



FORUM PASCASARJANA

Volume 29 Nomor 1 Januari 2006

- Strategi Peningkatan Kinerja Kelembagaan dan Pembiayaan
Pengelolaan Irigasi** 1-12
(Luh Putu Suciati, Affendi Anwar, dan Akhmad Fauzi)
- Model Pengelolaan Berkelanjutan Budi Daya Ikan dalam Keramba
Jaring Apung di Waduk: Studi Kasus di Perairan Waduk PB
Soedirman** 13-23
(Endang Widyastuti, Much. Sri Saeni, Daniel Djokosetiyanto, dan
Hartrisari Hardjomidjojo)
- Pengembangan Masyarakat Pesisir dalam Mengelola Sumber Daya
Pesisir dan Laut: Kasus di Kabupaten Buleleng, Provinsi Bali** 25-35
(Siti Amanah, Basita G. Sugihen, Sumardjo, Pang S. Asngari, dan
Djoko Susanto)
- Penggunaan Jaringan Fungsi Basis Radial pada Pemodelan
Ionosfer di Atas Sumedang** 37-51
(Anisa, Siswadi, Budi Suharjo, dan Buldan Muslim)
- Dampak Desentralisasi Fiskal terhadap Kinerja Perekonomian dan
Kelembagaan di Provinsi Riau** 53-64
(Saefudin, Bonar M. Sinaga, dan Hermanto Siregar)
- Pengelolaan Sumber Air Minum Lintas Wilayah di Kawasan
Gunung Ciremai, Provinsi Jawa Barat** 65-75
(Hikmat Ramdan, Kooswardhono Mudikjo, Dudung Darusman, dan
Hidayat Pawitan)
- Pemanfaatan Tanah dari Bawah Tegakan Jati Muna di Sulawesi
Tenggara sebagai Sumber Inokulum CMA** 77-94
(Hariyanti Nova, Irdika Mansur, dan Sri Wilarso)

**Sekolah Pascasarjana
Institut Pertanian Bogor
Bogor, Indonesia**

FORUM PASCASARJANA

Volume 29 No.1 Januari 2006

ISSN 0126-1886

Pelindung

Rektor (H. Ahmad Anshori Mattjik)

Penanggung Jawab

Dekan Sekolah Pascasarjana IPB (Syafri Manuwoto)

Pemimpin Redaksi

Wakil Dekan Sekolah Pascasarjana IPB (Khairil Anwar Notodiputro)

Wakil Pemimpin Redaksi

Sekretaris Program Doktor Sekolah Pascasarjana IPB (Marimin)
Sekretaris Program Magister Sekolah Pascasarjana IPB (Drajat Martianto)

Dewan Redaksi

Alex Hartana (Genetika dan Pemuliaan Tanaman)
Ari Purbayanto (Kelautan)
Basita Ginting S. (Penyuluhan Pembangunan dan Komunikasi Pertanian)
Tri Koesoemaningtyas (Agronomi, Ekofisiologi Tanaman)
Lailan Syaufina (Ilmu Pengetahuan Kehutanan)
I G. Putu Purnaba (Matematika dan Statistika)
M. Parulian Hutagaol (Ekonomi Pertanian dan Sosiologi)
M. Zairin Jr (Budi Daya Perairan)
Maggy T. Suhartono (Biokimia dan Bioteknologi)
Reviany Widjajakusuma (Fisiologi Hewan, Biologi Nuklir)
Setyo Pertiwi (Teknik Pertanian)
Asep Sudarman (Ilmu Produksi Ternak)
Utomo Kartosuwondo (Hama dan Penyakit Tumbuhan)

Redaksi Pelaksana

Wahju Q. Mugnisjah

Administrasi

Muhammad Fikri

Alamat Redaksi

Sekolah Pascasarjana IPB,
Gedung Rektorat Lantai I Kampus IPB Darmaga, Bogor 16680
Telp. 0251-622642 ext. 161 Fax. 0251-622986
e-mail: forum_pascasarjana@bima.ipb.ac.id

Forum Pascasarjana merupakan jurnal ilmiah yang diterbitkan setiap triwulan sebagai sarana diseminasi hasil-hasil penelitian Sekolah Pascasarjana IPB

DAFTAR ISI
CONTENS

- Strategi Peningkatan Kinerja Kelembagaan dan Pembiayaan 1-12**
Pengelolaan Irigasi
Strategy of Increasing Institution Performance and Budget of Irrigation Management
(Luh Putu Suciati, Affendi Anwar, dan Akhmad Fauzi)
- Model Pengelolaan Berkelanjutan Budi Daya Ikan dalam Keramba 13-23**
Jaring Apung di Waduk: Studi Kasus di Perairan Waduk PB Soedirman
Sustainable Management Model of Floating Cage Culture in Reservoir. Case Study in PB Soedirman Reservoir
(Endang Widyastuti, Much. Sri Saeni, Daniel Djokosetiyanto, dan Hartrisari Hardjomidjojo)
- Pengembangan Masyarakat Pesisir dalam Mengelola Sumber Daya 25-35**
Pesisir dan Laut: Kasus di Kabupaten Buleleng, Provinsi Bali
Coastal Community Development in Managing Coastal and Marine Resources: A Case of Buleleng Regency, Province of Bali
(Siti Amanah, Basita G. Sugihen, Sumardjo, Pang S. Asngari, dan Djoko Susanto)
- Penggunaan Jaringan Fungsi Basis Radial pada Pemodelan Ionosfer 37-51**
di Atas Sumedang
The Use of Radial Basis Function Network on Ionospheric Modelling in Sumedang
(Anisa, Siswadi, Budi Suharjo, dan Buldan Muslim)
- Dampak Desentralisasi Fiskal terhadap Kinerja Perekonomian dan 53-64**
Kelembagaan di Provinsi Riau
Impact of Fiscal Deçentralization on the Economic Performances and Institutional in Riau Province
(Saefudin, Bonar M Sinaga, dan Hermanto Siregar)
- Pengelolaan Sumber Air Minum Lintas Wilayah di Kawasan Gunung 65-75**
Ciremai, Provinsi Jawa Barat
Transboundary Drinking Water Sources Management in Mount Ciremai, West Java Province
(Hikmat Ramdan, Kooswardhono Mudikjo, Dudung Darusman, dan Hidayat Pawitan)
- Pemanfaatan Tanah dari Bawah Tegakan Jati Muna di Sulawesi 77-94**
Tenggara sebagai Sumber Inokulum CMA
The Use of Rizhosphere Soil of Jati Muna Stands from Southeast Sulawesi Province as Source of AMF Inoculum
(Hariyanti Nova, Irdika Mansur, dan Sri Wilarso)

PENGGUNAAN JARINGAN FUNGSI BASIS RADIAL PADA PEMODELAN IONOSFER DI ATAS SUMEDANG¹⁾

(The Use of Radial Basis Function Network on Ionospheric Modelling in Sumedang)

Anisa, Siswadi²⁾, Budi Suharjo²⁾, Buldan Muslim²⁾

ABSTRACT

Radial basis function network, recognized as JFBR, is one of the methods or model used to predict any data or to classify the pattern and also is one of the methods of modeling and forecasting in neural network. JFBR is also a model which is used to overcome the problem of unlinear and uncomplete data. This research aims to predict the input-output parameter ionosphere foF2 layer one day ahead for 1997 – 2003 data in Sumedang, using JFBR by watching the accuration of prediction, signed by small deviation value of MAD. The learning and testing of JFBR model conducted at three set of data with three input of geomagnetic activity, which is index of Ap, Dst and K, by using various data measure and spread combination at learning of model and also by two activation function or different transfer function, that is Gauss and logistics function. The results of learning and testing of JFBR model, generally, indicate that the use of large data measure ($M = 80\%$ from data) and width spread ($5,000 < \beta \leq 50,000$) on the learning make the higher level of accuration compared with other combinations. This research also shown the use of Gauss activation function gives higher accuration level relatively compared with logistics function. It also shown that the data plot and prediction of Gauss function is smoother compared with logistics function. Based on the input, input usage by geomagnetic K index is obtained by local data from Tangerang Geophysical Station gives higher accuration level compared by the index of geomagnetic Ap and Dst which is the global data. The result of this research is expected as input for LAPAN Bandung to predict critical frequency foF2 in Sumedang, which is useful to long distance radio communication service by using HF (high frequency) with wavelength 3 – 30 MHz as the carrier wave.

Key words: ionosphere, radial basis function network, prediction

PENDAHULUAN

Dalam bidang komunikasi radio menggunakan HF (*high frequency*), frekuensi dengan panjang gelombang 3-30 MHz, sebagai frekuensi gelombang pembawa, lapisan ionosfer merupakan media pemantul gelombang untuk komunikasi dari titik ke titik. Ionosfer adalah lapisan di atmosfer atas yang terdiri dari partikel-partikel bermuatan pada ketinggian sekitar 60 sampai 1000 km (Schunk dan Nagy, 2000) yang dapat mempengaruhi perambatan gelombang radio. Untuk itu diperlukan informasi tentang frekuensi maksimum yang masih dapat dipantulkan oleh ionosfer yang dikenal dengan MUF (*maximum usable frequency*). Salah satu peubah ionosfer yang penting dalam komunikasi radio

¹⁾ Bagian dari tesis penulis pertama, Program Studi Statistika, Sekolah Pascasarjana IPB

²⁾ Berturut-turut adalah Ketua dan Anggota Komisi Pembimbing

untuk menentukan MUF adalah frekuensi kritis foF2, yang akan dikaji dalam penelitian ini.

Kondisi ionosfer sebagai media pemantul tidak selalu stabil karena dipengaruhi oleh beberapa hal, seperti gangguan akibat aktivitas matahari, variasi medan magnet bumi, lokasi, dan waktu setempat yang dapat mempengaruhi komunikasi radio. Ionosfer yang terganggu atau mengalami ketidakstabilan akan dapat menyebabkan *fading* pada sinyal gelombang radio yang dipantulkan atau melewati ionosfer. Untuk itu prediksi frekuensi kritis lapisan ionosfer dengan tingkat akurasi yang tinggi pada waktu yang akan datang perlu dilakukan sehingga deteksi dini karakteristik lapisan tersebut yang dapat mempengaruhi pelayanan komunikasi radio jarak jauh dapat dilakukan lebih awal.

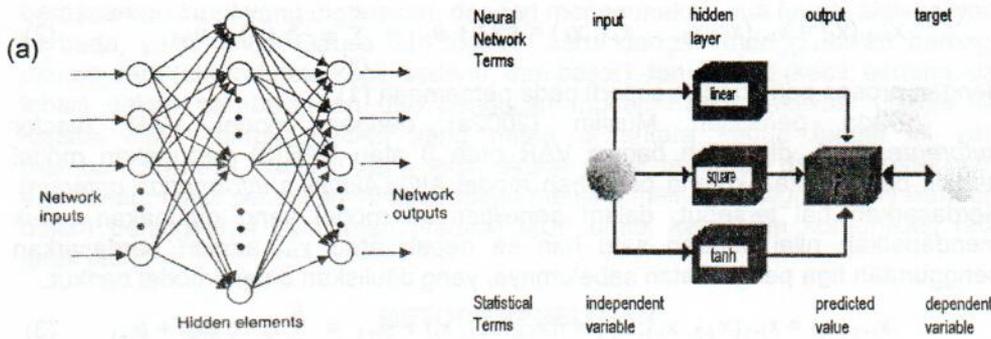
Untuk prediksi MUF, selama ini LAPAN Bandung menggunakan model IPS (*Ionospheric Prediction Services*) pada software ASAPS (*Advanced Stand Alone Prediction Services*) yang diturunkan dari model empiris dengan menggunakan model linear.

Berdasarkan verifikasi yang telah dilakukan oleh Budiyanto *et al.* (2001), prediksi ASAPS ternyata kurang akurat diterapkan di Indonesia karena memiliki penyimpangan sebesar 31.64%. Prediksi dengan model fisis memperoleh simpangan sebesar 70% dan model Klobuchar yang juga merupakan model global hanya mampu mereduksi bias ionosfer sampai sekitar 50% (Muslim, 2002a). Penelitian lain dengan menggunakan model JFBR dengan data amatan frekuensi foF2 di atas Sumedang, untuk data bulan Januari tahun 1998 sampai Januari tahun 2000, memperoleh simpangan sebesar 16.7% (Muslim, 2002b).

Untuk mendapatkan model ionosfer yang berlaku pada batas regional atau area tertentu, dalam pembuatan modelnya haruslah menggunakan data ionosfer pada regional tersebut karena akan sesuai dengan karakteristik ionosfer pada daerah itu. Jika pada data ionosfer terdapat amatan yang hilang dan proporsi amatan yang hilang tersebut berpengaruh terhadap hasil prediksi, proses pendugaan amatan yang hilang dengan melakukan interpolasi pada data perlu dilakukan (Francis *et al.*, 2000).

Berdasarkan uraian di atas, diperlukan suatu model untuk mengatasi masalah ketidaklinearan pada data dan ketidaklengkapan data amatan sehingga prediksi frekuensi kritis lapisan ionosfer dapat dilakukan dengan tingkat akurasi yang tinggi. Jaringan syaraf tiruan fungsi basis radial atau dikenal dengan JFBR, yang merupakan salah satu model pada *neural network* (NN), adalah salah satu model yang digunakan untuk mengatasi masalah tersebut (Francis *et al.*, 2000; Bishop, 1995).

Sebagaimana model pada NN lainnya, struktur dasar JFBR disusun secara hierarki ke dalam lapisan-lapisan (*layer*), yaitu lapisan *input*, lapisan *output*, dan satu lapisan antara kedua lapisan tersebut yang disebut lapisan *hidden*. Penggunaan JFBR juga dibedakan berdasarkan tiga karakteristik, yaitu pola koneksi yang digunakan atau arsitektur, metode penentuan bobot koneksi atau algoritma pembelajaran yang digunakan, dan berdasarkan fungsi yang mentransformasikan *input* menjadi *output* atau disebut fungsi aktivasi atau fungsi transfer. Selain itu, JFBR dapat diterapkan untuk jumlah data kecil atau yang relatif besar (Rud, 2001). Secara umum struktur dasar JFBR diberikan pada Gambar 1a, sedangkan perbandingan salah satu contoh model NN dengan model statistika diberikan pada Gambar 1b.



Gambar 1. Struktur dasar JFBR dengan 3 layer (a) dan perbandingan model NN dengan 1 *hidden layer* dengan model Statistika (b)

Pada penelitian ini model JFBR akan digunakan pada masing-masing peubah *input-output* ionosfer dan peubah *input* ionosfer dengan tujuan yang berbeda. Model JFBR pada peubah *input-output* ionosfer digunakan untuk pembelajaran dan pengujian model untuk mendapatkan model prediksi karakteristik ionosfer foF2 yang memberikan tingkat akurasi terbaik relatif terhadap data yang digunakan.

Jika terdapat N pasang data *input-output*, $\{x_i, y_i\}_{i=1}^N$, secara umum model JFBR dituliskan dalam persamaan berikut:

$$y(x) = f(x) + e(x) = \hat{y}(x) + e(x) = \sum_{j=1}^K \omega_j \phi_j(x) + e(x), \quad K \leq M. \quad (1)$$

dengan x adalah peubah *input* berdimensi- p , $x' = (x_1, x_2, \dots, x_p)$, ω_j adalah bobot dari parameter yang akan ditentukan nilainya (identik dengan pendugaan koefisien regresi pada model statistika konvensional), K adalah optimum banyaknya bobot yang diperoleh dalam pembelajaran model sehingga simpangan dengan data pembelajaran yang lain lebih kecil dari ξ , $0 < \xi < 1$, $\phi(\bullet)$ adalah fungsi basis radial, suatu fungsi nonlinear yang merupakan fungsi transfer atau fungsi aktivasi dalam model JFBR; dalam hal ini $\phi_j(x)$ merupakan fungsi dari $\|x - c_j\|$, fungsi dari jarak Euclid antara vektor *input* dengan pusat-pusat dari fungsi basis yang dinotasikan dengan c_j , c_j merupakan vektor rata-rata (sentroid) dari j amatan pertama dari vektor *input* dalam pembelajaran model, M menyatakan banyaknya data yang disediakan dalam pembelajaran model, $M < N$, sedangkan $e(x)$ menyatakan galat pemodelan pada x (Bishop, 1995).

Pada peubah *input* ionosfer, model JFBR akan digunakan untuk mencari nilai dugaan satu hari ke depan untuk peubah-peubah *input* tersebut yang nantinya akan digunakan sebagai masukan untuk prediksi frekuensi kritis karakteristik ionosfer foF2. Pada tahap ini model JFBR akan digunakan pada data amatan yang berasal dari satu sumber tetap, yang terjadinya berdasarkan indeks waktu t secara berurutan dengan interval waktu yang tetap. Data seperti ini disebut juga sebagai data runtun waktu atau *time series* (Cryer, 1986). Jika setiap pengamatan pada suatu peubah *input* tertentu dinyatakan dalam $x_1, x_2, \dots, x_{t-2}, x_{t-1}, x_t$ dengan t adalah waktu pengamatan terakhir atau yang terbaru, secara umum model JFBR untuk peubah *input* tersebut dituliskan dalam persamaan berikut:

$$x_{t+1}(x_t) = x_{t+1}(x_1, x_2, \dots, x_{t-1}, x_t) = f(x_t) + e_{t+1} = \sum_{j=1}^K \omega_j \phi_j(x_t) + e_{t+1} \quad (2)$$

dengan proses perhitungan seperti pada persamaan (1).

Pada penelitian Muslim (2002a) dengan model VAR (*vector autoregression*), diperoleh bahwa VAR orde 3 atau VAR(3) merupakan model terbaik berdasarkan kriteria pemilihan model AIC (*Akaike's information criterion*). Berdasarkan hal tersebut, dalam penelitian ini model yang digunakan untuk mendapatkan nilai dugaan satu hari ke depan atau x_{t+1} adalah berdasarkan penggunaan tiga pengamatan sebelumnya, yang dituliskan dalam model berikut:

$$x_{t+1}(x_t) = x_{t+1}(x_{t-2}, x_{t-1}, x_t) = f(x_{t-2}, x_{t-1}, x_t) + e_{t+1} = \sum_{j=1}^K \omega_j \phi_j(x_t) + e_{t+1} \quad (3)$$

Beberapa fungsi aktivasi yang dapat digunakan untuk JFBR, di antaranya, adalah fungsi aktivasi Gauss, multikuadratik, invers multikuadratik, Cauchy, dan fungsi logistik. Hutchinson (1994) dalam penelitiannya menggunakan data harian tahun 1989 – 1991 indeks harga permintaan pasar untuk sektor industri negara Jepang, dan Schumacher *et al.* (1996) dalam penelitiannya menggunakan data di bidang kesehatan, menyatakan bahwa fungsi aktivasi Gauss lebih *smooth* jika dibandingkan dengan fungsi logistik. Berdasarkan keragaman yang dimiliki oleh fungsi-fungsi tersebut, fungsi aktivasi Gauss mempunyai ragam yang lebih kecil jika dibandingkan dengan fungsi Cauchy, multikuadratik, dan juga invers multikuadratik (<http://www.anc.ed.ac.uk/mjo/intro/node33.htm1> [Januari 2003]) sehingga penelitian ini akan difokuskan pada penggunaan fungsi aktivasi Gauss dan logistik.

Bentuk fungsi $\phi(\cdot)$ untuk JFBR jika fungsi aktivasi Gauss yang digunakan adalah

$$\phi_j(x) = \exp \left[-\frac{1}{\beta} (\|x - c_j\|)^2 \right] \quad (4)$$

dengan konstanta β yang dikenal dengan *spread* (Howlett dan Jain, 2001) merupakan lebar dari fungsi Gauss tersebut, sedangkan jika yang digunakan adalah fungsi aktivasi logistik,

$$\phi_j(x) = [1 + \exp(-\|x - c_j\|)]^{-1}$$

Terdapat beberapa algoritma yang dapat digunakan untuk menentukan pembobot-pembobot yang optimal sedemikian hingga menghasilkan galat (*error*) yang minimum, di antaranya, adalah algoritma *orthogonal least squares* (OLS), Levenberg-Marquardt (LM), dan Quasi-Newton (QN). Chng *et al.* (1995) menyatakan bahwa OLS adalah suatu algoritma yang efisien digunakan pada seleksi alur maju (*forward selection*), sedangkan Chen *et al.* (2004) menyatakan bahwa OLS adalah algoritma yang sederhana dan efisien untuk prediksi data runtun waktu nonlinear dengan menggunakan JFBR sehingga penelitian ini akan difokuskan pada penggunaan algoritma pembelajaran OLS.

Penelitian ini bertujuan memprediksi peubah *input-output* ionosfer satu hari ke depan dengan menggunakan model JFBR dengan melihat seberapa besar tingkat akurasi prediksi yang dihasilkan dengan menggunakan model tersebut, yang ditandai dengan nilai simpangan model dalam MAD (*mean absolute deviation*). Pada penelitian ini akan dilakukan pembelajaran dan pengujian model JFBR dengan algoritma pembelajaran OLS pada tiga gugus data yang berbeda

berdasarkan *input* yang digunakan, dengan menggunakan dua fungsi aktivasi yang berbeda, yaitu fungsi Gauss dan logistik, serta dengan menggunakan berbagai ukuran data (ukuran data kecil, sedang, dan besar) dan *spread* (kecil, sedang, dan lebar) dalam pembelajaran dan pengujian model. Fungsi aktivasi Gauss dan logistik dipilih untuk melihat yang mana di antara kedua fungsi ini yang memberikan hasil prediksi yang lebih akurat relatif terhadap data ionosfer yang digunakan. Hasil penelitian ini diharapkan menjadi masukan bagi LAPAN Bandung dalam peningkatan pelayanan prediksi MUF untuk keperluan komunikasi radio jarak jauh.

METODE PENELITIAN

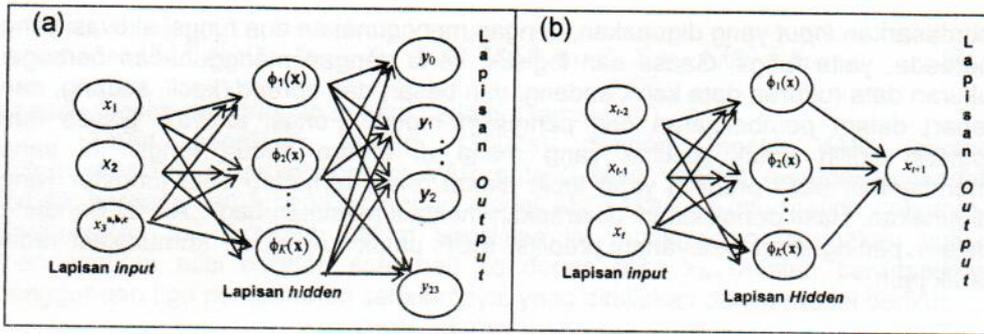
Data yang digunakan dalam penelitian ini diambil dari Bidang Ionosfer dan Telekomunikasi, Pusat Pemanfaatan Sains Antariksa, LAPAN, Bandung, yang merupakan data harian pengamatan foF2 mulai tanggal 1 Januari 1997 - 31 Desember 2003, dari jam 00.00 LT sampai jam 23.00 LT, sebagai peubah *output* (target). Jumlah data ionosfer yang ada seharusnya adalah $((7 \text{ tahun} \times 365 \text{ hari}) + 1 \text{ hari}) \times 24 \text{ jam} = 61\,344$ data karena pada bulan Februari 2000 terdapat 29 hari (tahun Kabisat). Tetapi data yang ada hanya berjumlah 30\,053, atau ada 31\,291 amatan yang hilang. Oleh karena itu, pendugaan amatan yang hilang dengan interpolasi menggunakan fungsi harmonik akan dilakukan terlebih dahulu sebelum proses pembelajaran dan pengujian model JFBR. Deskripsi peubah *input-output* ionosfer diberikan pada Tabel 1.

Tabel 1. Deskripsi peubah *input-output* ionosfer

| | Nama peubah (notasi) | Waktu pengamatan per hari | Jumlah amatan/hari | Data yang digunakan |
|-------------------------------|--|---|--------------------|---------------------|
| Peubah <i>input</i> ionosfer | Bilangan <i>sunspot</i> R (x_1) | Setiap jam 12.00 LT | 1 | 1 amatan |
| | Fluks matahari 10.7cm (x_2) | Setiap jam 12.00 LT | 1 | 1 amatan |
| | Indeks geomagnet global Ap (x_3^a) | Setiap interval 3 jam, mulai jam 00.00 – 23.00 UT | 8 | Jumlah 8 amatan |
| | Indeks geomagnet global Dst (x_3^b) | Setiap jam, mulai jam 00.00 – 23.00 UT | 24 | Rata-rata 24 amatan |
| | Indeks geomagnet lokal K (x_3^c) | Setiap interval 3 jam, mulai jam 00.00 – 23.00 LT | 8 | Jumlah 8 amatan |
| Peubah <i>output</i> ionosfer | Frekuensi kritis foF2 $Y_i, i=0,1,\dots,23$ | Setiap jam, mulai jam 00.00 – 23.00 LT | 24 | 24 amatan |

Keterangan: a, b, dan c menyatakan proses masuknya peubah-peubah indeks gangguan geomagnet tersebut ke dalam model satu persatu.

Berdasarkan pada persamaan (1), (3), dan (4) atau (5), struktur dasar JFBR untuk peubah *input-output* dan peubah *input* ionosfer diperlihatkan pada Gambar 2.



Gambar 2. Struktur dasar model JFBR untuk peubah *input-output* ionosfer (a) dan struktur dasar model peubah *input* ionosfer (b)

Berikut arti dari notasi yang digunakan pada Gambar 2.

- $x_1, x_2, x_3^{a,b,c}$ = Peubah-peubah *input* ionosfer sebagaimana dideskripsikan pada Tabel 1.
- $\phi_1(x), \phi_2(x), \dots, \phi_k(x)$ = Berturut-turut adalah fungsi transfer atau fungsi aktivasi pertama, kedua, dan ke- K , dengan K adalah optimum banyaknya bobot yang diperoleh dalam pembelajaran. Jika fungsi aktivasi yang digunakan adalah fungsi Gauss, $\phi_k(x) = \exp \left[-\frac{1}{\beta} (||x - c_j||)^2 \right]$, sedangkan bila yang digunakan adalah fungsi logistik, $\phi_j(x) = [1 + \exp(- (||x - c_j||))]^{-1}$, $j = 1, 2, \dots, K, K \leq M$, dengan M banyaknya data yang disediakan untuk pembelajaran model.
- $y_0, y_1, y_2, \dots, y_{23}$ = Berturut-turut adalah frekuensi kritis foF2 yang diamati pada jam 00.00 LT, jam 01.00 LT, jam 02.00 LT, seterusnya sampai pada jam 23.00 LT.
- $x_{t-2}, x_{t-1}, x_t, x_{t+1}$ = Berturut-turut adalah data amatan suatu peubah *input* tertentu, misalkan peubah x_i yang dideskripsikan pada Tabel 1, $i = 1, 2, 3^a, 3^b, 3^c$, dengan nilai dugaan x_{t+1} diperoleh berdasarkan penggunaan tiga amatan sebelumnya, yaitu x_{t-2}, x_{t-1} , dan x_t .

Berbagai ukuran data dalam pembelajaran model dan berbagai lebar *spread* β pada suatu interval tertentu untuk fungsi aktivasi Gauss yang digunakan dalam penelitian ini diberikan pada Tabel 2. Untuk mempercepat proses pembelajaran dan pengujian model, nilai β pada interval yang digunakan pada ukuran *spread* kecil, sedang, dan lebar masing-masing adalah nilai β dengan kelipatan 10, 100, dan 1 000.

Tabel 2. Berbagai ukuran data dan lebar *spread* yang digunakan dalam pembelajaran model JFBR.

| Ukuran data | | Ukuran <i>spread</i> | |
|-------------|-----------------|----------------------|-------------------------------|
| Kecil | $M = 20\%$ data | Kecil | $0 < \beta \leq 500$ |
| Sedang | $M = 50\%$ data | Sedang | $500 < \beta \leq 5\,000$ |
| Besar | $M = 80\%$ data | Lebar | $5\,000 < \beta \leq 50\,000$ |

Metode analisis yang digunakan dalam penelitian ini dilakukan dengan dua tahap berikut:

1. tahap pembelajaran dan pengujian model JFBR untuk peubah *input-output* ionosfer dan melihat seberapa besar tingkat akurasi model yang dihasilkan (lihat nilai MAD).
2. tahap prediksi frekuensi kritis karakteristik ionosfer satu hari ke depan, dengan sebelumnya dilakukan prediksi peubah *input* lapisan ionosfer untuk hari yang sama.

HASIL DAN PEMBAHASAN

Pendugaan Amatan yang Hilang

Seperti yang telah dijelaskan sebelumnya, pendugaan amatan yang hilang hanya dilakukan pada data pengamatan ionosfer saja. Jika data pengamatan dilihat per bulan, data pengamatan bulan Januari, Maret, April, Mei, Juli, November, dan Desember relatif lebih lengkap jika dibandingkan dengan data pengamatan bulan Februari, Juni, Agustus, September, dan Oktober. Hasil pendugaan amatan yang hilang dengan menggunakan fungsi harmonik beserta tingkat akurasi yang dihasilkan diberikan pada Tabel 3.

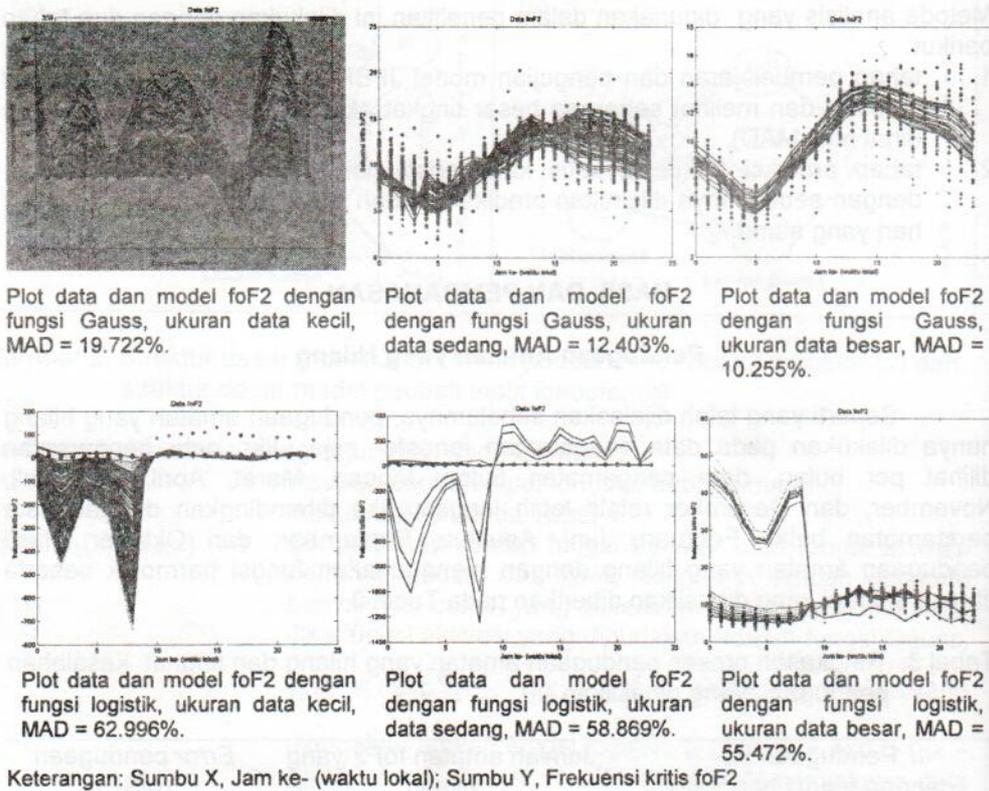
Tabel 3. Ringkasan proses pendugaan amatan yang hilang dan tingkat kesalahan pendugaan yang dihasilkan

| Pendugaan ke- (dengan fungsi harmonik) | Jumlah amatan foF2 yang hilang | Error pendugaan (MSE) |
|--|-----------------------------------|--------------------------|
| 0 | 31 291 | - |
| 1 | 29 412 | 0.468 |
| 2 | 18 734 | 0.341 |
| 3 | 7 674 | 0.357 |
| 4 | 3 253 | 0.250 |

Dari Tabel 3 terlihat bahwa masih terdapat 3 253 amatan yang tidak dapat diduga oleh fungsi harmonik. Dalam analisis selanjutnya, data tersebut akan diabaikan karena dianggap proporsinya tidak mempengaruhi jumlah keseluruhan data yang telah siap untuk proses pembelajaran dan pengujian model JFBR.

Prediksi Nilai Frekuensi Kritis foF2 dengan Model JFBR

Proses pembelajaran dan pengujian model JFBR menggunakan paket program Matlab 6.5 dilakukan dengan pemrosesan data menggunakan data dengan bulan yang sama untuk semua tahun. Berdasarkan hasil pembelajaran dan validasi model data bulan Januari yang relatif lebih lengkap jika dibandingkan dengan data pada bulan lain untuk dua fungsi aktivasi yang berbeda, terlihat bahwa penggunaan fungsi aktivasi logistik pada model JFBR memberikan tingkat akurasi yang rendah pada ketiga gugus data jika dibandingkan dengan penggunaan fungsi aktivasi Gauss, ditandai dengan nilai simpangan dalam MAD yang relatif besar. Hal ini juga terlihat dari plot model yang sangat jauh menyimpang dari pola aslinya (lihat Gambar 3).



Gambar 3. Perbandingan plot data dan model peubah *output* dengan dua fungsi aktivasi yang berbeda dengan *input* indeks R, F, dan indeks K

Dari gambar tersebut terlihat bahwa penggunaan fungsi aktivasi logistik untuk ketiga ukuran data pada gugus data ketiga memberikan hasil yang relatif sama untuk pembelajaran dan pengujian dengan menggunakan model JFBR, yaitu nilai simpangan MAD yang relatif jauh lebih besar jika dibandingkan dengan nilai simpangan yang diperoleh menggunakan fungsi aktivasi Gauss, yaitu nilai lebih dari 50%. Hasil yang relatif sama juga diperoleh untuk pembelajaran dan pengujian model pada gugus data pertama dan kedua sehingga pembelajaran dan pengujian model JFBR selanjutnya dilakukan dengan hanya menggunakan fungsi aktivasi Gauss saja, begitu juga pembelajaran dan pengujian model pada peubah *input* ionosfer. Selanjutnya dilakukan pembelajaran dan pengujian model JFBR pada ketiga gugus data dengan menggunakan fungsi aktivasi Gauss. Rata-rata tingkat akurasi yang diperoleh dari berbagai kombinasi ukuran data dan *spread* yang ditandai dengan nilai simpangan MAD diberikan pada Tabel 4.

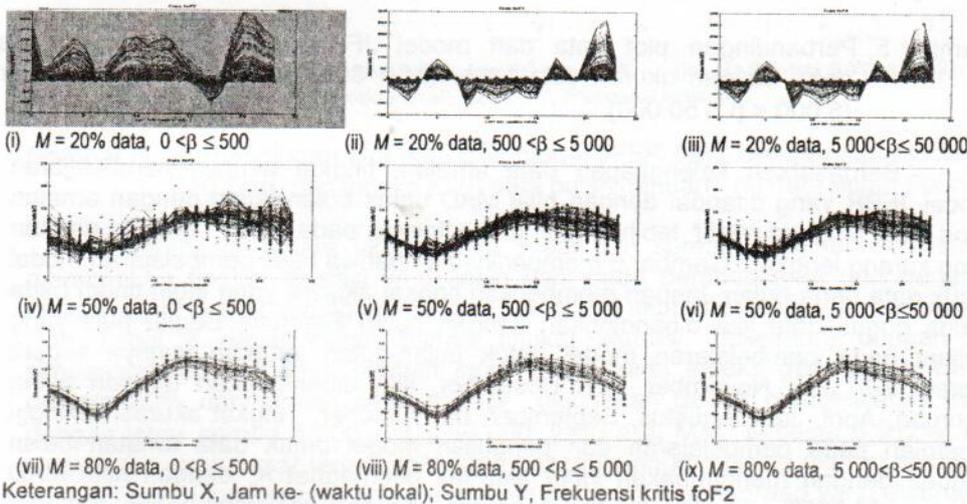
Pada Tabel 4, umumnya terlihat bahwa tingkat akurasi yang tinggi diperoleh pada penggunaan kombinasi ukuran data sedang dan besar dalam pembelajaran ($M = 50\%$ dan 80% jumlah data) dan dengan *spread* sedang dan lebar ($500 < \beta \leq 5\,000$ dan $5\,000 < \beta \leq 50\,000$). Tingkat akurasi tertinggi diperoleh pada kombinasi ukuran data besar dan *spread* lebar, masing-masing dengan MAD sebesar 12.364%, 12.992%, dan 11.300% untuk ketiga gugus. Tingkat akurasi yang rendah ditandai dengan nilai simpangan MAD yang cukup besar, umumnya

terjadi pada kombinasi ukuran data kecil dan *spread* yang kecil atau sedang, bahkan pada *spread* yang lebar.

Tabel 4. Rata-rata nilai MAD berdasarkan pembelajaran dan pengujian model JFBR untuk peubah *output* ionosfer

| Ukuran data | Spread | Gugus Data I : | Gugus Data II : | Gugus Data III : |
|-------------|--------|------------------------------|-------------------------------|-----------------------------|
| | | input R,F, dan Ap MAD (%) | input R,F, dan Dst MAD (%) | input R,F, dan K MAD (%) |
| Kecil | Kecil | 19.665 | 19.862 | 19.204 |
| | Sedang | 18.497 | 18.337 | 17.825 |
| | Lebar | 17.446 | 16.992 | 16.199 |
| Sedang | Kecil | 15.530 | 16.579 | 15.331 |
| | Sedang | 14.833 | 15.980 | 14.504 |
| | Lebar | 13.829 | 14.445 | 12.900 |
| Besar | Kecil | 13.608 | 14.280 | 12.275 |
| | Sedang | 13.110 | 13.748 | 11.893 |
| | Lebar | 12.364 | 12.992 | 11.300 |

Hasil pembelajaran dan pengujian model JFBR dengan fungsi aktivasi Gauss pada suatu gugus data dalam berbagai kombinasi ukuran data dan *spread* ditampilkan dalam bentuk plot data dan model yang diberikan pada Gambar 4 dengan menggunakan indeks geomagnet K sebagai *input*.

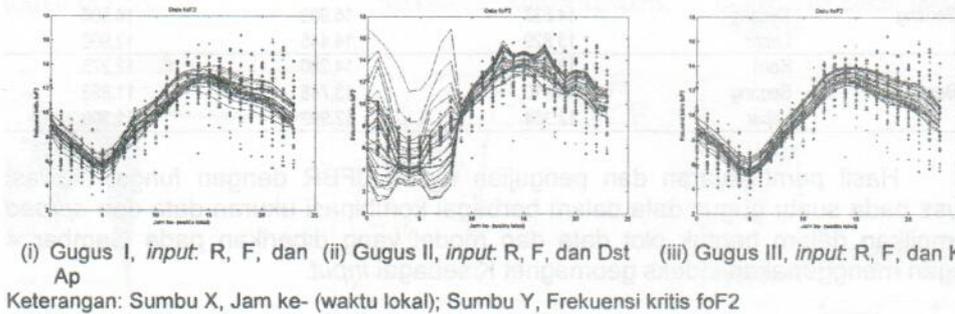


Gambar 4. Perbandingan plot data dan model JFBR foF2 pada berbagai ukuran data dan *spread* dengan *input* indeks R, F10.7cm, dan indeks K.

Pada Gambar 4, umumnya terlihat bahwa hasil pembelajaran dan pengujian model untuk gugus data yang digunakan mengalami perubahan plot pada berbagai kombinasi ukuran data dan *spread*. Kombinasi ukuran data kecil pada lebar *spread* yang berbeda memberikan hasil dalam bentuk plot data dan prediksi yang kurang *smooth* dan jauh menyimpang dari pola variasi harian frekuensi kritis lapisan ionosfer foF2. Begitu pula yang kadang-kadang terlihat pada kombinasi ukuran data sedang dengan lebar *spread* yang kecil dan sedang. Plot model dengan JFBR umumnya mulai mendekati pola variasi harian frekuensi ionosfer foF2 pada penggunaan ukuran data yang sedang dalam pembelajaran

dengan *spread* yang lebar atau pada penggunaan ukuran data besar pada berbagai lebar *spread*. Pada berbagai kombinasi ukuran data dan *spread* ini juga terlihat mengalami perubahan pada nilai MAD sebagaimana yang ditunjukkan pada Tabel 4.

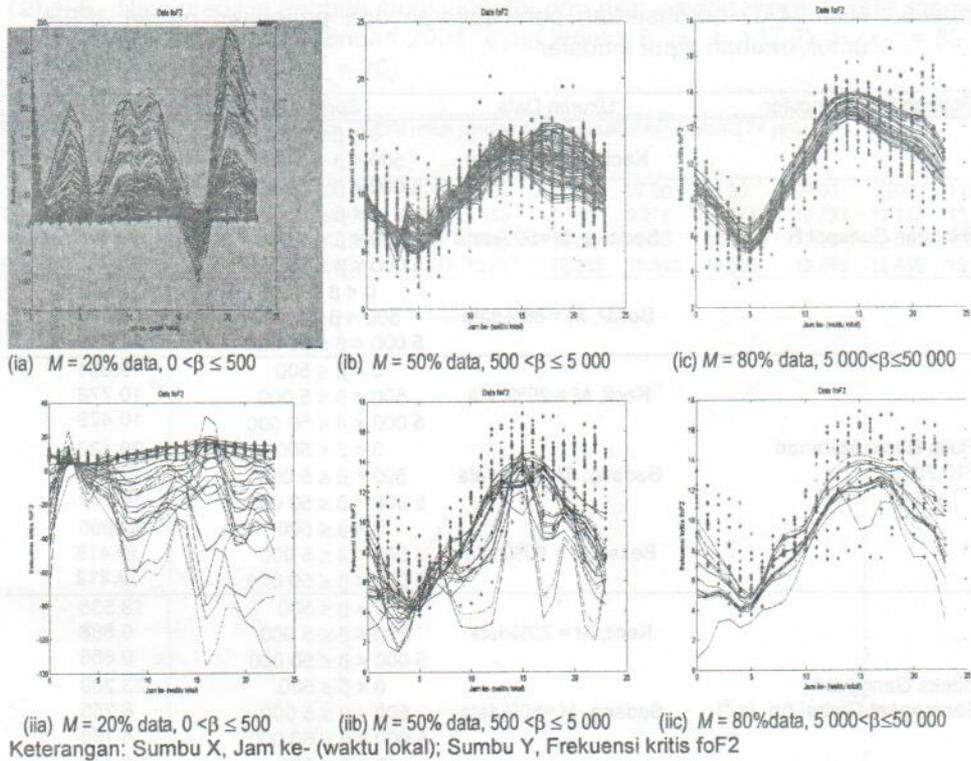
Berdasarkan gugus data yang digunakan, penggunaan indeks geomagnet lokal K sebagai parameter *input* memberikan hasil yang lebih bagus jika dibandingkan dengan penggunaan indeks geomagnet global Ap dan Dst. Hal ini bisa dilihat dari plot data dan model yang lebih *smooth*, yang diberikan pada Gambar 5, dan juga pada tingkat akurasi yang dihasilkan oleh ketiga gugus data, yang ditandai dengan nilai simpangan MAD yang lebih kecil (lihat Tabel 4).



Gambar 5. Perbandingan plot data dan model JFBR foF2 pada tiga gugus data, dengan ukuran data besar ($M = 80\%$ data) dan *spread* lebar ($5\,000 < \beta \leq 50\,000$).

Berdasarkan kelengkapan data amatan, tingkat akurasi pembelajaran model JFBR yang ditandai dengan nilai MAD untuk bulan-bulan dengan amatan yang lebih lengkap relatif lebih tinggi dibandingkan pada bulan dengan amatan yang kurang lengkap. Gambar 6 memperlihatkan bahwa hasil pembelajaran model untuk data pada bulan Januari memberikan tingkat akurasi yang lebih tinggi pada ketiga gugus data jika dibandingkan dengan bulan Februari. Begitu pula yang terlihat pada pembelajaran model untuk bulan-bulan lengkap lainnya seperti Maret, Mei, Juli, November, dan Desember, jika dibandingkan dengan bulan Februari, April, Juni, Agustus, September, dan Oktober. Tingkat akurasi tertinggi diperoleh pada pembelajaran dan pengujian model untuk data amatan bulan Januari dengan menggunakan *input* aktivitas geomagnet K, dengan nilai MAD sebesar 10.255%. Tingkat akurasi terendah, dengan nilai simpangan terbesar diperoleh pada pembelajaran dan pengujian model untuk data amatan bulan April dengan *input* indeks geomagnet Dst, dengan nilai MAD sebesar 14.961%.

Berdasarkan hasil pembelajaran dan validasi model pada peubah *input* ionosfer, diperoleh nilai MAD pada tiga gugus data yang digunakan (lihat Tabel 5). Dari tabel tersebut terlihat juga bahwa indeks K yang merupakan indeks gangguan geomagnet lokal memberikan tingkat akurasi yang lebih baik pada berbagai ukuran data dan *spread* dengan menggunakan model JFBR jika dibandingkan dengan indeks gangguan geomagnet lainnya seperti indeks global Ap dan Dst serta indeks aktivitas matahari R dan F10.7cm.



Gambar 6. Perbandingan plot data dan model JFBR foF2 dengan *input* indeks R, F10.7cm, dan indeks K: (i) data bulan Januari (ii) data bulan Februari

Kombinasi antara ukuran data besar dan *spread* yang lebar umumnya memberikan tingkat akurasi yang lebih baik pada pembelajaran dan pengujian peubah *input* jika dibandingkan dengan kombinasi ukuran data dan *spread* lainnya. Dari Tabel 5 dapat dilihat bahwa tingkat akurasi maksimum dengan nilai simpangan terkecil untuk peubah *input* terjadi pada indeks geomagnet lokal K dengan 80% dari jumlah seluruh data digunakan dalam pembelajaran model dengan lebar *spread* $5\,000 < \beta \leq 50\,000$, yaitu nilai MAD sebesar 3.912%. Nilai simpangan yang besar terjadi baik pada penggunaan kombinasi ukuran data kecil, yaitu 20% dari jumlah seluruh data dengan berbagai lebar *spread* yang digunakan, maupun pada ukuran data sedang atau besar dalam pembelajaran dengan lebar *spread* kecil ($0 < \beta \leq 500$).

Pada Tabel 6 diberikan hasil prediksi masing-masing peubah *input* ionosfer dan karakteristik ionosfer foF2 selama 24 jam untuk tanggal 1 Januari 2004, menggunakan *input* indeks R, F, dan indeks K, sedangkan Gambar 7 adalah hasil prediksi frekuensi kritis foF2 dalam bentuk plot dengan *input* yang sama.

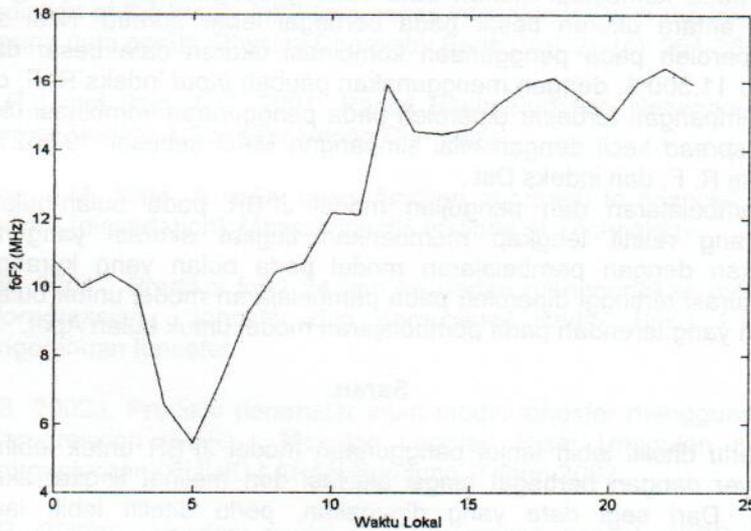
Penggunaan model JFBR untuk prediksi karakteristik ionosfer foF2 menggunakan tingkat akurasi Gauss memberikan tingkat akurasi yang lebih baik jika dibandingkan dengan penggunaan tingkat akurasi logistik, dengan nilai simpangan MAD terkecil sebesar 3.360% yang diperoleh pada pembelajaran peubah data dengan *input* indeks K, F, dan indeks K.

Tabel 5. Nilai MAD berdasarkan pembelajaran dan pengujian model JFBR untuk peubah input ionosfer

| Peubah Input Ionosfer | Ukuran Data | Spread | MAD (%) |
|--|-------------------------|-------------------------------|--------------|
| Bilangan Sunspot R (x_1) | Kecil, $M = 20\%$ data | $0 < \beta \leq 500$ | 15.932 |
| | | $500 < \beta \leq 5\ 000$ | 8.805 |
| | | $5\ 000 < \beta \leq 50\ 000$ | 8.805 |
| | Sedang, $M = 50\%$ data | $0 < \beta \leq 500$ | 22.274 |
| | | $500 < \beta \leq 5\ 000$ | 8.776 |
| | | $5\ 000 < \beta \leq 50\ 000$ | 8.155 |
| | Besar, $M = 80\%$ data | $0 < \beta \leq 500$ | 22.993 |
| | | $500 < \beta \leq 5\ 000$ | 7.160 |
| | | $5\ 000 < \beta \leq 50\ 000$ | 7.160 |
| Fluks Radio Matahari F10.7cm (x_2) | Kecil, $M = 20\%$ data | $0 < \beta \leq 500$ | 19.091 |
| | | $500 < \beta \leq 5\ 000$ | 10.778 |
| | | $5\ 000 < \beta \leq 50\ 000$ | 10.428 |
| | Sedang, $M = 50\%$ data | $0 < \beta \leq 500$ | 29.122 |
| | | $500 < \beta \leq 5\ 000$ | 10.310 |
| | | $5\ 000 < \beta \leq 50\ 000$ | 10.192 |
| | Besar, $M = 80\%$ data | $0 < \beta \leq 500$ | 29.890 |
| | | $500 < \beta \leq 5\ 000$ | 9.418 |
| | | $5\ 000 < \beta \leq 50\ 000$ | 9.212 |
| Indeks Gangguan Geomagnet Global Ap (x_3^a) | Kecil, $M = 20\%$ data | $0 < \beta \leq 500$ | 18.536 |
| | | $500 < \beta \leq 5\ 000$ | 9.888 |
| | | $5\ 000 < \beta \leq 50\ 000$ | 9.888 |
| | Sedang, $M = 50\%$ data | $0 < \beta \leq 500$ | 23.209 |
| | | $500 < \beta \leq 5\ 000$ | 8.255 |
| | | $5\ 000 < \beta \leq 50\ 000$ | 8.198 |
| | Besar, $M = 80\%$ data | $0 < \beta \leq 500$ | 23.430 |
| | | $500 < \beta \leq 5\ 000$ | 8.111 |
| | | $5\ 000 < \beta \leq 50\ 000$ | 8.114 |
| Indeks Gangguan Geomagnet Global Dst (x_3^b) | Kecil, $M = 20\%$ data | $0 < \beta \leq 500$ | 24.658 |
| | | $500 < \beta \leq 5\ 000$ | 14.744 |
| | | $5\ 000 < \beta \leq 50\ 000$ | 14.651 |
| | Sedang, $M = 50\%$ data | $0 < \beta \leq 500$ | 28.039 |
| | | $500 < \beta \leq 5\ 000$ | 9.162 |
| | | $5\ 000 < \beta \leq 50\ 000$ | 9.083 |
| | Besar, $M = 80\%$ data | $0 < \beta \leq 500$ | 28.101 |
| | | $500 < \beta \leq 5\ 000$ | 9.011 |
| | | $5\ 000 < \beta \leq 50\ 000$ | 8.918 |
| Indeks Gangguan Geomagnet Lokal K (x_3^c) | Kecil, $M = 20\%$ data | $0 < \beta \leq 500$ | 14.641 |
| | | $500 < \beta \leq 5\ 000$ | 7.225 |
| | | $5\ 000 < \beta \leq 50\ 000$ | 7.225 |
| | Sedang, $M = 50\%$ data | $0 < \beta \leq 500$ | 20.791 |
| | | $500 < \beta \leq 5\ 000$ | 5.095 |
| | | $5\ 000 < \beta \leq 50\ 000$ | 5.004 |
| | Besar, $M = 80\%$ data | $0 < \beta \leq 500$ | 20.989 |
| | | $500 < \beta \leq 5\ 000$ | 4.104 |
| | | $5\ 000 < \beta \leq 50\ 000$ | 3.912 |

Tabel 6. Nilai prediksi peubah *input* ionosfer dan nilai prediksi karakteristik ionosfer foF2 tanggal 1 Januari 2004, *input* indeks R ($x_1 = 157.2$), F ($x_2 = 89.7$), dan indeks K ($x_3^c = 20$)

| Waktu dan Prediksi | Nilai prediksi untuk peubah output ionosfer foF2 selama 24 jam | | | | | | | | | | | |
|--------------------|--|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| Waktu | 00.00 | 01.00 | 02.00 | 03.00 | 04.00 | 05.00 | 06.00 | 07.00 | 08.00 | 09.00 | 10.00 | 11.00 |
| Prediksi | 10.786 | 9.980 | 10.405 | 9.915 | 6.577 | 5.440 | 7.280 | 9.277 | 10.474 | 10.723 | 12.183 | 12.127 |
| Waktu | 12.00 | 13.00 | 14.00 | 15.00 | 16.00 | 17.00 | 18.00 | 19.00 | 20.00 | 21.00 | 22.00 | 23.00 |
| Prediksi | 15.930 | 14.560 | 14.478 | 14.634 | 15.331 | 15.922 | 16.128 | 15.548 | 14.889 | 15.988 | 16.416 | 15.950 |



Gambar 7. Plot prediksi frekuensi kritis foF2 selama 24 jam, tanggal 1 Januari 2004

Jika dikaitkan dengan kecepatan pembelajaran, waktu proses yang digunakan untuk pembelajaran dan pengujian model JFBR relatif lebih lama daripada model VAR dan AR (Anisa dan Muslim, 2004). Hal ini disebabkan karena pada model JFBR, proses pembelajaran data dilakukan secara iterasi. Pada pembelajaran dan pengujian model *input-output* dan model *input* ionosfer, dibutuhkan waktu proses yang lebih lama pada pembelajaran peubah *input* karena dalam menentukan nilai dugaan satu hari ke depan digunakan seluruh nilai amatan secara bertahap.

KESIMPULAN DAN SARAN

Kesimpulan

Penggunaan model JFBR untuk prediksi karakteristik ionosfer foF2 menggunakan fungsi aktivasi Gauss memberikan tingkat akurasi yang lebih baik jika dibandingkan dengan penggunaan fungsi aktivasi logistik, dengan nilai simpangan MAD terkecil sebesar 11.300% yang diperoleh pada pembelajaran gugus data III dengan *input* indeks R, F, dan indeks K.

Pada pembelajaran dan pengujian model pada peubah *input* yang digunakan, indeks geomagnet K yang merupakan data lokal memberikan tingkat akurasi yang lebih tinggi jika dibandingkan dengan penggunaan indeks yang lain, dengan nilai simpangan terkecil dalam MAD sebesar 3.912%, diikuti oleh indeks aktivitas matahari R, indeks geomagnet global Ap, dan Dst, kemudian fluks radio matahari F yang merupakan data global dengan nilai simpangan terkecil dalam MAD sebesar 9.212%.

Dari berbagai kombinasi ukuran data dan *spread* yang digunakan dalam pembelajaran dan pengujian model JFBR, umumnya tingkat akurasi yang tinggi diperoleh pada kombinasi ukuran data sedang dengan *spread* yang lebar dan kombinasi antara ukuran besar pada berbagai lebar *spread*. Nilai simpangan terkecil diperoleh pada penggunaan kombinasi ukuran data besar dan *spread* lebar, yaitu 11.300%, dengan menggunakan peubah *input* indeks R, F, dan indeks K. Nilai simpangan terbesar diperoleh pada penggunaan kombinasi ukuran data kecil dan *spread* kecil dengan nilai simpangan MAD sebesar 19.862%, dengan *input* indeks R, F, dan indeks Dst.

Pembelajaran dan pengujian model JFBR pada bulan-bulan dengan amatan yang relatif lengkap memberikan tingkat akurasi yang tinggi jika dibandingkan dengan pembelajaran model pada bulan yang kurang lengkap. Tingkat akurasi tertinggi diperoleh pada pembelajaran model untuk bulan Januari, sedangkan yang terendah pada pembelajaran model untuk bulan April.

Saran

Perlu diteliti lebih lanjut penggunaan model JFBR untuk lebih dari satu *hidden layer* dengan berbagai fungsi aktivasi dan melihat tingkat akurasi yang dihasilkan. Dari segi data yang digunakan, perlu diteliti lebih lanjut untuk penggunaan peubah lain, misalnya angin matahari, sebagai *input* model yang dianggap dapat mempengaruhi karakteristik ionosfer foF2, dan melihat tingkat akurasi prediksi foF2 yang dihasilkan dengan model JFBR. Juga dapat dilakukan prediksi beberapa hari ke depan, yang hasilnya dapat dibandingkan dengan prediksi yang telah dilakukan oleh NCDC (*National Climatic Data Center*) atau NOAA (*National Oceanic and Atmospheric Administration*), sehingga deteksi dini karakteristik ionosfer foF2 yang dapat mempengaruhi komunikasi radio jarak jauh dapat dilakukan lebih awal.

DAFTAR PUSTAKA

- Anisa dan Muslim, B. 2004. Prediksi aktivitas matahari jangka pendek menggunakan fungsi basis radial. Prosiding Pertemuan Ilmiah Nasional Basic Science I, ISBN: 979-508-459-3, pp : 166-173.
- Bishop, C.M. 1995. Neural Networks for Pattern Recognition. Oxford, U.K. Clarendon Press.
- Budiyanto *et al.* 2001. Verifikasi ASAPS dengan data oblique sounding. Warta LAPAN, 3 (3), Juli – September.
- Chen, S, Hong X, dan Harris, C.J. 2004. Kernel density construction using orthogonal forward regression. Proceeding 5th International Conference

- Intelligent Data Engineering and Automated Learning (Exeter, UK), August 25 – 27, pp : 586-592.
- Chng, E.S, Chen, S, and Mulgrew, B. 1995. Efficient computational schemes for the orthogonal least squares algorithm for radial basis function networks. *IEEE Transaction Signal Processing*, 43 (1): 373-376.
- Cryer, J.D. 1986. *Time Series Analysis*. Boston: PWS-KENT Publishing Company.
- Francis, N.M, Brown, A.G, Cannon, P.S., and Broomhead, D.S. 2000. Nonlinear prediction of the hourly foF2 time series in conjunction with the interpolation of missing data points. *Physica Chemistry Earth*, Vol. 25 (4): 261-265.
- Howlett, R.J and Jain, L.C. 2001. *Radial Basis Function Networks Volume 1*. Physica-Verlag, A Springer-Verlag Company.
- Hutchinson, J.M. 1994. *A radial basis function approach to financial time series analysis [dissertation]*. Massachusetts Institute of Technology.
- Muslim, B. 2001. *Prediksi foF2 24 jam ke depan menggunakan metode vector autoregression*. Ionosfer dan Komunikasi Radio, Buku 1, Puslitbang Pengetahuan Ionosfer.
- Muslim, B. 2002a. *Prediksi parameter input model ionosfer menggunakan vector autoregression (VAR)*. Makalah Laporan Riset Unggulan Kemandirian Kedirgantaraan (RUUK) LAPAN Bandung, Tahun 2002.
- Muslim, B. 2002b. *Validasi model nonlinier jangka pendek JFBR untuk foF2 regional Indonesia bulan Januari dengan data Sumedang tahun 1998-2000*. Makalah Laporan Riset Unggulan Kemandirian Kedirgantaraan (RUUK) LAPAN Bandung, Tahun 2002.
- Rud, OP. 2001. *Data Mining Cookbook: Modelling Data for Marketing, Risk and Customer Relationship Management*. London: John Wiley and Sons.
- Schumacher, M. *et al.* 1996. Neural networks and logistic regression. *Computational Statistics and Data Analysis*, 21 : 661-682.
- Schunk, R.W. and Nagy, A.F. 2000. *Ionospheres: Physics, Plasma Physics, and Chemistry*. Cambridge University Press.