

# Model Prediksi Penjualan Makanan Berbasis *Neural Network Backpropagation* dengan Optimasi *Particle Swarm Optimization*

Syarif Hidayatulloh

**Abstract**— Predictions in sales have an important role because prediction results can be used as a tool in making decisions based on sales history data. The Neural Network (NN) algorithm can be used in predicting. However, it still has weaknesses in training time and parameter determination. To overcome the problem used Particle Swarm Optimization (PSO) for optimization and speed up the calculation time in the next process to achieve convergen state. In this research, the parameters of NN and PSO are arranged. Setting is done to get the smallest RMSE value so that formed the best model of the method used.

**Intisari**— Prediksi di bidang penjualan memiliki peranan penting karena hasil prediksi dapat digunakan sebagai alat bantu dalam membuat keputusan berdasarkan data histori penjualan. Algoritma *Neural Network* (NN) dapat digunakan dalam hal memprediksi. Akan tetapi masih memiliki kelemahan dalam waktu pelatihan dan penentuan parameternya. Untuk mengatasi masalah tersebut digunakan *Particle Swarm Optimization* (PSO) untuk optimasi dan mempercepat waktu kalkulasi pada proses selanjutnya untuk mencapai keadaan *convergen*. Dalam penelitian ini, dilakukan pengaturan Parameter-parameter NN dan PSO. Pengaturan tersebut dilakukan untuk mendapatkan nilai RMSE terkecil sehingga terbentuk model terbaik dari metode yang digunakan.

**Kata Kunci**— Prediksi, *time series*, *neural network*, PSO.

## I. PENDAHULUAN

Penjualan merupakan sebuah proses dimana kebutuhan pembeli dan penjualan dipenuhi, melalui pertukaran informasi dan kepentingan. Jadi konsep penjualan adalah cara untuk memengaruhi konsumen untuk membeli produk yang ditawarkan [15]. Menurut Swastha dan Irawan, “di dalam penjualan dipengaruhi oleh beberapa faktor diantaranya kondisi dan kemampuan penjual (pengadaan barang), jenis dan karakteristik barang yang ditawarkan, frekuensi pembelian”.

Sebuah minimarket yang menjual produk makanan langsung kepada konsumen memiliki masalah dalam menentukan jumlah permintaan barang kepada produsen. Sebagian besar makanan yang dijual mempunyai jenis dan karakteristik khusus. Produk seperti roti dan makan siap saji yang dijual di minimarket ini tidak mengandung pengawet, maka dari itu makanan-makanan ini hanya tahan 3 sampai 5

hari saja dalam suhu ruangan yang sejuk untuk roti dan dalam keadaan beku untuk makanan siap saji. Akan tetapi untuk menjaga kualitas makanan yang dijual, 3 hari setelah permintaan barang dari produsen, barang harus dibuang atau disebut dengan istilah WO (*Work Off*). Masalah kedua yang dihadapi yaitu terkadang penjualan tidak dapat diprediksi dengan akurat dan terjadi penumpukan barang WO yang cukup banyak. Prediksi penjualan yang tidak akurat menyebabkan jumlah permintaan barang kepada produsen tidak tepat.

Prediksi merupakan metode yang digunakan untuk memperkirakan suatu nilai dimasa depan dengan menggunakan *record* data di masa lalu. Sedangkan aktifitas prediksi adalah merupakan suatu fungsi bisnis yang berusaha memperkirakan penjualan dan penggunaan suatu produk sehingga produk-produk itu dapat dibuat atau disediakan dengan tepat [10]. Masalah prediksi banyak dihadapi pada berbagai bidang persoalan antara lain ramalan cuaca, ramalan beban listrik, dan ramalan penjualan [10]. Dalam penelitian ini salah satu bidang permasalahan yang diteliti adalah bidang penjualan. Prediksi dalam bidang penjualan memiliki peranan yang cukup penting karena hasil peramalan dapat digunakan sebagai alat untuk membantu para produsen atau pembuat keputusan menangani masalah dan memberikan informasi peramalan data masa depan berdasarkan data histori yang telah terjadi [22].

Data yang digunakan dalam penelitian ini adalah data rentet waktu (*time series*) yang menyimpan *record* penjualan suatu produk dalam beberapa bulan/tahun terakhir. Dalam perkembangan penelitian, data rentet waktu merupakan objek penelitian dari *data mining* karena banyak berhubungan dengan bidang seperti keuangan, kesehatan, kimia, biologi, astronomi, robotik, jaringan komputer, dan industri. Keunikan dari data rentet waktu sendiri karena jumlah data yang besar ada atau keragaman datanya menurut dan tidak terstruktur [4].

Metode yang digunakan untuk mengolah data rentet waktu dalam penelitian ini adalah *Neural Network* (NN) dengan optimasi *Particle Swarm Optimization* (PSO). NN memiliki kelebihan pada prediksi non linear, memiliki performance yang sangat baik dari parallel processing dan kemampuan untuk mentoleransi kesalahan [25]. Hal ini sangat tepat untuk karakteristik data prediksi penjualan pada penelitian ini.

NN memiliki beberapa algoritma seperti *Perceptron* dan *Backpropagation*. Algoritma yang paling populer pada metode NN adalah algoritma *Backpropagation* yang banyak digunakan untuk memecahkan banyak masalah di

*Jurusan Sistem Informasi STMIK Nusa Mandiri Jakarta, Jl. Damai No. 8, Warung Jati Barat (Margasatwa), Pasar Minggu, RT.1/RW.1, Ragunan, Pasar Minggu, Jakarta 12540 (telp: 021-78839502; fax: 021-78839421; e-mail: arrh56@gmail.com)*

dunia nyata dengan membangun model terlatih yang menunjukkan kinerja yang baik dalam beberapa masalah *non linear* [23]. Pada implementasi beberapa metode masih memiliki beberapa kelemahan diantaranya waktu pelatihan yang lama, penentuan parameter pelatihan seperti *learning rate* dan *momentum* yang tepat dalam proses pelatihan [21].

Beberapa penelitian yang terkait dengan penggunaan metode NN dan PSO dalam memprediksi penjualan maupun produksi, antara lain: penelitian untuk memprediksi susu kambing mingguan. Penelitian dari 35 kambing, 22 kambing menjadi model *neural* dan 13 kambing sebagai *data testing*. Setelah dijalankan dengan model NN ditemukan bahwa input terpenting dari produksi susu kambing ditentukan dari pasteurisasi, pengendalian produksi susu dan macam diet yang diterapkan. Hasil dengan model *neural* dengan tingkat akurasi RMSE (*Root Mean Square Error*) = 0.31kg/d dan low bias (kesalahannya, ME) = -0.05kg/dl [9].

Hartono & Wahono melakukan penelitian untuk memprediksi penjualan minuman kesehatan menggunakan metode NN yang menyatakan bahwa NN dengan algoritma *Backpropagation* dapat menghasilkan model rentet waktu secara akurat. Kendala dalam penelitian ini adalah kenaikan penjualan yang kadang signifikan terhadap bulan-bulan tertentu [12].

Penelitian memprediksi pelanggan telekomunikasi yang hilang menggunakan NN *Backpropagation* dan PSO. Didapatkan bahwa NN *Backpropagation* memiliki kelemahan pada kebutuhan untuk data pelatihan besar dan untuk optimasi kurang efisien. PSO digunakan untuk memecahkan masalah optimasi tersebut. Pengujian model dengan berbasis NN *Backpropagation* dengan optimasi PSO menggunakan data pelanggan hilang pada telekomunikasi. Model yang dihasilkan diuji untuk memperoleh akurasi dan nilai AUC dari masing-masing algoritma untuk mendapatkan tes menggunakan nilai yang diperoleh akurasi NN *Backpropagation* adalah 85,48% dan nilai AUC adalah 0,531. Sementara pengujian dengan menggunakan NN *Backpropagation* berbasis PSO dipilih atribut dan penyesuaian nilai parameter yang diperoleh 86,05%. Akurasi dan nilai AUC adalah 0,637. Dari penelitian ini disimpulkan bahwa penggunaan NN *Backpropagation* berbasis PSO lebih akurat dalam prediksi pelanggan telekomunikasi yang hilang dibanding dengan NN *Backpropagation* [20].

Dari data diatas dapat kita lihat bahwa algoritma NN merupakan algoritma yang dapat digunakan dalam memprediksi data rentet waktu untuk data penjualan yang beragam. Metode peramalan yang memiliki tingkat error data cukup rendah dan cukup baik dalam proses generalisasi adalah NN [29]. Dengan *data training* yang cukup dan proses pembelajaran penyesuaian bobot yang tepat diharapkan model ini mampu untuk meramalkan data rentet waktu untuk beberapa periode waktu kedepan.

Metode pelatihan yang biasa digunakan untuk memperbaiki bobot jaringan syaraf tiruan adalah *Backpropagation*. Akan tetapi penerapan metode ini masih memiliki kelemahan dalam waktu pelatihan yang lama

untuk mencapai *convergen* dan penentuan parameter pelatihan. Untuk mengatasi masalah optimasi bobot jaringan maka digunakan PSO, karena merupakan salah satu teknik AI terbaik untuk optimasi dan mempercepat waktu kalkulasi pada proses selanjutnya untuk mencapai keadaan *convergen* [21]. Karakteristik PSO adalah interaksi sosial mempromosikan pembagian informasi antara partikel yang akan membantu dalam pencarian solusi yang optimal [23]

Pada penelitian ini menggunakan prediksi rentet waktu NN *Backpropagation* dengan optimasi PSO dan menitik beratkan pada penerapan PSO sebagai metode pelatihan bobot NN *Backpropagation* untuk mendapatkan hasil yang lebih akurat dalam memprediksi penjualan agar bisa membuat permintaan barang kepada produsen dengan lebih akurat.

Berdasarkan latar belakang dan rumusan masalah diatas, maka penelitian tujuan dari penelitian ini adalah untuk meneliti dan mengimplementasi metode NN *Backpropagation* dengan optimasi PSO dalam prediksi penjualan dengan lebih akurat dan mendapatkan nilai error yang lebih kecil.

## II. KAJIAN LITERATUR

Data berkala atau *time series* adalah data yang dikumpulkan dari waktu ke waktu untuk menggambarkan perkembangan suatu kegiatan. Analisis data berkala memungkinkan kita untuk mengetahui perkembangan suatu atau beberapa kejadian serta hubungan/ pengaruh terhadap kejadian lainnya. Pola gerakan data atau nilai-nilai variabel dapat diikuti atau diketahui dengan adanya data berkala, sehingga data berkala dapat dijadikan sebagai dasar untuk:


1. Pembuatan keputusan pada saat ini
2. Peramalan keadaan perdagangan dan ekonomi pada masa yang akan datang
3. Perencanaan kegiatan untuk masa depan

Gerakan-gerakan khas dari data *time series* dapat digolongkan kedalam empat kelompok utama, yang sering disebut komponen-komponen *time series*:

1. Gerakan jangka panjang atau sekuler merujuk kepada arah umum dari grafik *time series* yang meliputi jangka waktu yang panjang.
2. Gerakan siklis atau variasi siklis merujuk kepada gerakan naik turun dalam jangka panjang dari suatu garis atau kurva *trend*. Siklis yang demikian dapat terjadi secara periodik ataupun tidak, dapat ataupun tidak dapat mengikuti pola yang tepat sama setelah interval-interval waktu yang sama. Dalam kegiatan bisnis dan ekonomi, gerakan-gerakan hanya dianggap siklis apabila timbul kembali setelah interval waktu lebih dari satu tahun.
3. Gerakan musiman atau seasonal *movements* merujuk kepada pola-pola yang identik, atau hampir identik yang cenderung diikuti suatu *time series* selama bulan-bulan yang bersangkutan dari tahun ke tahun. Gerakan-gerakan demikian disebabkan oleh peristiwa-peristiwa yang berulang terjadi setiap tahun.

4. Gerakan tidak teratur atau random movements merujuk kepada gerakan-gerakan sporadis dari *time series* yang disebabkan karena peristiwa-peristiwa kebetulan seperti banjir, pemogokan, pemilihan umum dan sebagainya. Meskipun umumnya peristiwa-peristiwa tersebut dianggap menyebabkan variasi-variasi yang hanya berlangsung untuk jangka pendek, namun dapat saja terjadi bahwa peristiwa-peristiwa ini demikian hebatnya sehingga menyebabkan gerak-gerakan siklis atau hal lain yang baru.

Salah satu metode pelatihan terawasi pada NN adalah metode *Backpropagation*, dimana ciri dari metode ini adalah meminimalkan *error* pada *output* yang dihasilkan oleh jaringan. Pada gambar dibawah ini, unit *input* dilambangkan dengan X, *hidden unit* dilambangkan dengan Z dan unit *output* dilambangkan dengan Y. Bobot antara X dan Z dilambangkan dengan V. Bobot antara Z dan Y dilambangkan dengan W.



Sumber :

Gbr 1. Arsitektur Neural Network Backpropagation

PSO adalah teknik optimasi berbasis populasi yang dikembangkan oleh Eberhart dan Kennedy pada tahun 1995, yang terinspirasi oleh perilaku kawanan burung atau ikan [23]. 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 [24]. PSO digunakan untuk memecahkan masalah optimasi. Serupa dengan algoritma genetika (GA), PSO melakukan pencarian menggunakan populasi (*swarm*) dari individu (*particle*) yang akan diperbaharui dari iterasi. PSO memiliki beberapa parameter seperti posisi, kecepatan, kecepatan maksimum, konstanta percepatan, dan berat inersia. PSO memiliki perbandingan lebih unggul untuk banyak masalah optimasi dengan lebih cepat dan tingkat konvergensi yang lebih stabil [23].

III. METODE PENELITIAN

Penelitian adalah kegiatan pemecahan yang sistematis, yang dilakukan dengan perhatian dan kepedulian dalam konteks situasi yang dihadapi [2]. Sedangkan penelitian adalah mencari melalui proses yang metodis untuk menambahkan pengetahuan itu sendiri dan dengan yang lainnya, oleh penemuan fakta dan wawasan tidak biasa [6]. Pengertian lainnya, penelitian adalah sebuah kegiatan yang bertujuan untuk membuat kontribusi orisinal terhadap ilmu pengetahuan.

Penelitian ini adalah penelitian eksperimen dengan metode penelitian sebagai berikut:

A. Pengumpulan data

Dalam penelitian ini, data yang digunakan adalah data rentet waktu (*time series*) dan bertipe primer karena diperoleh langsung dari objek penelitian. Data berisi *record* penjualan hari ini dan penjualan hari-hari sebelumnya yang nantinya akan digunakan untuk memprediksi penjualan di hari berikutnya. Penelitian ini menggunakan metode kuantitatif untuk mengumpulkan data, baik data penjualan, permintaan, dan produk terbuang. Data dikumpulkan mulai dari bulan Desember 2013 dan berakhir pada bulan November 2015. Pencatatan dilakukan setiap hari karena setiap hari ada produk yang dibuang. Jumlah data berhasil dikumpulkan sekitar 700 data.

Dengan memprediksi penjualan untuk hari berikutnya, kita bisa memprediksi permintaan produk, dan dengan begitu bisa mengurangi resiko terbuang produk yang tidak terjual. Parameter penjualan yang digunakan termasuk dalam faktor yang mempengaruhi prediksi penjualan yaitu, permintaan (*delivery*), penjualan (*sell*), terbuang (*Work Off*), tanggal (*day*), bulan (*month*), tahun (*year*).

B. Pengolahan awal data

Data yang didapatkan adalah data *record* penjualan harian untuk seluruh *item* produk makanan siap saji yang dijual di minimarket tersebut. Total dari seluruh *item* penjualan ada sekitar 70 *item* makanan. Pada penelitian ini penulis akan mengambil 3 *item* makanan yang memiliki jumlah terbuang paling banyak dengan *record* penjualan harian dari bulan Desember 2013 sampai dengan November 2015. Dibawah ini adalah tiga peringkat teratas produk dengan jumlah terbuang tertinggi yang nantinya akan digunakan sebagai data dalam penelitian ini.



Gbr 2. Grafik tiga peringkat WO teratas

Dari grafik diatas dapat dilihat bahwa produk “nasi tenggo chicken teriyaki” adalah produk dengan jumlah

terbuang paling banyak periode Desember 2013 sampai dengan November 2015. Oleh karena itu data produk tersebut yang akan digunakan sebagai data percobaan untuk mencari parameter terbaik dalam penelitian ini. Dan untuk data dua produk lainnya akan diuji dengan parameter terbaik yang telah ditemukan, *record* ke dua data lainnya sama yaitu mulai dari 1 Desember 2013 sampai 30 November 2015.

Gbr 3 adalah grafik *record* terbuang data yang akan dijadikan data *training* yaitu produk “nasi tenggo chicken teriyaki” antara Desember 2013 sampai dengan November 2015 dalam satuan bulan.



Gbr 3. Grafik WO “nasi tenggo chicken teriyaki”

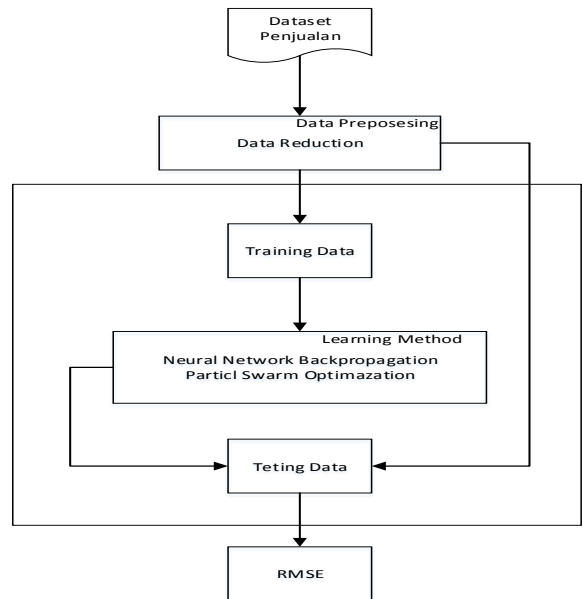
Data yang telah dimasukkan ke *excel*, perlu dibagi (*split*) menjadi 2 bagian, 1 bagian untuk *training* dan bagian lain untuk *testing*. Ukuran proporsional dari *data mining* untuk *training* dan *testing set* berada dalam *range* 50% *training* / 50% *testing* sampai dengan 90% *training* / 10% *testing* (Larose, 2005). Penggunaan *split* 50:50 antara *training* dan *testing* dapat disimpulkan tidak ideal. Lebih baik menggunakan lebih dari setengah data untuk *training* meskipun akan mengorbankan data untuk *testing* [27].

TABEL 1  
PEMBAGIAN DATA TRAINING DAN TESTING

Training	testing	RMSE
55	45	1,503
60	40	2,085
65	35	1,508
70	30	1,568
75	25	1,482
80	20	1,500
85	15	1,579
90	10	1,351
95	5	1,499

C. Model yang diusulkan

Model yang ditemukan pada penelitian ini berdasarkan *state of art* tentang prediksi penjualan adalah dengan menerapkan model NN dan NN dengan optimasi PSO. Langkah-langkah pada PSO untuk memilih fitur pada bobot atribut untuk memaksimalkan kinerja dari model yang dihasilkan sehingga hasil prediksi penjualan akan lebih akurat.



Gbr 4. Diagram model yang diusulkan

D. Ekseperimen dan pengujian model

1. Arsitektur NN *Backpropagation*

Memilih arsitektur NN yang tepat, agar menghasilkan *Root Mean Square Error* (RMSE) yang terkecil, diperlukan pengaturan (*adjustment*) untuk parameter-parameter *Neural Network*. Berikut ini adalah parameter-parameter yang membutuhkan *adjustment*.

TABEL 2  
PARAMETER PENCobaAN NN

Parameter	Nilai
<i>training cycles</i>	500 (default)
<i>learning rate</i>	0,1 – 0,5
<i>Momentum</i>	0,1 – 0,5
<i>hidden layer</i>	1
<i>size hidden layer I</i>	1, 5, 10, 15
<b>RMSE</b>	?

2. Arsitektur NN PSO

Untuk memilih arsitektur yang tepat untuk digunakan dalam menggabungkan dua metode *Neural Network* dan PSO ada ketentuan nilai parameter-parameter yang harus di uji coba agara dapat menghasilkan nilai RMSE yang terkecil.

TABEL 3  
PARAMETER PENCobaAN PSO

Parameter	Nilai
<b>C1 (weight pbest)</b>	1,0 (default)
<b>C2 (weight gbest)</b>	1,0 (default)
<i>population size</i>	20
<i>Maximum number</i>	30 (default)
<i>Inertia weight</i>	1,0 (default)
<i>Max weight</i>	1,0 (default)
<i>Min weight</i>	0,0 (default)

E. Evaluasi dan validasi hasil

Pada penelitian ini, penerapan algoritma NN *Backpropagation* dengan menentukan nilai *training cycle*,

learning rate, dan momentum terlebih dahulu. Setelah didapatkan nilai RMSE terkecil. Setelah RMSE terkecil ditemukan dengan training cycle, learning rate dan momentum selanjutnya adalah menentukan ukuran size (size) pada hidden layer tersebut. Sedangkan penerapan algoritma Backpropagation berbasis PSO berdasarkan pada nilai training cycle, learning rate, dan momentum pada algoritma tersebut untuk menemukan nilai RMSE terkecil.

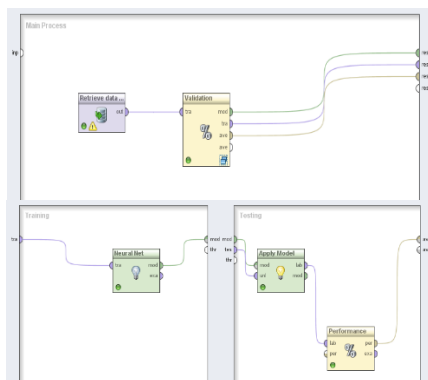
IV. HASIL DAN PEMBAHASAN

Eksperimen dalam penelitian ini menggunakan dua model pengujian, model pertama yaitu NN tanpa dikombinasikan dengan PSO dan model kedua yaitu NN yang dikombinasikan dengan PSO berdasarkan attribute weight. Model pengujian dilakukan terhadap empat kelompok data yang didasarkan pada perubahan parameter jumlah neuron pada satu hidden layer NN yaitu eksperimen dengan satu hidden layer dengan 1, 5, 10, dan 15 neuron.

A. Pengujian NN

Penelitian ini menguji nilai RMSE yang dihasilkan dari metode NN dengan menggunakan tiga data primary penjualan makanan. Namun untuk pencarian parameter terbaik data yang digunakan adalah data penjualan dengan jumlah terbuang paling banyak yaitu data penjualan “nasi tenggo chicken teriyaki”.

Gbr.5 adalah gambar pengujian NN menggunakan metode Split Validation dengan menggunakan Rapidminer:



Gbr 5. Pengujian split validation NN

TABEL 4  
PARAMETER NN PADA 1 HIDDEN LAYER DENGAN 1, 5, 10, 15 NEURON

learnin g rate	mome ntum	training cycle	RMSE			
			1 neur on	5 neur on	10 neuro n	15 neuro n
0.1	0.1	500	1.362	1.314	1.286	1.415
0.2	0.1	500	1.390	1.279	1.338	1.495
0.3	0.1	500	1.409	1.330	1.282	1.440
0.4	0.1	500	1.419	1.354	1.277	1.279
0.5	0.1	500	1.417	1.356	1.281	1.308
0.1	0.2	500	1.364	1.309	1.285	1.424
0.2	0.2	500	1.394	1.281	1.319	1.490
0.3	0.2	500	1.413	1.340	1.278	1.395
0.4	0.2	500	1.421	1.355	1.274	1.285
0.5	0.2	500	1.414	1.362	1.282	1.357

learnin g rate	mome ntum	training cycle	RMSE			
			1 neur on	5 neur on	10 neuro n	15 neuro n
0.1	0.3	500	1.368	1.313	1.286	1.441
0.2	0.3	500	1.400	1.283	1.303	1.441
0.3	0.3	500	1.420	1.350	1.284	1.425
0.4	0.3	500	1.427	1.349	1.277	1.271
0.5	0.3	500	1.414	1.381	1.291	1.379
0.1	0.4	500	1.374	1.316	1.340	1.480
0.2	0.4	500	1.408	1.303	1.306	1.430
0.3	0.4	500	1.433	1.340	1.273	1.268
0.4	0.4	500	1.434	1.369	1.284	1.324
0.5	0.4	500	1.411	1.403	1.331	1.537
0.1	0.5	500	1.383	1.315	1.333	1.534
0.2	0.5	500	1.419	1.346	1.297	1.374
0.3	0.5	500	1.452	1.352	1.271	1.314
0.4	0.5	500	1.439	1.389	1.280	1.386
0.5	0.5	500	1.401	1.443	1.411	1.454

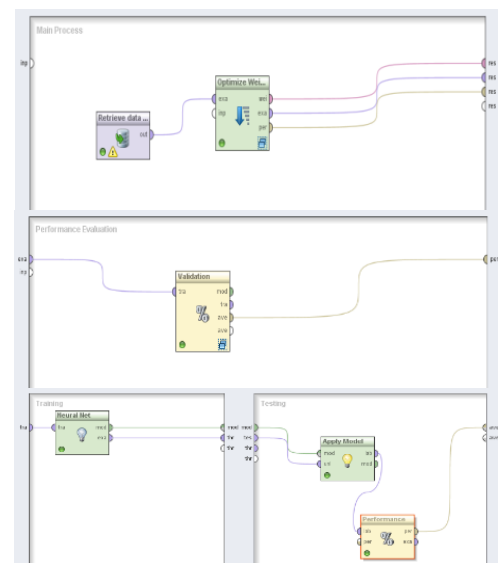
Eksperimen dilakukan sebanyak 25 variasi pengubahan parameter learning rate dan momentum. Indikator untuk mengetahui akurasi ditunjukkan oleh besarnya RMSE. Berikut ini adalah hasil terbaik dari pengujian dengan metode NN:

TABEL 5  
HASIL PENGUJIAN TERBAIK DARI NN

hidden layer	RMS E	learning rate	momentu m	training cycle
1 neuron	1.362	0.1	0.1	500
5 neuron	1.279	0.2	0.1	500
10 neuron	1.274	0.4	0.2	500
15 neuron	1.268	0.3	0.4	500

B. Pengujian NN-PSO

Berikut ini adalah gambar pengujian algoritma NN dengan optimasi PSO menggunakan metode Split Validation dengan menggunakan Rapidminer.




Gbr 6. Pengujian split validation NN-PSO

TABEL 6  
PARAMETER NN PADA 1 HIDDEN LAYER DENGAN 1, 5, 10, 15 NEURON

learning rate	momentum	training cycle	populasi	C1	C2	inertia	RMSE			
							1 neuron	5 neuron	10 neuron	15 neuron
0.1	0.1	500	20	1.0	1.0	1.0	1.162	1.058	1.026	1.048
0.2	0.1	500	20	1.0	1.0	1.0	1.178	1.077	1.025	1.079
0.3	0.1	500	20	1.0	1.0	1.0	1.118	1.072	1.030	1.078
0.4	0.1	500	20	1.0	1.0	1.0	1.224	1.020	1.014	1.056
0.5	0.1	500	20	1.0	1.0	1.0	1.127	1.154	1.104	1.012
0.1	0.2	500	20	1.0	1.0	1.0	1.138	1.042	1.037	1.083
0.2	0.2	500	20	1.0	1.0	1.0	1.124	1.014	1.118	1.119
0.3	0.2	500	20	1.0	1.0	1.0	1.044	1.050	1.006	1.073
0.4	0.2	500	20	1.0	1.0	1.0	1.104	1.088	1.028	1.044
0.5	0.2	500	20	1.0	1.0	1.0	1.150	1.153	1.054	1.085
0.1	0.3	500	20	1.0	1.0	1.0	1.118	1.047	1.056	1.076
0.2	0.3	500	20	1.0	1.0	1.0	1.186	1.097	1.103	0.084
0.3	0.3	500	20	1.0	1.0	1.0	1.135	1.104	0.995	1.065
0.4	0.3	500	20	1.0	1.0	1.0	1.135	1.090	1.075	1.023
0.5	0.3	500	20	1.0	1.0	1.0	1.172	1.175	1.084	1.015
0.1	0.4	500	20	1.0	1.0	1.0	1.082	1.076	1.122	1.029
0.2	0.4	500	20	1.0	1.0	1.0	1.170	1.033	1.151	1.083
0.3	0.4	500	20	1.0	1.0	1.0	1.200	1.149	1.079	1.021
0.4	0.4	500	20	1.0	1.0	1.0	1.196	1.140	1.132	1.020
0.5	0.4	500	20	1.0	1.0	1.0	1.214	1.115	1.076	1.123
0.1	0.5	500	20	1.0	1.0	1.0	1.029	1.066	1.084	1.124
0.2	0.5	500	20	1.0	1.0	1.0	0.997	1.073	1.007	1.077
0.3	0.5	500	20	1.0	1.0	1.0	1.158	1.011	1.061	1.103
0.4	0.5	500	20	1.0	1.0	1.0	1.117	1.049	1.154	1.029
0.5	0.5	500	20	1.0	1.0	1.0	1.166	1.139	1.184	1.045

Eksperimen dilakukan sebanyak 25 variasi perubahan parameter *learning rate* dan *momentum*. Indikator untuk mengetahui akurasi ditunjukkan oleh besarnya RMSE. hasil terbaik dari pengujian dengan metode NN-PSO dapat dilihat pada tabel 7.

Berdasarkan hasil eksperimen dan analisis data dalam penelitian ini, maka diperoleh perbandingan rata-rata nilai RMSE pada pengujian model NN sebelum dan sesudah dioptimasi dengan PSO *data testing* yang diterapkan pada data laju inflasi. Perbandingan ini memberikan diskripsi tentang perbandingan rata-rata tingkat akurasi pada penerapan model tersebut, yang ditunjukkan pada tabel 8 dan gambar 7.



Gbr 7. Grafik perbandingan rata-rata nilai RMSE dengan satu *hidden layer*

Berdasarkan hasil eksperimen dan analisis data dalam penelitian ini, maka diperoleh perbandingan nilai RMSE terkecil pada pengujian model NN sebelum dan sesudah dioptimasi dengan PSO pada yang diterapkan pada data penjualan. Perbandingan ini memberikan deskripsi tentang tingkat akurasi terbaik pada penerapan model tersebut, yang ditunjukkan pada tabel 9.

TABEL 8  
PERBANDINGAN RATA-RATA NILAI RMSE DENGAN SATU HIDDEN LAYER

Size Neuron	Rata-rata RMSE	
	NN	NN-PSO
1 Neuron	1,407	1,138
5 Neuron	1,341	1,084
10 Neuron	1,299	1,072
15 Neuron	1,398	1,024
Overall	1,361	1,079


TABEL 9  
PERBANDINGAN AKURASI TERBAIK BERDASARKAN NILAI RMSE PADA SATU HIDDEN LAYER

size neuron	NN		NN-PSO	
	RMSE	Lr ; M	NN-PSO	Lr ; M
1 neuron	1,362	0,1 ; 0,1	0,997	0,2 ; 0,5
5 neuron	1,279	0,2 ; 0,1	1,011	0,3 ; 0,5
10 neuron	1,274	0,4 ; 0,2	0,995	0,3 ; 0,3
15 neuron	1,268	0,3 ; 0,4	1,012	0,5 ; 0,1

TABEL 7  
HASIL PENGUJIAN TERBAIK DARI NN-PSO

hidden layer	RMSE	learning rate	momentum	training cycle	populasi	C1	C2	inertia
1 neuron	0.997	0.2	0.5	500	20	1.0	1.0	1.0
5 neuron	1.011	0.3	0.5	500	20	1.0	1.0	1.0
10 neuron	0.995	0.3	0.3	500	20	1.0	1.0	1.0
15 neuron	1.012	0.5	0.1	500	20	1.0	1.0	1.0

Selanjutnya secara grafik, deskripsi perbandingan data diatas ditunjukkan oleh gambar 8.



Gbr 8. Grafik perbandingan akurasi terbaik berdasarkan nilai RMSE pada satu hidden layer

Berdasarkan tabel 9, menunjukkan bahwa penerapan model NN dengan PSO dari semua jumlah neuron yang di uji cobakan menghasilkan nilai RMSE yang lebih kecil dibandingkan dengan penerapan NN sebelum optimasi PSO. Hal ini berarti bahwa model NN-PSO dengan jumlah neuron 1, 5, 10, 15 dapat meningkatkan akurasi dari prediksi.

C. Implementasi

Pada kasus ini, akan menguji coba mode NN dan NN-PSO yang menghasilkan akurasi terbaik dalam penelitian untuk memprediksi penjualan periode 1 desember 2013 sampai dengan 30 november 2015. Pengujian dilakukan dengan menggunakan parameter yang sama yang ditentukan pada penelitian.


1. Implementasi NN dan NN-PSO Terbaik pada Data Penjualan "Choco Stripe"

Pada kasus ini, peneliti menguji kemampuan akurasi formulasi yang terbentuk oleh model yang menghasilkan tingkat akurasi terbaik dalam penelitian dengan mengimplementasikan pada data penjualan "Choso Stripe" periode 1 Desember 2013 sampai dengan 30 November 2015. Hasil pengujian diperoleh perbandingan nilai RMSE penjualan pada model NN sebelum dan sesudah optimasi PSO. Seperti yang ditunjukkan pada tabel 10.

TABEL 10  
PERBANDINGAN IMPLEMENTASI HASIL PENELITIAN PADA PENJUALAN "CHOCO STRIPE"

size neuron	NN		NN-PSO	
	RMSE	Lr ; M	NN-PSO	Lr ; M
1 neuron	1,741	0,1 ; 0,1	0,997	0,2 ; 0,5
5 neuron	1,504	0,2 ; 0,1	1,011	0,3 ; 0,5
10 neuron	1,625	0,4 ; 0,2	0,995	0,3 ; 0,3
15 neuron	1,378	0,3 ; 0,4	1,012	0,5 ; 0,1

Selanjutnya secara grafik, deskripsi perbandingan data diatas ditunjukkan oleh gambar 9.



Gbr 9. Grafik Perbandingan Implementasi Hasil Penelitian Penjualan "Choco Stripe"


2. Implementasi NN dan NN-PSO Terbaik pada Data Penjualan "Choco Pillow Bread"

Pada kasus ini, peneliti menguji kemampuan akurasi formulasi yang terbentuk oleh model yang menghasilkan tingkat akurasi terbaik dalam penelitian dengan mengimplementasikan pada data penjualan "Choco Pillow Bread" periode 1 Desember 2013 sampai dengan 30 November 2015. Hasil pengujian diperoleh perbandingan nilai RMSE penjualan pada model NN sebelum dan sesudah optimasi PSO. Seperti yang ditunjukkan pada tabel 11.

TABEL 11  
PERBANDINGAN IMPLEMENTASI HASIL PENELITIAN PADA PENJUALAN "CHOCO PILLOW BREAD"

size neuron	NN		NN-PSO	
	RMSE	Lr ; M	NN-PSO	Lr ; M
1 neuron	1,137	0,1 ; 0,1	1,127	0,2 ; 0,5
5 neuron	1,713	0,2 ; 0,1	1,048	0,3 ; 0,5
10 neuron	1,522	0,4 ; 0,2	0,949	0,3 ; 0,3
15 neuron	1,573	0,3 ; 0,4	0,990	0,5 ; 0,1

Selanjutnya secara grafik, deskripsi perbandingan data diatas ditunjukkan oleh gambar 10.



Gbr 10. Grafik Perbandingan Implementasi Hasil Penelitian Penjualan "Choco Pillow Bread"

## V. KESIMPULAN

Berdasarkan pengujian penerapan model NN-PSO dalam prediksi penjualan makanan yang dilakukan 100 eksperimen yang terbagi dalam empat variasi jumlah neuron pada *hidden layer* yaitu 1 neuron, 5 neuron, 10 neuron, dan 15 neuron ditemukan bahwa rata-rata dari nilai RMSE NN yang dioptimasi dengan PSO dalam penelitian ini lebih kecil dibandingkan sebelum dioptimasi dan pada analisis uji beda menunjukkan bahwa ad perbedaan yang signifikan pada nilai rata-rata RMSE hasil eksperimen NN sebelum dan sesudah optimasi dengan PSO, sehingga dapat disimpulkan bahwa penerapan model NN dengan dioptimasi dengan PSO meningkatkan akurasi dalam prediksi penjualan makanan.

## UCAPAN TERIMA KASIH

Terima kasih saya ucapkan kepada Allah SWT atas rahmat dan ridho-Nya dapat menyelesaikan penelitian ini. Kedua saya ucapkan terima kasih kepada Ketua Redaksi JTI STMIK Antar Bangsa yang telah memperkenankan saya untuk bisa menulis di jurnal ini.

## REFERENSI

- [1] Au, K. F. & Chan, N. Y, Quick response for Hongkong Clothing Suppliers: A Total System Approach. Proceedings of the 13th Annual Conference of the Production and Operation Management Society 2002.
- [2] Berndtsson, M., Hansson, J., Olsson, B. & Lundell, B, Thesis Projects: A Guide for Students in Computer Science and Information Systems. 2nd penyunt. London: Springer, 2008.
- [3] Buffa S, E., R. & K, Modern Production and Operation Management. 8th penyunt. London: John Willey and Sons Inc, 1996.
- [4] Buza, K., Nanopoulos, A. & Thieme, L. S, Time-Series Clasification based on Individualised Error Prediction. IEEE International Conference on Computational Science and Engineering, pp. 48-54, 2010.
- [5] Choi, T. M, Quick Response in Fashion Supply Chains With Dual Information Updating. Journal Of Industrial And Management Optimazation, August, Volume 2, pp. 255-268, 2006.
- [6] Dawson, C. W, Projects in Computing and Information Systems. 2nd penyunt. Harlow: Pearson Educations, 2009.
- [7] Eberhart, R. & Shi, Y, Particle Swarm Optimazation : Development, Applications and Resource. Indiana Polis: Purdue School of Engineering and Technology, 2001.
- [8] Eppen, G. D. & Iyer, A. V, Improved Fashion Buying With Bayesian Updates. Operation Research, November-December, 45(0030-364X97/4506), pp. 805-829, 1997.
- [9] Fernandez, C. et al, Weekly Milk Prediction on Dairy Goats using Neural Networks. Neural Computing and Applications, May, Volume 16, pp. 373-381, 2007.
- [10] Gaspersz, V, Metode Analisis Untuk Peningkatan Kualitas. Jakarta: Gramedia Pustaka Utama, 2001.
- [11] Gnana, S. K. & S.N, D, Analysis of Computing Algoritm using Momentum in Neural Network. Journal of Computing, June, Volume 3, pp. 163-166, 2011.
- [12] Hartono, D. & Wahono, R. S, Model Prediksi Rentet Waktu Penujualan Minuman Kesehatan Berbasis Neural Network. Jurnal Teknologi Informasi, 9(ISSN : 1414-9999), pp. 12-21, 2013.
- [13] Haykin, S, Neural Network : A Comparison Foundation. 1st penyunt. Hamilton, Ontario: Pearson Education, 1999.
- [14] H. J. & R. B, Operation Management. 7th penyunt. Jakarta: (Manajemen Operasi edisi 7, Buku I) Penerbit Salemba Empat, 2005.
- [15] Kotler, P., K. & Lane, K, Marketing Management. New Jersey: Pearson Education Inc, 2006.

- [16] Kuo, R. J. & Xue, K. C, 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, 1998.
- [17] Larose, D. T, Discovering Knowledge in data an introduction to data mining. Information Processing and Management. Hoboken(New Jersey): John Wiley & Sons, Inc, 2005.
- [18] Lobo, D. G. D. C. & Santosa, S, Prediksi Penjualan Air Minum Dalam Kemasan Menggunakan Jaringan Syaraf Tiruan Resilent Propagation. Jurnal Teknologi dan Informasi, Oktober, 10(ISSN 1414-9999), pp. 186-210, 2014.
- [19] Makridakis, S., Wheelwright, S. C. & McGee, V. E, Metode dan Aplikasi Peramalan, Jilid I. 2nd penyunt. Jakarta: Binarupa Aksara, 1999.
- [20] Muzakkir, I., Syukur, A. & Dewi, I. N, Peningkatan Akurasi Algoritma Bacpropagation Dengan Seleksi Fitur Particle Swarm Optimazation Dalam Prediksi Pelanggan Telekomunikasi Yang Hilang. Jurnal Pesudocode, Februari, 1(ISSN 2355-5920), pp. 1-8, 2014.
- [21] Nugraha, H. G. & SN, A, Optimasi Bobot Jaringan Syaraf Tiruan Menggunakan Particle Swarm Optimazation. IJCCS, 8(ISSN: 1978-1520), pp. 25-36, 2014.
- [22] Pakaja, F., Naba, A. & P, Peramalan Penjualan Mobil Menggunakan Jaringan Syaraf Tiruan dan Certainty Factor. Jurnal EECIS, Juni, Volume 6, pp. 23-28, 2012.
- [23] Park, T.-S., Lee, J.-H. & Choi, B, 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, 2009.
- [24] Salappa, A., Doumpos, M. & Zopounidis, C, Feature selection algorithms in classification problems: an experimental evaluation. Optimization Methods and Software, February, 22(ISSN 1055-6788), pp. 199-214, 2007.
- [25] Shao, X. q, Based on two Swarm Optimized algorithm of Neural Network to prediction the switch's traffic of coal. 2011 International Symposium on Computer Science and Society, pp. 299-302, 2011.
- [26] Widodo, P. P. & Handayanto, R. T, Penerapan Soft Computing dengan MatLab. Bandung: Rekayasa Sains, 2012.
- [27] Witten, I. H. & Frank, E, Data mining : Practical Machine Learning Tools and Technique. 3rd penyunt. USA: Elsevier, 2011.
- [28] Xiao, T. & Yang, D, Price and service competition of supply chains with risk-averse retailers under demand uncertainty. Int. J. Production Economics, 114(0925-5273), pp. 187-200, 2008.
- [29] Redjeki, S., 2005, Prediksi Tingkat Inflasi Menggunakan Pendekatan Jaringan Syaraf Tiruan, Program Studi S2 Ilmu Komputer, Jurusan Ilmu Komputer Dan Elektronika, Fakultas Matematika Dan Ilmu Pengetahuan Alam,, Yogyakarta



Syarif Hidayatulloh. Lahir di Jakarta, 3 Juli 1988. Lulus Pasca Sarjana Magister Ilmu Komputer Konsentrasi E-business STMIK Nusa Mandiri Jakarta. Saat ini aktif sebagai dosen tetap Jurusan Sistem Informasi STMIK Nusa Mandiri Jakarta