

Peramalan Jumlah Peserta OJT di PT.POMI Menggunakan ARIMA *Box-Jenkins* dan *Radial Basis Function Neural Network*

Wiji Renisa Dwiningtyas dan Mike Prastuti

Departemen Statistika Bisnis, Institut Teknologi Sepuluh Nopember (ITS)

e-mail: mike_p@statistika.its.ac.id

Abstrak—*On the Job Training* (OJT) merupakan pelatihan dimana siswa maupun mahasiswa mempelajari suatu pekerjaan yang sesuai dengan bidangnya di perusahaan. PT.POMI merupakan salah satu perusahaan swasta yang bergerak di bidang Pembangkit Listrik Tenaga Uap (PLTU). PT.POMI memberi peluang bagi siswa maupun mahasiswa untuk melakukan OJT, tetapi tidak bisa menerima semua siswa maupun mahasiswa yang mendaftar. Oleh karena itu perlu dilakukan sebuah analisis peramalan untuk meramalkan jumlah peserta OJT di PT.POMI, yaitu menggunakan metode ARIMA *Box-Jenkins* dan *Radial Basis Function Neural Network* (RBFNN). Data yang digunakan adalah jumlah peserta OJT pada Bulan Januari 2010 hingga Desember 2020. Hasil analisis menunjukkan bahwa model ARIMA terbaik yaitu ARIMA (3,1,0) yang memiliki nilai MAPE sebesar 42,741 dan pada RBFNN memiliki nilai MAPE sebesar 41,239. Sehingga dapat disimpulkan bahwa RBFNN mampu menghasilkan ramalan jumlah peserta OJT lebih baik daripada model ARIMA.

Kata Kunci—ARIMA, Peramalan, PT.POMI, dan RBFNN.

I. PENDAHULUAN

ILMU pengetahuan dan teknologi di Indonesia saat ini dihadapkan pada persaingan yang sangat ketat pada tingkat global. Kualitas sumber daya manusia juga diharapkan meningkat seimbang dengan berkembangnya ilmu pengetahuan dan teknologi. Pengembangan sumber data manusia yang berkualitas dapat melalui lembaga-lembaga pendidikan serta sarana dan pra-sarana penunjang pendidikan yang baik. Salah satu cara yang dapat dilakukan yaitu dengan melakukan *On the Job Training* (OJT) di salah satu perusahaan agar siap menghadapi persaingan pada tingkat global.

OJT merupakan pelatihan yang dilakukan langsung di tempat kerja, dimana seorang siswa maupun mahasiswa dapat mempelajari suatu pekerjaan yang sesuai dengan bidangnya masing-masing. Salah satu perusahaan yang membuka kesempatan bagi siswa maupun mahasiswa untuk melakukan OJT adalah PT.POMI. PT.POMI merupakan salah satu perusahaan swasta yang bergerak pada bidang Pembangkit Listrik Tenaga Uap (PLTU).

PT.POMI tentunya tidak bisa menerima semua siswa maupun siswa yang ingin melakukan OJT. Oleh karena itu perlu dilakukan sebuah analisis peramalan. Beberapa metode peramalan yang sering digunakan yaitu *Autoregressive Moving Average* (ARIMA), dimana model ini memiliki kekurangan yaitu tidak dapat menangkap pola-pola yang bersifat non-linier. Untuk itu diperlukan metode *Radial Basis Function Neural Network* (RBFNN) agar bisa menangkap pola-pola yang bersifat non-linier yang biasa terdapat pada data *time series*.

Tabel 1.

Model ARIMA		
Model	ACF	PACF
MA(<i>q</i>)	Terpotong setelah lag <i>q</i>	Turun Cepat
AR (<i>p</i>)	Turun Cepat	Terpotong setelah lag <i>p</i>
ARMA (<i>p,q</i>)	Turun Cepat	Turun Cepat
AR (<i>p</i>) or MA (<i>q</i>)	Terpotong setelah lag <i>q</i>	Terpotong setelah lag <i>p</i>

Dalam melakukan analisis peramalan, tidak ada metode yang sangat tepat untuk meramalkan keadaan data di masa yang akan datang. Sehingga dalam setiap metode peramalan pasti terdapat sebuah kesalahan atau *error*. Alat yang digunakan untuk menghitung kesalahan pada peramalan menggunakan *Mean Absolute Percentage error* (MAPE).

II. TINJAUAN PUSTAKA

A. *Autoregressive Integrated Moving Average* (ARIMA)

Autoregressive Moving Average (ARIMA) merupakan gabungan antara model *Autoregressive* (AR) dan *Moving Average* (MA) yang memerlukan proses *differencing* agar mengubah data yang tidak stasioner menjadi stasioner [1]. Model ARIMA secara umum seperti dalam persamaan (1).

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

dimana,

p : orde pada model AR

q : orde pada model MA

$\phi_p(B)$: koefisien komponen AR pada orde ke-*p*

$\theta_q(B)$: koefisien komponen MA pada orde ke-*q*

$(1 - B)^d$: *differencing* orde *d*

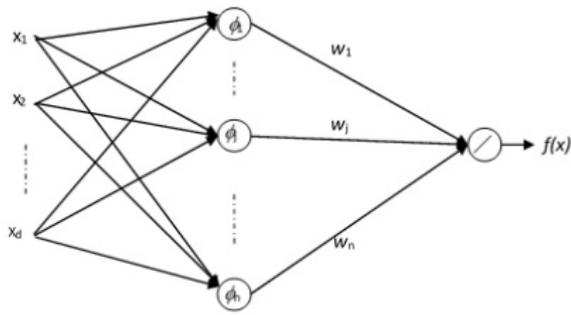
a_t : nilai kesalahan pada saat *t*

Pendugaan model ARIMA dapat dilihat melalui plot ACF dan PACF. Orde *p* menunjukkan model *Autoregressive* dan orde *q* menunjukkan model *Moving Average* [2]. Pendugaan model ARIMA dapat dilihat pada Tabel 1.

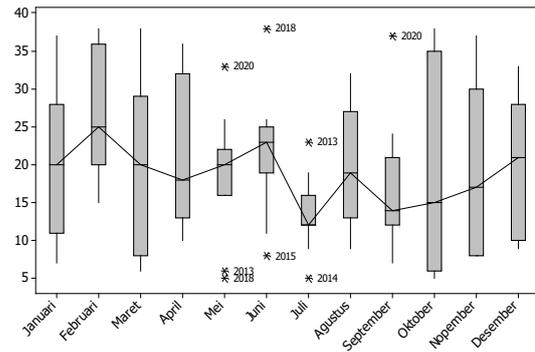
Setelah dilakukan pendugaan model ARIMA, selanjutnya dilakukan estimasi dan pengujian signifikansi parameter. Estimasi parameter menggunakan *conditional Least Square* (CLS) [3]. Untuk model AR(1) seperti dalam persamaan (2).

$$\hat{\phi}_1 = \frac{\sum_{t=2}^n (Z_t - \bar{Z})(Z_{t-1} - \bar{Z})}{\sum_{t=2}^n (Z_{t-1} - \bar{Z})^2} \tag{2}$$

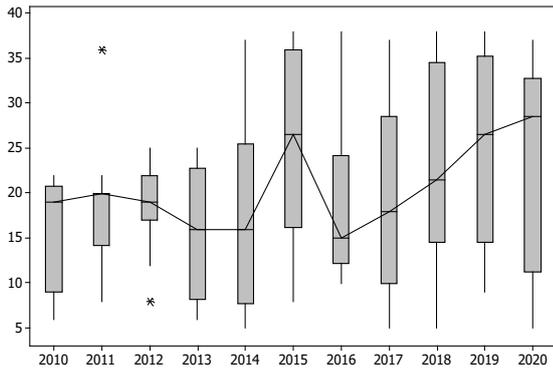
Pengujian signifikansi parameter dilakukan untuk mengetahui apakah hasil penaksiran parameter signifikan atau tidak [4]. Pengujian signifikansi untuk parameter AR adalah sebagai berikut.



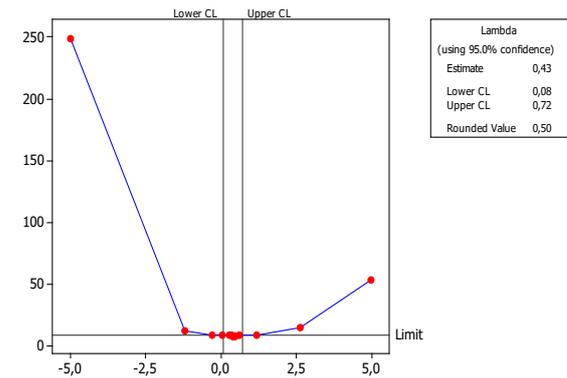
Gambar 1. Arsitektur RBFNN.



Gambar 3. Boxplot jumlah peserta OJT di PT.POMI.



Gambar 2. Boxplot jumlah peserta OJT di PT.POMI Tahun 2010-2020.



Gambar 4. Plot Box-Cox jumlah peserta OJT di PT.POMI Tahun 2010-2020.

Hipotesis:

$H_0 : \phi_i = 0$ (Parameter AR tidak signifikan terhadap model)

$H_1 : \phi_i \neq 0$ (Parameter AR signifikan terhadap model)

Statistik uji :

$$t_{hitung} = \frac{\hat{\phi}_i}{s_{\phi_i}} \quad (3)$$

Pengujian signifikansi untuk parameter MA adalah sebagai berikut.

Hipotesis:

$H_0 : \theta_j = 0$ (Parameter AR tidak signifikan terhadap model)

$H_1 : \theta_j \neq 0$ (Parameter AR signifikan terhadap model)

Statistik uji :

$$t_{hitung} = \frac{\hat{\theta}_j}{s_{\theta_j}} \quad (4)$$

Jika diterapkan taraf signifikansi α sebesar 5%, maka tolak H_0 jika $|t_{hitung}| > t_{\alpha/2, df=n-p}$ dengan p adalah banyaknya parameter atau $P-value < \alpha$

B. Cek Diagnosa Residual

1) White Noise

Residual disebut *white noise* jika tidak terdapat autokorelasi antara lag ke-1 sampai dengan lag ke- k . Pemeriksaan residual *white noise* adalah sebagai berikut.

Hipotesis :

$H_0 : \rho_{a,1} = \rho_{a,2} = \rho_{a,3} = \dots = \rho_{a,k} = 0$ (residual memenuhi proses *white noise*)

$H_1 : \rho_{a,k} \neq 0, k = 1, 2, \dots, K$ (residual tidak memenuhi proses *white noise*)

Statistik uji :

$$Q_k = n(n + 2) \sum_{k=1}^K \frac{\rho_{a,k}^2}{n-k} \quad (5)$$

Jika diterapkan taraf signifikansi α sebesar 5%, maka tolak H_0 jika $Q > \chi^2_{tabel}$ dengan derajat bebas (db) = $k - p - q$ atau $P-value < \alpha$ dengan p dan q merupakan orde AR dan MA. [2]

2) Berdistribusi Normal

Setelah dilakukan pemeriksaan residual *white noise*, selanjutnya memeriksa apakah residual berdistribusi normal. Pemeriksaan residual berdistribusi normal adalah sebagai berikut.

Hipotesis :

$H_0 : F(x) = F_0(x)$ (residual berdistribusi normal)

$H_1 : F(x) \neq F_0(x)$ (residual tidak berdistribusi normal)

Statistik Uji :

$$D = \sup |F(x) - F_0(x)| \quad (6)$$

Jika ditetapkan taraf signifikan α , maka daerah penolakannya adalah tolak H_0 jika $D > D_{(1-\alpha, n)}$ atau $P-value < \alpha$. Dimana n merupakan banyaknya data (observasi) [2].

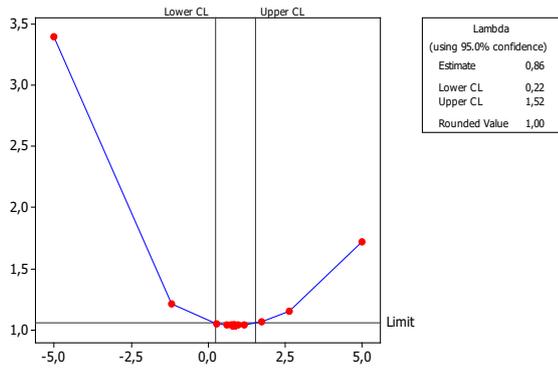
C. Pemilihan Model Terbaik

Mean Absolute Percentage error (MAPE) dihitung dengan menggunakan kesalahan absolut pada tiap periode dibagi dengan nilai observasi yang nyata untuk periode tersebut. Lalu, merata-rata kesalahan persentase absolut [2]. Rumus MAPE seperti dalam persamaan (7).

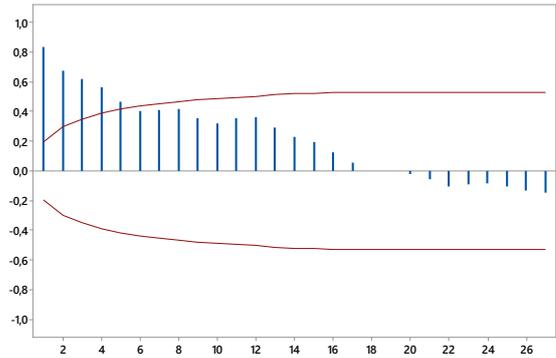
$$MAPE = \frac{\sum_{t=1}^n \left| \frac{Z_t - \hat{Z}_t}{Z_t} \right|}{n} \times 100\% \quad (7)$$

D. Uji Linieritas

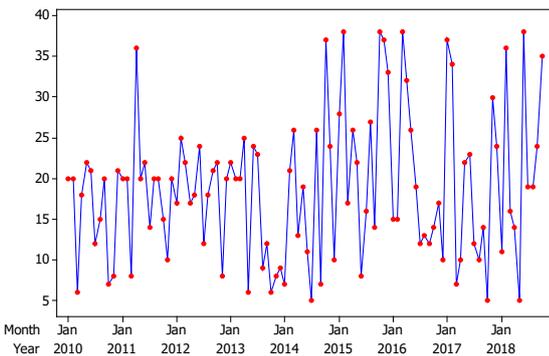
Uji linieritas menggunakan Uji Terasvirta dengan hipotesis sebagai berikut.



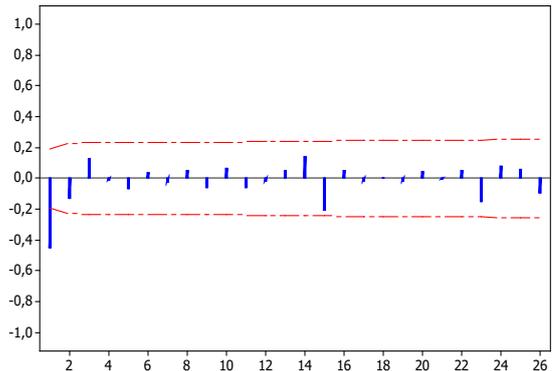
Gambar 5. Plot Box-Cox pada data transformasi jumlah peserta OJT di PT.POMI tahun 2010-2020.



Gambar 7. Plot ACF.



Gambar 6. Time series plot jumlah peserta OJT di PT.POMI tahun 2010-2020.



Gambar 8. Plot ACF setelah Differencing.

Hipotesis :

H_0 : Model linier

H_1 : Model nonlinier

Statistik Uji :

$$F_{hitung} = \frac{(SSR_0 - SSR_1) / m}{SSR_1 / (n - p - 1 - m)} \quad (8)$$

Jika ditentukan taraf signifikan α sebesar 5% maka tolak H_0 jika nilai $F_{hitung} > F_{(\alpha, m, (n-p-1-m))}$ atau nilai $P\text{-value} < \alpha$ [5].

E. Radial Basis Function Neural Network

Pendekatan RBFNN memperkenalkan n basis fungsi yang ditetapkan untuk setiap titik. Fungsi i bergantung pada jarak euclidean $\|x - x_i\|$. Output dari RBFNN adalah kombinasi linier dari bobot w_{js} dengan fungsi aktivasi $h_j(x)$ dan bobot bias w_{0s} [6].

$$y_s = \sum_{j=1}^k w_{js} \phi_j(x) + w_{0s} \quad (9)$$

Arsitektur RBFNN dapat dilihat pada Gambar 1. Terdapat d variabel input, n node pada hidden layer, dan a node pada output layer [7].

Fungsi Gaussian merupakan fungsi yang sering digunakan dalam pemodelan RBFNN, karena memberikan nilai nol jika inputnya cenderung tak terhingga dan memberikan nilai satuan jika fungsi input cenderung nol [6]. Secara umum pemetaan x ke y seperti dalam persamaan (10).

$$f(x_i) = y_i, i = 1, 2, 3, \dots, n \quad (10)$$

$f(x_i)$ didefinisikan oleh supervisi linier dari n fungsi basis yang sama. Jika diberikan n titik data, $\{x_i \in \mathbb{R}^d \mid i = 1, 2, \dots, n\}$ adalah pusat dari node pada hidden layer RBFNN, jadi dapat

ditulis matriks sebagai berikut:

$$\begin{bmatrix} \phi_{11} & \phi_{12} & \dots & \phi_{1n} \\ \phi_{21} & \phi_{22} & \dots & \phi_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \phi_{n1} & \phi_{n2} & \dots & \phi_{nn} \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}$$

dimana, $\phi_{ij} = \phi(\|x_i - x_j\|), i = 1, 2, 3, \dots, n$

jika $y = [y_1 \ y_2 \ \dots \ y_n]$, $w = [w_1 \ w_2 \ \dots \ w_n]^T$

dan $w = \varphi = \phi_j$, jadi $\varphi w = y$. Bobot dari output layer dapat ditulis $w = \varphi^{-1} y$. Fungsi aktivasi j pada pengamatan i seperti dalam persamaan (11).

$$\phi_j(x) = \exp\left(-\sum_{i=1}^I \left(\frac{\|x_i - c_{ji}\|^2}{2\sigma_{ji}^2}\right)\right) \quad (11)$$

III. METODOLOGI

A. Sumber Data

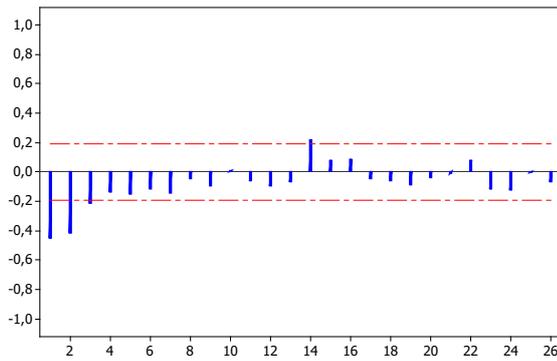
Data yang digunakan dalam penelitian ini didapatkan selama melakukan research di PT.POMI. Periode data adalah bulan Januari 2010 hingga Desember 2020.

B. Variabel Penelitian

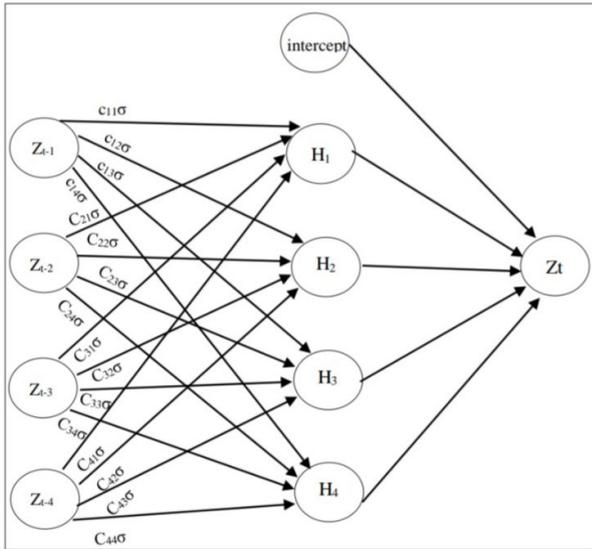
Pada penelitian ini variabel yang diamati adalah jumlah peserta OJT di PT.POMI dalam periode bulanan.

C. Langkah Analisis

Melakukan analisis karakteristik jumlah peserta OJT, melakukan analisis peramalan jumlah peserta OJT menggunakan ARIMA. Berikut adalah langkah-langkah yang dilakukan.



Gambar 9. Plot PACF.



Gambar 10. Arsitektur jaringan RBFNN jumlah peserta OJT di PT.POMI.

- 1) Identifikasi kestasioneran data
- 2) Identifikasi pendugaan model ARIMA menggunakan plot ACF dan PACF
- 3) Melakukan estimasi dan pengujian signifikansi parameter
- 4) Cek diagnosa residual *white noise* dan berdistribusi normal
- 5) Memilih model terbaik

Melakukan peramalan jumlah peserta OJT menggunakan RBFNN dengan langkah-langkah sebagai berikut.

- 1) Menentukan variabel *input*
- 2) Menentukan minimum dan maksimum node pada *hidden layer*
- 3) Menentukan jaringan yang optimum

Memilih model peramalan berdasarkan ARIMA dan RBFNN menggunakan MAPE, dan melakukan peramalan jumlah peserta OJT untuk satu periode kedepan

IV. HASIL DAN PEMBAHASAN

A. Karakteristik Jumlah Peserta OJT di PT.POMI

Karakteristik jumlah peserta OJT di PT.POMI pada tahun 2010-2020 dapat dilihat pada Gambar 1 dan Gambar 2. Gambar 2 menunjukkan bahwa terjadi penurunan nilai *median* jumlah peserta OJT di PT.POMI pada tahun 2013 dan 2016. Pada tahun 2014 dan 2017 terjadi peningkatan sampai pada tahun 2020. Terdapat data *outlier* pada tahun 2011 yaitu pada bulan April dengan jumlah peserta OJT sebanyak 36 peserta dan pada tahun 2012 yaitu pada bulan Nopember

Tabel 2. Pengujian signifikansi parameter

Model	Estimasi Parameter	Nilai Koefisien	P-value	Kesimpulan
ARIMA (0,1,1)	$\hat{\theta}_1$	0,981	<.0001	Signifikan
	$\hat{\phi}_1$	-0,737	<.0001	Signifikan
ARIMA (3,1,0)	$\hat{\phi}_2$	-0,569	<.0001	Signifikan
	$\hat{\phi}_3$	-0,225	0,023	Signifikan
	$\hat{\theta}_1$	0,988	<.0001	Signifikan
ARIMA (3,1,1)	$\hat{\phi}_1$	0,075	0,463	Tidak signifikan
	$\hat{\phi}_2$	-0,040	0,697	Tidak signifikan
	$\hat{\phi}_3$	0,140	0,171	Tidak signifikan

Tabel 3. Cek diagnosa residual *white noise*

Model	Residual			
	Lag	P-value	Keputusan	Kesimpulan
ARIMA (0,1,1)	6	0,7196	Gagal Tolak H_0	<i>White Noise</i>
	12	0,9496	Gagal Tolak H_0	
	18	0,5976	Gagal Tolak H_0	
	24	0,5996	Gagal Tolak H_0	
ARIMA (3,1,0)	6	0,0538	Gagal Tolak H_0	<i>White Noise</i>
	12	0,4256	Gagal Tolak H_0	
	18	0,0937	Gagal Tolak H_0	
	24	0,1165	Gagal Tolak H_0	

Tabel 4. Cek diagnosa residual berdistribusi normal

Model	Residual		
	P-value	Keputusan	Kesimpulan
ARIMA(0,1,1)	>0,1500	Gagal Tolak H_0	Berdistribusi Normal
ARIMA(3,1,0)	>0,1500	Gagal Tolak H_0	Berdistribusi Normal

dengan jumlah peserta OJT sebanyak 8 peserta.

Gambar 3 menunjukkan bahwa pada umumnya jumlah peserta OJT di PT.POMI cenderung tinggi pada Bulan Februari kemudian mulai turun pada Bulan Maret hingga April. Pada Bulan Mei dan Juni cenderung meningkat dan menurun pada bulan Juli. Pada Bulan Agustus meningkat kembali dan menurun pada Bulan September. Pada Bulan Oktober hingga Desember cenderung meningkat. Pola tersebut tidak berlaku pada bulan yang terdapat data *outlier* yaitu pada bulan Mei dan Juli tahun 2013, bulan Juli tahun 2014, bulan Mei dan Juni tahun 2018, serta bulan Mei dan September tahun 2020.

B. Peramalan Jumlah Peserta OJT Menggunakan ARIMA Box-Jenkins

Identifikasi stasioneritas dalam *varians* menggunakan plot *Box-Cox* seperti yang ditunjukkan pada Gambar 4. Gambar 4 menunjukkan bahwa pada data jumlah peserta OJT di PT.POMI memiliki nilai batas bawah (*Lower CL*) yaitu 0,08 dan nilai batas atas (*Upper CL*) sebesar 0,72, artinya nilai batas bawah dan batas atas tidak melewati angka satu. Selanjutnya dilihat pada nilai *rounded value* sebesar 0,50 yang menunjukkan bahwa data jumlah peserta OJT di PT.POMI belum stasioner dalam *varians* sehingga perlu dilakukan transformasi $\sqrt{Z_t}$. Hasil plot *Box-Cox* yang sudah ditransformasi menggunakan $\sqrt{Z_t}$ dapat dilihat pada Gambar 4. Gambar 5 menunjukkan bahwa setelah dilakukan transformasi menggunakan $\sqrt{Z_t}$ memiliki nilai batas bawah

Tabel 5.
Perhitungan MAPE

Model	MAPE
ARIMA (0,1,1)	45,394
ARIMA (3,1,0)	42,741

Tabel 6.
Uji linieritas data

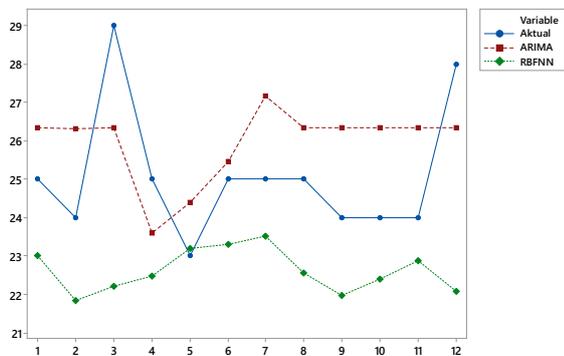
F _{hitung}	F _{tabel}	P-value
3,782	3,066	0,025

Tabel 7.
Nilai MSE

Data Training	Banyak node pada hidden layer	MSE (training)	MSE (testing)
90%	2	4919,037	512,357
	3	4920,591	512,605
	4	4916,903	486,857
	5	4917,224	512,314

Tabel 8.
Perbandingan kriteria kebaikan model ARIMA dan RBFNN

Model	MAPE
ARIMA (3,1,0)	42,741
RBFNN	41,239



Gambar 11. Perbandingan data aktual dan peramalan dengan ARIMA dan RBFNN.

yaitu 0,22 dan batas atas sebesar 1,52, yang berarti nilai batas bawah dan batas atas melewati angka satu. Selain itu dapat dilihat pada nilai *rounded value* sebesar 1,00 yang menunjukkan bahwa data sudah stasioner dalam *varians*.

Setelah melakukan analisis stasioneritas data dalam *varians*, selanjutnya melihat apakah data stasioner dalam *mean* atau tidak. Identifikasi stasioneritas data dalam *mean* dapat dilihat menggunakan plot *time series* dan plot ACF.

Gambar 6 menunjukkan bahwa fluktuasi data jumlah peserta OJT di PT.POMI tahun 2010-2020 tidak stabil sehingga diindikasikan data belum stasioner dalam *mean*. Selain melihat plot *time series*, untuk melihat apakah data stasioner dalam *mean* atau tidak dapat menggunakan plot ACF. Plot ACF dapat dilihat pada Gambar 7.

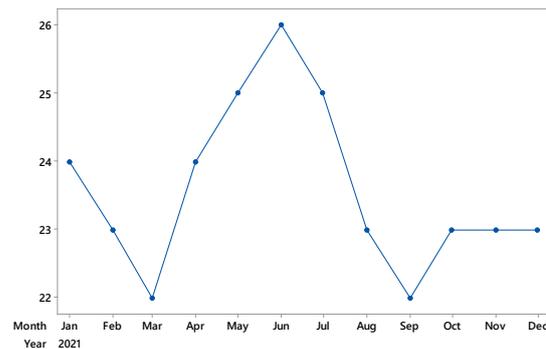
Gambar 7 menunjukkan bahwa plot ACF adalah *dies down fairly* atau turun secara lambat sehingga mengindikasikan bahwa data belum stasioner dalam *mean*. Karena data belum stasioner dalam *mean*, maka perlu dilakukan *differencing* dengan orde $d=1$. Hasil *differencing* dapat dilihat pada Gambar 8. Gambar 8 menunjukkan bahwa plot ACF *cuts off* pada lag 1 sehingga dapat dikatakan bahwa data sudah stasioner dalam *mean*.

Setelah data stasioner dalam *varians* dan *mean*, maka selanjutnya adalah identifikasi orde model ARIMA menggunakan plot ACF dan PACF. Plot ACF dan PACF dari

Tabel 9

Hasil peramalan jumlah peserta OJT di PT.POMI

Bulan	Jumlah Peserta OJT
Januari	24
Februari	23
Maret	22
April	24
Mei	25
Juni	26
Juli	25
Agustus	23
September	22
Oktober	23
Nopember	23
Desember	23



Gambar 12. Hasil ramalan jumlah peserta OJT di PT.POMI Tahun 2021.

data yang sudah stasioner ditunjukkan pada Gambar 8 dan 9.

Gambar 8 menunjukkan bahwa plot ACF signifikan pada lag ke-1. Sedangkan Gambar 9 menunjukkan bahwa plot PACF signifikan pada lag ke-1, 2, dan 3. Dugaan model ARIMA sementara adalah ARIMA (0,1,1), ARIMA (3,1,0), dan ARIMA (3,1,1).

Setelah didapatkan dugaan model, selanjutnya melakukan estimasi dan pengujian signfiikansi parameter. Hasil estimasi dan pengujian signfiikansi parameter dapat dilihat pada Tabel 2.

Model jumlah peserta OJT di PT.POMI yang semua parameternya signifikan adalah model ARIMA (0,1,1) dan ARIMA (3,1,0). Hasil dari analisis menunjukkan bahwa tidak semua dari dugaan model ARIMA yang diuji adalah signifikan.

Model ARIMA yang memiliki parameter signifikan akan dilanjutkan untuk cek diagnosa residual yang terdiri dari *white noise* dan berdistribusi normal. Cek diagnosa residual *white noise* dapat dilihat pada Tabel 2.

Model ARIMA yang memenuhi residual *white noise* adalah model ARIMA (0,1,1) dan ARIMA (3,1,0). Setelah dilakukan cek diagnosa *white noise*, selanjutnya dilakukan cek diagnosa berdistribusi normal yang dapat dilihat pada Tabel 3.

Tabel 4 menunjukkan bahwa hasil cek diagnosa residual berdistribusi normal terdapat dua model yang berdistribusi normal yaitu model ARIMA (0,1,1) dan ARIMA (3,1,0).

Pemilihan model terbaik dilakukan setelah cek diagnosa residual. Pemilihan model terbaik dengan melihat nilai MAPE terkecil. Hasil dari perhitungan MAPE dapat dilihat pada Tabel 5. Persamaan matematis dari model ARIMA (3,1,0) seperti dalam persamaan (12).

$$Z_t = 0,263Z_{t-1} + 0,168 Z_{t-2} + 0,344 Z_{t-3} + 0,225Z_{t-5} + a_t \quad (12)$$

Peramalan jumlah peserta OJT dipengaruhi oleh jumlah peserta OJT pada satu periode sebelumnya, dua periode sebelumnya, tiga periode sebelumnya, dan empat periode sebelumnya.

C. Uji Linieritas Data

Uji linieritas data dilakukan untuk mengetahui apakah terdapat pola linier pada data. Uji linieritas data yang digunakan adalah uji terasvirta. Hasil dari uji terasvirta dapat dilihat pada Tabel 6.

Tabel 6 menunjukkan bahwa F_{hitung} sebesar 3,782 lebih kecil dari F_{tabel} sebesar 3,067 dan diperkuat dengan nilai P -value sebesar 0,025 sehingga diputuskan tolak H_0 yang artinya data jumlah peserta OJT di PT.POMI memiliki pola non-linier.

D. Peramalan Jumlah Peserta OJT di PT.POMI Menggunakan Radial Basis Function Neural Network

Sebelum membentuk model peramalan menggunakan RBFNN, terlebih dahulu membagi data menjadi *training* dan *testing*. Data *training* yang digunakan adalah 90% dan data *testing* yang digunakan adalah 10%.

Tahap awal dalam pembentukan model RBFNN adalah dengan menentukan *input*. Variabel *input* dalam model ini $Z_{t-1}, Z_{t-2}, Z_{t-3},$ dan Z_{t-4} .

Penentuan ajrangan optimum menggunakan *trial and error*, dimana data *training* dikelompokkan ke dalam dua kelompok, tiga kelompok, empat kelompok, dan lima kelompok. Setiap percobaan yang dilakukan, diambil kelompok yang terbaik dengan melihat nilai *Mean Square Error* (MSE) terkecil. Hasil dari perhitungan MSE dapat dilihat pada Tabel 7.

Tabel 7 menunjukkan bahwa jika menggunakan data *training* sebesar 90%, terpilih empat pengelompokan karena memiliki nilai MSE terkecil yaitu sebesar 4916,903 pada *training* dan 486,857 pada *testing*. Dalam hal ini banyak *node* pada *hidden layer* yaitu sebanyak empat *neuron*.

Model RBFNN yang digunakan untuk peramalan jumlah peserta OJT di PT.POMI dapat dibentuk dengan arsitektur empat *neuron* pada *input layer*, empat *neuron* pada *hidden layer*, dan satu *neuron* pada *output layer*. Arsitektur jaringan RBFNN yang terbentuk dapat dilihat pada Gambar 10.

Nilai *center* dan standar deviasi serta bobot yang digunakan pada jaringan RBFNN adalah sebagai berikut:

$$c = \begin{pmatrix} 24,353 & 20,525 & 12,484 & 23,679 \\ 10,588 & 20,575 & 19,871 & 23,250 \\ 21,471 & 13,150 & 17,710 & 29,179 \\ 17,765 & 20,875 & 11,516 & 27,107 \end{pmatrix}$$

$$\sum (7,538 \quad 8,921 \quad 7,053 \quad 11,963)$$

$$W_{intercept} = 21,247, w_1 = -6,399, w_2 = -9,503,$$

$$w_3 = -0,768, w_4 = 6,649$$

Model matematis dari RBFNN seperti dalam persamaan berikut:

$$Z_t = 21,247 - 6,399 h_1(x) - \dots + 6,649 h_4(x) \quad (13)$$

E. Perbandingan Metode ARIMA dan Radial Basis Function Neural Network

Setelah mendapatkan model peramalan dengan metode ARIMA dan RBFNN, selanjutnya dilakukan peramalan. Hasil peramalan data *outsample* dengan menggunakan metode ARIMA dan RBFNN dapat dilihat pada Gambar 11.

Dalam membandingkan hasil ramalan dengan model ARIMA dan RBFNN, maka digunakan kriteria kebaikan model yaitu MAPE. Nilai MAPE dari kedua model dapat dilihat pada Tabel 8.

Tabel 8 menunjukkan bahwa model RBFNN menghasilkan nilai MAPE lebih kecil daripada model ARIMA yaitu sebesar 41,063. Sehingga dapat disimpulkan bahwa model terbaik untuk melakukan peramalan jumlah peserta OJT di PT.POMI adalah menggunakan model RBFNN.

F. Peramalan Jumlah Peserta OJT di PT.POMI

Hasil peramalan jumlah peserta OJT di PT.POMI bulan Januari hingga Desember 2021 dapat dilihat pada Tabel 9. Tabel 9 menunjukkan bahwa jumlah peserta OJT di PT.POMI paling banyak yaitu pada bulan Juni yaitu sebanyak 26 peserta dan paling sedikit yaitu pada bulan Maret dan September yaitu sebanyak 22 peserta. Visualisasi dari ramalan jumlah peserta OJT di PT.POMI pada bulan Januari hingga Desember tahun 2021 dapat dilihat pada Gambar 12.

V. KESIMPULAN

Setelah dilakukan analisis dan pembahasan, maka kesimpulan dari hasil analisis adalah sebagai berikut model ARIMA terbaik adalah ARIMA (3,1,0) dengan nilai MAPE sebesar 42,741. Model yang optimum dengan menggunakan metode RBFNN yaitu dengan menggunakan empat *neuron* pada *input layer*, empat *neuron* pada *hidden layer*, dan satu *neuron* pada *output layer* dengan nilai MAPE sebesar 41,239. Hasil perbandingan nilai MAPE menunjukkan bahwa metode RBFNN lebih baik dibandingkan dengan metode ARIMA. Hasil ramalan menunjukkan bahwa jumlah peserta paling banyak pada bulan Juni dan paling sedikit pada bulan Maret dan September

DAFTAR PUSTAKA

- [1] V. M. Hardiana, D. a Susilaningrum, and Suhartono, "Peramalan jumlah tamu di hotel 'X' dengan pendekatan ARIMA, fungsi transfer, dan ANFIS," *J. Sains dan Seni ITS*, vol. 2, no. 2, pp. D183--D188, 2013.
- [2] W. Wei, *Time Series Analysis Univariate and Multivariate*. London: Pearson education, 2006.
- [3] J. D. Cryer and K.-S. Chan, *Time Series Analysis with Application in R*. New York: Springer, 2008.
- [4] B. Bowerman, *Forecasting and Time Series: An Applied Approach*, 3rd ed. California: Duxbury Press, 1993.
- [5] Subanar and Suhartono, "Uji Linieritas Tipe Lagrange Multiplier dengan Ekspansi Taylor untuk Deteksi Hubungan Nonlinier pada Data Time Series," Departemen Statistika: Universitas Gadjah Mada, 2006.
- [6] S. Ulama, M. Prastuti, and A. Oktavia, "Modeling coal company stock by using fuzzy-RBFNN," *Int. J. Mech. Eng. Technol.*, vol. 9, pp. 858--865, 2018.
- [7] S. Haykin and N. Network, "Neural networks: a comprehensive foundation," *Neural networks*, vol. 2, 2004.