

Perbandingan Kinerja Hasil Luaran Model Jaringan Syaraf Tiruan dan SARIMA Untuk Prediksi Awal Musim Hujan Kota Pangkalpinang

Presli Panusunan Simanjuntak

Stasiun Klimatologi Bangka Belitung

Jalan Kartika I, Koba, Bangka Tengah, Kep. Bangka Belitung 33681

e-mail: presli.simanjuntak@bmkgo.go.id

ABSTRAK

Bangka Belitung merupakan wilayah penghasil utama dari lada dan karet. Informasi prediksi curah hujan dan awal musim hujan (AMH) diperlukan untuk meningkatkan produksi komoditi ini. Tujuan penelitian untuk membangun model Seasonal ARIMA (SARIMA) dan Jaringan Syaraf Tiruan (JST) guna memprediksi curah hujan dan penentuan AMH dengan model terbaik. Model prediksi yang digunakan adalah SARIMA dengan menggunakan data curah hujan dari masa lalu dan JST propagasi balik (backpropagation) dengan menggunakan prediktor suhu muka laut, angin zonal dan precipitable water periode 1981-2010. SARIMA merupakan metode yang digunakan dalam peramalan data runtun waktu musiman sedangkan JST backpropagation merupakan pelatihan model untuk mempelajari set pola data masa lalu dan mengevaluasi serta membuat formula yang dihubungkan dengan keluaran yang diinginkan. Model dibandingkan kinerjanya dengan menghitung nilai koefisien korelasi dan akar rerata kuadrat kesalahan. Hasil penelitian menunjukkan model JST lebih baik daripada SARIMA untuk memprediksi curah hujan dengan nilai RMSE sebesar 48,70 dan korelasi sebesar 0,25. Akan tetapi, JST belum mampu untuk menduga curah hujan ekstrim. Penentuan AMH menggunakan prediksi JST menghasilkan kesesuaian model prediksi sebesar 42,86 % dengan nilai skill sebesar 0,05 lebih baik daripada penentuan AMH menggunakan prediksi SARIMA terpilih yang menghasilkan kesesuaian model prediksi sebesar 14,26 % dengan nilai skill sebesar 0,00.

Kata kunci: backpropagation, korelasi, prediksi AMH, RMSE, SARIMA

ABSTRACT

Bangka Belitung Islands are the main producing areas of pepper and rubber. Predictive information on rainfall and the start of the rainy season (AMH) is needed to increase the production of this commodity. The aim of the research is to build a Seasonal ARIMA model (SARIMA) and an Artificial Neural Network (ANN) to predict rainfall and determine AMH with the best model. The prediction model used is SARIMA using rainfall data from the past and ANN backpropagation using predictors of sea surface temperature, zonal wind and precipitable water for the period 1981-2010. SARIMA is a method used in forecasting seasonal time series data while ANN backpropagation is a training model to study sets of past data patterns and evaluate and create formulas related to the desired output. Model performance is compared by calculating the value of the correlation coefficient and the mean square root of the error. The results showed that the ANN model was better than SARIMA for predicting rainfall with an RMSE value of 48.70 and a correlation of 0.25. However, ANN has not been able to predict extreme rainfall. Determining AMH using ANN predictions resulted in a predictive model fit of 42.86% with a skill value of 0.05 which was better than the AMH determination using selected SARIMA predictions which resulted in a predictive model fit of 14.26% with a skill value of 0.00.

Keywords: backpropagation, correlation, prediction of the onset of wet season, RMSE, SARIMA

PENDAHULUAN

Pangkalpinang adalah ibu kota dari Provinsi Kepulauan Bangka Belitung. Pangkalpinang dan beberapa wilayah sekitarnya seperti Kabupaten Bangka Tengah dan Kabupaten Bangka merupakan salah satu wilayah penghasil utama lada dan karet [1]. Tanaman lada tumbuh optimal pada kondisi curah hujan 1.000 sampai dengan 3.000 mm/tahun, dengan rata-rata hari hujan 110 sampai dengan 170 hari hujan/tahun. Kondisi optimal juga dapat tercapai dengan kemarau hanya 2 sampai 3 bulan per tahun (Suprpto, 2008). Pada tanaman karet, kondisi optimal untuk pertumbuhan tanaman ini dengan curah hujan 1.500 sampai dengan 3.000 mm/tahun dan diperlukan 1 sampai 3 bulan kering per tahun [2]. Produktivitas lada dan karet ini sangat terpengaruh kondisi iklim terutama curah hujan serta polanya sehingga informasi AMH sangat diperlukan.

Banyak penelitian sebelumnya telah menganalisis faktor-faktor yang mempengaruhi AMH. Sebagai contoh, nilai anomali suhu muka laut (SML) Indonesia memiliki peranan yang signifikan terhadap awal dan panjang musim hujan Indonesia. Keadaan SML Lookal dapat digunakan menjadi parameter dalam penentuan banyak sedikitnya kandungan uap air di atmosfer. Kondisi kandungan uap air di atmosfer berperan penting dalam pembentukan awan di Indonesia [3]. Selain itu, hal lain yang dapat dijadikan indikator untuk menjadi prediktor peluang terjadinya hujan disuatu wilayah adalah jumlah uap *precipitable water*. Kandungan jumlah uap air pada sebuah massa udara adalah indikator potensi terjadinya presipitasi. *Precipitable water* sebagai variabel tunggal persamaan regresi linier sederhana cukup baik digunakan untuk menghasilkan prediksi curah hujan di Pangkalpinang [4]

Terdapat beberapa cara yang dapat dilakukan dalam memprediksi AMH. Salah satu prediksi AMH adalah menggunakan teknologi *Artificial Intelligence* yaitu jaringan saraf tiruan (JST). Dengan menggunakan pemodelan JST, pengenalan pola data dari metode prediksi AMH dapat dilakukan dengan sistem pembelajaran. Berdasarkan hasil pembelajaran yang dimiliki, JST dapat dilatih untuk mengenali dan menganalisis pola data masa lalu dan mencari suatu fungsi yang menghubungkan pola data pada masa lalu dengan keluaran yang dikehendaki pada saat ini [5]. Saat ini metode JST telah banyak dipelajari dan diterapkan untuk berbagai masalah, termasuk prediksi.

Selain dengan pemodelan *Artificial Intelligence*, banyak penelitian sebelumnya menggunakan metode stastisik untuk memprediksi curah hujan maupun AMH. Salah satu metode statistik yang dapat digunakan dalam memprediksi curah hujan maupun AMH adalah ARIMA (*Autoregressive Integrated Moving Average*). Model yang dihasilkan dari metode ARIMA dapat meramalkan curah hujan dengan baik. Metode ARIMA mampu memberikan hasil yang baik dalam prediksi dengan menggunakan data dari masa lalu, dengan memenuhi beberapa kondisi diantaranya adalah *white noise*, stasioner dalam mean dan varians, berdistribusi normal. Pada data runtun waktu yang memiliki pola musiman model ARIMA dapat dikembangkan menjadi SARIMA (*Seasonal Autoregressive Integrated Moving Average*) [6]

Metode *Seasonal ARIMA* merupakan metode yang paling sering digunakan dalam peramalan data deret waktu [7]Metode lain yang juga dapat digunakan dalam melakukan peramalan adalah Jaringan Syaraf Tiruan Backpropagation. Jaringan Syaraf Tiruan (JST) merupakan suatu sistem pengolahan informasi yang terinspirasi dari sistem kerja syaraf biologis, seperti kinerja otak yang memproses informasi. Algoritma Backpropagation merupakan algoritma pembelajaran yang sering digunakan dalam melakukan pelatihan jaringan dalam berbagai aplikasi, seperti pemilihan lokasi, pengenalan pola maupun evaluasi kinerja [8]. Kota Pangkalpinang memerlukan

model yang handal untuk memprediksi curah hujan dan awal musim sebagai pedoman perencanaan tata Kelola kota dan Kelola pangan.

Berdasarkan uraian diatas, penelitian ini akan membahas lebih spesifik terkait perbandingan hasil model luaran JST dengan melibatkan prediktor SML, angin zonal dan *precipitable water* dengan hasil model luaran SARIMA untuk memprediksi AMH di Pangkalpinang.

METODE PENELITIAN

A. Data Penelitian

Data curah hujan harian diperoleh dari Stasiun Meteorologi Pangkalpinang. Data curah hujan harian diolah menjadi data curah hujan dasarian dengan cara menjumlahkan data curah hujan sepuluh harian tahun 1981-2017 untuk menentukan AMH.



Gambar 1. Pembagian Grid Prediktor Curah Hujan

Data prediktor curah hujan yang digunakan terdiri dari suhu muka laut (SML), angin zonal dan *precipitable water* pada lapisan 850 mb. Data harian prediktor tersebut diambil pada periode Januari 1981 – Desember 2017 dari situs *International Research Institute Data Library* (IRIDL). Data prediktor curah hujan tersebut dibatasi berdasarkan lintang dan bujur yang ditentukan yaitu 10° LU - 10° LS dan 90° BT - 115° BT. Daerah dengan luasan tersebut dibagi menjadi 20 grid dengan ukuran masing-masing grid 5° x 5°, seperti ditunjukkan pada Gambar 1. Data suhu muka laut (SML) harian diolah menjadi data SML dasarian dengan cara menghitung nilai rata-rata SML persepuluh hari.

$$SML_{dasarian} = \frac{\sum_{i=1}^n SML_1 + SML_1 + \dots + SML_n}{n} \tag{1}$$

dimana:

- $SML_{dasarian}$ = suhu muka laut dasarian (°C)
- n = banyaknya data (°C)
- SML = suhu muka laut (°C)

Data angin zonal harian diubah menjadi data angin zonal dasarian dengan cara merata-ratakan data harian menjadi data persepuluh hari.

$$M_o = b + \left(\frac{b_1}{b_1+b_2}\right)P \tag{2}$$

dimana:

- M_o = modus
- B = batas bawah kelas interval dengan frekuensi terbanyak
- P = panjang kelas interval
- b_1 = frekuensi terbanyak dikurangi frekuensi kelas sebelumnya
- b_2 = frekuensi terbanyak dikurangi frekuensi kelas sesudahnya

Data *precipitable water* harian diubah menjadi data *precipitable water* dasarian dengan cara menghitung menjumlahkan data *precipitable water* persepuluh hari.

B. Penetnuan Awal Musim Hujan (AMH)

Penentuan AMH didefenisikan menggunakan kriteria BMKG yaitu dengan menentukan AMH baru yang dihitung setelah normal dasarian AMH pada periode 1981-2010. Kriteria pertama yaitu AMH ditentukan dengan menjumlahkan curah hujan dasarian yang telah lebih dari 50 mm dan kemudiaan diharuskan diikuti dua dasarian berikutnya, apabila kriteria pertama tidak terpenuhi maka dapat menggunakan kriteria kedua. Kriteria kedua yaitu AMH ditentukan dengan jumlah curah hujan pada 3 (tiga) dasarian telah lebih dari 150 mm.

C. ARIMA

ARIMA adalah model pendekatan kuantitatif yang dipopulerkan oleh George Box dan Gwilym Jenkins[9]. Metode ARIMA menggunakan data masa lalu sebagai acuan dalam memprakirakan masa mendatang [10]. Metode ARIMA lebih mudah untuk mengikuti fluktuasi data dibandingkan metode statistik lainnya. ARIMA dibedakan menjadi model ARIMA nonmusiman, model ARIMA musiman (*Seasonal ARIMA/ SARIMA*) dan gabungan antara model ARIMA non-musiman dan musiman atau sering disebut sebagai ARIMA musiman multiplikatif. Secara umum model ARIMA non musiman terdiri dari model *autoregressive* (AR), *model moving average* (MA), model ARMA dan model ARIMA.

ARIMA merupakan metode runtut waktu yang tidak stasioner terhadap mean dan agar menjadi stasioner dibutuhkan proses *differencing* sebanyak d . Bentuk umum model ARIMA pada orde ke-p,q dengan *differencing* sebanyak d atau ARIMA(p,d,q) adalah sebagai [6]

$$\phi_p(B)(1-B)^d Z_t = \theta_0 + \theta_q(B)a_t \tag{3}$$

dengan

$$\phi_p(B) = (1 - \phi_1 B - \phi_2 B - \dots - \phi_p B^p) \tag{4}$$

$$\theta_q(B) = (1 - \theta_1 B - \theta_2 B - \dots - \theta_q B^q) \tag{5}$$

dimana $\phi_p(B)$ adalah operator dari AR, $\theta_q(B)$ adalah operator MA dan $(1 - B)$ adalah operator *backward shift* dengan d adalah orde *differencing*. Ketika $p = 0$, model ARIMA (p,d,q) dapat disebut sebagai model *integrated moving average*. Begitu juga ketika $q = 0$, model ARIMA(p,d,q) dapat disebut sebagai model *autoregressive integrated*.

ARIMA musiman (SARIMA) adalah model yang dibuat dari komposisi data yang dipengaruhi faktor musiman, sehingga plot yang dihasilkan membentuk pola musiman. Model ARIMA dengan periode musiman s dapat dinotasikan ARIMA (P,D,Q)^s dengan modelnya sebagai berikut[6]

$$\Phi_P(B^s)(1 - B^s)^D Z_t = \Theta_Q(B^s)a_t \tag{6}$$

dengan

$$\Phi_P(B^s) = (1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_p B^{ps}) \tag{7}$$

$$\Theta_Q(B^s) = (1 - \theta_1 B^s - \theta_2 B^{2s} - \dots - \theta_q B^{qs}) \tag{8}$$

dimana $\Phi_P(B^s)$ adalah faktor dari AR musiman, $\Theta_Q(B^s)$ adalah faktor MA musiman dan $(1 - B^s)^D$ adalah *differencing* musiman s dengan D adalah orde *differencing*.

1. Stasioneritas Time Series

Suatu data *time series* yang dapat analisis adalah data yang bersifat stasioner. Stasioner adalah keadaan dimana mean dan varians adalah konstan[11]. dengan demikian

Mean dari Z_t :

$$E(Z_t) = E(Z_{t+k}) = \mu \tag{9}$$

Varians dari Z_t :

$$E(Z_t - \mu)^2 = E(Z_{t+k} - \mu)^2 = \sigma^2 \tag{10}$$

Apabila nilai observasi sebanyak n berfluktuasi terhadap nilai varians dan *mean* secara konstan serta tidak terpengaruh waktu, maka dapat disimpulkan bahwa data *time series* tersebut adalah stasioner. Sebaliknya apabila nilai observasi sejumlah n tidak berfluktuasi terhadap means dan varian secara konstan, maka data disimpulkan bahwa *time series* tersebut tidak stasioner [11]Adapun cara untuk mengatasi ketidakstasioneran adalah dengan melakukan pembedaan (*differencing*) atau dengan transformasi *Box-cox*. Pembedaan (*differencing*) dibuat jika data tidak stasioner terhadap mean, sedangkan Transformasi *Box-cox* dibuat jika data tidak stasioner terhadap varians [12]

Stasioneritas data dalam mean dapat dilakukan dengan mengidentifikasi plot data dan bentuk ACF data. Apabila ACF menunjukkan kondisi pola yang turun lambat berarti data belum stasioner dalam mean. Dalam kondisi seperti maka dibutuhkan *differencing* agar datanya stasioner dalam mean. Namun apabila ACF menunjukkan kondisi pola yang menurun dengan cepat maka kondisi ini menunjukkan data sudah stasioner dalam mean. Adapun metode yang digunakan dalam mengatasi kondisi non-stasioner dalam mean adalah melakukan pembedaan (*differencing*) terhadap data dengan persamaan berikut [11]

$$W_t = Z_t - Z_{t-1} \tag{11}$$

dimana W_t merupakan nilai series Z_t setelah dilakukan *differencing*.

Sedangkan suatu deret waktu Z_t dikatakan tidak stasioner terhadap varians, apabila Z_t berubah sejalan dengan perubahan level $(Z_t) = cf(\mu_t)$, dimana c merupakan konstanta. *Box*

dan Cox pada teorinya memberikan pemahaman bahwa transformasi terhadap varians yang tidak konstan dapat menggunakan *power transformation* sebagai berikut [6]

$$T(Z_t) = \frac{Z_t^\lambda - 1}{\lambda}, \text{ dimana } \lambda \neq 0 \tag{12}$$

λ adalah parameter transformasi, untuk $\lambda = 0$ dilakukan pendekatan berikut :

$$\lim_{\lambda \rightarrow 0} T(Z_t) = \lim_{\lambda \rightarrow 0} Z_t^{(\lambda)} = \lim_{\lambda \rightarrow 0} \frac{Z_t^\lambda - 1}{\lambda} = \ln(Z_t) \tag{13}$$

2. Identifikasi Model

Apabila data telah stasioner kemudian diidentifikasi model dengan mengamati plot ACF dan PACF. Nilai p dilihat dengan mengamati plot PACF dan nilai q dilihat dengan mengamati plot ACF. Kondisi data yang tidak terdapat faktor musiman, maka untuk menduga model dapat dilakukan dengan memperhatikan kriteria seperti pada tabel berikut

Tabel 1. Struktur ACF dan PACF Pada Model ARIMA Reguler

Model	ACF	PACF
<i>Autoregressive</i> (p)	Turun eksponensial (<i>dies – down</i>)	Terpotong setelah lag-p (<i>cut off after lag-p</i>)
<i>Moving Average</i> (q)	Terpotong setelah lag-q (<i>cut off after lag-q</i>)	Turun eksponensial (<i>dies – down</i>)
<i>Autoregressive-Moving Average</i> (p,q)	Turun eksponensial (<i>dies – down</i>)	Turun eksponensial (<i>dies – down</i>)
<i>Autoregressive</i> (p) atau <i>Moving Average</i> (q)	Terpotong setelah lag-q (<i>cut off after lag-q</i>)	Terpotong setelah lag-p (<i>cut off after lag-p</i>)

Sedangkan pendugaan model yang terdapat faktor musiman dilakukan dengan memperhatikan kriteria seperti tabel berikut [11]

Tabel 2. Struktur ACF dan PACF Pada Model ARIMA Reguler

Model	ACF	PACF
<i>Autoregressive</i> (p)	Turun eksponensial (<i>dies – down</i>)	Terpotong setelah lag s, 2s,...,Ps (<i>cut off after lag Ps</i>)
<i>Moving Average</i> (q)	Terpotong setelah lag s, 2s,...,qs (<i>cut off after lag Qs</i>)	Turun eksponensial (<i>dies – down</i>)
<i>Autoregressive-Moving Average</i> (p,q)	Turun eksponensial (<i>dies – down</i>)	Turun eksponensial (<i>dies – down</i>)
<i>Autoregressive</i> (p) atau <i>Moving Average</i> (q)	Terpotong setelah lag s, 2s,...,qs (<i>cut off after lag Qs</i>)	Terpotong setelah lag s, 2s,...,Ps (<i>cut off after lag Ps</i>)

3. Uji Signifikansi Model

Pengujian parameter dilakukan untuk mengetahui apakah parameter signifikan terhadap model. pengujian signifikansi parameter dapat dinyatakan sebagai [11]

Hipotesis :

$H_0 : \beta = 0$ (parameter tidak signifikan)

$H_1 : \beta \neq 0$ (parameter signifikan)

dimana β adalah parameter pada model ARIMA

Statistik uji :

$$t = \frac{\hat{\beta}}{SE(\hat{\beta})} \quad (14)$$

Daerah penolakan : Tolak H_0 jika $|t| > t_{\alpha/2; n-m}$, dengan

$SE(\hat{\beta})$: standar error dari nilai taksiran β

m : banyaknya parameter yang ditaksir

4. Pengujian Asumsi

Asumsi yang harus dipenuhi pada model ARIMA meliputi asumsi residual *white noise* dan residual berdistribusi normal (Wei, 2006). Berikut adalah pengujian asumsi *white noise* dan uji kenormalan. *White noise* adalah suatu proses apabila tidak terdapat korelasi pada suatu deret residual. Untuk menguji kondisi residual yang telah memenuhi asumsi *white noise* maka dapat digunakan statistik uji yang dikemukakan oleh *Ljung Box*. Hipotesisnya adalah sebagai berikut :

$H_0 : \rho_1 = \rho_2 = \rho_K = 0$ (residual tidak saling berkorelasi)

H_1 : minimal ada satu $\rho_k \neq 0$ (residual saling berkorelasi), dengan $k = 1, 2, 3, \dots, K$.

Statistik uji :

$$Q = n(n+2) \sum_{k=1}^K (n-k)^{-1} \hat{\rho}_k^2 \quad (15)$$

Daerah Penolakan : tolak H_0 , jika nilai dari $Q > \chi^2_{(\alpha; K-p-q)}$ atau $P\text{-value} < \alpha$

dimana : p dan q adalah orde ARIMA

n : jumlah observasi dari *time series*

$\hat{\rho}_k$: taksiran autokorelasi residual lag k

Untuk pengujian kenormalan dengan memeriksa kenormalan data residual dengan melihat kecenderungan membentuk garis lurus (linier) pada *normal probability plot*.

5. Prediksi

Dilakukan menggunakan model terbaik yang memenuhi syarat estimasi parameter, pemeriksaan asumsi residual *white noise* dan berdistribusi normal.

D. Jaringan Syaraf Tiruan *Backpropagation*

JST dibuat untuk memberikan kemampuan jaringan mengenai pola. Model JST dapat dibuat apabila sudah menentukan data latih dan data uji. Metode JST yang digunakan adalah *backpropagation*. Pelatihan *backpropagation* meliputi 3 fase, yaitu fase propagasi maju (*feedforward*), fase propasi mundur (*backpropagation*), dan fase modifikasi bobot. Selain itu,

beberapa hal yang perlu ditentukan guna optimalisasi arsitektur backpropagation adalah sebagai berikut.

- a. Pemilihan bobot dan bias awal
Inisialisasi bobot adalah dengan cara mengambil nilai random yang cukup kecil [13]
- b. Jumlah lapisan dan unit tersembunyi
Jumlah lapisan tersembunyi (*hidden layer*) yang digunakan di dalam penelitian ini adalah 1. 1 *hidden layer* sudah cukup dan tidak membutuhkan banyak komputasi saat pelatihan [14] Sedangkan, jumlah unit tersembunyi (*hidden neuron*) yang digunakan berdasarkan aturan Heaton. Aturan Heaton engemukakan beberapa aturan untuk menentukan jumlah unit tersembunyi (*hidden neuron*) yang tepat untuk digunakan dalam lapisan tersembunyi (*hidden layer*) ([15])
 - 1. Jumlah *hidden neuron* harus berada diantara ukuran *input layer* dan *output layer*
 - 2. Jumlah *hidden neuron* harus 2/3 ukuran *input layer*, ditambah ukuran *output layer*.
 - 3. Jumlah *hidden neuron* harus kurang dari dua kali ukuran *input layer*.
- c. Jumlah pola pelatihan (training)
Training dilakukan terhadap setiap model prediksi pada masing-masing hidden neuron-nya. Jumlah pola pelatihan (training) dilakukan sampai menghasilkan nilai error yang stabil.
- d. Lama iterasi (*epoch*)
Banyaknya epoch yang digunakan pada setiap training model yaitu 1000. dalam penelitian terhadap prediksi curah hujan bulanan di Stasiun Tenggarong, Kalimantan Timur menunjukkan 1000 epoch menghasilkan nilai *Mean Square Error* terbaik [16].
- e. Parameter laju pelatihan (*learning rate*)
Pada penelitian ini menggunakan *adaptive learning rate*. Nilai learning rate pertama yaitu 0.01. Kemudian untuk nilai *learning rate* berikutnya bernilai 1.05 kali lebih besar dari yang sebelumnya hingga mencapai hasil konvergen. Namun, jika hasil yang diperoleh menunjukkan divergen, maka nilai *learning rate* berikutnya dikali 0.7.

E. Validasi dan Verifikasi Hasil Prediksi

a. Root Mean Square

Root Mean Square Error (RMSE) merupakan nilai rerata akar kuadrat dari residu antara prediksi dengan observasi. Hal ini untuk mengetahui besaran nilai simpangannya (*error*). RMSE digunakan untuk mengetahui besarnya penyimpangan yang terjadi antara nilai prakiraan curah hujan dasarian yang dihasilkan model JST dan ARIMA dengan nilai observasi. Hasil validasi RMSE dikatakan baik apabila nilainya mendekati 0 (semakin kecil). Secara matematis formula RMSE sebagai berikut [17].

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (X_t - F_t)^2}{n}} \tag{16}$$

dengan

- X_t : nilai aktual pada waktu ke-t
- F_t : nilai dugaan pada waktu ke-t
- n : jumlah data

b. Metode Kontingensi

Metode Kontingensi yang digunakan untuk mengetahui apakah model dapat menunjukkan kinerja yang dapat diterima dalam memprediksi AMH. Dalam buku verifikasi prediksi iklim Indonesia, verifikasi terhadap suatu hasil prediksi sangat penting dilakukan, tujuannya adalah untuk memantau kualitas dari hasil prediksi, tujuannya adalah untuk mengetahui sejauhmana ketepatan prediksi yang dibuat serta mengetahui perbaikan dari waktu ke waktu. Dalam Kajian ini menggunakan metode verifikasi dengan metode kontingensi. Dalam buku Verifikasi Prediksi Iklim Indonesia Pada Tahun 2012, keakuratan suatu prediksi dinyatakan dalam persentase kesesuaian dengan istilah “Sesuai Prediksi” dan “Menyimpang Prediksi”. Apabila (x_i, y_i) merupakan data series pasangan pprediksi dengandata observasinya maka dapat dibentuk table kontingensi untuk setiap pasangan (x_i, y_i) . Jumlah pasangan (x_i, y_i) kemudian dijabarkan dalam notasi n_i .

Table 3. Kontingensi Jumlah Pasangan Prediksi dan Observasi di Setiap Kategori

ij	Observasi					Jml
	1	2	...j...	K		
Prediksi	1	P_{11}	P_{12}	P_{1j}	P_{1k}	$\sum P_{1j}$
	2	P_{21}	P_{22}	P_{2j}	P_{2k}	$\sum P_{2j}$
	...i...	P_{i1}	P_{i2}	P_{ij}	P_{ik}	$\sum P_{2j}$
	K	P_{k1}	P_{k2}	P_{kj}	P_{kk}	$\sum P_{2j}$

Dari tabel diatas dibentuk tabel kontingensi berikutnya yang berisi nilai *frekuensi relative*. Apabila jumlah data adalah n_i , maka *frekuensi relative* dari jumlah pasangan prediksi tersebut kategori i dan observasi kategori j adalah P_{ij} .

$$P_{ij} = n_{ij} / n \tag{17}$$

c. Skill Score

Model prediksi AMH dikatakan memiliki skill yang lebih baik dibandingkan dengan prediksi menggunakan data normalnya jika skill bernilai antara 0 hingga sama dengan 1. Menurut WMO (2000) nilai skill dapat dihitung menggunakan rumus sebagai berikut :

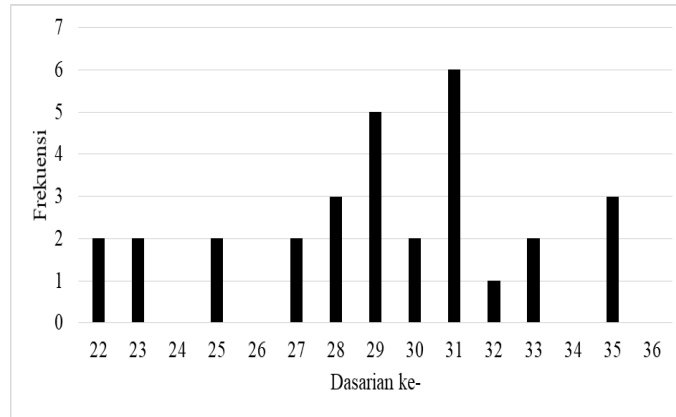
$$Skill\ Score = 1 - \frac{MAE_f}{MAE_n} \tag{18}$$

dengan MAE_f adalah selisih data observasi dengan prediksinya sedangkan MAE_n adalah selisih data observasi dengan data normalnya.

HASIL DAN PEMBAHASAN

A. Pola Curah Hujan dan Awal Musim Hujan Kota Pangkalpinang


Berdasarkan pembagian pola hujan di Indonesia, Pangkalpinang termasuk dalam wilayah yang memiliki pola hujan monsunial yang mana musim hujan dan musim kemarau dapat dibedakan secara jelas [18]. Berikut adalah karakteristik pola curah hujan di Pangkalpinang.



Gambar 2. Pola Curah Hujan Pangkalpinang Periode 1981-2010

Berdasarkan gambar 2 menunjukkan bahwa secara umum curah hujan tertinggi terjadi pada dasarian ke-1 yaitu 122,2 mm (Januari dasarian pertama), sedangkan curah hujan terendah terjadi pada pada dasarian ke-26 dengan 31,2 mm (September dasarian kedua).

Penentuan awal musim hujan (AMH) kemudian dilakukan dengan metode kriteria yang telah ditetapkan oleh BMKG yaitu AMH dilihat dengan jumlah curah hujan dasarian telah lebih 50 mm dan diikuti dua dasarian berikutnya, apabila tidak memenuhi kriteria pertama maka AMH dimulai dengan jumlah curah hujan dalam tiga (3) dasarian telah lebih dari 150 mm.



Gambar 3. Distribusi frekuensi AMH Pangkalpinang periode 1981-2010

Berdasarkan gambar 3, awal musim hujan sering terjadi pada dasarian ke-31 atau terjadi pada bulan November dasarian pertama dengan frekuensi kejadian 6 kali. Awal musim hujan tercepat terjadi pada dasarian ke-22 (pada bulan Agustus dasarian pertama) dan awal musim hujan paling akhir terjadi pada dasarian ke-35 (pada bulan Desember dasarian kedua). Selama periode tersebut

juga tidak pernah terjadi AMH pada dasarian 26 (pada bulan September dasarian kedua), dasarian 34 (Desember dasarian pertama) dan dasarian 36 (Desember dasarian ketiga).

Jumlah data AMH maju pada periode 1981-2010 sebanyak 11 kali, sedangkan jumlah data AMH mundur pada periode 1981-2010 sebanyak 14 kali sedangkan sesuai dengan normalnya sebanyak 5 kali. Hal ini menunjukkan bahwa AMH di Pangkalpinang cenderung mundur dari normalnya selama periode 1981-2010

B. Model Prediksi Curah Hujan dengan Jaringan Syaraf Tiruan

Pemodelan Jaringan Saraf Tiruan (JST) terdiri atas 1 lapisan input, 1 *hidden layer* dan 1 lapisan output. Input pada pemodelan JST adalah data SML, angin zonal dan *precipitable water* hasil dari pemilihan prediktor. Pemodelan JST menggunakan pembelajaran *Backpropagation*. Karakteristik dan spesifik yang digunakan pada arsitektur jaringan syaraf tiruan dapat dilihat pada Tabel 4.

Tabel 4. Karakteristik dan Spesifikasi JST Untuk Prediksi Curah Hujan

Karakteristik	Spesifikasi
Arsitektur	1 <i>hidden layer</i>
Neuron Input	3 neuron (suhu muka laut, angin zonal,
Neuron Output	<i>precipitable water</i>)
Hidden Neuron	1 target data
Learning Rate	2
Fungsi Aktivasi	<i>adaptive learning rate</i>
Algoritma JST	Sigmoid biner <i>backpropagation</i>

Simulasi prediksi dilakukan dengan menggunakan skema *lag time* terbaik pada setiap periode musiman untuk tahun 2011 sampai dengan 2017. Simulasi prediksi untuk 9 dasarian kedepan (simulasi sesuai periode musiman).

C. Model Dugaan SARIMA Terbaik

Setelah menemukan beberapa model untuk dugaan yang elah memenuhi asumsi dan signifikansi, selanjutnya memilih model terbaik. Pemilihan model terbaik digunakan untuk mendapatkan model yang paling akurat diantara model-model lainnya. 2 model dugaan yang telah signifikan dan memenuhi asumsi adalah SARIMA (1,0,1) (2,1,0)³⁶ dan SARIMA (1,0,1) (0,1,1)³⁶. Selanjutnya dari kedua model ini akan dilihat nilai RMSE terendah dan korelasi tertinggi untuk dipilih sebagai model terbaik diantara keduanya.

Tabel 5. Hasil Perhitungan RMSE dan Korelasi Model SARIMA Terbaik Periode Musiman

Periode	Model SARIMA (1,0,1) (2,1,0) ³⁶		Model SARIMA (1,0,1) (0,1,1) ³⁶	
	RMSE	Korelasi	RMSE	Korelasi
DJF	78.80	-0.20	68,20	-0.03
MAM	62.30	-0.18	51,30	0.10
JJA	42.20	0.001	34,90	0.10

SON 57.10 0.2 50,50 0.32

Berdasarkan dari penjabaran diatas dapat dilihat bahwa nilai RMSE terkecil terdapat pada model SARIMA (1,0,1) (0,1,1)³⁶ dengan 51,225 dan korelasi sebesar 0,12, sehingga model tersebut dipilih sebagai model ARIMA untuk prediksi curah hujan di Pangkalpinang.


Dengan mengkombinasikan persamaan (3) dan persamaan (6) maka Model SARIMA (1,0,1) (0,1,1)³⁶ secara matematis dapat dituliskan sebagai berikut.

- $(1 - \phi_1 B)(1 - B)(1 - B^{36})Z_t = (1 - \theta_1 B)(1 - \Theta_1 B^{36})a_t$
- $(1 - B^{36} - B + B^{37} - \phi_1 B + \phi_1 B^{37} + \phi_1 B^2 - \phi_1 B^{38})Z_t = (1 - \theta_1 B - \Theta_1 B^{36} + \theta_1 \Theta_1 B^{36})a_t$
- $Z_t = Z_{t-1} + Z_{t-36} - Z_{t-37} + \phi_1 Z_{t-1} - \phi_1 Z_{t-2} - \phi_1 Z_{t-37} + \phi_1 Z_{t-38} - \theta_1 a_{t-1} - \Theta_1 a_{t-36} + \theta_1 \Theta_1 a_{t-37} + a_t$
- $Z_t = Z_{t-1} + Z_{t-36} - Z_{t-37} + 0,8205Z_{t-1} - 0,8205Z_{t-2} - 0,8205Z_{t-37} + 0,8205Z_{t-38} - 0,77135a_{t-1} - 0,9468a_{t-36} + 0,7769a_{t-37} + a_t$

Dimana nilai Z_t merupakan nilai transformasi ln, untuk mengembalikan ke nilai aslinya (curah hujan) harus dikembalikan dengan $\exp(Z_t)$. Model tersebut menunjukkan bahwa curah hujan di Pangkalpinang pada dasarian ke-t dipengaruhi oleh curah hujan pada 1 dasarian sebelumnya, curah hujan pada 36 dasarian sebelumnya, curah hujan pada 37 dasarian sebelumnya, curah hujan pada 38 dasarian sebelumnya, kesalahan prediksi pada 1 dasarian sebelumnya, kesalahan prediksi pada 36 dasarian sebelumnya, kesalahan peramalan pada 37 dasarian sebelumnya dan kesalahan prediksi pada waktu ke-t.

D. Perbandingan Prediksi Curah Hujan Model JST dan SARIMA Terbaik


Selanjutnya hasil prediksi curah hujan dari dua model yaitu JST dan SARIMA akan dibandingkan dengan curah hujan aktual periode musiman tahun 2011-2017.



Gambar 4. Perbandingan curah hujan actual dengan model prediksi JST dan SARIMA terbaik periode DJF

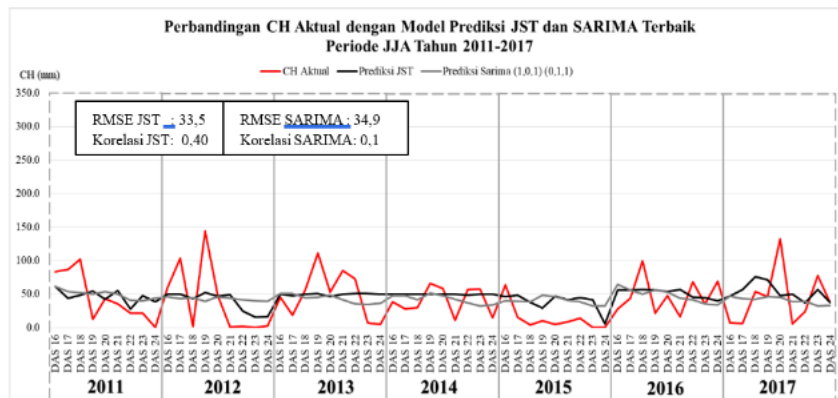
Perbandingan CH aktual dengan model prediksi JST dan SARIMA pada periode DJF menunjukkan bahwa persamaan model JST adalah model persamaan terbaik dalam memprakirakan curah hujan

dasarian di Pangkalpinang, pada periode DJF ditunjukkan dengan nilai korelasi paling tinggi dengan nilai 0,22 dan RMSE paling rendah dengan nilai 66,1.



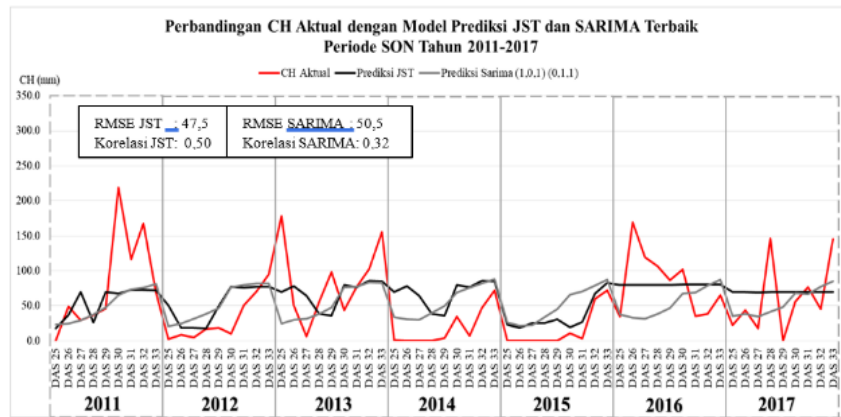
Gambar 5. Perbandingan curah hujan aktual dengan model prediksi JST dan SARIMA terbeik periode MAM

Perbandingan CH aktual dengan model prediksi JST dan SARIMA pada periode MAM menunjukkan bahwa persamaan model JST adalah model persamaan terbaik dalam memprakirakan curah hujan dasarian di Pangkalpinang, pada periode MAM ditunjukkan dengan nilai korelasi paling tinggi yaitu 0,20 dan RMSE yang hampir sama dengan SARIMA yaitu 52,4.



Gambar 6. Perbandingan curah hujan aktual dengan model prediksi JST dan SARIMA terbaik periode JJA

Perbandingan CH aktual dengan model prediksi JST dan SARIMA pada periode JJA (musim kemarau) menunjukkan bahwa persamaan model JST adalah model persamaan terbaik dalam memprakirakan curah hujan dasarian periode JJA di Pangkalpinang, pada periode JJA ditunjukkan dengan nilai korelasi paling tinggi yaitu 0,4 dan RMSE paling rendah yaitu 33,5.



Gambar 7. Perbandingan curah hujan aktual dengan model prediksi JST dan SARIMA terbaik periode SON

Perbandingan CH aktual dengan model prediksi JST dan SARIMA pada periode SON menunjukkan bahwa persamaan model JST adalah model persamaan terbaik dalam memprakirakan curah hujan dasarian periode SON di Pangkalpinang, pada periode SON ditunjukkan dengan nilai korelasi paling tinggi yaitu 0,50 dan RMSE paling rendah yaitu 47,5.

Curah hujan Pangkalpinang dipengaruhi oleh parameter iklim lain seperti suhu muka laut, angin zonal dan *precipitable water* dengan *time lag* yang sesuai dan saling mempengaruhi, sehingga model JST menghasilkan hasil prediksi curah hujan yang lebih baik dibandingkan model persamaan SARIMA terbaik yang hanya mengandalkan data *timeseries* curah hujan masa lampau untuk memprediksi curah hujan dasarian kedepan.

E. Prediksi Awal Musim Hujan (AMH) Berdasarkan Prediksi Model Terbaik

Berdasarkan hasil prediksi curah hujan dengan model JST dan SARIMA (1,0,1) (0,1,1)³⁶, kemudian dilakukan prediksi AMH tahun 2011-2017 di Pangkalpinang, sebagai berikut:

Tabel 6. Hasil Prediksi AMH Berdasarkan Prediksi Curah Hujan Model Terbaik

Tahun	Prediksi AMH JST	Prediksi SARIMA (1,0,1) (0,1,1) ³⁶	AMH Aktual	Normal AMH
2011	27	28	30	29
2012	30	28	31	29
2013	30	28	25	29
2014	30	28	33	29
2015	31	29	32	29
2016	25	28	24	29
2017	23	28	28	29

Tabel 6 menunjukkan hasil prediksi AMH dengan JST di Pangkalpinang periode tahun 2011-2017, paling awal terjadi pada tahun 2017 yaitu AMH jatuh di dasarian ke-23 (Agustus dasarian ke-2), sedangkan AMH paling lambat terjadi pada tahun 2015 yaitu AMH jatuh di dasarian ke-31

(November dasarian-1). Hasil prediksi AMH dengan SARIMA (1,0,1) (0,1,1)³⁶ di Pangkalpinang periode tahun 2011-2017, secara umum jatuh di dasarian 28 (Oktober dasarian ke-1).

Pola antara AMH observasi dan AMH hasil prediksi model JST cenderung mempunyai fluktuasi yang serupa dan terlihat hasil prediksi AMH dengan JST cenderung mengikuti AMH observasi. Akan tetapi, pada terdapat tahun-tahun tertentu yang hasil prediksi dengan JST tidak mengikuti pola observasi. Penyimpangan terbesar dari hasil prediksi AMH dengan JST jika dibandingkan dengan observasinya sebesar 5 dasarian yang terjadi pada tahun 2013 dan 2017. Sedangkan, prediksi AMH dengan SARIMA tidak memiliki pola.

F. Verifikasi Awal Musim Hujan (AMH)

Salah satu upaya untuk mengetahui apakah hasil prediksi awal musim hujan yang telah dilakukan memiliki kualitas baik atau tidak maka dilakukan verifikasi. Untuk memverifikasi apakah hasil suatu prediksi yang telah dilakukan baik atau tidak ialah dengan membandingkan data hasil prediksi dengan data observasi. Metode verifikasi yang digunakan yaitu metode kontingensi. Nilai akurasi dari satu prediksi dinyatakan dalam bentuk persentase dengan istilah “Sesuai Prakiraan” dan “Menyimpang Prakiraan”. Berdasarkan hasil verifikasi AMH dengan kontingensi dan definisi kesesuaian prakiraan awal musim dari BMKG dengan rentang kesesuaian +/- 1 dasarian (10 hari) dapat dihitung nilai akurasi untuk “Sesuai Prakiraan” dan “Menyimpang Prakiraan”

$$\text{Sesuai Prakiraan} : \frac{3}{7} \times 100\% = 42,86\% \text{ dan}$$

$$\text{Menyimpang Prakiraan} : 100\% - 42,86\% = 57,14\%$$

Berdasarkan hasil kesesuaian prakiraan, dapat terlihat bahwa hasil prediksi AMH dengan JST dari 7 kejadian yang mempunyai rentang kesesuaian dengan AMH aktual adalah sebanyak 3 kejadian. Tingkat akurasi hasil verifikasi yang tergolong “sesuai prakiraan” adalah sebanyak 3 kejadian dan yang “menyimpang prakiraan” sebanyak 4 kejadian. Persentase hasil prediksi yang “sesuai prakiraan” sebesar 42,86%. Adapun penjelasan dari sedikitnya kelompok jumlah tahun yang menyatakan “sesuai prakiraan” disebabkan oleh beberapa factor seperti pemilihan prediktor yang mempengaruhi AMH di Pangkalpinang, penggunaan metode untuk memprediksi awal musim hujan yang belum cukup baik untuk memprediksi jika adanya fenomena lokal maupun global yang mempengaruhi awal musim hujan di Pangkalpinang. Selain itu, menggunakan Skill Score untuk mengetahui AMH dikatakan memiliki skill yang lebih baik dibandingkan dengan prediksi menggunakan data normalnya. Hasilnya menunjukkan skill prediksi AMH periode 2011-2017 menggunakan prediksi CH model JST adalah 0,05. (dimana mendekati skill score 1, prediksi mendekati sempurna).

Berdasarkan hasil verifikasi AMH dengan kontingensi dan definisi kesesuaian prakiraan awal musim dari BMKG dengan rentang kesesuaian +/- 1 dasarian (10 hari) dapat dihitung nilai akurasi untuk “Sesuai Prakiraan” dan “Menyimpang Prakiraan”

$$\text{Sesuai Prakiraan} : \frac{1}{7} \times 100\% = 14,26\% \text{ dan}$$

$$\text{Menyimpang Prakiraan} : 100\% - 14,26\% = 85,74\%$$

Berdasarkan hasil kesesuaian prakiraan dan perhitungan *skill score*, dapat terlihat bahwa hasil prediksi AMH dengan SARIMA (1,0,1) (0,1,1)³⁶ dari 7 kejadian yang mempunyai rentang kesesuaian dengan AMH aktual adalah sebanyak 1 kejadian. Tingkat akurasi hasil verifikasi yang tergolong “sesuai prakiraan” adalah sebanyak 1 kejadian dan yang “menyimpang prakiraan”

sebanyak 6 kejadian. Persentase hasil prediksi yang “sesuai prakiraan” sebesar 14,26%. Selain itu, menggunakan *Skill Score* untuk mengetahui AMH dikatakan memiliki *skill* yang lebih baik dibandingkan dengan prediksi menggunakan data normalnya. Hasilnya menunjukkan *skill* prediksi AMH periode 2011-2017 menggunakan prediksi CH model SARIMA (1,0,1) (0,1,1)³⁶ adalah 0. (dimana mendekati *skill score* 1, prediksi mendekati sempurna).

Berdasarkan kesesuaian prakiraan dan perhitungan *skill score* prediksi AMH dari hasil prediksi curah hujan model JST dan SARIMA (1,0,1) (0,1,1)³⁶ menunjukkan bahwa hasil prakiraan AMH menggunakan model JST lebih baik daripada SARIMA di kota Pangkalpinang. Hal ini dikarenakan model JST menggunakan prediktor seperti *precipitable water*, angin zonal dan suhu muka laut dibandingkan dengan SARIMA yang hanya menghadalkan data masa lalu untuk melakukan prediksi.

KESIMPULAN

Berdasarkan hasil validasi model menunjukkan model prediksi JST lebih baik daripada model prediksi SARIMA yang hanya menggunakan data *series* curah hujan masa lampau. Akan tetapi model ini belum mampu untuk menduga curah hujan ekstrim. Menggunakan prediksi curah hujan model JST, hasil prediksi AMH di Pangkalpinang tahun 2011-2014 menunjukkan menyimpang dari normal AMH paling kecil adalah 1 dasarian dan paling besar adalah 6 dasarian. Sedangkan menggunakan prediksi curah hujan model SARIMA, hasil prediksi AMH di Pangkalpinang tahun 2011-2014 menunjukkan menyimpang dari normal AMH paling kecil adalah sesuai normal AMH (0 dasarian) dan paling besar adalah 1 dasarian. Verifikasi dari prediksi AMH menggunakan JST di Pangkalpinang menghasilkan kesesuaian model prediksi sebesar 42,86 % dengan nilai *skill* sebesar 0,05, sedangkan verifikasi dari prediksi AMH menggunakan SARIMA di Pangkalpinang menghasilkan kesesuaian model prediksi sebesar 14,26 % dengan nilai *skill* sebesar 0,00.

DAFTAR PUSTAKA

- [1] Kementerian Pertanian, *Statistik Perkebunan Indonesia 2015-2017 Lada*. Jakarta: Direktorat Jenderal Perkebunan, 2016.
- [2] T. H. S. Siregar and I. Suhendry, *Budidaya dan Teknologi Karet*. Bogor: Kanisius, 2013.
- [3] Badan Meteorologi Klimatologi dan Geofisika, *Prakiraan Musim Hujan 2013/2014 di Indonesia*. Jakarta: BMKG, 2013.
- [4] A. N. Khoir, “Prediksi Curah Hujan Bulanan di Pangkalpinang dengan Prediktor Precipitable Water dan Angin Zonal/ Meridional,” Sekolah Tinggi Meteorologi Klimatologi dan Geofisika, Tangerang Selatan, 2018.
- [5] L. Lubis and A. Buono, “Pemodelan Jaringan Syaraf Tiruan untuk Memprediksi Awal Musim Hujan Berdasarkan Suhu Permukaan Laut,” *Jurnal Ilmu Komputer dan Agri-Informatika*, vol. 1, p. 52, Nov. 2012, doi: 10.29244/jika.1.2.52-61.
- [6] W. Wei, *Time Series Analysis: Univariate and Multivariate Methods, 2nd edition*, 2006. 2006.
- [7] R. Ristiana, “Perbandingan Arima Dan Jaringan Syaraf Tiruan Propagasi Balik Dalam Peramalan Tingkat Inflasi Nasional,” Institut Pertanian Bogor, Bogor, 2015.

- [8] Y. Andriani, H. Silitonga, and A. Wanto, "Analisis Jaringan Syaraf Tiruan untuk prediksi volume ekspor dan impor migas di Indonesia," *Register: Jurnal Ilmiah Teknologi Sistem Informasi*, vol. 4, p. 30, Nov. 2018, doi: 10.26594/register.v4i1.1157.
- [9] A. Singh and G. C. Mishra, "Application of Box-Jenkins Method and Artificial Neural Network Procedure for Time Series Forecasting of Prices," *Statistics in Transition*, vol. 16, pp. 83–96, Mar. 2015, doi: 10.21307/stattrans-2015-005.
- [10] S. Rumagit and A. SN, "Prediksi Pemakaian Listrik Kelompok Tarif Menggunakan Jaringan Syaraf Tiruan dan ARIMA," *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, vol. 7, p. 189, Jul. 2013, doi: 10.22146/ijccs.3359.
- [11] Bowerman B. L. and O'Connell R. T., *Forecasting and time series : an applied approach (3rd ed.)*. Duxbury Press, 1993.
- [12] J. D. Cryer and K.-S. Chan, *Time Series Analysis*. New York, NY: Springer New York, 2008. doi: 10.1007/978-0-387-75959-3.
- [13] T. Sutojo, E. Mulyanto, and V. Suhartono, *Kecerdasan Buatan*. Yogyakarta: ANDI, 2010.
- [14] L. Fausett, *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*. USA: Prentice-Hall, Inc., 1994.
- [15] J. Heaton, "Programming Neural Networks with Encog 2 in Java," 2010. [Online]. Available: <https://api.semanticscholar.org/CorpusID:64015064>
- [16] M. Mislán, H. H., S. Hardwinarto, S. Soeparto, and M. Aipassa, *Rainfall Monthly Prediction Based on Artificial Neural Network – A Case Study Tenggara Station, East Kalimantan – Indonesia*, vol. 59. 2015. doi: 10.1016/j.procs.2015.07.528.
- [17] Walpole, *Pengantar Statistika*, 3rd ed. Jakarta: PT Gramedia Pustaka Utama, 1995.
- [18] E. Aldrian and R. Susanto, "Identification of three dominant rainfall regions within Indonesia and their relationship to sea surface temperature," *Int. J. Climatol.*, vol. 23, pp. 1435–1452, Oct. 2003, doi: 10.1002/joc.950.