

PARTICLE SWARM OPTIMIZATION SEBAGAI PENENTU NILAI BOBOT PADA ARTIFICIAL NEURAL NETWORK BERBASIS BACKPROPAGATION UNTUK PREDIKSI TINGKAT PENJUALAN MINYAK PELUMAS PERTAMINA

Muhammad Ali Ridla¹⁾

¹⁾Manajemen Informatika, Universitas Ibrahimy Sukorejo Situbondo
email: el.riedla@gmail.com

Abstract

The lubricating oil industry is one part of the oil and gas sector which is still one of the main pillars of economic growth in Indonesia. Sales predictions are needed by companies and policy makers as planning materials and economic development strategies to increase income in the future. Predictions that have a better level of accuracy can provide appropriate decisions. Various methods have been used, the Artificial Neural Network algorithm is one of the most widely used, especially in the Backpropagation (BPNN) structure which can predict non linear time series data. Backpropagation has been proven to have a better level of accuracy compared to econometric methods such as ARIMA. The integration of Backpropagation algorithm with other algorithms needs to be done to overcome the shortcomings and improve the ability of the National Land Agency itself. Particle Swarm Optimization (PSO) which is used as an optimization determinant of attribute weight values in the network structure of BPNN shows good results. After testing, BPNN without PSO has a Squared Error (SE) level of 0.012 and a Root Mean Squared Error (RMSE) of 0.111. While BPNN with PSO has SE levels of 0.004 and RMSE of 0.059. This shows that there is a significant decrease in the error rate after the PSO algorithm is added to the BPNN structure which is 46.85%.

Keywords: forecasting sales neural network, attribute weight with pso.

1. PENDAHULUAN

Segala macam mesin membutuhkan minyak pelumas untuk mengawetkan usia penggunaan (*life time*) mesin. Secara matematis umur sebuah elemen mesin bisa sampai tak terhingga jika pelumasannya belangsung sempurna [1]. Seluruh jenis oli atau minyak pelumas berfungsi sebagai bahan pelumas supaya mesin berjalan lancar, mulus dan bebas gangguan. Oli juga berfungsi sebagai pendingin, peredam getaran, pengangkut kotoran pada motor bakar serta berfungsi sebagai perapat (*Seal*) pada sistem kompresi. Bahkan penggunaan oli yang tepat pada mesin dapat berfungsi sebagai penghematan pada konsumsi bahan bakar minyak [2].

Pesatnya perkembangan industri serta peningkatan secara drastis pada penambahan penggunaan kendaraan bermotor menjadi pendorong yang cukup signifikan pada peningkatan konsumsi bahan pendukung otomotif itu sendiri, baik berupa bahan bakar minyak maupun minyak pelumas. Pada tahun 1997 Pertamina menguasai 90% pangsa pasar di Indonesia. Namun dengan adanya pasar bebas pada tahun 2002 dengan diperbolehkannya perusahaan swasta memproduksi pelumas serta mengolah pelumas

bekas untuk didaur ulang menyebabkan penurunan yang cukup signifikan pada penguasaan pasar minyak pelumas Pertamina.

Beberapa faktor di atas dapat menjadi penyebab terjadinya fluktuasi, pasang dan surut pada penjualan minyak pelumas/oli khususnya pada minyak pelumas produksi Pertamina. Pengumpulan data dilakukan untuk memprediksi penjualan yang akan datang, data tersebut dapat dianalisa dan diproses menggunakan pendekatan statistik maupun menggunakan metode-metode yang dapat digunakan untuk menganalisa data. Beberapa penelitian telah dilakukan untuk memprediksi keadaan pada masa yang akan datang berdasarkan data pada masa-masa sebelumnya, Abhishek Singh dan G. C. Mishra 2015 membandingkan metode ARIMA (*Autoregressive Integrated Moving Average*) dengan ANN (*Artificial Neural Network*) untuk memprediksi harga minyak kacang tanah di Mumbai India dengan hasil penelitian menunjukkan bahwa ANN mampu melakukan prediksi lebih baik dari ARIMA dengan hasil perbandingan nilai RMSE untuk ARIMA sebesar 4.26 sedangkan untuk ANN sebesar 3.09 [3]. Laksana T.G. pada 2013, melakukan perbandingan metode ANN dengan SVM untuk

peramalan penduduk miskin di Indonesia dan diperoleh hasil nilai perbandingan RMSE dari kedua metode antara lain ANN memperoleh nilai RMSE sebesar 0.997 dan SVM sebesar 17.652 [4].

Metode *Artificial Neural Network* (ANN) dengan algoritma *Backpropagation* banyak digunakan dalam berbagai penelitian prediksi data rentet waktu karena kemampuannya yang cukup handal dalam melakukan prediksi atau peramalan pada data *non linier time series* [5]. *Backpropagation* memiliki beberapa kelemahan, diantaranya tingkat konvergensi yang relatif lambat dan selalu terjebak pada tingkat minimum local serta masalah pada waktu pelatihan yang cukup lama untuk menghasilkan output serta penggunaan fungsi kompleks pada seleksi, crossover dan perhitungan mutasi [6]. Untuk mengatasi hal tersebut, beberapa algoritma diusulkan sebagai solusi atas kelemahan tersebut diantaranya *Genetic Algorithm* (GA), *Ant Colony Optimization* (ACO), dan *Particle Swarm Optimization* (PSO). PSO merupakan algoritma komputasi berbasis populasi yang terinspirasi dari perilaku kawanan burung [7]. Pada penelitian sebelumnya dapat dibuktikan bahwa PSO secara individu memiliki kinerja yang paling baik dibanding GA dan ACO [8].

Dalam perkembangannya algoritma PSO dikombinasikan dengan algoritma ANN sebagai penyempurna untuk mendapatkan nilai rata-rata yang efektif dalam konvergensi dan lokasi global minimum [9]. Sehingga pada penelitian ini diusulkan algoritma ANN dengan struktur *Backpropagation* yang dikombinasikan dengan algoritma PSO sebagai penentuan nilai bobot pada atribut input (*attribute weighting*) dalam memprediksi penjualan minyak pelumas pertamina, dengan model yang dibuat pada penelitian ini diharapkan mampu memberikan hasil RMSE yang rendah sehingga diperoleh prediksi yang akurat.

Berdasarkan pembahasan di atas dapat dimunculkan sebuah pertanyaan penelitian, “Bagaimana pemodelan algoritma *Particle Swarm Optimization* pada *Artificial Neural Network* dengan struktur *Backpropagation* terhadap hasil prediksi penjualan minyak pelumas/oli pertamina?”. Tujuan penelitian ini adalah untuk melakukan pemodelan algoritma PSO pada ANN dengan struktur *Backpropagation* untuk memprediksi penjualan minyak pelumas pertamina.

Penelitian ini diharapkan bermanfaat untuk menambah pengetahuan tentang metode yang digunakan dalam penelitian serta sebagai informasi, bahan pertimbangan dan acuan dalam melakukan penelitian selanjutnya.

2. TINJAUAN PUSTAKA


2.1. Penelitian Terkait

Beberapa penelitian terkait yang telah dilakukan antara lain: *Penerapan metode Neural Network Backpropagation untuk Prediksi Harga Ayam* yang dilakukan oleh Nanik Susanti pada tahun 2014 dengan data *time series* sebanyak 1015 *record*. Diperoleh hasil yang optimal dan cukup akurat dengan arsitektur jaringan 1 lapisan input dengan 4 neuron dan 1 lapisan hidden layer dengan 10 neuron. Parameter yang dipakai yaitu fungsi aktivasi *tansig* dan fungsi pelatihan *tranrp* dengan nilai toleransi error 0,001, learning rate 0,05 serta maksimum epoch sebanyak 5000 memperoleh nilai MSE 0,0113 [10]. Prediksi Pemakaian Listrik dengan Pendekatan *Backpropagation* yang dilakukan oleh Ruliah S. dan R. Rolyadely pada tahun 2014. [11]. Pada percobaan dengan parameter (α) = 0.3, error = 10^{-5} dan maksimum epoch = 1000 dilakukan dengan struktur jaringan 1 lapisan input dengan 12 *neuron* dan 1 lapisan *hidden* dengan 25 *neuron* diperoleh nilai RMSE sebesar 0.011 serta pada percobaan berikutnya dengan 100 neuron pada 1 *hidden* layer menghasilkan nilai RMSE sebesar 0.0098

2.2. Landasan Teori

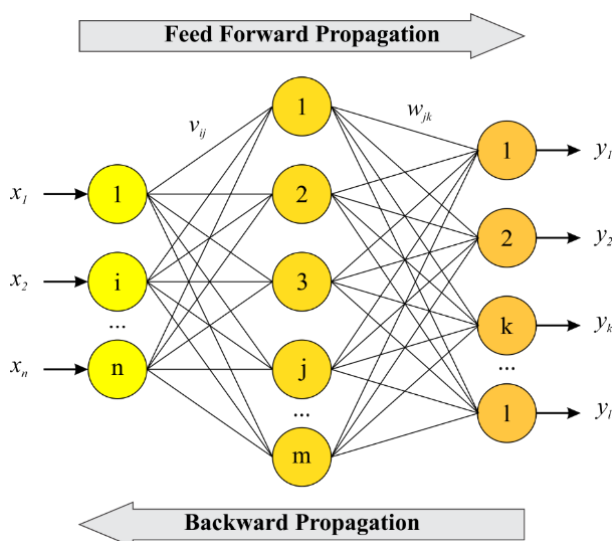
Forecasting adalah proses memperkirakan keadaan pada masa yang akan datang dengan melakukan penganalisaan data pada masa lampau. Data-data terdahulu secara sistematis dikombinasikan dengan metode yang telah ditentukan untuk mendapatkan estimasi masa depan [12]. *Artificial Neural Network* (ANN) merupakan sebuah model komputasi yang terinspirasi dari cara kerja otak manusia. *Neuron* alami menerima sinyal melalui *sinapsis* yang terletak pada *dendrit* atau *membran neuron*. Ketika sinyal yang diterima cukup kuat atau melampaui nilai *threshold* tertentu, maka *neuron* diaktifkan dan memancarkan sinyal melalui *akson*. Sinyal tersebut akan dikirim pada *sinapsis* lain sehingga dapat mengaktifkan *neuron* lainnya begitu seterusnya. Kompleksitas *neuron* pada otak manusia di terapkan pada model *neuron* buatan yang pada dasarnya terdiri dari *input* (seperti *sinapsis*)

yang dikalikan dengan bobot (kekuatan masing-masing sinyal) kemudian dihitung dengan fungsi matematika yang menentukan aktivasi *neuron*. Fungsi lain yang menentukan identitas akan menghitung *output* dari *neuron* buatan (tergantung pada *threshold* tertentu). ANN bekerja dengan menggabungkan *neuron* buatan untuk memproses informasi [13].



Gambar 1. Ilustrasi *neuron* buatan [23]

Backpropagation merupakan algoritma pelatihan ANN yang paling populer [13]. *Backpropagation* sendiri merupakan teknik pelatihan yang menggunakan sebagian data latih sebagai data *input* pada jaringan kemudian jaringan menghitung data *output*. Nilai *error* muncul apabila terdapat perbedaan antara target *output* yang diinginkan dengan nilai *output* yang diperoleh, jika hal tersebut terjadi maka akan dilakukan pembaharuan nilai bobot dalam jaringan untuk mengurangi *error* tersebut [14]. Algoritma *backpropagation* diusulkan untuk mengurangi kesalahan hingga ANN mempelajari data pelatihan. Pelatihan ini dimulai dengan bobot acak dengan tujuan untuk menyesuaikan hasil prediksi dengan nilai yang diharapkan sehingga meminimalisir kesalahan [13].



Gambar 2. Ilustrasi *neuron* *Backpropagation*

Backpropagation merupakan salah satu algoritma pembelajaran terawasi (*Supervised Learning*) yang menggunakan *error output* untuk mengubah nilai bobot yang dimilikinya dalam arah mundur (*backward*). Untuk memperoleh *error* ini, tahapan perambatan maju (*forward propagation*) harus dikerjakan terlebih dahulu. Pada saat perambatan maju dilaksanakan, seluruh *neuron* diaktifkan menggunakan fungsi aktivasi yang dapat dideferensiasikan, seperti fungsi aktivasi sigmoid [15]. Dalam pelatihannya algoritma *Backpropagation* terdiri dari 3 fase dengan langkah-langkah sebagai berikut:

- Menginisialisasi bobot pada jaringan secara acak.
- Tentukan nilai *epoch* dan *error* yang diharapkan.
- Lakukan langkah d sampai h apabila kondisi berhenti belum tercapai.
- Lakukan langkah e sampai g pada tiap data training.

e. Fase I, *Feed Forward Propagation*

- ❖ Jumlahkan seluruh sinyal yang masuk pada *neuron hidden*.

$$z_{net_j} = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (1)$$

Dengan:

z_{net_j} = Total sinyal *input* pada *neuron hidden j*

x_i = Nilai *input* pada *neuron i*.

v_{ij} = Bobot antara *neuron input i* dengan *neuron hidden j*.

- ❖ Menghitung keluaran seluruh *neuron hidden j* pada *hidden layer*.

$$z_j = f(z_{net_j}) = \frac{1}{1+e^{-z_{net_j}}} \quad (2)$$

Dengan:

z_j = Keluaran dari *neuron hidden j*

z_{net_j} = Total sinyal *input* pada *neuron hidden j*.

- ❖ Jumlahkan seluruh sinyal yang masuk pada *neuron output k*.

$$y_{net_k} = w_{0k} + \sum_{j=1}^m z_j w_{jk} \quad (3)$$

Dengan:

y_{net_k} = Total sinyal *input* pada *neuron output k*

z_j = Nilai *input* pada *neuron j*.

w_{jk} = Bobot antara *neuron hidden j* dengan *neuron output k*.

- ❖ Menghitung keluaran pada semua *neuron* pada *output layer*.

$$y_k = f(y_{net_k}) = \frac{1}{1+e^{-y_{net_k}}} \quad (4)$$

Dengan:

y_k = Keluaran dari neuron output k

y_{net_k} = Total sinyal input pada neuron output k .

f. Fase II, *Backward Propagation*

- ❖ Menghitung faktor kesalahan pada *output layer*

$$\delta_k = (t_k - y_k)y_k(1 - y_k) \quad (5)$$

Dengan:

δ_k = Faktor kesalahan dari *neuron output k*

t_k = Target pada *neuron output k*

y_k = Hasil keluaran *neuron output k*

- ❖ Menghitung suku perubahan bobot dari *hidden layer*.

$$\Delta w_{jk} = \alpha \delta_k z_j \quad (6)$$

Dengan:

α = *Learning rate* dengan nilai 0 hingga 1. Jika α bernilai kecil, maka perubahan bobot yang akan terjadi dalam setiap iterasi akan sedikit pula. Begitu pula dengan nilai *Learning Rate* yang akan berkurang selama proses pelaksanaan pembelajaran

- ❖ Menghitung penjumlahan *error* dari *neuron hidden*.

$$\delta_{net_j} = \sum_{k=1}^l \delta_k w_{jk} \quad (7)$$

- ❖ Menghitung faktor kesalahan pada *hidden layer*

$$\delta_j = \delta_{net_j} z_j(1 - z_j) \quad (8)$$

- ❖ Menghitung suku perubahan bobot dari *input layer*.

$$\Delta v_{ij} = \alpha \delta_j x_i \quad (9)$$

g. Fase III, Perubahan Bobot

- ❖ Mengubah bobot diantara *hidden layer* dan *output layer*

$$w_{jk}[t + 1] = w_{jk}[t] + \Delta w_{jk} + \mu (w_{jk}[t] - w_{jk}[t - 1]) \quad (10)$$

- ❖ Mengubah bobot diantara *input layer* dan *hidden layer*

$$v_{ij}[t + 1] = v_{ij}[t] + \Delta v_{ij} + \mu (v_{ij}[t] - v_{ij}[t - 1]) \quad (11)$$

Dengan: μ = *Momentum*

h. Menghitung nilai *Mean Square Error* (MSE) pada setiap *epoch*.

$$MSE = \frac{1}{sPola} \sum_k^{sPola} (t_k - y_k)^2 \quad (12)$$

Dengan:

t_k = Target nilai pada neuron *output k*

y_k = Keluaran dari *neuron output k*

s = Jumlah pola

Particle Swarm Optimization merupakan suatu metode optimasi yang mengadopsi perilaku sosial kawanan hewan, seperti burung atau ikan dimana *particle*-nya merupakan seekor hewan pada kawanan tersebut yang merupakan solusi potensial. Partikel-partikel ini bergerak dalam ruang pencarian n -dimensi untuk menemukan solusi terbaik. Setiap partikel memiliki dua sifat, yaitu posisi dan kecepatan, di mana kecepatan setiap partikel disesuaikan dengan posisi lokal terbaik serta posisi terbaik dari global yang terbaik. Selanjutnya posisi baru tersebut dihitung untuk memperbaharui kecepatan. Seumpama, d dimensi ruang pencarian dan n adalah jumlah total partikel serta t merupakan waktu pada setiap langkah yang dilakukan. Posisi partikel ke- i direpresentasikan sebagai vector $x_i = (x_{i1}, x_{i2}, x_{i3}, \dots, x_{id})$; lokal posisi terbaik untuk partikel ke- i dapat dinyatakan dengan vector $P_i = (p_{i1}, p_{i2}, p_{i3}, \dots, p_{id})$ dan posisi global terbaik dapat dinyatakan dengan vector $P_g = (p_{g1}, p_{g2}, p_{g3}, \dots, p_{gd})$; kecepatan dari partikel ke- i dilambangkan sebagai $V_i = (v_{i1}, v_{i2}, v_{i3}, \dots, v_{id})$ [16]

$$v_{id}^{t+1} = w \cdot v_{id}^t + c_1 r_1 (p_{id}^t - x_{id}^t) + c_2 r_2 (p_{gd}^t - x_{id}^t) \quad (13)$$

$$x_{id}^{t+1} = x_{id}^t + v_{id}^{t+1} \quad (14)$$

Dimana:


d = 1, 2, 3, ..., n

w = bobot

c_1 dan c_2 = percepatan konstanta dengan nilai positif

r_1 dan r_2 = fungsi acak dalam rentang [0,1]

Bobot w merupakan parameter yang paling penting untuk konvergensi dari *Particle Swarm Optimization*. Pada awal pelatihan, nilai bobot harus dikurangi dengan cepat untuk mencari nilai global yang optimal akan tetapi ketika di sekitar optimum global maka nilai bobot harus dikurangi secara perlahan [16].



Gambar 3. Perpindahan partikel pada PSO

Algoritma dari *Particle Swarm Optimization* untuk struktur jaringan terbaik dapat diimplementasikan dengan langkah-langkah berikut ini:

- Inisialisasi partikel secara acak untuk posisi awal dan kecepatan dalam lingkup yang diijinkan.
- Menghitung nilai *fitness* (nilai fungsi tujuan) untuk setiap partikel
- Jika nilai *fitness* yang dihitung lebih besar dari nilai personal terbaik, lanjutkan dengan langkah d, jika tidak melompat ke langkah e.
- Menetapkan nilai *fitness* saat ini sebagai nilai personal terbaik yang baru. Melompat ke langkah f.
- Mempertahankan nilai personal terbaik sebelumnya. Lanjutkan ke langkah f.
- Menetapkan nilai personal terbaik dari partikel terbaik sebagai nilai global terbaik.
- Menghitung kecepatan setiap partikel.
- Menggunakan nilai kecepatan untuk memperbarui nilai-nilai data pada setiap partikel.
- Jika target tercapai maka selesai. Jika tidak, ulangi lagi langkah b sampai selesai.

2.3. Kerangka Pemikiran

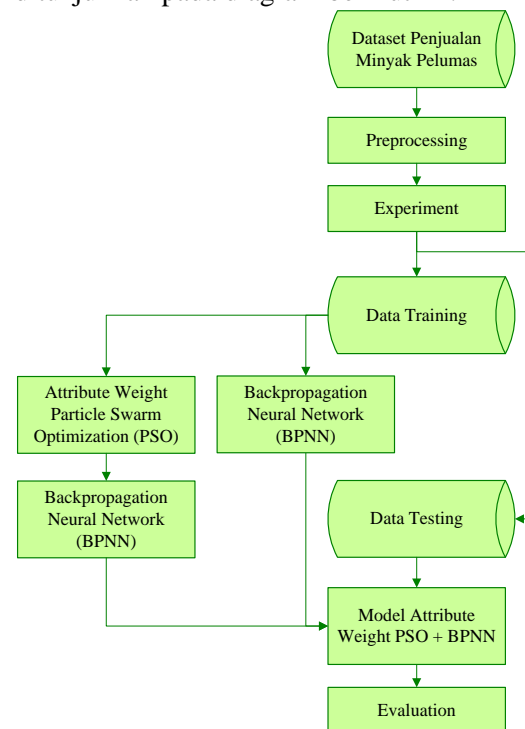
Adapun kerangka pemikiran pada penelitian ini tersusun sebagai berikut:

- Permasalahan
Tingkat error yang masih cukup tinggi untuk algoritma ANN sendiri, sehingga dibutuhkan algoritma optimasi untuk mengoptimasi bobot pada ANN
- Sumber Data
Data yang digunakan merupakan data penjualan minyak pelumas pertamina di SBPU As-Salafi (54.683.11) Sukorejo sejak Januari 2012 hingga Desember 2017
- Metode/Pendekatan
Metode yang diusulkan dalam penelitian ini adalah algoritma *Particle Swarm Optimization* sebagai optimasi bobot jaringan pada *Artificial Neural Network* dengan struktur *Backpropagation*
- Eksperimen/Pengujian
Pengujian data menggunakan metode yang dipilih untuk meperoleh hasil MSE dan RMSE terendah.
- Tujuan
Untuk mengetahui pengaruh algoritma *Particle Swarm Optimization* sebagai optimasi pada *Artificial Neural Network* dalam menghasilkan *MSE* dan *RMSE*.

- Hasil
Algoritma *Particle Swarm Optimization* dapat meningkatkan akurasi pada prediksi penjualan minyak pelumas pertamina.

3. METODE PENELITIAN

Metode eksperimental dilakukan dalam penelitian ini, proses eksperimen pada data yang diperoleh menggunakan metode *Artificial Neural Network* dengan struktur *Backpropagation* untuk kemudian diimplementasikan pada sebuah tool pendukung yaitu *rapidminer* untuk mengetahui hasil nilai *MSE* (*mean square error*) dan *RMSE* (*root mean square error*) yang lebih rendah sehingga dapat diperoleh nilai akurasi yang tinggi. Beberapa tahapan eksperimen penelitian dilakukan pada penelitian ini ditunjukkan pada diagram berikut ini:



Gambar 4. Metode penelitian yang digunakan

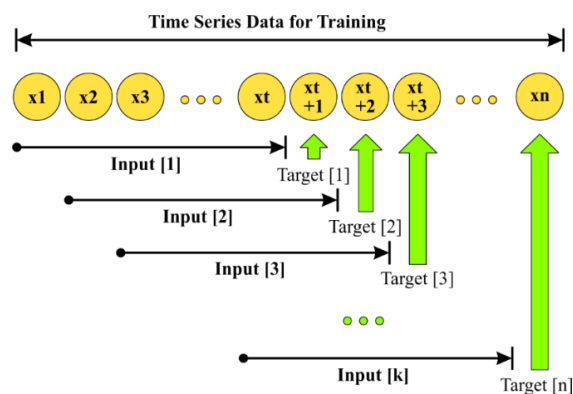
3.1 Metode Pengumpulan Data

Data yang digunakan pada penelitian ini merupakan data primer penjualan minyak pelumas/oli pertamina yang diperoleh di Stasiun Pengisian Bahan Bakar Umum (SPBU) 54.683.11 Sumberejo terhitung sejak tanggal 1 Januari 2012 hingga 31 Desember 2017. Total seluruh data yang diperoleh adalah penjualan minyak pelumas pertamina selama 2.190 hari dengan total 29 merk dagang. Data penjualan tersebut merupakan data *time series univariate*,

yaitu data tersebut memiliki sebuah atribut yaitu hasil penjualan minyak pelumas pertamina tanpa ada atribut lainnya yang mempengaruhi. Selanjutnya normalisasi dilakukan untuk mengelompokkan data dalam suatu skala atau suatu jangkauan tertentu sehingga memberikan kemudahan pada proses selanjutnya. Normalisasi yang digunakan adalah normalisasi data dalam jangkauan skala (0,1). Pre-processing data dilakukan menggunakan Microsoft Excel dengan rumus persamaan sebagai berikut [14]:

$$\hat{x}_{ik} = \frac{x_{ik} - \min(x_k)}{\max(x_k) - \min(x_k)} \quad (15)$$

Setelah dilakukan normalisasi, maka semua fitur akan berada dalam jangkauan yang sama sehingga proporsi pengaruh pada fungsi biaya dalam klasifikator menjadi seimbang. Langkah selanjutnya yang perlu dilakukan adalah mengubah data yang telah dinormalisasi menjadi data yang siap diolah berdasarkan jumlah input dari proses pembelajaran dengan tujuan mempelajari pola *time series* untuk memperoleh nilai parameter yang akan digunakan untuk prediksi rentet waktu. Pada proses pembelajaran *Artificial Neural Network* untuk prediksi data *time series univariat*, data dipecah sebagai *input* dan *label*. Cara yang dilakukan untuk mengubah ke bentuk data pelatihan ditunjukkan pada gambar berikut ini:



Gambar 5. Proses Data Pelatihan [17]

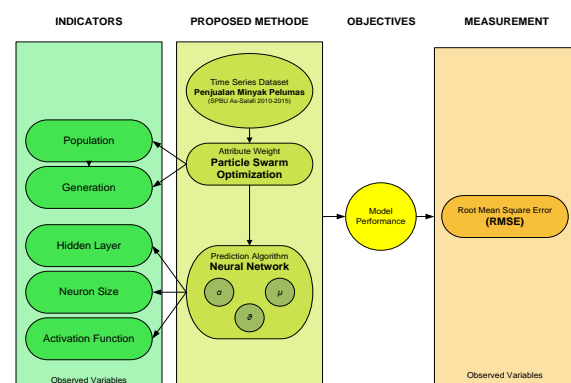
Tabel 1. Pola data *time series univariat* pada ANN [17]

Pola	Jeda Input	Target
1	$X_1, X_2, X_3, X_4, \dots, X_t$	X_{t+1}
2	$X_2, X_3, X_4, X_5, \dots, X_{t+1}$	X_{t+2}
3	$X_3, X_4, X_5, X_6, \dots, X_{t+2}$	X_{t+3}
...
n-t	$X_{n-t}, X_{n-t+1}, X_{n-t+2}, \dots, X_{n-1}$	X_n

3.2 Eksperimen Metode

Dalam melakukan prediksi pada penjualan minyak pelumas di SPBU 54.683.11 Sumberejo dibutuhkan suatu eksperimen pada metode yang akan diusulkan untuk selanjutnya dipakai untuk memprediksi penjualan minyak pelumas pada masa yang akan datang. Metode yang diusulkan pada penelitian ini adalah algoritma *Particle Swarm Optimization* sebagai optimasi nilai bobot atribut pada algoritma *Artificial Neural Network* dengan struktur *Backpropagation*. Metode tersebut diharapkan mampu membantu memperoleh hasil nilai error yang rendah untuk kemudian digunakan sebagai pembelajaran yang akan memberikan nilai akurasi yang baik pada peramalan penjualan minyak pelumas pertamina. Data yang telah diperoleh kemudian dimasukkan sebagai nilai *input* dan diolah berdasarkan nilai parameter terbaik dari *Particle Swarm Optimization* dan *Backpropagation Artificial Neural Network* sehingga diperoleh nilai prediksi yang tepat.

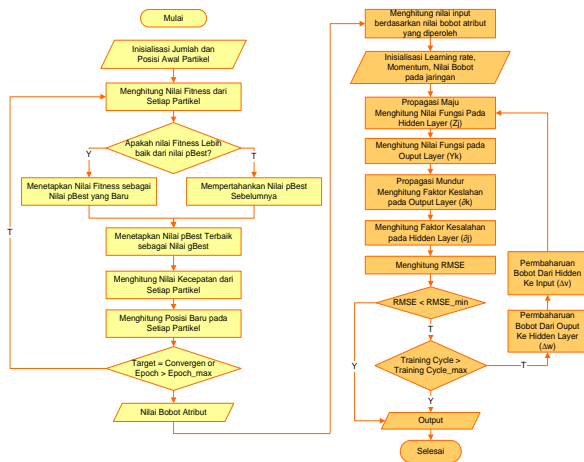
Adapun metode yang digunakan pada penelitian ini dalam menentukan model prediksi ditunjukkan pada gambar berikut ini:



Gambar 6. Model yang diusulkan

Untuk melakukan implementasi algoritma *Particle Swarm Optimization* sebagai optimasi nilai bobot atribut pada algoritma *Artificial Neural Network* dengan struktur *Backpropagation* pada eksperimen dan pengujian dalam penelitian ini menggunakan software pendukung yaitu *Rapidminer* dengan menentukan persentase data (*split ratio*) yang digunakan sebagai uji coba dengan nilai training dari 10% dengan testing sebesar 90% hingga nilai training menggunakan 90% dengan testing sebesar 10%. Tahapan langkah-langkah yang dilakukan pada bagian eksperimen dan pengujian penelitian ini dalam

menentukan model prediksi ditunjukkan pada gambar berikut ini:



Gambar 7. Flowchart Proses Peramalan ANN PSO

Penentuan model terbaik dari metode yang dipilih untuk melakukan prediksi penjualan produk minyak pelumas Pertamina merupakan tujuan dari penentuan parameter pada algoritma yang digunakan. Model terbaik yang dihasilkan dari metode tersebut kemudian digunakan untuk memprediksi penjualan produk minyak pelumas Pertamina pada bulan-bulan yang akan datang dengan memasukkan data penjualan pada bulan-bulan sebelumnya.

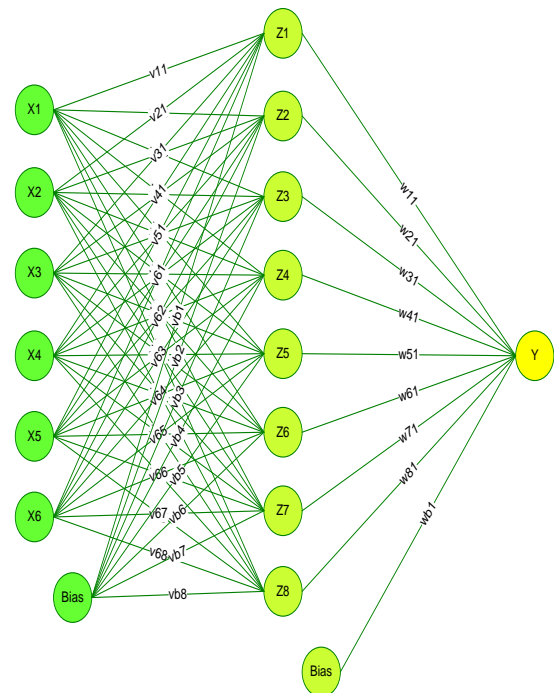
3.3 Evaluasi

Teknik evaluasi yang digunakan untuk melihat keberhasilan algoritma yang diusulkan dalam penelitian ini adalah mencapai RMSE yang diinginkan, yaitu nilai RMSE minimal dalam prediksi penjualan minyak pelumas Pertamina menggunakan algoritma *Particle Swarm Optimization* sebagai optimasi penentuan nilai bobot pada *Artificial Neural Network*, maka penelitian ini akan membandingkan hasil yang diperoleh dari penghitungan tanpa menggunakan algoritma optimasi *Particle Swarm Optimization*. Hal ini bertujuan untuk mengetahui pengaruh algoritma optimasi *Particle Swarm Optimization* dalam melakukan prediksi penjualan minyak pelumas Pertamina pada *Artificial Neural Network*, serta untuk menentukan model prediksi yang tepat untuk melakukan prediksi penjualan minyak pelumas Pertamina sehingga dengan diperolehnya model prediksi tersebut diharapkan dapat mengetahui prediksi penjualan pada masa yang akan datang.

4. HASIL PENELITIAN DAN PEMBAHASAN

Berdasarkan serangkaian pengujian yang telah dilakukan sebelumnya diperoleh hasil bahwa algoritma *Particle Swarm Optimization* yang digunakan sebagai penentu nilai bobot pada atribut *Artificial Neural Network* terbukti mampu memberikan nilai bobot yang optimal sehingga diperoleh hasil *Root Mean Squared Error* (RMSE) yang lebih baik dibandingkan dengan algoritma *Artificial Neural Network* dengan struktur *Backpropagation* saja.

Berdasarkan beberapa tahapan pengujian yang telah dilaksanakan untuk memprediksi penjualan minyak pelumas Pertamina diperoleh hasil bahwa penentuan nilai parameter pada struktur jaringan *Artificial Neural Network* sangat berpengaruh dalam perolehan model terbaik yang akan digunakan untuk memprediksi masa-masa yang akan datang. Model terbaik yang telah ditemukan kemudian dioptimasi menggunakan algoritma *Particle Swarm Optimization* sebagai penentu nilai bobot pada atribut *Artificial Neural Network*.



Gambar 8. Model arsitektur jaringan ANN terbaik

Gambar di atas merupakan model arsitektur jaringan *Artificial Neural Network* terbaik yang diperoleh dari hasil percobaan. Pada penelitian ini dilakukan beberapa tahapan pengujian parameter *Artificial Neural Network* dengan memasukkan jumlah *input* dari 3 hingga 12 yang dikombinasikan dengan *neuron* pada

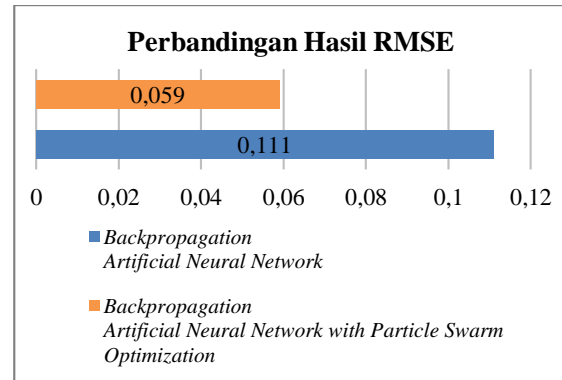
hidden layer dengan jumlah 2 *neuron* hingga 12 *neuron* pada satu *hidden layer*, memasukkan nilai *split ratio* data pelatihan dimulai dari 0.1 hingga 0.9, selanjutnya menentukan nilai *training cycle* dengan memasukkan nilai antara 100 sampai 1000, dilanjutkan dengan percobaan penentuan nilai *learning rate* dan *momentum* secara bersamaan dengan memasukkan kombinasi nilai dari 0.1 hingga 0.9 sehingga ditemukan model terbaik yaitu dengan 6 *neuron input*, 8 *neuron* pada 1 *hidden layer* dengan nilai *split ratio* data pelatihan sebesar 0.8 dan jumlah *training cycle* 400 serta nilai *learning rate* sebesar 0,3 dan *momentum* sebesar 0,3 diperoleh nilai *Root Mean Squared Error* (RMSE) sebesar 0,111 dengan waktu eksekusi selama 1 detik.

Sedangkan pada pengujian *Backpropagation Artificial Neural Network* terbaik yang kemudian dioptimasi menggunakan algoritma *Particle Swarm Optimization* sebagai penentu nilai bobot atribut dilakukan uji coba dengan nilai parameter *population size* dari 6 hingga 20, kemudian memasukkan nilai bobot $P_{Best}(c_1)$ dan $G_{Best}(c_2)$ secara bersamaan dimulai dari kombinasi nilai 1.0 hingga 5.0, selanjutnya uji coba penentuan nilai bobot inersia yang dimulai dari nilai 0.1 hingga 10.0 maka dengan kombinasi nilai parameter *population size* = 10, $P_{Best}(c_1) = 5.0$ dan $G_{Best}(c_2) = 3.0$, *max generation* = 30, *inersia weight* sebesar 0.1 serta nilai *max weight* = 1.0 dan *min weight* = 0.0 diperoleh nilai *Root Mean Squared Error* (RMSE) terkecil yaitu 0.059 dengan waktu eksekusi selama 16 menit 27 detik.

Hasil perbandingan nilai *Root Mean Squared Error* (RMSE) yang diperoleh dari serangkaian percobaan yang telah dilakukan yaitu percobaan menggunakan algoritma *Artificial Neural Network* dengan struktur *Backpropagation* tanpa optimasi yang dibandingkan dengan percobaan menggunakan algoritma *Artificial Neural Network* dengan struktur *Backpropagation* yang dioptimasi menggunakan algoritma *Particle Swarm Optimization* sebagai penentu nilai bobot atribut adalah seperti berikut:

Tabel 2. Perbandingan hasil RMSE

Method	Squared Error	Root Mean Squared Error	Execution Time
<i>Backpropagation Artificial Neural Network</i>	0.012 +/- 0.015	0.111 +/- 0.000	00.00.01
<i>Backpropagation Artificial Neural Network with Particle Swarm Optimization</i>	0.004 +/- 0.004	0.059 +/- 0.000	00.16:27



Gambar 9. Perbandingan hasil RMSE

Berdasarkan grafik di atas dapat disimpulkan bahwa nilai *Root Mean Squared Error* (RMSE) yang diperoleh dari percobaan menggunakan algoritma *Artificial Neural Network* dengan struktur *Backpropagation* yang dioptimasi menggunakan algoritma *Particle Swarm Optimization* lebih baik dibandingkan dengan nilai *Root Mean Squared Error* (RMSE) yang diperoleh dari percobaan menggunakan algoritma *Artificial Neural Network* dengan struktur *Backpropagation* saja tanpa optimasi dengan persentase tingkat penurunan sebesar 46.85% dari hasil percobaan sebelumnya.

5. KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan serangkaian percobaan yang telah dilakukan pada penelitian ini, diperoleh kesimpulan bahwa:

- Struktur *Backpropagation Artificial Neural Network* terbaik diperoleh dengan rincian parameter 6 *neuron input*, 8 *neuron* pada 1 *hidden layer*, nilai *split ratio* data pelatihan sebesar 0.8, jumlah *training cycle* 400, nilai *learning rate* sebesar 0,3 dan *momentum* sebesar 0,3 memperoleh nilai *Root Mean Squared Error* (RMSE) sebesar 0,111 dengan waktu eksekusi selama 1 detik.
- Pengujian struktur *Backpropagation Artificial Neural Network* terbaik yang kemudian dioptimasi menggunakan algoritma *Particle Swarm Optimization* pada penentuan nilai bobot atribut memperoleh hasil terbaik dengan menggunakan parameter *Population* = 10, $P_{Best}(c_1) = 5.0$ dan $G_{Best}(c_2) = 3.0$, *Max Generation* = 30, *inersia weight* sebesar 0.1 serta nilai *max weight* = 1.0 dan *min weight* = 0.0 diperoleh nilai *Root Mean Squared Error* (RMSE) sebesar 0.059 dengan waktu eksekusi selama 16 menit 27 detik.

- c. Perbandingan dua hasil *Root Mean Squared Error* (RMSE) dari percobaan yang telah dilakukan membuktikan bahwa algoritma *Artificial Neural Network* dengan struktur *Backpropagation* yang dioptimasi menggunakan algoritma *Particle Swarm Optimization* lebih baik dibandingkan dengan algoritma *Artificial Neural Network* dengan struktur *Backpropagation* saja tanpa optimasi dengan persentase tingkat penurunan *error* sebesar 46.85% dari hasil percobaan sebelumnya.
- d. Penambahan optimasi serta penyesuaian jumlah populasi dapat menghasilkan nilai yang lebih baik, akan tetapi juga disertai dengan penambahan waktu komputasi yang cukup signifikan.
- e. Berdasarkan nilai *error* yang diperoleh dapat disimpulkan bahwa algoritma *Artificial Neural Network* dengan struktur *Backpropagation* yang dioptimasi menggunakan algoritma *Particle Swarm Optimization* dapat digunakan sebagai metode untuk melakukan prediksi terhadap penjualan minyak pelumas Pertamina secara lebih akurat.

5.2 Saran

Saran yang dapat digunakan pada penelitian berikutnya untuk mencapai hasil yang lebih baik diantaranya:

- a. Untuk memperoleh akurasi yang lebih optimal disertai dengan waktu komputasi yang singkat dibutuhkan adanya penelitian lebih lanjut menggunakan penggabungan dari beberapa metode berbeda semisal penggabungan algoritma *Artificial Neural Network* dengan *Fuzzy Logic* yang dikenal dengan *Neurofuzzy* serta menggunakan optimasi *Swarm Intelligence* lainnya seperti ACO (*Ant Colony Optimization*), ABC (*Artificial Bee Colony*) *Algorithm* dan lain sebagainya.
- b. Penelitian ini terbatas dalam ruang lingkup bisnis lokal dengan karakter bisnis yang tidak terlalu besar sehingga perlu kiranya dilakukan penelitian menggunakan data dalam ruang lingkup bisnis yang cukup luas dan data yang lebih besar.

6. REFERENSI

- [1] Darmanto, "Mengenal Pelumas Pada Mesin," *Momentum*, vol. 7, no. 1, pp. 5–10, 2011.
- [2] M. Arisandi, Darmanto, and T. Priangkoso, "Analisa Pengaruh Bahan Dasar Pelumas Terhadap Viskositas Pelumas dan Konsumsi Bahan Bakar," *Momentum*, vol. 8, no. 1, pp. 56–61, 2012.
- [3] A. Singh and G. C. Mishra, "Application of Box-Jenkins Method and Artificial Neural Network Procedure for Time Series Forecasting of Prices," vol. 16, no. 1, pp. 83–96, 2015.
- [4] T. G. Laksana, "Perbandingan Algoritma Neural Network (NN) dan Support Vector Machines (SVM) dalam Peramalan Penduduk Miskin di Indonesia," *Inf. Comput. Technol.*, vol. 1, no. 1, pp. 49–58, 2013.
- [5] H. G. Nugraha and A. S. N., "Optimasi Bobot Jaringan Syaraf Tiruan Menggunakan Particle Swarm Optimization," *Indones. J. Comput. Cybern. Syst.*, vol. 8, no. 1, pp. 25–36, 2014.
- [6] H. N. A. Hamed, S. M. Shamsuddin, and N. Salim, "Particle Swarm Optimization for Neural Network," *J. Teknol. UTM*, vol. 49, no. D, pp. 13–26, 2008.
- [7] G. K. Jha, P. Thulasiraman, and R. K. Thulasiram, "PSO based neural network for time series forecasting," *2009 Int. Jt. Conf. Neural Networks*, pp. 1422–1427, 2009.
- [8] X. Hu and R. Eberhart, "Solving Constrained Nonlinear Optimization Problems with Particle Swarm Optimization," *Optimization*, vol. 2, no. 1, pp. 1677–1681, 2002.
- [9] J. Malik, R. Mishra, and I. Singh, "PSO-ANN Approach For Estimating Drilling Induced Damage In Cfrp Laminates," *Adv. Prod. Eng. Manag. APEM*, vol. 6, no. 2, pp. 95–104, 2011.
- [10] N. Susanti, "Penerapan Model Neural Network Backpropagation untuk Prediksi Harga Ayam," *Seminar Nasional Teknologi Industri dan Informatika (SNATIF)*, pp. 325–332, 2014.
- [11] S. Ruliah and R. Rolyadely, "Prediksi Pemakaian Listrik Dengan Pendekatan Back Propagation," *J. Tek. Inform. dan Sist. Inf.*, vol. 3, no. 1, pp. 465–476, 2014.
- [12] D. R. M. Gor, *Industrial Statistic and Operational Management; 6. Forecasting Techniques*. 2015.
- [13] C. Gershenson, "Artificial Neural Networks for Beginners," *University of*

- Sussex Brighton United Kingdom*, vol. cs.NE/0308, p. 8, 2003.
- [14] E. Prasetyo, *Data Mining, Mengolah data menjadi informasi menggunakan Matlab*. Yogyakarta: Andi Publisher, 2014.
- [15] S. Kusumadewi, *Membangun Jaringan Syaraf Tiruan Menggunakan MATLAB & EXCEL LINK*. Yogyakarta: Graha Ilmu, 2004.
- [16] T.-S. Park, J.-H. Lee, and B. Choi, "Optimization for Artificial Neural Network with Adaptive inertial weight of particle swarm optimization," *2009 8th IEEE Int. Conf. Cogn. Informatics*, pp. 481–485, 2009.
- [17] Purwanto, C. Eswaran, and R. Logeswaran, "Improved Adaptive Neuro-Fuzzy Inference System for HIV/AIDS Time Series Prediction," *Informatics Eng. Inf. Sci. Pt Iii*, vol. 253, pp. 1–13, 2011.