

PERAMALAN DERET WAKTU MENGGUNAKAN MODEL FUNGSI BASIS RADIAL (RBF) DAN *AUTO REGRESSIVE INTEGRATED MOVING AVERAGE* (ARIMA)

DT Wiyanti , R Pulungan

Jurusan Ilmu Komputer dan Elektronika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Gadjah Mada Yogyakarta

Info Artikel

Sejarah Artikel:

Diterima 9 Juli 2012

Disetujui 6 September 2012

Dipublikasikan Oktober 2012

Keywords:
time series
RBF
ARIMA

Abstrak

Salah satu metode peramalan yang paling dikembangkan saat ini adalah *time series* yakni menggunakan pendekatan kuantitatif dengan data masa lampau yang dijadikan acuan untuk peramalan masa depan. Berbagai penelitian telah mengusulkan metode-metode untuk menyelesaikan *time series* di antaranya statistik, jaringan syaraf, *wavelet*, dan sistem fuzzy. Metode-metode tersebut memiliki kekurangan dan keunggulan yang berbeda. Namun permasalahan yang ada dalam dunia nyata merupakan masalah yang kompleks. Satu metode saja mungkin tidak mampu mengatasi masalah tersebut dengan baik. Dalam artikel ini dibahas penggabungan dua buah metode yaitu *Auto Regressive Integrated Moving Average (ARIMA)* dan *Radial Basis Function (RBF)*. Alasan penggabungan kedua metode ini adalah karena adanya asumsi bahwa metode tunggal tidak dapat secara total mengidentifikasi semua karakteristik *time series*. Pada artikel ini dibahas peramalan terhadap data Indeks Harga Perdagangan Besar (IHPB) dan data inflasi komoditi Indonesia; kedua data berada pada rentang tahun 2006 hingga beberapa bulan di tahun 2012. Kedua data tersebut masing-masing memiliki enam variabel. Hasil peramalan metode ARIMA-RBF dibandingkan dengan metode ARIMA dan metode RBF secara individual. Hasil analisa menunjukkan bahwa dengan penggabungan ARIMA dan RBF, model yang diberikan memiliki hasil yang lebih akurat dibandingkan dengan penggunaan salah satu metode saja. Hal ini terlihat dalam *visual plot*, MAPE, dan RMSE dari semua variabel pada dua data uji coba.

Abstract

The accuracy of *time series* forecasting is the subject of many decision-making processes. *Time series* use a quantitative approach to employ data from the past to make forecast for the future. Many researches have proposed several methods to solve *time series*, such as using statistics, neural networks, *wavelets*, and fuzzy systems. These methods have different advantages and disadvantages. But often the problem in the real world is just too complex that a single method cannot provide adequate solutions since a single model may not completely identify all the characteristics of *time series*. In this research, we propose to combine two methods *Auto Regressive Integrated Moving Average (ARIMA)* and *Radial Basis Function (RBF)*. This research will make a forecasting for Wholesale Price Index (WPI) and inflation of Indonesian commodity. Each of data is in the range of 2006 to several months in 2012, and each has 6 variables. The results of ARIMA-RBF forecasting method will be compared with ARIMA method and RBF method individually. The result of the analysis shows that the combined method of ARIMA and RBF is more accurate than the ARIMA model or RBF model only. The result can be observed using the visual plot, MAPE, and MSE of all the variables in the two trial data.

Pendahuluan

Analisis *time series* dan *forecasting* adalah bidang penelitian yang aktif (Zheng & Zhong 2011). Artinya, keakuratan dalam *time series forecasting* menjadi pokok dari proses pengambilan keputusan. Beberapa penelitian yang melakukan riset pada *time series* adalah statistik, jaringan syaraf, *wavelet*, dan sistem *fuzzy*. Metode-metode tersebut memiliki kekurangan dan keunggulan yang berbeda. Terlebih lagi, masalah dalam dunia nyata seringkali merupakan masalah yang kompleks dan satu model mungkin tidak mampu mengatasi masalah tersebut dengan baik. Makridakis dan Hibon (2000) dalam Fauziah dan Suhartono (2012) menyatakan bahwa kelebihan dari menggabungkan beberapa model menjadi satu adalah menghasilkan ramalan dengan tingkat akurasi yang lebih baik secara rata-rata dibandingkan dengan model tunggal lainnya.

Salah satu metode peramalan yang paling dikembangkan saat ini ialah *time series*, yakni menggunakan pendekatan kuantitatif dengan data masa lampau dikumpulkan dan dijadikan acuan untuk peramalan masa depan. Teknik peramalan *time series* terbagi menjadi dua bagian. Pertama, model peramalan yang didasarkan pada model matematika statistik seperti *moving average*, *exponential smoothing*, regresi, dan ARIMA (*Box Jenkins*). Kedua, model peramalan yang didasarkan pada kecerdasan buatan seperti *neural network*, *algoritma genetika*, *simulated annealing*, *genetic programming*, *klasifikasi*, dan *hybrid*. Dengan demikian kita mengetahui bahwa dalam *time series forecasting*, ilmu statistik dan jaringan syaraf pun termasuk dalam bidang kajian penelitiannya.

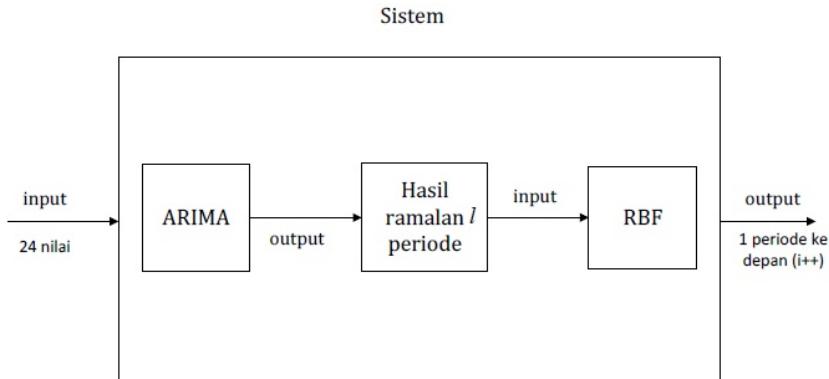
Permasalahan yang ditemui di dunia nyata adalah permasalahan data yang tidak stasioner atau tidak linier. Dibutuhkan suatu alat yang akurat dan efektif untuk meramalkan perilaku data yang tidak stasioner atau tidak linier tersebut. Namun terdapat pula permasalahan lain dalam model jaringan syaraf yang sering ditemui yaitu permasalahan *overfitting*, dimana model yang dibuat hanya menghasilkan *output* yang baik untuk data yang dilatih saja dan tidak untuk data yang divalidasi (data yang tidak termasuk proses *training*). Ini adalah *fenomena overfitting* yang termasuk masalah yang sering ditemui ketika menggunakan model jaringan syaraf. Di sisi lain, permasalahan tersebut dapat diminimalisir

dengan pengembangan yang mengombinasikannya dengan model lain. Kombinasi yang pernah dicobakan untuk peramalan *time series* adalah model jaringan syaraf tiruan dengan model *Auto Regressive Integrated Moving Average (ARIMA)* (Faruk 2010). Ada tiga hal yang menjadi alasan penggunaan pengkombinasi model ARIMA dan *neural network* (Zhang 2003). Pertama, sering kali terjadi kesulitan untuk menerapkan penggunaan model linier atau model nonlinier pada suatu permasalahan *time series*, sehingga model kombinasi ini menjadi alternatif yang lebih mudah. Kedua, dalam kenyataannya *time series* jarang yang linier atau nonlinier dan sering mengandung keduanya, dimana tidak hanya model ARIMA dan *neural network* masing-masing dapat memodelkan setiap kasusnya, sehingga pengkombinasi ini dapat digunakan untuk memodelkan *time series* yang mengandung linier dan nonlinier. Ketiga, dalam beberapa literatur peramalan menyatakan bahwa tidak ada model tunggal yang terbaik pada setiap situasi.

ARIMA sering disebut juga metode runtun waktu Box Jenkins. ARIMA cukup dikenal dalam peramalan *time series*. ARIMA sangat baik ketepatannya untuk peramalan jangka pendek dan untuk data *time series non stasioner* pada saat linier (Munarsih 2011). Sedangkan untuk data peramalan dalam periode yang cukup panjang ketepatannya kurang baik karena biasanya akan cenderung *flat* (datar/konstan). Selain itu ARIMA akan mengalami penurunan keakuratan apabila terdapat komponen nonlinier *time series* pada data pengamatan. Zhang (2003) pun menyatakan bahwa ARIMA tidak mampu memodelkan *time series* yang nonlinier.

Berbeda dengan ARIMA, model jaringan syaraf (*neural network*) merupakan metode peramalan yang dapat digunakan untuk memprediksi *time series nonlinier*, selain itu stasioneritas dari data juga tidak dihiraukan (Munarsih 2011). Padahal dalam kehidupan nyata banyak permasalahan dengan data yang mengandung kelinieran dan ketidak-linieran sekaligus.

Terdapat beberapa algoritma pembelajaran dalam jaringan syaraf tiruan (*Artificial Neural Network*) yang dikembangkan untuk *time series forecasting*. Salah satunya yaitu menggunakan fungsi basis radial atau *Radial Basis Function Neural Network (RBFNN)*, algoritma pembelajaran ini handal dan biasa



Gambar 1. Arsitektur sistem prediksi ARIMA-RBF

digunakan untuk penyelesaian masalah *forecasting* dan *time series modelling*, selain itu RBF sangat baik ketika digunakan untuk menyelesaikan permasalahan komponen non stasioner dan non linier. 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 Sutijo *et al.* (2006) menyebutkan bahwa *performance* model RBF menghasilkan model yang lebih baik di mana konsep teorinya dicobakan pada data *timeseries*

ARIMA dalam statistik dan RBF dalam *neural network* masing-masing telah dibuktikan dan dinyatakan menjadi metode yang handal dalam *time series forecasting*. Dengan mengkombinasikan dua metode tersebut diharapkan akan menghasilkan tingkat keakuratan yang lebih tinggi dibandingkan jika metode tersebut digunakan masing-masing tanpa dikombinasikan. Selain itu alasan penggabungan kedua model ini (ARIMA dan RBF) adalah karena adanya asumsi bahwa model tunggal tidak dapat secara total mengidentifikasi semua karakteristik dari time series (Terui & Van Dijk 2002). Hipotesis penulis adalah bahwa gabungan model RBF dengan ARIMA akan lebih akurat karena struktur autokorelasi kompleks pada data dapat dimodelkan.

Metode Penelitian

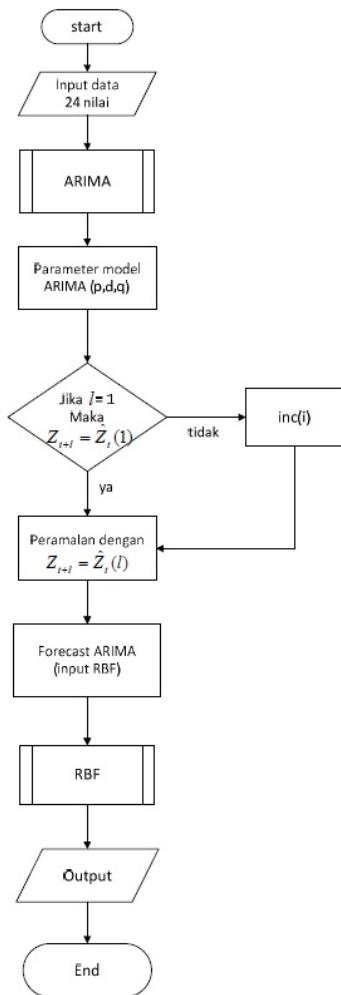
Pada artikel ini data yang digunakan adalah data *time series* Indeks Harga Perdagangan Besar Indonesia (IHPB) dari bulan Januari 2006-April 2012 dan data Inflasi Indonesia menurut kelompok komoditi dari bulan Januari 2006-Mei 2012. Secara garis besar sistem peramalan ARIMA-RBF yang akan dibangun ditunjukkan dengan Gambar 1.

Gambar 1 menggambarkan sistem

prediksi dari penggabungan metode ARIMA dan RBF. Pada sistem tersebut data berproses dalam ARIMA terlebih dahulu untuk data masukan selama dua tahun yang artinya 24 nilai input, hal ini terkait dengan prosedur ARIMA yang memiliki syarat minimum jumlah masukan. Data yang keluar dari proses ARIMA adalah sebuah ramalan untuk beberapa periode ke depan. Namun, meskipun telah diproses dengan ARIMA, diasumsikan masih terdapat ketidaklinieran dalam data tersebut. Sehingga proses selanjutnya adalah meng-kan data ramalan dari ARIMA ke dalam RBF, dimana jumlah *input*-nya akan dimodifikasi sedemikian sehingga didapatkan model RBF terbaik dengan nilai *error* yang minimum. Hasil *output* dari sistem adalah ramalan untuk beberapa periode ke depan yang dilakukan secara iteratif. Langkah-langkah kerja sistem ini dapat digambarkan secara lebih detail dalam diagram alir pada Gambar 2.

Gambar 2 akan didapatkan dengan langkah-langkah sebagai berikut: (a) Tujuan pertama dapat dicapai dengan memasukkan data selama dua tahun atau 24 nilai untuk diproses dengan metode ARIMA dan menggunakan bantuan *software* statistik Minitab 14. Untuk proses ARIMA sendiri ditunjukkan oleh Gambar 3. (b) Setelah didapatkan model ARIMA (*p*, *d*, *q*) yang terbaik maka proses selanjutnya adalah peramalan untuk beberapa periode ke depan dan dilakukan secara iteratif untuk *l* periode ke depan yang dilambangkan dengan $Z_{(t+l)}$. Ukuran *window* dari hasil peramalan ARIMA bergantung pada model ARIMA (*p*, *d*, *q*) yang terpilih. (c) Hasil peramalan ARIMA menjadi *input* untuk proses RBF untuk selanjutnya diproses menggunakan metode RBF. (d) *Output* dari Gambar 2 adalah hasil peramalan yang telah melalui proses ARIMA dan RBF.

Pada tahap pengkombinasi model ARIMA-RBF ini terdapat tiga tahapan yang



Gambar 2. Diagram alir proses RBF- ARIMA

harus diikuti (Zhang 2003) dalam (Munarsih 2011). Pengkombinasi dilakukan karena dalam dunia nyata jarang ditemukan kejadian *time series* yang murni linier ataupun murni nonlinier. Secara umum kombinasi dari model *time series* yang memiliki struktur autokorelasi linier dan nonlinier dapat dituliskan sebagai:

dimana Z_t merupakan time series murni, L_t

$$Z_t = L_t + N_t \quad (1)$$

merupakan komponen linier dan N_t merupakan komponen nonlinier. Tiga tahapan tersebut yaitu: a) Memodelkan komponen linier. b) Memodelkan komponen nonlinier. c) Kombinasi komponen linier dan nonlinier.

Memodelkan Komponen Linier

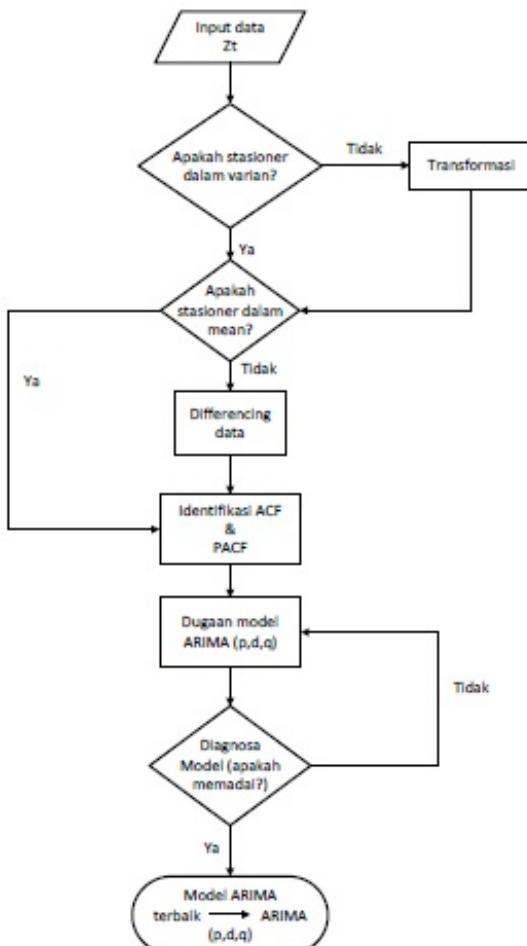
Model ARIMA digunakan pada tahapan pertama, yaitu pemodelan secara linier. Model ARIMA digunakan untuk menyelesaikan kasus yang linier, dimana residual dari model yang linier masih mengandung informasi hubungan non linier. Secara matematis dapat dituliskan sebagai:

$$e_t = Z_t - \hat{L}_t \quad (2)$$

dimana L_t adalah nilai peramalan pada waktu t dan Z_t adalah data awal waktu ket. Menurut Zheng dan Zhong (2011), karena RBF tidak mampu menangkap struktur linier dari data, residual dari kenonlinieran yang diberikan akan memberikan informasi kelinieran. Dengan memodelkan residual menggunakan model ARIMA, maka kelinieran tersebut ditemukan. Dengan model ARIMA maka residualnya adalah sebagai berikut.

$$e_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n}) + \varepsilon_t \quad (3)$$

Gambaran langkah-langkah analisis ARIMA Box Jenkins ada pada Gambar 3.



Gambar 3. Diagram alir proses ARIMA

Memodelkan Komponen NonLinier

Jaringan RBF digunakan dalam tahap memodelkan komponen nonlinier, dan total jaringan syaraf ada enam karena masing-masing untuk memprediksi komoditas yang berbeda. Langkah-langkah analisa RBF adalah:

- (a) *Input* data untuk proses *training*. Data yang akan digunakan dalam proses pelatihan adalah sebarang n jumlah data yang diinputkan oleh user. Data diatur sedemikian sehingga membentuk matriks. Ilustrasi proses pembentukan matriks ditunjukkan oleh Gambar 4.

	(y-2)	(y-1)	(y)	Target (y+1)
Jan 2006	160	161	161	160
	161	161	160	166
	161	160	166	169
	160	166	169	172
	166	169	172	173
	169	172	173	178
	172	173	178	184
	173	178	184	185
	178	184	185	190
.....
.....
245	243	243	246	
243	243	246	248	
243	246	248	253	
246	248	253	253	
248	253	253	254	
253	253	254	253	
253	253	253	254	

Gambar 4. Ilustrasi matriks

- (b) Menentukan jumlah *hidden neuron*.
 (c) Proses training dimulai dengan melakukan normalisasi data sedemikian sehingga data akan berada pada $[0,1]$. Rumus normalisasi yang digunakan adalah:

$$\text{data normalisasi} = \frac{\text{nilai } x - \text{nilai minimum}}{\text{nilai maksimum} - \text{nilai minimum}} \quad (4)$$

dengan x adalah data masukan.

- (d) Langkah proses training selanjutnya adalah melakukan perhitungan bobot (w) antara lapisan input ke lapisan tersembunyi menggunakan algoritma *unsupervised learning* yaitu algoritma SOM.

- (e) Mencari besarnya nilai spread yang akan digunakan.

$$\sigma = \frac{\text{jarak maksimum antara 2 pusat}}{\sqrt{\text{banyaknya pusat}}} = \frac{d_{\max}}{\sqrt{m}} \quad (8)$$

- (f) Perhitungan nilai aktivasi dengan fungsi Gaussian.

$$\varphi = \exp\left(-\frac{\sum(X-W)^2}{2\sigma^2}\right) \quad (9)$$

- (g) Membentuk matriks Gaussian dari hasil perhitungan pada langkah f.

$$G = \begin{bmatrix} \varphi_{11} & \varphi_{12} & \dots & \varphi_{1C} \\ \varphi_{21} & \varphi_{22} & \dots & \varphi_{2C} \\ \dots & \dots & \dots & \dots \\ \varphi_{M1} & \varphi_{M2} & \dots & \varphi_{MC} \end{bmatrix}$$

M → vektor input ke -M
C → hidden unit ke-C

Kolom terakhir, biasanya disi nilai bias

- (h) Menghitung *pseudo invers* dari matriks Gaussian. Perhitungan bobot dari lapisan tersembunyi ke lapisan *output* menggunakan sistem persamaan linear *pseudo invers* matriks, dimana bobot baru (w) dihitung dengan mengalikan *pseudo invers* dari matriks G , dengan vektor target (d) dari data *training*.

$$w = G^+ \cdot d$$

$$= (G^T \cdot G)^{-1} \cdot G^T \cdot d \quad (10)$$

G^T adalah transpose dari matriks G dimana setiap kolom dari matriks G menjadi baris pada G^T . Sedangkan $(G^T \cdot G)^{-1}$ adalah invers dari $G^T \cdot G$ sehingga $(G^T \cdot G) \cdot (G^T \cdot G)^{-1} = I$, dengan I adalah matriks identitas.

- (i) *Training* data dilakukan dengan *trial and error* sedemikian sehingga didapat nilai MAPE (*Mean Absolute Percentage Error*) dan RMSE (*Root Mean Square Error*) terkecil dengan jaringan yang telah mencapai optimal.

- (j) Dilakukan proses *testing* dengan memasukkan bobot pelatihan, data pelatihan, data *real*. Selanjutnya *output* dari proses *testing* adalah bobot baru, hasil peramalan RBF, serta RMSE dan MAPE.

- (k) Model optimal didapatkan dari perhitungan error terkecil dan tampilan grafik dimana titik-titik plot dari hasil prediksi mendekati data aktual.

Langkah-langkah algoritma SOM sebagai berikut.

- (1) Inisialisasi bobot secara *random*, *learning rate* yang digunakan, dan parameter topologi tetangga.
- (2) Selama kondisi berhenti masih salah, lakukan langkah 2-8.
- (3) Untuk setiap vektor masukan x , lakukan langkah 3-5.
- (4) Untuk setiap j , hitung jarak Euclidean dengan rumus:

dengan w_{ij} adalah bobot dari input i ke hidden

$$D(j) = \sum (w_{ij} - x_i)^2 \quad (5)$$

j , dan x_i adalah vektor input.

- (5) Menemukan indeks J sehingga $D(J)$ minimum.

- (6) Untuk setiap unit j yang termasuk di dalam tetangga dari j , dan untuk setiap i . Rumus yang digunakan:

$$w_{ij}(t+1) = w_{ij}(t) + \alpha(t)[x_i - w_{ij}(t)] \quad (6)$$

dengan $w_{ij}(t+1)$ adalah bobot baru, $w_{ij}(t)$ adalah bobot saat ini, (t) adalah laju pembelajaran.

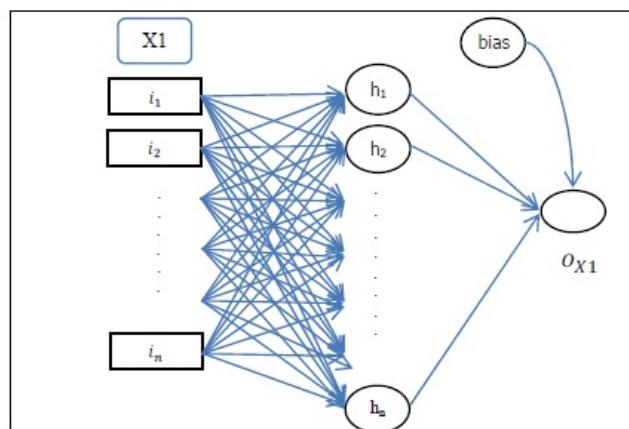
- (7) Memperbaiki nilai laju pembelajaran . Rumus yang digunakan:

- (8) Mengurangi radius tetangga topologis pada waktu yang sudah ditentukan.

$$\alpha_{\text{baru}} = \alpha_{\text{lama}} - (\alpha_{\text{lama}} \times \text{momentum}) \quad (7)$$

- (9) Tes kondisi berhenti.

Jaringan akan dilatih memiliki arsitektur seperti ditunjukkan dengan Gambar 5, dicontohkan untuk variabel X_1 . i_1, i_2, \dots, i_n adalah *input* sebanyak n sebarang jumlah data, h_1, h_2, \dots, h_n adalah *hidden neuron*, sedangkan O_{X1} adalah nilai prediksi X_1 untuk 1 periode ke depan. Ukuran *window* yang digunakan dalam peramalan dengan RBF ini bergantung pada banyaknya *input*.



Gambar 5. Arsitektur RBF dengan input n-data

Kombinasi Komponen Linier dan Nonlinier

Tahapan ini adalah tahap untuk memodelkan residual dari model ARIMA dengan menggunakan metode RBF. Oleh karena itu tahap ini disebut sebagai tahapan kombinasi komponen linier dan nonlinier. Hasil ramalan dari metode ARIMA kemudian dikombinasikan dengan hasil ramalan dari model RBF. Secara matematis, hasil ramalan secara keseluruhan yang diperoleh adalah sebagai berikut.

$$\hat{Z}_t = \hat{L}_t + \hat{N}_t \quad (11)$$

Z_t merupakan hasil peramalan yang merupakan gabungan nilai ramalan dari model ARIMA dan nilai ramalan dari model RBF.

Hasil dan Pembahasan

Hasil ramalan data *out sample* untuk data IHPB dan data inflasi komoditas selama 48 periode menggunakan model kombinasi ARIMA-RBF akan dibandingkan dengan model ARIMA dan model RBF secara individual. Perbandingan hasil ramalan dilakukan untuk masing-masing variabel menggunakan ketiga model tersebut. Hasil perbandingannya terlihat dalam Tabel 1 untuk data IHPB dan Tabel 2 untuk data inflasi.

Dalam Tabel 1 diperlihatkan bahwa hasil kombinasi ARIMA-RBF lebih baik dibandingkan dengan hasil ARIMA dan RBF secara individu. Hal ini terlihat terutama pada

Tabel 1. Perbandingan ketiga model untuk data IHPB

Variabel	ARIMA			RBF			ARIMA-RBF		
	Model		MAPE (p,d,q)	Model		MAPE (i,h,o)	Model		MAPE (i,h,o)
	Optimal	RMSE		Optimal	RMSE		Optimal	RMSE	
X1	(0,1,1)	2.96	0.58	(14,48,1)	2.6605	1.154	(6,8,1)	0.2240	0.449
X2	(1,1,1)	1.28	0.46	(7,37,1)	1.8392	0.690	(6,6,1)	0.2488	0.4768
X3	(0,1,1)	1.39	0.88	(8,41,1)	1.4602	0.548	(6,7,1)	0.0846	0.444
X4	(1,1,2)	3.86	0.40	(7,30,1)	3.1618	1.176	(6,6,1)	0.1702	1.533
X5	(1,0,0)	5.17	0.26	(9,14,1)	1.9687	1.352	(2,15,1)	1.9574	0.945
X6	(1,0,1)	10.01	0.27	(6,26,1)	7.6397	3.355	(2,25,1)	8.667	3.1671

Tabel 2. Perbandingan ketiga model untuk data inflasi

Variabel	ARIMA			RBF			ARIMA-RBF		
	Model		MAPE (p,d,q)	Model		MAPE (i,h,o)	Model		MAPE (i,h,o)
	Optimal	RMSE		Optimal	RMSE		Optimal	RMSE	
X1	(0,0,1)	1.12	2.56	(6,18,1)	1.0020	145.863	(2,24,1)	0.6955	12.028
X2	(0,0,1)	0.22	0.75	(6,37,1)	0.1775	33.470	(6,10,1)	0.0056	0.8851
X3	(1,0,1)	0.20	1.71	(6,40,1)	0.1857	78.862	(6,11,1)	0.0083	42.35
X4	(2,2,0)	0.90	35.57	(6,24,1)	0.6778	158.826	(2,33,1)	2.1676	28.99
X5	(1,0,1)	0.26	0.53	(6,20,1)	0.1853	52.899	(2,16,1)	0.2755	31.89
X6	(2,1,0)	29.54	0.17	(7,48,1)	0.1803	219.458	(6,22,1)	0.0028	14.3003

nilai RM SE yang secara keseluruhan lebih kecil nilainya jika dibandingkan dengan nilai RM SE dari kedua model lainnya. Namun seperti pada tabel-tabel sebelumnya yang memperlihatkan ketidak-signifikan antara RM SE dan MAPE, maka pada Tabel 6.5 pun demikian halnya. Dimana pada X2, MAPE dari model kombinasi ARIMA-RBF menempati posisi terkecil kedua setelah ARIMA. Begitu juga pada X5 dan X6, sedangkan pada X4 justru MAPE dari hasil kombinasi ARIMA-RBF paling besar di antara kedua model lainnya.

Dan dalam Tabel 2 hasilnya lebih bervariasi untuk kombinasi ARIMA-RBF, dimana untuk variabel X1, X2, X3, dan X6 mencapai hasil yang paling baik dibandingkan dengan hasil ARIMA dan RBF secara individu. Namun untuk MAPE, jika dibandingkan dengan ARIMA maka hampir seluruhnya MAPE ARIMA lebih baik, hanya satu dari nilai MAPE hasil kombinasi yang terbaik yaitu pada variabel X4. Namun untuk keseluruhan hasil dari RBF lebih besar dibandingkan dengan model kombinasi.

Kesimpulan dan Saran

Peramalan dengan menggunakan kombinasi metode ARIMA dan RBF dapat ditarik sejumlah kesimpulan bahwa: (a) Pada proses *training*, diketahui bahwa banyaknya *neuron* pada *hidden layer* sangat mempengaruhi hasil prediksi, baik visual plot, MAPE, maupun RM SE. Hasil yang ditunjukkan memperlihatkan bahwa berbedanya jumlah *hidden neuron* pada masing-masing variabel diperlukan untuk mendapatkan arsitektur terbaiknya. (b) Berbedanya jumlah *hidden neuron* pada masing-masing variabel dipengaruhi juga oleh inisialisasi bobot secara *random* dan algoritma SOM yang kompetitif, dimana hal tersebut yang menyebabkan perbedaan banyaknya *neuron* saat input dan saat pengujian, karena *neuron* yang tidak memiliki anggota akan langsung dieliminasi pada saat pelatihan. (c) Model kombinasi ARIMA-RBF adalah model terbaik saat digunakan untuk data uji coba IHPB dengan ukuran perhitungan *error* menggunakan RM SE. Untuk data uji coba inflasi hanya X1, X2, X3,

dan X6 yang terbaik. (d) Untuk nilai perhitungan error dengan MAPE memiliki hasil yang bervariasi untuk data IHPB. Sedangkan untuk data inflasi nilai MAPE terbaik didapatkan oleh model ARIMA.

Pengembangan sistem ini masih memiliki keterbatasan yang dapat dijadikan acuan untuk pengembangan di masa yang akan datang, sehingga dapat disarankan beberapa hal sebagai berikut: (a) Algoritma SOM yang digunakan memiliki kelebihan dalam kecepatannya menentukan bobot, namun cenderung tidak stabil apabila data yang digunakan tidak terlalu banyak. Dalam penelitian ini data yang digunakan masih belum terlalu banyak, dapat digunakan data yang lebih banyak dan beragam agar hasil yang diperlihatkan lebih baik. (b) Pseudoinvers matriks yang digunakan memiliki kelebihan dalam memperbaiki bobot hidden-output namun agak sulit diterapkan dalam program, maka perlu dikembangkan metode lain yang lebih mudah namun juga memiliki hasil yang lebih baik.

Daftar Pustaka

- Faruk DO. 2010. A hybrid neural network and ARIMA model for water quality time series prediction. *Eng App Intelligence* 23:586-594.
- Fauziah L & Suhartono. 2012. Peramalan jumlah kedatangan wisatawan mancanegara ke Indonesia melalui lima pintu kedatangan utama menggunakan model hibrida ARIMA-ANFIS. *Makalah Tugas Akhir Jurusan Statistika FMIPA-ITS*. Surabaya.
- Munarish E. 2011. Penerapan Model ARIMA-Neural Network Hybrid untuk Peramalan Time Series. *Thesis S2 Matematika FMIPA Universitas Gadjah Mada*. Yogyakarta.
- Sutijo B, Subanar & Guritno S. 2006. *Pemilihan hubungan input node pada jaringan syaraf fungsional basis Berkala* MIPA 16(1):55-61.
- Terui N & Van Dijk HK. 2002. Combined forecast from linear and nonlinear time series model. *Int J. of Forecasting* 18 (3):421-438.
- Zhang G. 2003. Time series forecasting using a hybrid ARIMA and neural network model. *JNeurocomputing* 50:159-175.
- Zheng F & Zhong S. 2011. Time series forecasting using a hybrid RBF neural network and AR model based on binomial smoothing. World Academy of Science. *Eng Technol* 75:1471-1475.