

**PREDIKSI CURAH HUJAN SEBAGAI DASAR PERENCANAAN
POLA TANAM PADI DAN PALAWIJA MENGGUNAKAN
MODEL GENERAL REGRESSION NEURAL NETWORK**

Budi Warsito¹, Tarno¹, Aris Sugiharto²

¹Program Studi Statistika FMIPA Universitas Diponegoro

²Program Studi Ilmu Komputer FMIPA Universitas Diponegoro

Korespondensi : budi_wrst@yahoo.com

**THE RAINFALL PREDICTION AS A BASE OF PLANNING
THE RICE AND CROPS PLANTING SYSTEM USE
GENERAL REGRESSION NEURAL NETWORK MODEL**

ABSTRACT

This paper discuss about General Regression Neural Network (GRNN) modelling to the rainfall data at some territory in the Central Java that dependent on rainfall for irrigation in the planting system i.e Musuk, Ngaringan and Jakenan. The data that used are the dasarian data (the every ten day) while the input model are choosen from ARIMA model with the ACF and PACF plot. The result of predict in sample show that GRNN model have a high precision, although the predict out of sample is guaranted better than ARIMA not yet. Then the model is used to forecast some next stage. The result of rainfall forecasting conclude that each territory is better to apply the rice-crops-crops in the planting system, with consider the estimation of climate anomaly to begins the planting time.

Key Words : GRNN, ARIMA, rainfall, planting system

I. PENDAHULUAN

Sistem produksi pertanian sangat dipengaruhi oleh iklim. Faktor iklim yang paling terasa perubahannya akibat anomali iklim adalah curah hujan. Di Indonesia kejadian anomali iklim dominan mempengaruhi produksi pertanian dan ketahanan pangan. Dampak anomali iklim diantaranya adalah terjadinya gangguan secara langsung terhadap sistem pertanian (Estiningtyas dan Amien, 2006), termasuk padi dan palawija. Prediksi curah hujan diperlukan karena untuk menyusun rencana masa tanam diperlukan data dan informasi kondisi curah hujan minimal satu musim ke depan. Prediksi curah hujan dapat dilakukan beberapa bulan ke depan bahkan satu tahun ke depan. Namun semakin panjang jangka waktu yang diprediksi maka kesalahan (*error*) model juga semakin besar. Dengan mengembangkan model yang tervalidasi dan segera (*on line forecasting*) diharapkan dapat menghasilkan informasi yang lebih akurat dalam waktu yang cepat serta mencakup wilayah yang lebih luas sehingga pemanfaatannya dapat lebih dirasakan oleh pengguna.

Permasalahan yang muncul kemudian adalah bagaimana membuat prediksi curah hujan berdasarkan proses stokhastik (probabilistik) dengan keakuratan yang tinggi. Dalam hal ini diperlukan fenomena ketergantungan terhadap waktu (*time dependent phenomenon*) yang diwujudkan dalam model-model stokhastik (Box, 1994). Pada awalnya metode peramalan yang sering digunakan untuk melakukan prediksi adalah ARIMA Box-Jenkins. Keterbatasan dari model ini adalah mengabaikan kemungkinan hubungan nonlinear dan berbagai asumsi model seperti stasioneritas data dan homoskedastisitas residual. Dalam perkembangan selanjutnya berkembang metode baru menggunakan algoritma Jaringan Syaraf Tiruan (JST) atau Neural Network (NN).

Beberapa penelitian telah dilakukan untuk menerapkan berbagai model NN dalam berbagai bidang. Lee (2000) telah menerapkan model Feed Forward Neural Network (FFNN) untuk uji Kernel Nonparametrik pada model regresi. Kaitannya dengan peramalan data time series, Barai, et. al. (2006) melakukan prediksi kualitas udara dengan model FFNN, serta Kao and Huang (2000) menerapkan model FFNN pada data kualitas udara di AS. Sedangkan Warsito dan Sumiyati (2007) menggunakan model FFNN dengan algoritma Quasi Newton BFGS dan Levenberg-Marquardt untuk prediksi curah hujan kota Semarang. Pada perkembangan model jaringan yang lain, Specht (1991) mengusulkan dan mengembangkan model yang baru yaitu *General Regression Neural*

Network (GRNN). Model GRNN termasuk model jaringan dengan pengawasan (*supervised training*) dimana output yang diharapkan diarahkan untuk mengikuti pola output data training. Model GRNN sebagaimana model NN yang lain merupakan model nonlinear dan nonparametrik. Kelebihan arsitektur model GRNN adalah tidak diperlukannya estimasi jumlah bobot jaringan yang harus diprediksi untuk mendapatkan arsitektur jaringan optimal (error minimal) karena sudah tertentu berdasarkan variabel input dan jumlah data yang digunakan sehingga tidak lagi bersifat *trial and error*.

Model GRNN telah banyak dikembangkan untuk berbagai masalah statistika baik untuk output multivariat maupun univariat. Diantaranya adalah Leung, et.al (2000) yang melakukan prediksi nilai tukar beberapa mata uang internasional dan membandingkannya dengan model MLFN dan beberapa model fungsi transfer. Kanevskii (1999) melakukan prediksi data spatial, sedangkan Warsito (2006) membandingkan keakuratan prediksi model FFNN dan GRNN pada penerapan bidang finansial. Warsito dkk (2008) juga telah menerapkan GRNN untuk prediksi tingkat pencemaran udara ambien di kota Semarang. Kaitannya pemodelan GRNN untuk data curah hujan, (Cigizoglu et. al, 2008) melakukan perbandingan model FFNN, RBFNN dan GRNN untuk pemodelan curah hujan pada data meteorologi Turki. Penelitian ini membahas model GRNN untuk prediksi curah hujan beberapa daerah di Jawa Tengah untuk perencanaan pola tanam padi dan palawija.

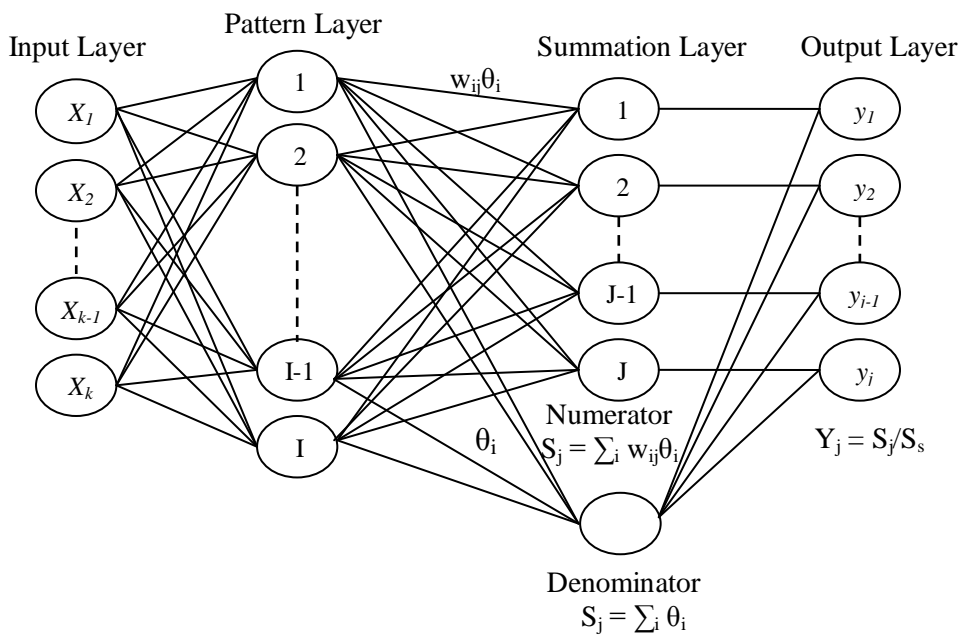
II. BAHAN DAN METODE

Pada penelitian ini data yang digunakan adalah data dasarian (10 harian) curah hujan beberapa daerah di Jawa Tengah dengan sistem tanam tadah hujan yaitu kecamatan Musuk Boyolali, kecamatan Ngaringan Grobogan dan kecamatan Jakenan Pati. Akan dilakukan prediksi curah hujan beberapa periode yang akan datang berdasarkan data curah hujan masa lampau. Sedangkan model yang digunakan adalah General Regression Neural Network (GRNN). Dasar dari operasi GRNN secara esensial didasarkan pada teori regresi nonlinear (kernel) dimana estimasi dari nilai harapan output ditentukan oleh himpunan input-inputnya. Walaupun GRNN menghasilkan output berupa vektor multivariat, dengan tidak mengurangi keumuman deskripsi dari logika operasi GRNN pada penelitian ini disederhanakan untuk kasus output univariat yaitu curah hujan. Persamaan (1) meringkas logika GRNN dalam formula regresi nonlinear :

$$E[y|X] = \frac{\int_{-\infty}^{\infty} yf(X, y)dy}{\int_{-\infty}^{\infty} f(X, y)dy} \quad (1)$$


dimana y adalah output yang diprediksi oleh GRNN dalam hal ini nilai prediksi curah hujan, X adalah vektor input (x_1, x_2, \dots, x_p) terdiri dari p variabel prediktor dalam hal ini data curah hujan masa lalu. $E[y|X]$ adalah harga harapan dari output y jika diberikan vektor input X dan $f(X,y)$ adalah fungsi densitas probabilitas bersama dari X dan y .

Konstruksi GRNN terdiri dari empat layer unit pemrosesan yaitu input layer, pattern layer, summation layer dan output layer. *Input layer* menerima vektor input X dan mendistribusikan data ke *pattern layer*. Tiap-tiap neuron dalam *pattern layer* kemudian membangun output θ dan mengirimkan hasilnya ke *summation layer*. Neuron-neuron numerator dan denominator pada summation layer menghitung jumlahan aritmatik sederhana dan terboboti didasarkan pada nilai θ dan w_{ij} yang diperoleh berdasarkan pembelajaran melalui training dengan supervisi. Operasi matematis yang sesungguhnya dibentuk oleh neuron-neuron dalam hidden layer tersebut. Neuron-neuron pada output layer kemudian melakukan pembagian terhadap jumlahan yang telah dihitung oleh neuron-neuron pada *summation layer*.



Gambar 1. Konstruksi GRNN secara umum

Gambar 1 mengilustrasikan skema desain GRNN dan logika operasionalnya. Konstruksi jaringan yang digambarkan akan valid untuk berbagai model dengan output multivariat. Desain khusus untuk model regresi time series hanya mempunyai satu (univariat) neuron output. Input layer merupakan vektor input $(x_{t-1}, x_{t-2}, \dots, x_{t-p})$ terdiri dari p variabel prediktor yang dalam hal ini adalah data curah hujan masa lalu sedangkan output layer y adalah output yang diprediksi oleh GRNN. Dengan desain model GRNN tersebut sebetulnya dimungkinkan untuk memasukkan variabel eksternal yang mungkin berpengaruh secara langsung terhadap curah hujan seperti arah dan kecepatan angin. Karena keterbatasan data hal itu tidak dilakukan. Namun diharapkan kondisi ini tidak mengurangi kebaikan model karena sebenarnya secara tidak langsung unsur eksternal tersebut sudah masuk ke dalam data curah hujan masa lalu sebagaimana filosofi dari data time series, dimana ketika diperoleh angka yang menunjukkan besarnya curah hujan maka nilai tersebut diperoleh juga berdasarkan faktor-faktor eksternal.



Gambar 2 Konstruksi GRNN untuk peramalan data curah hujan. Desain konstruksi GRNN yang diilustrasikan menunjukkan vektor input dengan p unit berdasarkan terminologi autoregresif. Terdapat $(n-p)$ neuron pada pattern layer merepresentasikan banyaknya data training. Nilai p sama dengan jumlah lag dalam spesifikasi model. Setelah training terawasi lengkap jaringan akan menghitung peramalan data curah hujan pada periode t berdasarkan nilai dari variabel prediktor.

Konstruksi GRNN untuk peramalan data time series, atau secara lebih khusus model GRNN untuk prediksi curah hujan disajikan pada gambar 2. Sebagai variabel input adalah data curah hujan masa lalu $(x_{t-1}, x_{t-2}, \dots, x_{t-p})$ dimana order dari p ditentukan

sebelumnya. Dalam hal ini metode ARIMA Box-Jenkins dapat digunakan. Output yang diperoleh merupakan nilai prediksi curah hujan yang akan datang.

Topologi GRNN yang dikembangkan oleh Specht (1991) sebagaimana diilustrasikan pada gambar 1 dan 2 pada prinsipnya terdiri dari empat layer unit pemrosesan (*neuron*). Layer pertama yang disebut neuron input (*input neurons*), bertanggung jawab untuk menerima informasi. Tidak ada pemrosesan data yang dilakukan pada neuron-neuron input tersebut. Neuron input kemudian mengirimkan data ke layer kedua yang disebut neuron pola (*pattern neurons*). Dalam hal ini, jumlah neuron pola sama dengan jumlah kasus dalam himpunan training. Neuron pola i mendapatkan data dari neuron input dan menghitung output θ_i menggunakan fungsi transfer :

$$\theta_i = e^{-\frac{(X-U_i)(X-U_i)}{2\sigma^2}} \quad (2)$$

dimana X adalah vektor input dari variabel prediktor untuk GRNN, U_i adalah vektor training yang direpresentasikan oleh neuron pola i dan σ adalah parameter smoothing. Persamaan (2) merupakan fungsi Gaussian multivariat yang diperluas oleh Cacoullos (1966) dan diadopsi oleh Specht dalam desain GRNN.

Output dari neuron pola kemudian diteruskan ke layer ketiga yang disebut neuron jumlahan (*summation neurons*) dimana output dari semua neuron pola ditambahkan. Secara teknis ada dua tipe penjumlahan yang dibentuk dalam *summation neurons* yaitu penjumlahan aritmatik sederhana dan penjumlahan terboboti. Dalam topologi GRNN terdapat unit pemrosesan terpisah yang melakukan penjumlahan aritmatik sederhana dan penjumlahan terboboti. Persamaan (3a) dan (3b) masing-masing menyatakan operasi matematis yang dibentuk oleh penjumlahan sederhana dan penjumlahan terboboti.

$$S_s = \sum_i \theta_i \quad (3a)$$

$$S_w = \sum_i w_i \theta_i \quad (3b)$$

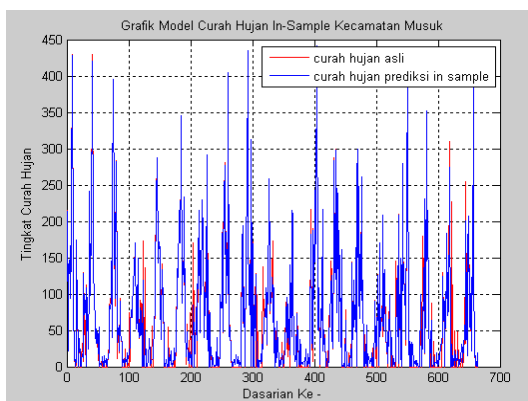
Jumlahan yang dihasilkan oleh *summation neurons* secara berturut-turut dikirimkan ke layer ke empat yaitu neuron output. Neuron output kemudian membentuk pembagian berikut untuk mendapatkan output regresi GRNN y :

$$y = \frac{S_w}{S_s} \quad (4)$$


III. HASIL

Data curah hujan di kecamatan Musuk yang akan digunakan untuk pengolahan data dimulai dari dasarian pertama bulan Januari 1985 sampai dasarian ketiga Maret 2008 sehingga ada sebanyak 801 data. Di Ngaringan data yang digunakan mulai dasarian I bulan Januari 1985 sampai dasarian III Juli 2008 sebanyak 849 data. Sedangkan di Jakenan data yang tersedia mulai dasarian I bulan Januari 1990 sampai dasarian III Juni 2008 atau sebanyak 666 data. Di Ngaringan dan Jakenan ada beberapa bagian dari data yang kosong (*missing*) sehingga dilakukan interpolasi dengan menghitung rata-rata untuk waktu yang sama selama periode-periode sebelumnya.


Dalam pembentukan model GRNN langkah pertama yang dilakukan adalah menentukan input. Pada penelitian ini input yang digunakan dibatasi hanya data curah hujan masa lalu. Sebenarnya dimungkinkan untuk memasukkan faktor eksternal yang diperkirakan juga berpengaruh terhadap curah hujan, tetapi karena keterbatasan data variabel ini tidak dimasukkan. Namun diharapkan hal ini tidak mengurangi ketelitian prediksi karena sebenarnya pengaruh variabel eksternal tersebut secara tidak langsung sudah masuk ke dalam setiap titik data masa lalu. Untuk menentukan pola input digunakan model terbaik ARIMA dengan bantuan plot fungsi autokorelasi (ACF) dan plot fungsi autokorelasi parsial (PACF). Plot data asli dan prediksi *in-sample* serta *out of sample* model GRNN curah hujan dasarian di ketiga daerah secara berturut-turut disajikan pada gambar 3a sampai 5b. Sedangkan nilai keakuratan model GRNN dibandingkan model ARIMA dari tiap-tiap daerah disajikan pada tabel 1.




Gambar 3a Hasil pengujian *predict in sample* model GRNN data curah hujan kecamatan Musuk




Gambar 3b Hasil pengujian *predict out of sample* model GRNN data curah hujan kecamatan Musuk




Gambar 4a Hasil pengujian *predict in sample* model GRNN data curah hujan kecamatan Ngaringan



Gambar 4b Hasil pengujian *predict out of sample* model GRNN data curah hujan kecamatan Ngaringan



Gambar 5a Hasil pengujian *predict in sample* model GRNN data curah hujan kecamatan Jakenan



Gambar 5b Hasil pengujian *predict out of sample* model GRNN data curah hujan kecamatan Jakenan

Tabel 1 Perbandingan beberapa model GRNN untuk prediksi curah hujan kecamatan Musuk, Ngaringan dan Jakenan

Kecamatan	Variabel Input	MSE in sample	MSE out of sample
Musuk	Lag 1, 2, 18	1.048	5.198
	Lag 1, 2, 18, 36	288	7.680
	ARIMA(2,0,1)(1,0,1) ¹⁸	5.141	5.652
Ngaringan	Lag 1, 2, 4, 18, 36, 52	10,8450	5.035,13
	Lag 1, 2, 3, 4, 18, 36, 52	10,6927	5.616,27
	ARIMA(4,0,1)(2,0,0) ¹⁸	2.947,0000	4.417,07
Jakenan	Lag 1, 2, 18, 36	51,83	3.045,17
	Lag 1, 2, 3, 4, 16, 19, 36, 37, 38	0,46	3.461,00
	Lag 1, 2, 3, 4, 16, 18, 19, 36, 37, 38	4,3 x 10 ⁻⁶	3.852,08
	ARIMA(1,0,1)(2,0,1) ¹⁸	2.077,00	1.520,68

IV. PEMBAHASAN

Secara umum prediksi model (*predict in sample*) curah hujan dengan data training untuk ketiga daerah memperlihatkan kesesuaian yang sangat baik. Hal ini dapat dilihat baik secara visual dimana pola dari nilai prediksi sangat dekat dengan data aslinya. Dapat pula dilihat dari nilai MSE yang relatif kecil. Misal untuk daerah Musuk dengan input lag 1, 2, 18 dan 36 menghasilkan nilai MSE sebesar 288, jauh lebih kecil dari model ARIMA yang mempunyai nilai MSE sebesar 4.141 dan di Jakenan dengan input lag 1, 2, 3, 4, 16, 18, 19, 36, 37 dan 38 menghasilkan MSE yang mendekati nol. Setelah didapatkan model GRNN langkah selanjutnya adalah melakukan prediksi ke depan (*predict out of sample*). Dari plot *predict out of sample* dapat dilihat bahwa walaupun masih nampak perbedaan pada nilai datanya tetapi nilai peramalan data ke depan sudah mendekati pola data asli. Nilai MSE memang tidak selalu lebih kecil daripada model ARIMA, namun secara umum pola prediksi sudah menyerupai data asli.

Hasil peramalan menunjukkan bahwa pada tahun 2008 ini awal musim hujan di Musuk dimulai pada dasarian dasarian pertama November. Namun pada dasarian kedua dan ketiga curah hujan akan kembali menurun kemudian meningkat lagi pada dasarian pertama Desember. Untuk kepentingan pola tanam, fenomena ini harus dicermati secara hati-hati. Menurut Suprihatno dkk (2008), untuk pertumbuhan yang relatif normal tanaman padi memerlukan curah hujan 200 mm/bulan selama minimal 4 bulan. Pada kondisi curah hujan yang kurang dari jumlah tersebut tanaman padi menjadi tidak normal dan pada kondisi yang lebih parah lagi akan mengalami kekeringan dengan gejala daun menggulung dan akhirnya mengering. Oleh karena itu ada resiko bila memulai menanam padi pada bulan Oktober atau November karena perkiraan pada dasarian kedua dan ketiga November curah hujan cenderung menurun kembali. Resiko akan lebih kecil bila mulai menanam padi pada dasarian pertama Desember sehingga akan ada jaminan ketersediaan air sampai masa panen pada bulan April, kemudian mulai bulan April menanam palawija. Sehingga pola tanam yang paling ideal bagi daerah ini adalah padi-palawija-palawija dengan catatan permulaan masa tanam harus diperhatikan, mengingat kemungkinan adanya fluktuasi musim pada dasarian kedua dan ketiga November 2008.

Hasil peramalan di Ngaringan menunjukkan bahwa pada tahun 2008 ini awal hujan dimulai pada dasarian pertama Oktober. Anomali iklim diperkirakan terjadi pada dasarian

ketiga Januari dan dasarian pertama Februari. Menurut Suprihatno dkk (2008), meskipun untuk pertumbuhan yang relatif normal tanaman padi memerlukan curah hujan 200 mm/bulan namun sebenarnya pada kondisi curah hujan 100 mm/bulan tanaman padi masih dapat tumbuh dengan baik meskipun tidak sebaik pada kondisi curah hujan cukup. Pada kondisi curah hujan sekitar 100 mm/bulan kelembaban tanah sampai kedalaman 20 cm masih lebih dari 20%, masih cukup baik untuk pertumbuhan tanaman padi dan tidak terjadi gejala kekeringan. Namun tanaman padi akan mulai menunjukkan gejala kekeringan permanen apabila kelembaban tanah sudah mencapai 7,5%. Ini terjadi bila curah hujan sangat minim atau hampir tidak ada hujan sama sekali. Berdasarkan analisis di atas masa tanam yang paling ideal adalah pada dasarian pertama bulan Oktober. Pada dasarian kedua Desember sampai dasarian pertama Januari curah hujan berkisar 100 mm/bulan diharapkan kebutuhan air untuk tanaman padi masih bisa mencukupi. Selanjutnya pada dasarian kedua Januari sampai masa panen paling tidak pada dasarian pertama Februari akan ada jaminan ketersediaan air. Selanjutnya mulai bulan Februari berganti menanam palawija karena curah hujan yang cukup rendah pada masa-masa sesudah itu, rata-rata kurang dari 100 mm/bulan. Bahkan pada bulan Maret dasarian kedua sampai April dasarian pertama serta April dasarian ketiga sampai Mei dasarian kedua hampir tidak ada hujan. Sehingga pola tanam yang paling ideal bagi daerah ini adalah padi-palawija-palawija. Hanya yang perlu menjadi catatan adalah permulaan masa tanam yang harus diperhatikan, mengingat kemungkinan adanya fluktuasi musim pada Januari dasarian ketiga dan Februari dasarian pertama.

Hasil peramalan di Jakenan menunjukkan pada tahun 2008 hujan dimulai pada dasarian ketiga November atau bahkan sangat mungkin pada dasarian pertama Desember. Fenomena anomali iklim terjadi pada dasarian ketiga Februari hingga dasarian pertama Maret. Sedangkan sepanjang bulan April diperkirakan masih akan terjadi hujan dengan intensitas sedang. Hal ini mendasari untuk mulai menanam padi pada akhir November atau awal Desember sehingga ada jaminan ketersediaan air sepanjang musim tanam padi dengan perhatian khusus pada akhir Februari dan awal Maret. Diharapkan pada akhir Maret atau awal April sudah bisa panen. Dengan memperhatikan pola musim pada bulan-bulan selanjutnya, pola tanam berikutnya yang paling memungkinkan adalah palawija. Dengan demikian pola tanam yang dikembangkan adalah padi-palawija-palawija. Sangat

riskan untuk menanam padi dua kali setahun mengingat perkiraan curah hujan di daerah ini rata-rata di bawah 100 mm/bulan pada bulan-bulan sesudah Mei.

V. SIMPULAN

Pada penelitian ini telah dikembangkan pemodelan General Regression Neural Network (GRNN) untuk data curah hujan di beberapa daerah di Jawa Tengah dimana pola tanam yang digunakan dengan menggunakan sistem tadah hujan. Program yang digunakan adalah Matlab 7.1 yang sangat fleksibel untuk segera dapat diupdate bagi keperluan peramalan (*on line forecasting*). Model General Regression Neural Network (GRNN) secara umum memberikan prediksi *in-sample* yang lebih baik dari model ARIMA. Sedangkan untuk prediksi *out of sample* memberikan hasil yang berimbang dengan model ARIMA. Berdasarkan hasil peramalan beberapa bulan ke depan pola tanam yang paling sesuai untuk ketiga daerah penelitian adalah padi-palawija-palawija. Perbedaan terjadi pada awal masa tanam karena mempertimbangkan kemungkinan terjadinya anomali iklim.

VI. UCAPAN TERIMA KASIH

Pada kesempatan ini penulis mengucapkan terima kasih kepada Badan Penelitian dan Pengembangan Pemerintah Jawa Tengah yang telah memberikan kesempatan penulis untuk melakukan penelitian melalui Riset Unggulan Daerah serta Badan Meteorologi dan Geofisika Provinsi Jawa Tengah yang telah menyediakan data sehingga penelitian ini dapat dilaksanakan. Semoga kerjasama ini dapat diteruskan pada kesempatan yang lain.

Daftar Pustaka

- Barai, S.V., Dikshit, A.A., Sharma, S., 2006, “*Neural Network Models for Air Quality Prediction : A Comparative Study*”, working paper
- Cigizoglu, H.,K., Askin., P., Ozturk, A., Gurbuz, A., Ayhan, O., Yildiz, M and Ucar, I., 2008, “*Artificial Neural Network Models in Rainfall-Runoff Modelling of Turkish Rivers*”, Istanbul Technical University, working paper.

- Estiningtyas, W. dan Amien, L.I., 2006, "*Pengembangan Model Prediksi Hujan dengan Metode Kalman Filter untuk Menyusun Skenario Masa Tanam*", Balai Besar Litbang Sumberdaya Lahan Pertanian
- Kanevskii, M. F. 1999. "*Spatial Predictions of Soil Contamination Using General Regression Neural Networks*". Switzerland: University of Lausanne.
- Leung, M.T., Chen, A.N., and Daouk, H., 2000, *Forecasting Exchange Rates using General Regression Neural Networks*, *Computers & Operations Research* 27, page 1093-1110
- Popescu, I. and Constantinou P. 2004. "*Generalized Regression Neural Network Prediction Model for Indoor Environment*". Greece: National Technical University of Athens. Specht, D.W., 1991, *General Regression Neural Network*, *IEEE Transactions*,
- Specht, F. D. NOV 1991. "*A General Regression Neural Network* , *IEEE Trans. Neural Networks*". Vol. 2, No.6, hal: 568 576. Sulandari, W., 2004, *Neural Network Model ARMA untuk Prediksi Data Finansial*, Tesis, Universitas Gadjah Mada, Yogyakarta
- Suprihatno, B., Samaullah, Y. Dan Sri, B., 2008, "*Pekan Padi Nasional (PPN) III BB Padi Tampilkan Inovasi Teknologi Galur Harapan Padi Sawah Toleran Kekeringan*", *Sinar Tani* Edisi 23-29 Juli 2008
- Warsito, B., 2006, "*Perbandingan Model FFNN dan GRNN pada Data Nilai Tukar Yen Terhadap Dolar AS*", *Proceeding Seminar Nasional Matematika*, UNDIP Semarang.
- Warsito, B. dan Sumiyati, S., 2007, "*Prediksi Curah Hujan kota Semarang dengan Feedforward Neural Network Menggunakan Algoritma Quasi Newton BFGS dan Levenberg-Marquardt*", *Jurnal PRESIPITASI* Volume 3 No 2 Edisi September, UNDIP Semarang
- Warsito, B., Rusgiyono, A., dan Amirillah, M.A., 2008, "*Pemodelan General Regression Neural Network pada Data Pencemaran Udara di Kota Semarang*", *Jurnal PRESIPITASI* Volume 4 No 1 Edisi Maret, UNDIP