



PERAMALAN DERET WAKTU DENGAN MENGGUNAKAN *AUTOREGRESSIVE* (AR), JARINGAN SYARAF TIRUAN *RADIAL BASIS FUNCTION* (RBF) DAN HIBRID AR-RBF PADA INFLASI INDONESIA

Al Hikmah , Arief Agoestanto, Riza Arifudin

Jurusan Matematika, FMIPA, Universitas Negeri Semarang, Indonesia
Gedung D7 Lt. 1, Kampus Sekaran Gunungpati, Semarang 50229

Info Artikel

Sejarah Artikel:
Diterima Mei 2017
Disetujui Juni 2017
Dipublikasikan November 2018

Keywords:

Autoregressive (AR),
Jaringan Syaraf Tiruan,
Radial Basis Function (RBF),
Inflasi

Abstrak

Tujuan penelitian ini adalah untuk menentukan hasil ramalan inflasi enam bulan berikutnya yaitu bulan Oktober 2016, November 2016, Desember 2016, Januari 2017, Februari 2017 dan Maret 2017 menggunakan metode *Autoregressive* (AR), Jaringan Syaraf Tiruan (JST) *Radial Basis Function* (RBF) dan hibrid AR-RBF. Selain itu untuk mengetahui metode mana yang lebih akurat untuk peramalan. Metode AR dapat menganalisis masalah bagian linier data. Sedangkan, metode JST RBF dapat digunakan untuk memprediksi data nonlinier. Metode penelitian yang digunakan yaitu kajian pustaka. Data yang digunakan yaitu tingkat inflasi Indonesia berdasarkan Indeks Harga Konsumen (IHK) pada bulan Januari 2003 sampai dengan September 2016. Hasil analisis menunjukkan bahwa hasil JST RBF memiliki hasil yang lebih akurat dari pada AR dan hibrid AR-RBF. Hal ini terlihat dari nilai MAPE JST RBF paling kecil yaitu 7,12199%. Hasil peramalan dengan metode JST RBF secara berturut-turut sebesar 3,0960%; 3,3567%; 3,4304%; 3,5468%; 3,6701% dan 3,8570%.

Abstract

The purpose of this research is to forecast the inflation on October 2016, November 2016, December 2016, January 2017, February 2017 and March 2017 using Autoregressive (AR), Radial Basis Function (RBF) Neural Network (NN) and hybrid AR-RBF. Except that the purpose of this research to get accurate method. AR method can be use to analyis problem of linear time series data. On contrasting with AR, RBF-NN method can to predict nonlinear data. The research method will be use is examine of books. This method is examined by using the data Inflation of Indonesian according to Consumer Price Index (CPI) on January 2003 until September 2016. The result of analysis indicate that RBF NN model get more accurate result than AR model and hybrid AR-RBF. It is shown that value MAPE of RBF NN method is the smallest percentage with 7,12199%. The result of forecasting with RBFNN method on consistenly 3,0960%; 3,3567%; 3,4304%; 3,5468%; 3,6701% and 3,8570%.

How to Cite

Hikmah, A., Agoestanto, A., & Arifudin, R. (2018). Peramalan Deret Waktu dengan Menggunakan *Autoregressive* (AR), Jaringan Syaraf Tiruan *Radial Basis Function* (RBF) dan Hibrid AR-RBF pada Inflasi Indonesia. *UNNES Journal of Mathematics* 7(2) : 228-241.

PENDAHULUAN

Salah satu peristiwa moneter yang sangat penting dan dijumpai di semua negara di dunia adalah inflasi. Inflasi adalah kecenderungan dari harga-harga untuk menaik secara umum dan terus menerus (Prasetyo, 2009). Laju inflasi merupakan salah satu indikator sekaligus komponen penting dalam perekonomian itu sendiri. Selama perubahan inflasi itu wajar, terkendali sampai batas tertentu, maka hal ini justru berpengaruh baik. Sedangkan jika perubahan inflasi itu tinggi, tidak terkendali dan terus menerus dalam waktu relatif lama, maka akan berakibat tidak baik bagi perekonomian suatu negara (Badan Pusat Statistik, 2012).

Indikator yang sering digunakan di Indonesia (Badan Pusat Statistik dan Bank Indonesia) untuk mengukur tingkat inflasi adalah Indeks Harga Konsumen (IHK). IHK adalah indeks yang mengukur harga rata-rata dari barang tertentu yang dibeli oleh konsumen (Prasetyo, 2009). IHK di Indonesia dikelompokkan ke dalam 7 kelompok pengeluaran (berdasarkan *the Classification of Individual Consumption by Purpose*), yaitu Kelompok Bahan Makanan; Kelompok Makanan Jadi; Minuman dan Tembakau; Kelompok Perumahan; Kelompok Sandang; Kelompok Kesehatan; Kelompok Pendidikan dan Olahraga; dan Kelompok Transpostasi dan Komunikasi.

Data inflasi merupakan data keuangan runtun waktu (*financial time series*) yang merupakan cara analisis keuangan memandang dunia seputar keuangan. Data-data tersebut menyimpan suatu pengertian tentang bagaimana data bergerak sesuai dengan pergerakan sistem keuangan yang dipresentasikan olehnya. Peramalan besarnya inflasi yang akan terjadi pada masa yang akan datang dapat dilakukan berdasarkan data tersebut.

Salah satu metode peramalan yang dikembangkan saat ini ialah deret waktu, yakni menggunakan pendekatan kuantitatif dengan data masa lampau dikumpulkan dan dijadikan acuan untuk peramalan masa depan. Menurut Wiyanti dan Pulungan (2012) teknik peramalan deret waktu terbagi menjadi dua bagian. Pertama, model peramalan yang didasarkan pada model matematika statistik seperti *Auto Regressive (AR)*, *Moving Average (MA)*, *Exponential Smoothing*, Regresi, dan *Auto Regressive Integrated Moving Average (ARIMA* atau Box Jenkins). Kedua, model peramalan yang didasarkan pada kecerdasan buatan seperti *Neural Network*, Algoritma Genetika, *Simulated*

Annealing, *Genetic Progammimg*, Klasifikasi dan Hibrid.

Menurut Zheng dan Zhong (2011) Analisis *time series* dan *forecasting* adalah bidang penelitian yang aktif. 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. Model stokastik yang sangat bermanfaat dalam mempresentasikan suatu proses yang terjadi pada data runtun waktu adalah model *autoregressive (AR)*. *Autoregressive (AR)* merupakan suatu observasi pada waktu saat ini dinyatakan sebagai fungsi linier terhadap waktu sebelumnya. Model AR digunakan untuk menganalisis masalah bagian linier dan tidak dapat menangkap struktur nonlinier data.

Berbeda dengan AR, prediksi data deret waktu yang menggunakan jaringan syaraf tiruan berhasil cukup baik jika dilakukan analisa terhadap data deret waktu (Anggriningrum dkk, 2013). Salah satu algoritma pembelajaran dalam jaringan syaraf tiruan yaitu Fungsi Basis Radial atau *Radial Basis Function (RBF)*, algoritma pembelajaran ini handal dan bisa digunakan untuk penyelesaian masalah *forecasting* dan *time series modelling*. Disebut fungsi basis karena fungsi tersebut merupakan fungsi yang lengkap sehingga segala fungsi yang lain dapat diekspansikan ke dalam fungsi tersebut (Wiyanti dan Pulungan, 2012).

Satu model mungkin tidak mampu mengatasi masalah tersebut dengan baik. Dengan mengkombinasikan metode yang berbeda, struktur autokorelasi kompleks pada data dapat dimodelkan lebih akurat. Kelebihan dari menggabungkan beberapa model menjadi satu adalah menghasilkan ramalan dengan tingkat akurasi yang lebih baik secara rata-rata dibandingkan dengan model tunggal lainnya.

Menurut Zhang (2003) ada tiga hal yang menjadi alasan penggunaan pengkombinasian model linear dan *Neural Network*. 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 linear dan *neural network* masing-masing dapat memodelkan setiap kasusnya, sehingga pengkombinasian 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. Data yang akan digunakan sebagai penelitian yaitu data inflasi negara Indonesia berdasarkan nilai IHK yang bersumber dari Bank Indonesia.

Permasalahan dalam penelitian ini adalah (1) Bagaimanakah hasil ramalan nilai Inflasi Indonesia berdasarkan IHK untuk enam bulan berikutnya menggunakan metode *Autoregressive* (AR)? (2) Bagaimanakah hasil ramalan nilai Inflasi Indonesia berdasarkan IHK untuk enam bulan berikutnya menggunakan metode Jaringan Syaraf Tiruan *Radial Basis Function* (RBF)? (3) Bagaimanakah hasil ramalan nilai Inflasi Indonesia berdasarkan IHK untuk enam bulan berikutnya menggunakan metode hibrid AR-RBF? (4) Manakah diantara metode *Autoregressive* (AR), Jaringan Syaraf Tiruan *Radial Basis Function* (RBF) dan hibrid AR-RBF yang lebih akurat untuk peramalan?

Tujuan penelitian ini adalah (1) Untuk menentukan hasil ramalan inflasi Indonesia berdasarkan IHK enam bulan berikutnya menggunakan metode *Autoregressive* (AR), Jaringan Syaraf Tiruan RBF dan hibrid AR-RBF. (2) Untuk mengetahui diantara metode *Autoregressive* (AR), Jaringan Syaraf Tiruan RBF dan hibrid AR-RBF yang lebih akurat untuk peramalan.

Inflasi

Menurut Prasetyo (2009) pengertian inflasi secara umum dapat diartikan sebagai kenaikan harga-harga umum secara terus menerus selama dalam satu periode tertentu. Dengan demikian beberapa unsur dalam pengertian inflasi perlu diketahui bahwa: (1) Inflasi merupakan proses kecenderungan kenaikan harga-harga umum barang-barang dan jasa secara terus menerus. (2) Kenaikan harga ini tidak berarti harus naik dengan persentase yang sama, yang penting terdapat kenaikan harga-harga umum barang secara terus menerus selama periode tertentu (satu bulan atau satu tahun). (3) Jika kenaikan harga yang terjadi hanya sekali saja dan bersifat sementara atau secara temporer (sekalipun dalam persentase yang besar) tetapi, tidak berdampak meluas bukanlah merupakan inflasi. Indikator yang sering digunakan di Indonesia (Badan Pusat Statistik dan Bank Indonesia) untuk mengukur tingkat inflasi adalah Indeks Harga Konsumen (IHK). IHK adalah indeks yang mengukur harga rata-rata dari barang tertentu yang dibeli oleh konsumen (Prasetyo, 2009). IHK di Indonesia dikelompokkan ke dalam 7 kelompok

pengeluaran (berdasarkan *the Classification of Individual Consumption by Purpose*), yaitu Kelompok Bahan Makanan; Kelompok Makanan Jadi; Minuman dan Tembakau; Kelompok Perumahan; Kelompok Sandang; Kelompok Kesehatan; Kelompok Pendidikan dan Olahraga; dan Kelompok Transpostasi dan Komunikasi. Cara perhitungan inflasi berdasarkan IHK terbagi 2 yaitu inflasi bulanan (mtm) dan inflasi tahunan (yoy) (Badan Pusat Statistik, 2012). Inflasi bulanan (mtm) dihitung dari perubahan indeks bulan tertentu dan indeks bulan sebelumnya pada tahun yang sama yaitu

$$LI_t = \frac{IHK_t - IHK_{t-1}}{IHK_{t-1}} \times 100\%$$

Keterangan:

LI_t = Laju inflasi periode t

IHK_t = Indeks harga konsumen periode t

IHK_{t-1} = Indeks harga konsumen t-1

Autoregressive (AR)

Model autoregresi menunjukkan Y_t sebagai fungsi linear dari sejumlah Y_t aktual sebelumnya. Model autoregresif dengan ordo p [AR(p)] atau model ARIMA (p,0,0) dinyatakan sebagai berikut:

$$Y_t = b_0 + b_1 Y_{t-1} + b_2 Y_{t-2} + \dots + b_n Y_{t-n} + e_t$$

Keterangan:

Y_t = variabel dependen

$Y_{t-1}, Y_{t-2}, \dots, Y_{t-n}$ = variabel bebas

$b_0, b_1, b_2, \dots, b_n$ = koefisien regresi

e_t = residual

Ada beberapa klasifikasi model AR. Pertama, model random (*white noise series*) yaitu suatu data runtun waktu mengandung rata – rata hitung (μ) dan unsur kesalahan random (e_t) yang bebas dari masalah autokorelasi atau memiliki autokorelasi sama dengan nol artinya nilai data pada periode sebelumnya tidak berkorelasi dengan nilai data sebelumnya (Jarret dalam Kuncoro, 2007). Sehingga dirumuskan menjadi :

$$Y_t = \beta_0 + e_t$$

Model di atas disebut ARIMA (0,0,0) karena tidak ada porsi AR (Y_t tidak tergantung dari Y_{t-1}), tidak ada diferensi dan tidak ada unsur MA (Y_t tidak tergantung pada e_t). Kedua, model *autoregressive* tingkat p, artinya model mengandung autokorelasi antara Y_t dan Y_{t-p} , sehingga untuk model AR(1) atau AR tingkat satu dirumuskan sebagai berikut :

$$Y_t = \beta_0 + Y_{t-1} + e_t$$

Metodologi Box-Jenkins

Dalam membangun model AR digunakan model ARIMA(p,d,q) dengan q = 0

sehingga model yang digunakan untuk AR adalah model ARIMA($p, d, 0$). Metodologi Box-Jenkins berguna untuk mendapatkan nilai p maupun d . Metode ini terdiri atas empat langkah sebagai berikut (Gujarati, 2012):

1. Identifikasi Model

Hasil dari grafik ACF dan PACF pada data yang sudah stasioner digunakan sebagai petunjuk untuk menentukan model awal sementara.

2. Estimasi Model

Tahap selanjutnya yaitu estimasi model. Model yang sudah dipilih akan diterima apabila koefisien hasil estimasi signifikan. Sebaliknya, apabila koefisien estimasi tidak signifikan maka model tersebut ditolak.

3. Diagnostic Checking

Pada tahap ini dilakukan verifikasi kesesuaian model dengan sifat-sifat data serta dilakukan pemilihan model terbaik dengan uji uji Q-Ljung-Box. Uji Q-Ljung-Box digunakan untuk mengetahui apakah residual memenuhi asumsi *white noise* (residual tidak berkorelasi).

4. Peramalan

Untuk menentukan model terbaik dapat digunakan perhitungan model residual yang sesuai berdasarkan kesalahan peramalan dengan menggunakan *Akaike's Information Criterion* (AIC). Model ARIMA yang memiliki nilai AIC terkecil merupakan model yang lebih baik. Setelah model terbaik diperoleh berdasarkan langkah-langkah sebelumnya, model tersebut digunakan untuk meramalkan data di masa yang akan datang.

Jaringan Syaraf Tiruan Radial Basis Function (RBF)

Model jaringan syaraf tiruan RBF merupakan salah satu bentuk *multilayer perceptron* yang memperbaiki nilai-nilai bobot, nilai tengah, dan jarak antar data agar mengurangi kesalahan yang terjadi pada keluaran jaringan. Menurut Wiyanti dan Pulungan (2012) disebut fungsi basis karena fungsi tersebut merupakan fungsi yang lengkap sehingga segala fungsi yang lain dapat diekspansikan ke dalam fungsi tersebut. Pada model ini, jaringan syaraf tiruan menggunakan fungsi aktivasi basis (*Gaussian*) pada lapisan tersembunyi.

Model RBF terdiri dari 3 lapisan, yaitu lapisan input (*input layer*), lapisan tersembunyi (*hidden layer*) dan lapisan output (*output layer*).

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

Dimana $\{\phi(\|x - x_i\|) | i = 1, 2, 3, \dots, N\}$ adalah himpunan fungsi nonlinear yang disebut fungsi

radial basis (*Radial Basis Function* = RBF) dan $\|\cdot\|$ adalah norm jarak *Euclid*.

Hibrid AR-RBF

Menurut Zheng dan Zhong (2011) dengan mengkombinasikan model jaringan syaraf tiruan dan model ARIMA struktur autokorelasi pada data dapat dimodelkan lebih akurat. Karena kemungkinan ketidakstabilan atau perubahan pola pada data, menggunakan metode hibrid dapat mengurangi ketidakpastian model yang mana terjadi pada statistik inferensial dan peramalan runtun waktu.

Secara umum, kombinasi dari model time series yang memiliki struktur autokorelasi linear dan nonlinear dapat dituliskan sebagai berikut:

$$Y_t = N_t + L_t$$

dimana N_t merupakan komponen nonlinear dan L_t adalah komponen linear.

Matlab (Matrix Laboratory)

Menurut Arhami dan Desiani (2005) Matlab (*Matrix Laboratory*) adalah sebuah program untuk analisis dan komputasi numerik, merupakan suatu bahasa pemrograman matematika lanjutan yang dibentuk dengan dasar pemikiran menggunakan sifat dan bentuk matriks. Matlab yang merupakan bahasa pemrograman tingkat tinggi berbasis pada matriks yang sering digunakan untuk teknik komputasi numerik, digunakan untuk menyelesaikan masalah-masalah yang melibatkan operasi matematika elemen, matriks, optimasi, aproksimasi, dan lain-lain.

METODE PENELITIAN

Tahap pertama adalah perumusan masalah yang dimaksudkan untuk memperjelas permasalahan. Masalah yang diangkat adalah meramalkan inflasi Indonesia berdasarkan IHK untuk enam bulan selanjutnya dan mendapatkan metode yang mempunyai error minimum atau MAPE terkecil diantara metode *Autoregressive* (AR), Jaringan Saraf Tiruan *Radial Basis Function* (RBF) dan hibrid AR-RBF.

Studi pustaka dilakukan dengan mengumpulkan sumber pustaka yang dapat berupa jurnal, buku, bahan ajar dan sebagainya. Setelah sumber pustaka terkumpul dilanjutkan dengan penelaahan dari sumber pustaka tersebut. Pada akhirnya sumber pustaka itu dijadikan landasan untuk menganalisis permasalahan. Pada pengumpulan data, data diunduh dari <http://www.bi.go.id> yang merupakan data sekunder inflasi Indonesia berdasarkan IHK pada bulan Januari 2003 sampai dengan September 2016 sebanyak 165 data.

Pada pemecahan masalah, meliputi peramalan dengan metode *Autoregressive* (AR) dengan langkah-langkah yang dilakukan yaitu uji stasioneritas, identifikasi model AR, estimasi model, *diagnostic checking* dan peramalan berdasarkan model terbaik. Peramalan selanjutnya dengan metode JST RBF dengan langkah-langkah yaitu identifikasi model, pembagian data, normalisasi, proses pelatihan (*training*), proses pengujian (*testing*) dan peramalan. Setelah itu peramalan dengan metode hibrid AR-RBF dengan cara melakukan pemodelan dan peramalan dengan model AR terbaik, residual dari model AR terbaik selanjutnya sebagai input untuk peramalan dengan metode JST RBF dan hasil peramalan diperoleh dengan menggabungkan hasil peramalan menggunakan metode AR dan hasil peramalan residual menggunakan JST RBF.

Perancangan sitem dilakukan dengan pembuatan program peramalan dengan masing-masing metode menggunakan software Matlab R2014a yang di desain dengan menggunakan *Graphic User Interface* (GUI). Penarikan kesimpulan didasarkan pada pemecahan masalah, studi pustaka, analisis dan pembahasan permasalahan. Simpulan yang diperoleh merupakan hasil analisis dari penelitian. Selanjutnya membandingkan keakuratan ketiga metode dengan melihat nilai MAPE terkecil pada masing-masing metode.

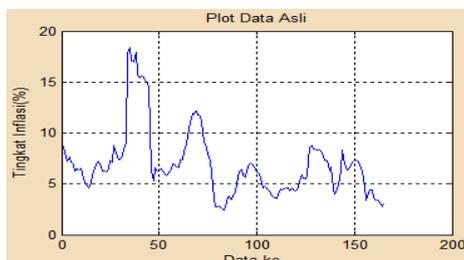
HASIL PENELITIAN DAN PEMBAHASAN

HASIL PENELITIAN

1. Peramalan Menggunakan Metode Autoregressive (AR)

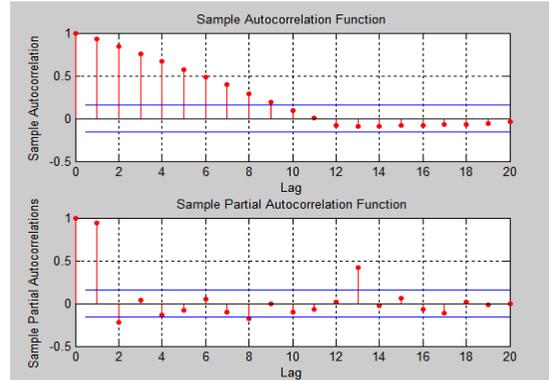
a. Uji Stasioneritas

Pada tahap uji stasioneritas langkah yang dilakukan yaitu memplotkan data asli untuk melihat perkembangan data dari waktu ke waktu, hasilnya terlihat pada Gambar 1.



Gambar 1. Plot Data Asli

Dari Gambar 1, terlihat bahwa data cenderung tidak mendatar sehingga data dikatakan tidak stasioner. Hal ini diperkuat dengan hasil plot grafik ACF dan PACF pada Gambar 2.



Gambar 2 Grafik ACF dan PACF Data Asli

Berdasarkan hasil grafik ACF yang terdapat pada Gambar 2, dimana pada lag pertama sampai dengan lag 9 berada pada luar garis Barlett yang ditunjukkan pada garis warna biru yang ada diatas maupun dibawah garis tengah (garis 0) dan menurun secara eksponensial secara perlahan menuju nol sehingga data nonstasioner. Sedangkan grafik PACF terputus seketika (*cut off*) menuju nol setelah lag p.

Untuk menguji kestasioneran data dapat menggunakan Uji Akar Unit (*Unit Root Test*) dengan jenis uji ADF (*Augmented Dickey Fuller*) yaitu dengan melihat nilai *Augmented Dickey – Fuller* (ADF). Jika nilai pada ADF lebih kecil daripada *t – statistic* pada nilai kritis berarti data tidak stasioner dan jika nilai ADF lebih besar dari *t – statistic* pada nilai kritis berarti data dikatakan stasioner (Kuncoro, 2007).

Hipotesis :

$H_0 : \phi = 1$ (Terdapat akar unit atau data tidak stasioner)

$H_1 : -1 < \phi < 1$ (Tidak terdapat akar unit atau data stasioner)

Statistik uji :

$$t = \frac{\hat{\phi}}{se(\hat{\phi})}$$

Taraf signifikan : $\alpha = 5\%$

Kriteria pengujian :

Jika nilai *t – statistik* > nilai kritis 5% maka H_0 ditolak atau H_1 diterima

Jika nilai *t – statistik* < nilai kritis 5% maka H_1 ditolak atau H_0 diterima

Hasil Pengujian diperoleh bahwa nilai *t-Stat* = -1,2648 lebih kecil dibandingkan nilai kritis 5% yaitu sebesar -1,9424 atau nilai *t-Stat* < *c-Value* (nilai minus tidak diperhatikan tetapi yang digunakan adalah nilai mutlak dari nilai kritis) berarti H_0 diterima atau H_1 ditolak. Hal ini menunjukkan bahwa data inflasi terdapat akar unit atau data inflasi tidak stasioner.

Karena data tidak stasioner, maka dilakukan *differencing* pertama $d = 1$. Berikut adalah hasil pengujiannya dengan Uji Akar Unit (*Unit Root Test*) dengan jenis uji ADF.

Hipotesis :

H_0 : Terdapat akar unit atau data tidak stasioner

H_1 : Tidak terdapat akar unit atau data stasioner

Kriteria pengujian :

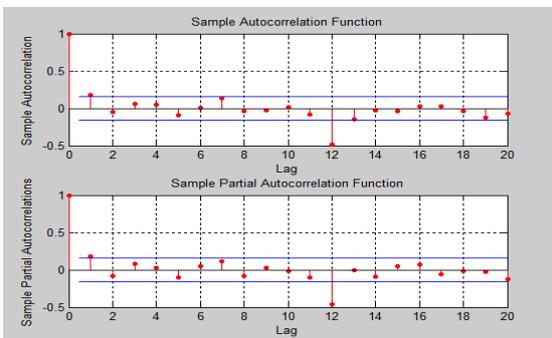
Jika nilai t – statistik $>$ nilai kritis 5% maka H_0 ditolak atau H_1 diterima

Jika nilai t – statistik $<$ nilai kritis 5% maka H_1 ditolak atau H_0 diterima

Hasil Pengujian didapat bahwa nilai t -Stat = -10.6116 lebih besar dibandingkan nilai kritis 5% yaitu sebesar -1,9424 atau nilai t -Stat $>$ c -Value (nilai minus tidak diperhatikan tetapi yang digunakan adalah nilai mutlak dari nilai kritis) berarti H_0 ditolak atau H_1 diterima. Hal ini menunjukkan bahwa data inflasi tidak terdapat akar unit atau data stasioner.

b. Identifikasi Model AR

Identifikasi model AR dilakukan dengan pendugaan sementara melihat pola ACF dan PACF. Hasil plot ACF dan PACF dari data Inflasi Indonesia hasil diferensiasi pertama ditunjukkan pada Gambar 3.



Gambar 3 Grafik ACF dan PACF Data Diferensiasi

Terlihat pada Gambar 3, bahwa pada plot ACF dan PACF lag 1 dan lag 12 diluar garis Barlet dan menuju nol dengan terputus seketika (*cut off*). Hal ini menunjukkan bahwa data mempunyai pola AR. Oleh sebab pada grafik PACF, lag yang berada diluar garis adalah lag 1 dan 12 maka model awal yang diperoleh yaitu AR(1) dan AR(12) atau ARIMA (1,1,0) dan ARIMA (12,1,0).

c. Estimasi Model

Setelah diperoleh dugaan model awal yang sesuai dengan data runtun waktu yang akan diramalkan, langkah selanjutnya melakukan

estimasi dari model AR(1) atau ARIMA (12,1,0). Jika parameter-parameter dari model tersebut signifikan maka model tersebut dapat diterima. Sebaliknya, jika parameter-parameter dari model tersebut tidak signifikan maka model tersebut ditolak.

Hipotesis :

H_0 = Parameter sama dengan nol atau tidak signifikan

H_1 = Parameter tidak sama dengan nol atau signifikan

Statistik Uji

$$T_{hitung} = \frac{\text{Hasil estimasi parameter}}{\text{SE estimasi parameter}}$$

Tingkat signifikansi (α) : 5% = 0,05

Kriteria pengujian :

Jika $T_{hitung} < T_{(\frac{\alpha}{2}, n-k)}$ atau $p\text{Value} > \alpha$ maka H_1

H_0 diterima dan jika $T_{hitung} > T_{(\frac{\alpha}{2}, n-k)}$ atau

$p\text{Value} < \alpha$ maka H_0 ditolak

Berdasarkan tabel t diperoleh nilai $T_{(\frac{\alpha}{2}, n-k)} = T_{(0,025, 163)} = 1.97462$. Hasil estimasi model awal ditunjukkan pada Tabel 1.

Tabel 1 Estimasi Model

Model	Parameter	t Stat	Keterangan
ARIMA (1,1,0)	Constant	0.0682	Tidak signifikan
	AR(1)	-14.390	Signifikan
ARIMA (12,1,0)	Constant	0,058	Tidak signifikan
	AR(1)	-10.4665	Signifikan
	AR(2)	-8.2123	Signifikan
	AR(3)	-3.7346	Signifikan
	AR(4)	-2.9798	Signifikan
	AR(5)	-2.4561	Signifikan
	AR(6)	-1.538	Tidak signifikan
	AR(7)	-0.4821	Tidak signifikan
	AR (8)	-0.4115	Tidak signifikan
	AR(9)	0.3785	Tidak signifikan
	AR(10)	0.7160	Tidak signifikan
	AR(11)	1.9489	Tidak signifikan
AR(12)	-2,0449	Signifikan	

Karena parameter AR dari ARIMA(1,1,0) signifikan dan AR(12,1,0) ada yang tidak signifikan maka model ARIMA(1,1,0) dapat diterima sebagai kemungkinan model awal. Namun, sebagai bahan pertimbangan model ARIMA(12,1,0) dapat dimasukkan. Sehingga akan didapatkan model yang lebih baik lagi.

d. Diagnostic Checking

Setelah mendapatkan model awal yaitu ARIMA (1,1,0) dan ARIMA (12,1,0) langkah selanjutnya adalah dilakukan *diagnostic checking* dengan uji Q-Ljung-Box. Uji Q-Ljung-Box digunakan untuk mengetahui apakah residual

memenuhi asumsi *white noise* (residual tidak berkorelasi). Hasil uji Q-Ljung Box disajikan pada Tabel 2.

Hipotesis :

H_0 : Parameter sama dengan nol atau tidak signifikan (Residual tidak berkorelasi)

H_1 : Parameter tidak sama dengan nol atau signifikan (Residual berkorelasi)

Taraf signifikansi (α) : 5% = 0,05

Kriteria pengujian :

Jika $p\text{ value} < \alpha$ maka H_0 ditolak dan jika $p\text{ value} > \alpha$ maka H_0 diterima

Hasil pengujian :

Tabel 2 Hasil Uji Q-Ljung Box

Model	h	p value
ARIMA(1,1,0)	1	3,9743e-11
ARIMA(12,1,0)	0	0,5572

Berdasarkan Tabel 2, terlihat bahwa nilai p value dari model ARIMA(1,1,0) yaitu 3,9743e-11 < 0,05 maka H_0 ditolak atau H_1 diterima artinya residualnya berkorelasi. Sedangkan untuk model ARIMA(12,1,0) nilai p value > α atau 0,5572 > 0,05, maka H_1 ditolak atau H_0 diterima artinya residualnya tidak saling berkorelasi. Dari hasil analisis tersebut, dapat disimpulkan bahwa model ARIMA(12,1,0) merupakan model yang sesuai untuk menggambarkan data inflasi.

e. Peramalan Berdasarkan Model Terbaik

Untuk menentukan model terbaik dapat digunakan perhitungan model residual yang sesuai berdasarkan kesalahan peramalan. Salah satu kriteria pemilihan model terbaik berdasarkan residual yang akan digunakan yaitu *Akaike's Information Criterion* (AIC). Model ARIMA yang memiliki nilai AIC terkecil merupakan model yang lebih baik.

Model yang sudah terpilih untuk peramalan inflasi adalah model ARIMA(12,1,0), tetapi perlu diuji coba model yang lainnya. Sehingga dapat dibandingkan model yang lebih baik lagi dibandingkan model ARIMA(12,1,0) dan mampu meramalkan nilai inflasi lebih akurat. Berikut ini hasil AIC dari beberapa model ARIMA yang ditunjukkan pada Tabel 3.

Tabel 3 Nilai AIC Model ARIMA

Model	AIC
ARIMA(1,1,0)	581,5559
ARIMA(12,1,0)	521,5795

Pada Tabel 3, menunjukkan bahwa model ARIMA yang memiliki nilai AIC terkecil yaitu

model ARIMA(12,1,0) sebesar 521,5795. Dengan begitu model yang diperoleh sesuai dengan kemungkinan model awal. Selanjutnya akan dilakukan peramalan dengan model terbaik yaitu model ARIMA(12,1,0). Hasil peramalan nilai inflasi untuk enam bulan kedepan beserta nilai MAPE ditunjukkan pada Tabel 4.

Tabel 4 Hasil Peramalan dan Nilai MAPE Model ARIMA(12,1,0)

Bulan	Data Asli (%)	Hasil Ramalan (%)	MAPE (%)
Oktober 2016	3,31	3,0762	10,36
November 2016	3,58	3,0848	
Desember 2016	3,02	3,0942	
Januari 2017	3,61	3,1048	
Februari 2017	3,83	3,1168	
Maret 2017	3,49	3,1299	

Hasil selengkapnya dari peramalan model ARIMA (12,1,0) pada tampilan GUI terlihat pada Gambar 4.

2. Peramalan Menggunakan Metode Jaringan Syaraf Tiruan Radial Basis Function (RBF)

a. Identifikasi Model

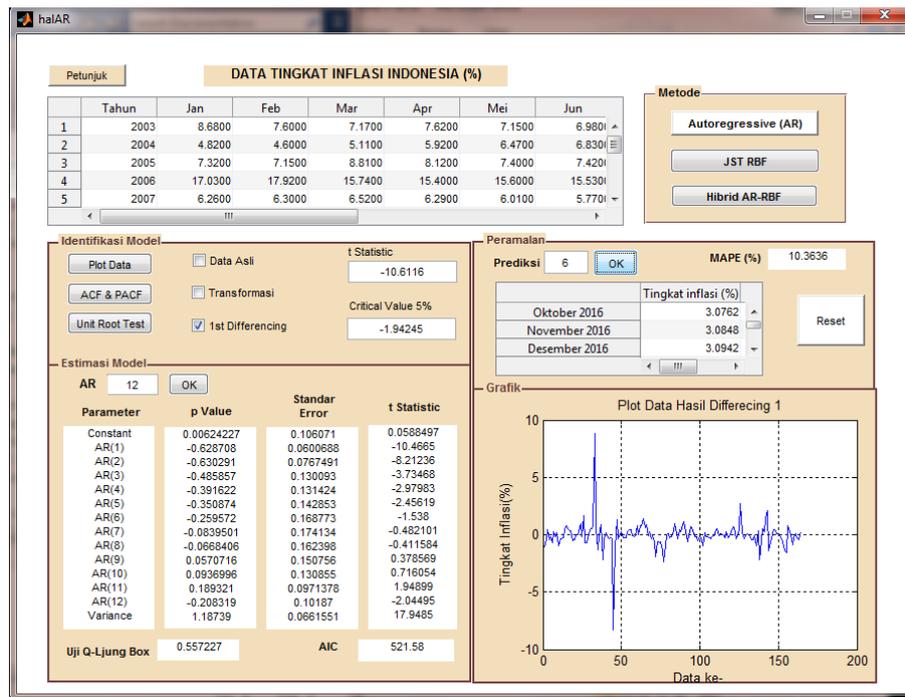
Pada pemodelan RBF input data adalah data masa lalu (lag time) dan target/output adalah data masa kini, sebagaimana terminologi AR pada metode ARIMA. Identifikasi lag sebagai komponen input didasarkan pada lag-lag yang memiliki nilai PACF signifikan (Fauzannisa dkk, 2015). Grafik PACF data tingkat inflasi Indonesia terlihat pada Gambar 2. Diperoleh 4 variabel input yaitu lag 1, lag 2, lag 8 dan lag 13 atau dapat dikatakan bahwa x dipengaruhi oleh x_{t-13} , x_{t-8} , x_{t-2} dan x_{t-1} .

b. Pembagian Data

Data inflasi dibagi menjadi dua bagian yaitu data pelatihan dan data pengujian. Pada skripsi ini digunakan komposisi 50% untuk data pelatihan dan 50% untuk data pengujian. Dari data inflasi yang ada sebanyak 165 data. Sehingga diperoleh 83 untuk data pelatihan dan sisanya yaitu 82 untuk data pengujian.

Data inflasi perlu dilakukan normalisasi data sedemikian sehingga data akan berada pada [0,1] untuk mempermudah perhitungan. Rumus normalisasi yang digunakan adalah:

$$\text{data normalisasi} = \frac{\text{nilai } x - \text{nilai } x \text{ minimum}}{\text{nilai } x \text{ maksimum} - \text{nilai } x \text{ minimum}} \quad (1)$$



Gambar 4 Tampilan GUI Hasil Peramalan Metode ARIMA (12,1,0)

c. Pembentukan Arsitektur JST RBF

Pada Matlab fungsi untuk membentuk jaringan syaraf tiruan RBF adalah newrbe dan newrb.

Fungsi: **net = newrbe(P,T,spread)**

net= newrb(P,T,goal,spread,MN,DF)

Jaringan yang terbentuk akan terdiri dari beberapa neuron dengan fungsi aktivasi RBF yaitu fungsi Gaussian (Kusumadewi, 2004). Pada penelitian ini fungsi yang akan digunakan yaitu fungsi newrb dengan spread 1 dan 2 serta maksimum epoch sebanyak 100 iterasi.

d. Proses Pelatihan

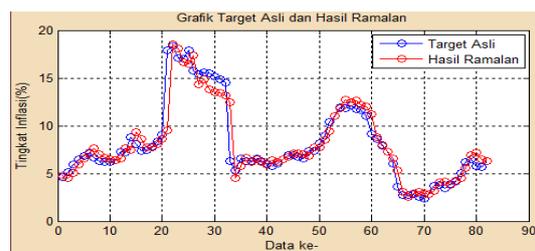
Pada saat pendeklarasian jaringan, program akan otomatis menginialisasi bobot-bobot dan bias input maupun lapisan tersembunyi dengan nilai random. Nilai spread atau penyebaran yang akan dilatihkan yaitu 1 dan 2. Jumlah neuron maksimum dilakukan secara bertahap dimulai dari yang terkecil hingga terbesar. Untuk mencari komposisi parameter terbaik, dilakukan beberapa variasi parameter seperti spread dan neuron.

Hasil output ternormalisasi dikembalikan atau denormalisasi untuk mendapatkan nilai output pada range yang sebenarnya. Sehingga akan diperoleh error yaitu nilai MAPE dari arsitektur jaringan tersebut. Hasil variasi parameter beserta nilai MAPE ditunjukkan pada Tabel 5.

Tabel 5. Hasil Variasi Parameter Proses Pelatihan Metode JST RBF

Spread	Neuron	MAPE (%)	Spread	Neuron	MAPE (%)
1	1	17.54	2	1	19.19
1	2	16.17	2	2	14.32
1	3	16.48	2	3	12.85
1	4	15.25	2	4	11.56
1	5	11.85	2	5	10.32
1	6	11.68	2	6	9.36
1	7	9.62	2	7	9.38
1	8	9.55	2	8	9.47
1	9	9.29	2	9	9.25
1	10	9.36	2	10	9.31

Berdasarkan Tabel 5, diatas bahwa jaringan terbaik yang memiliki nilai MAPE terkecil yaitu jaringan syaraf RBF dengan spread 2, neuron 9 dengan nilai MAPE sebesar 9.2547%. Grafik perbandingan hasil ramalan dengan data asli terlihat pada Gambar 5.



Gambar 5 Grafik Perbandingan Hasil Ramalan Data Pelatihan Metode JST RBF

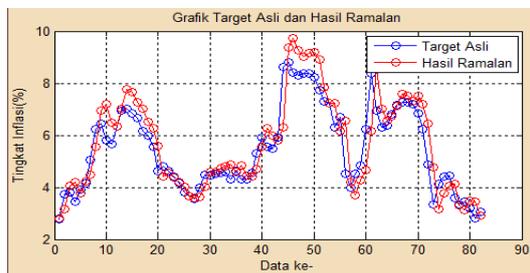
e. Proses Pengujian

Jaringan yang sudah dilatih pada tahap pelatihan, diujikan menggunakan data pengujian. Hasil variasi parameter beserta nilai MAPE ditunjukkan pada Tabel 6.

Tabel 6. Hasil Variasi Parameter Proses Pengujian Metode JST RBF

Spread	Neuron	MAPE (%)	Spread	Neuron	MAPE (%)
1	1	19.35	2	1	22.03
1	2	16.79	2	2	18.65
1	3	19.21	2	3	15.29
1	4	15.75	2	4	11.25
1	5	12.83	2	5	12.81
1	6	11.81	2	6	10.72
1	7	11.78	2	7	10.42
1	8	10.65	2	8	10.46
1	9	10.73	2	9	11.61
1	10	11.15	2	10	11.67

Berdasarkan hasil variasi jumlah neuron pada masing-masing spread diperoleh jaringan yang memiliki nilai MAPE terkecil yaitu jaringan dengan spread 2, neuron pada lapisan tersembunyi 7 neuron. Grafik perbandingan hasil ramalan terlihat pada Gambar 6.



Gambar 6 Grafik Perbandingan Hasil Ramalan Data Pengujian Metode JST RBF

Pada data pengujian, hasil output jaringan hampir mendekati data aslinya. Sehingga jaringan tersebut merupakan jaringan optimal yang dapat digunakan untuk meramalkan data tingkat inflasi Indonesia dengan arsitektur jaringan input 4, neuron 7 dan output 1, maka model RBF yang terbentuk adalah

$$X_t = \sum_{j=1}^7 w_j \phi_j(x)$$

f. Peramalan

Peramalan data tingkat inflasi Indonesia dilakukan dengan menggunakan arsitektur jaringan terbaik yaitu 4 input, 7 neuron pada lapisan tersembunyi dan 1 output. Hasil peramalan tingkat Inflasi Indonesia pada bulan Oktober 2016, November 2016, Desember 2016, Januari 2017, Februari 2017 dan Maret 2017

ditampilkan pada Tabel 7 dan hasil peramalan dalam GUI ditampilkan pada Gambar 7.

Tabel 7 Hasil Peramalan dan Nilai MAPE JST RBF (4-7-1)

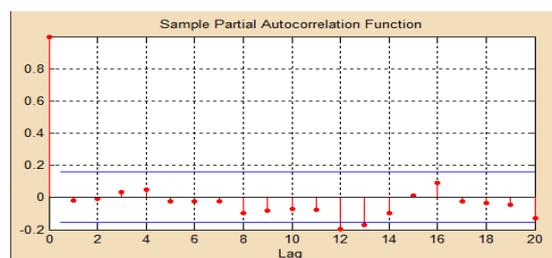
Bulan	Data Asli (%)	Hasil Ramalan (%)	MAPE (%)
Oktober 2016	3,31	3,0960	
November 2016	3,58	3,3567	
Desember 2016	3,02	3,4304	7,12
Januari 2017	3,61	3,5468	
Februari 2017	3,83	3,6701	
Maret 2017	3,49	3,8570	

3. Peramalan Menggunakan Metode Hibrid AR-RBF

Metode hibrid AR-RBF merupakan metode penggabungan antara metode AR dengan metode jaringan syaraf RBF. Data diproses dengan menggunakan metode AR terlebih dahulu untuk mendapatkan residual dari model AR terbaik. Hal ini dikarenakan data yang digunakan untuk metode hibrid AR-RBF adalah data residual dari model ARIMA (Zhang, 2003). Selanjutnya metode hibrid AR-RBF melalui tahapan pelatihan dan pengujian seperti pada proses JST RBF.

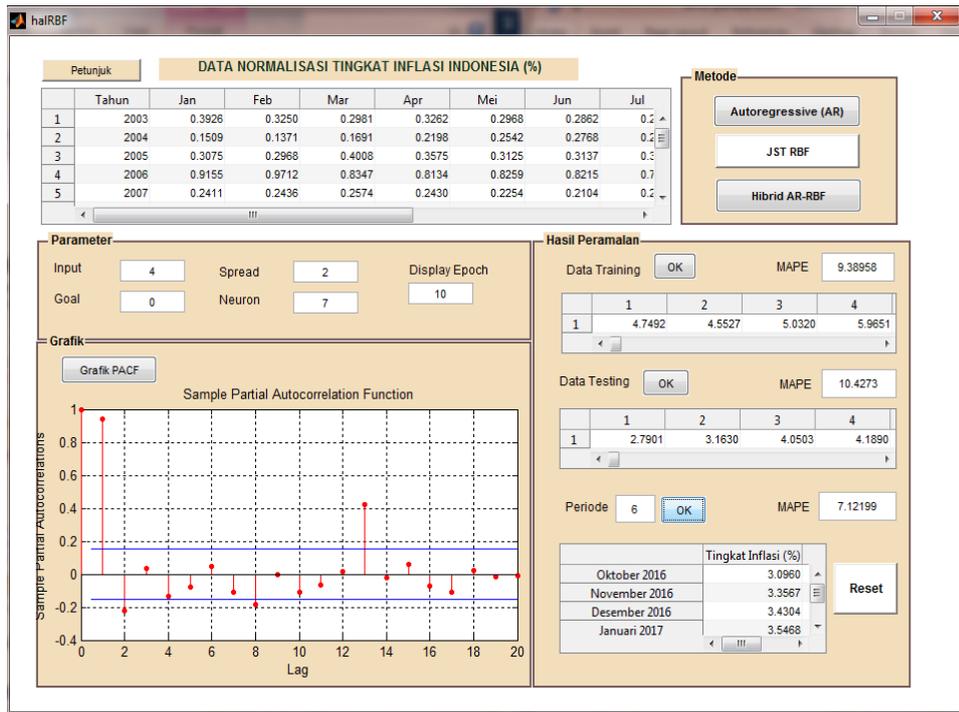
a. Identifikasi Model

Identifikasi lag sebagai komponen input didasarkan pada lag-lag yang memiliki nilai PACF signifikan. Grafik PACF data residual ARIMA(12,1,0) terlihat pada Gambar 8.



Gambar 8 Grafik PACF Data Residual ARIMA(12,1,0)

Berdasarkan plot PACF pada Gambar 8, diperoleh 2 variabel lag yang signifikan yang yaitu lag 12 dan lag 13 atau dapat dikatakan bahwa x_t dipengaruhi oleh x_{t-12} dan x_{t-13} . Selanjutnya data residual ARIMA(12,1,0) perlu dilakukan normalisasi pada range [0,1] menggunakan rumus (1).



Gambar 7 Tampilan GUI Hasil Peramalan Metode JST RBF

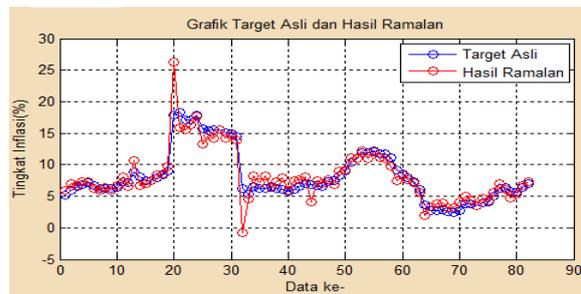
b. Proses Pelatihan

Pada metode AR data telah mengalami differencing pertama maka data berkurang 1. Sehingga data yang digunakan yaitu sebanyak 50% dari 164 diperoleh 82 data. Nilai bobot dan bias akan diperbaiki selama proses pelatihan. Kemudian hasil output didenormalisasi dan dijumlahkan dengan data hasil peramalan ARIMA(12,1,0) sebanyak 50% data. Hasil inilah yang merupakan hasil peramalan metode hibrid AR-RBF pada proses pelatihan. Hasil variasi parameter beserta nilai MAPE ditunjukkan pada Tabel 8.

Tabel 8. Hasil Variasi Parameter Proses Pelatihan Metode Hibrid AR-RBF

Spread	Neuron	MAPE (%)	Spread	Neuron	MAPE (%)
1	1	14.30	2	1	13.65
1	2	14.44	2	2	13.71
1	3	13.87	2	3	13.85
1	4	15.07	2	4	15.07
1	5	14.97	2	5	15.01
1	6	15.76	2	6	16.34
1	7	16.93	2	7	16.85
1	8	16.95	2	8	16.99
1	9	17.24	2	9	17.30
1	10	17.33	2	10	17.29

Berdasarkan hasil variasi parameter diperoleh jaringan yang memiliki nilai MAPE terkecil yaitu jaringan dengan spread 2, jumlah neuron pada lapisan tersembunyi sebanyak 7 neuron. Grafik perbandingan hasil ramalan dengan 7 neuron terlihat pada Gambar 9.



Gambar 9. Grafik Perbandingan Hasil Ramalan Proses Pelatihan Metode Hibrid AR-RBF

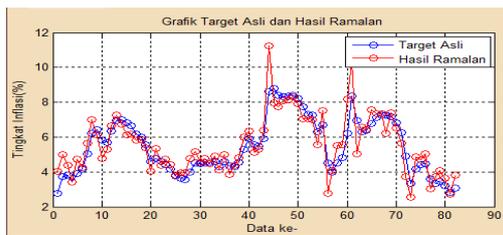
c. Proses Pengujian

Jaringan yang sudah dilatih pada tahap pelatihan, diujikan menggunakan data pengujian. Kemudian hasil output didenormalisasi dan dijumlahkan dengan data hasil peramalan ARIMA(12,1,0) sebanyak 50% data. Hasil variasi parameter beserta nilai MAPE ditunjukkan pada Tabel 7.

Tabel 7. Hasil Variasi Parameter Proses Pelatihan Metode Hibrid AR-RBF

Spread	Neuron	MAPE (%)	Spread	Neuron	MAPE (%)
1	1	14.30	2	1	13.65
1	2	14.44	2	2	13.71
1	3	13.87	2	3	13.85
1	4	15.07	2	4	15.07
1	5	14.97	2	5	15.01
1	6	15.76	2	6	16.34
1	7	16.93	2	7	16.85
1	8	16.95	2	8	16.99
1	9	17.24	2	9	17.30
1	10	17.33	2	10	17.29

Berdasarkan hasil variasi jumlah neuron pada masing-masing spread diperoleh jaringan yang memiliki nilai MAPE terkecil yaitu jaringan dengan spread 2, jumlah neuron 1. Untuk melihat grafik perbandingan hasil ramalan dengan 1 neuron terlihat pada Gambar 10.



Gambar 10, Grafik Perbandingan Hasil Ramalan Data Pengujian Metode Hibrid AR-RBF

Pada data pengujian, hasil output jaringan hampir mendekati data aslinya. Sehingga jaringan tersebut merupakan jaringan optimal yang dapat digunakan untuk meramalkan data tingkat inflasi Indonesia dengan arsitektur jaringan input 2, neuron 1 dan output 1 maka model RBF yang terbentuk adalah

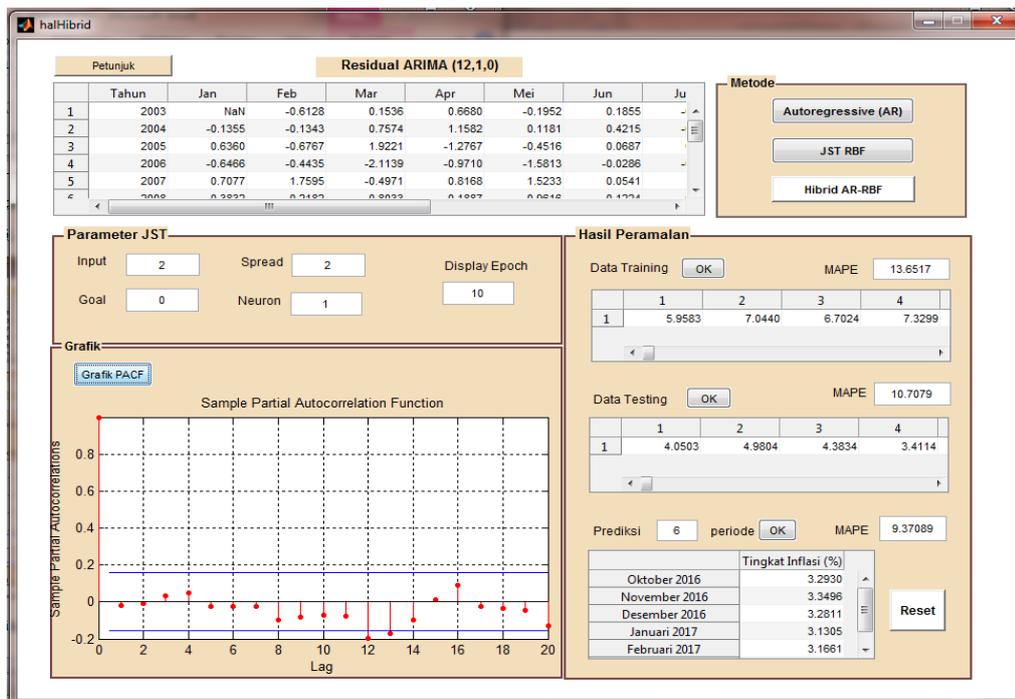
$$x_t = w_1 \phi_1(x)$$

d. Peramalan

Peramalan data tingkat inflasi Indonesia dilakukan dengan menggunakan arsitektur jaringan terbaik yaitu 2 input, 1 neuron tersembunyi dan 1 output dengan data input x_{t-13} dan x_{t-12} . Berdasarkan model hibrid AR-RBF yang terbentuk maka hasil peramalan tingkat Inflasi Indonesia pada bulan Oktober 2016, November 2016, Desember 2016, Januari 2017, Februari 2017 dan Maret 2017 ditampilkan pada Tabel 8 dan hasil tampilan GUI pada Gambar 11.

Tabel 8 Hasil Peramalan dan Nilai MAPE Hirbid AR-RBF (2-1-1)

Bulan	Data Asli (%)	Hasil Ramalan (%)	MAPE (%)
Oktober 2016	3,31	3,2930	9,37
November 2016	3,58	3,3496	
Desember 2016	3,02	3,2811	
Januari 2017	3,61	3,1305	
Februari 2017	3,83	3,1661	
Maret 2017	3,49	3,1405	



Gambar 11 Tampilan GUI Hasil Peramalan Metode Hibrid AR-RBF

PEMBAHASAN

Berdasarkan hasil analisis pada metode ARIMA, diperoleh bahwa model terbaik adalah ARIMA(12,1,0). Hasil peramalan untuk enam bulan berikutnya yaitu bulan Oktober 2016, November 2016, Desember 2016, Januari 2017, Februari 2017 dan Maret 2017 secara berturut-turut adalah 3,0762%; 3,0848%; 3,0942%; 3,1048%; 3,1168%; dan 3,1299%. Perbandingan hasil peramalan dengan data aslinya menggunakan nilai MAPE diperoleh sebesar 10,3636%. Pada peramalan menggunakan metode Jaringan Syaraf Tiruan (JST) RBF data dibagi menjadi 2 bagian yaitu 50% dari data untuk proses pelatihan dan 50% sisanya digunakan untuk proses pengujian. Dengan melihat plot PACF dari data asli diperoleh input sebanyak 4, jumlah neuron pada lapisan tersembunyi 7 neuron dengan nilai output 1. Dengan arsitektur jaringan tersebut diperoleh nilai MAPE pada proses pelatihan 9,38958% dan 10,4273% pada proses pengujian. Hal ini berarti jaringan dapat mempelajari nilai taburan data pelatihan dengan baik berdasarkan 83 pola data yang digunakan. Begitu juga pada tahap pengujian, jaringan dapat mempelajari nilai taburan data pengujian sebanyak 82 pola data yang digunakan. Hasil peramalan berdasarkan metode JST RBF untuk enam bulan berikutnya yaitu bulan Oktober 2016, November 2016, Desember 2016, Januari 2017, Februari 2017 dan Maret 2017 masing-masing secara berturut-turut sebesar 3,0960%; 3,3567%; 3,4304%; 3,5468%; 3,6701% dan 3,8570%. Perbandingan hasil peramalan dengan data aslinya diperoleh nilai MAPE sebesar 7,12199%. Pada metode ketiga yaitu metode hibrid AR-RBF peramalan yang dilakukan menggunakan input data dari residual ARIMA terbaik. Selanjutnya untuk langkah-langkah yang dilakukan sama dengan metode jaringan syaraf tiruan RBF. Hasil output jaringan kemudian ditambahkan dengan hasil peramalan pada metode ARIMA. Data residual berasal dari metode ARIMA(12,1,0), Karena data mengalami diferensiasi pertama maka jumlah data berkurang satu menjadi 164. Sehingga komposisi data 50% dan 50% masing-masing sebanyak 82 data dan 82 data. Banyaknya input ditentukan dengan melihat plot PACF data residual diperoleh input sebanyak 2. Berdasarkan variasi parameter 2 variabel spread dan 10 variasi jumlah neuron pada lapisan tersembunyi diperoleh arsitektur jaringan terbaik yaitu dengan spread 2, 2 input, 1 neuron dan 1 output. Dengan arsitektur jaringan tersebut diperoleh nilai MAPE pada proses pelatihan sebesar 13.6517% dan

10,7079% pada proses pengujian. Hal ini menggambarkan jaringan dapat mempelajari nilai taburan data pelatihan dengan baik berdasarkan 82 pola data yang digunakan. Begitu juga pada tahap pengujian, jaringan dapat mempelajari nilai taburan data pengujian sebanyak 82 pola data yang digunakan. Hasil peramalan berdasarkan metode JST RBF untuk enam bulan berikutnya yaitu bulan Oktober 2016, November 2016, Desember 2016, Januari 2017, Februari 2017 dan Maret 2017 secara berturut-turut sebesar 3,2930%; 3,3496%; 3,2811%; 3,1661%; 3,1405% dan 3,2811%. Sehingga perbandingan hasil peramalan dengan data aslinya diperoleh nilai MAPE sebesar 9,37089%. Untuk lebih jelasnya perbandingan hasil peramalan dari ketiga metode yang digunakan disajikan dalam Tabel 9.

Tabel 9 Hasil Peramalan Ketiga Metode

Bulan	Data Asli Tingkat Inflasi (%)	Hasil Peramalan (%)		
		AR	JST RBF	Hibri d AR- RBF
Oktober 2016	3,31	3,07	3,09	3,29
November 2016	3,58	3,08	3,35	3,35
Desember 2016	3,02	3,09	3,43	3,28
Januari 2017	3,61	3,10	3,54	3,13
Februari 2017	3,83	3,12	3,67	3,16
Maret 2017	3,49	3,13	3,86	3,14
MAPE (%)	-	10,36	7,12	9,37

Berdasarkan hasil peramalan dengan ketiga metode tersebut, hasil JST RBF lebih baik dibandingkan kedua model lainnya. Hal ini terlihat terutama dari nilai MAPE secara keseluruhan metode JST RBF lebih kecil dibandingkan metode AR dan Metode Hibrid AR-RBF. Walaupun metode hibrid AR-RBF merupakan metode yang dikembangkan dengan menggabungkan metode AR dan metode JST RBF, namun metode hibrid AR-RBF tersebut tidak dapat menjamin keakuratan yang lebih tinggi daripada metode hibrid AR-RBF. Hal tersebut bergantung pola data yang terbentuk. Peramalan dengan menggunakan metode JST RBF dapat diamati pada proses pelatihan bahwa nilai spread dan banyaknya neuron pada lapisan tersembunyi sangat mempengaruhi hasil peramalan. Hasil yang ditunjukkan memperlihatkan bahwa berbedanya neuron diperlukan untuk mendapatkan arsitektur terbaik. Selain itu banyaknya input mempengaruhi pola data sehingga mempengaruhi hasil ramalan juga. Berdasarkan

plot PACF pada data asli diperoleh 4 input pada peramalan metode JST RBF. Sementara itu, plot PACF pada data residual diperoleh 2 input pada peramalan metode hibrid AR-RBF. Hasil penelitian ini didukung dengan hasil penelitian dari Pratiwi (2015) bahwa hasil peramalan dengan RBF-FA-EGARCH memiliki nilai RMSE lebih kecil daripada ARIMA-EGARCH. Sehingga peramalan dengan menggunakan metode RBF-FA-EGARCH lebih akurat daripada ARIMA-EGARCH.

Dalam pengembangan metode ini masih memiliki keterbatasan yaitu komposisi data yang digunakan pada metode jaringan syaraf tiruan adalah 50% : 50%. Artinya pola data yang dibuat untuk input dan target pada proses pelatihan (training) adalah 50% dari data asli. Begitu pula untuk proses pengujian (testing), data yang digunakan juga 50% sisanya. Dalam metode jaringan syaraf tiruan, tidak ada penentuan yang pasti untuk menggunakan komposisi data dalam proses pelatihan dan proses pengujian. Namun, bagaimanapun komposisi data dapat mempengaruhi output atau hasil peramalan. Pada metode hibrid AR-RBF, komposisi data yang digunakan juga sama pada metode JST RBF yaitu 50% : 50%. Selain itu, dalam JST banyaknya input, besarnya nilai spread dan banyak neuron juga sangat mempengaruhi hasil visual plot, hasil peramalan maupun nilai MAPE. Sehingga bisa dilakukan banyaknya variasi input, spread dan neuron pada lapisan tersembunyi untuk mendapatkan arsitektur jaringan terbaik agar nilai MAPE juga kecil.

PENUTUP

Simpulan yang diperoleh dari penelitian ini adalah (1) Pada metode AR diperoleh model terbaik yaitu ARIMA(12,1,0). Hasil peramalan tingkat inflasi Indonesia dengan model terbaik ARIMA(12,1,0) pada enam bulan berikutnya yaitu bulan Oktober 2016, November 2016, Desember 2016, Januari 2017, Februari 2017 dan Maret 2017 secara berturut-turut adalah 3,0762%; 3,0848%; 3,0942%; 3,1048%; 3,1168%; dan 3,1299%. (2) Pada metode JST RBF dengan variasi parameter spread dan neuron diperoleh arsitektur jaringan terbaik yaitu dengan 4 input, spread 2, 7 neuron pada layar tersembunyi dan 1 output. Dengan jaringan terbaik tersebut diperoleh hasil peramalan tingkat Inflasi Indonesia pada enam bulan berikutnya yaitu bulan Oktober 2016, November 2016, Desember 2016, Januari 2017, Februari 2017 dan Maret 2017 masing-masing

secara berturut-turut sebesar 3,0960%; 3,3567%; 3,4304%; 3,5468%; 3,6701% dan 3,8570%. (3) Pada metode Hibrid AR-RBF dengan variasi parameter spread dan neuron diperoleh arsitektur jaringan terbaik yaitu dengan 2 input, spread 2, 1 neuron pada layar tersembunyi dan 1 output. Dengan jaringan terbaik tersebut diperoleh hasil peramalan tingkat Inflasi Indonesia pada enam bulan berikutnya yaitu bulan Oktober 2016, November 2016, Desember 2016, Januari 2017, Februari 2017 dan Maret 2017 secara berturut-turut sebesar 3,2930%; 3,3496%; 3,2811%; 3,1661%; 3,1405% dan 3,2811%. (4) Pemilihan metode yang optimal untuk peramalan didasarkan pada besarnya nilai MAPE yang diperoleh dari masing-masing metode. Nilai MAPE pada metode AR(12) atau ARIMA(12,1,0) sebesar 10,3636%, metode JST RBF 7,12199% dan metode Hibrid AR-RBF sebesar 9,37089%. Jadi metode yang optimal untuk meramalkan tingkat Inflasi Indonesia adalah metode JST RBF dengan besarnya nilai MAPE yang lebih kecil daripada metode lainnya.

Dalam pengembangan metode ini masih memiliki keterbatasan. Sehingga perlu dikembangkan beberapa hal diantaranya melakukan uji coba komposisi data dalam proses pelatihan dan pengujian metode JST RBF. Memperbanyak variasi parameter jaringan seperti input, spread dan neuron. Selain itu, pada JST RBF bisa melakukan pengembangan dalam perhitungan bobot dengan algoritma lain, contohnya *K-Mean Cluster* dan algoritma SOM (*Self Organizing Map*).

DAFTAR PUSTAKA

- Anggriningrum, D. P., Hendikawati, P. dan Abidin, Z. 2013. Perbandingan Prediksi Harga Saham dengan Menggunakan Jaringan Syaraf Tiruan Backpropagation dan ARIMA. *Unnes Journal of Mathematics*, 2(2) : 104 – 109.
- Arhami, M. dan Desiani, A. 2005. *Pemrograman Matlab*. Yogyakarta: ANDI.
- Badan Pusat Statistik. 2012. *Data Strategis BPS Indonesia*. Jakarta: Badan Pusat Statistik.
- Fauzannisa, R. A., Yasin, H. dan Ispriyanti, D. 2015. Peramalan Harga Minyak Mentah Dunia Menggunakan Metode *Radial Basis Function Neural Network*. *Jurnal Gaussian*, 5(1) : 193 – 202.
- Gujarati D. N dan Porter, D. C. 2013. *Dasar-dasar Ekonometrika*. Jakarta: Salemba Empat.

- Kuncoro, Mudrajat. 2007. *Metode Kuantitatif Edisi Ketiga*. Yogyakarta : UPP STIM YKPN
- Kusumadewi, S. 2004. *Membangun Jaringan Syaraf Tiruan (menggunakan MATLAB & Excel Link)*. Yogyakarta: Graha Ilmu.
- Makridakis, S., Wheelwright, S. C. & McGee, V. E. 1999. *Metode dan Aplikasi Peramalan, Edisi Kedua Jilid Satu*, Alih Bahasa Hari Suminto. Jakarta: Binarupa Aksara.
- Prasetyo, E. P. 2009. *Fundamental Makro Ekonomi*. Yogyakarta: Beta.
- Wiyanti, D. T. dan R. Pulungan. 2012. Peramalan Deret Waktu Menggunakan Model Fungsi Basis Radial (RBF) dan Auto Regressive Integrated Moving Average (ARIMA). *Jurnal MIPA*, 35(2): 175 – 182.
- Zhang, P. G. 2003. Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing Journal*, 50: 159 – 175.
- Zheng, F. dan S. Zhong. 2011. Time Series Forecasting Using a Hybrid RBF Neural Network and AR Model Based on Binomial Smoothing. *International Journal of Mathematical, Computational, Physical, Electrical and Computer Engineering*, 5(3): 419 – 423.
- <http://bi.go.id/id/moneter/inflasi/data/Default.aspx> [diakses pada 2 Oktober 2016]