural network* berbasis *particle swarm optimization*.

**Tabel 6.** Hasil pengujian PSO

Populasi	Max. of generation	Bobot inersia	Bobot Local best	Bobot Global best	RMSE
8	100	0.3	1	0,1	0.042
8	100	0.3	1	0,2	0.041
8	100	0.3	1	0,3	0.041
8	100	0.3	1	0,4	0.042
8	100	0.3	1	0,5	0.042
8	100	0.3	1	0,6	0.041
8	100	0.3	1	0,7	0,041
8	100	0.3	1	0,8	0.042
8	100	0.3	1	0,9	0.041
<b>8</b>	<b>100</b>	<b>0.3</b>	<b>1</b>	<b>1</b>	<b>0.040</b>

Terlihat dari hasil percobaan pada tabel 6., bahwa untuk pengujian dengan menggunakan BPNN berbasis PSO dengan parameter-parameter yang ada menghasilkan nilai RMSE rendah. Dimana untuk parameter PSO untuk nilai *max.of generation* 100 dan *inertia weight* 0.3 dengan nilai *local best weight* 1.0 dan nilai *global best weight* 1.0 mendapatkan nilai RMSE terkecil yaitu 0.040.

Berdasarkan hasil eksperimen yang telah dilakukan dengan BPNN berbasis PSO menggunakan parameter – parameter terbaik dan mendapatkan hasil RMSE terkecil yaitu 0,040 pada variabel periode 2. Sesuai hasilnya pengolahan model *particle swarm optimization* menampilkan bahwa nilai *attribute weights* menampilkan nilai pada variabel Xt 1, Xt 2 dan Xt 3 adalah 1 dan nilai pada variabel Xt 4, dan Xt 5 adalah 0. Dengan demikian variabel yang dianggap signifikan adalah variabel Xt 1, variabel Xt 2 dan variabel Xt 3.

#### D. Perbandingan Model

Berikut ini adalah hasil perbandingan nilai RMSE yang dihasilkan dari percobaan yang sudah dilakukan, yaitu percobaan menggunakan *backpropagation neural network* dan *backpropagation neural network* berbasis *particle swarm optimization*.

Tabel 7 Perbandingan Hasil RMSE

Metode	RMSE
<i>backpropagation neural network</i>	0.043 +/- 0.026 (mikro: 0.051 +/- 0.000)
<i>backpropagation neural network</i> berbasis <i>Particle Swarm Optimization</i>	0.040 +/- 0.029 (mikro: 0.049 +/- 0.000)



Gambar 5 Perbandingan Hasil RMSE

Dari gambar diatas menunjukkan bahwa nilai RMSE yang diperoleh dari percobaan menggunakan *backpropagation neural network* berbasis *particle swarm optimization* lebih baik dibandingkan dengan hasil RMSE yang diperoleh dari percobaan menggunakan *backpropagation neural network* saja.

#### KESIMPULAN

Peramalan harga komoditi karet spesifik teknis dengan menggunakan algoritma BPNN berbasis PSO berhasil dilakukan. Berdasarkan hasil penelitian nilai RMSE terendah di dapat pada *backpropagation neural network* berbasis *particle swarm optimization* dengan parameter untuk nilai *training cycle* 600, *learning rate* 0.1 dan *momentum* 0.2, serta *neuron size* adalah 3 dan pada *particle swarm optimization* nilai *population size* 8, nilai *max.of geneation* 100, nilai

*inertia weight* 0.3, nilai *local best weight* 1.0 dan nilai *global best weight* 1.0 menghasilkan nilai RMSE yang lebih baik. Pengujian dengan menggunakan *backpropagation neural network* saja menghasilkan nilai RMSE sebesar 0.043 sedangkan dengan menggunakan model *backpropagation neural network* yang dioptimasi dengan *particle swarm optimization* menghasilkan nilai RMSE yang lebih kecil yaitu 0.040. Dari hasil RMSE yang diperoleh membuktikan bahwa metode optimasi *Particle Swarm Optimization* dalam optimasi bobot pada *backpropagation neural network* terbukti dapat meningkatkan kinerja dari algoritma dan menghasilkan nilai RMSE yang lebih baik dibandingkan dengan tanpa menggunakan metode optimasi.

#### DAFTAR RUJUKAN

- Direktorat Jenderal Perkebunan, *Eksport and Import in Indonesia*, www.ditjenbun.deptan.go.id., 2011. (Diakses pada 3 Desember 2015)
- Hsieh, L.-F., Hsieh S.-C., and Tai P.-H., “Enhanced stock price variation prediction via DOE and BPNN-based optimization,” *Expert Systems with Applications*, May 2011
- J. Kennedy and R. C. Eberhart. *Particle swarm optimization*. In *Proceedings of the 1995 IEEE International Conference on Neural Networks*. IEEE Service Center, Piscataway, 1995.
- Purwanto, C. Eswaran, Logeswaran, *Improved Adaptive Neuro-fuzzy Inference System for HIV/AIDS Time Series Prediction*, Multimedia University. Malaysia. 2010
- Raharjo, Joko S. Dwi, 2013, Model Artificial Neural Network Berbasis Particle Swarm Optimization Untuk Prediksi Laju Inflasi, *Jurnal Sistem Komputer*,3,pp.10-21
- R. Eberhart, Y. Shi, *Particle Swarm Optimization : Development, Applications and Resources*. Indiana Polis, USA: Purdue School Of Engineering and Technology., 2001.
- Sularno, Aris, *Prediksi Nilai Saham Menggunakan Pemrograman Genetik dan Pemrograman Ekspresi Gen*, Universitas gunadarma. 2005
- Siang , J.J., “Jaringan Syaraf Tiruan dan Pemrogramannya menggunakan MATLAB,” Yogyakarta: C.V ANDI OFFSET , 2009, pp. 97–124.