

Perbandingan Metode *Extreme Learning Machine* dan *Particle Swarm Optimization Extreme Learning Machine* untuk Peramalan Jumlah Penjualan Barang

I Putu Susila Handika¹, Ida Ayu Giriantari², Agus Dharma³

Abstract— *Extreme Learning Machine* (ELM) merupakan salah satu metode pembelajaran dari *Artificial Neural Network* yang memberikan tingkat akurasi dan kecepatan yang lebih baik dari pada metode pembelajaran lainnya. Salah satu kelemahan dari metode ELM adalah jumlah *hidden nodes* ditentukan dengan cara *try and error*, sehingga tidak bisa diketahui berapa jumlah *hidden nodes* yang tepat untuk mendapatkan hasil peramalan menggunakan metode ELM. Untuk mengatasi masalah tersebut digunakan metode optimasi *Particle Swarm Optimization* untuk mencari jumlah *hidden nodes* yang optimal. Data yang digunakan untuk keperluan analisis adalah data *time series* penjualan barang salah satu minimarket di Bali. Hasil peramalan akan diukur menggunakan *Mean Square Error* (MSE) dengan data uji yang sama. Hasil penelitian menunjukkan metode PSO dapat diterapkan pada metode ELM untuk mengoptimasi jumlah *hidden nodes*. MSE yang dihasilkan oleh metode PSO ELM lebih kecil dibanding metode ELM. Selain itu *range error* yang dihasilkan oleh metode PSO ELM juga lebih kecil dibanding metode ELM.

Kata Kunci— Peramalan; *Extreme Learning Machine*; *Particle Swarm Optimization*, *Mean Square Error*.

I. PENDAHULUAN

Kemunculan minimarket yang begitu banyak membuat manajemen perusahaan harus berfikir kreatif agar dapat bersaing dengan usaha sejenis dalam merebut pangsa pasar. Salah satu cara untuk merebut pangsa pasar adalah dengan menyediakan barang yang diperlukan oleh konsumen. Pengelolaan sebuah minimarket diperlukan untuk menjaga persediaan barang-barang tetap tersedia karena persediaan barang merupakan bagian yang sangat penting dalam perkembangan sebuah minimarket. Jumlah persediaan sangat erat kaitannya dengan berapa target penjualan pada setiap barang yang dijual. Dapat dibayangkan, apabila pemilik tidak mengetahui kapan ia harus memesan barang atau bahkan tidak tahu berapa barang yang harus dipesan agar dapat menjaga jumlah persediaan di minimarket. Pemilik minimarket bisa saja memesan banyak barang untuk disimpan pada minimarketnya, namun yang perlu diperhatikan adalah jika barang dan penjualan yang terjadi sedikit, maka barang yang tersimpan pada minimarket dapat menyebabkan kerugian

terhadap pemilik minimarket. Pengelola minimarket harus dapat mengetahui berapa jumlah minimal dan maksimal barang agar persediaan barang di minimarket menjadi optimal. Jumlah minimal dan jumlah maksimal barang ditentukan dengan mengetahui berapa jumlah penjualan periode selanjutnya.

Pengelolaan barang yang terdapat pada minimarket saat ini telah menggunakan sistem yang dapat mengatur jumlah minimum dan maksimum barang untuk setiap minimarket. Metode peramalan yang digunakan dalam menentukan jumlah penjualan barang periode selanjutnya untuk setiap minimarket adalah *moving average*. Hasil peramalan yang didapat dari metode tersebut tidak dapat terjamin karena pola data yang terdapat pada bidang retail adalah pola data *non stasioner*. Suatu metode dibutuhkan untuk dapat meramalkan perilaku data *non stasioner* agar dapat mengurangi kesalahan yang terjadi. Metode *Artificial Neural Network* (ANN) dapat digunakan untuk mengatasi masalah perilaku data *non stasioner* karena metode ANN memiliki kemampuan untuk belajar [1]. Salah satu metode pembelajaran pada ANN adalah *Extreme Learning Machine* (ELM) yang memberikan tingkat akurasi dan kecepatan yang lebih baik dari pada metode pembelajaran lainnya [2]. Salah satu kelemahan dari metode ANN adalah penentuan parameter *hidden nodes* secara manual. Untuk mendapatkan hasil yang optimal metode ANN dapat digabungkan dengan salah satu metode optimasi yaitu *Particle Swarm Optimization* (PSO). Penggabungan metode PSO dan ANN dapat memberikan hasil yang lebih akurat dibanding metode ANN [3].

Pada penelitian ini, metode PSO akan digabungkan dengan metode ELM untuk meramalkan total penjualan barang pada minimarket. Penggabungan metode PSO dan ELM akan menghasilkan jumlah *hidden nodes* yang optimal sehingga didapatkan hasil peramalan yang lebih akurat.

II. EXTREME LEARNING MACHINE (ELM)

Extreme Learning Machine (ELM) adalah sebuah metode pembelajaran yang baru dari ANN yang menggunakan arsitektur *single hidden layer feedforward*. Pembuatan metode ini bertujuan untuk mengatasi permasalahan dari metode ANN terutama dalam hal *learning speed*. Parameter-parameter pada metode ELM seperti *input weight* dan *hidden bias* dipilih secara random, sehingga ELM memiliki *learning speed* yang cepa. Berbeda dari ANN *Feedforward*, metode ELM memiliki model matematis yang lebih sederhana dan efektif.

$$X_i = [x_{i1}, x_{i2}, \dots, x_{iN}]^T \in R^n \quad (1)$$

$$X_t = [x_{t1}, x_{t2}, \dots, x_{tN}]^T \in R^n \quad (2)$$

Secara umum fungsi matematis untuk *Single Hidden*

¹ Mahasiswa Magister Teknik Elektro dan Komputer Universitas Udayana, Kampus Sudirman, Denpasar Bali, Tel. 0361239599, fax: 0361239599; e-mail: susilaandika@gmail.com

² Dosen Magister Teknik Elektro dan Komputer Universitas Udayana, Kampus Sudirman, Denpasar Bali, Tel. 0361239599, fax: 0361239599; e-mail: dayu.giriantari@unud.ac.id

³ Dosen Magister Teknik Elektro dan Komputer Universitas Udayana, Kampus Sudirman, Denpasar Bali, Tel. 0361239599, fax: 0361239599; e-mail: agus_dharma@unud.ac.id

Layer Feedforward Neural Networks (SLFNs) dengan jumlah *hidden nodes* sebanyak N dan *activation function* (x) ditunjukkan pada Persamaan 3 [2].

$$\sum_{i=1}^N \beta_i g_i(x_j) = \sum_{i=1}^N \beta_i g_i(W_i X_j + b_i) = o_j \quad (3)$$

Keterangan :

j adalah bilangan 1, 2, ..., N

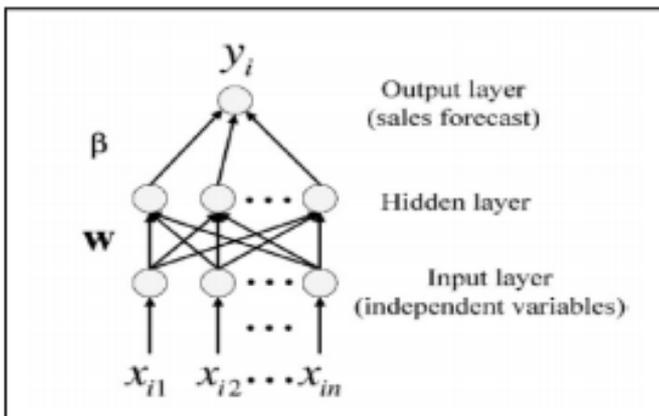
$w_i = (w_{i1}, w_{i2}, \dots, w_{in})^T$ adalah vektor dari *weight* yang menghubungkan i th *hidden nodes* dan *input nodes*.

$\beta_i = (\beta_{i1}, \beta_{i2}, \dots, \beta_{in})^T$ adalah vektor bobot yang menghubungkan i th *hidden* dan *output nodes*.

b_i adalah *threshold* dari i th *hidden nodes*.

$W_i X_j$ adalah *inner produk* dari w_i dan x_j .

Arsitektur sederhana metode ELM ditunjukkan pada Gambar 1.



Gambar 1. Arsitektur ELM [2].

Langkah-langkah yang dilakukan untuk menghitung menggunakan metode ELM adalah sebagai berikut [4].

- 1) Langkah 1: Tentukan bobot dan nilai bias secara random.
- 2) Langkah 2: Hitung output pada hidden layer menggunakan Persamaan 4.

$$G(\alpha_1, x_1, b_1) = \sum_{i=1}^N (a_i x_j + b_i) \quad (4)$$

- 3) Langkah 3: Hitung bobot akhir dari hidden layer menggunakan Persamaan 5.

$$\beta = H^+ T \quad (5)$$

H^+ merupakan matriks *Moore-Penrose Generalized Invers* dari matriks H . Sedangkan matriks H merupakan matriks yang tersusun dari output masing-masing *hidden layer*. Sedangkan T merupakan matriks target.

- 4) Langkah 4: Menghitung semua keluaran di unit output dengan menggunakan Persamaan 6.

$$g(x) = \frac{1}{1 + e^{-x}}$$

III. PARTICLE SWARM OPTIMIZATION (PSO)

Particle Swarm Optimization (PSO), merupakan sebuah metode optimasi yang didasarkan pada perilaku sebuah kawanan serangga misalnya semut, rayap, lebah atau burung. Suatu partikel dalam ruang memiliki posisi dan setiap posisi dalam ruang pencarian merupakan alternatif solusi yang dapat dievaluasi menggunakan fungsi objektif. Setiap partikel dapat menyesuaikan posisi dan kecepatan masing-masing dengan cara setiap partikel menyampaikan informasi terbaiknya kepada partikel yang lain [5]. Sebagai contoh perilaku yang diadopsi oleh metode ini adalah perilaku burung yang mempunyai keterbatasan dalam hal kecerdasan, namun burung-burung tersebut akan mengikuti kebiasaan (*rule*) seperti berikut [6].

- 1) Seekor burung tidak berada terlalu dekat dengan burung yang lain.
- 2) Burung tersebut akan mengarahkan terbangnya ke arah rata-rata keseluruhan burung.
- 3) Kawanan burung akan memposisikan diri dengan rata-rata posisi burung yang lain dengan menjaga sehingga jarak antar burung dalam kawanan itu tidak terlalu jauh.

Rumus untuk menghitung posisi dan kecepatan pada PSO ditunjukkan pada Persamaan 7 dan 8.

$$X_i(t) = x_{i1}(t), x_{i2}(t), \dots, x_{iN}(t) \quad (7)$$

$$V_i(t) = v(t), v_{i2}(t), \dots, v_{iN}(t) \quad (8)$$

Keterangan :

X adalah posisi partikel

V adalah kecepatan partikel

i adalah indeks partikel

t adalah iterasi ke- t

N adalah ukuran dimensi ruang

Penggambaran status partikel pada PSO, digunakan persamaan 9 dan 10.

$$V_t = V_i(t-1) + c_1 r_1 (X_i^l - X_i(t-1)) + c_2 r_2 (X^g - X_i(t-1)) \quad (9)$$

$$X_i(t) = V_i(t) + X_i(t-1) \quad (10)$$

Keterangan :

$X_i^l = x_{i1}^l, x_{i2}^l, \dots, x_{iN}^l$ merepresentasikan *local best* dari partikel ke- i .



$X^G = x_1^G, x_2^G, \dots, x_N^G$ merepresentasikan *global best* dari seluruh kawanan.

c adalah konstanta yang bernilai positif yang biasanya disebut sebagai *learning factor*.

r adalah suatu bilangan random yang bernilai antara 0 – 1.

Langkah-langkah untuk menghitung menggunakan metode PSO adalah sebagai berikut.

- 1) Langkah 1: Inisialisasi posisi awal partikel secara random.
- 2) Langkah 2: Hitung nilai fitness terbaik dari setiap partikel.
- 3) Langkah 3: Tentukan nilai fitness terbaik, dan tetapkan sebagai *Gbest*.
- 4) Langkah 4: Hitung kecepatan setiap partikel menggunakan persamaan 9. Dan hitung posisi setiap partikel menggunakan persamaan 10.
- 5) Langkah 5: Evaluasi nilai fitness dari setiap partikel menggunakan posisi yang baru.
- 6) Langkah 6: Jika kondisi belum terpenuhi, maka ulangi ke langkah 4.

IV. MEAN SQUARE ERROR (MSE)

Untuk menghitung akurasi peramalan digunakan metode MSE (*Mean Square Error*) yang merupakan ukuran ketepatan sebuah metode peramalan. MSE merupakan rata-rata error kuadrat dari untuk setiap data. Rumus MSE dapat dilihat pada Persamaan 14 [7].

$$MSE = \frac{\sum e_i^2}{n} = \frac{\sum (X_i - F_i)^2}{n} \quad (11)$$

Keterangan :

E adalah Error peramalan.

n adalah Jumlah data.

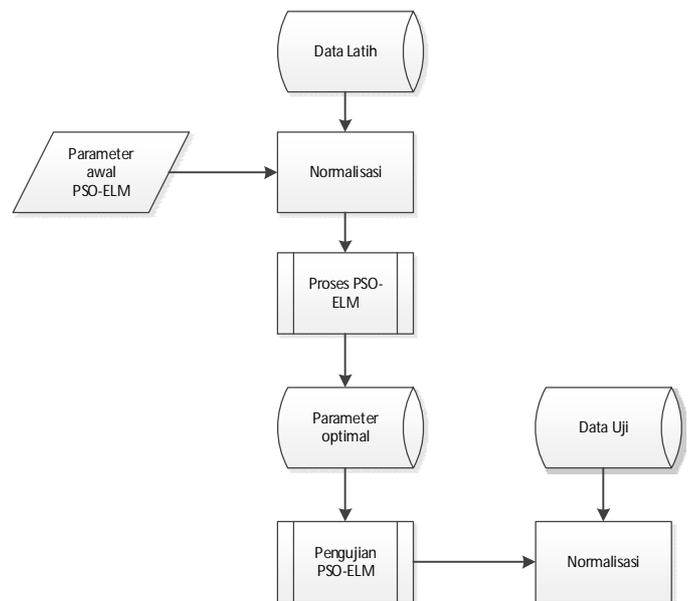
X_i adalah Data nyata ke i .

F_i adalah Data hasil peramalan ke i .

V. PERAMALAN METODE PSO ELM

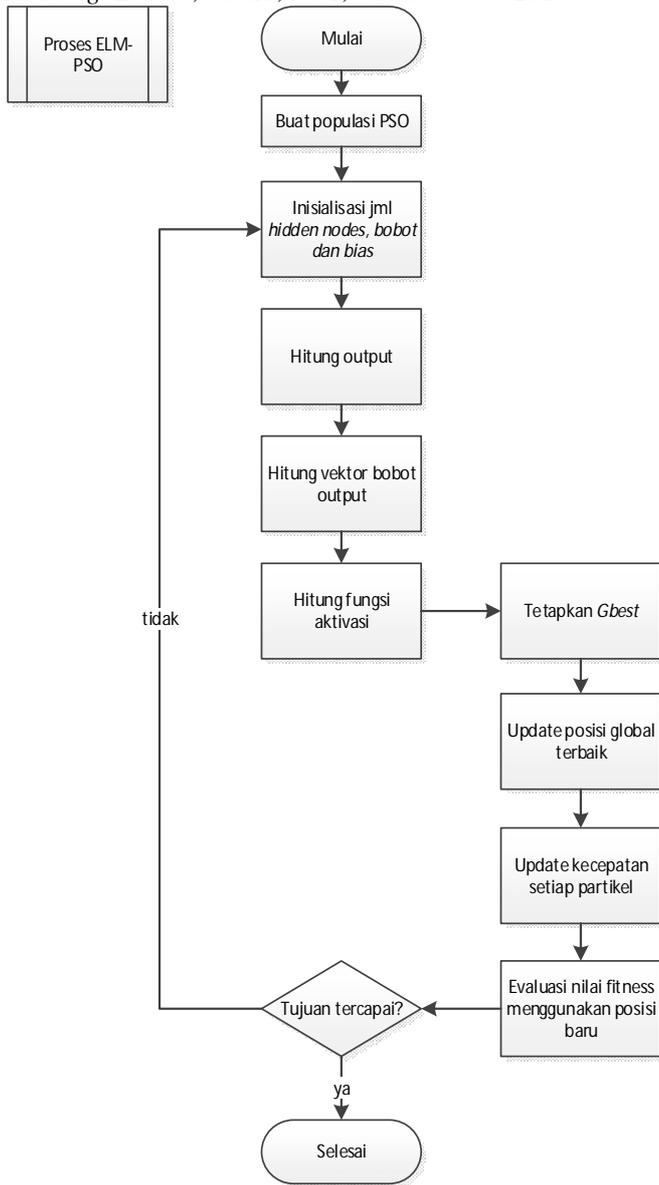
Metode yang digunakan untuk meramalkan jumlah penjualan adalah PSO ELM. Metode PSO berfungsi untuk mencari jumlah *hidden nodes* yang optimal yang selanjutnya digunakan oleh metode ELM untuk mencari jumlah penjualan barang periode selanjutnya. Secara umum proses peramalan jumlah penjualan barang menggunakan metode PSO dan ELM ditunjukkan pada Gambar 2

Proses awal dari sistem ini adalah memasukkan inputan parameter yang diperlukan dalam proses perhitungan peramalan menggunakan metode PSO dan ELM yaitu maksimum iterasi dan jumlah partikel. Pada penelitian ini jumlah partikel yang digunakan adalah 20 sampai 30 partikel, karena penggunaan pada umumnya partikel yang digunakan berkisar pada angka tersebut. Selain itu penggunaan partikel yang terlalu banyak akan menyebabkan proses perhitungan PSO menjadi panjang dan tidak stabil [6]. Sedangkan untuk jumlah iterasi yang digunakan .



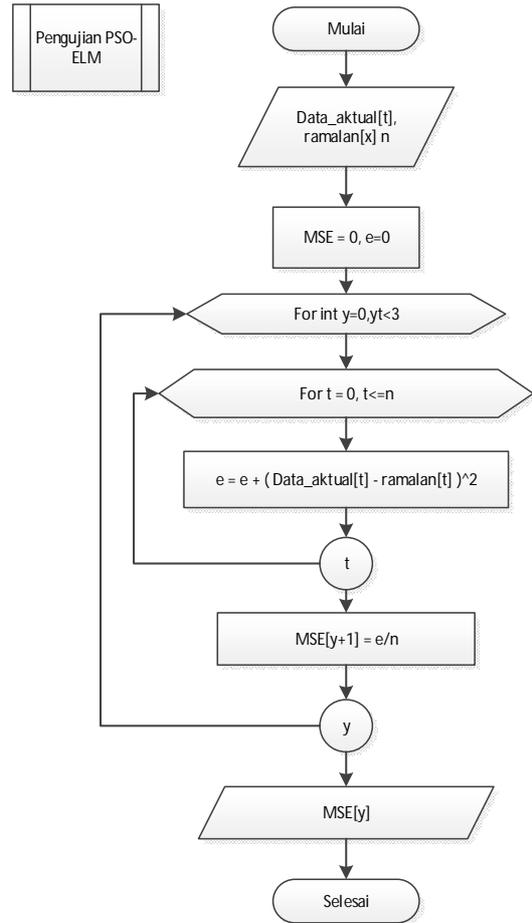
Gambar 2. Proses Peramalan Menggunakan Metode PSO ELM.

Selanjutnya sistem akan mengambil data dari database untuk dilakukan proses pelatihan. Data latih tersebut akan dinormalisasi agar mengurangi *noise* data serta mengurangi dominasi nilai yang bernilai besar terhadap variable yang bernilai kecil. Proses normalisasi yang digunakan adalah *min max normalization*. Proses selanjutnya adalah masuk ke subproses PSO ELM. Sub proses metode PSO ELM ditunjukkan pada Gambar 3. Pada sub proses PSO ELM, langkah awal yang dilakukan adalah membuat populasi untuk PSO secara random yang dalam kasus ini merupakan jumlah *hidden nodes* dari ELM. Setelah itu dilakukan proses inisialisasi bobot dan bias dimana bobot menggunakan nilai random. Selanjutnya dilakukan perhitungan output (dalam kasus ini adalah hasil peramalan penjualan barang) untuk setiap *hidden nodes* yang ditetapkan. Setelah didapatkan hasil output untuk setiap *hidden nodes*, selanjutnya adalah proses perhitungan vektor bobot output. Proses perhitungan output menggunakan fungsi aktivasi dilakukan setelah proses perhitungan vektor bobot output selesai. Hasil dari perhitungan menggunakan fungsi aktivasi ditetapkan sebagai *Gbest* dari populasi PSO, lalu merubah posisi global dan kecepatan setiap partikel PSO. Setelah itu dilakukan proses evaluasi nilai fitness menggunakan posisi yang baru. Jika kondisi yang diinginkan belum terpenuhi, proses akan kembali ke inisialisasi jumlah *hidden nodes*, bobot dan bias. Jika kondisi telah terpenuhi, proses dikatakan selesai dan posisi terbaik pada PSO akan menjadi jumlah *hidden nodes* optimal pada metode ELM



Gambar 3. Subproses PSO ELM.

Setelah proses PSO ELM selesai dilakukan proses selanjutnya adalah proses pengujian untuk mencari akurasi dari metode peramalan. Proses pengujian pada penelitian ini adalah membandingkan hasil peramalan metode ELM yang dioptimasi menggunakan metode PSO dan ELM tanpa optimasi. Pada proses PSO, jumlah partikel yang digunakan pada umumnya adalah dari 20 sampai 30 partikel karena penggunaan banyak partikel akan membuat perhitungan menjadi panjang dan tidak stabil [6]. Sedangkan pada metode ELM jumlah *hidden neurons* yang digunakan adalah bilangan random antara 1 sampai dengan 100 karena jumlah *hidden neurons* yang optimal belum diketahui dan dalam penelitian yang dilakukan oleh Sheela dkk, jumlah *hidden neurons* yang didapat 1 - 101 [8]. Sub proses pengujian hasil peramalan PSO ELM dan ELM tanpa optimasi ditunjukkan pada Gambar 4.

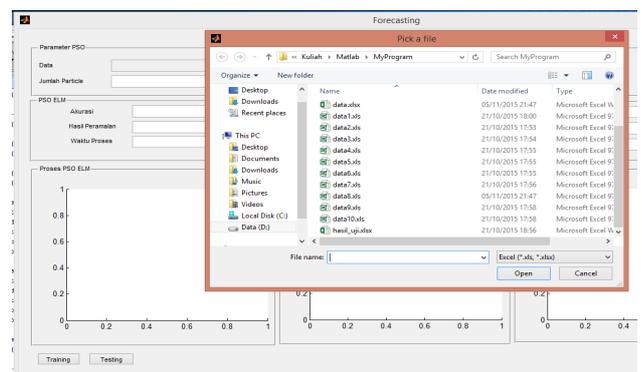


Gambar 4. Pengujian PSO ELM.

VI. HASIL DAN PEMBAHASAN

A. Aplikasi Peramalan

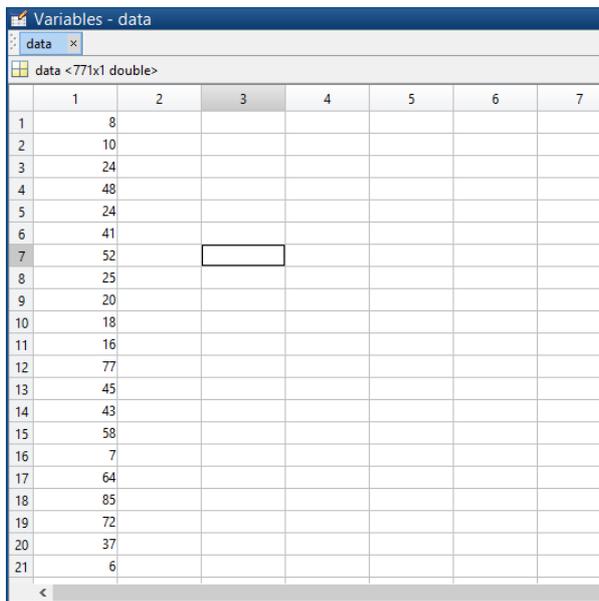
Gambar 5 menunjukkan hasil aplikasi peramalan yang telah dibuat menggunakan Matlab 2012. Data penjualan yang diproses disimpan dalam file excel kemudian dibaca oleh aplikasi peramalan. Jumlah partikel awal PSO ditentukan oleh user.



Gambar 5. Aplikasi Peramalan.



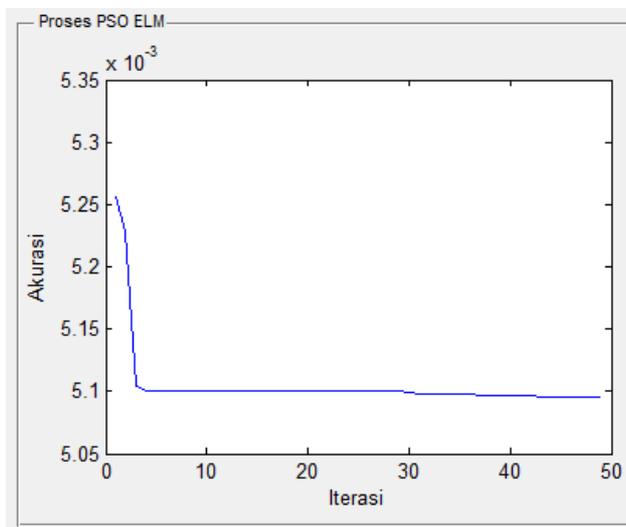
Output data disimpan dalam variable Matlab. Pada Gambar 6 dapat dilihat jumlah data yang terdapat pada data 1 adalah 771 record dimana 80% dari jumlah data tersebut digunakan untuk proses training dan 20% digunakan pada proses testing [9].



	1	2	3	4	5	6	7
1	8						
2	10						
3	24						
4	48						
5	24						
6	41						
7	52						
8	25						
9	20						
10	18						
11	16						
12	77						
13	45						
14	43						
15	58						
16	7						
17	64						
18	85						
19	72						
20	37						
21	6						

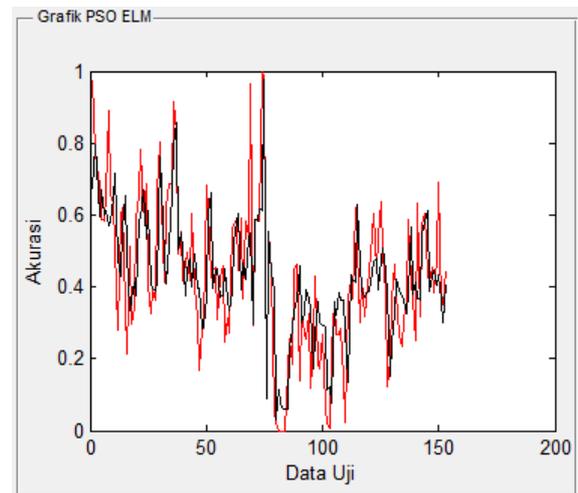
Gambar 6. Data peramalan pada matlab.

Proses training berfungsi untuk mencari jumlah *hidden nodes* optimal menggunakan metode PSO ELM. Jumlah hidden nodes tersebut akan digunakan pada proses testing. Pada Gambar 7 menunjukkan grafik akurasi yang dihasilkan pada setiap iterasi.

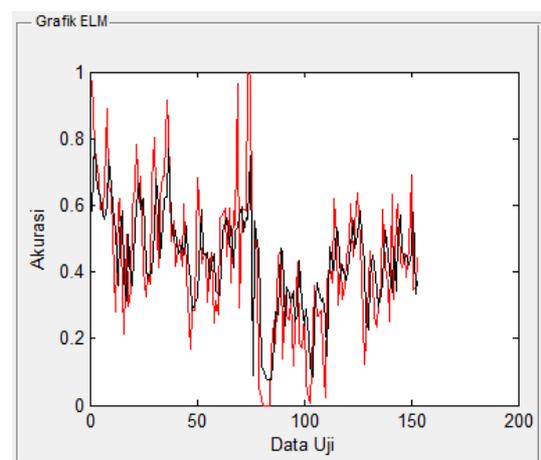


Gambar 7. Proses pencarian akurasi minimum PSO.

Setelah mendapatkan hasil akurasi minimum, maka dilanjutkan dengan proses peramalan menggunakan metode ELM menggunakan jumlah hidden nodes yang telah didapatkan pada proses training. Hasil perhitungan metode PSO ELM dan ELM digambarkan pada Gambar 8 dan Gambar 9.



Gambar 8. Grafik hasil peramalan PSO ELM.



Gambar 9. Grafik hasil peramalan ELM.

Gambar 8 dan Gambar 9 menunjukkan bahwa hasil peramalan menggunakan metode ELM yang dioptimasi dengan metode PSO tidak jauh berbeda dengan hasil peramalan yang didapat menggunakan metode ELM tanpa optimasi. Gambar 10 juga menunjukkan hasil peramalan yang didapat tidak terlalu jauh yaitu sejumlah 74 untuk metode ELM yang dioptimasi dengan metode PSO dan sejumlah 69 untuk metode ELM tanpa optimasi. Hasil akurasi yang dihasilkan untuk metode ELM adalah 0,02421, sedangkan hasil yang didapat pada metode ELM tanpa optimasi adalah 0,01757. Dengan demikian metode PSO dapat digunakan untuk mengoptimasi jumlah hidden nodes dari metode ELM walaupun hasil yang didapat tidak terlalu signifikan. Waktu proses yang didapat oleh metode PSO ELM adalah 33,0944 detik sedangkan metode ELM menghasilkan waktu proses sebesar 0,0570. Jadi dalam hal waktu proses, metode ELM lebih cepat dibandingkan metode PSO ELM.

PSO ELM	
Akurasi	0,01757
Hasil Peramalan	74
Waktu Proses	33,0944

ELM	
Akurasi	0,02421
Hasil Peramalan	69
Waktu Proses	0,0570

Gambar 10. Output Peramalan PSO ELM dan ELM.

B. Analisis Metode PSO ELM dan ELM

Hasil pengujian yang telah dilakukan pada bab VI didapat hasil perbandingan MSE antara metode PSO ELM dan ELM yang ditunjukkan pada TABEL 1.

TABEL 1. PERBANDINGAN MSE METODE PSO ELM DAN ELM

Jml Partikel	Rata-rata		Min		Max		Range	
	PSO-ELM	ELM	PSO-ELM	ELM	PSO-ELM	ELM	PSO-ELM	ELM
20	0,01160	0,01354	0,00207	0,00285	0,02796	0,02984	0,02589	0,02699
21	0,01127	0,01348	0,00208	0,00284	0,02796	0,02983	0,02588	0,02699
22	0,01154	0,01419	0,00207	0,00287	0,02796	0,03244	0,02589	0,02957
23	0,01126	0,01342	0,00141	0,00334	0,02742	0,02957	0,02602	0,02623
24	0,01124	0,01357	0,00143	0,00334	0,02712	0,02957	0,02570	0,02623
25	0,01132	0,01350	0,00208	0,00287	0,02796	0,03044	0,02588	0,02757
26	0,01161	0,01325	0,00207	0,00285	0,02796	0,02984	0,02589	0,02699
27	0,01125	0,01315	0,00141	0,00284	0,02742	0,02983	0,02602	0,02699
28	0,01126	0,01323	0,00208	0,00324	0,02792	0,02983	0,02584	0,02659
29	0,01121	0,01313	0,00207	0,00254	0,02696	0,02983	0,02489	0,02729
30	0,01122	0,01382	0,00208	0,00283	0,02796	0,02983	0,02588	0,02700

Pada TABEL 1 dapat dilihat rata-rata akurasi, nilai minimum dan nilai maximum yang dihasilkan oleh metode PSO ELM selalu lebih kecil dari pada metode ELM tanpa menggunakan optimasi. Hasil pada TABEL 1 menunjukkan rata-rata yang dihasilkan oleh metode PSO ELM berkisar antara 0,01121 sampai dengan 0,01161 sedangkan rata-rata yang dihasilkan oleh metode ELM berkisar antara 0,01315 sampai dengan 0,01419. Dengan demikian dapat dikatakan akurasi yang didapat oleh metode PSO ELM lebih kecil dibanding metode ELM. Selain itu *range* yang didapat dari metode PSO ELM lebih kecil dari metode ELM tanpa optimasi. Hal tersebut menunjukkan bahwa penggunaan metode optimasi PSO dapat memperkecil *range* kesalahan yang didapat dari metode ELM.

C. Waktu Proses Metode PSO ELM

Pengujian ini dilakukan menggunakan tiga spesifikasi komputer yang berbeda. Tujuan dari pengujian ini adalah mengetahui waktu proses dari metode PSO ELM. Spesifikasi perangkat pengujian yang digunakan ditunjukkan pada TABEL 2. Dan hasil pengujian menggunakan 10 item *best seller* di-tunjukkan pada

TABEL 3.

TABEL 2. SPESIFIKASI PERANGKAT PENGUJIAN.

Speksifikasi No.	Processor	RAM
Laptop	Core i5 (4 Core)	4 GB

Server	Intel Xeon E5 (24 Core)	32 GB
PC	Dual Core (2 Core)	2 GB

TABEL 3. HASIL PENGUJIAN WAKTU PROSES METODE PSO ELM.

Pengujian	Rata-rata PSO ELM Laptop (s)	Rata-rata ELM Laptop (s)	Rata-rata PSO ELM Server (s)	Rata-rata ELM Server (s)	Rata-rata PSO ELM PC (s)	Rata-rata ELM PC (s)
1	19,9726	0,0412	6,4314	0,0123	24,4167	0,1164
2	19,9726	0,0419	7,0168	0,0288	25,4780	0,1255
3	19,7941	0,0416	6,4440	0,0128	25,2081	0,1206
4	20,3800	0,0419	5,8912	0,0287	25,3318	0,0999
5	17,5409	0,0415	6,4578	0,0187	25,3082	0,0920
6	20,2524	0,0414	6,4263	0,0017	24,2056	0,1275
7	20,2405	0,0412	6,4312	0,0123	25,9315	0,1095
8	20,2959	0,0414	5,8967	0,0288	25,1250	0,1226
9	20,4715	0,0419	5,6763	0,0287	25,1010	0,1322
10	21,1135	0,0412	6,4552	0,0123	25,3237	0,1113

Jika dilihat pada

TABEL 3, waktu proses metode ELM lebih cepat dibandingkan dengan metode PSO ELM. Hal tersebut disebabkan oleh proses pencarian jumlah *hidden nodes* yang optimal pada metode PSO. Sehingga proses perhitungan akan menjadi lebih banyak dan waktu proses yang dibutuhkan akan menjadi lebih lama [10]. Selain itu penggunaan perangkat pengujian akan berpengaruh dengan waktu proses. Waktu proses tercepat dihasilkan oleh perangkat pengujian menggunakan server dan waktu proses terlama dihasilkan oleh perangkat pengujian menggunakan PC seperti yang di-tampilkan pada

TABEL 3.

VII. KESIMPULAN

Dari pembahasan pada bagian sebelumnya, Rata-rata *Mean Square Error* (MSE) yang dihasilkan oleh metode PSO ELM lebih kecil dibanding metode ELM, yaitu berkisar antara 0,01121 sampai dengan 0,01161 untuk metode PSO ELM dan berkisar antara 0,01315 sampai dengan 0,01419 untuk metode ELM. Dengan demikian dapat dikatakan metode PSO mampu mengoptimasi jumlah *hidden nodes* dari metode ELM untuk meramalkan jumlah penjualan barang.

REFERENSI

- [1] A. Kochak and S. Sharma, "Demand Forecasting Using Neural Network For Supply Chain Managemnt," *Int. J. Mech. Eng. Robot. Res.*, vol. 4, no. 1, pp. 97–104, 2015.
- [2] R. Hidayat and Suprpto, "Meminimalisasi Nilai Error Peramalan Dengan Algoritma Extreme Learning Machine," *J. Optimasi Sist. Ind.*, vol. 11, no. 1, pp. 187–192, 2012.
- [3] J. S. D. Raharjo, "Model Artificial Neural Network based on Particle Swarm Optimization Model For Inflation Rate Forecast," *J. Sist. Komput.*, vol. 3, no. 1, pp. 10–21, Jun. 2013.
- [4] D. P. Fardani, E. Wuryanto, and I. Werdiningsih, "Sistem Pendukung Keputusan Peramalan Jumlah Kunjungan Pasien Menggunakan Metode Extreme Learning Machine (Studi Kasus : Poli Gigi Rsu Dr. Wahidin Sudiro Husodo Mojokerto)," *J. Inf. Syst. Eng. Bus. Intell.*, vol. 1, no. 1, Apr. 2015.
- [5] D. A. R. Wati and Y. A. Rochman, "Model Penjadwalan Matakuliah Secara Otomatis Berbasis Algoritma Particle Swarm Optimization (PSO)," *J. Rekayasa Sist. Ind.*, vol. 2, no. 1, 2013.



- [6] B. Santosa and P. Willy, *Metode Metaheuristik, Konsep dan Implementasi*, 1st ed. Surabaya: Guna Widya, 2011.
- [7] S. Makridakis, S. C. Wheelwright, and R. J. Hyndman, *Forecasting Methods And Applications, 3rd Ed.* Wiley India Pvt. Limited, 2008.
- [8] K. G. Sheela, S. N. Deepa, K. G. Sheela, and S. N. Deepa, "Review on Methods to Fix Number of Hidden Neurons in Neural Networks, Review on Methods to Fix Number of Hidden Neurons in Neural Networks," *Math. Probl. Eng. Math. Probl. Eng.*, vol. 2013, 2013, p. e425740, Jun. 2013.
- [9] R. J. Hyndman and G. Athanasopoulos, *Forecasting: principles and practice*. OTexts, 2014.
- [10] Q. Hua Liang, "Improving the Conditioning of Extreme Learning Machine by Using Particle Swarm Optimization," *Int. J. Digit. Content Technol. Its Appl.*, vol. 6, no. 2, pp. 85–93, Feb. 2012.