

Prediksi Awal Musim Hujan di Kabupaten Pacitan Menggunakan Optimasi *Cascade Neural Network (CNN)* dengan *Genetic Algorithm (GA)* Berdasarkan Data GCM

Rainy Season Onset Prediction in Pacitan District Using Cascade Neural Network (CNN) Optimization with Genetic Algorithm (GA) Based on GCM

Fildza Novadiwanti*, Agus Bueno, Akhmad Faqih

Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Pertanian Bogor, Jl. Raya Darmaga Kampus IPB Darmaga 16680, Bogor

INFORMASI ARTIKEL

Riwayat artikel:

Diterima: 04 November 2016
Direview: 30 November 2016
Disetujui: 03 Juni 2017

Katakunci:

Awal musim hujan
Cascade neural network
Genetic algorithm
Global circulation model

Keywords:

Cascade neural network
Genetic algorithm
Global circulation mode
Onset of rainy season

Abstrak: Awal musim hujan yang tidak menentu merupakan salah satu variabel iklim yang dapat memengaruhi produksi pertanian dan kegagalan panen. Kemampuan memprediksi awal musim hujan dapat digunakan untuk mengurangi risiko penurunan hasil dan gagal panen. Penelitian ini bertujuan untuk mengembangkan model untuk memprediksi awal musim hujan di Kabupaten Pacitan, Provinsi Jawa Timur menggunakan *cascade neural network (CNN)* yang dioptimasi menggunakan *genetic algorithm (GA)*. Model tersebut dibangun berdasarkan data prediktan awal musim hujan yang dihitung dari data curah hujan harian observasi di tiga stasiun cuaca, yaitu Arjosari, Kebon Agung, dan Pringkuku. Data predictor diambil dari luaran 3 model *global circulation model (GCM)*, yaitu CMC1-CanCM3, CMC1-CanCM4, dan NCEP-CSFv2, untuk periode tahun 1983 - 2011. Optimasi CNN dengan GA dilakukan dengan mengoptimasi jumlah *hidden neuron*. Optimasi tersebut bertujuan untuk mengoptimalkan arsitektur dari model CNN yang dihasilkan sehingga meningkatkan nilai korelasi, r , antara nilai yang dihasilkan oleh model dengan data observasi. Penelitian ini menghasilkan nilai akurasi r yang meningkat cukup signifikan setelah dilakukan optimasi pada setiap stasiun cuaca. Hal ini menunjukkan bahwa setiap model pada masing-masing stasiun cuaca dapat digunakan untuk memprediksi awal musim hujan pada wilayah sekitar masing-masing stasiun cuaca.

Abstract. The anomaly of the onset of rainy season is one of the weather variable that may affect agricultural production and may cause crop failure. The ability to predict the onset of the rainy season can be used to minimize the risk of yield drop and crop failure. This research aims to develop a model for predicting the onset of rainy season in Pacitan District, East Java Province using optimized cascade neural network (CNN) optimized with the genetic algorithm (GA). The prediction model was developed by using rainy season daily rainfall data of three weather stations, i.e. Arjosari, Kebon Agung, and Pringkuku. The predictor data for the 1983 -2011 period were obtained from the output of three global circulation model (GCM), i.e. CMC1-CanCM3, CMC1-CanCM4, and NCEP-CSFv2. Optimization of CNN with GA was done by optimizing the amount of hidden neuron. The goal was to optimize the architecture of CNN model so that the value of correlation, r , between the model predicted and observed data increased. This research obtained increasing r value after optimization for each weather station. This indicates that each model at each weather station can be used to predict the onset of the rainy season in the area around each weather station.

Pendahuluan

Kondisi pertanian di Indonesia dipengaruhi oleh faktor-faktor alam, salah satunya adalah iklim. Pentingnya iklim bagi kondisi pertanian di Indonesia membuat iklim berperan dalam perencanaan tanam jangka pendek dan jangka panjang (Suciantini 2015). Curah hujan merupakan unsur iklim yang paling dominan dalam mencirikan kondisi iklim di Indonesia karena curah hujan di Indonesia memiliki keragaman dan fluktuasi yang tinggi (Sipayung 2005). Faktor yang mempengaruhi variabilitas iklim di Indonesia adalah ENSO. ENSO merupakan interaksi atmosfer laut yang berpusat di ekuator Samudera Pasifik yang berpotensi menyebabkan terjadinya anomali iklim

global, yaitu fenomena El Nino dan La Nina (Trenberth *et al.* 2000).

El Nino adalah fenomena global yang ditandai dengan memanasnya suhu permukaan laut di wilayah NINO 3.4 atau Ekuator Pasifik Tengah. Anomali suhu permukaan laut pada wilayah tersebut adalah positif sehingga berdampak pada berkurangnya jumlah curah hujan di Indonesia (Renggono 2011). Kondisi tersebut membuat pertanian di Indonesia mengalami peluang kekeringan. La Nina merupakan fenomena global yang ditandai dengan menurunnya suhu permukaan laut di Samudera Pasifik tropis bagian timur dan tengah dengan anomali suhu permukaan lautnya bernilai negatif. Fenomena La Nina menyebabkan curah hujan di Indonesia meningkat (Utami

*Corresponding author: fildzanova@gmail.com

et al. 2011). Jika kondisi tersebut berlangsung dalam waktu yang cukup lama, maka dapat mengakibatkan banjir dan dapat menyebabkan kegagalan panen. Pada penelitian Suciantini (2004) dengan studi kasus pada daerah Indramayu menunjukkan pada tahun El Nino awal musim hujan mundur antara satu sampai tiga dasarian dan pada tahun La Nina awal musim hujan akan maju antara satu sampai tiga dasarian.

Penentuan awal musim hujan bermanfaat untuk menentukan awal musim penanaman tanaman pertanian. Perubahan awal musim hujan dari waktu normal berpengaruh terhadap waktu tanam. Saat terjadi peristiwa El Nino awal musim hujan menjadi mundur dari waktu normalnya. Penentuan awal musim hujan menjadi strategi penting dalam budidaya pertanian terutama pada tanaman pangan yang sangat dipengaruhi anomali iklim (Naylor *et al.* 2002; Naylor *et al.* 2007). Hal tersebut membuat awal musim hujan menjadi informasi yang penting dalam pola tanam dan perencanaan musim tanam yang baik (Makmur *et al.* 2013). Awal musim hujan ditetapkan berdasarkan jumlah curah hujan dalam satu dasarian sama atau lebih dari 50 milimeter dan diikuti oleh dua dasarian berikutnya (BMKG 2013).

Prediksi awal musim hujan dapat dilakukan dengan membangun model prediksi dengan memanfaatkan data dari luaran simulasi model iklim global (Global Climate Model, GCM). GCM representasi dari atmosfer dan proses-proses didalamnya dalam skala besar (Jarvis *et al.* 2010). GCM telah banyak digunakan dalam berbagai aplikasi. Pengaplikasian dari GCM salah satunya adalah menganalisis interaksi proses-proses di dalam iklim, simulasi evolusi dari iklim, dan melakukan prediksi iklim (Kininmonth 2013).

Penggunaan berbagai model statistic untuk prediksi iklim musiman telah banyak dilakukan di Indonesia, sebagian telah memanfaatkan luaran data GCM sebagai predictor. Sanusi (2014) melakukan penelitian menggunakan support vector machine (SVR) yang dioptimasi dengan particle swarm optimization (PSO) untuk memprediksi curah hujan di musim kemarau dengan menggunakan data GCM dan menghasilkan model luaran GCM terbaik adalah model CMC1-CanCM3 dengan korelasi 0,793 dan Root Mean Square Error (RMSE) 21,685. Buono *et al.* (2014) melakukan pemodelan untuk memprediksi prediktor onsets di wilayah Pacitan menggunakan time-delay cascading neural network. Hasil dari penelitian ini menunjukkan nilai koefisien korelasi cascade neural network (CNN) lebih baik dibanding back propagation neural network (BPNN) dengan 0,71 untuk BPNN dan 0,72 untuk CNN. Apriyanti *et al.* (2006) melakukan optimasi jaringan syaraf tiruan dengan genetic algorithm untuk prediksi curah hujan dengan mengoptimasi jumlah hidden neuron. Hasil dari penelitian

ini adalah jaringan syaraf tiruan menghasilkan nilai R2 0,74 dan setelah dioptimasi menghasilkan nilai R2 0,87.

Peningkatan keakuratan prediksi iklim musiman masih perlu untuk terus dikembangkan. Oleh karena pengembangan model dengan berbagai metode statistik tingkat lanjut masih harus terus dilakukan. Penelitian ini melakukan optimasi pada cascade neural network (CNN) menggunakan genetic algorithm (GA) untuk studi kasus Pacitan. GA dilakukan untuk mengoptimasi struktur jaringan pada CNN. Optimasi struktur jaringan dengan GA untuk menemukan jumlah hidden neuron terbaik dari CNN.

Penggunaan metode CNN dikarenakan CNN merupakan pendekatan yang fleksibel dan memiliki arsitektur yang adaptif. CNN dikatakan fleksibel dan adaptif karena hidden unit hanya ditambahkan pada jaringan yang membutuhkan saja sehingga pada akhirnya menghasilkan arsitektur yang mengalir (Bodianskiy 2011). Penelitian ini menggunakan genetic algorithm (GA) untuk melakukan optimasi karena menurut Gen dan Cheng (1997), berdasarkan hasil penelitiannya menunjukkan bahwa algoritme genetika cukup robust untuk digunakan dalam melakukan optimasi fungsi sulit sekalipun.

Tujuan dari penelitian ini adalah untuk melakukan pemodelan CNN yang dioptimasi dengan GA untuk melakukan prediksi awal musim hujan dan mengevaluasi kinerja dari hasil prediksi yang telah dihasilkan. Manfaat dari penelitian diharapkan dapat mengetahui prediksi awal musim hujan di wilayah Pacitan, Provinsi Jawa Timur untuk membantu memberikan informasi lebih baik dalam pengelolaan pertanian, khususnya terkait dengan penentuan waktu tanam agar terhindar dari kegagalan panen.

Bahan dan Metode

Data dan Alat

Data observasi menggunakan data curah hujan pada kabupaten Pacitan pada tiga stasiun, yaitu stasiun cuaca Arjosari, Kebon Agung, dan Pringkuku dari tahun 1983 – 2011 sebagai data observasi diperoleh dari *Centre for Climate Risk and Opportunity Management in Southeast Asia Pasific* (CCROM SEAP IPB). Data prediktor, yaitu luaran data GCM dari *the North-American Multi Model Ensemble* (NMME) diperoleh dari situs *International Research Institute for Climate and Society* (IRI) (<https://iridl.ldeo.columbia.edu>). Data GCM yang digunakan tahun 1983 – 2011 dengan variabel *total precipitation*, *sea surface temperature*, dan *reference temperature*. Model GCM yang digunakan adalah CMC1-CanCM3, CMC1-CanCM4, dan NCEP-CSFv2. *Lead time* yang digunakan adalah 3 bulan, yaitu bulan Juni, Juli, dan Agustus.

Penentuan Awal Musim Hujan

Badan Meteorologi Klimatologi dan Geofisika (BMKG) menentukan awal musim hujan berdasarkan jumlah curah hujan dalam satu dasarian sama atau lebih dari 50 milimeter dan diikuti oleh dua dasarian berikutnya. Dasarian sendiri merupakan kriteria banyaknya curah hujan selama sepuluh hari (BMKG 2013). Selain kriteria yang ditentukan oleh BMKG, terdapat kriteria lain dalam menentukan awal musim hujan, salah satunya adalah penentuan awal musim hujan oleh Liebmann *et al.* (2007).

Awal musim hujan menurut Liebmann *et al.* (2007) adalah hari setelah dimulainya periode terpanjang dari akumulasi anomali curah hujan positif yang hanya berlaku secara lokal. Persamaan penentuan awal musim hujan menurut Liebmann dan Marengo (2001) sebagai berikut:

$$A(\text{day}) = \sum_{n=1}^{\text{day}} [R(n) - \bar{R}] \quad (1)$$

$R(n)$ adalah curah hujan harian dari awal perhitungan sampai hari ke-day selama satu tahun dan \bar{R} adalah rata-rata curah hujan selama satu tahun. Nilai A menunjukkan nilai akumulasi anomali curah hujan harian. Perhitungan nilai A dimulai dari 10 hari sebelum bulan paling kering (Liebmann *et al.* 2007; Liebmann *et al.* 2008). Awal musim hujan terjadi pada saat nilai A mengalami penurunan yang diikuti dengan kenaikan yang signifikan dan nilai akumulasinya selalu berada di atas nilai rata-rata curah hujan tahunan yang akan terbentuk positive slope yang menunjukkan terjadinya musim hujan (Liebmann dan Marengo 2001; Liebmann *et al.* 2007).

Pemilihan dan Reduksi Dimensi Data GCM

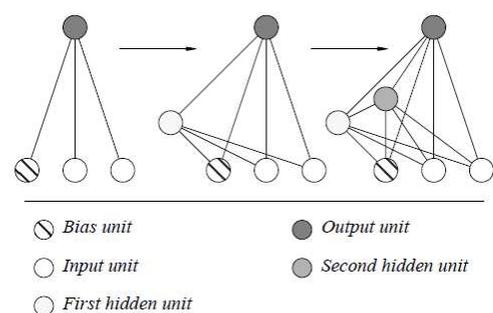
Data GCM memiliki dimensi yang besar sehingga perlu dilakukan reduksi. Data GCM direduksi dengan menggunakan PCA. PCA merupakan teknik statistik yang digunakan untuk menjelaskan struktur variansi-kovariansi dari sekumpulan variabel melalui variabel baru dimana variabel baru ini saling bebas, dan merupakan kombinasi linier dari variabel asal yang dinamakan komponen utama (*principal component*) (Johnson, 2002). Salah satu tujuan dari PCA adalah mereduksi dimensi data asal yang semula terdapat p variabel bebas menjadi k komponen utama (dimana $k < p$). Peubah p dan peubah k saling orthogonal yang masing-masing k peubah baru tersebut merupakan kombinasi linear dari p peubah asal. Adapun kriteria pemilihan k menurut Johnson (2002) yaitu proporsi kumulatif keragaman data asal yang dijelaskan oleh k komponen utama minimal 80%, dan proporsi total variansi populasi bernilai cukup besar. *Principal component score* yang diperoleh digunakan sebagai masukan dalam pemodelan CNN. *Principal component score* tersebut akan dibagi menjadi beberapa kelompok percobaan

menggunakan *k-fold cross validation*. Pada penelitian ini, data dibagi menjadi 3 kelompok percobaan dengan 2/3 data latih dan 1/3 data uji. *K-fold cross validation* mengulang percobaan sebanyak k -kali. Dari pengulangan tersebut, data terbagi himpunan secara acak menjadi subset untuk pengujian dan subset untuk pelatihan yang saling bebas (Kohavi 1995).

Proses Pemodelan dan Optimasi CNN dengan Genetic Algorithm

CNN merupakan *multilayer feed-forward neural network* yang semua unit input memiliki koneksi langsung ke semua *hidden unit* dan semua unit output. Setiap keluaran dari *hidden unit* menjadi masukan ke semua *hidden unit* selanjutnya dan *output unit* (Engelbrecht 2007). Algoritme CNN adalah sebagai berikut (Bodyanskiy *et al.* 2011):

1. Algoritme dimulai dengan jaringan sederhana yang terdiri dari *input* dan *output layer*.
2. *Input* yang masuk dilatih dengan jaringan sederhana tersebut.
3. Jika nilai akurasi CNN tidak memenuhi, ditambahkan satu *hidden unit* pada arsitektur jaringan tersebut dengan koneksi awal antara *input* dan *output* tidak mengalami perubahan. Jaringan tersebut dilatih secara independen dan secara paralel dengan bobot random berbeda.
4. Proses tersebut dilakukan terus dengan penambahan *hidden unit* yang menerima masukan dari *input unit* dan *hidden unit* sebelumnya.
5. Setelah itu, pembaruan bobot dilakukan dengan menggunakan algoritme *backpropagation*. Struktur algoritme CNN diilustrasikan pada Gambar 1.



Gambar 1. Struktur *cascade neural network* (Nechyba 1997)

Figure 1. *Cascade neural network structure* (Nechyba 1997)

Dalam melakukan pelatihan, arsitektur dari CNN ditentukan terlebih dahulu. Parameter-parameter yang digunakan dalam arsitektur CNN adalah nilai *learning rate*, jumlah *input neuron*, dan jumlah *output neuron*.

Selain itu, pada CNN terdapat fungsi aktivasi pada *hidden layer*, *output layer*, dan fungsi *training* yang ditentukan terlebih dahulu.

Proses optimasi CNN dengan GA dilakukan untuk menemukan jumlah *hidden neuron* yang paling optimal. GA merupakan pendekatan untuk menentukan global optimum dengan simulasi proses makhluk hidup. Algoritme genetika diaplikasikan pada calon solusi yang sebelumnya dikodekan dalam bentuk kromosom. Algoritme genetika mencari solusi dari kumpulan kromosom. Pada penelitian ini, pengkodean yang digunakan adalah *string* biner dengan tiap bit di dalam *string* kromosom merepresentasikan sebuah *neuron*. Bit bernilai 1 merepresentasikan *neuron* yang dipertahankan dan bit bernilai 0 merepresentasikan *neuron* yang tidak digunakan (Sihombing 2011). Pencarian solusi terbaik menggunakan fungsi *fitness*. Fungsi *fitness* mengukur seberapa baik solusi dari kromosom tersebut. Setiap kromosom merepresentasikan nilai *fitness* kromosom (Arkeman *et al.* 2012). Terdapat 3 proses dalam GA, yaitu proses kawin silang (*cross over*), proses mutasi, dan proses seleksi (Mitchell 1999).

Analisis dan Evaluasi

Hasil prediksi yang diperoleh diukur keakurasian dan galatnya. Pengukuran keakurasian dan galat dilakukan dengan menggunakan koefisien korelasi (*r*) dan RMSE. Hasil keakurasian pemodelan semakin baik jika nilai *r* semakin mendekati 1 dan hasil perhitungan galat akan semakin baik jika nilai RMSE semakin mendekati 0. Koefisien korelasi menunjukkan seberapa kuat nilai yang dihasilkan model dengan data observasi. Menurut Walpole (1992), *r* dirumuskan sebagai berikut:

$$r = \frac{n \sum_{i=1}^n x_i y_i - (\sum_{i=1}^n x_i) (\sum_{i=1}^n y_i)}{\sqrt{[n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2] [n \sum_{i=1}^n y_i^2 - (\sum_{i=1}^n y_i)^2]}} \dots (2)$$

dengan x_i = data observasi dan y_i = hasil prediksi

RMSE sendiri menunjukkan nilai simpangan dari nilai dugaan terhadap nilai aktual. Dengan rumusnya sebagai berikut (Walpole 1992):

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (X_t - F_t)^2}{n}} \quad (3)$$

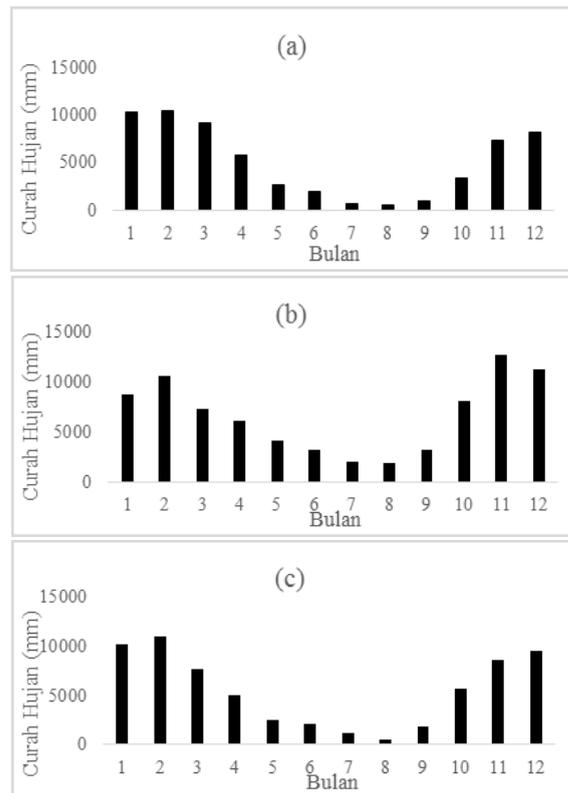
dengan X_t = nilai aktual pada waktu ke-*t* dan F_t = nilai dugaan pada waktu ke-*t*.

Hasil dan Pembahasan

Penentuan Awal Musim Hujan

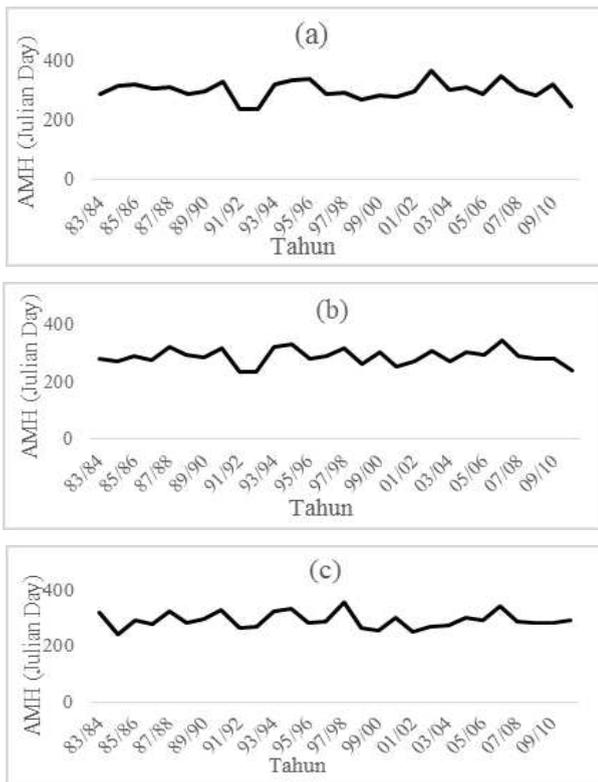
Penentuan awal musim hujan dimulai dengan menentukan titik awal perhitungannya. Titik awal perhitungan dimulai dari 10 hari sebelum bulan paling kering. Penentuan bulan paling kering dengan melihat rata-ran bulan yang paling sedikit curah hujannya dari tahun 1983 - 2011. Berdasarkan data pada penelitian ini, bulan terkering pada ketiga stasiun cuaca adalah bulan Agustus sehingga titik awal perhitungannya pada 21 Juli. Gambar 2 menunjukkan rata-ran curah hujan dari tahun 1983 - 2011 pada ketiga stasiun cuaca.

Penentuan AMH dilakukan pada masing-masing stasiun cuaca di Kabupaten Pacitan. Penentuan AMH dilakukan dengan menghitung rata-ran curah hujan selama satu tahun dan nilai akumulasi rata-ran curah hujan selama satu tahun. Hasil dari perhitungan AMH dengan metode Liebmann dan Marengo (2001) dapat dilihat pada Gambar 3. Grafik tersebut menunjukkan bahwa ketiga stasiun cuaca memiliki pola awal musim hujan yang cenderung sama.



Gambar 2. Rataan curah hujan: (a) Arjosari; (b) Kebon Agung; (c) Pringkuku

Figure 2. Average rainfall: (a) Arjosari; (b) Kebon Agung; (c) Pringkuku



Gambar 3. Awal musim hujan: (a) Arjosari; (b) Kebon Agung; (c) Pringkuku

Figure 3. Onset of rainy season: (a) Arjosari; (b) Kebon Agung; (c) Pringkuku

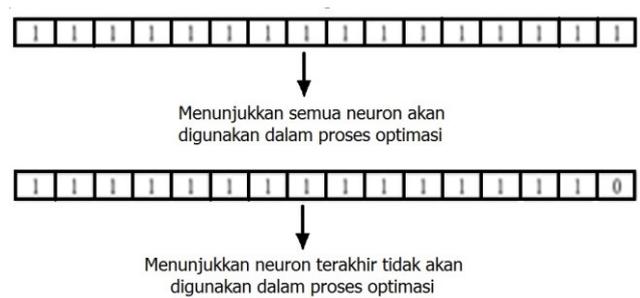
Proses Pemodelan dan Optimasi CNN dengan Genetic Algorithm

Tahap awal optimasi dengan algoritme genetika adalah menentukan representasi kromosom. Pada penelitian, kromosom merepresentasikan hidden neuron pada model CNN. Kromosom direpresentasikan sebanyak 16 bit sehingga setiap bit di dalam kromosom merupakan satu hidden neuron. Saat bit kromosom bernilai 1, maka neuron tersebut dipertahankan. Saat kromosom bernilai 0, maka neuron tersebut tidak digunakan. Ilustrasi dari kromosom yang digunakan dapat dilihat pada Gambar 4.

Untuk mengetahui seberapa baik solusi yang dihasilkan oleh kromosom, GA menggunakan fungsi fitness. Fungsi fitness pada penelitian ini dimaksudkan untuk meningkatkan akurasi. Nilai akurasi akan semakin baik jika nilai r mendekati 1 dan nilai RMSE mendekati 0. Namun, fokus pada penelitian ini adalah memaksimalkan nilai koefisien korelasi (r). Maka berikut adalah fungsi fitness yang digunakan:

$$f(r, RMSE) = r \frac{1}{RMSE + 0.001} \tag{4}$$

dengan r = nilai koefisien korelasi dan $RMSE$ = nilai *root mean square error*.



Gambar 4. Ilustrasi kromosom pada algoritme genetika
Figure 4. Illustration of chromosome in genetic algorithm

Pada GA terdapat parameter-parameter yang akan menentukan dalam proses optimasi. Parameter-parameter yang digunakan pada penelitian ini dapat dilihat pada Tabel 1. Pelatihan dengan CNN dilakukan dua kali, yaitu dengan optimasi algoritme genetika dan tidak menggunakan optimasi algoritme genetika. Parameter-parameter yang digunakan dapat dilihat pada Tabel 2.

Tabel 1. Parameter algoritme genetika
Table 1. Genetic algorithm parameters

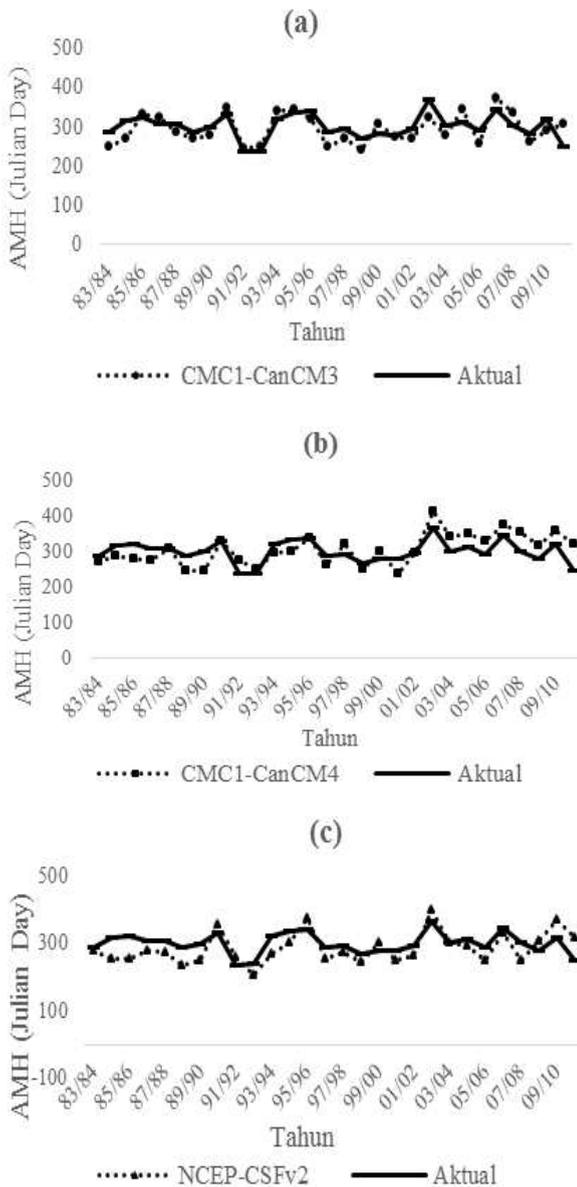
Parameter	Spesifikasi
Populasi	60
Jumlah generasi	1000
Pindah silang	Simple Crossover (0,6)
Mutasi	Binary Mutation (0,3)
Mekanisme seleksi	Roulette Wheel

Tabel 2. Karakteristik *cascade neural network*
Table 2. Cascade neural network characteristics

Karakteristik	Spesifikasi
Fungsi aktivasi <i>hidden layer</i>	Sigmoid biner (logsig)
Fungsi aktivasi <i>output layer</i>	Linear (purelin)
Fungsi training	Resilient (trainrp)
Toleransi galat	0,001
Maksimum <i>epoch</i>	500
Learning rate	0,01; 0,1; 0,3; 0,5
Neuron input layer	Data GCM
Lead time	Juni, Juli, Agustus
Neuron output layer	1 target data (data AMH)

Analisis dan Evaluasi

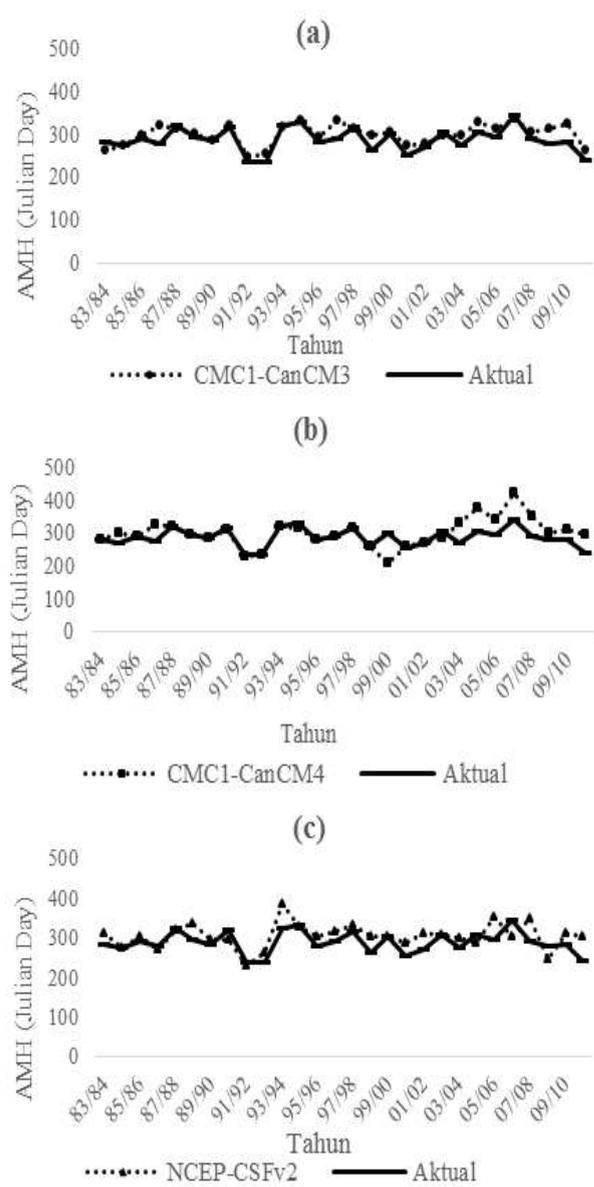
Pada Gambar 5 menunjukkan perbandingan AMH aktual dan AMH hasil dari pemodelan CNN yang dioptimasi menggunakan GA dari kombinasi parameter terbaik dari masing-masing model GCM di stasiun cuaca Arjosari. Hasil yang dihasilkan ketiga model sudah cukup baik dalam mengikuti pola data AMH aktual dan tidak dihasilkan nilai ekstrem dari hasil prediksi. Namun, pada model NCEP-CSFv2 kurang baik mengikuti pola pada data-data awal.



Gambar 2. Perbandingan AMH aktual di Arjosari dengan model: (a) CMC1-CanCM3; (b) CMC1-CanCM4; (c) NCEP-CSFv2

Figure 2. Comparison of actual AMH in Arjosari with models: (a) CMC1-CanCM3; (b) CMC1-CanCM4; (c) NCEP-CSFv2

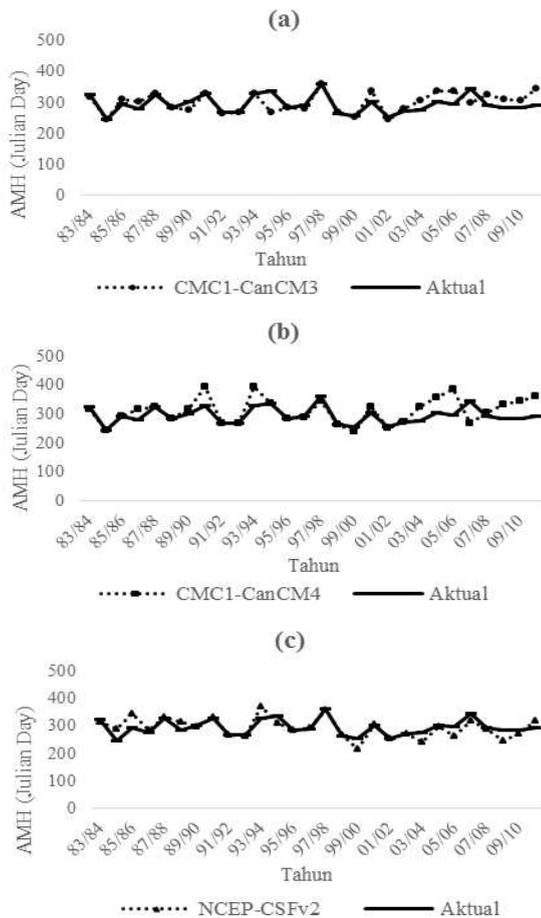
Pada Gambar 6 menunjukkan perbandingan AMH aktual dan AMH hasil dari pemodelan CNN yang dioptimasi menggunakan GA dari kombinasi parameter terbaik dari masing-masing model GCM di stasiun cuaca Kebon Agung. Dari ketiga grafik terlihat bahwa hasil yang dihasilkan ketiga model sudah cukup baik dalam mengikuti pola data AMH aktual. Namun, pada model NCEP-CSFv2 terlihat bahwa hasil yang diperoleh kurang begitu baik mengikuti pola pada bagian data-data akhir. Pada grafik terlihat bahwa model CMC1-CanCM3 menghasilkan pola yang paling baik.



Gambar 3. Perbandingan AMH aktual di Kebon Agung dengan model: (a) CMC1-CanCM3; (b) CMC1-CanCM4; (c) NCEP-CSFv2

Figure 3. Comparison of actual AMH in Kebon Agung with models: (a) CMC1-CanCM3; (b) CMC1-CanCM4; (c) NCEP-CSFv2

Pada Gambar 7 menunjukkan perbandingan AMH aktual dan AMH hasil dari pemodelan CNN yang dioptimasi menggunakan GA dari kombinasi parameter terbaik dari masing-masing model GCM di stasiun cuaca Pringku. Pada model NCEP-CSFv2 hasil AMH yang dihasilkan model sudah cukup baik mengikuti pola AMH aktual dan hasil AMH yg diperoleh tidak menghasilkan nilai ekstrem. Pada model CMC1-CanCM3 dan CMC1-CanCM4 hasil AMH yang diperoleh sudah cukup baik mengikuti pola dari AMH aktual, namun masih kurang baik mengikuti pola pada bagian akhir data.



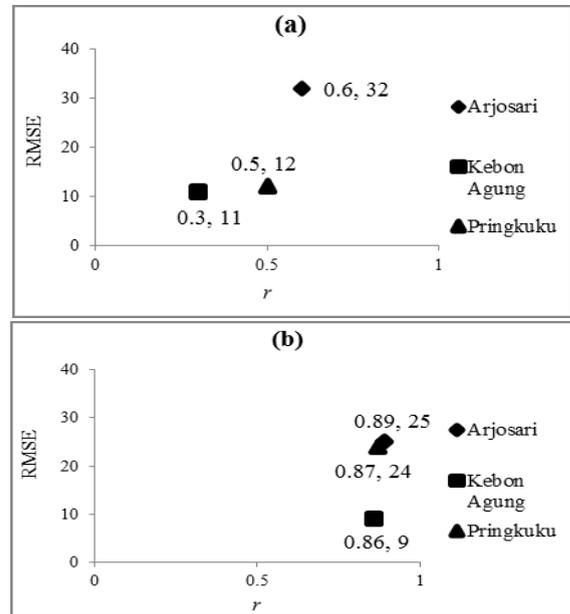
Gambar 4. Perbandingan AMH aktual di Pringkuku dengan model: (a) CMC1-CanCM3; (b) CMC1-CanCM4; (c) NCEP-CSFv2

Figure 4. Comparison of actual AMH in Pringkuku with models: (a) CMC1-CanCM3; (b) CMC1-CanCM4; (c) NCEP-CSFv2

Hasil prediksi yang diperoleh dari ketiga stasiun cuaca menunjukkan bahwa model CMC1-CanCM3 dan CMC1-CanCM4 cenderung menghasilkan pola yang serupa jika dibandingkan dengan model NCEP-CSFv2. Hal ini dapat terjadi dikarenakan karakteristik dari data CMC1-CanCM3 dan CMC1-CanCM4 dengan NCEP-CSFv2 berbeda. Pada model CMC1-CanCM3 memiliki karakteristik pada atmosfer dengan resolusi horizontal adalah 315 km dan resolusi vertikal adalah 31 level. Pada model CMC1-CanCM4 resolusi horizontal pada atmosfer adalah 315 km dan resolusi vertikal adalah 35 level. Pada model NCEP-CSFv2 memiliki resolusi horizontal 38 km dan resolusi vertikal adalah 64 level. Perbedaan yang cukup jauh antara model CMC1-CanCM3 dan CMC1-CanCM4 dengan NCEP-CSFv2 ini yang menyebabkan hasil prediksinya menghasilkan pola yang berbeda.

Perbandingan antara hasil sebelum dioptimasi dan setelah dioptimasi ditunjukkan pada Gambar 8. Pada penelitian ini, masing-masing stasiun cuaca dan masing-

masing model GCM diolah menggunakan berbagai macam parameter. Setiap model pada setiap stasiun cuaca memiliki parameter yang berbeda dalam menghasilkan arsitektur terbaik. Parameter yang menghasilkan model CNN terbaik dapat dilihat pada Tabel 3.



Gambar 5. Plot arsitektur terbaik setiap stasiun cuaca (a) tanpa GA; (b) dengan GA

Figure 5. Plot the best architecture of each weather station (a) without GA; (b) with GA

Tabel 3. Parameter arsitektur terbaik
Table 3. Best architecture parameters

Stasiun Cuaca	Model GCM	Learning Rate	Lead Time
Arjosari	CMC1-CanCM3	0,1	Agustus
Kebon Agung	CMC1-CanCM4	0,5	Juli
Pringkuku	NCEP-CSFv2	0,5	Agustus

Pada stasiun cuaca Arjosari, arsitektur terbaik yang dihasilkan adalah model CMC1-CanCM3 dengan parameter learning rate 0,1 dan lead bulan Agustus. Model ini memiliki akurasi r 0,89 dan RMSE 25 dengan akurasi sebelum dioptimasi dengan GA adalah r 0,6 dan RMSE 32. Pada stasiun cuaca Kebon Agung, arsitektur terbaik yang dihasilkan adalah pada model CMC1-CanCM3 dengan parameter learning rate 0,5 dan lead bulan Juli. Model ini memiliki akurasi r 0,86 dan RMSE 9 dengan akurasi sebelum dioptimasi dengan GA adalah r 0,3 dan RMSE 11. Pada stasiun cuaca Pringkuku, arsitektur terbaik yang dihasilkan adalah pada model NCEP-CSFv2 dengan parameter learning rate 0,5 dan lead bulan Agustus. Model ini memiliki akurasi r 0,87 dan RMSE 24 dengan akurasi sebelum dioptimasi dengan GA adalah r 0,5 dan RMSE 12.

Pada optimasi menggunakan GA, setiap stasiun cuaca memiliki kenaikan nilai r yang cukup baik. Pada stasiun cuaca Arjosari dan Kebon Agung nilai RMSE juga mengalami penurunan sehingga menjadi lebih baik. Namun, pada stasiun cuaca Pringkuku nilai RMSE mengalami kenaikan. Hal tersebut dapat terjadi karena pada penelitian ini fungsi fitness pada GA diutamakan untuk memaksimalkan nilai r . Meningkatnya nilai r menunjukkan bahwa hubungan antara nilai yang dihasilkan oleh model dengan data observasi memiliki hubungan yang kuat. Hal tersebut menunjukkan hasil yang dihasilkan oleh model optimasi CNN dengan GA cukup baik untuk digunakan untuk memprediksi awal musim hujan di Kabupaten Pacitan sehingga dari hasil prediksi yang diperoleh dapat dilakukan perencanaan musim tanam yang baik agar terhindar dari kegagalan panen.

Kesimpulan dan Saran

Penelitian ini telah berhasil melakukan pemodelan awal musim hujan menggunakan 3 model data GCM dengan metode *cascade neural network* (CNN) yang dioptimasi menggunakan *genetic algorithm* (GA) pada 3 stasiun cuaca di Kabupaten Pacitan. Nilai AMH yang diperoleh pada masing-masing model GCM di setiap stasiun cuaca menunjukkan pola yang cukup sesuai dengan nilai AMH aktual. Hasil dari penelitian ini menunjukkan nilai akurasi r yang meningkat setelah dilakukan optimasi pada setiap stasiun cuaca. Hal ini menunjukkan bahwa setiap model pada masing-masing stasiun cuaca dapat digunakan untuk memprediksi awal musim hujan pada wilayah sekitar masing-masing stasiun cuaca.

Pada penelitian ini digunakan parameter dari CNN yang dioptimasi dengan GA pada arsitektur hidden neuron. Penelitian ini dapat lebih dikembangkan dengan menambahkan parameter yang dioptimasi sehingga dapat menghasilkan nilai akurasi yang lebih baik. Selain itu, penambahan mekanisme pada algoritme genetika, seperti *elitism* dan optimasi fungsi *fitness* untuk nilai RMSE juga dapat digunakan untuk mengembangkan penelitian ini.

Daftar Pustaka

Apriyanti, N., A. Buono, dan A. Kustiyo. 2006. Optimasi jaringan syaraf tiruan dengan algoritme genetika untuk peramalan curah hujan. *Jurnal Ilmu Komputer* 4(1).

Arkeman, Y., K.B. Seminar, dan H. Gunawan. 2012. *Algoritma Genetika: Teori dan Aplikasinya untuk Bisnis dan Industri*. IPB Press, Bogor. 205 pp.

[BMKG] Badan Meteorologi Klimatologi dan Geofisika. 2013. Prakiraan musim hujan [internet]. [diacu 2013 Okt 18]. Tersedia dari: www.bmkg.go.id/BMKG_Pusat/DataDokumen/PMH_1314.pdf.

Bodyanskiy, Y., O. Kharchenko, dan O. Vynokurova. 2011. Hybrid cascade neural network based on wavelet-neuron. *International Journal "Information Theories and Application"*. 18(4):335-343.

Buono, A., I.S. Sitanggang, Mushthofa, dan A. Kustiyo. 2014. Time-delay cascading neural network architecture for modelling time-dependent predictor in onset prediction. *Journal of Computer Science*. 10(6): 976-984.

Engelbrecht, A.P. 2007. *Computational Intelligence: An Introduction*. John Wiley & Sons, New Jersey. 592 pp.

Gen, M. dan R. Cheng. 1997. *Genetic Algorithms and Engineering Design*. John Wiley and Sons, Ltd, West Sussex. 432 pp.

Johnson, R.A. and D.W. Wichern. 2002. *Applied Multivariate Statistical Analysis*. 5th Ed. Prentice Hall, New Jersey. 617 pp

Kininmonth, W. dan A. Lupo. Downscaling global circulation model outputs: the delta method decision and policy analysis working paper. *Climate Change Reconsidered II: Physical Science 2013 Report of the NIPCC*, 2013 September 18, Chicago.

Kohavi, R. 1995. A study of cross validation and bootstrap for accuracy estimation and model selection. *IJCAI*. 2:1137-1143.

Liebmann, B., I. Bladé, N.A. Bond, D. Gochis, D. Allured, dan G.T. Bates. 2008. Characteristics of North American summertime rainfall with emphasis on the monsoon. *J. Climate*. 21(6):1277-1294.

Liebmann, B., S.J. Camargo, A. Seth, J.A. Marengo, L.M. Carvalho, D. Allured, R. Fu, dan C.S. Vera. 2007. Onset and end of the rainy season in South America in observations and the ECHAM 4.5 atmospheric general circulation model. *J. Climate*. 20(10):2037-2050.

Liebmann, B. dan J. Marengo. 2001. Interannual variability of the rainy season and rainfall in the Brazilian Amazon Basin. *J. Climate*. 14(22):4308-4318.

Makmur, E., Y. Koesmaryono, E. Aldrian, dan H.A Wigena. 2013. Model prediksi awal musim hujan di sentra padi Pantura Jabar dengan prediktor regional dan global. *Jurnal Meteorologi dan Geofisika*. 14(3):127-137.

Mitchell, M. 1999. *An Introduction to Genetic Algorithms*. A Bradford Book, London. 209 pp.

Naylor, R.L., D.S. Battisti, D.J. Vimont, W.P. Falcon, dan M.B. Burke. 2007. Assessing the risks of climate variability and climate change for Indonesian rice agriculture. *Proc Nat Acad Sci* 104: 7752-7757.

Naylor, R.L., W. Falcon, N. Wada, dan D. Rochberg. 2002. Using El-Niño Southern Oscillation climate data to improve food policy planning in Indonesia. *Bull Indon Econ Stud* 38: 75-91.

Nechyba, M. Cascade Neural Networks with Node-Decoupled Extended Kalman Filtering. *International Symposium on Computational Intelligence in Robotics and Automation*, 1997 Juli 10-11, Monterey, California.

Renggono, F. 2011. Pengaruh ENSO terhadap pola angina dan curah hujan di Das Larona Sulawesi Selatan. *Jurnal Sains dan Teknologi dan Modifikasi Cuaca*. 12(2):63-68.

Sanusi. 2014. Optimasi SVR dengan PSO pada pemodelan statistical downscaling untuk prediksi curah hujan musim kemarau. Thesis. Institut Pertanian Bogor, Bogor. 39 pp.

- Sihombing, B. 2011. Jaringan syaraf tiruan dan algoritma genetika dalam pemodelan kalibrasi (studi kasus: tanaman obat temulawak). Thesis. Institut Pertanian Bogor, Bogor. 65 pp.
- Sipayung, S.B. 2005. Dampak variabilitas iklim terhadap produksi pangan di Sumatera. *Jurnal Sains Dirgantara*. 2(2):111-126.
- Suciantini. 2015. Interaksi iklim (curah hujan) terhadap produksi tanaman pangan di Kabupaten Pacitan. p. 358 – 365. Dalam Masyarakat Biodiversitas Indonesia. Prosiding Seminar Nasional, Solo, Indonesia, 7 November, 2015. Prosiding MBI no.1.
- Suciantini. 2004. Evaluasi prakiraan sifat hujan dan penyusunan model prediksi musim: studi kasus Kabupaten Indramayu. Thesis. Institut Pertanian Bogor, Bogor. 112 pp.
- Trenberth, K.E dan J.M. Caron. 2000. The Southern Oscillation Revisited: Sea Level Pressures, Surface Temperatures and Precipitation. *Journal of Climate*. 13. 4358 – 4365.
- Utami, A.W., Jamhari, dan S. Hardyastuti. 2011. El Nino, La Nina, dan penawaran pangan di Jawa, Indonesia. *Jurnal Ekonomi Pembangunan*. 12(2): 257-271.
- Walpole, E.R. 1992. Pengantar Statistika. Gramedia, Jakarta. 516 pp.