

Triple-Seasonal ARIMA Untuk Peramalan Data Konsumsi Beban Listrik

Nur Azizah¹, Kartika Nugraheni¹ & Syalam Ali Wira Dinata^{1,*}

¹Jurus Matematika dan Teknologi Informasi, Institut Teknologi Kalimantan, Indonesia

*Corresponding author: syalam_ali_wira_dinata@lecturer.itk.ac.id

Abstract. In life, electricity is an important and primary energy sources to meet the needs of human life, in industry, economy and technology. Along with the increasing demand for electricity from time to time, the problem faced is the power distributed quantity so that the electricity distribution to customers must be optimized according to needs. The goal is to be able to take the appropriate action based on electricity needs and improve the service quality to customers. Therefore, an effective electric load forecasting method is needed in the future to optimized electricity demand. In this study, forecasting was carried out using Triple SARIMA method based on sample data from Denmark for 60 minutes in Mega Watt units obtained from open source secondary data. Forecasting is conducted by taking into account seasonal factors daily, weekly, and yearly. The purpose of this study is to determine the pattern of triple-seasonal electric load data on the effect of periodic time, evaluate the best triple-seasonal model to get the minimum error and subset, multiplicative and additive seasonal models. The result of this study was obtained from three temporary models then carried out the estimation and significance tests with Maximum likelihood and residual assumption test. Thus, $(1,1,1)(1,1,1)^{24}(1,1,1)^{168}(0,1,1)^{8736}$ model is the best model with RMSE value 30,02746373 and MAPE 0,02298758004. In addition, it was also found that the multiplicative Triple SARIMA model is the best model compared with the subset and additive models where the AIC and SBC values are 489545 and 489597, respectively.

Keywords: *Triple SARIMA, ACF, PACF.*

1 Pendahuluan

Konsumsi listrik merupakan kebutuhan pokok manusia yang terus mengalami peningkatan setiap tahunnya seiring dengan kemajuan yang telah dicapai dalam pembangunan di berbagai bidang, baik dalam bidang industri, ekonomi, teknologi maupun informasi. Permintaan dan jumlah konsumen yang meningkat berbanding lurus dengan permintaan konsumen pengguna listrik yang meningkat. Seiring dengan meningkatnya permintaan listrik dari waktu ke waktu, persoalan yang dihadapi adalah kuantitas tenaga yang disalurkan, sehingga penyaluran tenaga listrik ke konsumen harus dioptimalkan sesuai kebutuhan. Oleh karena itu, diperlukan suatu metode peramalan beban listrik pada masa mendatang di suatu kota maupun negara.

Secara luas, peramalan beban listrik dapat dikategorikan ke dalam tiga kategori utama yaitu peramalan jangka panjang, menengah, dan pendek. Peramalan jangka pendek berperan penting dalam *real time control*, dimana semakin pendek jangka peramalan yang dilakukan maka hasil akan lebih akurat. Saat melakukan *forecasting* sebaiknya menggunakan analisis *time series*. Metode analisis *time series* yang baik digunakan adalah ARIMA. Metode ARIMA memiliki akurasi yang sangat baik untuk peramalan jangka pendek, tetapi kurang baik untuk peramalan jangka panjang. Hal tersebut diperjelas pada masa kini, dimana metode peramalan ARIMA merupakan model yang baik untuk peramalan data *time series* dengan berbagai kondisi pola yang cocok diterapkan pada setiap observasi [1].

Pola data musiman merupakan fluktuasi data yang berulang secara berkala akibat faktor musiman, seperti cuaca, hari, minggu, bulan, maupun tahun [2]. Sehingga, saat terdapat pola musiman, dapat menggunakan metode *Seasonal ARIMA* (SARIMA) yang merupakan pengembangan dari metode ARIMA. Jika data mengalami pola musiman ganda berulang seperti hari dan tahun, maka dapat menggunakan metode *Double SARIMA* yang merupakan pengembangan dari metode SARIMA. Beberapa metode peramalan dengan tingkat keberhasilan yang bervariasi telah diimplementasikan untuk peramalan beban listrik termasuk pada penelitian Syalam, dkk [2-4]. Selanjutnya, terdapat juga pengembangan dari metode *Double SARIMA* yaitu *Triple SARIMA* yang berkaitan dengan data seasonal berulang seperti hari, bulan, dan tahun.

Penelitian metode *Double SARIMA* dilakukan Norizan [5] tentang peramalan beban listrik menggunakan metode *Double SARIMA*. Khusus untuk model SARIMA, kebanyakan peneliti sebelumnya biasanya langsung menggunakan model *multiplicative* tanpa menguji apakah parameter *multiplicative*-nya signifikan. Artinya, model *multiplicative* SARIMA diasumsikan terdapat parameter yang signifikan sebagai hasil perkalian antara parameter non-musiman dan musiman [6]. Salah satu penelitian terdahulu yang membahas hal tersebut adalah Suhartono [6] mengenai peramalan kedatangan turis menggunakan model *subset*, *multiplicative* dan *additive* SARIMA. Berdasarkan hal tersebut akan dilakukan peramalan mengenai konsumsi beban listrik menggunakan metode *Triple SARIMA* dengan memperhatikan periode harian, mingguan dan tahunan. Selain itu, penelitian ini juga mencari model *subset*, *multiplicative* dan *additive* dari model terbaik.

2 Peramalan (*Forecasting*)

Peramalan adalah ilmu untuk memperkirakan kejadian di masa depan dengan menggunakan teknik tertentu. Peramalan pada umumnya dilakukan untuk meminimalisir ketidakpastian pada suatu keadaan di masa depan [7]. Peramalan dibedakan menjadi peramalan subjektif dan objektif. Berdasarkan jangka waktu peramalan dibagi menjadi peramalan jangka panjang, menengah dan pendek. Peramalan berdasarkan sifat ramalan terbagi menjadi peramalan kualitatif dan kuantitatif.

3 Model *Triple Seasonal Autoregressive Integrated Moving Average (Triple-SARIMA)*

Triple-SARIMA merupakan pengembangan dari model SARIMA yang terdapat tiga pola musiman di dalamnya, yaitu musiman harian, musiman mingguan dan musiman tahunan. Model ARIMA musiman *triple* multiplikasi umum ini yaitu sebagai berikut.

$$\begin{aligned}\phi_p(B)\Phi_{P_1}(B^{S_1})\Pi_{P_2}(B^{S_2})\Omega_{P_3}(B^{S_3})(1-B)^d(1-B^{S_1})^{D_1}(1-B^{S_2})^{D_2} \\ (1-B^{S_3})^{D_3}\dot{Z}_t = \theta_q(B)\Theta_{Q_1}(B^{S_1})\Psi_{Q_2}(B^{S_2})\Gamma_{Q_3}(B^{S_3})a_t,\end{aligned}\quad (5)$$

Dimana \dot{Z}_t adalah permintaan beban yang diubah secara tepat dalam periode t , $\phi_p(B)$ dan $\theta_q(B)$ adalah polinomial *autoregressive* dan *moving average* reguler p dan q , $\Phi_{P_1}(B^{S_1})$, $\Pi_{P_2}(B^{S_2})$, $\Omega_{P_3}(B^{S_3})$, $\Theta_{Q_1}(B^{S_1})$, $\Psi_{Q_2}(B^{S_2})$, $\Gamma_{Q_3}(B^{S_3})$ adalah polinomial *autoregressive* dan *moving average* P_1, P_2, P_3, Q_1, Q_2 dan Q_3 , S_1, S_2 dan S_3 adalah periode musiman dan d, D_1, D_2 dan D_3 adalah perintah integrasi.

Dengan:

$$\begin{array}{ll}\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p & \Phi_P(B^S) = 1 - \Phi_1 B^S - \dots - \Phi_p B^{PS} \\ \Pi_P(B^S) = 1 - \Pi_1 B^S - \dots - \Pi_p B^{PS} & \Omega_P(B^S) = 1 - \Omega_1 B^S - \dots - \Omega_p B^{PS} \\ \theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q & \Theta_Q(B^S) = 1 - \Theta_1 B^S - \dots - \Theta_q B^{QS} \\ \Psi_Q(B^S) = 1 - \Psi_1 B^S - \dots - \Psi_q B^{QS} & \Gamma_Q(B^S) = 1 - \Gamma_1 B^S - \dots - \Gamma_q B^{QS}\end{array}$$

Dimana S_1, S_2 , dan S_3 merupakan musiman harian, mingguan dan tahunan.

4 Identifikasi Model

Identifikasi data dilakukan dengan melihat apakah data *time series* sudah stasioner atau tidak dalam *mean* maupun varian. Setelah data stasioner, penentuan model sementara dilihat melalui berapa kali *differencing* untuk memprediksi model d dan D pada SARIMA(p, d, q)(P, D, Q) S . Pada bagian model p, q, P , dan Q dapat dilihat pada pola *Autocorrelation function* (ACF) dan pola *Partial Autocorrelation function* (PACF).

5 Estimasi Parameter Model

Dalam analisis *partial*, estimasi parameter bertujuan untuk pembentukan model yang baik. Estimasi ini berguna untuk mendapatkan besaran koefisien pada model. Metode yang dapat digunakan untuk estimasi parameter bermacam-macam, yaitu metode *moment*, *ordinary least square* (OLS), *maximum likelihood estimation* (MLE), atau *conditional least square* (CLS). Metode yang digunakan dalam penelitian ini adalah metode *maximum likelihood estimation* (MLE).

6 Cek Diagnosa

6.1 Uji Signifikansi Parameter

Pengujian signifikansi parameter digunakan untuk menguji apakah suatu parameter model layak masuk dalam model atau tidak. Secara umum, misalkan θ adalah suatu parameter pada model dan $\hat{\theta}$ adalah nilai taksiran parameter tersebut, serta $SE(\hat{\theta})$ adalah standard error dari nilai taksiran, maka uji signifikan dapat dilakukan dengan tahapan sebagai berikut:

Hipotesis : H_0 = Parameter model tidak signifikan

H_1 = Parameter model signifikan

Statistik Uji t : $t_{hitung} = \frac{\hat{\theta}}{SE(\hat{\theta})}$.

Kriteria Penolakan: Tolak H_0 jika $|t_{hitung}| > \frac{t_\alpha}{2}$; $df = n - n_p$, n_p merupakan banyaknya parameter atau dengan menggunakan nilai $p - value$, yakni tolak H_0 jika nilai $-p < \alpha$.

6.2 Uji Asumsi Residual

6.2.1 Uji Normalitas

Pada Penelitian ini menggunakan uji *Kolmogorov-Smirnov* yang merupakan uji normalitas yang umum digunakan karena dinilai lebih sederhana dan tidak menimbulkan perbedaan persepsi. Uji *Kolmogorov-smirnov* dilakukan dengan tingkat signifikan 0,05. Pengambilan keputusan uji *Kolmogorov-smirnov* sebagai berikut

Hipotesis :

H_0 : $(x) = F_0(x)$ Residual berdistribusi normal (untuk semua x)

H_1 : $(x) \neq F_0(x)$ Residual tidak berdistribusi normal (untuk beberapa x)

Statistik Uji : $D_{hitung} = \sup_x |(x) - F_0(x)|$.

Kriteria Penolakan : Tolak H_0 jika $D_{hitung} > D_{\alpha,n}$ atau $p - value < \alpha$ dengan menggunakan $\alpha = 0.05$.

6.2.2 Uji White Noise

Suatu proses $\{a_t\}$ dinamakan *white noise process* (proses yang bebas dan identik) apabila data terdiri dari variabel acak yang berurutan tidak saling berkorelasi dan mengikuti distribusi tertentu. Rata-rata $E(a_t) = \mu_a$ dari proses ini diasumsikan bernilai nol dan mempunyai variansi yang konstan yaitu $Var(a_t) = \sigma_a^2$ dan nilai kovariansi untuk proses ini.

$$\gamma_k = Cov(a_t, a_{t+k}) = 0 \text{ untuk } k \neq 0.$$

Pada proses *white noise* digunakan pengujian *Ljung-Box* untuk melihat apakah *residual* dalam proses *white noise* sudah memenuhi atau belum, dengan persamaan:

$$Q = n(n+2) \sum_{k=1}^K \frac{\rho_k^2}{n-k} \quad (9)$$

Dengan k adalah nilai *lag* ke- k , K adalah maksimum *lag*, ρ_k adalah nilai fungsi *autokorelasi lag*- k .

Hipotesis : H_0 : *residual* memenuhi *white noise*

H_1 : *residual* tidak memenuhi *white noise*

Kriteria Penolakan : Tolak H_0 jika $Q > X_{(\frac{\alpha}{df}:K-k)}^2$ (K berarti pada *lag* K dan k adalah jumlah parameter) atau nilai $p - value < \alpha$ (nilai $\alpha = 0,05$).

Dengan demikian, suatu deret waktu disebut *white noise* jika rata-rata dan variansinya konstan dan saling bebas [8].

7 Model *Subset, Multiplicative* dan *Additive SARIMA*

7.1 *Subset SARIMA*

Bentuk umum model ARIMA (0,0,[1,12,13]), dimana dikenal sebagai *subset SARIMA*, yang dituliskan dengan

$$Z_t - \mu = \alpha_t - \theta_1 \alpha_{t-1} - \theta_{12} \alpha_{t-12} - \theta_{13} \alpha_{t-13} \quad (10)$$

dimana θ_1, θ_{12} dan θ_{13} menunjukkan parameter MA

7.2 *Multiplicative SARIMA*

Bentuk umum model ARIMA (0,0,1)(0,0,1)¹², dimana dikenal sebagai *multiplicative SARIMA*, yang dituliskan dengan

$$Z_t - \mu = \alpha_t - \theta_1 \alpha_{t-1} - \theta_{12} \alpha_{t-12} - \theta_1 \theta_{13} \alpha_{t-13} \quad (11)$$

dimana masing-masing θ_1 dan θ_{12} menunjukkan parameter ordo MA *non-seasonal* dan *seasonal*. Model ini sama dengan *subset* model SARIMA pada Persamaan 10 saat $\theta_{13} = -\theta_1 \theta_{12}$.

7.3 *Additive SARIMA*

Bentuk umum model ARIMA (0,0,[1,12]), dimana dikenal sebagai *additive SARIMA*, yang dituliskan dengan

$$Z_t - \mu = \alpha_t - \theta_1 \alpha_{t-1} - \theta_{12} \alpha_{t-12} \quad (12)$$

dimana masing-masing θ_1 dan θ_{12} menunjukkan parameter ordo MA *non-seasonal* dan *seasonal*. Model ini sama dengan model SARIMA pada Persamaan 10 saat $\theta_{13} = 0$.

8 Kriteria Model Terbaik

8.1 MAPE (*Mean Absolute Percentage Error*)

MAPE merupakan rata-rata diferensiasi absolut antara nilai peramalan dan aktual, yang dinyatakan sebagai persentase nilai aktual.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{z_t - \hat{z}_t}{z_t} \right| \times 100 \quad (13)$$

Dengan Z_t adalah nilai pengamatan aktual pada periode t dan \hat{Z}_t adalah nilai prediksi waktu ke- t .

8.2 AIC (*Akaike's Information Criterion*) dan SBC (*Schwartz's Bayesian Criterion*)

AIC merupakan kriteria pemilihan model terbaik menggunakan data *in-sample* yang melibatkan jumlah parameter dalam model. AIC dengan nilai terkecil merupakan model terbaik. Persamaan AIC sebagai berikut:

$$AIC = n \ln \left(\frac{SSE}{n} \right) + 2f + n + n \ln (2\pi) \quad (15)$$

SBC merupakan kriteria pemilihan model terbaik menggunakan data *in-sample* berdasarkan nilai terkecil. Persamaan SBC sebagai berikut [8]:

$$SBC = n \ln \left(\frac{SSE}{n} \right) + f \ln n + n + n \ln (2\pi) \quad (16)$$

Dengan SSE adalah *Sum Square Error*, n adalah jumlah data dan f adalah banyaknya parameter yang digunakan dalam model.

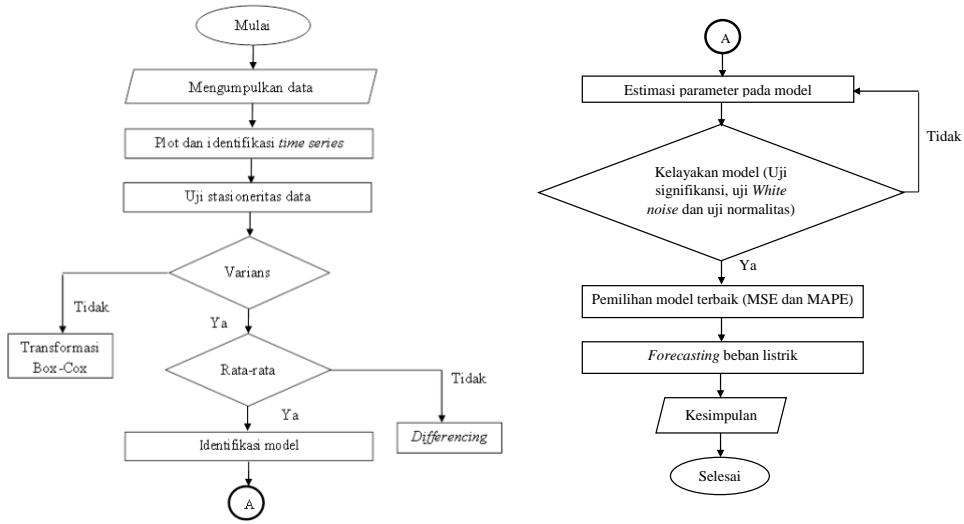
9 Metodologi Penelitian

9.1 Data

Data yang digunakan merupakan data sekunder yang diperoleh dari *open source* (https://data.open-power-system-data.org/time_series/2020-10-06). Data ini berupa data konsumsi besar beban listrik dengan jumlah data 50.398, dengan satuan Mega Watt (MW).

9.2 Diagram Alur

Berikut adalah tampilan diagram alur penelitian.



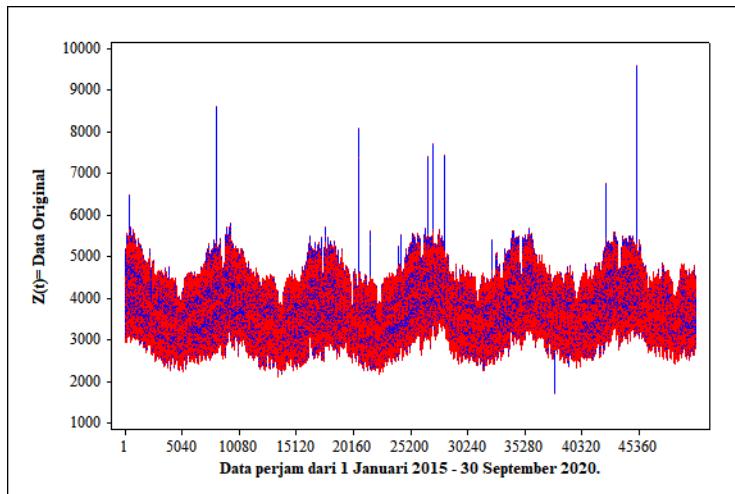
Gambar 1 Diagram Alur Penelitian

10 Hasil dan Pembahasan

10.1 Data Beban Listrik

Data yang digunakan dibagi menjadi dua bagian yaitu data *in sample* dan *out sample*, dengan perbandingan 80% (40.318 data) dan 20% (10.080 data). Data *in sample* digunakan untuk membentuk dan menguji model sedangkan data *out sample* digunakan untuk validasi hasil peramalan model terbaik.

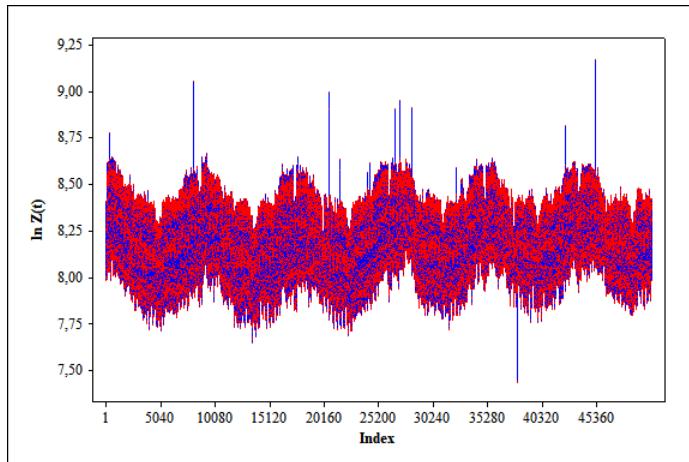
Gambar 2 berikut merupakan *plot time series* dari data yang digunakan.



Gambar 2 Plot Time Series Data Aktual

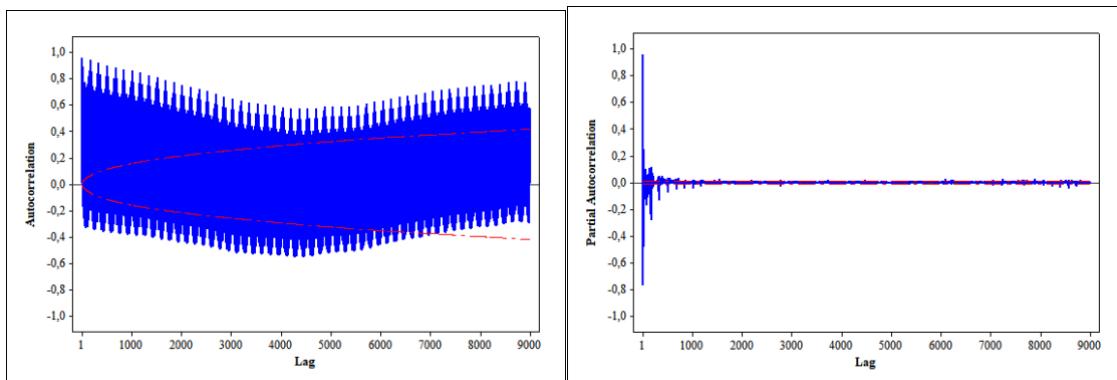
10.2 Stasioner

Diperoleh data tidak stasioner terhadap *mean* dan varian karena data memiliki pola data yang cenderung naik turun secara lambat atau tidak konstan. Kemudian, dilakukan stasioneritas data terhadap varian menggunakan *plot Box-Cox* untuk melihat nilai lambda. Adapun nilai lambda diperoleh sebesar 3,9 yang berarti data belum stasioner terhadap varian, karena data dapat dikatakan varian jika lambda bernilai 1. Maka, dilakukan transformasi Box-Cox kembali dan diperoleh lambda bernilai 1 yang berarti data telah stasioner terhadap varian. Berikut merupakan *plot* data yang telah di transformasi.



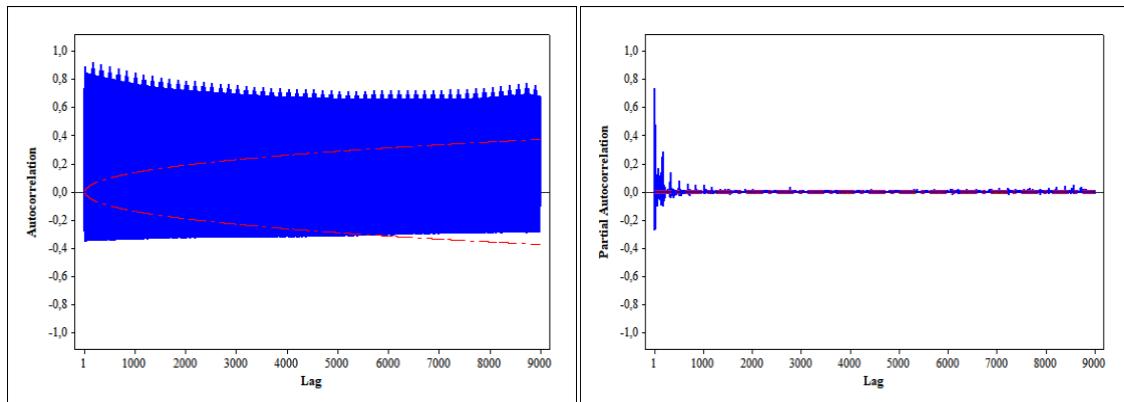
Gambar 3 Plot Time Series Data yang Telah Ditransformasi

Data hasil transformasi perlu dilakukan uji stasioneritas terhadap *mean* dengan menggunakan plot ACF dan PACF.

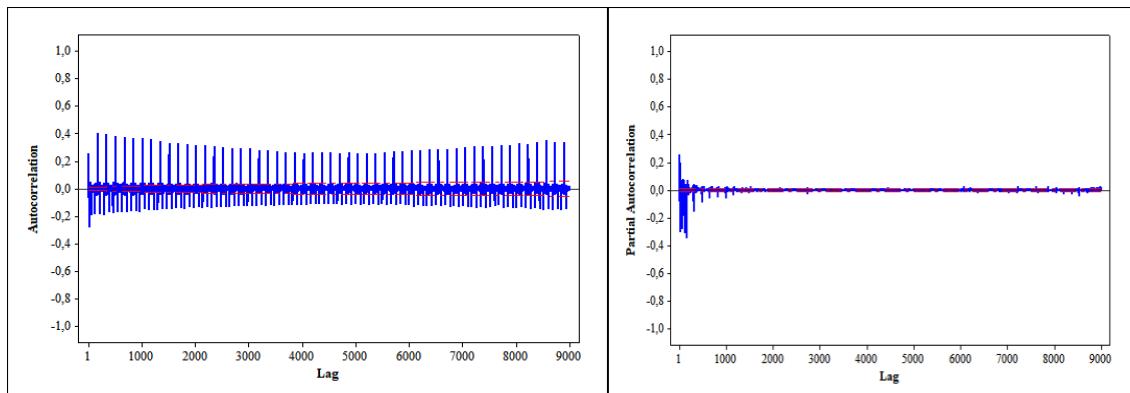


Gambar 4 ACF dan PACF load

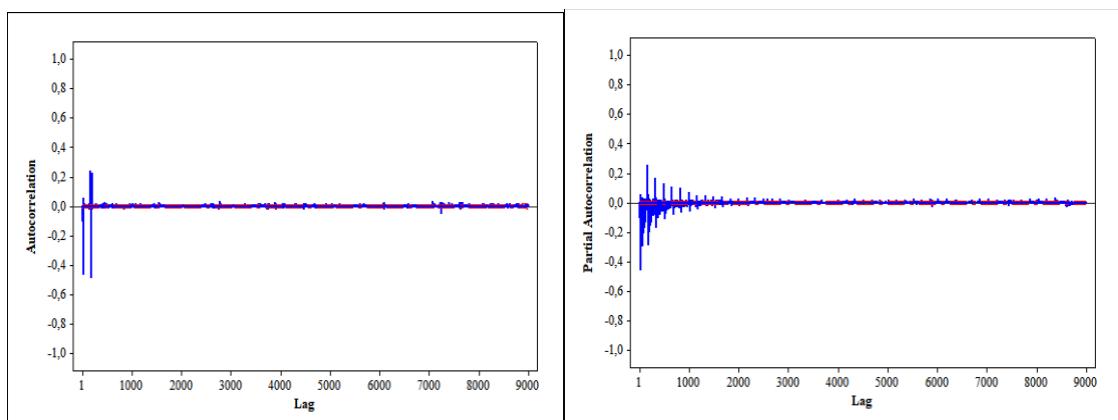
Terlihat bahwa pola turun sangat lambat sehingga terindikasi bahwa data tidak stasioner terhadap *mean*, maka dilakukan *differencing* pada *lag* 1, 24, 168 dan 8736.



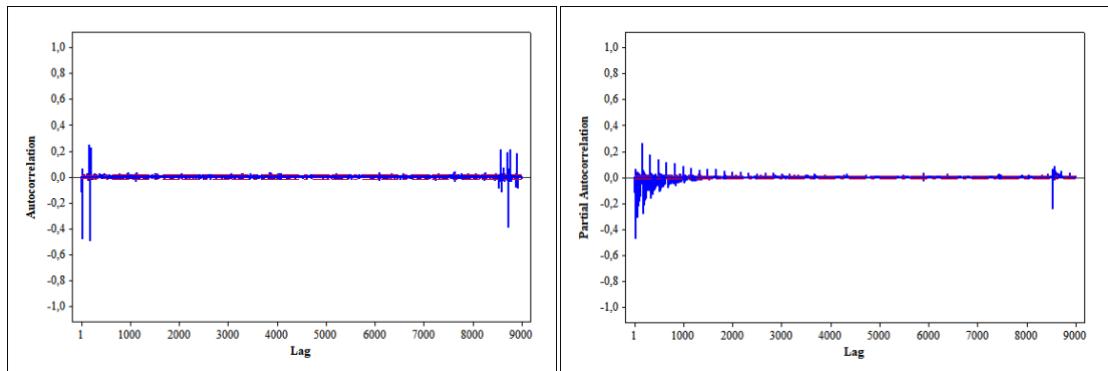
Gambar 5 ACF dan PACF Setelah $d = 1$



Gambar 6 ACF dan PACF Setelah $d = D_1 = 1$ dan $S_1 = 24$



Gambar 7 ACF dan PACF Setelah $d = D_1 = D_2 = 1$ $S_1 = 24$ dan $S_2 = 168$



Gambar 8 ACF dan PACF Setelah $d = D_1 = D_2 = D_3 = 1$, $S_1 = 24$, $S_2 = 168$ dan $S_3 = 8736$

Berdasarkan *plot* di atas maka diperoleh asumsi model sebagai berikut.

Tabel 1 Asumsi Model *Triple SARIMA*

Model	Model Sementara
Model 1	$(0,1,1)(1,0,1)^{24}(1,0,1)^{168}(0,0,1)^{8736}$
Model 2	$(0,1,1)(1,0,1)^{24}(1,0,1)^{168}(0,0,1)^{8736}$
Model 3	$(0,1,1)(1,0,1)^{24}(1,0,1)^{168}(0,0,1)^{8736}$

10.3 Estimasi dan Uji Signifikansi Model

Pada penelitian ini menggunakan *Maximum Likelihood*, maka dilakukan hipotesis sebagai berikut.

H_0 : Parameter model tidak signifikan

H_1 : Parameter model signifikan

Tingkat signifikansi (α): 0,05

Daerah kritis :

Jika $|t_{hitung}| > t_{\alpha/2}$; $df = n - n_p$, n_p = jumlah parameter atau menggunakan **p-value** yaitu H_0 ditolak jika nilai **p-value** $< \alpha$, maka diperoleh tabel berikut.

Tabel 2 Nilai Estimasi dan Uji Signifikansi Sementara

Model <i>Triple SARIMA</i>	Parameter	Nilai Parameter	t-value	Keterangan
$(0,1,1)(1,1,1)^{24}$	Φ	-0,49138	-113,2508	Signifikan
$(1,1,1)^{168}(0,1,1)^{8736}$	Π	-0,50528	-23508,15	Signifikan
	θ	-0,08853	-3583,245	Signifikan
	Θ	0,93912	548,651	Signifikan

Model Triple SARIMA	Parameter	Nilai Parameter	t-value	Keterangan
$(1,1,0)(1,1,1)^{24}$ $(1,1,1)^{168}(0,1,1)^{8736}$	Ψ	0,99999	44804,23	Signifikan
	Γ	0,81366	248,7281	Signifikan
	ϕ	0,03217	6,462709	Signifikan
	Φ	-0,49177	-22756,7	Signifikan
	Π	-0,50535	-23512,5	Signifikan
	Θ	0,93089	511,521	Signifikan
	Ψ	0,99997	25867,3	Signifikan
	Γ	0,80722	243,034	Signifikan
	ϕ	0,03217	6,462709	Signifikan
$(1,1,1)(1,1,1)^{24}$ $(1,1,1)^{168}(0,1,1)^{8736}$	Φ	-0,4917	-22756,7	Signifikan
	Π	-0,5053	-23512,5	Signifikan
	θ	-0,0885	-17,8458	Signifikan
	Θ	0,9391	548,651	Signifikan
	Ψ	0,9999	44804,2	Signifikan
	Γ	0,8136	248,728	Signifikan

10.4 Uji Asumsi Residual

Dilakukan uji asumsi residual yaitu uji *white noise* dan uji distribusi normal. Maka dilakukan hipotesis sebagai berikut.

$$H_0 : \text{Residual memenuhi white noise}$$

$$H_1 : \text{Residual tidak memenuhi white noise}$$

Tingkat signifikansi (α): 0,05

Daerah kritis :

Jika $Q > X^2 \left(\frac{\alpha}{df}; K - k \right)$, dengan $K = \text{lag } K$ dan $k = \text{jumlah parameter}$, maka H_0 ditolak. Berdasarkan hasil komputasi diperoleh nilai uji asumsi residual berikut.

Tabel 3 Nilai Uji Asumsi Residual White Noise Triple SARIMA

Model Triple SARIMA	Lag	Q	X²	Keterangan
$(0,1,1)(1,1,1)^{24}$ $(1,1,1)^{168}(0,1,1)^{8736}$	12	30847,35	12,5915	Tidak White noise
	24	1013108,64	28,86929	Tidak White noise
	36	1105148,9	43,77297	Tidak White noise
	48	1142060,39	58,12403	Tidak White noise
$(1,1,0)(1,1,1)^{24}$ $(1,1,1)^{168}(0,1,1)^{8736}$	12	52476,31	12,59158	Tidak White noise
	24	1668399,072	28,86929	Tidak White noise
	36	1807177,695	43,77297	Tidak White noise
	48	1861261,666	58,12403	Tidak White noise

Model Triple SARIMA	Lag	Q	X²	Keterangan
(1,1,1)(1,1,1) ²⁴	12	10061,50	11,07049	Tidak White noise
(1,1,1) ¹⁶⁸ (0,1,1) ⁸⁷³⁶	24	328007,02	27,58711	Tidak White noise
	36	336115,52	42,5569	Tidak White noise
	48	340804,68	56,94238	Tidak White noise

Selanjutnya dilakukan uji distribusi dengan hipotesis sebagai berikut.

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

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

Tingkat signifikansi (α): 0,05

Daerah kritis:

Jika $D_{hitung} > D_{\alpha, n}$ maka tolak H_0 . Sehingga diperoleh g berikut:

Tabel 4 Nilai Uji Distribusi Normal Triple SARIMA

Model Triple SARIMA	Sup S - F₀(x) 	D_{α,n}	Keterangan
(0,1,1)(1,1,1) ²⁴ (1,1,1) ¹⁶⁸ (0,1,1) ⁸⁷³⁶	0,9966775	0,0067233	Tidak Berdistribusi Normal
(1,1,0)(1,1,1) ²⁴ (1,1,1) ¹⁶⁸ (0,1,1) ⁸⁷³⁶	0,9955985	0,0067233	Tidak Berdistribusi Normal
(1,1,1)(1,1,1) ²⁴ (1,1,1) ¹⁶⁸ (0,1,1) ⁸⁷³⁶	0,9955985	0,0067233	Tidak Berdistribusi Normal

10.5 Pemilihan Model terbaik

Model Triple Seasonal ARIMA terbaik yaitu $(1, 1, 1)(1, 1, 1)^{24}(1, 1, 1)^{168}(0, 1, 1)^{8736}$
Dari model tersebut diperoleh RMSE sebagai berikut:

$$\sqrt{\frac{\sum_{t=1}^n e_t^2}{n}} = 30,02746373 \quad (17)$$

Selain itu, diperoleh MAPE dari 48530 sampai 48574 sebagai berikut:

$$\sum_{t=48530}^{48574} \left| \frac{z_t - \hat{z}_t}{z_t} \right| \times 100\% = 0,02298758004 \quad (18)$$

Tabel 5 Nilai RMSE dan MAPE Model *Triple SARIMA*

Model	RMSE	MAPE
$(0,1,1)(1,1,1)^{24}(1,1,1)^{168}(0,1,1)^{8736}$	332541,1	6264,81%
$(1,1,0)(1,1,1)^{24}(1,1,1)^{168}(0,1,1)^{8736}$	1915707,073	40812,05%
$(1,1,1)(1,1,1)^{24}(1,1,1)^{168}(0,1,1)^{8736}$	30,02746373	2,298758%

10.6 Model *Subset, Multiplicative* dan *Additive*

Model $(1,1,1)(1,1,1)^{24}(1,1,1)^{168}(0,1,1)^{8736}$

$$\begin{aligned} \phi_p(B)\Phi_{P_1}(B^{S_1})\Pi_{P_2}(B^{S_1})(1-B)^d(1-B)^{D_1}(1-B)^{D_2}(1-B)^{D_3}Z_t \\ = \theta_q(B)\Theta_{Q_1}(B^{S_1})\Psi_{Q_2}(B^{S_2})\Gamma_{Q_3}(B^{S_3})e_t \end{aligned} \quad (19)$$

Sehingga, dibentuk model sebagai berikut:

$$\begin{aligned} (1 - \phi_1 B)(1 - \Phi_{24} B^{24})(1 - \Pi_{168} B^{168})(1 - B)(1 - B)^{24} \\ (1 - B)^{168}(1 - B)^{8736}Z_t = (1 - \theta_1 B)(1 - \Theta_{24} B^{24})(1 - \\ \Psi_{168} B^{168})(1 - \Gamma_{8736} B^{8736})e_t \end{aligned} \quad (20)$$

Penjelasan teoritis tentang ACF untuk ketiga model difokuskan pada orde non-seasonal dan seasonal MA, yaitu model $(0,0,1)(0,0,1)^{24}(0,0,1)^{168}(0,0,1)^{8736}$.

ARIMA(0,0,[1,24,168,8736]), ARIMA(0,0,1)(0,0,1)^{24}(0,0,1)^{168}(0,0,1)^{8736}, dan ARIMA(0,0,[1,24,168,8736])

masing-masing untuk model *subset, multiplicative* dan *additive*.

10.6.1 Model *Subset SARIMA*

Bentuk umum orde MA dari model *subset Triple SARIMA* ini dituliskan sebagai berikut:

$$\begin{aligned} \dot{Z}_t = Z_t - \theta_1 Z_{t-1} - \Theta_{24} Z_{t-24} - \theta_1 \Theta_{24} Z_{t-25} - \Psi_{168} Z_{t-168} \\ - \theta_1 \Psi_{168} Z_{t-169} - \Gamma_{8736} Z_{t-8736} - \theta_1 \Gamma_{8736} Z_{t-8737} \end{aligned} \quad (21)$$

Kemudian, substitusi nilai parameter MA $\theta = -0,08853, \Theta = 0,93912, \Psi = 0,99999$ dan $\Gamma = 0,81366$. Sehingga, diperoleh sebagai berikut:

$$\begin{aligned} \dot{Z}_t = Z_t + 0,08853 Z_{t-1} + 0,93912 Z_{t-24} + 0,08314 Z_{t-25} - \\ 0,99999 Z_{t-168} + 0,08852 Z_{t-169} - 0,81366 Z_{t-8736} + \\ 0,07203 Z_{t-8737} \end{aligned} \quad (22)$$

10.6.2 Model *Multiplicative SARIMA*

Bentuk umum orde MA dari model *multiplicative Triple SARIMA* ini dituliskan sebagai berikut:

$$\begin{aligned}
\dot{Z}_t = & Z_t - \theta_1 Z_{t-1} - \Theta_{24} Z_{t-24} + \theta_1 \Theta_{24} Z_{t-25} - \Psi_{168} Z_{t-168} + \\
& \theta_1 \Psi_{168} Z_{t-169} - \Theta_{24} \Psi_{168} Z_{t-192} - \theta_1 \Theta_{24} \Psi_{168} Z_{t-193} - \Gamma_{8736} Z_{t-8736} + \\
& \theta_1 \Gamma_{8736} Z_{t-8737} + \Theta_{24} \Gamma_{8736} Z_{t-8760} - \theta_1 \Theta_{24} \Gamma_{8736} Z_{t-8761} + \\
& \Psi_{168} \Gamma_{8736} Z_{t-8904} - \theta_1 \Psi_{168} \Gamma_{8736} Z_{t-8905} - \Theta_{24} \Psi_{168} \Gamma_{8736} Z_{t-8928} + \\
& \theta_1 \Theta_{24} \Psi_{168} \Gamma_{8736} Z_{t-8929}
\end{aligned} \tag{23}$$

Kemudian, substitusi nilai parameter MA $\theta = -0,08853$, $\Theta = 0,93912$, $\Psi = 0,99999$ dan $\Gamma = 0,81366$. Sehingga, diperoleh sebagai berikut:

$$\begin{aligned}
\dot{Z}_t = & Z_t + 0,08853 Z_{t-1} + 0,08853 Z_{t-24} - 0,08314 Z_{t-25} - \\
& 0,99999 Z_{t-168} - 0,08852 Z_{t-169} - 0,93911 Z_{t-192} + 0,08313 Z_{t-193} - \\
& 0,81366 Z_{t-8736} - 0,07203 Z_{t-8737} + 0,76412 Z_{t-8760} + 0,0676 Z_{t-8761} + \\
& 0,81365 Z_{t-8904} + 0,07203 Z_{t-8905} - 0,76411 Z_{t-8928} - 0,0676 Z_{t-8929}
\end{aligned} \tag{24}$$

10.6.3 Model *Additive* SARIMA

Bentuk umum orde MA dari model *additive Triple* SARIMA ini dituliskan sebagai berikut:

$$\dot{Z}_t = Z_t - \theta_1 Z_{t-1} - \Theta_{24} Z_{t-24} - \Psi_{168} Z_{t-168} - \Gamma_{8736} Z_{t-8736} \tag{25}$$

Kemudian, substitusi nilai parameter MA $\theta = -0,08853$, $\Theta = 0,93912$, $\Psi = 0,99999$ dan $\Gamma = 0,81366$. Sehingga, diperoleh sebagai berikut:

$$\begin{aligned}
\dot{Z}_t = & Z_t + 0,08853 Z_{t-1} - 0,93912 Z_{t-24} - 0,99999 Z_{t-168} - \\
& 0,81366 Z_{t-8736}
\end{aligned} \tag{26}$$

Model ini sama dengan model *subset Triple* SARIMA saat $\theta_1 \Theta_{24} = \theta_1 \Psi_{168} = \theta_1 \Gamma_{8736} = 0$. Sehingga, dapat disimpulkan bahwa model *additive* juga merupakan bagian dari model *subset* Persamaan 21. Selain itu, model *additive* ini juga dapat dilihat sebagai model *subset* dengan orde bawah. Kemudian diperoleh nilai AIC dan SBC sebagai berikut.

Tabel 6 Nilai AIC dan SBC

ARIMA Estimation Optimization Summary							
Estimation Method						Maximum Likelihood	
Parameters Estimated						7	
Termination Criteria						Maximum Relative Change in Estimates	
Iteration Stopping Value						0.001	
Criteria Value						1.563668	
Maximum Absolute Value of Gradient						54725384	
R-Square Change from Last Iteration						0.072807	
Objective Function						Log Gaussian Likelihood	
Objective Function Value						-244793	
Marquardt's Lambda Coefficient						1E-6	
Numerical Derivative Perturbation Delta						0.001	
Iterations						8	
Warning Message						Estimates may not have converged.	
Maximum Likelihood Estimation							
Parameter	Estimate	Standard Error	t Value	Pr > t	Approx	Lag	
MA1,1	-0.28176	0.0065612	-42.94	<.0001		1	
MA1,2	-0.07442	0.0046708	-15.93	<.0001		24	
MA1,3	-0.06709	0.0045155	-14.86	<.0001		25	
MA2,1	0.45474	0.0060911	74.66	<.0001		1	
MA3,1	0.94704	0.0018782	504.21	<.0001		24	
MA4,1	0.99999	1.87591	0.53	0.5940		168	
MA5,1	0.73739	0.0095903	76.89	<.0001		8736	
Variance Estimate						6502.232	
Std Error Estimate						80.63642	
AIC						489600.7	
SBC						489661.1	
Number of Residuals						41469	
The SAS System				16:15 Friday, April 26, 2002			
15							
The ARIMA Procedure							
Correlations of Parameter Estimates							
Parameter	MA1,1	MA1,2	MA1,3	MA2,1	MA3,1	MA4,1	MA5,1
MA1,1	1.000	-0.006	0.140	-0.756	-0.017	0.013	0.025
MA1,2	-0.006	1.000	0.295	-0.026	-0.303	0.029	-0.009
MA1,3	0.140	0.295	1.000	-0.115	-0.108	0.011	-0.008
MA2,1	-0.756	-0.026	-0.115	1.000	0.012	-0.008	-0.005
MA3,1	-0.017	-0.303	-0.108	0.012	1.000	-0.056	-0.022
MA4,1	0.013	0.029	0.011	-0.008	-0.056	1.000	0.035
MA5,1	0.025	-0.009	-0.008	-0.005	-0.022	0.035	1.000

Hasil evaluasi menunjukkan bahwa model *multiplicative* merupakan model yang lebih baik dibandingkan dengan model *subset* dan *additive* karena menghasilkan AIC dan SBC yang lebih rendah.

11 Kesimpulan dan Saran

11.1 Kesimpulan

Berdasarkan hasil dan pembahasan mengenai prediksi beban listrik di Negara Denmark, diperoleh kesimpulan data beban listrik yang digunakan memiliki pola *seasonal* dalam periode harian ($S_1 = 24$ jam), mingguan ($S_2 = 168$ jam) dan tahunan ($S_3 = 8736$ jam). Pada evaluasi model sementara, diperoleh model *Triple SARIMA* terbaik yaitu model $(1,1,1)(1,1,1)^{24}(1,1,1)^{168}(0,1,1)^{8736}$, dimana memiliki nilai RMSE dan MAPE yang paling rendah dan bahwa model *multiplicative Triple SARIMA* pada data ini merupakan model terbaik, karena memiliki nilai AIC dan SBC terkecil.

11.2 Saran

Berdasarkan hasil penelitian, penulis memberi saran bahwa diharapkan pada penelitian selanjutnya dapat menggunakan metode lain seperti metode SARFIMA yang merupakan pengembangan dari metode ARIMA, dimana metode SARFIMA dapat menjelaskan data jangka pendek maupun panjang dengan *differencing* (d) bernilai riil, serta dapat menggunakan data beban listrik yang berada di Indonesia.

12 Daftar Pustaka

- [1] Yuanti, A.D., 2016, *Perbandingan Model Partial Seasonal ARIMA (SARIMA) dan Seasonal ARFIMA (SARFIMA) pada Data Beban Konsumsi Listrik Jangka Pendek di Jawa Timur*, Universitas Airlangga.
- [2] Giovani, M., I Anggriani, SAWD Simatupang, 2012, *COMPARISON IN PREDICTING THE SHORT-TERM USING THE SARIMA, DSARIMA AND TSARIMA METHODS*, BAREKENG: Jurnal Ilmu Matematika dan Terapan 16 (4), 1487-1496.
- [3] Dinata, SAW., M Azka, M Faisal, Suhartono, R Yendra, MDH Gamal 2020, *Short-Term load forecasting double seasonal ARIMA methods: An evaluation based on Mahakam-East Kalimantan data*, AIP: AIP Conference Proceedings 2268 (1), 020004.
- [4] Dinata, SAW., M Azka, P Hasanah, S Suhartono, MDH Gamal., 2021, *Comparison of Short-Term Load Forecasting Based on Kalimantan*, Indonesian Journal of Statistics and Its Applications 5 (2), 243-259.
- [5] Prahesti, D.D., E. Puspita & F. Agustina, 2016, *Peramalan Curah Hujan Kota Bandung Menggunakan Model Fungsi Transfer Multivariat Pada Deret Berkala Musiman*, Eureka Matika, 4(1), 104-118.
- [6] Heizer, J. & Render, B., 2014, *Operations Management: Sustainability and Supply Chain Management Eleventh Edition*, New Jersey: Pearson Eddison Wesley.
- [7] Subagyo, P., 2000, *Forecasting Konsep dan Aplikasi Edisi Kedua*, Yogyakarta: BPFE.

- [8] Aswi & Sukarna, 2006, *Analisis Deret Waktu: Teori dan Aplikasi*, Makasar: Andira Publisher.