

*Corresponding author: Ahmad Zaki,
Department of Mathematics,
Universitas Negeri Makassar,
Makassar, 90223, Indonesia

E-mail: ahmadzaki@unm.ac.id

RESEARCH / REVIEW ARTICLE [Calibri 11pt]

Peramalan Jumlah Penderita Demam Berdarah Dengue Menggunakan Metode Seasonal-ARIMA

Ahmad Zaki*, Maya Sari Wahyuni, Irwan, Wiwi Nari, & Abdul Rahman

Department of Mathematics, Universitas Negeri Makassar, Makassar, 90223, Indonesia

Abstract: Penelitian ini membahas tentang peramalan jumlah penderita Demam Berdarah Dengue (DBD) menggunakan metode Seasonal Autoregressive Integrated Moving Average (Seasonal-ARIMA). Tujuan dari penelitian ini adalah untuk mendapatkan model Seasonal-ARIMA terbaik sehingga dapat meramalkan jumlah penderita DBD di Kabupaten Bulukumba untuk 12 bulan ke depan. Jenis penelitian ini adalah penelitian terapan dengan data sekunder yang diperoleh dari Dinas Kesehatan Kabupaten Bulukumba. Jumlah data yang digunakan adalah 84 data dari tahun 2014-2020. Data dianalisis dengan menggunakan software Minitab 17. Hasil penelitian ini diperoleh model terbaik yaitu model Seasonal-ARIMA(1,1,0) (0,1,1)¹² untuk melakukan peramalan 12 bulan ke depan dengan nilai MAPE sebesar 30,62% yang berarti bahwa model peramalan cukup baik, layak dan memadai untuk melakukan peramalan.

Keywords: Peramalan, DBD, Seasonal-ARIMA, MAPE

1. Pendahuluan

Peramalan merupakan suatu teknik untuk memperkirakan suatu nilai pada masa yang akan datang dengan memperhatikan data masa lalu maupun data saat ini (Aswi & Sukarna, 2006). Peramalan umumnya dilakukan pada data *time series*. Data *time series* adalah data historis dari kejadian-kejadian yang terjadi di masa lalu (Soejoeti, 1987). Salah satu model yang sering digunakan dalam melakukan peramalan *time series* adalah model *Autoregressive Integrated Moving Average* (ARIMA). ARIMA adalah teknik untuk mencari pola yang paling cocok dari sekelompok data, dengan demikian ARIMA memanfaatkan sepenuhnya data masa lalu dan sekarang untuk melakukan peramalan jangka pendek yang akurat (Wigati, Rais, & Utami, 2016).

Metode Seasonal-ARIMA merupakan pengembangan metode ARIMA yang digunakan untuk peramalan data yang mengandung unsur musiman (Rochman, 2019). Kelebihan dari model ini dapat menerima semua jenis pola *time series* meskipun dalam prosesnya harus distasionerkan terlebih dahulu. Model Seasonal-ARIMA dapat diterapkan dalam bidang kesehatan untuk meramalkan jumlah penderita suatu penyakit, salah satunya yaitu penyakit demam berdarah.

DBD adalah penyakit yang disebabkan oleh virus dengue dan merupakan vector borne disease atau ditularkan melalui vector, yaitu nyamuk *Aedes aegypti*. DBD merupakan salah satu penyakit yang dapat menimbulkan wabah. Penyakit ini merupakan masalah kesehatan masyarakat yang besar di Indonesia khususnya Provinsi Sulawesi Selatan. Salah satu



kabupaten di Provinsi Sulawesi Selatan yang memiliki kasus DBD yang cukup tinggi yaitu Kabupaten Bulukumba (Dinkes Prov.Sulsel, 2018).

Tingginya angka penderita DBD di Kabupaten Bulukumba mengisyaratkan bahwa sangat penting untuk dilakukan pencegahan dan pengendalian penyakit. Manfaat penelitian ini sebagai bentuk upaya pencegahan dan pengendalian DBD dengan meramalkan jumlah penderita DBD di Kabupaten Bulukumba menggunakan metode Seasonal-ARIMA.

2. Tinjauan Pustaka

2.1. Model Runtun Waktu

Seasonal-ARIMA adalah salah satu model dalam analisis runtun waktu (time series) yang merupakan pengembangan dari model ARIMA yang dikembangkan oleh Box-Jenkins. Berikut ini merupakan bentuk umum model AR, MA, ARMA, ARIMA, dan SARIMA.

a. Model Autoregressive (AR)

AR merupakan suatu bentuk regresi, akan tetapi bukan menghubungkan variabel bebas dengan variabel terikat. Model ini digunakan untuk mengukur tingkat keceratan (*association*) antara X_t dengan X_{t-k} , apabila pengaruh dari *time lag* 1,2,3..., dan seterusnya sampai $k - 1$ dianggap terpisah (Makridarkis, 1999). Pada model ini menunjukkan nilai X_t aktual sebelumnya (Mudrajat, 2007).

Bentuk umum peramalan model *autoregressive* yaitu:

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \phi_3 X_{t-3} + \dots + \phi_p X_{t-p} + e_t$$

b. Model Moving Average (MA)

MA pada orde q menyatakan bahwa suatu model pengamatan ke- t dipengaruhi oleh kesalahan masa lalu. Bentuk umum dari *moving average* yaitu:

$$X_t = e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q}$$

c. Model Autoregressive Moving Average (ARMA)

Model AR dan MA dapat digabungkan ke dalam persamaan yang sama. Gabungan kedua model tersebut dinamakan ARMA (p,q).

Adapun persamaan umum ARMA yaitu:

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + e_t + \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q}$$

d. Model Autoregressive Integrated Moving Average (ARIMA)

Metode ARIMA merupakan metode yang secara intensif dikembangkan oleh George Box dan Gwilyn Jenkins. ARIMA merupakan suatu metode yang menghasilkan ramalan-ramalan berdasarkan sintesis dari pola data secara historis (Arsyad,1995). Model ARIMA (p,d,q) dapat dinyatakan dalam rumus sebagai berikut :

$$\phi_p(B)(1 - B)^d X_t = \theta_0 + \theta_q(B)e_t$$

e. Model Seasonal Autoregressive Integrated Moving Average (Seasonal-ARIMA)

Model Seasonal-ARIMA yang dikembangkan oleh Box-Jenkins adalah model yang telah banyak digunakan sebagai acuan dalam berbagai studi tentang peramalan time series pola musiman. Data runtun waktu seringkali dijumpai terdapat pola musiman atau berulang setiap kelipatan S periode waktu atau $S > 1$.

Bentuk umum model *Seasonal-ARIMA* dapat dinyatakan sebagai berikut :



$$\phi_p(B) \Phi_P(B^S)(1 - B)^d(1 - B^S)^D X_t = \theta_q(B) \Theta_Q(B^S) a_t$$

2.2. Stasioneritas

a. Stasioneritas dalam Mean (Rata-rata)

Suatu data runtun waktu dikatakan stasioner dalam mean jika rata-rata tetap pada keadaan waktu yang kondusif atau jika tidak ada unsur trend dalam data dan apabila suatu diagram time series berfluktuasi secara lurus. Apabila data tidak satasioner dalam mean maka dapat dilakukan proses differencing (pembedaan) pertama.

$$X'_t = X_t - X_{t-1}$$

b. Stasioneritas dalam Varians

Suatu data runtun waktu dikatakan stasioner dalam variansi jika struktur data dari waktu ke waktu mempunyai fluktuasi data yang tetap atau konstan dan tidak berubah-ubah, atau tidak ada perubahan variansi dalam besarnya fluktuasi.

Apabila ketidakstasioneran dalam variansi terjadi, maka dapat dihilangkan dengan melakukan perubahan untuk menstabilkan variansi. Misalkan $T(X_t)$ adalah fungsi transformasi dari X_t dan untuk menstabilkan variansi, kita dapat menggunakan transformasi kuasa atau *Box-Cox* (Wei,2006: Fauzi,2015):

$$T(X_t) = \begin{cases} \frac{X_t^\lambda - 1}{\lambda}, & \lambda \neq 0 \\ \ln X_t, & \lambda = 0 \end{cases}$$

2.3. Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF)

a. ACF

ACF adalah korelasi antara nilai-nilai suatu deret waktu yang sama dengan selisi waktu (*time lag*) 0, 1, 2 periode atau lebih. Untuk suatu data deret waktu X_1, X_2, \dots, X_n maka nilai fungsi autokorelasinya adalah sebagai berikut :

$$\rho_k = \frac{\sum_{t=1}^{n-k} (X_t - \bar{X})(X_{t+k} - \bar{X})}{\sum_{t=1}^n (X_t - \bar{X})^2}$$

b. PACF

PACF digunakan untuk mengukur tingkat keeratan (*association*) antara X_t dan X_{t-k} , apabila pengaruh dari lag waktu (*time lag*) 1, 2, 3, ..., $k-1$ dianggap terpisah. Pada tahun 1960 Durbin telah memperkenalkan metode yang lebih efisien untuk menyelesaikan persamaan Yulle-Walker yaitu :

$$\phi_{kk} = \frac{\rho_k - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_j}$$

a. Kriteria Pemilihan Model Terbaik

Menurut Hendikawati (2015), ada beberapa cara yang digunakan untuk mengukur kesalahan peramalan, yaitu :

a. Mean Square Error (MSE)

$$MSE = \frac{\sum_{t=1}^n 1(\bar{X}_t - X_t)^2}{n}$$

b. Root Mean Square Error (RMSE)

$$RMSE = \frac{\sum |\bar{X}_t - X_t|}{n}$$

c. Mean Absolute Percentage Error (MAPE)

$$MAPE = \frac{\sum_{t=1}^n |PE_t|}{n}$$



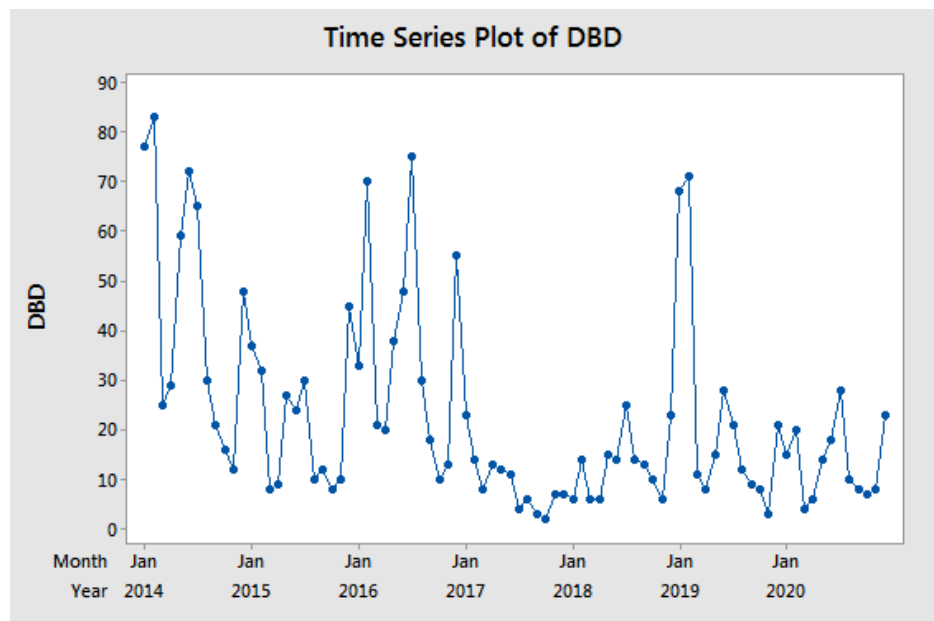
3. Metode Penelitian

Penelitian ini menggunakan metode *Seasonal-ARIMA* untuk meramalkan jumlah penderita DBD di Kabupaten Bulukumba. Data yang digunakan adalah data jumlah penderita DBD bulan Januari 2014 hingga Desember 2020 dari Dinas Kesehatan Kabupaten Bulukumba.

4. Hasil dan Pembahasan

Hasil dan pembahasan meliputi proses penstasioneran data untuk mendapatkan model *Seasonal-ARIMA* terbaik sehingga dapat meramalkan jumlah penderita DBD untuk 12 bulan ke depan.

4.1. Plot Time Series Data DBD




Gambar 1. Plot *Time Series* Jumlah Penderita DBD

Gambar 1 menunjukkan data tidak stasioner karena adanya fluktuasi data yang naik turun, sehingga data perlu distasionerkan terlebih dahulu dengan transformasi dan *differencing* (pembedaan) dengan mengurangi nilai satu periode dengan periode sebelumnya.

4.2. Identifikasi Kestasioneran Data

Proses identifikasi stasioner dalam varians terhadap data penderita DBD ini dapat dilihat melalui *box-cox* transformation seperti pada Gambar 2.



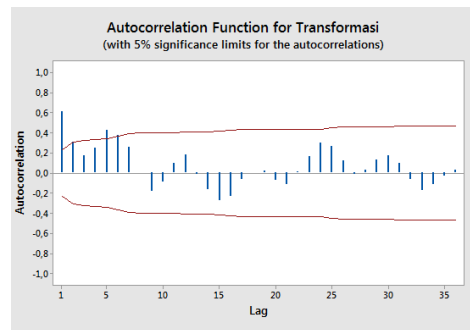
(a). *Box Cox* Plot data *In Sample*

(b). *Box Cox* Plot Hasil Transformasi

Gambar 2. *Box Cox* Transformation

Berdasarkan Gambar 2(a) menunjukkan bahwa data belum stasioner terhadap varians karena nilai *rounded value*-nya bernilai 0, sehingga perlu dilakukan transformasi untuk menstasionerkannya dimana transformasi yang digunakan adalah transformasi logaritma natural seperti pada Gambar 2(b) yang menunjukkan nilai *rounded value*-nya telah bernilai 1, sehingga mengindikasikan bahwa data telah stasioner dalam varians.


Langkah selanjutnya yaitu menentukan data telah stasioner dalam *mean* atau belum. Data telah stasioner dalam *mean* atau rata-rata dapat dilihat dari plot ACF. Lag pada plot ACF menunjukkan nilai autokorelasi pada data.



Gambar 3. Plot ACF Data *In Sample* Hasil Transformasi

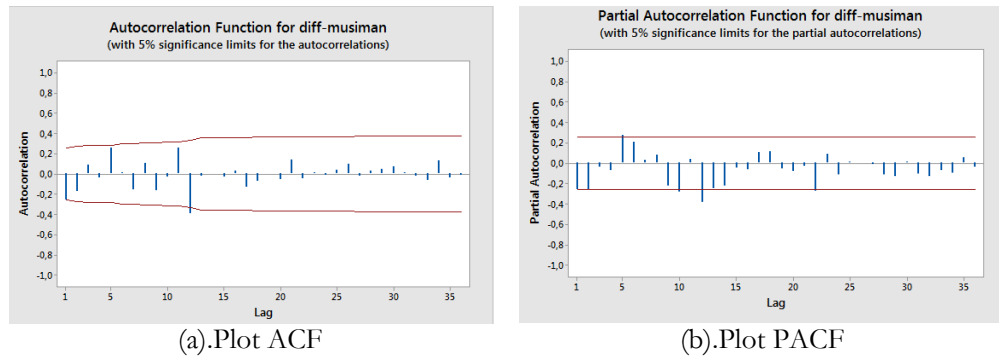
Gambar 3 plot ACF terlihat bahwa setelah lag 12 dan lag 24 mengalami penurunan secara eksponensial sehingga dapat disimpulkan bahwa terjadi musiman dengan pola perulangan sebanyak 12 lag, sehingga kita harus menggunakan *Seasonal-ARIMA* untuk memproyeksikan data selanjutnya.

Plot ACF pada Gambar 3 menunjukkan bahwa 3 lag pertama yaitu lag 1, 2, dan lag 5 masih melewati batas *comident interval* atau garis merah yang menunjukkan bahwa data masih terdapat autokorelasi dan tidak stasioner dalam *mean* atau rata-rata. Sehingga perlu dilakukan *differencing* atau pembedaan untuk menstasionerkannya.



Gambar 4. Plot ACF Hasil *Differencing* Pertama

Gambar 4 Plot ACF hasil *differencing* pertama menunjukkan bahwa data yang memiliki pola musiman yaitu lag 12 masih signifikan atau melewati batas *comident interval* sehingga untuk menghilangkan efek musiman tersebut perlu dilakukan proses *differencing* sekali lagi yaitu *differencing* musiman dimana nilai *differencing* adalah 12 sesuai dengan pola musiman yang terjadi.



Gambar 5. Plot ACF dan PACF *Differencing Musiman*

Plot ACF Gambar 5(a) dapat dilihat jumlah lag yang signifikan yaitu hanya lag pertama yang signifikan yang melewati batas *confident interval* dan lag 12 pada musimannya.

4.3. Identifikasi Model Seasonal-Arima

Model *Seasonal-ARIMA* dinotasikan dengan $(p, d, q)(P, D, Q)^S$ dimana $S = 12$ untuk pola musimannya. Nilai ordo dapat dilihat dari plot ACF dan PACF pada Gambar 5. Plot ACF digunakan untuk menentukan ordo dari MA(q) dan SMA(Q). Sedangkan plot PACF digunakan untuk menentukan ordo dari AR(p) dan SAR(P).

Berdasarkan Gambar 5 diidentifikasi model *Seasonal-ARIMA* yaitu : $(2,1,1)(1,1,1)^{12}, (1,1,1)(1,1,1)^{12}, (0,1,1)(1,1,1)^{12}, (1,1,0)(0,1,1)^{12}, (0,1,1)(1,1,0)^{12}, (0,1,1)(0,1,1)^{12}, (1,1,0)(1,1,0)^{12}$, dan $(0,1,0)(0,1,1)^{12}$.

4.4. Estimasi Parameter Model

Berdasarkan model yang telah diperoleh pada tahap identifikasi, selanjutnya dilakukan estimasi parameter dari setiap model pada Tabel 1.

Tabel 1. Hasil Estimasi Parameter Model *Seasonal-ARIMA*

Model <i>Seasonal-ARIMA</i>	Parameter	Estimasi	SE Estimasi	P-value	Ket.
$(2,1,1)(1,1,1)^{12}$	ϕ_1	-0,0905	0,2550	0,724	Tidak Sig
	ϕ_2	-0,3174	0,1875	0,096	Tidak Sig
	Φ_{12}	-0,4701	0,1710	0,008	Sig
	θ_1	0,4496	0,2611	0,091	Tidak Sig
	Θ_{12}	0,7694	0,2014	0,000	Sig
$(1,1,1)(1,1,1)^{12}$	ϕ_1	0,0842	0,2445	0,732	Tidak Sig
	Φ_{12}	-0,4310	0,1773	0,018	Sig
	θ_1	0,6290	0,1900	0,002	Sig
	Θ_{12}	0,7405	0,1823	0,000	Sig
$(0,1,1)(1,1,1)^{12}$	Φ_{12}	-0,4355	0,1755	0,016	Sig
	θ_1	0,5870	0,1108	0,000	Sig
	Θ_{12}	0,7453	0,1782	0,000	Sig
$(1,1,0)(0,1,1)^{12}$	ϕ_1	-0,2649	0,1316	0,049	Sig
	Θ_{12}	0,8505	0,1397	0,000	Sig
$(0,1,1)(1,1,0)^{12}$	Φ_{12}	-0,6335	0,1237	0,000	Sig
	θ_1	0,5542	0,1119	0,000	Sig
$(0,1,1)(0,1,1)^{12}$	θ_1	0,4513	0,1201	0,000	Sig
	Θ_{12}	0,7528	0,1676	0,000	Sig

Model <i>Seasonal-ARIMA</i>	Parameter	Estimasi	SE Estimasi	<i>P-value</i>	Ket.
$(1,1,0)(1,1,0)^{12}$	ϕ_1	-0,2923	0,1338	0,033	Sig
	Φ_{12}	-0,5256	0,1346	0,000	Sig
$(0,1,0)(0,1,1)^{12}$	Θ_{12}	0,8668	0,1347	0,000	Sig

Hipotesis:

H_0 : Estimasi parameter = 0 (parameter tidak signifikan dalam model)

H_1 : Estimasi parameter \neq 0 (parameter signifikan dalam model)

Kriteria penolakan tolak H_0 apabila $p\text{-value} < (\alpha) = 0.05$. Hasil uji signifikansi menunjukkan bahwa terdapat enam model *Seasonal-ARIMA* yang signifikan berdasarkan nilai $p\text{-value}$ -nya yaitu : $(0,1,1)(1,1,1)^{12}$, $(1,1,0)(0,1,1)^{12}$, $(0,1,1)(1,1,0)^{12}$, $(0,1,1)(0,1,1)^{12}$, $(1,1,0)(1,1,0)^{12}$, dan $(0,1,0)(0,1,1)^{12}$.

4.5. Pemeriksaan Diagnostik

a. Uji White Noise

Suatu model bersifat *white noise* artinya residual dari model tersebut memenuhi asumsi identik (variasi residual homogen) dan independen atau residual tidak berkorelasi (Munawaroh, 2010). Hasil uji asumsi *white noise* dapat dilihat pada Tabel 2.

Tabel 2. Hasil Statistik Uji L-Jung Box Asumsi *White Noise*

Model <i>Seasonal-ARIMA</i>	L-Jung Box					Ket.
$(0,1,1)(1,1,1)^{12}$	Lag	12	24	36	48	Tidak <i>White Noise</i>
	Chi Square	11,1	38,6	32	44	
	Df	8	20	32	44	
	<i>P-value</i>	0,194	0,008	0,019	0,058	
$(1,1,0)(0,1,1)^{12}$	Lag	12	24	36	48	<i>White Noise</i>
	Chi Square	16,9	31,7	40,4	45,2	
	Df	9	21	33	45	
	<i>P-value</i>	0,051	0,063	0,175	0,465	
$(0,1,1)(1,1,0)^{12}$	Lag	12	24	36	48	Tidak <i>White Noise</i>
	Chi Square	14,7	36,2	47,2	48,7	
	Df	9	21	33	45	
	<i>P-value</i>	0,100	0,021	0,052	0,327	
$(0,1,1)(0,1,1)^{12}$	Lag	12	24	36	48	Tidak <i>White Noise</i>
	Chi Square	15,1	33,0	45,4	50,5	
	Df	9	21	33	45	
	<i>P-value</i>	0,087	0,046	0,074	0,265	
$(1,1,0)(1,1,0)^{12}$	Lag	12	24	36	48	Tidak <i>White Noise</i>
	Chi Square	19,2	34,3	44,1	44,9	
	Df	9	21	33	45	
	<i>P-value</i>	0,024	0,033	0,094	0,475	
$(0,1,0)(0,1,1)^{12}$	Lag	12	24	36	48	<i>White Noise</i>
	Chi Square	17,6	30,3	40,5	43,7	
	Df	10	22	34	46	
	<i>P-value</i>	0,063	0,112	0,205	0,570	

Berdasarkan Tabel 2 model sementara yang signifikan, hanya model *Seasonal-ARIMA* $(1,1,0)(0,1,1)^{12}$ dan *Seasonal-ARIMA* $(0,1,0)(0,1,1)^{12}$ yang memenuhi asumsi *white noise* karena nilai $p\text{-value}$ nya $> \alpha(0,05)$.

b. Uji Distribusi Normal

Setelah model memenuhi asumsi *white noise*, selanjutnya dilakukan uji asumsi distribusi normal dengan menggunakan statistik uji kolmogorov smirnov pada Tabel 3.

Tabel 3. Hasil Statistik Uji Kolmogorov-Smirnov


Model <i>Seasonal-ARIMA</i>	KS	<i>P-value</i>
$(1,1,0) (0,1,1)^{12}$	0,108	0,087
$(0,1,0)(0,1,1)^{12}$	0,097	0,150

Hipotesis :


H_0 = Residual berdistribusi normal

H_1 = Residual tidak berdistribusi normal

Kriteria keputusan tolak H_0 jika *p-value* < 0,05. Berdasarkan hasil uji komogorov smirnov diperoleh bahwa kedua model telah memenuhi distribusi normal, karena nilai *p-value* > 0,05. Adapun dalam bentuk grafik dapat dilihat pada Gambar 6.



(a). Distribusi Normal Model $(1,1,0)(0,1,1)^{12}$



(b). Distribusi Normal Model $(0,1,0)(0,1,1)^{12}$

Gambar 6. Grafik Distribusi Normal

Gambar 6 terlihat bahwa sebaran data dari kedua model telah mengikuti garis normal, sehingga data telah mengikuti syarat distribusi normal.

4.6. Pemilihan Model Terbaik

Kriteria pemilihan model terbaik diperoleh dengan menggunakan nilai MSE dan MAPE. Model yang memiliki nilai MSE dan MAPE yang terkecil merupakan model terbaik.

Tabel 4. Nilai MSE dan MAPE

Model <i>Seasonal-ARIMA</i>	MSE	MAPE
$(1,1,0)(0,1,1)^{12}$	0,2889	30,62%
$(0,1,0)(0,1,1)^{12}$	0,3052	53,38%

Berdasarkan Tabel 4, yang memiliki nilai MSE dan MAPE terkecil adalah model *Seasonal-ARIMA*(1,1,0) (0,1,1)¹² dengan MSE sebesar 0,2889 dan MAPE 30,62% sehingga model tersebutlah yang akan dijadikan model terbaik untuk melakukan peramalan.

4.7. Peramalan

Berdasarkan tahap estimasi dan uji ketepatan model, sehingga diperoleh model terbaik yaitu model *Seasonal-ARIMA*(1,1,0) (0,1,1)¹² untuk melakukan peramalan beberapa periode ke depan dengan nilai koefisien parameter yang diperoleh yaitu $\phi_1 = -0,2649$ dan $\theta_{12} = 0,8505$ yang dapat dijabarkan dengan persamaan :

$$X_t = X_{t-1} + X_{t-12} - X_{t-13} + (-0,2649)X_{t-1} - (-0,2649)X_{t-2} - (-0,2649)X_{t-13} + (-0,2649)X_{t-14} - (0,8505)a_{t-12} + a_t$$

Berdasarkan persamaan model, diperoleh hasil prediksi jumlah penderita DBD pada Tabel 5.

Tabel 5. Hasil Peramalan Penderita DBD

Periode	Peramalan	Periode	Peramalan
Jan 2020	16	Jan 2021	28
Feb 2020	24	Feb 2021	40
Mar 2020	8	Mar 2021	14
Apr 2020	9	Apr 2021	15
Mei 2020	18	Mei 2021	32
Jun 2020	21	Jun 2021	37
Jul 2020	23	Jul 2021	42
Agus 2020	14	Agus 2021	25
Sep 2020	11	Sep 2021	20
Okt 2020	8	Okt 2021	15
Nov 2020	8	Nov 2021	14
Des 2020	31	Des 2021	58

5. Kesimpulan

Peramalan menggunakan metode *Seasonal-ARIMA* menghasilkan model terbaik yaitu model (1,1,0) (0,1,1)¹² untuk meramalkan penderita DBD di Kabupaten Bulukumba periode 2021 (Tabel 5). Model ini memiliki nilai MAPE sebesar 30,62% yang berarti bahwa model cukup baik, layak, dan memadai untuk melakukan peramalan. Kasus DBD tertinggi terjadi pada bulan Desember 2021 sebanyak 58 kasus, sedangkan kasus terendah terjadi pada bulan Maret dan November 2021 sebanyak 14 kasus.

References

- Arsyad, Lincolin. 1995. *Peramalan Bisnis*. Jakarta: Graia Indonesia.
- Aswi, & Sukarna. (2006). *Analisis Deret Waktu*. Andira Publisher, Makassar.
- Dinkes Provinsi Sulawesi Selatan,. (2018). *Profil Dinas Kesehatan Prov.Sulawesi Selatan Tahun 2017*. <http://dinkes.sulseprov.go.id/page/info/15/profil-kesehatan>.
- Fauzi, A. (2015). *Peramalan Menggunakan Model ARIMA pada Harga Saham Telkom dan Lippo*.
- Hendikawati, P., (2015). *Peramalan Data Runtun Waktu: Metode dan Aplikasinya dengan Minitab & Eviews*. Semarang: FMIPA Universitas Negeri Semarang.
- Makridakis, S. W. (1999). *Metode dan Aplikasi Peramalan edisi ke-2*. Jakarta: Erlangga
- Mudrajad, Kuncoro (2007). *Metode Kuantitatif, Teori dan Aplikasi untuk Bisnis dan Ekonomi*. UPP STIM YKPN, Yogyakarta.
- Munawaroh, N. A. (2010). *Peramalan Jumlah Penumpang Pada PT. Angkasa Pura I (PERSERO) Kantor Cabang Bandar Udara Internasional Adisutjipto Yogyakarta dengan Metode Winter's*

Exponential Smoothing dan *Seasonal* ARIMA.

- Rochman, D. F. (2019). Estimasi Parameter Model *Seasonal Autoregressive Integrated Moving Average* dengan Metode Kalman Filter.
- Soejoeti, Zanzawi. (1987). Analisis Runtun Waktu. Jakarta: Karunika Jakarta.
- Wei, W.W.S. (2006). *Time Series Analysis, Univariate and Multivariate Methods*. 2nd edition. Pennsylvania: Person Education Inc.
- Wigati., Rais., & Utami, T. (2016). Pemodelan *Time Series* dengan Proses ARIMA untuk Prediksi Indeks Harga Konsumen (IHK) di Palu-Sulawesi Tengah. *JIMT*, 12, 149-159