

# Penerapan Metode *Nueral Network* dan *Particle Swarm Optimization* (PSO) untuk Prediksi Penjualan Bahan Kimia

Asri Wahyuni<sup>1</sup>, Narti<sup>2</sup>, Eka Puspita Sari<sup>3</sup>

**Abstract—** Many chemical production companies are competing to continue producing mainly Hydrated Lime chemicals. Hydrated Lime is used to mix paper making one of them. The development of paper marketing is now progressing rapidly, hence the company makes a great opportunity in the production of Hydrated Lime chemicals. An increase in the number of paper mills not accompanied by the supply of Hydrated Lime chemicals may result in scarcity. In this case will encourage the company continues to increase its production volume to meet growing consumer demand. Prediction is a source of information that can be used by companies to prepare themselves in determining the strategy for the future better. In this study, predicted sales of Hydrated Lime with Neural Network method and Particle Swarm Optimization (PSO) optimization to predict time series data, so as to minimize RMSE value. From the test results obtained the average mean Root Mean Square Error (RMSE) Neural Network based Particle Swarm Optimization (PSO) with 7 neurons of 1.279.

**Intisari-** Banyak perusahaan produksi bahan kimia yang bersaing untuk terus memproduksi bahan kimia terutama *Hydrated Lime*. *Hydrated Lime* digunakan untuk campuran pembuatan kertas salah satunya. Perkembangan pemasaran kertas saat ini semakin maju pesat, maka dari itu perusahaan menjadikan suatu peluang yang besar dalam produksi bahan kimia *Hydrated Lime*. Pertambahan jumlah pabrik kertas yang tidak disertai dengan *supply* bahan kimia *Hydrated Lime* sehingga bisa terjadi kelangkaan. Dalam hal ini akan mendorong perusahaan terus meningkatkan *volume* produksinya untuk memenuhi permintaan konsumen yang semakin hari semakin besar. Prediksi merupakan sumber informasi yang dapat digunakan oleh perusahaan untuk mempersiapkan diri dalam menentukan strategi ke depan yang lebih baik. Pada penelitian ini, dilakukan prediksi penjualan *Hydrated Lime* dengan metode *Neural Network* dan optimasi *Particle Swarm Optimization* (PSO) untuk memprediksi data *time series*, sehingga dapat meminimalkan nilai RMSE. Dari hasil pengujian didapatkan nilai rata-rata *Root Mean Square Error* (RMSE) terkecil *Neural Network* berbasis *Particle Swarm Optimization* (Pso) dengan 7 neuron sebesar 1.279.

**Kata Kunci:** *Neural Network*, *Particle Swarm Optimization* (PSO), Prediksi Penjualan, *Time Series*,

## I. PENDAHULUAN

Secara umum penjualan mempunyai arti yaitu kegiatan dimana seorang atau suatu perusahaan mengajak orang lain untuk membeli barang dan jasa ditawarkan yang dapat menghasilkan pendapatan bagi perusahaan itu sendiri. Dalam dunia usaha penjualan merupakan salah satu indikator paling penting dalam sebuah perusahaan, bila tingkat penjualan yang dihasilkan oleh perusahaan tersebut besar, maka laba yang dihasilkan perusahaan itu akan besar pula sehingga perusahaan dapat bertahan dalam persaingan bisnis dan bisa mengembangkan usahanya [6].

PT. Kemindo International, merupakan salah satu perusahaan multinasional yang memberikan solusi bagi pelanggan di bidang kimia, yang meliputi Area Bisnis Kertas, Pertambangan, Batu Bara dan Layanan Logistik. PT. Kemindo International memproduksi produk salah satunya adalah *Hydrated Lime* yaitu bubuk bahan kimia untuk pembuatan kertas. *Hydrated Lime* atau kata lain Kalsium hidroksida adalah senyawa kimia dengan rumus kimia  $\text{Ca}(\text{OH})_2$ . Kalsium hidroksida dapat berupa kristal tak berwarna atau bubuk putih. Kalsium hidroksida dihasilkan melalui reaksi kalsium oksida ( $\text{CaO}$ ) dengan air. Senyawa ini juga dapat dihasilkan dalam bentuk endapan melalui pencampuran larutan kalsium klorida ( $\text{CaCl}_2$ ) dengan larutan natrium hidroksida ( $\text{NaOH}$ ).

Banyak perusahaan produksi bahan kimia yang bersaing untuk terus memproduksi bahan kimia terutama *Hydrated Lime*. *Hydrated Lime* digunakan untuk campuran pembuatan kertas salah satunya. Perkembangan pemasaran kertas saat ini semakin maju pesat, maka dari itu PT. Kemindo International menjadikan suatu peluang yang besar dalam memproduksi bahan kimia *Hydrated Lime*. Pertambahan jumlah pabrik kertas yang tidak disertai dengan *supply* (Verawaty, Damayanti & Santosa, 2015) bahan kimia *Hydrated Lime* sehingga dapat terjadi kurang akurat dalam penjualan [10] dan kelangkaan produk [11]. Dalam hal ini akan mendorong perusahaan terus meningkatkan *volume* produksinya untuk memenuhi permintaan konsumen yang semakin hari semakin besar. Dengan demikian juga perusahaan tentunya akan semakin meningkat persaingannya sehingga untuk mendorong hal tersebut harus dilakukan strategi untuk dapat bersaing dengan perusahaan lain.

Prediksi merupakan sumber informasi yang dapat digunakan oleh perusahaan untuk mempersiapkan diri dalam menentukan strategi ke depan yang lebih baik. Prediksi penjualan [5] adalah salah satu cara untuk dapat

<sup>1,2</sup> Program Studi Sistem Informasi STMIK Nusa Mandiri, Jl. Kramat no.18, Jakarta. (tlp: 021-3100413; e-mail: [asri.awx@nusamandiri.ac.id](mailto:asri.awx@nusamandiri.ac.id), [narti.nrx@bsi.ac.id](mailto:narti.nrx@bsi.ac.id))

<sup>3</sup> Program Studi Teknik Komputer AMIK BSI Jakarta, Jl. RS. Fatmawati No.24 Jakarta. (tlp: 021-7500282; e-mail: [eka.eps@bsi.ac.id](mailto:eka.eps@bsi.ac.id))

bersaing atau bahkan dapat meningkatkan laba perusahaan sehingga prediksi diperlukan untuk menyetarakan antara perbedaan waktu yang sekarang dan yang akan datang terhadap kebutuhan.

Metode pelatihan yang biasa digunakan untuk memperbaiki bobot jaringan syaraf tiruan adalah backpropagation. Akan tetapi penerapan metode ini masih memiliki kelamahan dalam waktu pelatihan yang lama untuk mencapai konvergen dan penentuan parameter pelatihan. Untuk mengatasi masalah optimasi bobot jaringan maka digunakan *Particle Swarm Optimazation* (PSO), karena merupakan salah satu teknik AI terbaik untuk optimasi dan mempercepat waktu kalkulasi pada proses selanjutnya untuk mencapai keadaan [7].

Karakteristik *Particle Swarm Optimazation* (PSO) adalah interaksi sosial mempromosikan pembagian informasi antara partikel yang akan membantu dalam pencarian solusi yang optimal [8]

Dalam penelitian ini menggunakan metode prediksi rentet waktu *Neural Network* dengan optimasi *Particle Swarm Optimization* (PSO) dan menitikberatkan pada penerapan *Particle Swarm Optimization* (PSO) sebagai metode pelatihan bobot *Neural Network* untuk mendapatkan nilai parameter yang sesuai dan dapat menentukan fitur terbaik pada bobot otribut yang sesuai dan optimal sehingga hasil prediksi lebih akurat dengan nilai *Root Mean Square Error* (RMSE) terkecil karena nilai *Root Mean Square Error* (RMSE) yang tertinggi berdampak pada nilai akurasi.

## II. KAJIAN LITERATUR

### A. Data Mining

Data Mining didefinisikan sebagai proses penemuan pola dalam data [13]. Menurut Daryl Pregibons (Gorunescu, 2011) "Data mining adalah perpaduan dari ilmu statistik, kecerdasan buatan, dan penelitian bidang *database*". Keduanya memerlukan penyaringan melalui sejumlah besar material, atau menyelidiki dengan cerdas untuk mencari keberadaan sesuatu yang bernilai. Nama data mining berasal dari kemiripan antara pencarian informasi yang bernilai dari *database* yang besar dengan menambang sebuah gunung untuk sesuatu yang bernilai [2]

### B. Peramalan Penjualan

Peramalan penjualan mengacu kepada memprediksi penjualan berdasarkan data histori. Berkaitan dengan kompetensi dan globalisasi, peramalan penjualan memainkan peran penting pada sistem pengambilan keputusan pada perusahaan komersil [4]. Efektifitas ramalan penjualan dapat menolong pengambilan keputusan mengkalkulasi produksi dan biaya material serta menentukan harga jual [1] Ramalan penjualan akan menghasilkan resiko rendah pada *inventory*, respon cepat dan mencapai objektif pengantaran *Just In Time* (JIT) [2]. Metode peramalan yang baik dapat menolong *retailers* mengurangi biaya *over stocking* dan *under stocking* [3]

### C. Jaringan Syaraf Tiruan atau *Neural Network*

Jaringan syaraf tiruan merupakan sebuah arsitektur paralel terdistribusi dengan banyak *node* dan *connections*. Tiap *connections* (hubungan) menghubungkan sebuah node lainnya, dan tiap *connections* mempunyai nilai bobot [12]. Jaringan syaraf tiruan telah diregenerasi sebagai model matematik dari kondisi manusia, dengan didasarkan pada asumsi-asumsi sebagai berikut:

- 1) Pemrosesan informasi terjadi pada banyak elemen-elemen sederhana yang disebut dengan *neurons*.
- 2) Sinyal-sinyal dikirim antar *neuron* melalui *connections-links*.
- 3) Setiap *connections-links* mempunyai bobot yang sesuai, tergantung tipe jaringan *neural*.

Setiap *neuron* memiliki *activation function* (biasanya non *linear*) yang merupakan jumlahan dari sinyal-sinyal *input* untuk menentukan sinyal *output*.

### D. *Particle Swarm Optimazation* (PSO)

*Particle Swarm Optimazation* (PSO) adalah teknik optimasi berbasis populasi yang dikembangkan oleh Eberhart dan Kennedy pada tahun 1995, yang terinspirasi oleh perilaku kawanan burung atau ikan [8]. *Particle Swarm Optimazation* (PSO) dapat diasumsikan sebagai kelompok burung secara mencari makanan disuatu daerah. Burung tersebut tidak tahu dimana makanan tersebut berada, tapi mereka tahu seberapa jauh makanan itu berada, jadi strategi terbaik untuk menemukan makanan tersebut adalah dengan mengikuti burung yang terdekat dari makanan tersebut [9] *Particle Swarm Optimazation* (PSO) digunakan untuk memecahkan masalah optimasi. Serupa dengan algoritma genetika (GA), *Particle Swarm Optimazation* (PSO) melakukan pencarian menggunakan populasi (*swarm*) dari individu (*particle*) yang akan diperbarui dari iterasi. *Particle Swarm Optimazation* (PSO) memiliki beberapa parameter seperti posisi, kecepatan, kecepatan maksimum, konstanta percepatan, dan berat inersia. *Particle Swarm Optimazation* (PSO) memiliki perbandingan lebih unggul untuk banyak masalah optimasi dengan lebih cepat dan tingkat konvergensi yang lebih stabil [8].

## III. METODE PENELITIAN

Jenis metode penelitian yang digunakan pada penelitian ini adalah penelitian Eksperimen, dimana penelitian ini termasuk dalam metode penelitian kuantitatif dengan metode penelitian antara lain pengumpulan data dimana data yang digunakan adalah data rentet waktu (*time series*) berupa data primer yang diambil dari data penjualan ataupun permintaan konsumen.

Data penelitian ini berisi record data penjualan hari ini serta data penjualan hari sebelumnya yang akan digunakan untuk memprediksi penjualan di hari berikutnya.

Dalam pengolahan data penelitian ini menggunakan atribut untuk tahap pengelolaan data awal (*preparation data*) dengan teknik *Data Integration* untuk meningkatkan akurasi dan efisiensi algoritma (Puspita & Wahyudi, 2015).

Data yang digunakan bernilai kategorikal. Data *Size Reduction and Discritization*, untuk memperoleh data set dengan jumlah atribut dan record yang lebih sedikit tetapi bersifat informatif. Semua dataset akan diuji dengan metode *Neural Network* yang dioptimasi dengan *Particle Swarm Optimization (PSO)* pada aplikasi Ms. Excel 2013 & Rapid Miner 5.

Banyaknya data penelitian ini diambil mulai dari September 2014 hingga Maret 2016 sebanyak 755 record/data penjualan ataupun data permintaan konsumen untuk data yang akan diolah dalam pengujian metode.

#### IV. HASIL DAN PEMBAHASAN

Pada tahap ini dilakukan eksperimen dan pengujian metode *Neural Network* dengan optimasi *Particle Swarm Optimazation* (PSO). Metode ini dilakukan dengan menentukan data training dan data testing, parameter *Neural Network* dengan optimasi *Particle Swarm Optimazation* (PSO) dan penentuan *size hidden layer*.

Dari data yang telah ada sebanyak 755 record untuk pengolahan data selanjutnya adalah menentukan atribut yang digunakan dalam tahap pengelolaan data awal (*Preparation Data*). Atribut yang digunakan diantaranya :

TABEL 1.  
ATRIBUT YANG DIGUNAKAN

No	Atribut	Nilai
1	Tanggal	Tanggal Penjualan
2	Bayar	Tempo Pembayaran
3	Jumlah Produksi	Jumlah Produksi
4	Stok Produk	Stok Produk
5	Total	Total Penjualan

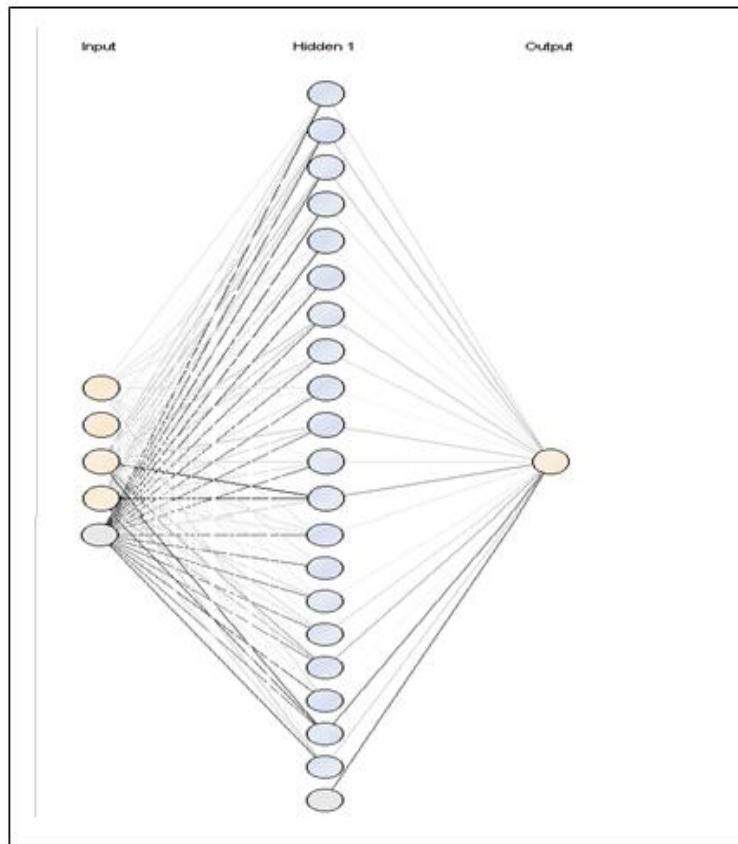
Dengan menerapkan *Neural Network* dengan optimasi *Particle Swarm Optimazation* (PSO) pada *Rapidminer* dengan setting parameter *default* untuk mencari proporsi yang tepat untuk pembagian data antara data *training* dan data *testing*. Penentuan tersebut dilakukan menggunakan data penjualan *Hydrated Lime* yang telah diuji sebagai berikut :

TABEL 2.  
PEMBAGIAN DATA TRAINING & DATA TESTING

Training (%)	Testing(%)	RMSE
55	45	31.270
60	40	24.733
65	35	49.216
70	30	27.047
75	25	26.995
80	20	44.216
85	15	28.960
90	10	22.314 *
95	5	26.417

Berdasarkan tabel diatas, proporsi *split* data yang digunakan untuk menghasilkan *Root Mean Square Error* (RMSE) terkecil yaitu proporsi 90-10. Dengan demikian berarti penelitian ini dapat menggunakan *split* data *training* 90% dan *testing* 10%, dalam artian penelitian tersebut dapat menggunakan 679 data untuk *training* dan 76 data untuk *testing*.

Berdasarkan dari data awal dan atribut yang digunakan serta dalam pengujian penelitian ini dilakukan satu persatu maka dapat digambarkan arsitektur sebagai berikut :



Gbr 1. Arsitektur Neural Network dengan optimasi Particle Swarm Optimazation (PSO)

Arsitektur diatas merupakan arsitektur 5-20-1, arsitektur ini terdiri dari 1 lapisan input dengan 5 *neuron*, 1 lapisan *hidden* dengan 20 *neuron*, dan 1 lapisan *output* dengan 1 *neuron*, arsitektur tersebut masih belum diolah satu persatu untuk menghasilkan yang teroptimal.

Dalam penelitian ini untuk mendapatkan nilai *training cycles* ditentukan dengan cara melakukan pengujian memasukan nilai *training cycles* antara 100 – 1000, nilai *learning rate* 0.3 dan *momentum* 0.2. Berikut hasil pengujian untuk menentukan nilai *training cycles*.

TABEL 3.  
PENGUJIAN MENENTUKAN NILAI TRAINING CYCLES

<b>Training Cycles</b>	<b>Learning Rate</b>	<b>Momentum</b>	<b>RMSE</b>
100	0.3	0.2	28.909
200	0.3	0.2	27.262
300	0.3	0.2	26.765
400	0.3	0.2	26.533
500	0.3	0.2	26.417
600	0.3	0.2	26.357
700	0.3	0.2	26.325
800	0.3	0.2	26.307
900	0.3	0.2	26.297
<b>1000</b>	<b>0.3</b>	<b>0.2</b>	<b>26.291 *</b>

Berdasarkan hasil pengujian diatas, terdapat nilai *training cycles* berdasarkan dari nilai *Root Mean Square Error* (RMSE) terkecil yaitu nilai *training cycles* 1000 dengan nilai RMSE 26.291. Dengan nilai *training cycles* tersebut selanjutnya akan digunakan untuk menentukan nilai *Root Mean Square Error* (RMSE) terkecil yang disertakan nilai *learning rate* dan nilai *momentum*.

Pada penelitian ini *hidden layer* yang digunakan adalah 1 *hidden layer* dengan pengujian yang dilakukan *size range* 1 sampai dengan 20. Yaitu untuk menentukan *size hidden layer* yang nantinya akan digunakan untuk mengukur *Root Mean Square Error* (RMSE) terkecil selanjutnya. Berikut hasil pengujian yang dilakukan :

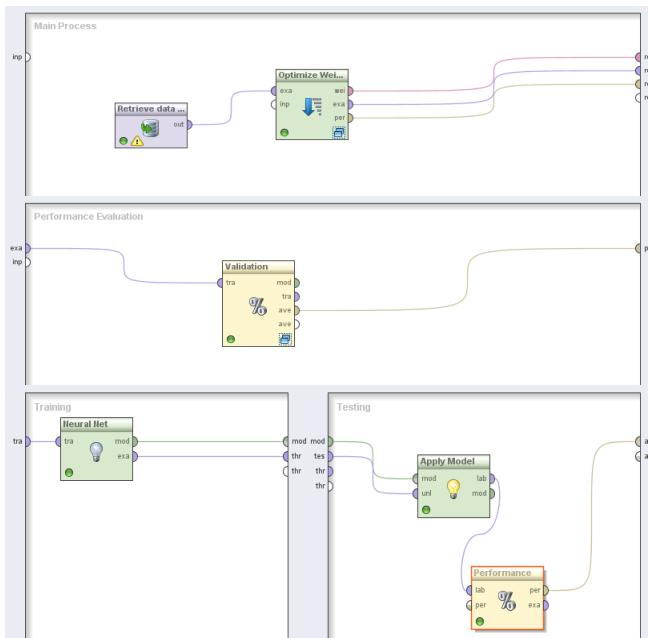
TABEL 4.  
PENGUJIAN MENENTUKAN SIZE HIDDEN LAYER DENGAN SATU HIDDEN LAYER

<b>Size</b>	<b>Training Cycles</b>	<b>Learning Rate</b>	<b>Momen tum</b>	<b>RMSE</b>
1	1000	0.3	0.2	26.291
2	1000	0.3	0.2	10.466
3	1000	0.3	0.2	15.701
4	1000	0.3	0.2	18.832
5	1000	0.3	0.2	8.366
6	1000	0.3	0.2	8.710
<b>7</b>	<b>1000</b>	<b>0.3</b>	<b>0.2</b>	<b>5.441 *</b>
8	1000	0.3	0.2	11.796
9	1000	0.3	0.2	10.487

10	1000	0.3	0.2	9.824
11	1000	0.3	0.2	10.768
12	1000	0.3	0.2	8.360
13	1000	0.3	0.2	11.164
14	1000	0.3	0.2	12.617
15	1000	0.3	0.2	18.412
16	1000	0.3	0.2	8.694
17	1000	0.3	0.2	5.121 *
18	1000	0.3	0.2	8.198 *
19	1000	0.3	0.2	8.144 *
20	1000	0.3	0.2	7.960 *

Dari pengujian diatas, dihasilkan beberapa hasil terbaik dengan satu *hidden layer* yaitu *hidden layer* dengan size 7, 17, 18, 19 dan 20 dengan masing-masing RMSE terkecil yaitu 5.441, 5.121, 8.198, 8.144, dan 7.960. Size *hidden layer* tersebut yang dapat digunakan untuk pengujian selanjutnya berdasarkan dari *Training Cycle*, *Learning Rate* dan *Momentum*.

Penelitian ini menguji keakuratan analisa prediksi data penjualan menggunakan *Neural Network* dengan optimasi PSO dari data penjualan Bahan Kimia. Berikut merupakan gambar pengujian algoritma *Neural Network* dengan optimasi *Particle Swarm Optimazation* (PSO) menggunakan metode *Split Validation*.



Gbr 2. Pengujian SplitValidation Neural Network & Particle Swarm Optimazation (PSO)

Pada penelitian ini, pengujian dilakukan untuk mendapatkan hasil *Root Mean Square Error* (RMSE) terkecil pada satu *Hidden Layer* dengan size 7 *neuron*, *Learning Rate* 0.1-0.5, *Momentum* 0.1-0.5, *Training Cycle* 1000, Populasi 20, C1 1.0, C2 1.0, dan *Inertia* 1.0 . Berikut pengujian tersebut :

TABEL 5.  
PENGUJIAN NEURAL NETWORK – PARTICLE SWARM  
OPTIMAZATION (PSO) PADA SATU HIDDEN LAYER DENGAN 7  
NEURON

Lear ning Rate	Mome ntum	Traini ng Cycle	Popul asi	C1	C2	iner tia	RMSE
0,1	0,1	1000	20	1,0	1,0	1,0	2.753
0,2	0,1	1000	20	1,0	1,0	1,0	2.353
0,3	0,1	1000	20	1,0	1,0	1,0	2.364
0,4	0,1	1000	20	1,0	1,0	1,0	1.968
0,5	0,1	1000	20	1,0	1,0	1,0	1.541
0,1	0,2	1000	20	1,0	1,0	1,0	2.787
0,2	0,2	1000	20	1,0	1,0	1,0	2.489
0,3	0,2	1000	20	1,0	1,0	1,0	2.197
0,4	0,2	1000	20	1,0	1,0	1,0	2.047
0,5	0,2	1000	20	1,0	1,0	1,0	1.701
0,1	0,3	1000	20	1,0	1,0	1,0	2.690
0,2	0,3	1000	20	1,0	1,0	1,0	2.115
0,3	0,3	1000	20	1,0	1,0	1,0	1.974
0,4	0,3	1000	20	1,0	1,0	1,0	1.928
0,5	0,3	1000	20	1,0	1,0	1,0	1.476
0,1	0,4	1000	20	1,0	1,0	1,0	2.725
0,2	0,4	1000	20	1,0	1,0	1,0	2.299
0,3	0,4	1000	20	1,0	1,0	1,0	2.151
0,4	0,4	1000	20	1,0	1,0	1,0	1.632
0,5	0,4	1000	20	1,0	1,0	1,0	1.461
0,1	0,5	1000	20	1,0	1,0	1,0	2.312
0,2	0,5	1000	20	1,0	1,0	1,0	2.255
0,3	0,5	1000	20	1,0	1,0	1,0	1.914
0,4	0,5	1000	20	1,0	1,0	1,0	1.730
0,5	0,5	1000	20	1,0	1,0	1,0	1.279*

Dari pengujian diatas didapat hasil terbaik dengan pengujian sebanyak 25 variasi pengubahan parameter *learning rate* dan *momentum* menghasilkan *Root Mean Square Error* (RMSE) terkecil dengan nilai *Leraning Rate* 0.5, *Momentum* 0.5 dengan nilai RMSE yaitu 1.279.

Selanjutnya pengujian yang dilakukan untuk menentukan nilai *Root Mean Square Error* (RMSE) terkecil pada satu *Hidden Layer* dengan size 17 *neuron*, *Learning Rate* 0.1-0.5, *Momentum* 0.1-0.5, *Training Cycle* 1000, Populasi 20, C1 1.0, C2 1.0, dan *Inertia* 1.0 . Berikut pengujian tersebut :

TABEL 6.  
PENGUJIAN NEURAL NETWORK – PARTICLE SWARM  
OPTIMAZATION (PSO) PADA SATU HIDDEN LAYER DENGAN 17  
NEURON

Lear ning Rate	Mome ntum	Traini ng Cycle	Popu lasi	C1	C2	iner tia	RMSE
0,1	0,1	1000	20	1,0	1,0	1,0	2.200
0,2	0,1	1000	20	1,0	1,0	1,0	2.092
0,3	0,1	1000	20	1,0	1,0	1,0	1.939
0,4	0,1	1000	20	1,0	1,0	1,0	1.821
0,5	0,1	1000	20	1,0	1,0	1,0	1.813
0,1	0,2	1000	20	1,0	1,0	1,0	2.215
0,2	0,2	1000	20	1,0	1,0	1,0	2.105
0,3	0,2	1000	20	1,0	1,0	1,0	1.895
0,4	0,2	1000	20	1,0	1,0	1,0	1.784

0,5	0,2	1000	20	1,0	1,0	1,0	1.646*
0,1	0,3	1000	20	1,0	1,0	1,0	2.230
0,2	0,3	1000	20	1,0	1,0	1,0	2.014
0,3	0,3	1000	20	1,0	1,0	1,0	1.789
0,4	0,3	1000	20	1,0	1,0	1,0	1.854
0,5	0,3	1000	20	1,0	1,0	1,0	1.666
0,1	0,4	1000	20	1,0	1,0	1,0	2.131
0,2	0,4	1000	20	1,0	1,0	1,0	2.000
0,3	0,4	1000	20	1,0	1,0	1,0	1.817
0,4	0,4	1000	20	1,0	1,0	1,0	1.716
0,5	0,4	1000	20	1,0	1,0	1,0	1.530
0,1	0,5	1000	20	1,0	1,0	1,0	2.062
0,2	0,5	1000	20	1,0	1,0	1,0	1.906
0,3	0,5	1000	20	1,0	1,0	1,0	1.602
0,4	0,5	1000	20	1,0	1,0	1,0	1.629
0,5	0,5	1000	20	1,0	1,0	1,0	1.474

Dari pengujian diatas didapat hasil terbaik dengan pengujian sebanyak 25 variasi pengubahan parameter *learning rate* dan *momentum* menghasilkan *Root Mean Square Error* (RMSE) terkecil dengan nilai *Leraning Rate* 0.5, *Momentum* 0.2 dengan nilai RMSE yaitu 1.646.

Selanjutnya pengujian yang dilakukan untuk menentukan nilai *Root Mean Square Error* (RMSE) terkecil pada satu *Hidden Layer* dengan size 18 *neuron*, *Learning Rate* 0.1-0.5, *Momentum* 0.1-0.5, *Training Cycle* 1000, Populasi 20, C1 1.0, C2 1.0, dan *Inertia* 1.0 . Berikut pengujian tersebut :

Dari pengujian diatas didapat hasil terbaik dengan pengujian sebanyak 25 variasi pengubahan parameter *learning rate* dan *momentum* menghasilkan *Root Mean Square Error* (RMSE) terkecil dengan nilai *Leraning Rate* 0.4, *Momentum* 0.2 dengan nilai RMSE yaitu 1.410.

Selanjutnya pengujian yang dilakukan untuk menentukan nilai *Root Mean Square Error* (RMSE) terkecil pada satu *Hidden Layer* dengan size 19 *neuron*, *Learning Rate* 0.1-0.5, *Momentum* 0.1-0.5, *Training Cycle* 1000, Populasi 20, C1 1.0, C2 1.0, dan *Inertia* 1.0 . Berikut pengujian tersebut :

TABEL 8.  
PENGUJIAN NEURAL NETWORK – PARTICLE SWARM  
OPTIMAZATION (PSO) PADA SATU HIDDEN LAYER DENGAN 19  
NEURON

Lear ning Rate	Mome ntum	Triai ning Cycle	Popu lasi	C1	C2	Iner tia	RMSE
0,1	0,1	1000	20	1,0	1,0	1,0	2.150
0,2	0,1	1000	20	1,0	1,0	1,0	1.976
0,3	0,1	1000	20	1,0	1,0	1,0	1.957
0,4	0,1	1000	20	1,0	1,0	1,0	1.504
0,5	0,1	1000	20	1,0	1,0	1,0	2.879
0,1	0,2	1000	20	1,0	1,0	1,0	2.187
0,2	0,2	1000	20	1,0	1,0	1,0	1.907
0,3	0,2	1000	20	1,0	1,0	1,0	1.666
0,4	0,2	1000	20	1,0	1,0	1,0	1.845
0,5	0,2	1000	20	1,0	1,0	1,0	1.745
0,1	0,3	1000	20	1,0	1,0	1,0	1.867
0,2	0,3	1000	20	1,0	1,0	1,0	1.982
0,3	0,3	1000	20	1,0	1,0	1,0	1.735
0,4	0,3	1000	20	1,0	1,0	1,0	1.732
0,5	0,3	1000	20	1,0	1,0	1,0	2.567
0,1	0,4	1000	20	1,0	1,0	1,0	2.120
0,2	0,4	1000	20	1,0	1,0	1,0	1.846
0,3	0,4	1000	20	1,0	1,0	1,0	1.908
0,4	0,4	1000	20	1,0	1,0	1,0	1.639
0,5	0,4	1000	20	1,0	1,0	1,0	1.475*
0,1	0,5	1000	20	1,0	1,0	1,0	2.105
0,2	0,5	1000	20	1,0	1,0	1,0	1.784
0,3	0,5	1000	20	1,0	1,0	1,0	1.799
0,4	0,5	1000	20	1,0	1,0	1,0	1.669
0,5	0,5	1000	20	1,0	1,0	1,0	1.539

Dari pengujian diatas didapat hasil terbaik dengan pengujian sebanyak 25 variasi pengubahan parameter *learning rate* dan *momentum* menghasilkan *Root Mean Square Error* (RMSE) terkecil dengan nilai *Leraning Rate* 0.5, *Momentum* 0.4 dengan nilai RMSE yaitu 1.475.

Selanjutnya pengujian yang dilakukan untuk menentukan nilai *Root Mean Square Error* (RMSE) terkecil pada satu *Hidden Layer* dengan size 20 *neuron*, *Learning Rate* 0.1-0.5, *Momentum* 0.1-0.5, *Training Cycle* 1000, Populasi 20, C1 1.0, C2 1.0, dan *Inertia* 1.0 . Berikut pengujian tersebut :

Lear ning Rate	Mome ntum	Triai ning Cycle	Popu lasi	C1	C2	inertia	RMSE
0,1	0,1	1000	20	1,0	1,0	1,0	2.230
0,2	0,1	1000	20	1,0	1,0	1,0	2.175
0,3	0,1	1000	20	1,0	1,0	1,0	1.922
0,4	0,1	1000	20	1,0	1,0	1,0	1.734
0,5	0,1	1000	20	1,0	1,0	1,0	1.579
0,1	0,2	1000	20	1,0	1,0	1,0	2.247
0,2	0,2	1000	20	1,0	1,0	1,0	1.996
0,3	0,2	1000	20	1,0	1,0	1,0	2.013
0,4	0,2	1000	20	1,0	1,0	1,0	1.410*
0,5	0,2	1000	20	1,0	1,0	1,0	1.721
0,1	0,3	1000	20	1,0	1,0	1,0	2.235
0,2	0,3	1000	20	1,0	1,0	1,0	1.989
0,3	0,3	1000	20	1,0	1,0	1,0	1.764
0,4	0,3	1000	20	1,0	1,0	1,0	1.672
0,5	0,3	1000	20	1,0	1,0	1,0	1.628
0,1	0,4	1000	20	1,0	1,0	1,0	2.127
0,2	0,4	1000	20	1,0	1,0	1,0	2.047
0,3	0,4	1000	20	1,0	1,0	1,0	1.840
0,4	0,4	1000	20	1,0	1,0	1,0	1.632
0,5	0,4	1000	20	1,0	1,0	1,0	1.600
0,1	0,5	1000	20	1,0	1,0	1,0	2.181
0,2	0,5	1000	20	1,0	1,0	1,0	1.837
0,3	0,5	1000	20	1,0	1,0	1,0	1.678
0,4	0,5	1000	20	1,0	1,0	1,0	1.725
0,5	0,5	1000	20	1,0	1,0	1,0	2.675

TABEL 9.  
PENGUJIAN NEURAL NETWORK – PARTICLE SWARM  
OPTIMAZATION (PSO) PADA SATU HIDDEN LAYER DENGAN 20  
NEURON

Lear ning Rate	Mo men tum	Trai ning Cycle	Popu lasi	C1	C2	iner tia	RMSE
0,1	0,1	1000	20	1,0	1,0	1,0	1,946
0,2	0,1	1000	20	1,0	1,0	1,0	2,095
0,3	0,1	1000	20	1,0	1,0	1,0	1,955
0,4	0,1	1000	20	1,0	1,0	1,0	1,842
0,5	0,1	1000	20	1,0	1,0	1,0	2,968
0,1	0,2	1000	20	1,0	1,0	1,0	1,881
0,2	0,2	1000	20	1,0	1,0	1,0	1,998
0,3	0,2	1000	20	1,0	1,0	1,0	1,957
0,4	0,2	1000	20	1,0	1,0	1,0	1,791
0,5	0,2	1000	20	1,0	1,0	1,0	1,755
0,1	0,3	1000	20	1,0	1,0	1,0	1,973
0,2	0,3	1000	20	1,0	1,0	1,0	1,950
0,3	0,3	1000	20	1,0	1,0	1,0	1,766
0,4	0,3	1000	20	1,0	1,0	1,0	1,782
0,5	0,3	1000	20	1,0	1,0	1,0	1,742
0,1	0,4	1000	20	1,0	1,0	1,0	2,134
0,2	0,4	1000	20	1,0	1,0	1,0	2,018
0,3	0,4	1000	20	1,0	1,0	1,0	1,762
0,4	0,4	1000	20	1,0	1,0	1,0	1,589
0,5	0,4	1000	20	1,0	1,0	1,0	2,934
0,1	0,5	1000	20	1,0	1,0	1,0	2,061
0,2	0,5	1000	20	1,0	1,0	1,0	1,866
0,3	0,5	1000	20	1,0	1,0	1,0	1,662
0,4	0,5	1000	20	1,0	1,0	1,0	1,577*
0,5	0,5	1000	20	1,0	1,0	1,0	2,789

Dari pengujian diatas didapat hasil terbaik dengan pengujian sebanyak 25 variasi pengubahan parameter *learning rate* dan *momentum* menghasilkan *Root Mean Square Error* (RMSE) terkecil dengan nilai *Leraning Rate* 0,4, *Momentum* 0,5 dengan nilai RMSE yaitu 1.577.

Berdasarkan dari hasil diatas didapat beberapa hasil *neuron* antara lain 7 *neuron*, 17 *neuron*, 18 *neuron*, 19 *neuron*, dan 20 *neuron* masing-masing mempunyai nilai RMSE terkecil sebagai berikut :

Neu ron	Learn ing Rate	Mo men tum	Traini ng Cycle	Popul asi	C1	C2	iner tia	RMSE
7	0,5	0,5	1000	20	1,0	1,0	1,0	1,279*
17	0,5	0,2	1000	20	1,0	1,0	1,0	1,646
18	0,4	0,2	1000	20	1,0	1,0	1,0	1,410
19	0,5	0,4	1000	20	1,0	1,0	1,0	1,475
20	0,4	0,5	1000	20	1,0	1,0	1,0	1,577

Dari pengujian diatas telah didapat hasil *Root Mean Square Error* (RMSE) terkecil dengan 7 *neuron* yang menghasilkan nilai terkecil yaitu 1.279. Nilai tersebut merupakan nilai maksimal *Root Mean Square Error* (RMSE) terkecil dengan menggunakan metode *Neural Network* dengan optimasi *Particle Swarm Optimazation* (PSO).

## V. KESIMPULAN

Berdasarkan pengujian diatas sebelumnya dapat diambil kesimpulan bahwa hasil penelitian untuk nilai *Root Mean Square Error* (RMSE) dengan penerapan metode *Neural Network* dengan optimasi *Particle Swarm Optimazation* (PSO) menggunakan 679 *record* dan data *testing* sebanyak 76 *record* serta melakukan pengujian eksperimen yang terbagi 5 (lima) variasi jumlah *neuron* pada *size hidden layer* yaitu 7 *neuron*, 17 *neuron*, 18 *neuron*, 19 *neuron*, dan 20 *neuron* didapat hasil *Root Mean Square Error* (RMSE) terkecil sebesar 1.279 dengan 7 *neuron*, *Learning Rate* 0,5, *Momentum* 0,5, *Training Cycle* 1000, *Populasi* 20, C1 1,0, C2 1,0, Inertia 1,0.

Penerapan metode *Neural Network* dengan optimasi *Particle Swarm Optimazation* (PSO) dapat diartikan bahwa *Neural Network* yang di optimasi dengan *Particle Swarm Optimazation* (PSO) dapat meningkatkan nilai terkecil rata-rata nilai *Root Mean Square Error* (RMSE) untuk prediksi penjualan Bahan Kimia.

## REFERENSI

- [1] Au, K. F. & Chan, N. Y., 2002. Quick response for Hongkong Clothing Suppliers: A Total System Approach. *Proceedings of the 13th Annual Conference of the Production and Operation Management Society*.
- [2] Choi, T. M., 2006. Quick Response in Fashion Supply Chains With Dual Information Updating. *Journal Of Industrial And Management Optimazation*, August, Volume 2, pp. 255-268.
- [3] Eppen, G. D. & Iyer, A. V., 1997. Improved Fashion Buying With Bayesian Updates. *Operation Research*, November-December, 45(0030-364X97/4506), pp. 805-829.
- [4] Kuo, R. J. & Xue, K. C., 1998. A decision support system for sales forecasting through fuzzy neural networks with asymmetric fuzzy weights. *Decision Support Systems*, October 19th, Volume 24, pp. 102-126.
- [5] Lobo, D. G. D. C., & Santosa, S. (2014). Prediksi Penjualan Air Minum Dalam Kemasan Menggunakan Jaringan Syaraf Tiruan Resilient Propagation. *Jurnal Teknologi Informasi* 10(2), 186-210.
- [6] Mulyadi, 2010. Sistem Akuntansi. Edisi Ketiga. Jakarta : Salemba Empat.
- [7] Nugraha, G.H., & Azhari, S.N. (2014). Optimasi Bobot Jaringan Syaraf Tiruan Menggunakan *Particle Swarm Optimization*. *Indonesian Journal Of Computing and Cybernetics Systems*, 8(1), 25-36.
- [8] Park, T.-S., Lee, J.-H. & Choi, B., 2009. Optimization for Artificial Neural Network with Adaptive Inertial Weight of Particle Swarm Optimization. *2009 8th IEEE International Conference on Cognitive Informatics*, June, pp. 481-485.
- [9] Salappa, A., Doumpos, M. & Zopounidis, C., 2007. Feature selection algorithms in classification problems: an

- experimental evaluation. *Optimization Methods and Software*, February, 22(ISSN 1055-6788), pp. 199-214.
- [10] Susilowati, S., & Riasti, B. K. (2012). Pembuatan Sistem Informasi Klinik Rawat Inap Prima Husada Widoro Pacitan Berbasis Website. Speed-Sentra Penelitian Engineering dan Edukasi, 3(1).
- [11] Tukiran, T., & Susanto, A. (2016). Resistensi Dan Fleksibilitas Penduduk Perdesaan Lahan Kering. Jurnal Populasi, 10(1).
- [12] Widodo, P. P. & Handayanto, R. T., 2012. *Penerapan Soft Computing dengan MatLab*. Bandung: Rekayasa Sains.
- [13] Witten, I. H. & Frank, E., 2011. *Data Mining : Practical Machine Learning Tools and Technique*. 3rd penyunt. USA: Elsevier.



Asri Wahyuni, memperoleh gelar S.Kom pada Program Studi Sistem Informasi STMIK Nusa Mandiri Jakarta, lulus tahun 2013 dan S2 Program Studi Ilmu Komputer STMIK Nusa Mandiri Jakarta, lulus tahun 2016. Saat ini bekerja pada sebagai Tenaga Pengajar pada STMIK Nusa Mandaidi dan AMIK BSI Jakarta.



Narti, memperoleh gelar S.Kom pada Program Studi Sistem Informasi STMIK Nusa Mandiri Jakarta, lulus tahun 2014 dan S2 Program Studi Ilmu Komputer STMIK Nusa Mandiri Jakarta, lulus tahun 2016. Saat ini bekerja pada sebagai Tenaga Pengajar pada STMIK Nusa Mandaidi dan AMIK BSI Jakarta.



Eka Puspita Sari, memperoleh gelar S.Kom pada Program Studi Sistem Informasi STMIK Nusa Mandiri Jakarta, lulus tahun 2009 dan S2 Program Studi Ilmu Komputer STMIK Nusa Mandiri Jakarta, lulus tahun 2014. Saat ini bekerja pada sebagai Tenaga Pengajar pada STMIK Nusa Mandaidi dan AMIK BSI Jakarta.