

Perbandingan Akurasi Peramalan Curah Hujan dengan menggunakan ARIMA, Hybrid ARIMA-NN, dan FFNN di Kabupaten Malang

(Comparison of Rainfall Forecasting Accuracy using ARIMA, Hybrid ARIMA-NN, and FFNN in Malang District)

Bestari Archita Safitri^{1*}, Atiek Iriany², dan Ni Wayan Surya Wardhani³

^{1,2,3} Universitas Brawijaya

Email: ¹bestariarchitassafitri@gmail.com, ²atiekiriiany@ub.ac.id, ³wswardhani@ub.ac.id

ABSTRAK

Analisis deret waktu adalah suatu pengamatan yang dibangun berdasarkan urutan waktu. Peranan analisis deret waktu bermanfaat di berbagai bidang khususnya meteorologi. Salah satu aspek meteorologi adalah curah hujan, yang mana dapat memberikan dampak bagi kehidupan manusia. Curah hujan memiliki pola yang rumit untuk diprediksi, sehingga diperlukan metode terbaik untuk meramalkan curah hujan. Terdapat beberapa metode yang mampu menganalisis intensitas curah hujan. Metode yang dapat digunakan untuk meramalkan curah hujan adalah metode ARIMA, metode *Feed Forward Neural Network* (FFNN), dan *hybrid* ARIMA-NN. Penelitian ini bertujuan untuk mendapatkan pemodelan dan prediksi curah hujan yang terbaik berdasarkan ketiga metode di atas. Data curah hujan yang digunakan berasal dari alat *Mini Weather Station* (MWS) di lokasi Dusun Supiturang dan Dusun Manggisari. Berdasarkan hasil penelitian, pada lokasi Supiturang didapatkan model terbaik yaitu ARIMA(1,1,1) dengan RMSE sebesar 3,4326. Pada lokasi Manggisari didapatkan model terbaik yaitu *Hybrid* ARIMA(1,1,1) FFNN(4-9-1) dengan RMSE sebesar 3,1056.

Kata Kunci: ARIMA, Curah Hujan, FFNN, *Hybrid* ARIMA-NN, RMSE.

ABSTRACT

Time series analysis is an observation that is built on time sequences. Time series analysis is useful in various fields, especially meteorology. One aspect of meteorology is rainfall, which can have an impact on human life. Rainfall has a complicated pattern to predict, so we need the best method for forecasting rainfall. There are several methods that can analyze the intensity of rainfall. Methods that can be used to predict rainfall are ARIMA method, Feed Forward Neural Network (FFNN) method, and hybrid ARIMA-NN. This study aims to obtain the best rainfall modeling and prediction based on the three methods above. The rainfall data used came from the Mini Weather Station (MWS) at Supiturang and Manggisari hamlets. Based on the results of the study, at Supiturang, the best model was ARIMA(1,1,1) with RMSE of 3.4326. At Manggisari, the best model is Hybrid ARIMA(1,1,1) FFNN(4-9-1) with RMSE of 3.1056.

Keywords: ARIMA, FFNN, *Hybrid* ARIMA-NN, Rainfall, RMSE.

PENDAHULUAN

Negara Indonesia adalah titik temu sirkulasi meridional (Utara-Selatan) atau *Hardley* dan sirkulasi zonal (Timur-Barat) atau *Walker* yang berpengaruh pada keragaman iklim di Indonesia (Saputro, 2009). Selain itu, peningkatan konsentrasi rumah kaca di atmosfer juga menyebabkan perubahan iklim yang tidak terkendali dan berpotensi mengubah pola cuaca secara ekstrem di berbagai negara termasuk Indonesia. Curah hujan di Indonesia memiliki pola yang rumit dan sulit diprediksi, sehingga memerlukan metode khusus dalam menangani kondisi tersebut. Data curah hujan memiliki keterkaitan dengan waktu, oleh karena itu digunakan analisis deret waktu dengan memanfaatkan data curah hujan pada waktu sebelumnya untuk meramalkan curah hujan pada waktu yang akan datang (Wei, 2006).

Terdapat beberapa metode yang dapat digunakan dalam peramalan curah hujan, yaitu metode *Autoregressive Integrated Moving Average* (ARIMA) yang dikembangkan oleh Box dan Jenkins (1976). Metode ARIMA menjelaskan keterkaitan antar pengamatan pada variabel di suatu waktu dengan pengamatan variabel pada waktu sebelumnya, metode ARIMA baik digunakan untuk analisis data berpola linier. Selain ARIMA, terdapat metode lain yaitu *Neural Network* (NN). NN memudahkan dalam analisis data berpola linier maupun nonlinier. Salah satu arsitektur jaringan NN adalah *Feed Forward Neural Network* (FFNN). Zhang (2003) memperkenalkan kombinasi model ARIMA dengan NN. Pengombinasian dua metode tersebut dapat menjadi alternatif dalam melakukan peramalan data deret waktu jarang yang memiliki pola linier ataupun nonlinier.

Beberapa penelitian curah hujan yang sudah dilakukan diantaranya Susanto (2016) yaitu pemodelan curah hujan dengan pendekatan ARIMA, FFNN, dan *Hybrid* ARIMA-NN di Banyuwangi, didapatkan hasil penelitian bahwa model FFNN (3-3-1) merupakan pendekatan model terbaik dikarenakan memiliki nilai RMSE *out sample* terkecil apabila dibandingkan dengan ARIMA dan *Hybrid* (ARIMA-NN). Wahyuni dkk. (2017) meneliti tentang peramalan curah hujan menggunakan *Hybrid Adaptive Neuro-Fuzzy Inference System* (ANFIS) dan Algoritma Genetik, hasil penelitian menunjukkan bahwa ANFIS-GA menghasilkan RMSE terkecil dibanding metode lain. Penelitian Iriany dkk. (2020) tentang peramalan curah hujan menggunakan pendekatan model *neural network*, didapatkan hasil bahwa NN-GSTAR-SUR adalah model terbaik dan akurat untuk meramalkan curah hujan.

Pada pemodelan curah hujan ini, peneliti ingin melakukan penelitian dengan menggunakan pendekatan ARIMA, *Hybrid* ARIMA-NN, dan FFNN di Kabupaten Malang. Pemodelan dengan metode tersebut diharapkan dapat menghasilkan model yang terbaik dan prediksi yang akurat untuk data curah hujan tersebut.

METODE

Penelitian ini menggunakan pendekatan metode ARIMA dan FFNN serta kombinasi dari metode ARIMA dan FFNN atau *Hybrid* ARIMA-NN. *Software* yang digunakan adalah *Excel*, *R*, dan *Minitab*.

Sumber Data

Penelitian ini menggunakan data sekunder curah hujan di lokasi Supiturang dan Manggisari dari alat *Mini Weather Station* (MWS) oleh Iriany dkk. (2019) dengan data *update* per 5 menit setiap hari. Lokasi Supiturang dimulai pada periode tanggal 1 hingga 24 Februari 2021, sebanyak 4476 data. Sedangkan, lokasi Manggisari periode mulai tanggal 2 hingga 16 Desember 2020, sebanyak 3918 data.

Metode Analisis Data

a. Pemodelan ARIMA

- Melakukan uji stasioneritas ragam menggunakan transformasi *Box-Cox* menggunakan rumus:

$$T(Z_t) = \frac{Z_t^{\lambda} - 1}{\lambda} \text{ (Wei, 2006) (1)}$$

dimana:

$T(Z_t)$ = transformasi *Box-Cox*

Z_t = pengamatan pada periode waktu ke- t

λ = parameter transformasi

- Melakukan uji stasioneritas rata-rata menggunakan plot ACF atau menggunakan Uji *Augmented Dickey Fuller* (ADF).

$$\Delta Z_t = \beta_0 + (\beta_1 - 1)Z_{t-1} + a_t$$

$$\Delta Z_t = \beta_0 + \gamma Z_{t-1} + a_t$$

Dengan $\Delta Z_t = Z_t - Z_{t-1}$ dan $\gamma = (\beta_1 - 1)$. Jika $\gamma = 0$, maka $\beta_1 = 1$ artinya Z_t memiliki akar unit atau data tidak stasioner terhadap rata-rata. Parameter γ diestimasi menggunakan metode *Ordinary Least Square* (OLS) dengan statistik uji τ dan membandingkan nilai uji terhadap tabel kritis *Dickey Fuller*

$$\tau = \frac{\hat{\gamma} - \gamma}{se(\hat{\gamma})} \text{ (Rusdi, 2011) (2)}$$

dimana:

Z_{t-1} = pengamatan pada periode waktu ke- $(t-1)$

ΔZ_t = hasil *differencing* pertama pengamatan Z_t

τ = statistik uji

γ = parameter

$se(\hat{\gamma})$ = *standart error* penduga parameter model

- Menentukan orde ARIMA berdasarkan plot ACF dan PACF.

- Menduga parameter model menggunakan *Ordinary Least Square* (OLS) menggunakan rumus:

$$\hat{\phi} = \frac{\sum_{t=2}^n Z_{t-1} Z_t}{\sum_{t=2}^n Z^2_{t-1}} \text{ (Wei, 2006) (3)}$$

dimana:

$\hat{\phi}$ = penduga parameter OLS

- Menguji signifikansi parameter dengan statistik uji t menggunakan rumus:

$$t = \frac{\hat{\phi}_i}{se(\hat{\phi}_i)} \sim t_{(n-p)} \text{ (Wei, 2006) (4)}$$

dimana:

- $\hat{\phi}_i$ = penduga parameter model
- $se(\hat{\phi}_i)$ = standart error penduga parameter model
- p = banyak parameter
- n = banyak pengamatan

6. Melakukan pengujian asumsi *white noise* sisaan model dengan uji *Ljung-Box* menggunakan rumus:

$$Q = n(n + 2) \sum_{k=1}^k \frac{\hat{\rho}_k^2}{n-k} \sim \chi^2_{(k-m)} \text{ (Wei, 2006)} \dots\dots\dots (5)$$

dimana:

- k = banyak autokorelasi yang diuji
- n = banyak pengamatan
- m = banyak parameter yang diduga pada model ($m=p+q$)
- $\hat{\rho}_k$ = penduga autokorelasi sisaan pada lag ke- k

7. Melakukan pengujian normalitas sisaan model dengan uji statistik *Kolmogorov-Smirnov* menggunakan rumus:

$$D = \max |F_n(x) - F_0(x)| \sim D_{(N)} \dots\dots\dots (6)$$

dimana:

- $F_n(x)$ = fungsi kumulatif data contoh
- $F_0(x)$ = fungsi kumulatif distribusi normal

8. Memilih model terbaik ARIMA berdasarkan kriteria *Root Mean Square Error (RMSE)* menggunakan rumus:

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (\hat{Z}_t - Z_t)^2}{n}} \text{ (Willmott dan Matsuura, 2005)} \dots\dots\dots (7)$$

dimana:

- Z_t = pengamatan pada periode waktu ke- t
- n = banyak pengamatan

b. Pemodelan FFNN

1. Menentukan *input* berdasarkan *lag* PACF yang signifikan pada data.
2. Melakukan normalisasi data *input* menggunakan persamaan:

$$X' = \frac{x-a}{b-a} \text{ (Patro dan Sahu, 2015)} \dots\dots\dots (8)$$

dimana:

- a = data minimum
- b = data maksimum
- x = data asli
- X' = data normalisasi

3. Menentukan banyaknya *neuron* dan *hidden layer*
4. Melakukan pembelajaran jaringan menggunakan Algoritma *Backpropagation*.
5. Melakukan denormalisasi data *output* menggunakan rumus:

$$X = a + (\hat{y}(b - a)) \dots\dots\dots (9)$$

dimana:

- a = data minimum
- b = data maksimum
- x = data asli
- \hat{y} = data keluaran (*output*)

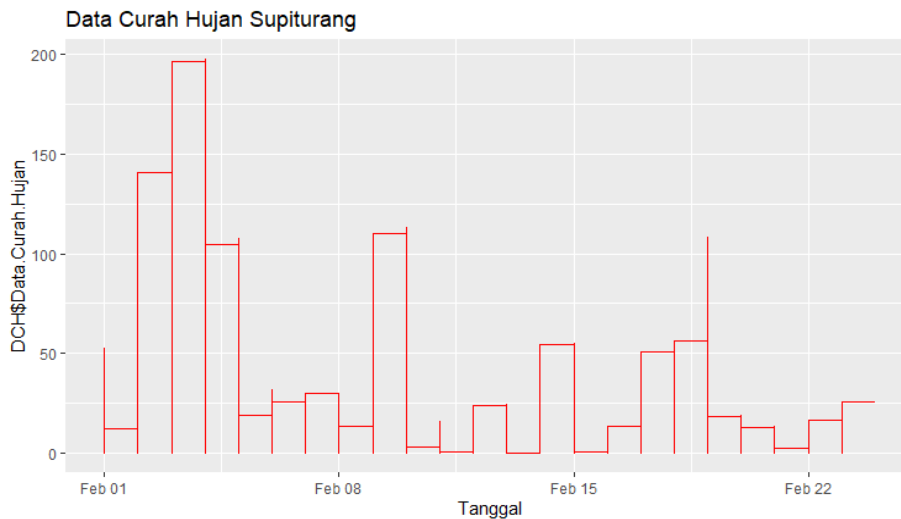
6. Memilih model terbaik berdasarkan kriteria RMSE dari data *training* maupun *testing*.

c. Pemodelan Hybrid ARIMA-NN

1. Menentukan *input* berdasarkan plot PACF sisaan pemodelan ARIMA.
2. Melakukan normalisasi data *input* sisaan ARIMA
3. Menentukan banyaknya *neuron* dan *hidden layer*
4. Melakukan pembelajaran jaringan menggunakan Algoritma *Backpropagation*.
5. Melakukan denormalisasi data *output*
6. Memilih model terbaik berdasarkan kriteria RMSE data *training* maupun *testing*.

HASIL DAN PEMBAHASAN

Data curah hujan pertama yang digunakan adalah data curah hujan di lokasi Supiturang. Gambaran awal mengenai curah hujan Supiturang dapat diketahui melalui plot curah hujan pada Gambar 1.



Gambar 1. Curah hujan daerah Supiturang.

Pada Gambar 1. diketahui awal bulan Februari curah hujan sangat tinggi, sedangkan pada akhir Februari curah hujan tergolong lebih rendah. Sebagian besar curah hujan yang terjadi di Supiturang sebesar 31,29 mm dengan curah hujan maksimal sebesar 197,54 mm.

Sebelum melakukan pemodelan pada data curah hujan menggunakan pendekatan ARIMA, *Hybrid* ARIMA-NN dan FFNN, dilakukan pengujian linieritas terhadap data yang akan digunakan. Pengujian tersebut dilakukan untuk mengetahui dan menangkap pola nonlinier pada data. Berdasarkan hasil pengujian linieritas diketahui bahwa $p\text{-value}$ (0,3707) $>$ α (0,05), maka dapat diputuskan menerima H_0 . Pada pengujian linieritas ini, dapat disimpulkan bahwa data curah hujan memiliki pola linier. Meskipun data yang digunakan dinyatakan linier, hal tersebut tidak menutup kemungkinan untuk tetap dilakukan pemodelan curah hujan menggunakan pendekatan *Neural Network* (NN) yang dapat mengatasi data yang berpola linier atau nonlinier.

Pemodelan curah hujan dengan ARIMA perlu dilakukan pengecekan stasioneritas terhadap ragam dan rata-rata. Data Supiturang tidak stasioner terhadap ragam karena memiliki λ sebesar 0,24 yang belum mendekati 1, sehingga diperlukan transformasi *Box-Cox* agar stasioner. Stasioneritas terhadap rata-rata diketahui melalui pengujian *Augmented Dickey Fuller* (ADF) dengan $p\text{-value}$ (0,01) $<$ α (0,05), sehingga data stasioneritas terhadap rata-rata. Tahap selanjutnya adalah pendugaan dan pengujian signifikansi parameter model yang dapat diketahui melalui Tabel 1.

Tabel 1. Pendugaan parameter dan uji signifikansi model Supiturang.

Model	Penduga Parameter	t hitung	t tabel		Keterangan
			$t_{(0,05,3133-p)}$	$t_{(0,1,3133-p)}$	
ARIMA (1,1,1)	$\phi_1 = 0,7546$	2,8615	1.9607	1.6453	Signifikan
	$\theta_1 = -0,7317$	2,6743	1.9607	1.6453	Signifikan
ARIMA (1,1,0)	$\phi_1 = 0,0280$	1,5642	1.9607	1.6453	Tidak Signifikan
ARIMA (0,1,1)	$\theta_1 = 0,0276$	1,5505	1.9607	1.6453	Tidak Signifikan

Pada Tabel 1, diketahui bahwa hanya model ARIMA (1,1,1) yang memiliki parameter signifikan, dengan koefisien penduga $\phi_1 = 0,7546$ dan $\theta_1 = -0,7317$. Pengujian asumsi *white noise* dan normalitas sisaan ARIMA (1,1,1), diketahui bahwa asumsi *white noise* terpenuhi karena $p\text{-value}$ (0,9762) $>$ α (0,05). Namun, pada asumsi normalitas tidak terpenuhi karena $p\text{-value}$ ($2,2 \times 10^{-16}$) $<$ α (0,05), hal ini terjadi dimungkinkan terdapat pencilan pada data Supiturang. Pemilihan model terbaik ARIMA yaitu ARIMA (1,1,1) memiliki RMSE data *training* sebesar 5,6056 dan data *testing* sebesar 3,4326. Persamaan model ARIMA (1,1,1) dapat ditulis sebagai berikut:

$$Z_t = (1 + \phi)Z_{t-1} + \phi Z_{t-2} + a_t - \theta_1 a_{t-1}$$

$$Z_t = 1,7546 Z_{t-1} + 0,7546 Z_{t-2} + a_t + 0,7317 a_{t-1}$$

Pemodelan curah hujan menggunakan *Hybrid ARIMA-NN* merupakan kombinasi pemodelan linier ARIMA dengan nonlinier *Neural Network*. *Input* yang digunakan merupakan sisaan model ARIMA. Tahap awal pemodelan *Hybrid ARIMA-NN* yaitu normalisasi data dengan interval [0,1]. Kemudian, membentuk arsitektur jaringan dengan jumlah *hidden layer* sebanyak 1 dan menguji coba (*trial and error*) 2-10 *neuron* pada *hidden layer* untuk mendapatkan *error* model terkecil. Arsitektur yang terbentuk dapat diketahui pada Tabel 2 berikut.

Tabel 2. Arsitektur jaringan *hybrid ARIMA-NN* Supiturang.

No.	Hidden Layer	Arsitektur Jaringan	RMSE <i>training</i>	RMSE <i>testing</i>
1	2	Hybrid (ARIMA (1,1,1) FFNN (4-2-1))	10,2986	3,4327
2	3	Hybrid (ARIMA (1,1,1) FFNN (4-3-1))	10,2981	3,4330
3	4	Hybrid (ARIMA (1,1,1) FFNN (4-4-1))	10,2854	3,4338
4	5	Hybrid (ARIMA (1,1,1) FFNN (4-5-1))	10,3002	3,4350
5	6	Hybrid (ARIMA (1,1,1) FFNN (4-6-1))	10,2966	3,4326
6	7	Hybrid (ARIMA (1,1,1) FFNN (4-7-1))	10,3017	3,4322
7	8	Hybrid (ARIMA (1,1,1) FFNN (4-8-1))	10,2815	3,4334
8	9	Hybrid (ARIMA (1,1,1) FFNN (4-9-1))	10,2955	3,4336
9	10	Hybrid (ARIMA (1,1,1) FFNN (4-10-1))	10,3040	3,4323

Berdasarkan Tabel 2, model ARIMA(1,1,1) FFNN(4-8-1) memiliki RMSE data *training* terkecil sebesar 10,2815 dan RMSE data *testing* sebesar 3,4334. Pembentukan arsitektur *Hybrid ARIMA-NN* ditentukan oleh bobot. Semakin besar bobot, semakin penting hubungan diantara *neuron*, hal tersebut dapat diketahui pada Tabel 3.

Tabel 3. Bobot akhir *hidden layer* ke *output* Supiturang.

W[i,]	W[,j]
	1
0	-0,0088
1	-1,2206
2	0,3435
3	0,3054
4	0,6341
5	0,8521
6	0,5193
7	-1,1905
8	0,6199

Berdasarkan Tabel 3, dapat diketahui bahwa *output* model Hybrid ARIMA (1,1,1) FFNN (4-8-1) secara matematis:

$$\hat{N}_t = -0,0088 - 1,2206f_1^h + 0,3435f_2^h + 0,3054 f_3^h + 0,6341 f_4^h + 0,8521 f_5^h + 0,5193f_6^h - 1,1905f_7^h + 0,6199f_8^h$$

Model *Hybrid ARIMA-NN* terbaik adalah *Hybrid ARIMA(1,1,1) FFNN (4-8-1)* dengan persamaan sebagai berikut.

$$\hat{Z}_t = \hat{L}_t + \hat{N}_t$$

$$\hat{Z}_t = 1,7546 Z_{t-1} + 0,7546Z_{t-2} + a_t + 0,7317 a_{t-1} - 0,0088 - 1,2206 f_1^h + 0,3435f_2^h + 0,3054 f_3^h + 0,6341 f_4^h + 0,8521 f_5^h + 0,5193f_6^h - 1,1905f_7^h + 0,6199f_8^h$$

Pemodelan curah hujan FFNN menggunakan *input* dari lag PACF yang signifikan yaitu lag ke-1. Tahap awal pemodelan FFNN adalah normalisasi data dengan interval [0,1]. Kemudian, membentuk arsitektur jaringan dengan jumlah *hidden layer* sebanyak 1 dan menguji coba (*trial and error*) 2-10 *neuron* pada *hidden layer* untuk mendapatkan *error* model terkecil. Arsitektur yang terbentuk dapat diketahui pada Tabel 4 berikut.

Tabel 4. Arsitektur jaringan FFNN Supiturang.

No.	Hidden Layer	Arsitektur Jaringan	RMSE <i>training</i>	RMSE <i>testing</i>
1	2	FFNN (1-2-1)	5,6241	3,4478
2	3	FFNN (1-3-1)	5,6139	3,4375
3	4	FFNN (1-4-1)	5,6192	3,4411
4	5	FFNN (1-5-1)	5,6225	3,4448
5	6	FFNN (1-6-1)	5,6185	3,4406
6	7	FFNN (1-7-1)	5,6154	3,4377
7	8	FFNN (1-8-1)	5,6281	3,4509
8	9	FFNN (1-9-1)	5,6216	3,4447
9	10	FFNN (1-10-1)	5,6246	3,4476

Berdasarkan Tabel 4, model FFNN (1-3-1) memiliki RMSE data *training* terkecil sebesar 5,6139 dan RMSE data *testing* sebesar 3,4375. Pembentukan arsitektur FFNN ditentukan oleh bobot. Semakin besar bobot, semakin penting hubungan diantara *neuron*, hal tersebut dapat diketahui pada Tabel 5.

Tabel 5. Bobot akhir *hidden layer* ke *output* Supiturang.

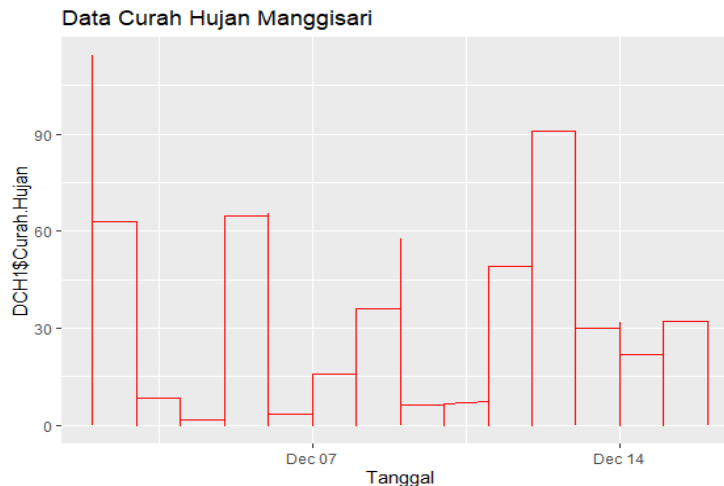
W[i,]	W[,j]
	1
0	0,4089
1	0,9884
2	-0,3619
3	-0,7172

Berdasarkan Tabel 3.5, dapat diketahui bahwa *output* model FFNN (1-3-1) secara matematis:

$$\hat{Z}_t = b^0 + w_1^0 f_1^h + w_2^0 f_2^h + w_3^0 f_3^h$$

$$\hat{Z}_t = 0,4089 + 0,9884 f_1^h - 0,3619 f_2^h - 0,7172 f_3^h$$

Data curah hujan kedua yang digunakan adalah data curah hujan di lokasi Manggisari. Gambaran awal mengenai curah hujan Manggisari dapat diketahui melalui plot curah hujan pada Gambar 2.



Gambar 2. Curah hujan daerah Manggisari.

Pada Gambar 2, diketahui awal bulan Desember terdapat curah hujan yang tinggi, sedangkan diakhir bulan Desember terjadi penurunan curah hujan. Sebagian besar curah hujan yang terjadi di Manggisari sebesar 19,94 mm dengan curah hujan maksimal sebesar 114,28 mm.

Sebelum melakukan pemodelan pada data curah hujan menggunakan pendekatan ARIMA, *Hybrid* ARIMA-NN dan FFNN, dilakukan pengujian linieritas terhadap data yang akan digunakan. Berdasarkan pengujian linieritas yang dilakukan, diketahui bahwa $p\text{-value}$ ($2,2 \times 10^{-16}$) $< \alpha(0,05)$, maka dapat diputuskan menolak H_0 . Pada pengujian linieritas ini, dapat disimpulkan bahwa data curah hujan memiliki pola nonlinier.

Penerapan metode neural network yang digunakan diharapkan dapat mengatasi data curah hujan di daerah Manggisari.

Pemodelan ARIMA Manggisari dilakukan untuk mendapatkan sisaan model ARIMA sebagai data *input* pada pemodelan *Hybrid* ARIMA-NN. Tahap awal ARIMA adalah pengecekan stasioneritas terhadap ragam dan rata-rata. Data Manggisari tidak stasioner terhadap ragam karena memiliki λ sebesar 0,09 yang belum mendekati 1, sehingga diperlukan transformasi *Box-Cox* agar stasioner. Stasioneritas terhadap rata-rata diketahui melalui pengujian *Augmented Dickey Fuller* (ADF) dengan $p\text{-value}$ $(0,01) < \alpha(0,05)$, sehingga data stasioneritas terhadap rata-rata. Tahap selanjutnya adalah pendugaan dan pengujian signifikansi parameter model yang dapat diketahui melalui Tabel 6.

Tabel 6. Pendugaan parameter dan uji signifikansi model Manggisari.

Model	Penduga Parameter	t hitung	t tabel		Keterangan
			$t_{(0,05,2742)}$	$t_{(0,1,2742-p)}$	
ARIMA (1,1,1)	$\phi_1 = 0,5845$	2.0246	1.9608	1.6454	Signifikan
	$\theta_1 = -0,5591$	1.8998	1.9608	1.6454	Signifikan
ARIMA (1,1,0)	$\phi_1 = 0,0228$	1.1937	1.9608	1.6454	Tidak Signifikan
ARIMA (0,1,1)	$\theta_1 = 0,0219$	1.1711	1.9608	1.6454	Tidak Signifikan

Pada Tabel 6, diketahui bahwa hanya model ARIMA (1,1,1) yang memiliki parameter signifikan, dengan koefisien penduga $\phi_1 = 0,5845$ dan $\theta_1 = -0,5591$. Pengujian asumsi *white noise* dan normalitas sisaan ARIMA (1,1,1), diketahui bahwa asumsi *white noise* terpenuhi karena $p\text{-value}$ $(0,6367) > \alpha(0,05)$. Namun, pada asumsi normalitas tidak terpenuhi karena $p\text{-value}$ $(2,2 \times 10^{-16}) < \alpha(0,05)$, hal ini terjadi dimungkinkan terdapat pencilan pada data Manggisari. Pemilihan model terbaik ARIMA yaitu ARIMA (1,1,1) dengan persamaan sebagai berikut.

$$Z_t = (1 + \phi)Z_{t-1} + \phi Z_{t-2} + a_t - \theta_1 a_{t-1}$$

$$Z_t = 1,5845 Z_{t-1} + 0,5845 Z_{t-2} + a_t + 0,5591 a_{t-1}$$

Pemodelan *Hybrid* ARIMA-NN Manggisari menggunakan *input* sisaan ARIMA model terbaik. Tahap awal pemodelan *Hybrid* ARIMA-NN adalah normalisasi data dengan interval [0,1]. Kemudian, membentuk arsitektur jaringan dengan jumlah *hidden layer* sebanyak 1 dan menguji coba (*trial and error*) 2-10 *neuron* pada *hidden layer* untuk mendapatkan *error* model terkecil. Arsitektur yang terbentuk dapat diketahui pada Tabel 7 berikut.

Tabel 7. Arsitektur jaringan *hybrid* ARIMA-NN Manggisari.

No.	<i>Hidden Layer</i>	Arsitektur Jaringan	RMSE <i>training</i>	RMSE <i>testing</i>
1	2	(ARIMA (1,1,1) FFNN (4-2-1))	5,6593	3,1029
2	3	(ARIMA (1,1,1) FFNN (4-3-1))	5,6831	3,1009
3	4	(ARIMA (1,1,1) FFNN (4-4-1))	5,6574	3,1021
4	5	(ARIMA (1,1,1) FFNN (4-5-1))	5,6522	3,1026
5	6	(ARIMA (1,1,1) FFNN (4-6-1))	5,6693	3,1017
6	7	(ARIMA (1,1,1) FFNN (4-7-1))	5,6653	3,1013
7	8	(ARIMA (1,1,1) FFNN (4-8-1))	5,6577	3,1002
8	9	(ARIMA (1,1,1) FFNN (4-9-1))	5,6439	3,1056
9	10	(ARIMA (1,1,1) FFNN (4-10-1))	5,6475	3,0991

Berdasarkan Tabel 7, model ARIMA (1,1,1) FFNN (4-9-1) memiliki nilai RMSE data *training* terkecil sebesar 5,6439 dan RMSE data *testing* sebesar 3,1056. Pembentukan arsitektur *Hybrid* ARIMA-NN ditentukan oleh bobot. Semakin besar bobot, semakin penting hubungan diantara *neuron*, hal tersebut dapat diketahui pada Tabel 8.

Tabel 8. Bobot akhir *hidden layer* ke *output* Manggisari.

W[i,]	W[,j] 1
0	-0,1992
1	-0,2853
2	-0,4299
3	0,2205
4	0,2359
5	-1,0327
6	0,1914
7	-0,0485
8	-0,2416
9	0,6070

Berdasarkan Tabel 8, dapat diketahui bahwa *output* model Hybrid ARIMA (1,1,1) FFNN (4-9-1) secara matematis:

$$\hat{N}_t = -0,1992 - 0,2853f_1^h - 0,4299f_2^h + 0,2205f_3^h + 0,2359f_4^h - 1,0327f_5^h + 0,1914f_6^h - 0,0485f_7^h - 0,2416f_8^h + 0,6070f_9^h$$

Model *Hybrid* ARIMA-NN terbaik adalah *Hybrid* ARIMA(1,1,1) FFNN (4-9-1) dengan persamaan sebagai berikut.

$$\hat{Z}_t = \hat{L}_t + \hat{N}_t$$

$$\hat{Z}_t = 1,5845 Z_{t-1} + 0,5845 Z_{t-2} + a_t + 0,5591 a_{t-1} - 0,1992 - 0,2853f_1^h - 0,4299f_2^h + 0,2205f_3^h + 0,2359f_4^h - 1,0327f_5^h + 0,1914f_6^h - 0,0485f_7^h - 0,2416f_8^h + 0,6070f_9^h$$

Pemodelan curah hujan FFNN menggunakan *input lag* PACF yang signifikan yaitu *lag* ke-1, Tahap awal pemodelan FFNN adalah normalisasi data dengan interval [0,1]. Kemudian, membentuk arsitektur jaringan dengan jumlah *hidden layer* sebanyak 1 dan menguji coba (*trial and error*) 2-10 *neuron* pada *hidden layer* untuk mendapatkan *error* model terkecil. Arsitektur yang terbentuk dapat diketahui pada Tabel 9 berikut.

Tabel 9. Arsitektur jaringan FFNN Manggisari.

No.	Hidden Layer	Arsitektur Jaringan	RMSE <i>training</i>	RMSE <i>testing</i>
1	2	FFNN (1-2-1)	3,1295	5,5464
2	3	FFNN (1-3-1)	3,4733	5,3470
3	4	FFNN (1-4-1)	3,5094	4,7497
4	5	FFNN (1-5-1)	3,1509	5,5260
5	6	FFNN (1-6-1)	3,1412	5,0899
6	7	FFNN (1-7-1)	3,1315	5,0899
7	8	FFNN (1-8-1)	3,1389	5,0356
8	9	FFNN (1-9-1)	3,1389	4,6209
9	10	FFNN (1-10-1)	3,1311	5,3042

Berdasarkan Tabel 9, model FFNN (1-2-1) memiliki nilai RMSE data *training* terkecil sebesar 3,1295 dan RMSE data *testing* sebesar 5,5464. Pembentukan arsitektur FFNN ditentukan oleh bobot. Semakin besar bobot, semakin penting hubungan diantara *neuron*, hal tersebut dapat diketahui pada Tabel 10.

Tabel 10. Bobot akhir *hidden layer* ke *output* Manggisari.

W[i,]	W[,j] 1
0	1,0559
1	-6,2379
2	-10,8860

Berdasarkan Tabel 10, dapat diketahui bahwa *output* model FFNN (1-2-1) secara matematis dapat ditulis sebagai berikut.

$$\hat{Z}_t = b^0 + w_1^0 f_1^h + w_2^0 f_2^h$$

$$\hat{Z}_t = 1,0559 - 6,2379 f_1^h - 10,8860 f_2^h$$

Hasil validasi data Supiturang dan data Manggisari dapat diketahui pada Tabel 11.

Tabel 11. Hasil Validasi Data Supiturang dan Data Manggisari.

Metode	Data Supiturang		Metode	Data Manggisari	
	RMSE <i>Training</i>	RMSE <i>Testing</i>		RMSE <i>Training</i>	RMSE <i>Testing</i>
ARIMA (1,1,1)	5,6056	3,4326	Hybrid (ARIMA (1,1,1) FFNN (4-9-1))	5,6439	3,1056
Hybrid (ARIMA (1,1,1) FFNN (4-8-1))	10,2815	3,4334	FFNN (1-2-1)	3,1295	5,5464
FFNN (1-3-1)	5,6139	3,4375			

Berdasarkan Tabel 11, data Supiturang yang memiliki pola data linier didapatkan model terbaik yaitu model ARIMA (1,1,1) dengan RMSE data *testing* terkecil dibandingkan model lain. Sedangkan pada data Manggisari yang memiliki pola data nonlinier didapatkan model terbaik dengan RMSE data *testing* terkecil pada model Hybrid (ARIMA (1,1,1) FFNN (4-9-1)).

KESIMPULAN

Pemodelan curah hujan Supiturang diperoleh model ARIMA (1,1,1) dengan RMSE *testing* 3,4326, metode Hybrid ARIMA-NN yaitu model (ARIMA (1,1,1) FFNN (4-8-1)) dengan RMSE *testing* 3,4334, dan Pemodelan FFNN yaitu model FFNN (1-3-1) dengan RMSE *testing* 3,4375. Pemodelan curah hujan Manggisari diperoleh pada metode Hybrid ARIMA-NN yaitu model (ARIMA (1,1,1) FFNN (4-9-1)) dengan RMSE *testing* 3,1056 dan pemodelan FFNN yaitu model FFNN (1-2-1) dengan RMSE *testing* 5,5464.

Model ARIMA (1,1,1) merupakan model yang memiliki akurasi terbaik dalam meramalkan data yang berpola linier yaitu data curah hujan di Supiturang. Pada data yang memiliki pola nonlinier, metode Hybrid ARIMA (1,1,1) FFNN (4-9-1) merupakan model yang memiliki akurasi terbaik dalam meramalkan curah hujan di Manggisari.

UCAPAN TERIMA KASIH

Segala puji syukur kepada Allah SWT atas limpahan rahmat dan karunia-Nya, sehingga penulis mampu menyelesaikan jurnal yang disusun. Ucapan terima kasih atas kegiatan Hibah doktor-lektor FMIPA Universitas Brawijaya yang telah memberikan pendanaan untuk kegiatan penelitian ini.

DAFTAR PUSTAKA

- Box, G. E. P., & Jenkins, G. M. (1976). *Time Series Analysis; Forecasting and Control*. Holden-Day, Inc.
- Iriany, A., Mahmudi, W. F., Nugroho, W. H., & Sulistyono, A. D. (2019). Rainfall Forecasting Using Gstar-Sur-Nn Approach in West Java Province. *International Conference on Science, Engineering, Bulit Environment, and Social Science*, 8, 161–165.
- Iriany, A., Rosyida, D., Sulistyono, A. D., & Ruchjana, B. N. (2020). Precipitation Forecasting Using Neural Network Model Approach. *IOP Conference Series: Earth and Environmental Science*, 458(1).
- Patro, S. G. K., & Sahu, K. K. (2015). *Normalization : A Preprocessing Stage*. 2(3), 2393–2395.
- Rusdi. (2011). Uji Akar-Akar Unit dalam Model Runtun Waktu Autoregresif. *Statistika*, 11(2), 67–78.
- Saputro, D. R. S. (2009). Memprediksi Curah Hujan (Data Spatio-Temporal) dengan Metode Bayesian Network. *Proceeding of National Seminar on Research, Teaching, and Application of Mathematics and Science*, 37–42.
- Susanto, Y. (2016). *Peramalan Curah Hujan dengan Pendekatan Model ARIMA, Feed Forward Neural Network dan Hybrid (ARIMA-NN) di Banyuwangi*. Institut Teknologi Sepuluh November.
- Wahyuni, I., Mahmudy, W. F., & Iriany, A. (2017). Rainfall Prediction Using Hybrid Adaptive Neuro-Fuzzy Inference System (ANFIS) and Genetic Algorithm. *Journal of Telecommunication, Electronic and Computer Engineering*, 9(2–8), 51–56.
- Wei, W. W. S. (2006). *Time Series Analysis Univariate and Multivariate Methods* (D. Lynch, S. Oliver, & R. Hampton (eds.); 2nd ed.). Pearson Education.
- Willmott, C. J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30(1), 79–82.
- Zhang, G. P. (2003). Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*, 50, 159–175.