

Optimasi Radial Basis Function Neural Network dengan Growing Hierarchical Self Organizing Map pada Data Time Series

Putu Sugiartawan^{#1}, Arfan Mauko^{*2}

[#] Teknik Informatika, STIMIK STIKOM INDONESIA
Denpasar, Bali

¹ Putu.sugiartawan.85@gmail.com

^{*} Teknik Informatika, Universitas Nusa Cendana
NTT, Kupang

² arfanmauko@gmail.com

Abstract

Salah satu model JST yang sesuai dengan peramalan data time series, adalah model Radial Basis Function Network (RBFN). Jaringan syaraf tiruan Radial Basis Function merupakan jaringan feed-forward yang memiliki tiga lapisan, yaitu lapisan masukan (input layer), lapisan tersembunyi (hidden layer) dan lapisan keluaran (output layer). Besarnya dimensi input pada jaringan syaraf menyebabkan menurunnya kemampuan komputasi suatu model jaringan. Salah satu cara untuk mengatasi hal tersebut adalah dengan mereduksi dimensi input. Dalam penelitian ini jaringan syaraf tiruan Radial Basis Function dipadukan dengan metode Growing Hierarchical Self Organizing Map (GH-SOM). Penggunaan teknik clustering data pada proses awal, memungkinkan mengurangi dimensi input dengan kehilangan informasi yang minimum. Sehingga dapat mengoptimalkan proses prediksi dengan menggunakan pendekatan RBFN. Prediksi harga saham dengan Optimasi metode Radial Basis Function neural network dengan Menggunakan Growing Hierarchical Self Organizing Map, dengan jumlah vektor data sebanyak 364 dengan SSE sebesar 0,074713 diperoleh akurasi sebesar 94,03%

Keywords— Growing Hierarchical Self Organizing Map (GH-SOM), Radial Basis Function Network, data time series

I. PENDAHULUAN

Tingkat akurasi prediksi harga saham dengan model neural network dipengaruhi oleh pelatihan yang dilakukan. Proses pelatihan data pada metode neural network memerlukan waktu yang cukup lama, hal ini disebabkan dari jumlah data yang digunakan saat proses pelatihan. Salah satu model JST yang sesuai dengan peramalan data time series adalah model Radial Basis Function Network (RBFN), dimana model ini sangat baik ketika digunakan untuk menyelesaikan permasalahan komponen non stasioner dan non linier [1]. Disebut fungsi basis karena fungsi tersebut merupakan fungsi yang lengkap sehingga segala fungsi yang lain dapat diekspansikan ke dalam fungsi tersebut. Hasil penelitian yang dilakukan [2] menyebutkan bahwa performance model RBF menghasilkan model yang lebih baik di mana konsep teorinya dicobakan pada data

time series. Jaringan syaraf tiruan Radial Basis Function merupakan jaringan feed-forward yang memiliki tiga lapisan, yaitu lapisan masukan (input layer), lapisan tersembunyi (hidden layer) dan lapisan keluaran (output layer). Besarnya dimensi input pada jaringan syaraf menyebabkan menurunnya kemampuan komputasi suatu model jaringan. Salah satu cara untuk mengatasi hal tersebut adalah dengan mereduksi dimensi input. Dalam penelitian ini jaringan syaraf tiruan Radial Basis Function dipadukan dengan metode Growing Hierarchical Self Organizing Map (GH-SOM). GH-SOM merupakan teknik pembelajaran tidak terawasi atau unsupervised learning. Teknik ini mengelompokkan data ke dalam suatu klaster-klaster tertentu berdasarkan kemiripan pada data atau pengelompokan kelasnya secara hirarki, berdasarkan similarity dan dissimilarity dari data yang ada [3]. Metode pengelompokan tersebut digunakan untuk mereduksi dimensi input dengan kehilangan informasi yang minimum,


dari penerapan algoritma RBFN.

Berdasarkan latar belakang permasalahan diatas, maka tema yang diangkat pada penelitian ini adalah Optimasi metode Radial Basis Function dengan Menggunakan Growing Hierarchical Self Organizing Map. Data time series yang digunakan adalah data saham, salah satu saham yang menjadi bahan penelitian adalah saham Kalbe Farma.Tbk. Penggunaan teknik clustering data pada proses awal, memungkinkan mengurangi dimensi input dengan kehilangan informasi yang minimum. Sehingga dapat mengoptimalkan proses prediksi dengan menggunakan pendekatan RBFN.

II. TINJAUAN PUSTAKA

A. Radial Basis Function Network s

Radial Basis Function Network (RBFN) pada arsitektur jaringannya neuron keluaran (output) merupakan kombinasi linier fungsi basis neuron-neuron pada lapisan tersembunyi. Sebagai fungsi basis yang umum digunakan adalah Gaussian. Seperti halnya jaringan saraf tiruan yang lain, Radial Basis Function Network (RBFN) juga memiliki topologi jaringan. Topologi milik RBFN terdiri atas unit lapisan masukan (input), unit lapisan tersembunyi (hidden), dan unit lapisan keluaran (output). Topologi RBFN digambarkan seperti berikut



Gambar 1 Topologi radial basis fuction network

Berikut algoritma dari proses pelatihan jaringan dengan metode RBF:

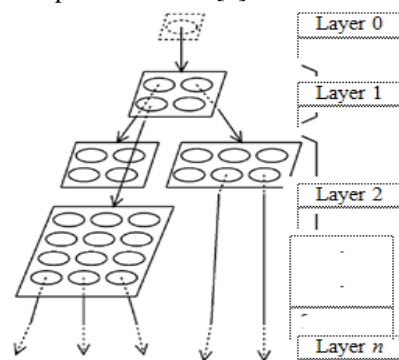
- Step 1** : Inialisasi *center* data input matriks normalisasi dan dan centre hasil perhitungan K-Means Clustering.
- Step 2** :Melakukan inialisasi nilai spread yang akan digunakan pada perhitungan matriks Gaussian.
- Step 3** : Menentukan sinyal input ke hidden layer dan menghitung nilai fungsi aktivasinya pada tiap hidden layer.
- Step 4** : Menghitung bobot baru (W) dengan mengalikan pseudoinverse dari matriks G dengan vector target (d) dari data training
- Step 5**: Menghitung nilai output jaringan Y(n)
- Step 6** : Simpan nilai hasil training. Hasil training yang disimpan adalah data center 1, center 2, nilai output dan nilai spread yang digunakan dalam

proses training jaringan syaraf.

B. Growing Hierarchical Self Organizing Map (GH-SOM)

Growing Hierarchical Self Organizing Map (GH-SOM) adalah salah satu pemodelan neural network yang memetakan data-data multi dimensi ke model rendah dimensi (biasanya dua dimensi). GH-SOM merupakan pengembangan dari Self-Organizing Map (SOM) dengan kemampuan model yang dibentuk bersifat dinamis dan memiliki hubungan hirarki. GHSOM dapat mengelompokkan data-data multi dimensi yang memiliki kemiripan atribut ke dalam kelompok yang sama sehingga dapat digunakan untuk melakukan proses clustering pada dataset yang diberikan [4].

Algoritma GHSOM memiliki struktur Hirarki dari beberapa lapisan, dimana setiap lapisan terdiri dari beberapa Independent Growing SOM. Lapisan pada GH-SOM dimulai dari Top-Level Map, dimana masing-masing map mirip dengan growing grid model, tumbuh dengan memiliki ukuran tertentu yang mewakili koleksi data yang spesifik untuk masing-masing level lebih detail. Proses unit penyisipan dan lapisan stratifikasi pada GH-SOM bekerja sesuai dengan nilai dari dua macam parameter. GH-SOM tidak dapat merubah struktur sampel data yang adaptif saat training maps. Oleh karena itu, hanya beberapa sampel yang akurat pada terminal map hirarki.GH-SOMmemiliki strukturpohonyang kompleks danbanyaknode(peta). Adapunhasilklasifikasitersebut,diperolehpengetahuan daristruktur data lebih rendah dari data mining, baik itu cakupan ataupun efeknya. Pada Gambar 2 menunjukkan struktur hirarki pada GHSOM [5].



Gambar 2 Struktur hirarki pada GHSOM

Berikut algoritma dari GHSOM, yang terdiri dari beberapa tahapan diantaranya [5].

- Step 1** : Semua parameter diinisialisasi.
- Step 2** : *Mean quantization error* dari sebuah unit *i* dihitung pada layer ke 0,
- Step 3** : Selanjutnya $M_{l,v}$ ($v = 1, 2, \dots, n$) menjadi sebuah peta pada lapisan $l = 1, 2, \dots, n$.
- Step 4** : Hitung *mean quantization error* untuk masing-masing pemenang unit *k* pada $M_{l,v}$
- Step 5** :Biarkan *e* menjadi unit yang mewakili kesalahan terbesar antara *input* dan *reference vector* pemenang antara unit di $M_{l,v}$.

- Step 6 :** Hitung *mean quantization error* $mqe_{M_{l,v}}$ untuk subset u dari pemenang unit k pada $M_{l,v}$
- Step 7 :** Jika *mean quantization error* sudah terpenuhi seperti, maka unit dimasukkan pada baris / kolom
- Step 8 :** Bobot awal diberikan sebagai rata-rata dari d dan e
- Step 9 :** Jika *mean quantization error* tidak memenuhi sesuai proses penyisipan unit berhenti dan kembali ke peta yang berada pada lapisan atas dan SOM
- Step 10 :** Setelah langkah ke-9, jika *quantization error* nilainya ternyata lebih besar, maka tambahkan layer baru pada peta.

C. Prediksi Data Time Series

Data *time series* adalah *sequence* atau deret nilai harga dari aset nilai pada suatu periode waktu tertentu. Jenis data ini terdiri dari satu objek tetapi meliputi beberapa periode waktu misalnya harian, mingguan, bulanan, tahunan dan lain-lain. Penggunaan *data time series* bermanfaat untuk meramalkan kejadian di masa depan, karena pola yang terbentuk di masa lalu kemungkinan terulang di masa datang [6]. Data *time series* dapat dinotasikan sebagai sebuah vektor, seperti berikut :

$$x = \{x_t, t = 1, \dots, n\},$$


Keterangan :

x : merupakan data observasi yang terurut berdasarkan waktu

t : adalah indeks waktu

n : jumlah observasi / pengamatan

Salah satu pendekatan dari model standar JST dalam melakukan prediksi data *time series* adalah dengan *sliding windows*.



Gambar 3 Prediksi data time series dengan sliding windows

Teknik ini mendorong fungsi f pada JST dan menggunakan fungsi *feedforward* seperti pada arsitektur MLP, RBF atau korelasi *cascade*, dengan menggunakan satu set N tuple sebagai masukan dan satu *output* sebagai nilai target jaringan.

III. METODOLOGI PENELITIAN

A. Jenis dan Sumber Data Input

Variabel data masukan merupakan sekumpulan data serial atau berkala dari transaksi pada suatu jangka waktu dan sering disebut dengan data *time series*, Data harga

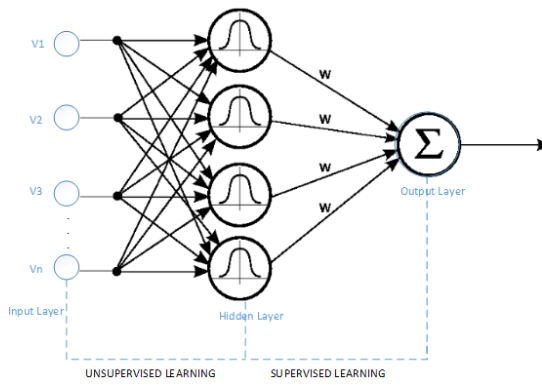
saham dapat di unduh pada situs <http://finance.yahoo.com/>, sedangkan faktor eksternal dapat di unduh pada web <http://www.bi.go.id>. Pada sistem peramalan jaringan syaraf tiruan, data input yang digunakan diantaranya:

1. Harga tertinggi merupakan harga saham tertinggi yang diperoleh pada satu hari transaksi saham di bursa efek. Nilai harga tertinggi diinisialisasikan dengan variabel X1.
2. Harga terendah merupakan harga saham terendah yang diperoleh pada satu hari transaksi saham di bursa efek. Nilai hargaterendah diinisialisasikan dengan variable X2.
3. Harga Pembukaan adalah harga pembukaan saham yang menjadi pembukaan transaksi saham pada hari itu. Nilai harga pembukaan diinisialisasikan dengan variabel X3.
4. Harga penutupan diinisialisasikan dengan variabel X4.
5. Volume merupakan jumlah atau banyaknya lembar saham yang terjual pada transaksi saham di satu hari transaksi. Volume saham diinisialisasikan dengan variabel X5.
6. Nilai Index Lq 45 merupakan nilai index harga saham gabungan dari saham-saham Lq 45 pada hari itu, diinisialisasikan dengan variabel X6.
7. Inflasi adalah kenaikan harga secara terus-menerus dan kenaikan harga yang terjadi pada seluruh kelompok barang dan jasa, nilai inflasi yang digunakan adalah perhari dan diinisialisasikan dengan variabel X7.
8. Kurs Dolar merupakan nilai tukar mata uang rupiah terhadap dolar amerika, diinisialisasikan dengan variabel X8.
9. Suku bunga (BI Rate) adalah harga yang dibayar oleh peminjam kepada pemberi pinjaman, suka bungan digunakan perharinya dan diinisialisasikan dengan variabel X9.

B. Rancangan Arsitektur Optimasi RBF dengan GHSOM

Algoritma optimasi RBF dengan GHSOM merupakan gabungan dari algoritma GH-SOM dan RBF. Optimasi Metode RBF menggunakan algoritma GHSOM sebagai lapisan awal untuk memproses input, Selanjutnya algoritma RBF memproses sinyal input hasil dari proses pembelajaran algoritma GHSOM sebagai faktor pembimbing untuk memprediksi harga saham dimasa yang datang.

Pada Gambar 4 menjabarkan bahwa kumpulan data yang berupa vektor input yang terdiri dari 9 variabel dan 1494 vektor input. Data saham dibagi menjadi 2 bagian, yaitu data pelatihan (*training*) dan data pengujian (*testing*). Jumlah data *training* sebesar 75% dari total data, sedangkan data *testing* sebesar 25%. Proses GHSOM pada tahap pertama mengcluster data *training* menjadi beberapa vektor input dan selanjutnya masing-masing vektor input ditentukan nilai tingkat kesalahan dengan SSE (*Sum Square error*). Masing-masing kelompok data, selanjutnya di *training* dengan algoritma RBF.



Gambar 4 Proses optimasi algoritma RBF deng GHSOM

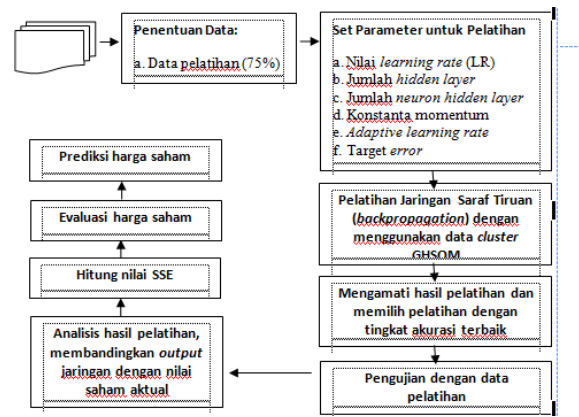
Rancangan arsitektur jaringan saraf untuk prediksi saham pada Gambar 4 terdiri dari sembilan *neuron* pada *input layer* yang merupakan variabel data saham, seperti harga saham penutupan ($v1$), harga saham pembukaan ($v2$), harga saham tertinggi ($v3$), harga saham terendah ($v4$) dan *volume* saham ($v5$), inflasi ($v6$), *BI Rate* ($v7$), *Index LQ 45* ($v8$) dan kurs dollar ($v9$). Pada *hidden layer* terdiri dari n buah *neuron* dan terdapat 1 unit *neuron* pada *output layer*, nilai *output* merepresentasikan harga saham pembuka di hari berikutnya.. Pada jaringan ini juga terdapat nilai *bias* yang terhubung pada *hidden* dan *output layer*, vektor bobot pada *hidden layer* disebarkan melalui lapisan *hidden* yang dilakukan secara random. Inisialisasi bobot dan *threshold* dalam jaringan didistribusikan secara random dalam sebuah rentangan [7] seperti pada Rumus matematika berikut dimana F_i adalah jumlah *neuron input*.

$$\left(-\frac{2.4}{F_i}, +\frac{2.4}{F_i}\right)$$

Hidden layer dan masing-masing *neuron* ditentukan secara *trial* dan *error*, dengan harapan untuk mencapai nilai *error* yang paling optimal (*minimum error*). Jumlah *neuron* pada *context layer* memiliki jumlah sama dengan jumlah *neuron* pada lapisan *hidden*. *Neuron* pada lapisan *output* memiliki sebuah *neuron* yaitu Y , dimana nilainya berupa harga saham hasil prediksi.

C. Prosedur Training

Diagram alur proses *training* dan pelatihan algoritma RBF ditunjukkan pada Gambar 5. Gambar tersebut menunjukkan keseluruhan proses yang dilakukan sehingga dihasilkan nilai prediksi harga saham. keseluruhan data yang digunakan sebagai objek penelitian dibagi menjadi dua. Komposisi pembagian data tersebut meliputi, 75% data digunakan untuk pelatihan atau disebut dengan data training dan sisanya sebesar 25% digunakan untuk pengujian atau disebut dengan data *testing*. Penentuan parameter optimal seperti halnya *learning rate*, *momentum*, jumlah *hidden layer* dan yang lainnya ditentukan melalui percobaan, sehingga dari beberapa percobaan akan diperoleh nilai optimal untuk masing-masing parameter.



Gambar 5 Diagram alur kerja sistem optimasi RBF

Proses ini berhenti apabila nilai SSE (*Sum Square Error*) lebih kecil atau sama dengan target error yang ditetapkan atau dengan *epoch* maksimum yang telah ditentukan oleh pemakai. *Epoch* (iterasi maksimum) merupakan suatu set putaran vektor-vektor pembelajaran [8]. Tujuan dilakukan proses pembelajaran adalah meminimalkan tingkat kesalahan. Pada proses training terdapat dua prosedur yang mesti diperhatikan, diantaranya.

A. Normalisasi Data

Data yang digunakan pada proses prediksi harga saham terlebih dahulu dinormalisasi baik yang digunakan untuk *training* maupun *testing*. Proses ini perlu dilakukan untuk menyertakan rentangan data asli agar sama dengan rentangan yang digunakan pada Jaringan Saraf Tiruan. Fungsi aktivasi yang digunakan pada JST adalah *hyperbolic tangent*, sehingga rentangan yang digunakan adalah $-1 \leq n \leq 1$ [8] menyatakan normalisasi data dapat dilakukan dengan persamaan 1.

$$h'(x) = [1 + h(x)][1 - h(x)] \dots (1)$$

B. Inisialisasi parameter

Proses selanjutnya yang dilakukan setelah menentukan data training dan testing adalah melakukan beberapa inisialisasi yang mesti dilakukan sebelum memulai proses pembelajaran, inisialisasi yang dilakukan diantaranya:

1. **Bias** merupakan masukan nilai yang tetap sama selama proses.
2. **Learning rate** adalah laju pembelajaran untuk menentukan perubahan pada nilai bobot dan bias. Semakin besar nilai *learning rate* berimplikasi pada semakin besarnya langkah pembelajaran. Nilai *learning rate* disesuaikan agar algoritma menjadi stabil dan dapat mencapai target yang ditentukan.
3. **Hidden layer** dan neuron, diatur jumlah lapisan hidden beserta jumlah unit neuron-nya.
4. **Konstanta momentum**, nilainya diatur apabila menggunakan momentum dalam perhitungan bobot.
5. **Parameter adaptive learning rate**, nilainya diatur apabila diaktifkan dalam proses pembelajaran.

- Epoch** maksimum merupakan perulangan atau iterasi maksimum dari proses yang dilakukan untuk mencapai target error yang telah ditentukan.
- Target error** adalah suatu nilai untuk menghentikan proses apabila error lebih kecil atau sama dengan target.
- Jumlah epoch** untuk *restart*, nilai ini diset untuk melakukan restart epoch untuk membantu kinerja sistem.

D. Implementasi Sistem Optimasi RBF

Proses prediksi harga saham dilakukan dengan menggunakan algoritma RBF neural network, data yang digunakan adalah data saham hasil prediksi sebelumnya menggunakan algoritma GHSOM. Adapun hasil implementasi proses prediksi tersebut, akan dijabarkan secara mendetail pada Gambar 6.

Setelah data berhasil diambil dari file excel, maka data tersebut akan dilatih dengan RBF dan juga pengaturan beberapa parameter agar jaringan bekerja lebih optimal. Pengaturan parameter serta proses training pada NN ditunjukkan seperti pada Gambar 6, jumlah neuron masing-masing layer, nilai bias, learning rate, momentum dan sum of square error diatur pada halaman ini. Pada sebelah kanan terdapat tampilan grafik perbandingan harga sebenarnya dengan hasil prediksi serta grafik nilai SSE terhadap jumlah *epoch* pada saat proses perhitungan, semakin kecil nilai SSE maka jumlah epoch makin besar sampai dengan nilai SSE mendekati dengan nol. Selanjutnya proses training pada prediksi harga saham dengan menggunakan data yang ada dilakukan pada bagian bawah menu grafik. Pada proses training tersebut nilai output pada data dapat dibandingkan dengan nilai output proses perhitungan JST, sehingga dapat dibandingkan akurasi nilai tersebut. Hasil proses training dapat disimpan dan selanjutnya hasil tersebut dapat digunakan untuk pembelajaran serta proses prediksi.



Gambar 6 Implementasi Prediksi Harga Saham

E. Analisis Jaringan RBF dengan GHSOM

Jumlah data yang digunakan pada proses training sebanyak 1090 vektor data saham, dengan menggunakan parameter seperti pada Tabel 2. Nilai SSE yang digunakan adalah sebesar 0,5 dan nilai tersebut sudah mewakili nilai

keseluruhan, sedangkan epoch maksimum yang digunakan sebesar 50.000 dan jumlah *hidden layer* sebanyak satu lapisan, nilai *momentum* digunakan sebesar 0,1. Proses berikutnya adalah menguji hasil training dengan menggunakan jumlah neuron berbeda-beda pada masing-masing percobaan.

Hasil percobaan yang didapat dengan menggunakan jumlah neuron yang berbeda-beda pada *hidden layer*, hasil yang didapat menunjukkan bahwa dengan jumlah neuron sebanyak 10 unit menghasilkan nilai epoch terkecil dari seluruh percobaan dan dengan waktu tercepat.

TABEL 1
HASIL TRAINING DATA SAHAM KLBIF DENGAN MAKSIMUM SSE 0,5

Percobaan	Neuron	Epoch	SSE	Durasi
1	4	3544	0,499844670	00:00:15
2	7	1905	0,499601692	00:00:11
3	10	951	0,499482900	00:00:06
4	15	1046	0,499970466	00:00:10
5	20	1058	0,499412358	00:00:12
6	25	6149	0,499973357	00:01:29
7	30	4235	0,499985904	00:01:12
8	35	5325	0,499971122	00:01:45
9	45	955	0,498430312	00:00:22
10	50	988	0,498388648	00:00:25

pengaturan parameternya ditunjukkan pada Tabel 6.20. Jaringan backpropagation yang digunakan memiliki arsitektur yang telah disesuaikan dengan hasil percobaan diatas, untuk fungsi aktivasi menggunakan hiperbolik tangen karena memiliki jangkauan nilai yang lebih besar dibandingkan fungsi sigmoid biner. Nilai toleransi yang ditetapkan pada seluruh percobaan adalah sebesar 0,05, diberikannya nilai toleransi ini memberikan range nilai bernilai benar diantara toleransi tersebut.

TABEL 2
PENGATURAN PARAMETER OPTIMAL RBF

Parameter	Nilai	Keterangan
Target error(SSE)	0,01	Target proses berhenti
Learning rate	0,001	Kecepatan pembelajaran sistem
Momentum	0,95	Konstanta momentum
Hidden Layer	1	Jumlah lapisan tersembunyi
Node	10	Jumlah node pada <i>hidden layer</i>
Input Layer	9	Jumlah node pada lapisan <i>input</i>
Output Layer	1	Jumlah keluaran yang diinginkan
Bias	1	Jumlah <i>node bias</i>
Toleransi	0,001	Nilai toleransi prediksi saham
Transfer Function	Hiperbolic tangent	
Bobot	Random (0,1)	

Hasil *training* dengan jumlah vektor data sebanyak 1090 menghasilkan akurasi sebesar 91,95 % dalam kurun 00:00:03:44, dari proses pembelajaran tersebut selanjutnya diimplementasikan pada data *testing*. Hasil *testing* dengan jumlah vektor data sebanyak 364 dengan SSE sebesar 0,074713. Bobot yang diperoleh dari hasil *training* mampu mengenali sebagian data *testing*, hasilnya diperoleh akurasi

sebesar 94,03% sehingga dapat disimpulkan lebih banyak data yang dapat dikenali dari proses pembelajaran tersebut.

IV. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan melalui pengumpulan data, pemodelan dan analisis dapat disimpulkan prediksi harga saham dengan Optimasi metode *Radial Basis Function neural network* dengan Menggunakan *Growing Hierarchical Self Organizing Map*. Hasil *testing* dengan jumlah vektor data sebanyak 364 dengan SSE sebesar 0,074713 diperoleh akurasi sebesar 94,03%

SARAN

Perancangan dan pembangunan sistem prediksi harga saham dengan Optimasi metode *Radial Basis Function neural network* dengan Menggunakan *Growing Hierarchical Self Organizing Map* dapat ditambah dengan metode Hierarchical Clustering, K-Means Clustering, Gaussian Mixture Model, Self Organizing Maps, Hidden Markov Model pada bagian unsupervised learning.

DAFTAR PUSTAKA

- [1] Wiyanti, DT.,Pulungan ,R.,. Peramalan deret waktu menggunakan model fungsi basis radial (RBF) dan auto regressive Integreted Moving Avarage (ARIMA), Jurnal MIPA 35 (2):175-182, semarang., 2012
- [2] Sutijo Dkk. Pemilihan hubungan input-node pada jaringan saraf fungsi radial basis (Input-Nodes Link Selection on Radial Basis Funtion Neural Network). Jurnal Berkala MIPA, Yogyakarta. 2006
- [3] Rauber, A., The Growing Hierarchical Self-Organizing Map: Exploratory Analysis of High-Dimensional Data IEEE Transaction of Neural Network. 2002.
- [4] de Brito, R.F.B.,Oliveira, A.L.I., A foreign exchange market trading system by combining GHSOM and SVR, International Joint Conference on, Digital Object Identifier, Brisbane, Australia, halaman 1-7. 2012.
- [5] Ichimura, T., Yamaguchi, T., A proposal of interactive growing hierarchical SOM, IEEE International Conference on Digital Object Identifier, Halaman 3149 – 3154. 2011.
- [6] Jumingan. Analisis LaporanKeuangan, Bumi Aksara, Surakarta. 2009.
- [7] Haykin, S., Neural Network A Comprehensive Foundation, Second Edition, Pearson Education, Singapore. 1999.
- [8] Noorviani, Y., Penerapan Elman Recurrent Neural Network untuk Diagnosis Gangguan Autis Pada Anak, Tesis, Fakultas Matematika dan Ilmu Pengetahuan Alam, Program Studi S2 Ilmu Komputer, Universitas Gadjah Mada, Yogyakarta. 2011.