

Pemodelan Jaringan Syaraf Tiruan Untuk Memprediksi Awal Musim Hujan Berdasarkan Suhu Permukaan Laut

Artificial Neural Network Modeling To Predict The Beginning of Rainy Season Based On Sea Surface Temperature

LAILA SARI LUBIS, AGUS BUONO*

Abstrak

Anjatan, Indramayu adalah salah satu daerah pertanian di Indonesia. Keberhasilan atau kegagalan panen setiap tahun tergantung pada ketersediaan air di wilayah tersebut. Oleh karena itu, diperlukan suatu metode yang akurat untuk memprediksi awal musim hujan. Metode yang digunakan untuk prediksi dalam penelitian ini adalah jaringan saraf tiruan (JST) *back-propagation*. Hasil akurasi prediksi JST diukur dengan R^2 dan RMSE. Penelitian ini menggunakan suhu permukaan laut (SST) ECHAM4p5_CA yang merupakan salah satu model suhu permukaan laut di bulan Juni, Juli, dan Agustus. Domain SST dipilih berdasarkan korelasi 5% dan 10% untuk masing-masing bulan Juni, Juli, dan Agustus. Penelitian ini menggunakan arsitektur JST dengan dua parameter: *hidden neuron* (HN) dan *learning rate* (LR). Jumlah *hidden neuron* yang digunakan dalam penelitian ini adalah 5, 10, 20, dan 40, dan tingkat pembelajaran adalah 0.3, 0.1, dan 0.01. Prediksi hasil terbaik untuk korelasi 5% menggunakan JST adalah untuk bulan Juni dengan R^2 adalah 51% dan RMSE 3.03 pada HN 10 dan LR 0.01, Juli dengan R^2 adalah 48% dan RMSE 3.39 pada HN 20 dan LR 0.1, dan Agustus dengan R^2 adalah 75% dan RMSE 2.51 di HN 40 dan LR 0.01. Prediksi hasil terbaik untuk korelasi 10% menggunakan JST adalah untuk bulan Juni dengan R^2 adalah 44% dan RMSE 3.32 di HN 5 dan LR 0.3, Juli dengan R^2 adalah 42% dan RMSE 3.42 di HN 10 dan LR 0.1, dan Agustus dengan R^2 adalah 71% dan RMSE 3.37 di HN 20 dan LR 0.01. Kesimpulan dari penelitian ini adalah *hidden neuron* dan *learning rate* dengan nilai yang berbeda mempengaruhi R^2 dan RMSE.

Kata kunci: *hidden neuron*, jaringan saraf tiruan, *learning rate*, RMSE, R^2

Abstract

Anjatan, Indramayu is the one of agriculture regions in Indonesia. The success or failure of the harvest each year depends on water availability in the region. Therefore we need an accurate method to predict the beginning of rainy season. The method used to predict in this research is artificial neural network (ANN) back-propagation. Result of ANN prediction accuracy is measured by R^2 and RMSE. This research uses ECHAM4p5_CA sea surface temperature (SST) that is one of the sea surface temperature models with the months of June, July, and August. The domain of SST is selected based on the correlation of 5% and 10% for each of the month June, July, and August. This research uses ANN architecture with two parameters: *hidden neuron* (HN) and *learning rate* (LR). The number of hidden neurons used in this research are 5, 10, 20, and 40, and the learning rates are 0.3, 0.1, and 0.01. The best prediction result for correlation of 5% using the ANN is for June with R^2 is 51% and RMSE 3.03 at HN 10 and LR 0.01, July with R^2 is 48% and RMSE 3.39 at HN 20 and LR 0.1, and August with R^2 is 75% and RMSE 2.51 at HN 40 and LR 0.01. The best prediction result correlation of 10% using the ANN is for June with R^2 is 44% and RMSE 3.32 at NH 5 and LR 0.3, July with R^2 is 42% and RMSE 3.42 at NH 10 and LR 0.1, and August with R^2 is 71% and RMSE 3.37 at NH 20 and LR 0.01. The conclusion from this research is the *hidden neuron* and *learning rate* with different values affect R^2 and RMSE.

Keywords: *artificial neural network*, *hidden neuron*, *learning rate*, RMSE, R^2

PENDAHULUAN

Latar Belakang

Indonesia terletak di antara Samudera Hindia dan Samudera Pasifik dan di antara Benua Asia dan Benua Australia serta berada pada ekuator. Kondisi ini menyebabkan cuaca, musim dan iklimnya dipengaruhi oleh sirkulasi atmosfer global, regional, dan lokal, seperti sirkulasi utara-selatan (*Hadley*), sirkulasi barat-timur (*Walker*), dan sistem angin lokal. Faktor-faktor yang menyebabkan perubahan iklim ini salah satunya ialah faktor suhu muka laut (SML).

Wilayah Anjatan, Indramayu merupakan salah satu wilayah sentra pertanian di Indonesia dengan tingkat keberhasilan maupun kegagalan panen tiap tahun yang bergantung pada ketersediaan air. Apabila awal musim hujan (AMH) dinyatakan maju atau mundur dari normalnya, jadwal tanam para petani akan terpengaruh. Dengan demikian, suatu metode yang akurat dibutuhkan untuk memprediksi awal musim hujan yang dipengaruhi oleh suhu muka laut. AMH di wilayah Indonesia didasarkan pada ketentuan yang dibuat oleh Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) yaitu AMH yang ditandai dengan jumlah curah hujan dasarian lebih dari 50 mm dan diikuti minimal dua dasarian (10 harian) berikutnya. Sebaliknya, awal musim kemarau ditandai dengan jumlah curah hujan dasarian kurang dari 50 mm dan diikuti dua dasarian berikutnya. Satu tahun kalender terbagi ke dalam 36 dasarian. Dasarian pertama mencatat total hujan dari tanggal 1 hingga tanggal 10 bulan yang bersangkutan. Dasarian kedua mencatat total hujan dari tanggal 11 hingga 20 pada bulan yang bersangkutan. Selanjutnya, dasarian ketiga mencatat total hujan dari tanggal 21 hingga akhir bulan (BMG 2008). AMH juga dapat bergantung pada kondisi wilayah lokal untuk bidang pertanian. AMH ialah informasi yang penting dalam penentuan waktu dan pola tanam. AMH yang digunakan pada pertanian Indonesia ialah apabila curah hujan setelah 1 Agustus tercatat > 40 mm dalam 5 hari berturut-turut tanpa diikuti 10 hari curah hujan < 5 mm dalam periode 10 hari (Moron *et al.* 2008).

Metode yang digunakan untuk memprediksi awal musim hujan ini ialah jaringan syaraf tiruan (JST). Dengan menggunakan pemodelan JST, identifikasi pola data dari sistem prediksi awal hujan dapat dilakukan dengan metode pembelajaran. Berdasarkan kemampuan belajar yang dimilikinya, JST dapat dilatih untuk mempelajari dan menganalisis pola data masa lalu dan berusaha mencari suatu formula atau fungsi yang akan menghubungkan pola data pada masa lalu dengan keluaran yang diinginkan pada saat ini.

Penelitian ini sebelumnya telah dilakukan oleh Novi (2005) yang mengoptimasi jaringan syaraf tiruan dengan algoritme genetika untuk peramalan curah hujan dan Normakristagaluh (2004) yang melakukan penerapan jaringan syaraf tiruan untuk peramalan curah hujan dalam *statistical downscaling* dengan data lokal GCM untuk peramalan curah hujan, menghasilkan akurasi 74%. Said (2011) melakukan penelitian peramalan panjang musim hujan menggunakan jaringan syaraf tiruan *resilient backpropagation* yang menghasilkan prediksi terbaik pada *lag* Agustus sebesar 84%, dan Marjuki (2011) membangun model prediksi awal musim hujan di pulau Jawa dengan menggunakan informasi suhu muka laut di kawasan Pasifik dan India. Mengacu pada penelitian-penelitian tersebut, penelitian ini menerapkan jaringan syaraf tiruan (JST) yang menggunakan model ECHAM4p5_CA *Sea Surface Temperature* (SST) sebagai *input* dan data awal musim hujan sebagai *output*. Model arsitektur jaringan yang terbaik dapat memberikan nilai prediksi AMH yang akurat.

Tujuan

Penelitian ini mengimplementasikan pemodelan jaringan syaraf tiruan untuk memprediksi awal musim hujan.

Ruang Lingkup

Penelitian ini memiliki batasan berupa:

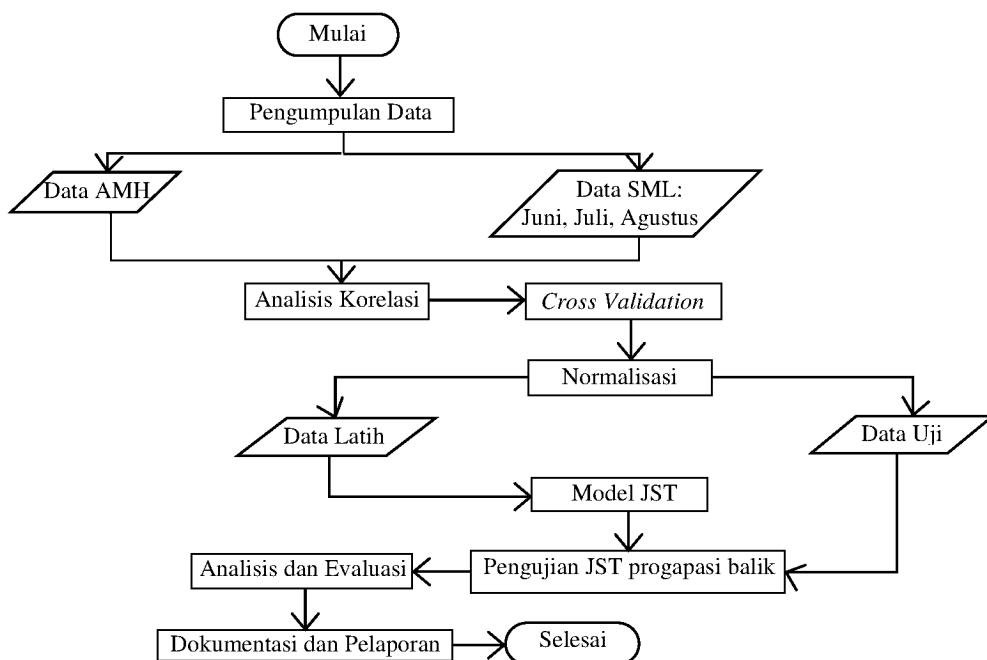
- 1 Data yang digunakan adalah data suhu muka laut dan data awal musim hujan dari tahun 1992-2008 untuk wilayah Anjatan, Indramayu.
- 2 Data model yang digunakan ialah ECHAM4p5_CASST *Sea Surface Temperature* pada bulan Juni, Juli, dan Agustus.
- 3 Analisis korelasi digunakan untuk menentukan keeratan hubungan antara awal musim hujan.
- 4 Metode JST *Backpropagation* digunakan untuk menunjukkan model prediksi awal musim hujan.
- 5 Evaluasi menggunakan dua parameter, yaitu R^2 dan RMSE.

Manfaat Penelitian

Penelitian ini diharapkan dapat membantu masyarakat terutama pada bidang pertanian dalam memprediksi awal musim hujan.

METODE PENELITIAN

Penelitian ini dikembangkan dengan metode yang terdiri atas beberapa tahap: (1) pengumpulan data, (2) pemilihan data, (3) proses pada JST, dan (4) analisis dan evaluasi. Alur tahapan-tahapan prediksi AMH dapat dilihat pada Gambar 1



Gambar 1 Diagram alur model prediksi AMH

Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah data penelitian AMH dan SML (ECHAM4p5_CASST). Respon yang digunakan dalam penelitian ini ialah AMH tahun 1992-2008 yang mencakup wilayah Anjatan, Indramayu yang terletak pada lintang -6.36 dan bujur 107.92 yang diperoleh dari Marjuki (2011). Data ECHAM4p5_CASST diperoleh dari *Institute Research International* (IRI) sebagai salah satu model *Sea Surface Temperature* (SST) dengan skala grid $2.8^\circ \times 2.8^\circ$ dan $32^\circ\text{LU}-32^\circ\text{LS}$ dan $30^\circ\text{BT}-295^\circ\text{BT}$ yang mencakup

wilayah Samudera India-Pasifik. SML yang digunakan untuk prediksi AMH ialah 95x24 grid dari tahun 1992-2008.

Pemilihan Data

Pemilihan data SML berdasarkan pada bulan Juni, Juli, dan Agustus dan korelasi yang signifikan menggunakan taraf nyata 5% dan 10% sehingga didapatkan 6 kelompok percobaan masing-masing 5% dan 10% untuk bulan Juni, Juli, dan Agustus. Enam kelompok percobaan tersebut akan digunakan sebagai *input* pada model JST. Setiap kelompok percobaan yang akan dimasukkan pada JST dibagi menjadi 75% untuk data latih dan 25% data uji dengan menggunakan 4 *fold* pengujian. Kelompok percobaan, baik data uji dan data latih, akan mengalami proses normalisasi. Setelah data mengalami proses normalisasi data pelatihan akan dilatih dengan algoritme *Backpropagation* untuk mendapatkan arsitektur JST yang terboboti. Kemudian, data pengujian disimulasikan dengan arsitektur JST yang sudah terboboti tersebut untuk mendapatkan nilai prediksi AMH.

Pada saat proses penentuan arsitektur JST, parameter yang digunakan terdiri atas jumlah *hidden neuron* (NH) dan *learning rate* (LR) dengan nilai yang berbeda-beda untuk mengetahui kinerja jaringan secara umum.

Model Jaringan Syaraf Tiruan

Model JST dibuat untuk memberikan kemampuan jaringan mengenali pola. Model JST dibentuk sesudah menetapkan data latih dan data uji. Karakteristik dan spesifikasi yang digunakan pada arsitektur JST dapat dilihat pada Tabel 1.

Tabel 1 Karakteristik dan spesifikasi pada arsitektur JST

Karakteristik	Spesifikasi
Arsitektur	1 <i>layer hidden</i>
<i>Neuron Input</i>	SML korelasi AMH Juni, Juli, dan Agustus taraf nyata 5% dan 10%
<i>Hidden neuron</i>	5,10, 20, dan 40
<i>Neuron Output</i>	1(target data prediksi awal musim hujan)
Fungsi Aktivasi <i>Layer Hidden</i>	Sigmoid Biner
Fungsi Aktivasi <i>Output</i>	Linear
Toleransi galat	0.001
Maksimum Epoch	500
<i>Learning rate</i> (LR)	0.3, 0.1, dan 0.01
<i>Training</i>	<i>Trainrp</i>

Analisis dan Evaluasi

Hasil dari pengujian ialah tingkat keakuratan antara nilai dugaan (*y*-prediksi) dengan *y*-aktual berdasarkan dua parameter, yaitu R^2 dan RMSE. R^2 yang dihasilkan akan dikalikan 100% untuk memudahkan pembacaan tingkat akurasi dan RMSE yang dihasilkan. Akurasi terbaik diambil pada nilai RMSE yang terkecil atau yang mendekati 0.

Lingkungan Pengembangan Sistem

Penelitian ini menggunakan perangkat keras dan perangkat lunak dengan spesifikasi ialah sebagai berikut: (a) perangkat keras berupa *notebook* dengan *processor* Intel Core i5, RAM kapasitas 2 GB, dan *hard disk* kapasitas 500 GB; dan (b) perangkat lunak berupa sistem operasi Microsoft Windows 7 Ultimate, aplikasi pemrograman Matlab R2008b, dan Microsoft Excel 2007.

HASIL DAN PEMBAHASAN

Analisis Korelasi

Analisis korelasi digunakan untuk menentukan keeratan hubungan SML dengan AMH. Nilai koefisien korelasi maksimum yang terjadi pada bulan Juni, Juli, dan Agustus menghasilkan nilai 0.73, 0.70, dan 0.71. Nilai koefisien korelasi yang dihasilkan pada bulan Juni, Juli, dan Agustus memiliki kriteria korelasi kuat sehingga suhu muka laut mempengaruhi untuk memprediksi AMH.

Nilai koefisien korelasi tidak dapat menyatakan bahwa nilai tersebut signifikan. Oleh karena itu, dilakukan uji signifikansi untuk mendapatkan nilai yang signifikan. Korelasi SML dan AMH didasarkan pada uji signifikansi SML bulan Juni, Juli, dan Agustus dengan menggunakan taraf nyata 5% dan 10% sehingga didapatkan 6 kelompok percobaan. Rata-rata korelasi bulan Juni dengan taraf nyata 5% dan 10% sebesar 0.53 dan 0.47, bulan Juli sebesar 0.52 dan 0.46 serta bulan Agustus sebesar 0.54 dan 0.48. Tabel 2 menunjukkan hasil rata-rata korelasi untuk setiap percobaan.

Tabel 2 Rata-rata korelasi setiap percobaan

Bulan	Percobaan	A	Rata-rata korelasi
Juni	1	5%	0.53
	2	10%	0.47
Juli	3	5%	0.52
	4	10%	0.46
Agustus	5	5%	0.54
	6	10%	0.48

Pola Input Data JST

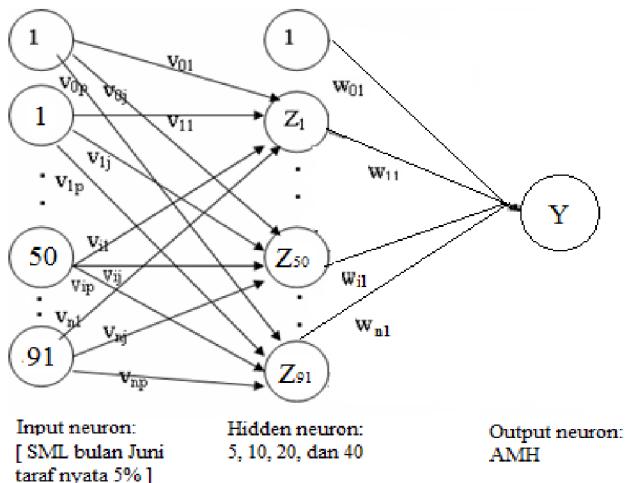
Pola *input* data sangat berpengaruh terhadap keakuratan pendugaan dalam JST. Seperti yang telah dijelaskan pada metode penelitian, data diolah ke dalam 6 kelompok percobaan dan berikutnya akan dibahas dan diperlihatkan pada grafik untuk masing-masing percobaan dengan unjuk kerja terbaiknya. Pada enam kelompok percobaan tersebut, data dibagi menjadi 2 bagian yaitu 75% data latih dan 25% data uji dengan menggunakan *4 fold* pada pengujian. Arsitektur jaringan syaraf tiruan untuk memprediksi awal musim hujan dengan menggunakan salah satu data percobaan pertama yaitu data SML bulan Juni dengan taraf nyata 5%. Salah satu arsitektur tersebut dapat dilihat pada Gambar 2.

Kelompok Percobaan

Kelompok percobaan pertama data SML (neuron *input*) untuk bulan Juni dengan taraf nyata 5% dan AMH (target). Data dibagi menjadi 2 bagian yaitu 75% data latih dan 25% data uji dengan metode *4 fold*.

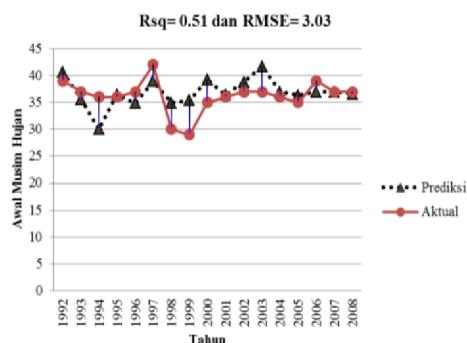
Grafik pada Gambar 3 merupakan grafik prediksi terbaik yang didapatkan pada kelompok percobaan pertama. R^2 yang dihasilkan pada percobaan pertama ialah 0.51 atau 51% dengan RMSE 3.03. Terlihat garis prediksi menempel garis aktual. Hal tersebut bisa diartikan bahwa nilai dugaan atau prediksi sama dengan nilai aktualnya. Namun, ada beberapa juga hasil yang nilai prediksinya tidak sama dengan nilai aktual sehingga menghasilkan sisaan yang disebut *error* (RMSE). Pada kasus ini, jika garis prediksi semakin tepat menempel pada garis aktual, *error* pun semakin kecil. *Error* yang sangat kecil dan R^2 yang sangat besar dapat menghasilkan keakuratan pendugaan lebih baik. Arsitektur JST yang dimiliki pada Gambar 3 tersebut terdiri atas *hidden neuron* 10 dan *learning rate* 0.01.

Kelompok percobaan kedua yang menggunakan taraf nyata 10% menghasilkan arsitektur terbaik pada *hidden neuron* 5 dan *learning rate* 0.3 dengan rata-rata R^2 yang dihasilkan 0.44 atau 44% dan RMSE 3.32. Grafik hasil prediksi dengan aktual kelompok percobaan ke-2 dapat dilihat pada Gambar 4.

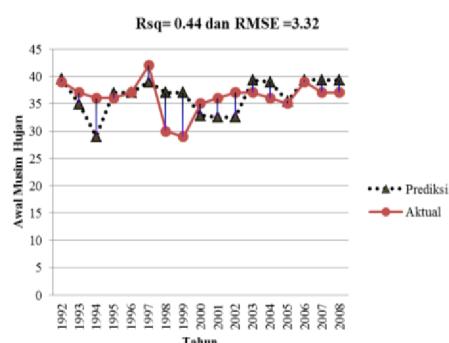


Gambar 2 Arsitektur JST

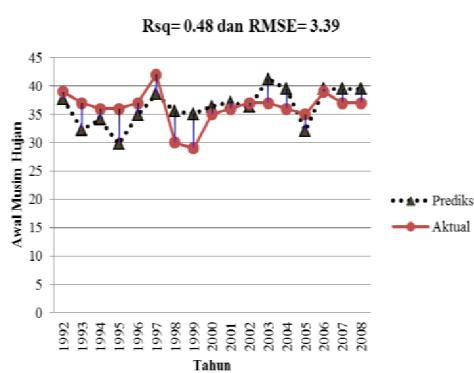
Kelompok percobaan ketiga data SML (*neuron input*) untuk bulan Juli dengan taraf nyata 5% dan AMH (target). Data dibagi menjadi 2 bagian yaitu 75% data latih dan 25% data uji dengan metode *4 fold*. Grafik pada Gambar 5 merupakan grafik prediksi terbaik yang didapatkan pada kelompok percobaan ketiga. R^2 yang dihasilkan pada percobaan ketiga ialah 0.48 dengan RMSE 3.39. Arsitektur JST yang dimiliki pada Gambar 5 tersebut terdiri atas *hidden neuron* 20 dan *learning rate* 0.1. Kelompok percobaan keempat yang menggunakan taraf nyata 10% menghasilkan arsitektur terbaik pada *hidden neuron* 10 dan *learning rate* 0.1 dengan rata-rata R^2 yang dihasilkan 0.42 dan RMSE 3.42. Grafik hasil prediksi dan aktual kelompok percobaan ke-4 disajikan pada Gambar 6. Kelompok percobaan kelima data SML (*neuron input*) untuk bulan Agustus dengan taraf nyata 5% dan AMH (target). Data dibagi menjadi 2 bagian yaitu 75% data latih dan 25% data uji dengan metode *4 fold*. Grafik pada Gambar 7 merupakan grafik prediksi terbaik yang didapatkan pada kelompok percobaan kelima. R^2 yang dihasilkan pada percobaan kelima ialah 0.75 dengan RMSE 2.51. Arsitektur JST pada Gambar 7 tersebut terdiri atas *hidden neuron* 40 dan *learning rate* 0.01. Kelompok percobaan keenam yang menggunakan taraf nyata 10% menghasilkan arsitektur terbaik pada *hidden neuron* 20 dan *learning rate* 0.01 dengan rata-rata R^2 yang dihasilkan 0.71 atau 71% dan RMSE 3.37. Grafik hasil prediksi dan aktual kelompok percobaan ke-6 dapat dilihat pada Gambar 8. Hasil perbandingan masing-masing kelompok percobaan disajikan pada Tabel 3. Kesesuaian model dikatakan semakin baik jika R^2 mendekati 1 dan RMSE mendekati 0. Berdasarkan hasil perbandingan R^2 dan RMSE dari masing-masing kelompok percobaan pada Tabel 3, dapat dinyatakan bahwa percobaan 5 menghasilkan percobaan terbaik jika dibandingkan dengan percobaan 1, 2, 3, 4, dan 6 dengan R^2 yang dihasilkan sebesar 75% dan RMSE 2.51.



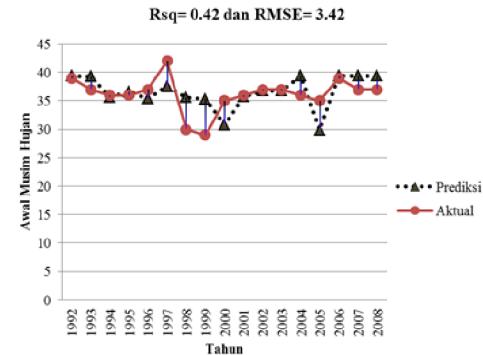
Gambar 3 Hasil prediksi dan aktual kelompok percobaan ke-1



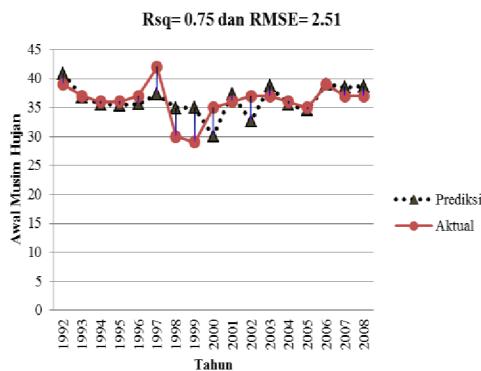
Gambar 4 Hasil prediksi dan aktual kelompok percobaan ke-2



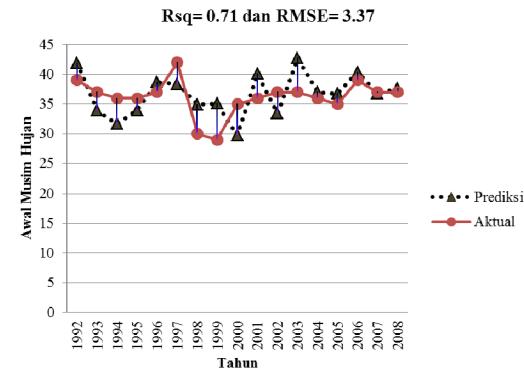
Gambar 5 Hasil prediksi dan aktual kelompok percobaan ke-3



Gambar 6 Hasil prediksi dan aktual kelompok percobaan ke-4



Gambar 7 Hasil prediksi dan aktual kelompok percobaan ke-5



Gambar 8 Hasil prediksi dan aktual kelompok percobaan ke-6

Tabel 3 Hasil perbandingan R^2 dan RMSE

Percobaan	R^2	RMSE
1	51%	3.03
2	44%	3.32
3	48%	3.39
4	42%	3.42
5	75%	2.51
6	71%	3.37

Hasil R^2 dan RMSE untuk percobaan 5 memiliki ketepatan pendugaan terbaik karena RMSE yang dihasilkannya lebih rendah dan R^2 lebih besar dibandingkan dengan percobaan 1, 2, 3, 4, dan 6.

Arsitektur Terbaik

Penelitian ini memilih rata-rata terbaik dari unjuk kerja masing-masing *setting* parameter yang digunakan untuk 6 kelompok percobaan. Arsitektur JST yang digunakan pada setiap kelompok percobaan ini ialah *neuron hidden* dan *learning rate* yang berbeda-beda. Tabel 4, 5, dan 6 memperlihatkan rata-rata R^2 dan RMSE terbaiknya dari masing-masing kelompok percobaan. Tabel 4 merupakan arsitektur JST terbaik untuk kelompok percobaan pertama dan kedua. Kelompok percobaan pertama yang dihasilkan oleh *learning rate* sebesar 0.3 terdiri atas jumlah *hidden neuron* sebanyak 5; pada saat *learning rate* sebesar 0.1 terdiri atas jumlah *hidden neuron* sebanyak 10; dan pada saat *learning rate* 0.01 terdiri atas jumlah *hidden neuron* sebanyak 10. Kelompok percobaan kedua yang dihasilkan oleh *learning rate* sebesar 0.3 terdiri atas jumlah *hidden neuron* sebanyak 5; pada saat *learning rate* sebesar 0.1 terdiri

atas jumlah *hidden neuron* sebanyak 5; dan pada saat *learning rate* 0.01 terdiri atas jumlah *hidden neuron* sebanyak 5.

Tabel 5 merupakan arsitektur JST terbaik untuk kelompok percobaan ketiga dan keempat. Kelompok percobaan ketiga yang dihasilkan oleh *learning rate* sebesar 0.3 terdiri atas jumlah *hidden neuron* sebanyak 40, pada saat *learning rate* sebesar 0.1 terdiri atas jumlah *hidden neuron* sebanyak 20 dan pada saat *learning rate* 0.01 terdiri atas jumlah *hidden neuron* sebanyak 20. Kelompok percobaan keempat yang dihasilkan oleh *learning rate* sebesar 0.3 terdiri atas jumlah *hidden neuron* sebanyak 5; pada saat *learning rate* sebesar 0.1 terdiri atas jumlah *hidden neuron* sebanyak 10; dan pada saat *learning rate* 0.01 terdiri atas jumlah *hidden neuron* sebanyak 5. Tabel 6 merupakan arsitektur JST terbaik untuk kelompok percobaan kelima dan keenam. Kelompok percobaan kelima yang dihasilkan oleh *learning rate* sebesar 0.3 terdiri atas jumlah *hidden neuron* sebanyak 20; pada saat *learning rate* sebesar 0.1 terdiri atas jumlah *hidden neuron* sebanyak 40; dan pada saat *learning rate* 0.01 terdiri atas jumlah *hidden neuron* sebanyak 40. Kelompok percobaan keenam yang dihasilkan oleh *learning rate* sebesar 0.3 terdiri atas jumlah *hidden neuron* sebanyak 10; pada saat *learning rate* sebesar 0.1 terdiri atas jumlah *hidden neuron* sebesar 40; dan pada saat *learning rate* 0.01 terdiri atas jumlah *hidden neuron* sebanyak 20.

Laju pembelajaran (*learning rate*) juga sangat berpengaruh terhadap kualitas atau keakuratan hasil pendugaan. Pada penelitian ini dilakukan tiga laju pembelajaran yang berbeda yaitu 0.3, 0.1, dan 0.01. Tabel 4, 5, dan 6 memperlihatkan rata-rata R^2 dan RMSE terbaiknya dari masing-masing kelompok percobaan. Masing-masing arsitektur pada Tabel 4, 5, dan 6 merupakan arsitektur yang diperoleh dari nilai rata-rata R^2 yang paling besar dan RMSE yang paling kecil pada percobaan yang dilakukan dengan laju pembelajaran tertentu. Hal ini menunjukkan bahwa perbedaan pada laju pembelajaran dengan jumlah *neuron* yang berbeda akan berpengaruh terhadap R^2 dan RMSE.

Tabel 4 Hasil terbaik percobaan ke-1 dan ke-2

A	HN	LR	R^2	RMSE
5%	5	0.3	35%	3.61
5%	10	0.1	20%	3.55
5%	10	0.01	51%	3.03
10%	5	0.3	44%	3.32
10%	5	0.1	51%	3.80
10%	5	0.01	53%	4.08

Tabel 5 Hasil terbaik percobaan ke-3 dan ke-4

A	HN	LR	R^2	RMSE
5%	40	0.3	75%	3.68
5%	20	0.1	48%	3.39
5%	20	0.01	32%	3.59
10%	5	0.3	34%	3.68
10%	10	0.1	42%	3.42
10%	5	0.01	59%	3.82

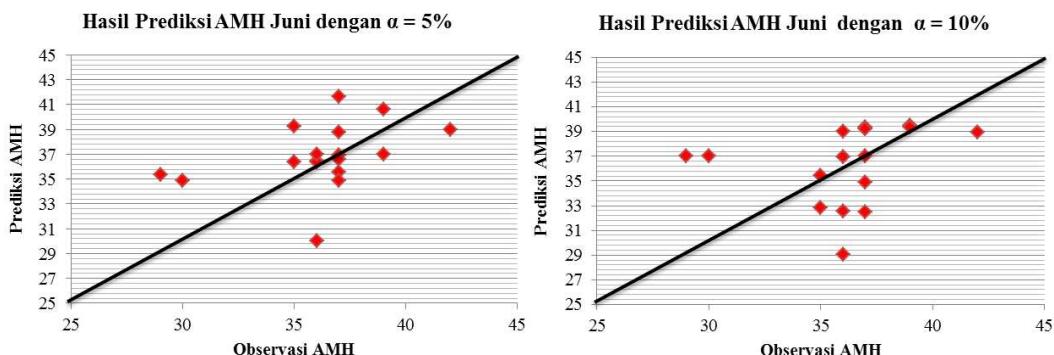
Tabel 6 Hasil terbaik percobaan ke-5 dan ke-6

A	HN	LR	R^2	RMSE
5%	20	0.3	86%	2.64
5%	40	0.1	63%	3.19
5%	40	0.01	75%	2.51
10%	10	0.3	70%	3.63
10%	40	0.1	60%	3.70
10%	20	0.01	71%	3.37

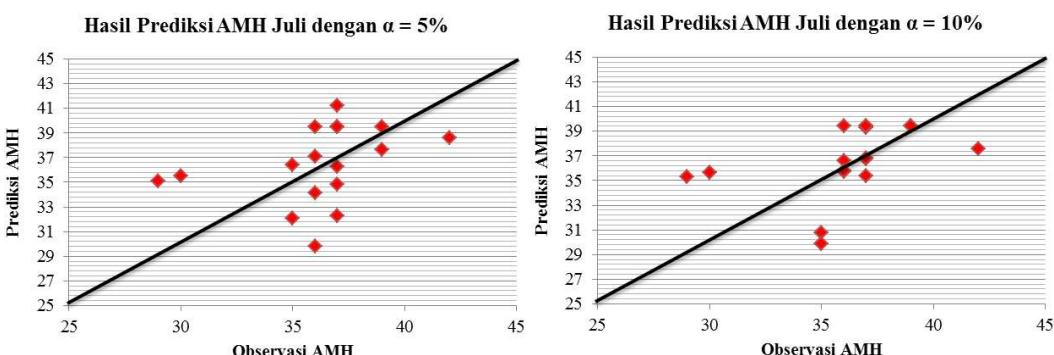
Hasil Prediksi AMH

Hasil terbaik dihasilkan untuk prediksi AMH dengan menggunakan data SML pada korelasi taraf nyata 5% dan 10%. Gambar 9, 10, dan 11 merupakan *scatter plot* prediksi AMH

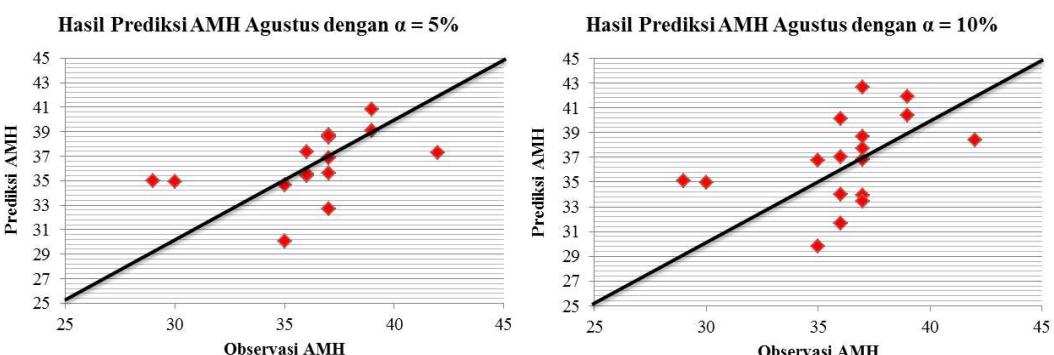
bulan Juni, Juli, dan Agustus dengan observasi AMH berdasarkan korelasi taraf nyata 5% dan 10%. Nilai prediksi AMH dengan observasi AMH menunjukkan bahwa hasil prediksi pada bulan Agustus menyediakan prediksi terbaik dibandingkan dengan hasil prediksi bulan Juni dan Juli. Hal ini menyebabkan prediksi variabilitas meningkat dan korelasi antara observasi dengan prediksi pun lebih kecil. Prediksi terbaik terdapat pada Gambar 11 yang menghasilkan rata-rata R^2 sebesar 75% dan 71%, sedangkan model prediksi untuk bulan Juni menghasilkan R^2 sebesar 51% dan 44%, sementara bulan Juli menghasilkan R^2 sebesar 48% dan 42%. Dengan demikian dapat dinyatakan bahwa nilai prediksi bulan Juni dan Juli kurang baik bila dibandingkan dengan prediksi bulan Agustus. Hal ini menyebabkan prediksi variabilitas meningkat dan akhirnya korelasi antara observasi dengan prediksi lebih kecil. Hasil prediksi dan R^2 masing-masing kelompok dapat dilihat pada Tabel 7. Gambar 9, 10, dan 11 merupakan *scatter plot* prediksi AMH bulan Juni, Juli, dan Agustus dengan observasi AMH berdasarkan korelasi taraf nyata 5% dan 10%.



Gambar 9 *Scatter plot* prediksi AMH dengan observasi AMH bulan Juni



Gambar 10 *Scatter plot* prediksi AMH dengan observasi AMH bulan Juli



Gambar 11 *Scatter plot* prediksi AMH dengan observasi AMH bulan Agustus

Tabel 7 Hasil prediksi dan R^2

SML	A	Prediksi	R^2
Juni	5%	36.87 dasarian	51%
	10%	35.43 dasarian	44%
Juli	5%	36.31 dasarian	48%
	10%	36.56 dasarian	42%
Agustus	5%	36.22 dasarian	75%
	10%	36.59 dasarian	71%

SIMPULAN

SML bulan Juni, Juli, dan Agustus memiliki kriteria korelasi kuat sehingga SML sangat berpengaruh dalam memprediksi awal musim hujan. Rata-rata korelasi yang dihasilkan setelah dilakukan uji signifikansi dengan taraf nyata 5% dan 10% yaitu bulan Juni 0.53 dan 0.47, bulan Juli 0.52 dan 0.46, serta bulan Agustus 0.54 dan 0.48.

Pola *input* data yang digunakan sangat berpengaruh terhadap kinerja JST dalam melakukan proses prediksi AMH. SML bulan Agustus menghasilkan prediksi terbaik R^2 pada taraf nyata 5% sebesar 75%, sedangkan bulan Juni dan Juli sebesar 51% dan 48%.

Hasil prediksi yang dihasilkan untuk periode berikutnya menggunakan SML bulan Agustus pada korelasi taraf nyata 5% dengan hasil akurasi sebesar 75% ialah 36.22 dasarian, sedangkan SML bulan Juni dan Juli dengan korelasi taraf nyata 5% ialah 36.87 dan 36.31 dengan masing-masing akurasi 51% dan 48%.

DAFTAR PUSTAKA

- [BMG] Badan Meteorologi dan Geofisika. 2008. Prakiraan Musim Hujan 2008/2009 di Indonesia. Jakarta(ID): BMG.
- Fausset L. 1994. *Fundamental Of Neural Network*. New Jersey(US): Prentice Hall.
- Fu LM. 1994. *Neural Network in Computer Intellegence*. Singapura(SG): McGraw-Hill.
- Marjuki. 2011. Model prediksi awal musim hujan di pulau Jawa dengan menggunakan informasi suhu muka laut di kawasan Pasifik dan India [tesis]. Bogor(ID): Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Pertanian Bogor.
- Novi A. 2006. Optimasi jaringan syaraf tiruan dengan algoritme genetika untuk peramalan curah hujan [skripsi]. Bogor(ID): Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Pertanian Bogor.
- Normakristagaluh P. 2004. Penerapan jaringan syaraf tiruan untuk peramalan curah hujan dalam *statistical downscaling* [skripsi]. Bogor(ID): Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Pertanian Bogor.
- Said MM. 2011. Peramalan panjang musim hujan menggunakan jaringan syaraf tiruan *resilient backpropagation* [skripsi]. Bogor(ID): Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Pertanian Bogor.
- Sulyianto. 2011. *Ekonometrika Terapan Teori dan Aplikasi dengan SPSS*. Yogyakarta(ID): Andi Offset.