

**PENGGUNAAN METODE K-MEANS CLUSTERING  
UNTUK PENENTUAN PUSAT FUNGSI BASIS  
PADA MODEL RADIAL BASIS FUNCTION NEURAL NETWORK (RBFNN)  
DENGAN MENGGUNAKAN DATA KUNJUNGAN WISMAN  
KE YOGYAKARTA 1994 - 2006**

Uswatun Khasanah  
Program studi pendidikan matematika, FKIP UAD, Yogyakarta  
[Uswatun.khasanah2@yahoo.co.id](mailto:Uswatun.khasanah2@yahoo.co.id)

Abstrak

Radial Basis Function Neural Network merupakan kelompok besar dari model neural network yang jarak antara vector input dengan vektor prototype merupakan input dari unit hidden. Manfaat dari Radial Basis Function Neural Network untuk menentukan pendekatan fungsi regulasi, noisy interpolation, estimasi densitas, optimal classification theory dan fungsi potensial. Cukup banyak manfaat Radial Basis Function Neural Network namun belum adanya prosedur yang baku untuk menentukan model Radial Basis Function Neural Network yang optimal pada data time series.

Di dalam penelitian ini digunakan data kunjungan wisatawan mancanegara (wisman) ke Yogyakarta pada tahun 1994-2006. Data tersebut diambil banyaknya input 4 dan banyaknya kelas 3,4,5,6, dan 7. Selanjutnya ditentukan pusat dan varian dari masing-masing kelas dengan menggunakan metode K-Means clustering dan ditentukan banyaknya fungsi basis pada model Radial Basis Function Neural Network dengan menggunakan metode forward selection.

Hasil penelitian terdapat lima tipe pusat berdasarkan jumlah input dan jumlah kelas. Berdasarkan pusat-pusat yang diperoleh, dengan menggunakan forward selection untuk banyaknya kelas 3, 4, 5, 6, dan 7 diperoleh secara berturut-turut banyaknya fungsi basis 3, 3, 4,6, dan 7.

Kata kunci: Radial Basis Function Neural Network, K-Means clustering, forward selection, wisman

## Pendahuluan

Otak merupakan pengendali utama dalam tubuh manusia yang mengatur semua kegiatan selama 24 jam sehari. Otak tersusun atas miliaran sel kecil yang disebut neuron atau sel syaraf. Sistem syaraf manusia hanya terdiri dari tiga tahap besar yaitu penerima rangsangan (*receptor*), pemroses rangsangan (otak) dan perespon rangsangan (*effector*) dengan struktur organisasi yang rumit yang belum dapat disamai oleh sistem ciptaan manusia yang manapun. *Artificial neural network* atau

yang lebih dikenal dengan *neural network* (NN) mencoba mengadaptasi cara kerja sistem syaraf manusia tersebut. *Radial Basis function Neural Network* ( RBFNN ) merupakan kelas yang besar dari model NN dimana jarak antara vektor input dan vector prototype merupakan input fungsi aktivasi dari suatu unit tersembunyi (*hidden unit*). RBFNN telah menarik perhatian banyak ilmuwan pada masa lalu. RBFN dapat digunakan untuk membentuk suatu hubungan antara fungsi pendekatan, *noisy*

*interpolation*, klasifikasi dan estimasi fungsi.

Dalam makalah Beberapa referensi berkaitan dengan konsep dan bentuk dari model RBF dapat dilihat pada Bishop (1995), Ripley (1996) dan Haykin (1999). Dalam penerapannya, RBFN mengandung sejumlah parameter yang harus ditaksir. Bagaimana mendapatkan model RBFN yang optimal merupakan topik sentral dalam beberapa literatur NN.

Terdapat beberapa artikel yang membahas masalah pembelajaran RBFNN. Topchy dkk membagi masalah pembelajaran RBFN kedalam sub masalah, yaitu: penelitian tentang lokasi dan ukuran optimal dari ruang input serta mendefinisikan parameter dari output layer dengan alat *prosedur gradient* atau dengan prosedur yang lain. Sedangkan dalam artikel Leonardis dan Bishof menemukan beberapa metode dalam pembelajarann NN: Metode yang menyatakan jumlah RBFN yang harus diberikan suatu priori, metode mencari jumlah fungsi basis, center dan radii mereka, metode pruning

Dalam rangka membentuk model RBFNN, perlu dilakukan penentuan rata-rata dan varian. Ada beberapa cara penentuan tersebut yaitu diambil dari semua data input, data sampel, pemilihan himpunan

bagian, *k-means clustering* dan *constructive learning*. Di dalam penelitian ini digunakan metode *k-means clustering*. Ada beberapa literatur yang berkaitan dengan k-means clustering. J.b. MacQueen (1967) , Yudi Agusta (2007) dan Andrew D. Back(2002).

Selain itu juga terdapat beberapa artikel yang membahas tentang pemilihan model RBFNN. Ali Ghodsi dan Dale Schuurmans menerapkan metode estimasi Stein's Unbiased Risk Estimator (SURE) serta menerapkan criteria pemilihan model RBFNN dengan BIC (*Bayesian information Criteria*). Rivas dkk (2003) menerapkan Evolutionary (evRBF) untuk mengoptimalkan generalisasi error serta mencari jumlah neuron dalam *hidden layer* serta rata-rata dan varian. Sedangkan Lendase dkk (2005) melakukan pemilihan model dengan metode *Fast Bootstrap* (FB). Beberapa artikel terakhir tentang pembentukan model RBFN dengan menggunakan statistik inferensia dapat dilihat pada Anders dan Korn (1998), rammu Mehran (2004).

Permasalahan utama dalam pembentukan model NN dalam kerangka pemodelan statistik adalah masih belum adanya prosedur yang baku untuk mendapatkan model NN yang optimal pada suatu data *time series*. Dengan demikian

masih terbuka luas untuk dilakukan penelitian lebih lanjut berkaitan dengan model *neural network*. Dalam makalah ini NN dipandang sebagai suatu model statistik untuk *time series* yang akan diterapkan untuk peramalan jumlah wisatawan mancanegara yang berkunjung di Yogyakarta. Alasan diambil data wisatawan karena kota Yogyakarta merupakan selain sebagai kota pelajar juga merupakan kota wisata. Banyak objek wisata yang terdapat di Yogyakarta yang selain sebagai tujuan wisatawan domestik juga wisatawan mancanegara. Selain pada rentang waktu 1 Januari 1996 sampai dengan 31 Desember 2006 terjadi bom Bali dan gempa bumi di Yogyakarta yang menyebabkan data wisatawan mancanegara (wisman) menjadi tidak stasioner.

Adapun ada beberapa pembatasan masalah dalam penelitian ini, yaitu :

- a. Model NN yang dibahas adalah model RBFNN dengan satu *hidden layer*.
- b. Fungsi aktivasi yang digunakan dalam model RBFNN adalah fungsi *Gaussian*.
- c. Pemodelan hanya pada penentuan pusat dan banyaknya fungsi basis, belum dilanjutkan pada peramalan.

Berdasarkan latar belakang, rumusan masalah yang akan dibahas dalam penelitian ini adalah sebagai berikut

- a. Bagaimana prosedur-prosedur identifikasi yang optimal untuk menentukan center hidden layer dan penentuan bobot output model RBFNN pada data time series
- b. Bagaimana prosedur-prosedur penentuan jumlah fungsi basis model RBFNN yang optimal
- c. Bagaimana menentukan model RBFNN pada data time series secara komputasi

### **Tujuan Penelitian**

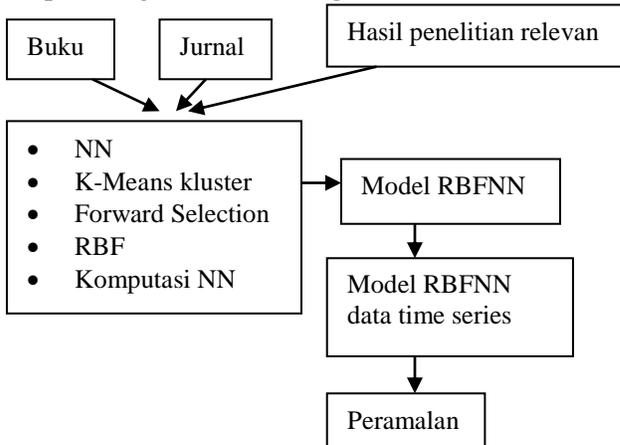
Tujuan penelitian yang berjudul “*K-means Clustering* untuk Penentuan Center neuron hidden layer model RBFNN pada data time series” ini adalah

- a. Menentukan pusat fungsi basis dan jumlah fungsi basis model RBFNN pada data kunjungan wisman ke Yogyakarta tahun 1994 - 2006
- b. Menentukan pusat fungsi basis dan banyaknya fungsi basis secara komputasi

### **Metode penelitian**

Penelitian ini merupakan penelitian jenis studi literatur. Peneliti mengumpulkan beberapa konsep dari beberapa sumber misalnya buku, jurnal dan hasil penelitian yang relevan.

Langkah-langkah penelitian ini dapat disajikan dalam bagan berikut ini



Gambar 1. Diagram design penelitian

Penelitian ini merupakan studi literatur, sehingga instrumen yang digunakan berbeda dengan penelitian yang lain. Adapun untuk mengukur keoptimalan model, digunakan ukuran mean square error (MSE). Semakin kecil MSE maka semakin baik model yang diperoleh.

Adapun teknik pengumpulan dataanya yaitu data-data yang diperoleh dari beberapa literatur kemudian dikaji, dikembangkan dan dianalisis sehingga diperoleh suatu model matematika.

Analisis data yang dilakukan dalam penelitian ini adalah

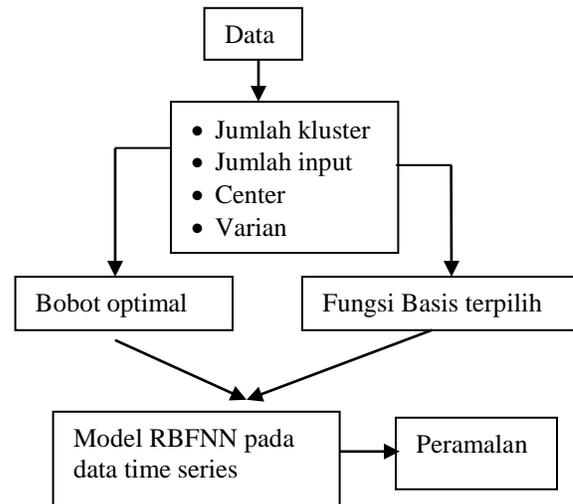
a. Data yang sudah diperoleh ditentukan center dan varian dengan menggunakan metode k- Means kluster

b. Setelah diperoleh jumlah input dan kluster akibatnya diperoleh sejumlah fungsi basis. Selanjutnya ditentukan fungsi basis mana yang terpilih menjadi fungsi aktivasi dengan menggunakan pendekatan *forward selection*

c. Penentuan bobot optimal dengan menggunakan metode kuadrat terkecil

d. Penentuan model RBFNN yang optimal

e. Aplikasi model pada data time series Analisis data tersebut dapat dibentuk dalam bagan sebagai berikut



Gambar 2. Diagram analisis data

### Pembahasan

NN telah dikembangkan sebagai model matematika yang menyerupai pola pikir manusia atau jaringan syaraf makhluk hidup, dengan asumsi bahwa: proses informasi terjadi pada banyak neuron, sinyal

yang melalui antar neuron menggunakan hubungan tertentu, setiap hubungan mempunyai bobot yang bersesuaian, kemudian mengalikan sinyal yang dikirimkan, dan setiap neuron menggunakan fungsi aktivasi terhadap input (jumlah sinyal input yang terboboti) untuk menentukan sinyal output. NN membangun kelas model yang sangat fleksibel sehingga dapat digunakan dalam berbagai macam terapan seperti regresi nonlinier dan analisis diskriminan. Output *network* dapat merupakan nilai prediksi variabel terikat  $y$  dan bisa ditulis sebagai fungsi  $f(x,w)$  atau  $Z$  dengan data input  $X = [x_1, \dots, x_p]$  dan parameter *network*  $w$  biasa disebut bobot. Adapun model matematika dari NN adalah

$$Z = \sum_{j=1}^q \beta_j \psi \left( \sum_{i=1}^p \gamma_{ij} x_i \right)$$

dengan  $w = [\beta_1 \ \beta_2 \ \dots \ \beta_q \ \gamma_{11} \ \gamma_{12} \ \dots \ \gamma_{pq}]'$  adalah besaran-besaran bobot (*network weights*) atau parameter-parameter pada model *neural network*. Bentuk nonlinear dari fungsi  $Z$  terjadi melalui suatu fungsi yang disebut fungsi aktivasi  $\psi$  dan biasanya merupakan fungsi yang halus seperti fungsi logistik sigmoid atau fungsi tangen hiperbolik.

RBFNN merupakan suatu kelompok besar dari model neural network yang mana

jarak antara vektor input dengan vektor prototipe merupakan input dari unit hidden. Menurut Bishop (1995) RBFNN merupakan model neural network yang mempunyai sifat menarik. Sifat tersebut adalah RBF membentuk hubungan kasatuan antara sejumlah konsep yang berbeda. RBF digunakan untuk mencari pendekatan fungsi regulasi, *noisy interpolation*, estimasi densitas, *optimal clasification theori* dan potensial fungsi. RBFNN biasanya memetakan suatu vektor  $x_k \in \mathfrak{R}^n$  ke suatu vektor  $y_k \in \mathfrak{R}^m$  dimana pasangan  $(x_k, y_k)$  dengan  $1 \leq k \leq M$  merupakan bentuk dari himpunan training. Jika pemetaan ini ditunjukkan sebagai suatu fungsi pada ruang input  $\mathfrak{R}^n$ , pembelajaran dapat dipandang sebagai masalah fungsi pendekatan. Adapun pembelajaran tersebut ekuivalen dengan menentukan suatu permukaan dalam ruang multidimensional yang memberikan himpunan training yang sangat tepat.

Arsitektur RBFNN mempunyai tiga layer yaitu input layer, hidden layer dan output layer. Model sederhana RBFNN dimana untuk setiap  $n$  komponen vektor input  $x$  mempengaruhi  $m$  fungsi basis. Adapun output  $f(x)$  yang dihasilkan dari model RBFN tersebut merupakan kombinasi linear dari bobot  $\{w_j\}_{j=1}^m$  dengan fungsi

basis  $h_j(x)$ , dan dapat dirumuskan sebagai berikut

$$f(x) = \sum_{j=1}^m w_j h_j(x)$$

$x_1, x_2, \dots, x_n$  merupakan input dan  $h_j(x_i)$  merupakan fungsi basis ke- $j$  dari input ke- $i$  dengan definisi sebagai berikut

$$h_j(x_i) = \exp\left(-\frac{(x_i - c_j)^2}{r_j^2}\right)$$

Algoritma pembelajaran RBFNN menurut Andrew (2002) terdiri tiga bagian yaitu menentukan center dan jarak dari setiap fungsi basis, jumlah fungsi basis (Hidden unit), dan bobot Output layer.

Salah satu prosedur pemilihan pusat RBF adalah prosedur yang diperkenalkan oleh Moody dan Darken yaitu menggunakan *k-means clustering*. Metode K-means kluster adalah salah satu bentuk pemetaan pada pada dirinya sendiri (*self organizing map*). Pada metode K-Means, data dipartisi kedalam subset atau kluster, dimana pada setiap kluster mempunyai sifat yang homogen serta antar kluster mempunyai ciri yang berbeda. Jika ada  $m$  kluster pada RBFNN, maka akan ada  $c_i$ ,  $i = 1, 2, \dots, m$  nilai rata-rata.

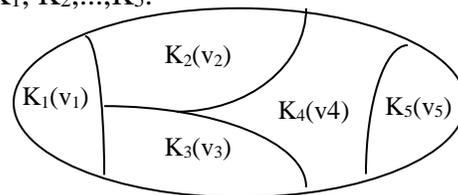
Metode *K-means clustering* menurut Macqueen (1967) dapat dilakukan dengan algoritma dasar sebagai berikut:

menentukan jumlah cluster, mengalokasikan data ke dalam cluster secara random, menghitung rata-rata dari data yang ada di masing-masing kluster, mengalokasikan masing-masing data ke rata-rata terdekat sampai tidak ada data yang berpindah klater.

Data dialokasikan secara tegas ke kluster yang mempunyai rata-rata terdekat dengan data tersebut. Pengalokasian ini dapat dirumuskan sebagai berikut.

$$a_{ik} = \begin{cases} 1, & d = \min\{D(x_k, v_i)\} \\ 0, & \text{lainnya} \end{cases} \quad (5.7)$$

Dimana  $a_{ik}$ : Keanggotaan data ke- $k$  cluster ke- $i$ ,  $v_i$ : Nilai rata-rata cluster ke- $i$  dan  $D(x_k, v_i)$ : nilai terdekat antar  $v_i$  dengan data  $x_k$ . Jika  $x_k$  dekat dengan rata-rata  $v_i$  maka  $x_k$  termasuk ke dalam cluster ke- $i$ . Misalkan diambil rata-rata kelas ke- $i$  yaitu  $v_i$ .  $a_{ik}$  akan bernilai 1 jika  $x_k$  nilainya terdekat dengan  $v_i$  dibandingkan dengan  $v_j$  dimana  $j \neq i$ . Sebaliknya  $a_{ik}$  akan bernilai 0 jika  $x_k$  nilainya lebih dekat dengan  $v_j$  dibandingkan dengan  $v_i$  dimana  $j \neq i$ . Sebagai ilustrasi dari persamaan (5.7) diberikan diagram venn berikut ini. Misalkan  $S\{x_1, x_2, \dots, x_n\}$  vektor input dan diambil sebanyak 5 kelas yaitu  $K_1, K_2, \dots, K_5$ .



Gb.3. Diagram venn persamaan 5.7

Dimana  $K_i(v_i)$  merupakan kelas ke- $i$  dengan pusat  $v_i$ . Misalkan  $x_2 \in K_3$  maka  $a_{32} = 1$  dan  $a_{i2} = 0$  untuk  $i \neq 3$ . Jika  $x_k \in K_5$  maka  $a_{5k} = 1$  dan  $a_{ik} = 0$  untuk  $i \neq 5$

Ada beberapa prosedur pemilihan variabel dalam hal ini pemilihan jumlah RBF yang menyebabkan model optimal. Prosedur-prosedur tersebut adalah *Forward selection*, *backward selection*, *stepwise selection* dan *the hidden scandal of statistics*. Dalam penelitian ini digunakan prosedur *forward selection*.

Suatu strategi alternatif untuk membandingkan model-model yang terbentuk dari subset-subset yang berbeda dari fungsi basis yang diambil dari beberapa himpunan yang sama. Hal ini dalam statistik dinamakan *subset selection*. Adapun untuk menentukan subset yang terbaik dari  $2^M$  subset (yaitu satu subset dari himpunan berukuran  $M$ ) sehingga *heuristics* harus digunakan untuk mencari suatu yang kecil tetapi dengan harapan menarik bagian ruang semua himpunan bagian.

Di dalam penelitian ini digunakan *forward selection* untuk *subset selection*. Menurut Orr(1996) *forward selection* mempunyai beberapa keuntungan, yaitu sebagai pendahuluan tidak memerlukan jumlah tertentu *hidden unit*, kriteria

pemilihan model mudah dikerjakan dan sarat perhitungan relatif rendah. Di dalam *forward selection* setiap langkah melibatkan pertumbuhan network dengan satu fungsi basis. Penambahan fungsi basis baru ke  $m+1$  dalam suatu model linear yang mempunyai  $m$  fungsi basis dan  $p$  mempunyai pengaruh penambahan extra kolom matriks design. Misalkan mula-mula terdapat  $m$  fungsi basis yaitu  $h_1, h_2, \dots, h_m$  dengan  $n$  input yaitu  $x_1, x_2, \dots, x_n$ , maka diperoleh matriks design mula-mula sebagai berikut Jika matriks design mula-mula  $H_m$  yang berukuran  $n \times m$  adalah sebagai berikut

$$\mathbf{H}_m = [\mathbf{h}_1 \ \mathbf{h}_2 \ \dots \ \mathbf{h}_m]$$

$$= \begin{bmatrix} h_1(x_1) & h_2(x_1) & \dots & h_m(x_1) \\ h_1(x_2) & h_2(x_2) & \dots & h_m(x_2) \\ \vdots & \vdots & \dots & \vdots \\ h_1(x_n) & h_2(x_n) & \dots & h_m(x_n) \end{bmatrix}$$

dan penambahan fungsi basis baru adalah  $h_{m+1}(x)$  maka diperoleh matriks design baru sebagai berikut

$$\mathbf{H}_{m+1} = [\mathbf{H}_m \quad \mathbf{h}_{m+1}]$$

$$= \begin{bmatrix} h_1(x_1) & h_2(x_1) & \dots & h_m(x_1) & h_{m+1}(x_1) \\ h_1(x_2) & h_2(x_2) & \dots & h_m(x_2) & h_{m+1}(x_2) \\ \vdots & \vdots & \dots & \vdots & \vdots \\ h_1(x_n) & h_2(x_n) & \dots & h_m(x_n) & h_{m+1}(x_n) \end{bmatrix}$$

Kriteria pemilihan model terbaik yang dapat dipakai adalah AIC (Akaike Information Criteria), MSE (*mean squared error*) atau rata-rata kuadrat error, MAPE (*mean absolute percentage error* atau

persentase nilai mutlak rata-rata error), MAD (*mean absolute deviation* atau nilai mutlak rata-rata deviasi) dan UEV (*The unbiased estimate of variance*) . Model terbaik berdasarkan ketiganya adalah model yang meminimalkan kriteria. Beberapa penghitungan kriteria di atas sbb :

$$\text{MSE} = \frac{1}{M} \sum_{l=1}^M e_l^2$$

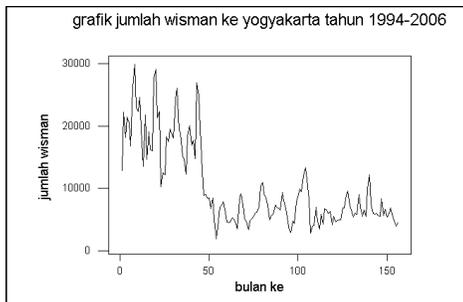
$$\text{MAPE} = \left( \frac{1}{M} \sum_{l=1}^M \left| \frac{e_l}{Z_{n+1}} \right| \right) 100\%$$

$$\text{UEV} = \frac{\mathbf{Z}^T \mathbf{P}^2 \mathbf{Z}}{n - \gamma}, \text{ dengan}$$

$$\mathbf{P} = \mathbf{I}_n - \mathbf{H}\mathbf{A}^{-1}\mathbf{H}^T \text{ dan } \mathbf{A} = \mathbf{H}^T \mathbf{H}$$

### Implementasi metode K-Means Kluster pada data wisman

Data bulanan jumlah wisatawan mancanegara yang berkunjung di Yogyakarta, mulai bulan Januari 1994 sampai bulan Desember 2006 dapat digambarkan sebagai berikut:



Gb.4. Data bulanan jumlah wisman

Berdasarkan gambar di atas terlihat bahwa grafik data fluktuatif dan

tidak stasioner. Di dalam pemodelan time series dengan pendekatan RBFNN, jika data tidak stasioner maka tidak perlu dibuat stasioner. Sebagai langkah awal adalah penentuan mean dan varian. Dengan menggunakan metode K-Means kluster. Dalam makalah ini banyaknya kelas yang diambil adalah 3,4,5,6, dan 7. Sedangkan banyaknya input adalah 4.

Berdasarkan K-Means  $\frac{1}{M} \sum_{l=1}^M |e_l|$  kluster menggunakan software MINITAB dilakukan langkah-langkah sebagai berikut masukkan semua nilai data  $x_i$ , menentukan input, menentukan jumlah kluster dan menentukan pusat dan varian dari masing-masing kluster. Adapun hasil penentuan center dari data wisatawan mancanegara yang berkunjung di Yogyakarta dengan pendekatan K-Means Clustering berturut-turut berdasarkan jumlah kluster 3,4,5,6, dan 7 adalah sebagai berikut.

Selanjutnya penentuan jumlah fungsi basis dengan menggunakan pemrograman MATLAB tentang forward untuk masalah peramalan data *time series* sebagaimana diperkenalkan oleh Mark J. L. Orr. (1997). Adapun hasil fungsi basis yang terpilih dan banyaknya fungsi basis yang terpilih melalui software MATLAB dari data wisman dengan 4 input dan banyaknya kelas 3,4,5,6, dan 7 adalah sebagai berikut:

Tabel 1

Input	Kelas	Center
1	1	5961
	2	19320
	3	9156
2	1	5822
	2	19678
	3	9619
3	1	5864
	2	19949
	3	9719
4	1	6016
	2	19554
	3	10171

Tabel 2

Input	Kelas	Center
1	1	5921
	2	20677
	3	8005
	4	17847
2	1	5619
	2	23108
	3	8954
	4	16208
3	1	5654
	2	22551
	3	8976
	4	17575
4	1	5647
	2	21723
	3	887
	4	17410

Tabel 3

Input	Kelas	Center
1	1	5921
	2	16213
	3	8005
	4	18816
	5	24141
2	1	5619
	2	19230
	3	8954
	4	16990
	5	26859
3	1	5654
	2	23841
	3	9125
	4	17112
	5	21326
4	1	5832
	2	25574
	3	9133
	4	17356
	5	17330

Tabel 4

Input	Kelas	Center
1	1	5921
	2	13943
	3	8005
	4	20487
	5	27471
	6	20945
2	1	5619
	2	17430
	3	8954
	4	16577
	5	26248
	6	24480
3	1	5654
	2	18653
	3	9125
	4	17576
	5	16405
	6	26124
4	1	5832
	2	22187
	3	9133
	4	16106
	5	18254
	6	21824

Tabel 5

Input	Kelas	Center
1	1	5921
	2	15519
	3	8005
	4	20935
	5	27471
	6	20812
	7	18326
2	1	5619
	2	19917
	3	8954
	4	16403
	5	26248
	6	27471
	7	21767
3	1	5654
	2	18082
	3	9125
	4	17263
	5	16405
	6	26248
	7	25189
4	1	5832
	2	20827
	3	9133
	4	15011
	5	18254
	6	16405
	7	26691

## Kesimpulan

Berdasarkan landasan teori dan aplikasi pada data time series diperoleh beberapa kesimpulan, yaitu Penentuan pusat dan varian sebagai parameter fungsi basis dapat digunakan metode K-Means cluster dan untuk menginvestigasi permasalahan penentuan jumlah unit hidden optimal dalam RBFNN dengan menggunakan pendekatan *forward selection* yaitu dimulai dari jumlah unit hidden kosong atau  $m = 0$ , selanjutnya fungsi basis mulai ditambahkan satu persatu ke dalam model dan penambahan mulai dihentikan ketika penurunan nilai kriteria UEV berakhir.

- Agusta, Y(2007). *K-Means-Penerapan, Permasalahan dan metode terkait*. Jurnal Sistem dan Informatika vol.3 (februari 2007), 47-60
- Anders, U., Korn, O., 1997, Model Selection in Neural Networks, *Neural Networks*, 12, 309-323.
- Andrew.D.back.*Radial Basis Function*,p.3.1-3.handbook of Neural Network Signal Processing. Edited by Yu hen Hu, jeng-Neng Hwang
- Bishop, C. M., (1995). *Neural Network for Pattern Recognition*. Oxford: Clarendon Press.
- Fauset, L.(1994). *Fundamental of Neural Network, Architectures, Algorithms, and Applications*. Florida Institute of Technology. Prentice Hall, Englewood Cliffs, NJ 07632
- Ghodsi, A. dan Schuurmans, D. *Automatic Basis selection Techniques for RBF Networks*. Paper School of Computer

Science University of Waterloo 200 University Avenue West N2L 3G1, Canada

- Haykin, H. (1999). *Neural Networks: A Comprehensive Foundation*, second edition, Prentice-Hall, Oxford.
- MacQueen, J. B. (1967). *Some Methods for clasification and Analysis of Multivariate Observations*.Proceedings of 5-th Berkeley Symposium of Mathematical Statistics and Probability, Berkeley, University of California Press,1: 281-297
- Miyamoto, S. And Agusta, Y.(1995). An efficient Algoritma for  $L_1$  and  $L_p$  Fuzzy C-Means and their Convergence,in C. Hayashi, N.Oshumi,K.Yajima, y.Tanaka, h. H. Bock and Y. Baba, *Data Science, Classification, and Related Methods*, Springer-Verlag, Tokyo, Japan, pp. 295-302
- Moody, J. Dan Darken, C. (1989). *Fast Learning in Network of Locally-Tuned Processing Unit*. Neural Computation
- Orr, M.J.L (1996).*Introduction to Radial Basis Function Networks*. Centre for Cognitive Science, University of Edinburgh,2, Buccleuch Place, Edinburgh EH8 9LW, Scotland
- Orr.M.J.L (1997 ) *.MATLAB Routines for Subset Selection and Ridge Regression in Linear Neural Network*. Centre for Cognitive Science, University of Edinburgh, Scotland
- Rencher, A.V.(2000).*Linear Models in Statistics*. Department of Statistics Brigham Young University Provo, utah. A wiley-Interscience Publication JOHN WILEY & SONS,INC.

Ripley, B. D. (1996). *Pattern Recognition and Neural Networks*. Cambridge University Press, Cambridge.

Rivas, V. M. Dkk. (2003). *Evolving RBF Neural Networks for Time Series forecasting with EvRBF*. Information Sciences 165(2004) 207-220. [WWW.sciencedirect.com](http://WWW.sciencedirect.com)