

Peramalan Temperatur Udara di Kota Surabaya dengan Menggunakan ARIMA dan *Artificial Neural Network*

Ali Machmudin dan Brodjol S. S. Ulama

Jurusan Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Teknologi Sepuluh Nopember (ITS)

Jl. Arief Rahman Hakim, Surabaya 60111

E-mail: ¹zeal_ali25@yahoo.com dan ²brodjol_su@statistika.its.ac.id

Abstrak—Pada dekade terakhir terjadi peningkatan temperatur terutama di kota besar tidak terkecuali di Surabaya. Dampak yang ditimbulkan akibat kenaikan temperatur udara adalah kekeringan, krisis air, hingga perubahan cuaca. Untuk mengantisipasi perubahan suhu udara diperlukan suatu model yang dapat meramalkan kondisi udara / temperatur. Model yang banyak digunakan adalah model ARIMA untuk pendekatan model linear. Berdasarkan proses identifikasi model ARIMA yang didapat adalah Model ARIMA (0,1,2). Sedangkan untuk model Pendugaan data temperatur udara Kota Surabaya dengan menggunakan *Artificial Neural Network* dengan metode *backpropagation* menghasilkan model optimum FFNN (2,4,1). Berdasarkan kedua model tersebut yang memberikan nilai MAPE terkecil adalah FFNN (2,4,1) yaitu sebesar 0.0714% dibandingkan model ARIMA sebesar 2.305 % .

Kata Kunci—Temperatur, ARIMA, ANN, *Backpropagation*.

I PENDAHULUAN

Tingkat pemanasan rata-rata selama lima puluh tahun terakhir hampir dua kali lipat dari rata-rata seratus tahun terakhir, dimana pemanasan lebih dirasakan pada daerah daratan daripada lautan [1]. Pada Sebelas tahun terakhir merupakan tahun-tahun terhangat dalam temperatur permukaan global sejak 1850. Hal tersebut juga berpengaruh pada cuaca di Surabaya. Menurut Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) suhu panas di Kota Pahlawan diperkirakan mencapai puncaknya sejak awal Oktober 2011 [6]. Peningkatan temperatur memiliki dampak diantaranya kekeringan dan krisis air bersih serta naiknya pemakaian *Air Conditioner* (AC) dimana secara tidak langsung menaikkan konsumsi listrik.

Akibat kenaikan suhu, temperatur udara juga sangat berkaitan dengan kelembaban udara di suatu wilayah yang juga akan mempengaruhi cuaca. Sehingga peramalan yang tepat akan temperatur udara sangat dibutuhkan. Selama ini BMKG dalam melakukan peramalan tidak memperhatikan unsur-unsur ketidakpastian [2]. Berdasarkan hasil penelitian Pirzada (2010) bahwa penggunaan metode kalibrasi menghasilkan performa yang bagus dengan pendekatan *Bayesian Model Averaging Expectation Maximization (BMA-EM)* [4]. Penelitian lain mencoba meramalkan data temperatur udara di sekitar Palangkaraya [3]. Penelitiannya menghasilkan kesimpulan bahwa model MA(1) adalah bentuk

model yang paling baik karena memiliki nilai MAPE ((*Mean Absolute Percentage error*) terkecil.

Artificial Neural Network (ANN) atau Jaringan Syaraf Tiruan (JST) adalah salah satu metode yang sudah banyak dikembangkan untuk pendugaan. Metode ini juga dapat dipakai untuk meramalkan berdasarkan pola kejadian yang ada di masa lampau. Ini dapat dilakukan mengingat kemampuan jaringan syaraf tiruan untuk mengingat dan membuat generalisasi dari apa yang sudah ada sebelumnya. Salah satu metode yang dapat digunakan untuk memperbaiki bobot adalah metode *backpropagation*. Metode ini umum digunakan untuk diaplikasikan pada penyelesaian suatu masalah berkaitan dengan identifikasi, prediksi, pengenalan pola dan sebagainya. Pada latihan yang berulang-ulang, algoritma ini akan menghasilkan unjuk kerja yang lebih baik. Hal ini berarti bahwa “bobot interkoneksi” JST semakin mendekati bobot yang seharusnya. Kelebihan lain yang dimiliki JST ini adalah kemampuannya untuk belajar (bersifat adaptif) dan kebal terhadap adanya kesalahan (*Fault Tolerance*) dengan kelebihan tersebut JST dapat mewujudkan sistem yang tahan akan kerusakan (*robust*) dan konsisten bekerja dengan baik [4]. Pengaplikasian ANN pada peramalan temperatur di Surabaya dapat menjadi alternatif metode peramalan yang baik dalam kaitannya menghasilkan nilai ramalan yang tepat. Untuk mengetahui pendugaan peramalan terbaik ANN tersebut maka akan dibandingkan dengan pendugaan temperatur dengan menggunakan metode ARIMA sebagaimana penelitian Ramdani tetapi dengan data yang berbeda.

II. LANDASAN TEORI

A. Tentang Time Series

Metode *time series* adalah suatu metode peramalan untuk masa depan yang dilakukan berdasarkan nilai atau data masa lalu dari suatu variabel dan kesalahan (*error*) masa lalu. Tujuan dari metode peramalan *time series* ini adalah untuk menemukan pola data *time series* (runtun waktu) dan mengekstrapolasikan pola tersebut ke masa depan [5].

B. Proses Stationer

Stasioneritas data *time series* adalah suatu keadaan dimana proses pembangkitan yang mendasari suatu deret berkala didasarkan pada nilai tengah (*mean*) dan nilai varians yang konstan [5].

Transformasi *Box Cox* digunakan untuk mengetahui kestasioneran data berdasarkan nilai varians. Rumus matematis transformasi tersebut ditampilkan sebagai berikut.

$$Z^* = \frac{Z^{\lambda-1}}{\lambda} \tag{1}$$

Keterangan :

Z^* = Transformasi *Box Cox*

λ = Nilai koefisien dari transformasi *Box Cox*

Transformasi *Box Cox* berdasarkan nilai lambda (λ) sebagai berikut [6].

Tabel 1.
Transformasi *Box Cox*

Nilai estimasi λ	Transformasi
-1	$\frac{1}{Z_t}$
-0,5	$\frac{1}{\sqrt{Z_t}}$
0,0	$\text{Ln}(Z_t)$
0,5	$\sqrt{Z_t}$
1	Z_t (tidak ditransformasi)

Pengecekan kestasioneran data pengamatan dalam mean secara umum dapat melihat plot *Partial Autocorrelation Function* (PACF).

C. ACF dan PACF

Fungsi Autokorelasi atau *autocorrelation function* (ACF) merupakan suatu hubungan linier antara pengamatan Z_t dengan pengamatan Z_{t-k}

$$\hat{\rho}_k = r_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} \tag{2}$$

Fungsi autokorelasi parsial atau *partial autocorrelation function* (PACF) digunakan untuk menunjukkan besarnya hubungan antar nilai variabel yang sama, dengan menganggap pengaruh dari semua kelambatan waktu yang lain adalah konstan.

$$\hat{\phi}_{kk} = \frac{r_k - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} r_{k-j}}{1 - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} r_j} \tag{3}$$

Dimana

$$\hat{\phi}_{kj} = \hat{\phi}_{k-1,j} - \hat{\phi}_{kk} \hat{\phi}_{k-1,k-j} \text{ untuk } j = 1, 2, \dots, k-1$$

D. Model ARIMA

Berdasarkan pola ACF dan PACF maka dilakukan identifikasi dan estimasi parameter. Adapun model ARIMA secara umum adalah sebagai berikut.

$$\phi_p(B)\Phi_p(B^S)(1-B)^d(1-B)^D Z_t = \theta_q(B)\Theta_q(B^S)a_t \tag{4}$$

E. Pemeriksaan Diagnostik

Untuk mengetahui kebaikan model maka perlu dilakukan langkah-langkah pengujian sebagai berikut.

1. Pengujian Signifikansi Parameter Model Set
2. Uji Asumsi Residual (*Diagnostic Check*)
3. Pemilihan Model Terbaik

F. Artificial Neural Network

Artificial Neural Network atau Jaringan Syaraf Tiruan (JST) adalah sistem pemrosesan informasi yang memiliki karakteristik mirip dengan jaringan syaraf biologi [7]. JST dibentuk sebagai generalisasi model matematika dari jaringan syaraf biologi. JST ditentukan oleh 3 hal :

1. Pola hubungan antar neuron (disebut arsitektur jaringan)
2. Metode untuk menentukan bobot penghubung (metode training/learning/algorithm)
3. Fungsi aktivasi

D. Pemilihan Model Terbaik

Pemilihan model terbaik dapat menggunakan beberapa kriteria, antara lain:

a. Kriteria *In Sample*

Kriteria yang digunakan pada *in sample* antara lain:

1. AIC (*Akaike's Information Criterion*), dimana model terbaik dipilih dengan mempertimbangkan jumlah param-ter dalam model. Semakin kecil nilai AIC, maka model semakin baik dan layak untuk digunakan.

$$AIC(M) = n \ln \hat{\sigma}_a^2 + 2M \tag{5}$$

2. *Schwartz Bayesian Criterion* (SBC), dimana kriteria pe-milihan model terbaik dipilih berdasarkan nilai terkecil. semakin kecil nilai SBC, maka model yang didapatkan akan semakin baik. Berikut ini merupakan rumus kriteria SBC:

$$SBC(M) = n \ln \hat{\sigma}_a^2 + M \ln n \tag{6}$$

dengan:

n = banyaknya observasi

$\hat{\sigma}_a^2$ = estimasi maksimum likelihood dari σ_a^2

M = jumlah parameter dalam model ARIMA (p,q)

b. Kriteria *Out Sample*

Kriteria yang digunakan pada *out sample* adalah RMSE (*Root Mean Square Error*) dan MAPE (*Mean Absolute Percentage error*) dengan rumus sebagai berikut:

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \tag{7}$$

$$MAPE = \frac{\sum_{t=1}^n |(y_t - \hat{y}_t) / y_t|}{n} \times 100\% \tag{8}$$

Semakin kecil nilai RMSE dan MAPE, maka semakin baik dan model tersebut layak untuk digunakan. Namun jika hasil pemilihan model terbaik antara *in sample* dan *out sample*, maka yang digunakan adalah hasil pemodelan pada *out sample*.

III. METODOLOGI

A. Sumber Data

Data yang digunakan dalam penelitian ini berasal dari BMKG Perak II tentang temperatur udara harian di Surabaya. Periode data adalah antara Januari 2011 hingga Maret 2012. Adapun untuk analisis maka data periode Januari 2011 hingga Februari 2012 digunakan sebagai data *in sample* dan pada bulan Maret 2012 digunakan sebagai *out sample*.

B. Variabel Penelitian

Pada penelitian ini variabel yang diamati adalah data temperatur udara di Surabaya. Data tersebut dalam satuan celsius dalam periode harian.

C. Metode Analisis Data

1. Analisis ARIMA

Pendugaan kecepatan angin dengan ARIMA dilakukan dengan prosedur sebagai berikut.

- Plot data inisiasi
- Mengidentifikasi kestasioneran data dengan melihat ACF dan PACF
- Melakukan pengujian estimasi parameter model
- Melakukan pengujian parameter model, dan beberapa asumsi residual yang harus dipenuhi antara lain: asumsi *white noise* dengan menggunakan statistik uji *Ljung-Box* dan asumsi kenormalan dengan menggunakan statistik uji *Kolmogorov Smirnov*.

2. Analisis Artificial Neural Network

Bentuk arsitektur jaringan syaraf tiruan yang digunakan dalam pendugaan temperatur udara di Surabaya menggunakan metode *backpropagation*. Berikut langkah-langkah prosedur peramalan jaringan syaraf tiruan.

- Data inisiasi diskalkan terlebih dahulu antara 0-1
- Inisiasi bobot *weight* [0,1]
- Menentukan banyak input berdasarkan pola PACF data yang sudah stasioner.
- Pembelajaran data dengan algoritma *backpropagation*
- Mengevaluasi kriteria pemilihan model terbaik (AIC, SBC) pada setiap kombinasi input dan neuron.
- Data hasil *training* dikembalikan ke data skala awal

D. Penentuan Model Terbaik

Untuk menentukan model terbaik dari kedua model maka perlu dilihat nilai MAPE yang terkecil. Semakin kecil nilai tersebut maka semakin baik dan model tersebut layak untuk digunakan

IV. HASIL DAN PEMBAHASAN

A. Statistika Deskriptif

Data temperatur untuk periode Januari 2011 hingga Maret 2012 ditampilkan sebagaimana tabel dan gambar sebagai berikut.

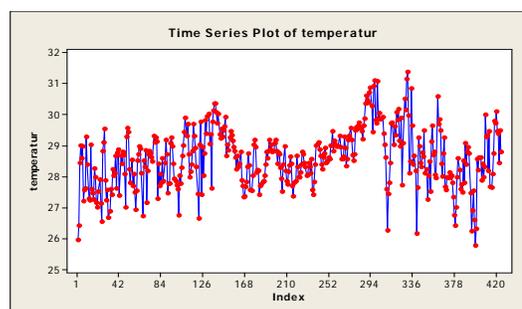
Tabel 2.
Nilai Statistika Deskriptif

Kriteria	Nilai
Minimum	25,792
Maksimum	31,383
Mean	28,580
Median	28,596
Standar Deviasi	0,934

Berdasarkan Tabel 2 diketahui bahwa data temperatur Kota Surabaya memiliki nilai minimum sebesar 25,792 °C dan nilai maksimal sebesar 31,383 °C. Rata-rata (*mean*) suhu udara sepanjang tahun 2011 hingga awal 2012 sebesar 28,580°C. Nilai tengah (*median*) dari data temperatur sebesar 28,596 sedangkan nilai standar deviasi data temperatur udara sebesar 0,934 °C menunjukkan bahwa keragaman nilai data temperatur udara tidak terlalu bervariasi dan nilainya terletak pada range nilai minimum dan maksimum dari data tersebut.

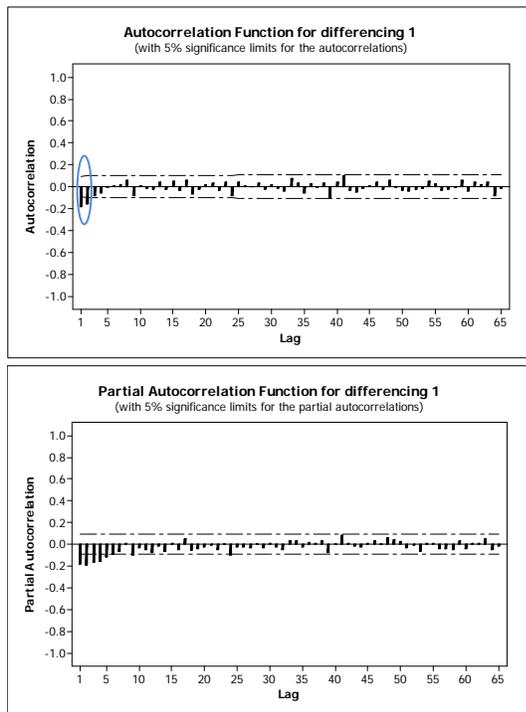
B. Permodelan ARIMA

Identifikasi pada data temperatur bertujuan mengetahui kestasioneran data baik stasioner dalam mean maupun varians. Proses identifikasi dapat dilakukan dengan menggunakan *Time Series Plot*, *Box-cox Transformation*, Pola *Autocorrelation Function (ACF)*.



Gambar. 1. *Time series plot* data temperatur Kota Surabaya.

Pola data temperatur udara secara gambaran umum tidak berada di nilai rata-ratanya sebesar 28.565. Hal tersebut dapat diindikasikan bahwa data pengamatan berdasarkan Gambar 1 belum stasioner dalam mean serta tidak terlihat adanya pengaruh dari deret waktu. Apabila melihat nilai varians data pengamatan yaitu sebesar 0.942 dimana nilainya cukup kecil belum dapat menjadi acuan bahwa data pengamatan dianggap sudah stasioner dalam varians. Berdasarkan hal tersebut untuk menstasionerkan diperlukan *differencing*.



Gambar. 2. Pola Autocorrelation Function (ACF) dan Pola Partial Autocorrelation Function (PACF) Data Temperatur setelah Differencing 1

Berdasarkan Gambar 2 dapat dinyatakan bahwa pada pola ACF lag-1 dan lag-2 keluar dari nilai batas. Adapun untuk pola PACF pada lag-1, lag-2, lag-3, lag-4, dan lag-5 keluar dari batasnya. Untuk mengetahui model ARIMA terbaik maka dilakukan pencarian model terbaik berdasarkan pola ACF dan PACF.

Berdasarkan pola ACF dan PACF maka model yang terbaik yang dipilih adalah ARIMA (0,1,2) dengan nilai MAPE 2.305%. Model ARIMA (0,1,2) adalah model *Autoregressive Integrated Moving Average* dengan differencing pada lag-1 dimana parameter signifikan pada lag-1 dan lag 2 pada nilai rata-rata Bergeraknya. Secara matematis model ARIMA (0,1,2) dapat ditulis sebagai berikut.

$$Z_t = Z_{t-1} - 0.39327 a_{t-1} - 0.33681 a_{t-2} + a_t \quad (9)$$

Model ARIMA (0,1,2) untuk layak digunakan perlu dilakukan beberapa pengujian. Pengujian yang dimaksud adalah pengujian signifikansi parameter, *diagnostic checking* yang meliputi uji *white noise* dan uji kenormalan.

Uji signifikansi parameter digunakan untuk mengetahui apakah parameter dari model signifikan memiliki pengaruh pada model atau tidak. Pengujian signifikansi parameter ARIMA (0,1,2) dijelaskan sebagai berikut.

Hipotesis:

$$\begin{aligned} H_0 : \theta_1=0 & \quad H_0 : \theta_2=0 \\ H_1 : \theta_1 \neq 0 & \quad H_1 : \theta_2 \neq 0 \end{aligned}$$

Nilai estimasi parameter model ARIMA (0,1,2) beserta nilai statistik hitungnya ditampilkan Tabel 3 sebagai berikut. Nilai

tersebut akan dibandingkan dengan nilai taraf nyatanya (α) sebesar 5%

Tabel 3. Uji Signifikansi Parameter ARIMA (0,1,2)

Parameter	Estimasi	t_value	P_value	Keputusan
θ_1	0.39327	8.53	<.0001	Signifikan
θ_2	0.33681	7.3	<.0001	Signifikan

Berdasarkan Tabel 3 disimpulkan bahwa semua parameter untuk model ARIMA (0,1,2) telah signifikan. Untuk dilanjutkan pada pengujian residual. Pengujian residual model tersebut untuk memastikan bahwa model layak untuk digunakan peramalan. Uji yang dilakukan adalah uji *white noise* dan uji kenormalan.

Pengujian *white noise* digunakan untuk mengetahui ke independenan residual dan homogenitas dari residual (varians homogen). Pengujian *white noise* yang umumnya dilakukan adalah dengan menggunakan Ljung-Box.

Hipotesis:

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_{48}$$

$$H_1 : \text{Minimal ada satu } \rho_i \text{ yang tidak sama dengan nol } i = 1, 2, \dots, 48$$

Nilai *chi-square* pada pengujian *white noise* model ARIMA (0,1,2) beserta nilai statistik hitungnya ditampilkan Tabel 4 sebagai berikut. Nilai tersebut akan dibandingkan dengan nilai taraf nyatanya (α) sebesar 5%

Tabel 4. Pengujian Ljung-Box ARIMA (0,1,2)

Lag	Chi-Square	Pr > Chi Square	Kesimpulan
6	9.09	0.059	White Noise
12	14.84	0.138	White Noise
18	20.56	0.196	White Noise
24	26.37	0.236	White Noise
30	28.38	0.4444	White Noise
36	32.04	0.564	White Noise
42	38.39	0.5429	White Noise
48	40.78	0.6901	White Noise

Output pada Tabel 4 memberikan hasil bahwa keseluruhan lag yang diuji pada pengujian Ljung-Box menghasilkan keputusan gagal tolak H_0 . Hal tersebut berarti bahwa asumsi *white noise* telah terpenuhi dan varians residual telah homogen dan independen.

Uji selanjutnya yang dilakukan adalah uji kenormalan residual. Salah satu pengujian kenormalan yang banyak digunakan adalah Uji Kolmogorov-Smirnov.

Hipotesis:

$$H_0 : \text{Residual berdistribusi normal}$$

$$H_1 : \text{Residual tidak berdistribusi normal}$$

Nilai statistik D pada pengujian kenormalan model ARIMA (0,1,2) beserta nilai statistik hitungnya ditampilkan Tabel 5 sebagai berikut. Nilai tersebut akan dibandingkan dengan nilai taraf nyata (α) sebesar 5%

Tabel 5.
Pengujian Kenormalan Residual ARIMA (0,1,2)

Test	Statistik (D)	P value (Pr > D)
Kolmogorov-Smirnov	0.041932	0.0699

Berdasarkan Tabel 5 pengujian kenormalan diketahui nilai P_value pada pengujian Kolmogorof Smirnof. Nilai P_value dari pengujian residual normal melebihi nilai α sebesar 5%. Keputusan dari pengujian tersebut adalah terima H_0 yang berarti residual model telah mengikuti distribusi normal.

Berdasarkan keseluruhan pengujian sebelumnya maka model ARIMA (0,1,2) layak digunakan untuk peramalan. Hasil peramalan model ARIMA (0,1,2) adalah sebagai berikut.

Tabel 6.
Hasil Peramalan ARIMA (0,1,2)

Tanggal	Temp (°C)	Tanggal	Temp (°C)	Tanggal	Temp (°C)
1-Mar-12	28.82	12-Mar-12	29.04	23-Mar-12	29.04
2-Mar-12	29.04	13-Mar-12	29.04	24-Mar-12	29.04
3-Mar-12	29.04	14-Mar-12	29.04	25-Mar-12	29.04
4-Mar-12	29.04	15-Mar-12	29.04	26-Mar-12	29.04
5-Mar-12	29.04	16-Mar-12	29.04	27-Mar-12	29.04
6-Mar-12	29.04	17-Mar-12	29.04	28-Mar-12	29.04
7-Mar-12	29.04	18-Mar-12	29.04	29-Mar-12	29.04
8-Mar-12	29.04	19-Mar-12	29.04	30-Mar-12	29.04
9-Mar-12	29.04	20-Mar-12	29.04	31-Mar-12	29.04
10-Mar-12	29.04	21-Mar-12	29.04		
11-Mar-12	29.04	22-Mar-12	29.04		

C. Permodelan ANN

Analisis ANN data temperatur pada arsitektur *Neural Network* menggunakan pendekatan *Feed Forward Neural Network* (FFNN) atau *backpropagation*. Fungsi aktivasi yang digunakan adalah fungsi logistik sigmoid untuk pemrosesan dari input ke *hidden layer*. Adapun untuk pemrosesan dari *hidden layer* ke output menggunakan fungsi linear.

Input pada pemrosesan FFNN pada data temperatur menggunakan beberapa jumlah input. Ada 3 macam input yang digunakan yaitu 1) Input pada lag-1 (Z_{t-1}); 2) Input pada lag-1 (Z_{t-1}) dan lag-2 (Z_{t-2}); dan 3) Input pada lag-1 (Z_{t-1}), lag-2 (Z_{t-2}), lag-3 (Z_{t-3}), lag-4 (Z_{t-4}), dan lag-5 (Z_{t-5}).

Pemrosesan FFNN dengan satu input pada lag-1 (Z_{t-1}) dan 1 output dengan jumlah neuron pada *hidden layer* antara 1 hingga 10 menghasilkan nilai-nilai kebaikan model (AIC, SBC, RMSE) pada *in sample* serta MAPE dan RMSE pada *out sample*. Berikut ditampilkan kriteria-kriteria tersebut.

Tabel 7
Perbandingan Model dengan Input pada Lag-1 (Z_{t-1})

Neuron	Training			Testing	
	AIC	SBC	RMSE	MAPE	RMSE
1	-322.4654	-306.2665	0.6773	0.073	0.7668
2	-321.3602	-293.0121	0.6734	0.0722	0.759
3	-319.4252	-278.9278	0.6701	0.0729	0.7678
4	-311.1472	-258.5007	0.6719	0.0729	0.7671
5	-311.9832	-247.1874	0.6665	0.0717	0.7539
6	-325.3427	-248.3978	0.6515	0.0723	0.7606
7	-303.8936	-214.7995	0.6635	0.0717	0.7541
8	-303.6979	-202.4545	0.659	0.0997	1.0597
9	-299.7893	-186.3967	0.6573	0.0753	0.7885
10	-297.3353	-171.7936	0.6546	0.0996	1.0584

Berdasarkan Tabel 7 maka model FFNN yang terpilih adalah model FFNN (1,5,1). Model FFNN tersebut terdiri dari 1 input, 5 neuron, dan 1 output. Nilai MAPE untuk hasil permalan sebesar 0.0717%. Berikut hasil nilai permalan dari model FFNN (1,5,1).

Pemrosesan FFNN dengan du input pada lag-1 (Z_{t-1}) dan lag-2 (Z_{t-2}) serta 1 output dengan jumlah neuron pada *hidden layer* antara 1 hingga 10 menghasilkan nilai-nilai kebaikan model (AIC, SBC, RMSE) pada *in sample* serta MAPE dan RMSE pada *out sample*. Berikut ditampilkan kriteria-kriteria tersebut.

Tabel 8
Perbandingan Model dengan Input pada Lag-1 (Z_{t-1}) dan Lag-2 (Z_{t-2})

Neuron	Training			Testing	
	AIC	SBC	RMSE	MAPE	RMSE
1	-322.4693	-302.2207	0.6757	0.0727	0.764
2	-322.6141	-286.1665	0.6692	0.0729	0.7684
3	-318.218	-265.5715	0.6664	0.0729	0.7687
4	-332.2684	-263.423	0.6493	0.0714	0.7631
5	-344.6899	-259.6455	0.6338	0.0754	0.8034
6	-337.8756	-236.6322	0.6329	0.0746	0.7976
7	-326.8343	-209.392	0.6352	0.0765	0.7986
8	-332.5263	-198.8851	0.625	0.0775	0.8243
9	-324.3863	-174.5462	0.6251	0.0765	0.8107
10	-328.3963	-162.3572	0.6163	0.0717	0.7661

Berdasarkan Tabel 8 maka model FFNN yang terpilih adalah model FFNN (2,4,1). Model FFNN tersebut terdiri dari 2 input, 4 neuron, dan 1 output. Nilai MAPE untuk hasil permalan sebesar 0.0714%.

Pemrosesan FFNN dengan Input pada lag-1 (Z_{t-1}), lag-2 (Z_{t-2}), lag-3 (Z_{t-3}), lag-4 (Z_{t-4}), dan lag-5 (Z_{t-5}) dan 1 output dengan jumlah neuron pada *hidden layer* antara 1 hingga 10 menghasilkan nilai-nilai kebaikan model (AIC, SBC, RMSE)

pada *in sample* serta MAPE dan RMSE pada *out sample*. Berikut ditampilkan kriteria-kriteria tersebut.

Tabel 9
Perbandingan Model dengan Input pada Lag-1 (Z_{T-1}), Lag-2 (Z_{T-2}), Lag-3 (Z_{T-3}), Lag-4 (Z_{T-4}), Lag-5 (Z_{T-5})

Neuron	Training			Testing	
	AIC	SBC	RMSE	MAPE	RMSE
1	-325.4621	-293.0642	0.6685	0.0801	0.8539
2	-319.6843	-258.9383	0.6621	0.133	1.3933
3	-330.385	-241.2908	0.6431	0.112	1.1769
4	-351.4142	-233.9719	0.6171	0.0797	0.847
5	-328.6234	-182.833	0.6235	0.0789	0.8378
6	-347.3568	-173.2183	0.5999	0.0975	1.0797
7	-364.5548	-162.0681	0.5782	0.1212	1.3593
8	-374.0542	-143.2194	0.5624	0.1069	1.1242
9	-278.4974	-19.3145	0.6192	0.0721	0.7921
10	-389.263	-101.731	0.5345	0.1548	1.5503

Berdasarkan Tabel 9 maka model FFNN yang terpilih adalah model FFNN (5,9,1). Model FFNN tersebut terdiri dari 5 input, 9 neuron, dan 1 output. Nilai MAPE untuk hasil permalan sebesar 0.0714%.

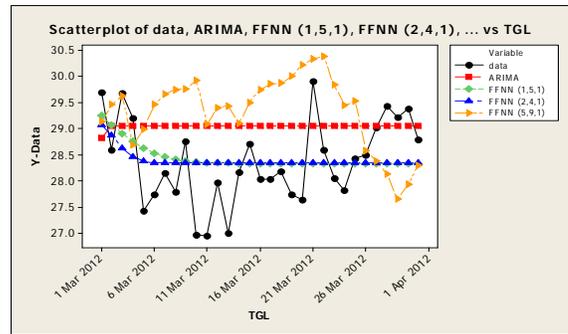
D. Perbandingan Model ARIMA dan ANN

Untuk mengetahui model yang terbaik berdasarkan nilai keakuratan dalam melakukan peramalan data temperatur Kota Surabaya maka antara model ARIMA dan ANN dibandingkan. Berdasarkan model-model yang telah didapatkan sebelumnya maka dilakukan perbandingan sebagaimana tabel di bawah ini.

Tabel 10.
Perbandingan ARIMA dan ANN

Model	MAPE (%)
ARIMA (0,1,2)	2.3050
FFNN (1,5,1)	0.0717
FFNN (2,4,1)	0.0714
FFNN (1,5,1)	0.0721

Berdasarkan Tabel 10 maka model yang mendekati dari nilai data asli adalah FFNN(2,4,1). Sehingga dapat disimpulkan bahwa model terbaik untuk data temperatur Kota Surabaya adalah FFNN (2,4,1). Berikut grafik perbandingan hasil peramalan antara model ARIMA dan ANN.



Gambar. 3. Plot Perbandingan Model ARIMA dan ANN

V. KESIMPULAN

Berdasarkan pembahasan dalam bab sebelumnya maka dapat diambil beberapa kesimpulan sebagai berikut.

1. Pendugaan data temperatur udara Kota Surabaya dengan menggunakan metode ARIMA menghasilkan model ARIMA (0,1,2)
2. Pendugaan data temperatur udara Kota Surabaya dengan menggunakan *Artificial Neural Network* menghasilkan model FFNN (5,10,1)
3. Berdasarkan kedua model tersebut maka model terbaik yang dapat diterapkan dalam peramalan temperatur udara Kota Surabaya adalah FFNN (5,10,1)

Model ARIMA dari hasil penelitian masih belum baik sehingga penelitian selanjutnya dapat memperbaiki model. Adapun untuk ANN *Backpropagation* memberikan model yang cukup baik dan dapat dikembangkan pada model ANN lainnya.

DAFTAR PUSTAKA

- [1] Ahmad Luky (2008). Hubungan Iklim (Curah Hujan, Kelembaban, dan Suhu Udara) dengan Kejadian penyakit Demam Berdarah Dengue (DBD) [Online]. Available: <http://gudangmakalah.blogspot.com>.
- [2] Benazir Pirzada, “Kalibrasi Peramalan Ensemble Data Temperatur Udara Harian dengan Bayesian Model Averaging BMA (Studi Kasus: Data Stasiun Pengamatan Juanda Surabaya Tahun 2008-2009),” Tugas Akhir Jurusan Statistika Institut Teknologi Sepuluh Nopember, Surabaya (2010).
- [3] Ramdani, “Penggunaan Model ARIMA dalam Peramalan Suhu Udara di Sekitar Palangkaraya,” Skripsi Jurusan Statistika, Institut Pertanian Bogor, Bogor (2008).
- [4] Anonim (2008) Jaringan Syaraf Tiruan (Artificial Neural Network) [Online]. Available: <http://creasoft.wordpress.com/2008/04/21/jaringan-saraf-tiruan-artificial-neural-network>.
- [5] S. Makridakis, S. C. Wheelwright, dan V. E. McGee, *Forecasting: Methods and Application*, 2nd Edition, New York: John Wiley and Sons Inc (1983).
- [6] William W. S. Wei, *Time Series Analysis: Univariate and Multivariate Methods*, USA: Addison-Wesley Publishing Company (1990).
- [7] Jong Jek Siang, *Aplikasi Jaringan Syaraf Tiruan dan Pemrograman Menggunakan MATLAB*. Jogjakarta: Andi Jogjakarta (2005).