

PERAMALAN AWAL MUSIM HUJAN MENGGUNAKAN JARINGAN SYARAF TIRUAN BACKPROPAGATION LEVENBERG-MARQUARDT

Agus Buono¹, Alif Kurniawan¹, dan Akhmad Faqih²

¹Departemen Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Pertanian Bogor
Jl. Raya Darmaga - Bogor Jawa Barat
Telp./Fax (0251) 8625584

² Center For Climate Risk and Opportunity Management (CCROM) IPB
Jl. Raya Pajajaran - Bogor Jawa Barat
Telp./Fax (0251) 88313709
E-mail: pudesha@yahoo.co.id

ABSTRAK

Penelitian ini difokuskan pada pemodelan Jaringan Syaraf Tiruan propagasi balik Levenberg-Marquardt untuk prediksi Awal Musim Hujan (AMH), dengan mengambil studi kasus Kabupaten Indramayu. Peubah yang dipergunakan sebagai prediktor adalah Southern Oscillation Index (SOI). Pemilihan bulan untuk data SOI berdasar nilai korelasi pada taraf nyata 5%. Sedangkan peubah respon adalah awal musim hujan satu periode ke depan yang diukur dalam dasarian (10 harian). Dari 30 tahun periode data (1978-2007), selanjutnya dilakukan pemodelan JST dengan 4 variasi jumlah hidden neuron (5, 10, 15 dan 20) dan divalidasi dengan metode Leave One Out (LOO) cross validation untuk melihat skil dari model dalam melakukan prediksi. Hasil percobaan menunjukkan bahwa SOI bulan Juni, Juli dan Agustus mempunyai korelasi yang kuat dengan awal musim hujan, dengan korelasi masing-masing sebesar -0.46, -0.368, dan -0.364. Berdasar SOI pada 3 bulan tersebut dibangun model JST dengan output AMH. Skil model JST diukur menggunakan korelasi antara observasi dengan hasil prediksi. Korelasi tertinggi diperoleh dengan menggunakan hidden neuron 20, yaitu sebesar 0.99. Sedangkan untuk hidden neuron 5, 10 dan 15 masing-masing menghasilkan prediksi dengan korelasi sebesar 0.58, 0.7 dan 0.8.

Kata kunci: Awal Musim Hujan (AMH), Souther Oscillation Index (SOI), Dasarian, Jaringan Syaraf Tiruan (JST), Leave One Out (LOO) cross validation.

1. PENDAHULUAN

1.1 Latar Belakang

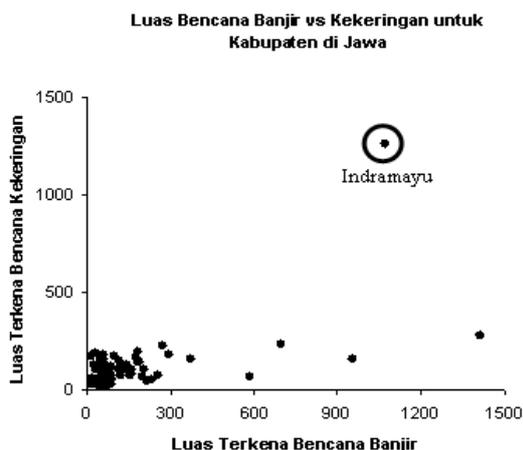
Keragaman hasil produksi padi di Indonesia sangat berkaitan erat dengan keragaman curah hujan. Baik pada saat curah hujan di atas rata-rata ataupun curah hujan di bawah rata-rata. Berdasar data yang ada, 81% kegagalan panen disebabkan oleh variabilitas iklim, dan 19% dikarenakan serangan hama (Boer et al. 2008). Dari kegagalan yang disebabkan variabilitas iklim tersebut, 90% berupa bencana kekeringan yang terjadi pada masa pertanaman kedua. Hal ini diperparah jika awal musim hujan mengalami kemunduran. Dengan mundurnya awal musim hujan, maka penanaman juga mengalami kemunduran, sehingga penanaman padi masa tanam pertama berkurang. Hal ini dikompensasi oleh petani dengan meningkatkan penanaman padi pada musim tanam kedua. Pertanaman pada pada musim tanam kedua ini rawan terhadap kekeringan, khususnya jika panjang musim hujan adalah pendek dan sifat hujan di musim kemarau adalah di bawah normal. Untuk meminimalisasi risiko bencana kekeringan tersebut diperlukan informasi mengenai awal musim hujan dan panjang musim serta sifat hujan di musim kemarau. Dengan informasi ini, maka bisa

dirumuskan langkah-langkah antisipasi untuk menekan risiko gagal panen.

Lo et al., 2007 dan Robertson et al., 2009 menunjukkan secara empiris adanya pengaruh dari feneomena global seperti ENSO (El Nino Southern Oscillation), IOD (Indian Ocean Dipole), SOI (Souther Oscillation Index) dan lainnya terhadap peubah-peubah iklim lokal tersebut di atas. Haylock 2001 menunjukkan adanya korelasi yang kuat antara SOI dengan karakteristik hujan di Indonesia. Said 2011 memodelkan jaringan syaraf tiruan untuk prediksi panjang musim hujan berdasar SOI dengan korelasi antara observasi dengan hasil prediksi sebsar 0.84. Hung 2009 menggunakan jaringan syaraf tiruan untuk prediksi awal musim hujan di Thailand berdasar fenomena global tersebut di Samudera Pasifik. Akurasi dari model yang dibangun adalah adanya korelasi 0.94 antara obseravsi dengan prediksi. ³Buono et al 2010 memodelkan jaringan syaraf tiruan untuk downscaling data General Circular Model untuk prediksi curah hujan di Indramayu dan memberikan akurasi berupa korelasi antara observasi dengan hasil prediksi sekitar 0.70. Dengan demikian, informasi mengenai fenomema global dapat dimanfaatkan untuk melakukan prediksi iklim lokal yang selanjutnya menjadi masukan dalam

memutuskan langkah adaptasi sehingga kerugian yang terjadi dapat diminimalkan.

Penelitian yang dilakukan ini bertujuan membuat model jaringan syaraf tiruan untuk prediksi awal musim hujan dengan mengambil studi kasus di Indramayu. Pemilihan lokasi ini didasarkan bahwa Indramayu merupakan wilayah lumbung padi nasional dan bersifat rawan terhadap bencana karena iklim, baik yang berupa banjir maupun kekeringan seperti diperlihatkan pada Gambar 1 (^bBuono et al 2010).



Gambar 1. Posisi Indramayu terhadap Kabupaten lain di Jawa berdasar Luas Bencana Banjir dan Kekeringan

Selanjutnya paper ini disajikan dengan susunan sebagai berikut : Bagian 2 mengenai data dan metodologi. Hasil dan Pembahasannya disajikan pada bagian 3. Sebagai penutup adalah kesimpulan dan saran untuk penelitian selanjutnya yang disajikan pada bagian 4.

2. DATA DAN METODOLOGI

2.1 Data

Ada dua jenis data yang dipergunakan dalam penelitian ini, yaitu data observasi iklim di stasiun-stasiun curah hujan di Indramayu dan data SOI yang keduanya tersedia dari tahun 1978 hingga 2008. Data awal musim hujan diperoleh dari BMKG (Badan Meteorologi Klimatologi dan Geofisika), dan data SOI dari Badan Meteorologi Australia melalui website.

Awal musim hujan dihitung dengan satuan dasarian (yaitu 10-harian). Dalam 1 tahun ada 36 dasarian, dimulai dasarian pertama di 10 hari pertama pada Bulan Januari dan dasarian ke 36 pada 10 hari terakhir di Bulan Januari. SOI merupakan perbandingan antara tekanan udara di Pulau Tahiti dengan tekanan udara di Darwin Australia dan dirumuskan sebagai :

$$SOI = 10 \frac{[P_{diff} - P_{diffav}]}{SD(P_{diff})}$$

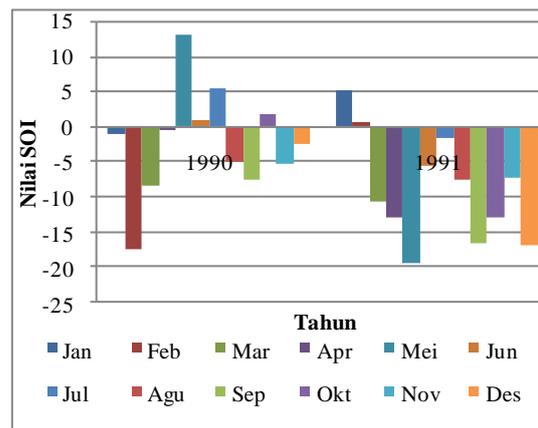
Dengan :

$$P_{diff} = (\text{rata-rata MSLP Tahiti per bulan}) - (\text{rata-rata MSLP Darwin per bulan})$$

$$P_{diffav} = \text{rata-rata } P_{diff} \text{ pada bulan yang dicari.}$$

$$SD_{(P_{diff})} = \text{standar defiasi dari } P_{diff} \text{ dari bulan yang dicari}$$

Perkalian dengan 10 adalah suatu konvensi sehingga nilai rentang dari SOI pada interval [-35,35]. Gambar 2 menyajikan contoh perhitungan SOI tahun 1990 sampai dengan tahun 1991 oleh Badan Meteorologi Australia.



Gambar 2. Data SOI 1990-1991

Kalau pada Said 2011, peubah prediktor adalah suhu permukaan laut pada Bulan Juni, Juli dan Agustus, maka pada penelitian ini adalah SOI dengan bulan yang didasarkan pada analisis korelasi antara awal musim hujan dengan SOI dengan taraf nyata 95%.

2.2 Metodologi

Tahapan penelitian yang dilakukan adalah mengikuti diagram alur seperti disajikan pada Gambar 3. Setelah diperoleh data awal musim hujan (dari BMKG Jakarta) dan SOI (dari website Badan Meteorologi Australia), selanjutnya dilakukan analisis korelasi untuk memilih bulan dari SOI yang dipergunakan sebagai prediktor. Setelah terpilih bulan untuk data SOI yang dipergunakan sebagai prediktor, maka selanjutnya membagi data menjadi 2 bagian, yaitu data latih dan data uji. Dari data latih dibuat model JST propagasi balik Levenberg-Marquardt untuk setiap jumlah neuron hidden (5, 10, 15 dan 20). Persamaan matematika untuk menentukan bobot baru pada algoritma Levenberg-Marquardt adalah (Bishop 1995) :

$$w_{new} = w_{old} - (Z^T Z)^{-1} Z^T \epsilon(w_{old})$$

dengan

w_{new} = bobot baru

w_{old} = bobot lama

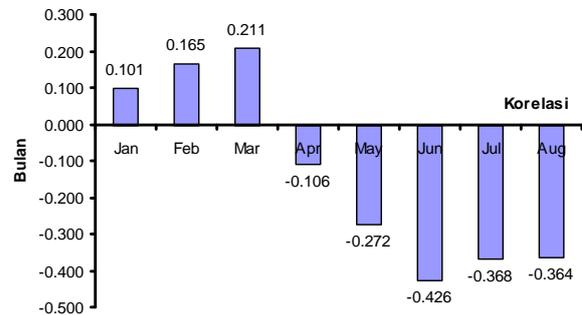
= vektor galat

Z = matrix yang anggotanya adalah hasil diferensial galat terhadap bobotnya.

Setelah itu dilakukan pengujian menggunakan data uji. Dalam penelitian ini, proses percobaan dilakukan dengan menggunakan metode LOO (*Leave One Out Cross Validation*). Dari 30 data (tahun 1978-2007), satu periode sebagai data uji dan 29 periode lainnya sebagai data latih. Proses ini dilakukan 30 kali. Berdasar hasil validasi silang ini dilakukan analisis untuk mengetahui kinerja model JST dalam memprediksi AMH.

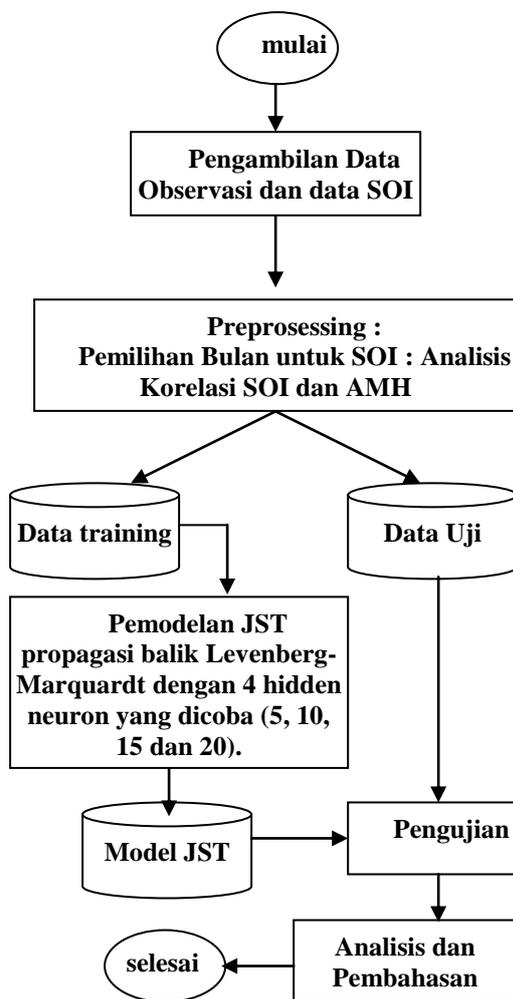
Oleh karena awal musim hujan biasanya sekitar Bulan Oktober dan dengan pertimbangan bahwa BMKG menyediakan prediksi pada 3 bulan sebelumnya, maka bulan SOI yang dihitung untuk dicek pengaruhnya adalah Bulan Januari hingga Agustus.

Juli dan Agustus. Oleh karena itu selanjutnya berdasar SOI ini dibangun model JST.

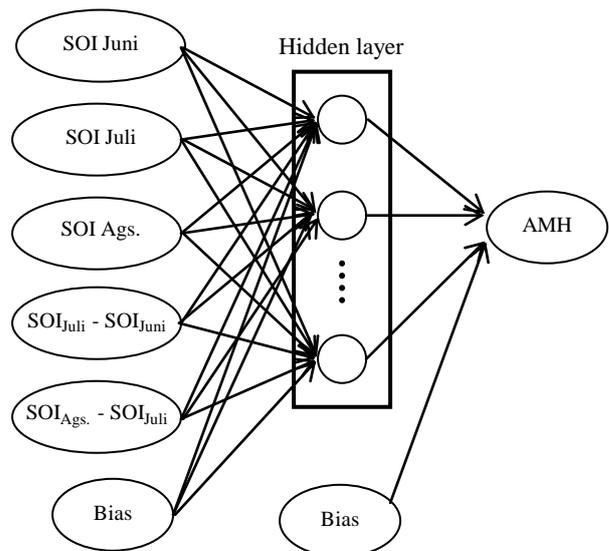


Gambar 4. Nilai Korelasi antara SOI Bulan Januari hingga Agustus dengan AMH

Dalam hal ini ada 5 peubah input, yaitu : SOI Bulan Juni, Bulan Juli, Bulan Agustus dan selisih SOI antara Bulan Juli dengan SOI Bulan Juni dan selisih SOI Bulan Agustus dengan SOI Bulan Juli. Neuron hidden yang dicoba adalah 5, 10, 15 dan 20, sehingga arsitektur jaringan adalah seperti disajikan pada Gambar 5.



Gambar 3. Diagram Alur Percobaan



Gambar 5. Arsitektur JST untuk Model Prediksi AMH dengan 6 Neuron Input

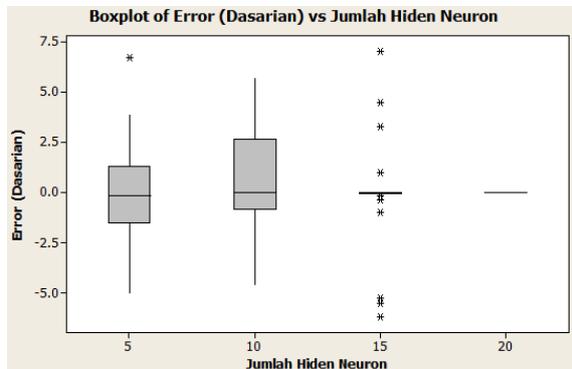
3. HASIL DAN PEMBAHASAN

3.1 Analisis Korelasi Pemilihan Bulan

Analisis korelasi antara SOI mulai Bulan Januari hingga Agustus disajikan pada Gambar 4. Berdasar uji statistik untuk nilai korelasi pada taraf uji 5%, diperoleh hasil bahwa SOI yang secara nyata mempengaruhi AMH adalah SOI Bulan Juni,

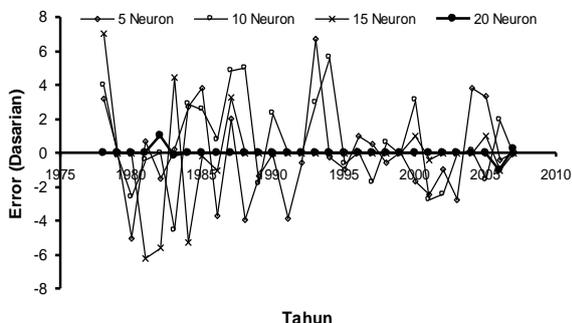
Perbandingan hasil prediksi dari ke empat arsitektur tersebut disajikan pada Gambar 6. Dari gambar tersebut terlihat bahwa JST dengan hidden neuron sebanyak 20 memberikan akurasi terbaik, yaitu hampir semuanya tepat. Kesalahan yang terjadi tidak lebih dari satu dasarian. Sedangkan untuk JST dengan 5 hidden neuron mempunyai rentang kesalahan cukup besar dari -5 hingga 6 dasarian, dengan mayoritas kesalahannya pada rentang 1 dasarian (baik maju maupun mundur). Untuk JST dengan 10 neuron hidden, kesalahan sebagian terjadi pada rentang dasarian maju dan 2

hingga 3 dasarian mundur. Untuk JST dengan 15 hidden neuron memberikan akurasi cukup baik, yaitu hampir semuanya tepat, namun ada beberapa tahun yang diprediksi jauh dari nilai sebenarnya.



Gambar 6. Boxplot Perbandingan Tingkat Kesalahan (dalam Dasarian) dari 4 Arsitektur JST

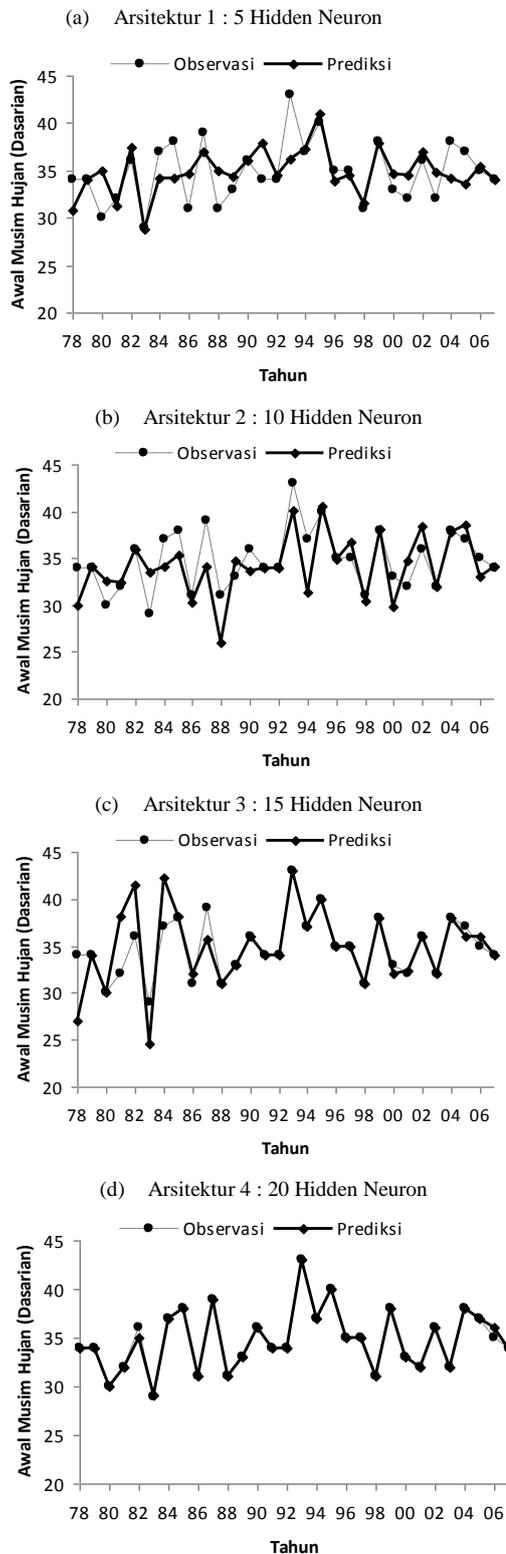
Kalau dilihat lebih lanjut mengenai tahun-tahun yang sulit diprediksi, terlihat bahwa masing-masing model memberikan informasi yang berbeda seperti ditunjukkan pada Gambar 7. Dari gambar tersebut terlihat tidak ada kemiripan mengenai pola kesalahan. Sementara itu, arsitektur JST dengan 20 neuron hidden memberikan akurasi yang sangat baik. Kesalahan signifikan sebesar 1 dasarian terjadi pada tahun 2006, yaitu maju 1 dasarian.



Gambar 7. Pola Kesalahan Prediksi (Dalam Dasarian) dari Setiap Arsitektur JST

Gambar 8 memberikan perbandingan antara pola data observasi dengan pola hasil prediksi dari tahun 1978 hingga 2007. Dengan 5 neuron hidden terlihat bahwa kesalahan prediksi awal musim hujan mencapai 7 dasarian maju yang terjadi pada tahun 1993. Pada tahun 1980 terjadi salah prediksi 5 dasarian mundur. Hal yang hampir sama juga terjadi pada JST dengan 10 neuron hidden, dengan kesalahan prediksi yang lebih kecil, yaitu 5 dasarian maju (1994) dan 3 dasarian mundur (1980). Dengan 15 hidden neuron, tingkat kesalahan makin kecil, dan terjadi pada sebelum tahun 1990, dengan kesalahan tertingginya adalah 5 dasarian mundur (1983). JST dengan 15 dasarian memberikan akurasi yang sangat baik, hampir semuanya tepat,

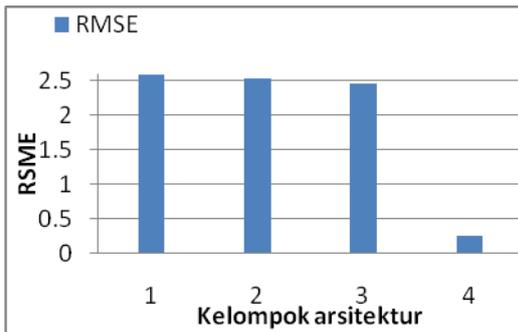
kecuali pada tahun 2006. Pada tahun ini AMH prediksi mundur 1 dasarian



Gambar 8. Perbandingan Pola Observasi dengan Pola Prediksi Hasil JST pada 4 Jenis Neuron Hidden

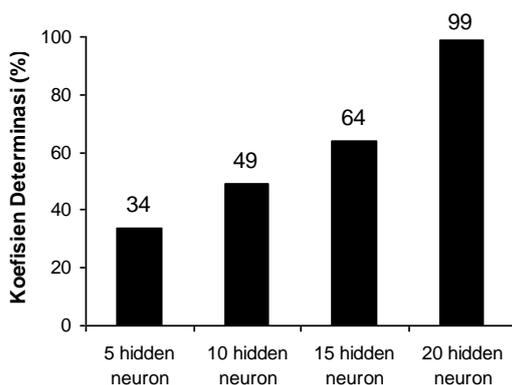
Jaringan syaraf tiruan dengan 20 hidden neuron juga memberikan prediksi dengan ketelitian yang

tinggi. Hal ini ditunjukkan dengan nilai root mean square error (RMSE) yang kecil dibandingkan dengan 3 model lainya seperti terlihat pada Gambar 9. Dari gambar ini terlihat bahwa nilai RMSE dari JST dengan 20 neuron hidden adalah sekitar 0.25. Hal ini berarti hampir semua nilai prediksi mempunyai kesalahan di bawah 0.25 dasarian. Oleh karena itu, jika dilakukan pembulatan terhadap nilai prediksi, maka hasil prediksi AMH akan persis sama dengan nilai observasi.



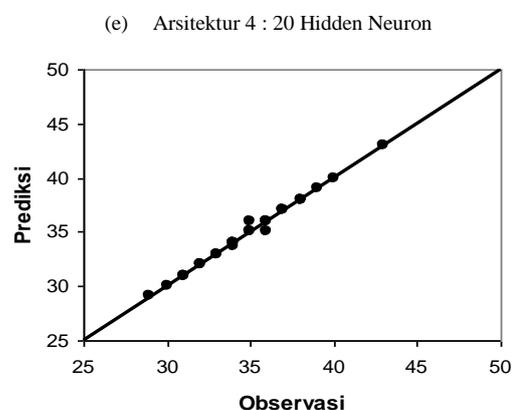
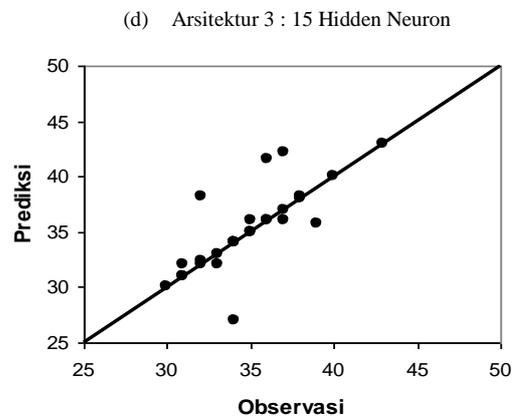
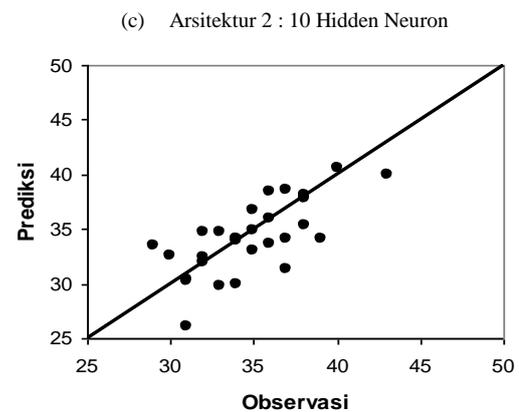
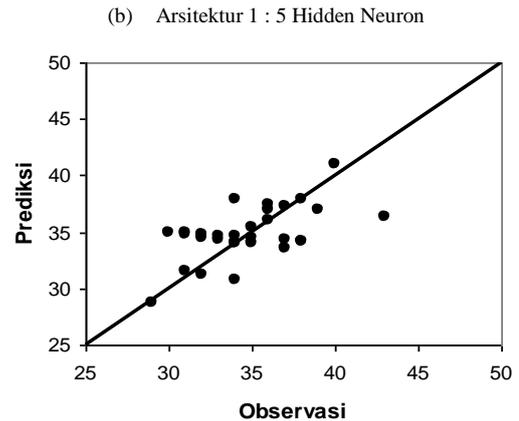
Gambar 9. Grafik Perbandingan Nilai RMSE dari 4 Arsitektur JST

Jika dilakukan fitting antara nilai observasi dengan nilai prediksi terlihat bahwa koefisien determinasinya meningkat dari 34% menjadi 99% dari JST dengan 5 hidden neuron ke JST dengan 20 hidden neuron seperti diperlihatkan pada Gambar 10. Fakta ini mengatakan bahwa model JST Levenberg-Marquardt dengan 20 neuron hidden dan input SOI bulan Juni, Juli, Agustus, selisih SOI bulan Juli dengan Juni dan selisih SOI bulan Agustus dengan Juli mampu memberikan hasil prediksi sangat baik.



Gambar 10. Koefisien Determinasi hubungan AMH Observasi vs Prediksinya untuk 4 Jenis JST

Gambar 11 menyajikan scatter plot antara prediksi dengan observasi. Dari gambar tersebut terlihat bahwa semua model memberikan prediksi yang tidak underestimate dan juga tidak overestimate, semuanya berkisar di sekitar garis $y=x$.



Gambar 11. Plot antara Observasi AMH dengan Nilai Prediksinya untuk 4 Jenis JST

4. KESIMPULAN

Berdasar percobaan yang sudah dilakukan ada beberapa kesimpulan yang bisa disajikan disini, yaitu bahwa SOI Bulan Juni, Juli dan Agustus dapat dipergunakan sebagai prediktor dalam memprediksi AMH satu periode ke depan dengan korelasi berkisar dari -0.36 hingga -0.42. Dalam hal ini jika SOI bernilai negatif, maka ada kecenderungan bahwa AMH makin besar, yang berarti musim hujan mundur.

Dugaan AMH dari Model JST Levenberg-Marquardt mempunyai rata-rata yang sesuai dengan observasi (tidak overestimate dan tidak underestimate) dengan nilai korelasi berkisar dari 0.6 hingga 0.99. Model terbaik adalah JST dengan jumlah neuron hidden sebanyak 20 yang menghasilkan RMSE 0.25. Sementara itu model terjelek adalah dengan 5 neuron hidden yang menghasilkan prediksi dengan RMSE 2.5. Hal ini berarti nilai prediksinya sebagian besar mundur atau maju 2.5 dasarian.

UCAPAN TERIMA KASIH

Penelitian ini adalah bagian dari Proyek IM-HERE B2c IPB yang dibiayai oleh Pemerintah Indonesia melalui kontrak No. 7/13.24.4/SPP/I-MHERE/2011. Penulis juga mengucapkan terima kasih kepada BMKG yang menyediakan data Awal Musim Hujan

PUSTAKA

Bishop Christopher M. 1995. *Neural Network for Pattern Recognition*. Oxford University Press Inc, New York.

^{a)}Buono, et. al. 2010. A Principle Component Analysis Cascade with Multivariate Regression for Statistical Downscaling Technique : A Case Study in Indramayu District. Proceedings dalam International Conference in Computer Science and Information System (ICACISIS), November 2010, Bali Indonesia, ISSN 2086-1796, Hal. 321-327

^{b)}Buono, et al. 2010. A Neural Network Architecture for Statistical Downscaling Technique : A Case Study in Indramayu District. Proceedings AFITA 2010 International Conference The Quality Information For Competitive Agricultural Based Production System and Commerce, ISSN 978-979-493-277-3

Haylock Malcolm, McBride John. 2001. Spatial Coherence and Predictability of Indonesian Wet Season Rainfall. *Journal of Climate* 14:3882-3887.

Hung NQ, MS Babel, S Weesakul, NK Tripathi. 2009. An Artificial neural network model for rainfall forecasting in Bangkok, Thailand. *Hydrology and Earth System Sciences* 13:1413-1425

Lo, F., Wheeler, M.C., Meinke, H. and Donald, A., 2007. Probabilistic forecasts of the onset of the North Australian wet season. *Monthly Weather Review*, 135, 3506–3520.

Rizaldi Boer, 2008. *Climate Change impact and adaptation in Indonesia*. Discussion on Climate Change Impact, Friend of Earth, Tokyo, Japan.

Robertson, A. W. , V. Moron, and Y. Swarinoto, 2009. Seasonal predictability of daily rainfall statistics over Indramayu district, Indonesia. *Int. J. Climatology*, 29, 1449-1462.

Said MM. 2011. *Peramalan Panjang Musim Tiruan Resilient Backpropagation* [skripsi]. Bogor: Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Pertanian Bogor.