

PEMILIHAN HUBUNGAN INPUT-NODE PADA JARINGAN SARAF FUNGSI RADIAL BASIS

(Input-Nodes Link Selection on Radial Basis Function Neural Network)

Brodjol Sutijo¹, Subanar² dan Suryo Guritno²

¹ Jurusan Statistika, Institut Teknologi Sepuluh Nopember, Surabaya
sutijo_b@yahoo.com

² Jurusan Matematika, Universitas Gadjah Mada, Yogyakarta
subanar@yahoo.com, Guritno0@mailcity.ac.id

ABSTRAK

Model jaringan saraf fungsi radial basis (*Radial Basis Function Neural Network* = RBFNN) adalah model jaringan saraf dengan satu unit dalam lapisan tersembunyi, dimana fungsi aktivasinya adalah fungsi basis (Gaussian) dan fungsi linear pada lapisan output. Untuk mendapatkan model RBFNN terbaik, diperlukan kombinasi yang tepat antara jumlah variabel input, jumlah node (kluster), yang berimplikasi pada jumlah parameter optimal. Untuk mendapatkan sejumlah node yang diinginkan dilakukan dengan mengelompokkan data. Salah satu metode pengelompokan data adalah metode K-mean. Dengan terbentuknya kelompok data, maka nilai tengah dan varians variabel input pada setiap kluster dapat dihitung. Komponen invers varians pada fungsi aktivasi RBFNN merupakan bobot dari suatu pergeseran, sehingga diperlukan nilai interval untuk varians tersebut. Nilai varians suatu variabel input pada suatu node yang berada diluar interval mengindikasikan hubungan input dengan node tidak memberi sumbangan yang signifikan pada model RBFNN, sehingga perlu dihapus. Penentuan model terbaik dari RBFNN dapat diketahui dengan kriteria nilai Mean Square Error (MSE) kecil dan Koefisien Determinasi (R^2) besar.

Kata kunci : RBFNN, K-mean, Interval Varians, MSE, R^2

ABSTRACT

Radial Basis Function Neural Network (RBFNN) model is neural network model with gaussian activation function in a unit hidden layer and linear function in output layer. To find best of RBFNN model is needed combination of input variables and number of node in hidden layer. Implication of the combination is mean and variance of input variables in each node. Clustering input data by using K-mean method is done to get a number of nodes. Variance inverse component of activation function RBFNN is a weight shift of mean. Large of weight is small variance, so cannot get useful information. On the contrary small of weight is large variance, so too much get un-useful information. Confidence interval of variance is needed to solve the problem. Link a input variable to a node is insignificant if variance input on the node out of confidence interval, so the link can be disconnected. To select best model of RBFNN is used Mean Square Error (MSE) and determination coefficient (R^2) criterion.

Keywords: RBFNN, K-mean, Variance, MSE, R^2

1. PENDAHULUAN

Model *neural network* (NN) mempunyai struktur model yaitu input melewati unit hidden sebelum diproses pada output. Model NN mempunyai beberapa desain seperti, *perceptron*, *feedforward neural network* (FFNN), *radial basis function neural network* (RBFNN) dan lain-lain. Desain dari RBFNN adalah model NN mentransformasi input secara nonlinear dengan menggunakan fungsi aktivasi Gaussian pada lapisan unit *hidden* sebelum diproses secara linear pada lapisan output. Beberapa referensi model NN adalah Bishop (1995), Ripley (1996) and Fine (1999), sedangkan artikel utama tentang RBFNN adalah Broomhead dan Lowe (1988), Moody dan Darken (1989), Poggio dan Girosi (1990).

Model NN adalah model nonparametrik dengan struktur fungsi yang fleksibel. Sehingga model NN cepat berkembang dan telah banyak diaplikasikan pada berbagai bidang. Hal ini secara umum dimotivasi dengan kondisi syarat yang lunak, sederhana dan dapat digunakan untuk pendekatan suatu fungsi, seperti yang dilakukan oleh Cybenko (1989), Funahashi (1989), Hornik dkk. (1989, 1990), White (1990), atau Gallant dan White (1992). Lapedes dan Farber (1987) adalah salah satu peneliti yang mengawali menggunakan model NN untuk peramalan data time series. Lazaro dkk. (2003) telah mengaplikasikan algoritma EM untuk learning RBF dan Rivas dkk. (2004) mengenalkan Evolving RBF untuk peramalan data time series. Penggunaan model NN juga dapat dipakai untuk menguji nonlinearitas dari data seperti yang dilakukan oleh White (1989) tentang kondisi nonlinear yang terabaikan pada time series, Terasvirta dkk (1993) tentang kekuatan uji linearitas. Deteksi nonlinearitas pada data time series dengan menggunakan model NN juga telah dilakukan telaah oleh Sutijo dan Subanar (2004).

Optimisasi model RBFNN juga telah banyak dilakukan seperti yang dilakukan oleh Lazzarro dkk (2003) tentang penggunaan EM algoritma, Lendasse dkk (2005) menggunakan metode Bootstrap untuk seleksi model, Sutijo dkk. (2005) melakukan penambahan

parameter regulasi, Sutijo dkk. (2006) melakukan pemilihan model NN terbaik dengan pendekatan perbandingan berganda dan Sutijo dkk (2007) melakukan uji untuk memilih link yang kurang berguna.

Dalam penerapannya, model RBFNN mengandung sejumlah parameter (*weight*) yang harus ditaksir. Untuk mendapatkan model RBF yang sesuai, perlu menentukan kombinasi yang tepat antara jumlah variabel input, jumlah node (cluster) pada unit *hidden layers*, nilai tengah dan standar deviasi (skala atau *width*) dari variabel input pada setiap node, yang berimplikasi pada jumlah parameter yang optimal. Hal ini merupakan topik sentral dalam beberapa literatur NN dan telah banyak dibahas pada berbagai artikel seperti pada Bishop (1995), Ripley (1996), Fine (1999), Haykin (1999), atau pada Reed dan Marks II (1999), serta Lazaro dkk (2003).

2. TINJAUAN TEORI

2.1 Fungsi radial basis

RBFNN didesain untuk membentuk pemetaan nonlinear dari variabel input ke unit *hidden layer* dan pemetaan linear dari *hidden layer* ke output. Sehingga pada RBFNN dilakukan pemetaan input dari ruang berdimensi p ke output ruang berdimensi 1.

$$s: \mathfrak{R}^p \rightarrow \mathfrak{R}^1 \quad (1)$$

Berdasarkan teori interpolasi multivariate :

Jika diberikan N buah titik berbeda $\{x_i \in \mathfrak{R}^p | i=1, 2, \dots, N\}$ yang berhubungan dengan N buah bilangan real d_i , $\{d_i \in \mathfrak{R}^1 | i=1, 2, \dots, N\}$.

Fungsi $F: \mathfrak{R}^p \rightarrow \mathfrak{R}^1$ adalah fungsi yang memenuhi:


$$F(x_i) = d_i, \quad i = 1, 2, \dots, N.$$

Agar memenuhi teori di atas, Interpolasi dengan menggunakan fungsi $F(x)$ harus meloloskan semua data. Teori interpolasi multivariate secara ringkas dapat dinyatakan dengan:

$$F: \mathfrak{R}^p \rightarrow \mathfrak{R}^1$$

$$F(x_i) = d_i, i = 1, 2, \dots, N. \quad (2)$$

Disain dari model RBFNN untuk pendekatan suatu fungsi adalah sebagai berikut :



gambar 1. Design RBF network

Pada pemodelan RBFNN dilakukan dengan memilih suatu fungsi $F(x)$ sehingga (2) dipenuhi. Interpolasi input-output (2) dengan melihat disain model RBFNN, maka (2) dapat dinyatakan dengan:

$$F(x) = \sum_{i=1}^N w_i f(\|x - x_i\|) \quad (3)$$

Dimana $\{f(\|x - x_i\|) | i = 1, 2, 3, \dots, N\}$ adalah himpunan fungsi nonlinear yang disebut fungsi radial basis (*Radial Basis Function* = RBF). dan $\|\cdot\|$ adalah norm jarak Euclid. Fungsi radial basis yang sering digunakan adalah fungsi gaussian karena mempunyai sifat lokal, yaitu bila input dekat dengan rata-rata (pusat), maka fungsi akan menghasilkan nilai satu, sedangkan bila input jauh dari rata-rata, maka fungsi membe-rikan nilai nol. Ada beberapa fungsi radial basis diantaranya adalah :

1. Fungsi *Thin Plate Spline*

$$f(z) = (z - m)^2 \log(z - m)$$

2. Fungsi Multikuadratik

$$f(z) = [(z - m)^2 + s^2]^{1/2}$$

3. Fungsi Invers Multikuadratik

$$f(z) = [(z - m)^2 + s^2]^{-1/2}$$

4. Fungsi Gaussian

$$f(z) = \exp[-(z - m)^2 / s^2].$$

Apabila diketahui N buah titik data $\{x_i \in \mathfrak{R}^p | i = 1, 2, \dots, N\}$ adalah pusat dari RBF, maka persamaan (3) dapat ditulis :

$$\begin{bmatrix} f_{11} & f_{12} & \dots & f_{1N} \\ f_{21} & f_{22} & \dots & f_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ f_{N1} & f_{N2} & \dots & f_{NN} \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_N \end{bmatrix} = \begin{bmatrix} d_1 \\ d_2 \\ \vdots \\ d_N \end{bmatrix} \quad (4)$$

dimana $f_{ij} = f(\|x_i - x_j\|)$

$$i, j = 1, 2, 3, \dots, N.$$

Bila (4) dinyatakan dalam bentuk persa-maan matrik, persamaan (4) menjadi :

$$\mathbf{f} \mathbf{w} = \mathbf{d} \quad (5)$$

dimana $\mathbf{d} = [d_1 \ d_2 \ \dots \ d_N]$,

$$\mathbf{w} = [w_1 \ w_2 \ \dots \ w_N] \text{ dan}$$

$$\mathbf{f} = \mathbf{f}_{ij}$$

matrik \mathbf{f} adalah matrik interpolasi yang definit positif dan mempunyai innvers .

Pendekatan suatu fungsi dengan menggunakan RBFNN dilakukan dengan interpolasi untuk mendapatkan penyelesaian optimal dari ruang berdimensi tinggi ke dimensi yang lebih rendah. Poggio dan Girosi (1990) menyusun teknik standar yang disebut metode Galerkin. Pada meto-de ini, $F(x)$ adalah suatu fungsi yang didekati dengan sejumlah basis lebih sedi-ikit dibandingkan ukuran sampel, sehingga fungsi $F(x)$ pada (3) menjadi :

$$F^*(x) = \sum_{i=1}^M w_i f_i(x) \quad (6)$$

Dimana $\{f_i(x) | i = 1, 2, \dots, M\}$ adalah himpunan fungsi basis baru yang diasum-sikan bebas linear. Secara umum, himpu-nan fungsi basis baru lebih sedikit diban-dingkan dengan banyak data ($M \leq N$) dan w_i adalah bobot unit ke i ke output.

2.2 Metode K-mean cluster

Pendekatan fungsi dengan menggu-nakan model RBFNN dilakukan dengan dua tahap. Tahap pertama adalah pembe-lajaran unsupervised, yaitu untuk menen-tukan mean dan standart deviasi dari variabel input pada setiap node pada unit hidden layer. Metode K-mean cluster atau pengelompokkan dengan

menggunakan metode k-mean adalah salah satu metode dari beberapa metode unsupervised pada pemodelan RBFNN dan metode K-mean adalah salah satu bentuk metode pemetaan pada dirinya sendiri (*Self Organizing map*) yang juga dikembangkan dalam pemodelan NN. Pada metode K-mean, data dipartisi kedalam subgroup atau kluster, dimana pada setiap kluster mempunyai sifat yang homogen serta antar kluster mempunyai ciri yang berbeda. Jika ada m buah unit pada RBFNN, maka ada akan ada $m_i, i = 1, 2, 3, \dots, m$ nilai rata-rata atau pusat.

Penentuan nilai rata-rata dari setiap kluster dilakukan dengan iterasi. Nilai rata-rata kluster untuk iterasi ke n adalah $m_i(n)$. Algoritma dari metode K-mean secara garis besar adalah sebagai berikut :

1. Inisialisasi :

Memilih nilai secara random sebagai nilai awal dari pusat kluster

$$m_i(0), \quad i = 1, 2, 3, \dots, M.$$

2. Similaritas :

Dapatkan nilai $k(\mathbf{x})$, indeks dari kesesuaian terbaik untuk pusat kluster, dengan meminimumkan jarak euclidian, dengan kriteria :

$$k(\mathbf{x}) = \arg \min_k \|\mathbf{x}(n) - \mu_k(n)\| \quad (7)$$

$$k = 1, 2, \dots, m$$

3. Update :

Menghitung nilai pusat baru, dengan menggunakan suatu pendekatan, sebagai berikut :

$$\mu_k(n+1) = \begin{cases} nk(n) + h(\mathbf{x}(n) - \mu_k(n)), & k = k(x) \\ \mu_k(n) & , \text{ yang lain} \end{cases}$$

dimana h adalah parameter laju pembelajaran

4. Ulangi langkah 2 dan 3 sampai tidak ada perubahan nilai pusat.

2.3 Invers Varians

Pada model RBFNN dengan fungsi aktivasi adalah gaussian :

$$f_j(\mathbf{x}) = \exp \left[\frac{-\|\mathbf{x} - \mu_j\|^2}{2s_j^2} \right]. \quad (8)$$

menunjukkan bahwa komponen varians ($1/s_j^2$) pada (8) dapat dianggap sebagai

bobot dari suatu pergeseran $\|\mathbf{x} - \mu_j\|$.

Sehingga jika bobot bernilai sangat besar yang berarti nilai varians kecil menuju nol, berimplikasi bentuk fungsi sempit, sehingga tidak dapat menangkap informasi yang ada. Sebaliknya jika nilai bobot sangat kecil, berarti nilai varian besar, berimplikasi pada bentuk fungsi yang lebar dan berisi banyak informasi yang kurang berguna. Sehingga diperlukan suatu nilai batas bawah dan batas atas untuk varians tersebut.

Mengingat yang kita peroleh dari data adalah dugaan dari S^2 (S^2), sehingga nilai S^2 harus berada pada suatu interval kepercayaan. Nilai batas untuk varians dapat didekati dengan menghitung interval kepercayaan $(1-\alpha)$ dari nilai varians tersebut. Berdasarkan distribusi chi-square diketahui bahwa :

$$\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{S^2} \sim \chi^2_{(n-1)} \quad (9)$$

maka interval kepercayaan $(1-\alpha)$ untuk

$$\sum_{i=1}^n (x_i - \bar{x})^2 = (n-1)S^2 \text{ adalah :}$$

$$\text{Batas bawah : } \frac{S^2}{\chi^2_{(n-1); 1-\alpha/2}} \quad (10)$$

$$\text{Batas atas : } \frac{S^2}{\chi^2_{(n-1); \alpha/2}} \quad (11)$$

Karena nilai S^2 tidak diketahui, maka nilai S^2 dicari dengan pendekatan lain, yaitu dengan melakukan simulasi sebanyak n kali.

Nilai $(n-1)S^2$ yang berada diluar interval adalah petunjuk awal bahwa hubungan (link) variabel input ke node adalah calon untuk dihapus, karena terindikasi tidak dapat menangkap informasi yang ada atau terlalu banyak mendapat informasi yang tidak berguna.

3. METODOLOGI

Untuk menunjang konsep teori di atas dicobakan pada data time series berupa data Indeks Harga Konsumen (IHK) Indonesia dengan tahun dasar 2002, hasil publikasi


Badan Pusat Statistik (BPS), mulai periode Januari 1999 sampai Oktober 2006.

Tahap pertama pemodelan adalah melihat pola data dan melakukan analisis dengan menggunakan metode standart (Meto-de Time Series). Mengingat data memben-tuk trend linear, maka dilakukan prepro-sesing data dengan menghilangkan kompo-nen linear (*detrended*). Data hasil *de-trended* inilah yang akan digunakan dalam pemodelan RBFNN. Tahap kedua adalah menentukan nilai rata-rata dan varians untuk setiap kluster hasil dari klustering data dengan metode K-Mean, serta mene-tukan nilai $(n-1)S^2$ yang berada diluar interval. Tahap tiga adalah pemodelan RNFNN, baik untuk link penuh atau tanpa link yang terindikasi tidak bermanfaat. Ta-hap akhir adalah mengukur tingkat kebai-kan model didasarkan pada nilai Mean Square Error (MSE).

4. HASIL ANALISIS DATA

Data IHK Indonesia, periode bulan Januari 1999 sampai bulan Oktober 2006 pada harga konstan januari 2002, menun-jukkan tidak stasioner dalam rata-rata dan mempunyai trend linear (gambar 2.a). Hal ini menunjukkan bahwa data tidak dapat langsung dianalisis dengan menggunakan metode time series (metode Box-Jenskin). Jika dilakukan pembedaan (*diffrencing*), model yang terbentuk adalah model ran-dom walk (acak), yaitu ARIMA (0,1,0) mengingat pola autokorelasi dan autoko-relasi parsial berada dalam interval. Analisis alternatif adalah dengan meng-hilangkan komponen trend (*detrended*).

Detrended adalah salah satu bentuk metode preprosesing dalam pemodelan NN. Hasil data detrended menunjukkan bahwa pola data detrended tidak sesuai bila dimodelkan dengan model linear (gambar 2.b). Berdasarkan hasil yang diperoleh Sutijo dan Subanar (2004), menunjukkan bahwa model NN mampu melakukan pen-dekatan fungsi untuk pola data tersebut.



gambar 2.a. Plot IHK 2.b Detrended IHK

Berdasarkan pola nilai autokorelasi dari data detrended, diketahui bahwa lag 1 sampai lag 4 nilai autokorelasi signifikan, berarti model yang akan dibentuk adalah $y_t = f(y_{t-1}, y_{t-2}, y_{t-3}, y_{t-4})$

Pengklusteran data dengan menggu-nakan metode K-mean dibentuk menjadi 4 kluster. Hasil pengklusteran dengan metode K-Mean dan batas interval hasil simulasi di-tampilkan pada tabel 1.


Tabel 1. Mean, SD dan CI 95% SD dari variabel input

Var	Cls	mean	SD	CI 95% SD	
				BB	BA
Y _{t-1} (1)	1	6.702	0.647	0.092	1.727
	2	5.282	1.335	0.310	1.690
	3	3.760	1.120	0.745	1.667
	4	-1.58	1.120	1.390	1.860
Y _{t-2} (2)	1	7.763	0.854	0.875	1.762
	2	5.761	0.950	0.329	1.671
	3	3.140	2.050	0.788	1.728
	4	-1.57	1.388	1.370	1.609
Y _{t-3} (3)	1	8.795	0.664	0.232	1.729
	2	6.314	0.645	0.469	1.929
	3	2.330	2.850	0.873	1.886
	4	-1.54	1.418	0.268	1.576
Y _{t-4} (4)	1	9.236	0.020	0.049	1.137
	2	6.835	0.716	0.310	1.895
	3	1.550	2.690	0.992	1.935
	4	-1.50	1.471	1.272	1.613

Berdasarkan hasil yang ditampilkan pada tabel 1, diketahui bahwa link (1-4) yaitu link antara variabel satu (y_{t-1}) ke kluster empat calon untuk dihapus. Hal ini dika-renakan nilai SD variabel y_{t-1} pada kluster empat berada diluar inter-val kepercayaan 95% untuk SD. Link-link lain calon untuk dihapus adalah (2-3), (3-3), (4-1) dan (4-3), pada tabel 1, ditunjukkan dengan warna dasar yang berbeda.

Desain RBFNN berdasarkan data de-trended IHK adalah seperti pada gambar 3. Pada gambar 3, link variabel input de-ngan

node calon untuk dihapus ditunjukkan dengan garis putus-putus.



Gambar 3. Desain RBFNN detrended IHK

Mengingat ada sebanyak lima link variabel input ke node calon untuk dihapus, maka perlu mencari kombinasi dari link-link tersebut untuk dihapus, sehingga diperoleh model RBFNN dengan *performance* terbaik.


Performance model RBFNN diukur dengan menggunakan nilai koefisien determinasi (R^2) dan *Mean Square Error* (MSE), baik untuk model lengkap (tidak ada link yang dihapus) dan model tidak lengkap (ada satu atau lebih link yang dihapus). Sebagian hasil *performance* model RBFNN ditampilkan pada tabel 2. Model yang ditampilkan tabel 2, adalah model dengan *performance* terbaik dari sejumlah kombinasi link terhapus, mulai kombinasi satu sampai kombinasi lima. Berdasarkan tabel 2, diketahui bahwa model terbaik adalah model RBFNN dengan kombinasi link terhapus adalah model (2,3) (3,3) (4,1) (4,3). Pada tabel 2. juga ditampilkan MSE dari model AR(1) data detrended sebagai perbandingan. Berdasarkan nilai MSE model AR(1) lebih baik dibandingkan dengan model lengkap RBFNN akan tetapi tidak lebih baik dari model RBFNN dengan satu atau beberapa link dihapus.

Tabel 2. Performance model RBFNN

Model	MSE	R^2 (%)
Model lengkap	1.304	70.1
(4,1)	1.106	74.6
(3,3) (4,3)	1.064	75.6
(2,3) (3,3) (4,3)	0.790	81.8

(2,3) (3,3) (4,3)	0.790	81.8
(2,3) (3,3) (4,1) (4,3)	0.736	83.1
(1,4) (2,3) (3,3) (4,1) (4,3)	0.749	82.8
Time Series AR(1)	1.289	

Untuk mengetahui lebih lengkap tentang hasil dari model yang terbentuk, ditampilkan plot series data detrended dan nilai taksiran.



Gambar 4. Plot data detrended dan nilai taksiran

5. KESIMPULAN

Komponen varians dari fungsi aktivasi gaussian pada model RBFNN merupakan bobot pergeseran dari mean. Varians variabel input dari setiap node yang berada diluar interval merupakan link calon untuk dihapus.

Pemodelan data IHK dengan menggunakan model time series diperoleh model ARIMA(0,1,0). Preprocessing data IHK dilakukan dengan detrended, dimana model RBFNN adalah

$$y_t = f(y_{t-1}, y_{t-2}, y_{t-3}, y_{t-4}).$$

Berdasarkan simulasi yang dilakukan diketahui bahwa link (1-4) atau link variabel satu ke node node, (2-3), (3-3), (4-1) dan (4-3) adalah calon link yang akan dihapus.

Model RBFNN terbaik untuk data IHK detrended adalah model RBFNN dengan link (2-3), (3-3), (4-1) dan (4-3) dihapus dari desain RBFNN dengan nilai MSE =0.736 dan R^2 =83.1%.

DAFTAR PUSTAKA

- Bishop, C. M., 1995, *Neural Network for Pattern Recognition*. Oxford: Clarendon Press.
- Broomhead, D.S. and Lowe, D., 1988, Multivariable functional interpolation and adaptive network. *Complex Systems*, 2, 321–355.

- Cybenko, G., 1989. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals and Systems*, 2, 304–314.
- Fine, T. L. 1999. *Feedforward Neural Network Methodology*. Springer, New York.
- Funahashi, K., 1989. On the approximate realization of continuous mappings by neural networks. *Neural Networks*, 2, 183–192.
- Haykin, H., 1999. *Neural Networks: A Comprehensive Foundation*, second edition, Prentice-Hall, Oxford.
- Hornik, K., Stinchcombe, M. and White, H., 1989 Multilayers FeedForward Network are Universal Approximation, *Neural Network*, Vol:2 ; 359 – 366
- Hornik, K., Stinchcombe, M. and White, H. 1990. Universal Approximation of an Unknown Mapping and Its Derivatives Using Multilayers Feed-forward, *Neural Network*, Vol : 3 ; 551 - 560
- Gallant, A. R. and White, H. 1992. On learning the derivatives of an unknown mapping with multiplayer feedforward networks. *Neural Networks*, 5, 129–138.
- Lapedes, A. and Farber, R., 1987. Nonlinear Signal Processing Using Neural Networks: *Prediction and System Modeling*. Technical Report LAUR-87-2662, Los Alamos National Laboratory, Los Alamos, NM.
- Lazarro, M., Santamaria, I., and Pantaleon, C., 2003. A new EM-based training algorithm for RBF networks. *Neural Networks*, 16, 69–77.
- Lendasse, A. et. al., 2005. Fast Bootstrap methodology for regression model selection, *Neuro Computing*, 64 (2005), 161-181
- Moody, J. and Darken, C., 1989. Fast learning in networks of locally tuned processing units. *Neural Computation*, 1 (2), 281–294.
- Poggio, T. and Girosi, F., 1990. Network for approximation and learning. *Proceedings of IEEE*, 78 (9), 1491–1497.
- Reed, R. D. and Marks II, R. J., 1999. *Neural Smthing*. MIT Press, Cambridge, MA.
- Ripley, B. D., 1996. *Pattern Recognition and Neural Networks*. Cambridge University Press, Cambridge.
- Rivas, V.,M., Merelo, J.J, 2004. Evolving RBFNN untuk time series forecasting, With EvRBF. *Informatica Science*, 165, 7-20.
- Sutijo, B., dan Subanar, 2004, *Uji Nonlinearitas yang Diabaikan dalam time series*, ICSM, Unisba, Bandung
- Sutijo, B., Subanar dan Guritno, S., 2005. *Efek Regulasi Dalam Estimasi Fungsi dengan Pendekatan Jaringan Fungsi Radial Basis*, Seminar sehari Matematika dan Komputer, UNS, Surakarta.
- Sutijo, B., Subanar dan Guritno, S., 2006. Model Selection Strategy in Radial Basis Function, ICOMS, Unisba Bandung
- Sutijo, B., Subanar dan Guritno, S., 2007. Selecting Input Factor for Units of Radial Basis function Network, Joint Conference Indonesia-Malaysia, ITS Surabaya
- Tsay, R.S.,1986, Nonlinearity Test for Time Series , *Biometrika* 73, 461-466
- Rivas, V.,M., Merelo, J.J, 2004. Evolving RBFNN untuk time series forecasting, With EvRBF. *Informatica Science*, 165, 7-20.
- Terasvirta, T., Lin, C.-F. , and Granger, C.W.J., 1993, Power of the neural network linearity test. *Journal of Time Series Analysis*, 14, 159–171.
- White, H., 1989, An Additional Hidden Unit Test for Neglected Nonlinearity in Multilayer FFNN, Univ. of California
- White, H., 1990. Connection nonparametric regression: Multilayer feedforward networks can learn arbitrary mapping. *Neural Networks*, 3, 535–550.