

Optimasi Jaringan Saraf Tiruan Menggunakan Algoritme Genetik Untuk Peramalan Panjang Musim Hujan

¹⁾Agus Buono, ²⁾Maulita Pangesti, ³⁾Ahmad faqih

^{1), 2)}Computer Science Department

Faculty of Mathematic and Natural Science Bogor Agriculture University
Bogor, Indonesia

³⁾Meteorology and Geophysics Department

Faculty of Mathematic and Natural Science Bogor Agriculture University
Bogor, Indonesia

¹⁾pudesh@gmail.com

²⁾maulitapangesti91@yahoo.com

The focus of this research is to predict length of the rainy season in Indramayu using artificial neural networks (ANN) optimized by genetic algorithm (GA). The weights generated by the neural network is random, so the result of predictive value can change in each training. GA is a computational model that has operator selection, crossover, and mutation for generating a new population. The initialization of weights that is given by ANN will optimize using GA. The predictors which are used in this research are southern oscillation index (SOI) data and beginning of rainy season (AMH) data with the length of rainy season data in previous year to predict length of rainy season in current year. The best result is obtained from the model on average region. On this region, the RMSE is amount of 1.4 dasarian and the correlation coefficient between the observed values and predicted values is amount of 0.741 at 10% the significance level, the RMSE is amount of 1.9 dasarian and the correlation coefficient between the observed values and predicted values is amount of 0.694 at 5% the significance level.

Keywords- back propagation, genetic algorithm, length of rainy season, neural network

I. PENDAHULUAN

Indonesia sebagai negara agraris sangat berkepentingan terhadap budidaya pertanian, khususnya padi. Adalah hal yang sudah dipahami bersama bahwa produktifitas pertanian padi di Indonesia sangat berkaitan erat dengan faktor ketersediaan air yang ditentukan oleh kondisi hujan. Salah satu peubah mengenai hujan adalah panjang musim hujan (PMH). Panjang musim hujan, selain menentukan distribusi hujan di musim penghujan juga berpengaruh pada ketersediaan air di musim kemarau. Selain faktor lokal, panjang musim hujan juga dipengaruhi kondisi global. Salah satu index global yang mempunyai korelasi yang kuat dengan panjang musim hujan adalah *Southern Oscillation Index* (SOI),

Adhani dan Buono 2013. Dengan kemajuan teknologi informasi, maka nilai index global, termasuk SOI, sudah tersedia secara bebas dan dapat diunduh melalui internet.

SOI merupakan salah satu index global yang merepresentasikan kondisi global di lautan pacific, dan dikenal dengan nama ENSO (*El-Nino Southern Oscillation*). ENSO merupakan gabungan antara proses di atmosfer dan di samudera yang disebabkan oleh sirkulasi panas dan momentum atmosferik di daerah Pasifik Ekuator, McPhaden 2002. Beberapa variasi hujan yang dipengaruhi ENSO adalah awal musim hujan, nilai curah hujan, serta panjang musim hujan, serta sifat

hujan di musim kemarau, Tjasyono B 2003.

Pada sektor pertanian khususnya di daerah Indramayu yang sebagian besar penduduknya bekerja sebagai petani yang memproduksi padi,musim hujan dapat menguntungkan yaitu dalamirigasi sebagai pengairan di sawah dan sebagai persediaan cadangan air pada saat musim kemarau tiba. Akan tetapi, faktor yang dapat merugikan adalah apabila hujan yang turun terlalu lama dan tidak normal akan menyebabkan gagal panen dalam proses produksinya akibat perairan yang terlalu berlebihan yang tidak mampu diserap oleh tanah. Dari masalah kerugian inilah, timbul suatu ide untuk mencegah terjadinya kegagalan panen tersebut dengan memberikan ketersedian informasi yang akurat tentang lamanya musim hujan untuk para petani sebelum melakukan proses produksi.

Pada penelitian sebelumnya yang berkaitan panjang musim hujan pernah dilakukan oleh Said pada tahun 2011 yang menggunakan jaringan saraf tiruan *resilient backpropagation* dalam memprakirakan panjang musim hujan didapatkan nilai RMSE sebesar 1.0 dasarian. Data yang digunakan sebagai prediktor adalah data suhu permukaan laut atau SST. Diponogoro pada tahun 2013 yang menggunakan *adaptive neuro fuzzy inference system* dalam neramalkan panjang musim hujan didapatkan nilai RMSE 4.09 dasarian. Data yang digunakan sebagai predictor adalah data SOI (*Southern Oscillation Index*) bulan Juli, September, Agustus, Oktober dan Februari, serta data awal musim hujan.

Jaringan saraf tiruan (JST) adalah sistem pemodelan komputasi dengan karakteristik kinerja serupa dengan jaringan saraf tiruan biologis manusia, ausett 1994. Jaringan saraf tiruan bisa digunakan untuk melakukan suatu peramalan, klasifikasi pola, dan clustering, Jain et al 1996. Salah satu

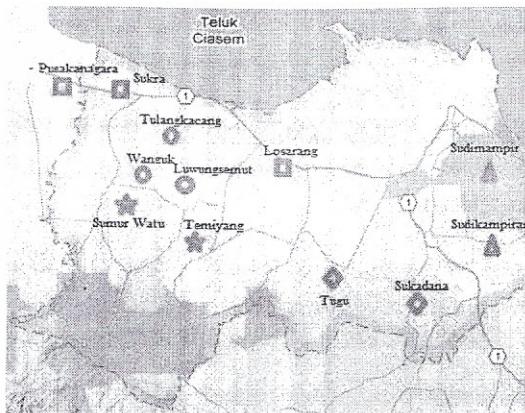
algoritmeJST adalah *backpropagation* atau “alurmundur”. JST *backpropagation* menggunakan *error* untuk mengubah nilai bobot-bobot jaringan dalam arah mundur, sehingga dapat meminimalkan *error* pada saat melakukan peramalan, Kumar,dkk 2008. JST*backpropagation* memiliki kelemahan yaitu salah satunya adalah tidak stabilnya nilai yang dihasilkan dalam beberapa kali pengulangan pelatihan, faktor utamanya adalah data yang tidak mencukupi sebagai bahan pelatihan dalam JST*backpropagation*. Sementara itu algoritme genetika adalah suatu model pencarian berdasarkan pada seleksi alam dan genetik alam. Algoritme genetika digunakan sebagai alat optimisasi yang handal dan efisien untuk ruang masalah yang kompleks, Goldberg 1989.

Bertolak dari hal di atas, maka pada paper ini disajikan suatu pemodelan komputasional untuk memprakirakan panjang musim hujan berdasar index global, yang dalam hal ini adalah *southern oscillation index*. Model komputasional yang diterapkan adalah JST propagasi balik yang inisialisasi bobotnya menggunakan algoritma genetika.

Selanjutnya, paper ini disajikan dengan susunan sebagai berikut: bagian 2 mendeskripsikan metode percobaan, data yang dipergunakan, serta pemrosesan yang dilakukan. Bagian berikutnya difokuskan pada diskusi mengenai hasil dan pembahasan. Akhirnya, pada bagian 4 akan disajikan kesimpulan dari penelitian ini.

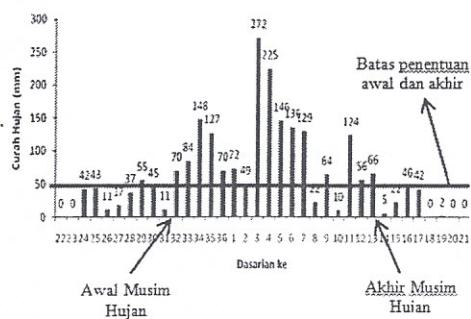
II. DATA DAN METODE

Ada dua jenis data yang dipergunakan dalam Penelitian ini, yaitu data SOI yang diperoleh dengan mengunduh pada website <http://reg.bom.gov.au/climate/glossary/soi.shtml>. Pada website ini tersedia data SOI bulanan sejak tahun 1887. Data kedua adalah observasi hujan harian yang diperoleh di beberapa stasiun hujan di Indramayu yang terbagi dalam 5 wilayah hujan (WH) seperti ditunjukkan Gambar 1.



Gambar 1 Peta wilayah stasiun cuaca Kabupaten Indramayu

Selanjutnya dari data harian tersebut dikonversi menjadi data dasarian yang merupakan jumlah hujan setiap 10 hari. Dengan demikian, dalam satu tahun ada 36 dasarian. Gambar 2 menyajikan pola hujan dasarian, awal musim dan akhir musim hujan. Panjang data observasi curah hujan yang berhasil diperoleh adalah 30 hingga 40 tahun, sesuai dengan wilayah hujannya. Model yang dibangun akan memprediksi nilai rata-rata dari 5 wilayah hujan tersebut maupun per wilayah hujan. Pembagian data latih dan uji adalah seperti disajikan pada Tabel 1. Pengujian dilakukan dengan pengujian 1 tahun ke depan dengan Dalam prediksi tahun, dari tahun

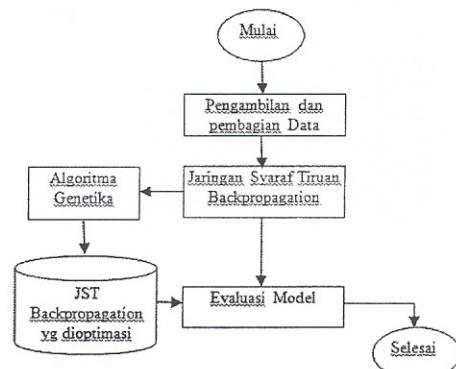


Gambar 2. Contoh pola hujan dasarian, awal musim hujan dan akhir musim hujan

Tabel 1. Pembagian data latih dan data uji per wilayah hujan 1 hingga 5 dan rata-ratanya

	1	2	3	4	5	Rataan
Data Latih	30	20	20	34	29	34.
Data Uji	10	10	10	10	10	10
Jumlah	40	30	30	44	39	44

Selanjutnya percobaan dilakukan dengan mengikuti tahapan seperti disajikan pada Gambar 3.



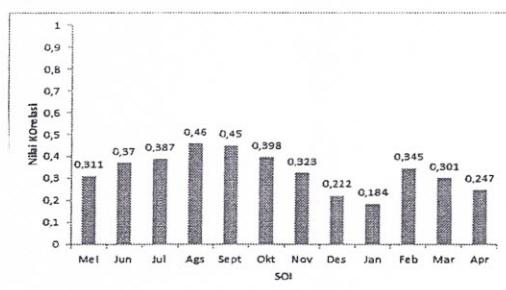
Gambar 3. Blok Diagram Percobaan

III. PEMBAHASAN

Pemilihan Prediktor

Dalam penelitian ini, data yang digunakan ialah data SOI dan data awal musim hujan. Data mencangkup lima kelompok wilayah hujan dengan prediktor sesuai taraf nyata 5% dan 10%. Kelompok data di wilayah hujan pertama yaitu wilayah hujan Pusakanagara, Losarang, Sukra, dan Ujung Garis Kabupaten Indramayu pada tahun 1969-2010, tidak termasuk data tahun 2006/2007. Kelompok data di wilayah hujan kedua yaitu wilayah hujan Sudikampiran dan Sudimampir pada tahun 1978-2010, tidak termasuk data tahun 2002/2003 dan 2006/2007. Kelompok data di wilayah hujan ketiga yaitu wilayah hujan Lw Semut, Teluk Kacang, dan Wanguk pada tahun 1971-2004, tidak termasuk data tahun 1996/1997, 1997/1998, dan 2002/2003. Kelompok data di wilayah hujan keempat yaitu wilayah hujan Rentang, Sukadana, dan Tugu pada tahun 1965-2010, tidak termasuk data tahun 2006/2007. Kelompok data di wilayah pertama yaitu wilayah hujan Sumur Watu, Taminyang, Slamet pada tahun

1970-2010, tidak termasuk data tahun 2006/2007. Gambar 4 menunjukkan nilai korelasi data SOI dengan data panjang musim hujan. Dari grafik tersebut, data SOI yang memenuhi syarat sebagai data sampel taraf nyata 5% yaitu bulan Juli, Agustus, September dan Februari, akan tetapi bulan Februari tidak digunakan sebagai prediktor dikarenakan musim hujan terkadang sudah berhenti, sedangkan pada taraf nyata 10% yaitu bulan Juni, Juli, Agustus, September, Oktober, dan November.



Gambar 4 Grafik nilai korelasi data SOI dengan data panjang musim hujan

Analisis RMSE

Prediksi dilakukan dengan menggunakan JST *backpropagation* dan ST *backpropagation* yang dioptimasi dengan algoritma genetika pada setiap wilayah serta rataan wilayah dengan membandingkan nilai RMSE hasil prediksi.

Tabel 2 menunjukkan nilai galat di setiap wilayah dengan menggunakan JST *backpropagation* maupun JST *stackpropagation* optimasi pada taraf rata 5% dan taraf nyata 10%. Dari tabel tersebut terlihat dengan menggunakan JST *backpropagation* telah optimasi algoritme genetika terkadang tidak membuat nilai galat minimum dan maximum menjadi turun dari JST *backpropagation* belumnya, melainkan dapat turunkan nilai RMSE untuk setiap kelompok. Nilai penurunan tersebut adalah untuk kelompok pertama besar 0.6 dasarian pada taraf nyata

5% dan sebesar 0.4 dasarian pada taraf nyata 10%, kelompok kedua sebesar 0.3 dasarian pada taraf nyata 5% dan sebesar 0.8 dasarian pada taraf nyata 10%, kelompok ketiga sebesar 0.6 dasarian pada taraf nyata 5% dan sebesar 0.3 dasarian pada taraf nyata 10%, kelompok keempat sebesar 0.6 dasarian pada taraf nyata 5% dan sebesar 0.6 dasarian pada taraf nyata 10%, kelompok kelima sebesar 0.6 dasarian pada taraf nyata 5% dan sebesar 0.6 dasarian pada taraf nyata 10%, dan kelompok rataan wilayah sebesar 0.2 dasarian pada taraf nyata 5% dan sebesar 0.1 dasarian pada taraf nyata 10%.

Tabel 2. Nilai galat setiap kelompok wilayah pada taraf nyata 5% dan 10%

		5%		10%	
		JST	JST-GA	JST	JST-GA
WH I	Min	0.05	0.4	0.9	0.2
	Max	4.9	4.5	5.8	4.4
	RMSE	3.6	3.0	2.7	2.3
WH II	Min	0.11	0	0.2	0.75
	Max	5.6	5.6	7.0	5.1
	RMSE	2.5	2.2	2.8	2.0
WH III	Min	0.35	0.22	0.19	0.6
	Max	5.2	3.1	3.7	3.75
	RMSE	2.6	1.8	2.4	2.1
WH IV	Min	0.5	2.5	0.2	1.2
	Max	8.5	6.18	7.4	6.1
	RMSE	4.0	3.4	4.0	3.4
WH V	Min	0.4	0.2	0.56	0.2
	Max	9.1	7.0	5.8	8.4
	RMSE	4.9	4.3	4.47	3.9
Rataan Wilayah	Min	0.7	0.8	0.07	0.03
	Max	4.6	4.5	3.7	3.5
	RMSE	2.1	1.9	1.5	1.4

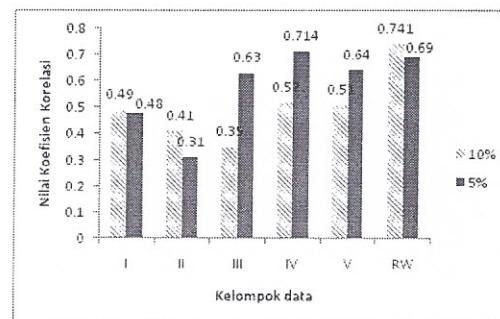
Dari tabel tersebut juga terlihat rentang nilai galat bervariasi, pada taraf nyata 5% rentang nilai galat tertinggi hasil JST *backpropagation* optimasi sebesar 6.8 pada kelompok kelima dengan nilai RMSE sebesar 4.3

dasarian. Pada taraf nyata 10% rentang nilai galat tertinggi hasil JST *backpropagation* optimasi sebesar 8.2 pada kelompok kelima dengan nilai RMSE sebesar 3.9 dasarian. Hal ini menunjukkan, nilai RMSE tidak dipengaruhi dengan rentang galat, Nilai RMSE dipengaruhi dari sebaran galat beragam dan besar yang akan menyebabkan nilai RMSE besar. Pada taraf nyata 5% rataan nilai RMSE dengan JST *backpropagation* di lima wilayah sebesar 3,28 dasarian atau kesalahan dalam memprediksi panjang musim hujan sebesar 32 hari, sedangkan rataan nilai RMSE dengan JST *backpropagation* yang telah dioptimasi di lima wilayah sebesar 2,78 dasarian atau kesalahan dalam memprediksi panjang musim hujan sebesar 27 hari. Dan pada taraf nyata 10% rataan nilai RMSE dengan JST *backpropagation* di lima wilayah sebesar 3,11 dasarian atau kesalahan dalam memprediksi panjang musim hujan sebesar 31 hari, sedangkan rataan nilai RMSE dengan JST *backpropagation* yang telah dioptimasi di lima wilayah sebesar 2.51 dasarian atau kesalahan dalam memprediksi panjang musim hujan sebesar 25 hari.

Analisis Korelasi Sederhana

Hasil korelasi antara nilai prediksi dengan nilai observasi dengan menggunakan JST *backpropagation* optimasi dilakukan dengan perhitungan di setiap wilayah hujan. Koefisien korelasi dibutuhkan untuk mengetahui keterikatan hubungan antara nilai prediksi dan nilai observasi, jika nilai koefisien korelasi bernilai positif, maka nilai prediksi dan nilai observasi berbanding lurus. Hal ini berarti, semakin tinggi nilai observasi yang ada, maka nilai prediksi juga semakin tinggi. Hasil koefisien korelasi di setiap wilayah hujan didapatkan dengan melakukan perhitungan. Pada taraf nyata 5% nilai koefisien korelasi tertinggi sebesar 0.714 pada rataan

wilayah, sedangkan nilai koefisien korelasi terkecil sebesar 0.31 pada wilayah hujan II. Dan pada taraf nyata 10% nilai koefisien korelasi tertinggi sebesar 0.741 pada rataan wilayah, sedangkan nilai koefisien korelasi terkecil sebesar 0.35 pada wilayah III.



Gambar 5 Perbandingan nilai koefisien korelasi antara nilai prediksi dengan nilai observasi di setiap wilayah pada JST *backpropagation* yang dioptimasi. RW merupakan perataan wilayah

Gambar 5 menunjukkan nilai perbandingan koefisien korelasi di setiap wilayah hujan. Pada taraf nyata 10% nilai koefisien korelasi di kelompok wilayah hujan I sebesar 0.49 sehingga nilai koefisien determinasi di kelompok ini sebesar 0.24 atau 24%. Hal ini berarti sebanyak 24% dari nilai observasi dapat digambarkan hubungan lininya terhadap nilai prediksi yang terdapat pada kelompok wilayah hujan tersebut, sedangkan Pada taraf nyata 5% nilai koefisien korelasi di kelompok wilayah hujan I sebesar 0.48 sehingga nilai koefisien determinasi di kelompok ini sebesar 0.23 atau 23%. Hal ini berarti sebanyak 23% dari nilai observasi dapat digambarkan hubungan lininya terhadap nilai prediksi yang terdapat pada kelompok wilayah hujan tersebut.

Pada taraf nyata 10% nilai koefisien korelasi di kelompok wilayah hujan II sebesar 0.41 sehingga nilai koefisien determinasi di kelompok ini sebesar 0.16 atau 16%. Hal ini berarti sebanyak 16% dari nilai observasi dapat digambarkan hubungan lininya terhadap nilai prediksi yang terdapat

pada kelompok wilayah hujan tersebut, sedangkan pada taraf nyata 5% nilai koefisien korelasi di kelompok wilayah hujan II sebesar 0.31 sehingga nilai koefisien determinasi di kelompok ini sebesar 0.10 atau 10%. Hal ini berarti sebanyak 10% dari nilai observasi dapat digambarkan hubungan liniernya terhadap nilai prediksi yang terdapat pada kelompok wilayah hujan tersebut.

Pada taraf nyata 10% nilai koefisien korelasi di kelompok wilayah hujan III sebesar 0.35 sehingga nilai koefisien determinasi di kelompok ini sebesar 0.12 atau 12%. Hal ini berarti sebanyak 12% dari nilai observasi dapat digambarkan hubungan liniernya terhadap nilai prediksi yang terdapat pada kelompok wilayah hujan tersebut, sedangkan pada taraf nyata 5% nilai koefisien korelasi di kelompok wilayah hujan III sebesar 0.63 sehingga nilai koefisien determinasi di kelompok ini sebesar 0.39 atau 39%. Hal ini berarti sebanyak 39% dari nilai observasi dapat digambarkan hubungan liniernya terhadap nilai prediksi yang terdapat pada kelompok wilayah hujan tersebut.

Pada taraf nyata 10% nilai koefisien korelasi di kelompok wilayah hujan IV sebesar 0.52 sehingga nilai koefisien determinasi di kelompok ini sebesar 0.27 atau 27%. Hal ini berarti sebanyak 27% dari nilai observasi dapat digambarkan hubungan liniernya terhadap nilai prediksi yang terdapat pada kelompok wilayah hujan tersebut, sedangkan pada taraf nyata 5% nilai koefisien korelasi di kelompok wilayah hujan IV sebesar 0.714 sehingga nilai koefisien determinasi di kelompok ini sebesar 0.51 atau 51%. Hal ini berarti sebanyak 51% dari nilai observasi dapat digambarkan hubungan liniernya terhadap nilai prediksi yang terdapat pada kelompok wilayah hujan tersebut.

Pada taraf nyata 10% nilai koefisien korelasi di kelompok wilayah hujan V sebesar 0.51 sehingga nilai koefisien determinasi di kelompok ini sebesar 0.26 atau 26%. Hal ini berarti sebanyak

26% dari nilai observasi dapat digambarkan hubungan liniernya terhadap nilai prediksi yang terdapat pada kelompok wilayah hujan tersebut, sedangkan pada taraf nyata 5% nilai koefisien korelasi di kelompok wilayah hujan V sebesar 0.64 sehingga nilai koefisien determinasi di kelompok ini sebesar 0.40 atau 40%. Hal ini berarti sebanyak 40% dari nilai observasi dapat digambarkan hubungan liniernya terhadap nilai prediksi yang terdapat pada kelompok wilayah hujan tersebut.

Pada taraf nyata 10% nilai koefisien korelasi di kelompok perataan wilayah hujan sebesar 0.741 sehingga nilai koefisien determinasi di kelompok ini sebesar 0.55 atau 55%. Hal ini berarti sebanyak 55% dari nilai observasi dapat digambarkan hubungan liniernya terhadap nilai prediksi yang terdapat pada kelompok wilayah hujan tersebut, sedangkan pada taraf nyata 5% nilai koefisien korelasi di kelompok perataan wilayah hujan sebesar 0.69 sehingga nilai koefisien determinasi di kelompok ini sebesar 0.47 atau 47%. Hal ini berarti sebanyak 47% dari nilai observasi dapat digambarkan hubungan liniernya terhadap nilai prediksi yang terdapat pada kelompok wilayah hujan tersebut.

Analisis Kelompok Terbaik

Hasil yang telah didapatkan dari semua data kelompok wilayah hujan di Indramayu, dievaluasi berdasarkan nilai koefisien korelasi dan nilai RMSE. Dari semua data kelompok, kelompok wilayah hujan rata-rata yang memiliki nilai koefisien korelasi dan nilai RMSE yang baik pada taraf nyata 5% dan 10%. Hasil nilai koefisien terkecil didapatkan pada kelompok data wilayah I sebesar 0.31 pada taraf nyata 5% dan pada taraf 10% sebesar 0.35 di kelompok data wilayah III. Nilai RMSE terkecil pada taraf nyata 5% sebesar 1.8 dasarian yang terdapat pada kelompok wilayah III dan pada taraf nyata 10% sebesar 1.6 dasarian pada perataan wilayah.

Dari hasil evaluasi terhadap data prediksi yang didapatkan dari semua kelompok data wilayah hujan masih terdapat kekurangan. Ada beberapa faktor yang mempengaruhi hasil prediksi. Faktor pertama adalah data latih yang tidak mencukupi, sehingga pembentukan pola yang tidak teratur yang akan menghasilkan nilai prediksi yang kuarang akurat. Faktor kedua adalah program ini menggunakan nilai peluang pada saat melakukan perpindahan silang, seringkali mengakibatkan titik potong yang tidak tepat sehingga hasil yang didapatkan kurang maksimal. Faktor ketiga adalah pola data latih yang tidak beraturan, yang mengakibatkan hasil prediksi memiliki nilai galat yang besar atau kurang mendekati nilai observasi.

IV. KESIMPULAN

Dari hasil penelitian yang dilakukan, penggunaan algoritma genetika dalam hal mengoptimasi bobot awal JST *backpropagation* dapat menghasilkan hasil prediksi yang mendekati nilai observasi sehingga *error* yang dihasilkan pun dapat diminimalkan daripada menggunakan JST *backpropagation* tanpa optimasi. Hasil terbaik didapatkan pada data kelompok wilayah hujan rata-rata pada taraf nyata 5% ataupun 10% dengan nilai koefisien korelasi sebesar 0.69 dan 0.741, serta nilai RMSE sebesar 1.4 dasarian dan 1.6 dasarian. Prediktor yang digunakan adalah data SOI bulan Juni, Juli, Agustus, September, Oktober, dan November untuk taraf nyata 10% dan data SOI bulan Juli, Agustus, dan Septemeber untuk taraf nyata 5%, serta data awal musim hujan baik taraf nyata 5% atau 10%.

Saran untuk penelitian selanjutnya bisa menambahkan karakteristik lain pada algoritma genetika yaitu bisa

menambahkan elitisme atau metode seleksi lainnya, metode *crossover* dalam penentuan posisi gen saat pindah silang, mutasi yang lebih terarah, serta metode fungsi fitness yang lebih baik, sehingga dapat menghasilkan nilai peramalan panjang musim hujan yang memiliki *error* yang lebih baik.

ACKNOWLEDGMENT

Penulisan mengucapkan terima kasih kepada Center for Climate Risk and Opportunity Management in Southeast Asia and Pacific (CCROM-SEAP IPB) yang telah menyediakan data dan Kementerian Pendidikan Nasional atas dukungan sebagian dana dalam penulisan paper ini melalui skema BOPTN IPB.

DAFTAR PUSTAKA

- [1] Diponogoro AB. 2013. Peramalan Panjang Musim Hujan Menggunakan *Adaptive Neuro Fuzzy Inference System* [Skripsi]. Bogor: Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Pertanian Bogor.
- [2] Fausett L. 1994. *Fudamentals of Neural Networks*. New Jersey(US):Prentice Hall.
- [3] Golberg DE. 1989. *Genetic Algorithms in Search, Optimization & Machine Learning*. Boston(US): Addison-Wesley.
- [4] Jain AK, Mao J, Mohiuddin K. 1996. Artificial Neural Network : A Tutorial. *IEEE Comput.* 29(3):31-44.
- [5] Kumar PR, Murthy MVR, Eashwar D, Venkatdas M. 2005. Times Series Modeling Using Artificial Neural Networks. *JATIT*. Volume tidak diketahui(Edisi tidak diketahui):1259-1264.
- [6] McPhaden, M. J., 2002. El Niño and La Niña: Causes and global consequences. *Encyclopedia of Global Environmental Change*, Anonymous John Wiley and Sons, LTD, 353-370.
- [7] Said MM. 2011. Peramalan Panjang Musim Hujan Ressilient *Backpropagation* [Skripsi]. Bogor: Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Pertanian Bogor.
- [8] Tjasyono B, Bannu. 2003. Dampak ENSO pada Faktor Hujan di Indonesia. *Mathematics and Sains*.8(1):15-22.