

PERAMALAN PENGGUNAAN LISTRIK DI PROVINSI BALI MENGUNAKAN METODE ARIMA

I Gede Gana Ariawan^{1§}, I Wayan Sumarjaya², Made Susilawati³

¹Program Studi Matematika, Fakultas MIPA-Universitas Udayana [[Email:ganaariawan99@gmail.com](mailto:ganaariawan99@gmail.com)]

²Program Studi Matematika, Fakultas MIPA-Universitas Udayana [[Email:sumarjaya@unud.ac.id](mailto:sumarjaya@unud.ac.id)]

³Program Studi Matematika, Fakultas MIPA-Universitas Udayana [[Email:mdsusilawati@gmail.ac.id](mailto:mdsusilawati@gmail.ac.id)]

[§]Corresponding Author

ABSTRACT

This study aims to forecast electricity consumption in the Province of Bali using the ARIMA (Autoregressive Integrated Moving Average) method. The forecasting process is based on monthly electricity usage data spanning from January 2015 to June 2024. The initial analysis revealed a significant upward trend, with a notable decline in usage during 2020, coinciding with the COVID-19 pandemic. To address the issue of non-stationarity in the data, a differencing process was applied until stationarity was achieved, as confirmed by the Augmented Dickey-Fuller (ADF) test. Model identification was conducted using ACF and PACF plots, and several ARIMA models were evaluated based on their Akaike Information Criterion (AIC) values. The ARIMA(0,1,1) model was selected as the most suitable model due to its lowest AIC value and its compliance with diagnostic assumptions, including uncorrelated residuals (verified by the Ljung-Box test) and normally distributed residuals (confirmed by the Shapiro-Wilk test). The forecasting results demonstrated that the selected model provides stable predictions for the subsequent 12 months. This study is expected to contribute to effective planning and management of electricity demand in the Bali region.

Keywords: ARIMA, Time Series, Shapiro-Wilk, Forecasting, Stationarity.

1. PENDAHULUAN

Listrik di zaman sekarang merupakan salah satu kebutuhan pokok yang digunakan manusia dalam menjalani kehidupan. Saking terikatnya manusia penggunaan listrik, banyak hal yang dulunya menggunakan bahan bakar lain mulai dialihkan ke listrik yang merupakan salah satu energi yang dapat diperbaharui. Banyak cara digunakan untuk meningkatkan produksi listrik karena meningkat pula alat alat yang mulai menggunakan tenaga listrik.

Pada masa pandemi Covid-19 yang penyebarannya dimulai tahun 2020 di Indonesia, banyak kegiatan harus dilakukan secara dalam jaringan (daring). Dengan perubahan dari konvensional (tatap muka) yang diubah menjadi daring kemungkinan akan mempengaruhi penggunaan listrik untuk menjalankan banyak peralatan elektronik. Selain penggunaan daring, pemerintah juga menerapkan lockdown untuk mengurangi aktivitas perkembangan Covid-19 sehingga masyarakat banyak menghabiskan kegiatannya di dalam rumah.

Sejak terjadinya penyebaran Covid-19, di tahun 2021 sudah mulai dilakukan kebijakan lockdown (PPKM) oleh pemerintah. Dari perubahan kebijakan pemerintah yang berimbas pada konsumsi listrik di Indonesia. Konsumsi listrik turun selama pandemi di Indonesia (Kompas.com, 2021).

Karena terjadinya banyak perubahan tersebut menarik perhatian untuk mengetahui bagaimana perubahan listrik yang akan datang. Perubahan penggunaan listrik akan diramalkan menggunakan metode ARIMA. Peramalan yang dilakukan mencakup jumlah KWH listrik yang terjual dari tahun 2016 sampai 2021 di Provinsi Bali.

Pemakaian listrik yang berlebihan juga berdampak pada pemanasan global. Hal ini dikarenakan masih banyaknya pembangkit listrik yang menggunakan bahan bakar batu bara yang menghasilkan emisi karbon yang berdampak langsung pada lapisan ozon bumi. Dengan meningkatnya penggunaan listrik tentu

mengharuskan meningkatkan jumlah produksi listrik yang harus disediakan.

2. METODE PENELITIAN

Pada penelitian ini, peramalan penggunaan listrik untuk periode berikutnya menggunakan metode ARIMA dengan bantuan *software* R. Adapun langkah-langkah yang dilakukan dalam penelitian ini adalah:

2.1 Penggambaran data

Pembuatan plot deret waktu dari data yang telah dimiliki. Bertujuan untuk melihat apakah data memiliki trend dan/atau musiman.

2.2 Differencing

Differencing dilakukan jika hasil dari penggambaran data menunjukkan data tidak stasioner. Tujuan utama dari proses ini adalah untuk menghilangkan tren dan membuat data menjadi stasioner.

Stasioner dalam analisis deret waktu adalah kondisi di mana data memiliki sifat statistik yang konstan sepanjang waktu, terutama dalam hal rata-rata, variansi, dan autokorelasi. Artinya, pola data tidak berubah secara signifikan seiring waktu, sehingga pergerakan data hanya terjadi karena fluktuasi acak, bukan karena tren atau musiman. Kestasioneran sangat penting dalam pemodelan seperti ARIMA, karena model ini mengasumsikan bahwa data yang dianalisis bersifat stasioner. Jika data tidak stasioner, maka hasil peramalan akan bias dan kurang akurat. Untuk mencapai kestasioneran, biasanya dilakukan transformasi seperti differencing atau penghapusan tren dan musiman dari data.

2.3 Penentuan Model

Dilakukan dengan memperhatikan plot ACF dan PACF untuk mendapatkan Nilai AR dan MA yang akan digunakan dalam ordo model ARIMA. Plot ACF digunakan untuk melihat sejauh mana observasi masa lalu memengaruhi nilai sekarang. Dalam ARIMA, pola ACF biasanya digunakan untuk menentukan nilai q (orde *Moving Average*). PACF mengukur korelasi antara nilai data saat ini dengan lag tertentu, setelah menghilangkan pengaruh lag-lag di antaranya. Plot PACF digunakan untuk menentukan nilai p (orde *Autoregressive*).

2.4 Diagnostik Model

Dilakukan untuk menguji model yang memungkinkan yang telah dipilih. Model yang ideal yaitu model yang memiliki nilai AIC lebih

rendah, residual tidak berautokorelasi dan residual berdistribusi normal.

AIC (*Akaike Information Criterion*) adalah ukuran yang digunakan untuk memilih model terbaik di antara beberapa model kandidat. AIC menilai seberapa baik model cocok dengan data sekaligus memberi penalti pada model yang terlalu kompleks. AIC memiliki rumus sebagai berikut;

$$AIC = -2\ln(L) + 2k \quad (1)$$

Semakin kecil nilai AIC, semakin baik model tersebut dianggap karena mampu memberikan keseimbangan antara akurasi dan kesederhanaan. Dalam pemodelan ARIMA, AIC digunakan untuk membandingkan beberapa model kandidat sehingga model dengan nilai AIC terendah dapat dipilih sebagai model terbaik.

2.5 Peramalan

Proses penerapan model ARIMA yang telah didapat untuk mendapatkan hasil untuk periode kedepan dari data yang telah dimiliki.

Model ARIMA adalah model umum dari ARMA (*Autoregressive Moving Average*) yang merupakan gabungan dari proses AR (*Autoregressive*) dan proses MA (*Moving Average*) yang digabungkan menjadi satu kesatuan yang utuh (*Integrated*). AR, yaitu sebuah model regresi yang menggunakan ketergantungan antara observasi dan sejumlah pengamatan masa lampau. I (*Integrated*) mengukur pengamatan pada waktu yang berbeda untuk membuat deret waktu stasioner. MA yaitu pendekatan yang memperhitungkan ketergantungan antara observasi dan residual error ketika model digunakan untuk mengamati Lag.

a. Model AR (*Autoregressive*)

Pemodelan autoregresif dikembangkan sebagai akibat dari tuntutan estimasi spektral resolusi tinggi. Model AR cocok untuk merepresentasikan spektrum dengan puncak yang tajam (tetapi bukan lembah yang dalam), demikian sangat berguna untuk memodelkan data yang memiliki bentuk gelombang sinus atau cosinus.

Bentuk sederhana dari model AR dengan jumlah (orde) p , yaitu AR(p), dapat ditulis sebagai proses linier yang diberikan oleh:

$$x_t = c + \sum_{i=1}^p \phi_i x_{t-i} + \epsilon_t \quad (2)$$

Dimana x_t adalah variabel stasioner, c adalah konstanta, dengan syarat ϕ_i adalah koefisien autokorelasi di lag 1, 2, ..., p dan

residu ϵ_t adalah Gaussian *white noise* dengan rata – rata nol (0) dan varian σ_ϵ^2 .

b. Model MA (*Moving Average*)

Pembuatan model yang seluruhnya didasarkan pada karakteristik autokorelasi empiris yang diamati tidak dapat sepenuhnya memuaskan, khususnya ketika tidak ada ukuran tunggal yang dapat memberikan estimasi yang memuaskan. Namun, jika dilihat dari struktur koefisien autokorelasi untuk model AR dan model MA, terlihat bahwa model AR lebih cocok untuk situasi ketergantungan planar, sedangkan model MA lebih cocok untuk situasi ketergantungan lokal.

Model MA dengan jumlah (orde) q , yaitu MA(q), dapat ditulis dalam bentuk:

$$x_t = \mu + \sum_{i=0}^q \theta_i \epsilon_{t-i} \quad (3)$$

Dimana μ adalah ekspektasi dari x_t (biasanya diasumsikan sama dengan nol), θ_i adalah bobot yang diterapkan pada nilai saat ini dan sebelumnya dari suku stokastik dalam deret waktu, dan $\theta_0 = 1$. Dengan asumsi ϵ_t adalah Gaussian *white noise* dengan rata – rata nol (0) dan varian σ_ϵ^2 .

c. Model ARIMA


Dari bentuk model AR dan model MA dapat digabungkan untuk memperoleh model ARMA. Jika terdapat selisih pada deret waktu dan dilakukan analisis dengan model ARMA (p, q) pada data tersebut sehingga model ARIMA digunakan. Bentuk umum model ARIMA dengan orde (p, d, q) :

$$x_t = c + \sum_{i=1}^p \phi_i x_{t-i} + \epsilon_t + \sum_{i=1}^q \theta_i \epsilon_{t-i} \quad (4)$$

Dimana $\phi_i \neq 0, \theta_i \neq 0$ dan $\sigma_\epsilon^2 > 0$.

3. HASIL DAN PEMBAHASAN


Dari data yang dimiliki diolah untuk didapat hasil berupa grafik plot time series untuk mengetahui pola data, apakah data stasioner atau tidak stasioner.



Gambar 1. Plot Time Series Penggunaan Listrik di Bali.


Dari gambar terlihat pada awalnya data terlihat seperti tangga naik yang menunjukkan data memiliki tren. Kemudian data mengalami penurunan setelah data ke-60, tepatnya data pada tahun 2020 awal sampai bulan agustus 2020 yang kemungkinan disebabkan oleh pandemi covid-19 yang mulai melanda Bali, Indonesia pada awal tahun 2020.

Pola musiman tidak terlihat secara jelas pada plot ini, sehingga perlu dikonfirmasi dengan analisis lebih lanjut seperti ACF dan PACF. Dari sisi kestasioneran, data ini tidak bersifat stasioner karena adanya tren yang jelas, sehingga diperlukan proses differencing



Gambar 2. Plot ACF Penggunaan Listrik di Bali (Asli)

Garis ACF pada lag awal (lag 1, 2, 3) terlihat tinggi dan positif, kemudian menurun perlahan. Pola seperti ini menunjukkan bahwa data tidak stasioner dan kemungkinan membutuhkan differencing.




Gambar 3. Plot PACF Penggunaan Listrik di Bali (Asli)

Pada PACF, hanya lag pertama yang signifikan (melewati garis batas), sementara lag-lag berikutnya relatif kecil dan berada dalam batas. Pola ini biasanya menunjukkan komponen AR (Autoregressive) orde rendah, misalnya AR(1).

Dapat diambil kesimpulan awal bahwa data belum stasioner, sehingga harus dilakukan differencing sebelum menentukan model ARIMA. Setelah differencing, pola ACF dan PACF akan digunakan untuk menentukan nilai p (AR) dan q (MA).

Setelah differencing diperoleh plot data sebagai berikut.



Gambar 4. Plot Data Penggunaan Listrik di Bali Setelah Dilakukan Differencing Terhadap Tren.

Hasil plot setelah dilakukan differencing menunjukkan bahwa data telah menjadi lebih stasioner. Hal ini terlihat dari fluktuasi nilai yang berpusat di sekitar nol dan tidak lagi menunjukkan tren naik atau turun. Untuk lebih memastikan kestasioneran data akan dilakukan dengan ADF test, dengan:


H_0 : data tersebut tidak stasioner

H_1 : data stasioner


dengan nilai value $\alpha=5\%$, jika $p\text{-value} < \alpha$ tolak H_0 , jika $p\text{-value} > \alpha$ terima H_0 .

Dari pengolahan menggunakan perangkat lunak R diperoleh hasil $p\text{-value}$ sebesar 0.01. ini menunjukan $p\text{-value} < \alpha$ sehingga tolak H_0 atau terima H_1 yaitu data stasioner sehingga tidak perlu dilakukan differencing lagi.

Selanjutnya akan dibuat plot ACF dan PACF baru untuk menentukan parameter ARIMA yang akan digunakan (p, d, q).



Gambar 5. Plot ACF Penggunaan Listrik di Bali Setelah Dilakukan Differencing Terhadap Tren.



Gambar 6. Plot PACF Penggunaan Listrik di Bali Setelah Dilakukan Differencing Terhadap Tren.

Hampir semua garis vertikal (lag) berada di dalam garis biru, artinya tidak ada autokorelasi

yang signifikan antar lag. Ini menunjukkan bahwa data sudah stasioner setelah differencing.


Sama seperti ACF, semua lag juga berada di dalam garis batas, yang berarti tidak ada pola AR (Autoregressive) yang kuat.

Pada proses sebelumnya telah dilakukan proses differencing sebanyak 1 kali. Model ARIMA ordo (p,d,q), dimana ordo untuk d merupakan jumlah differencing data sehingga ordo ARIMA sekarang menjadi (p,1,q). Karena tidak terdapat pola AR dan MA yang kuat, model yang paling sederhana dan sesuai adalah ARIMA(0,1,0). Namun, sebagai alternatif, model ARIMA(0,1,1) juga dapat dipertimbangkan untuk menangkap kemungkinan adanya komponen MA yang lemah. Pemilihan model akhir sebaiknya didasarkan pada nilai AIC, serta uji diagnostik residual seperti Shapiro-Wilk dan Ljung-Box untuk memastikan bahwa model yang dipilih memenuhi asumsi.


Dari hasil perhitungan, diperoleh nilai AIC Model ARIMA(0,1,0) sebesar -310.7451, sedangkan Model ARIMA(0,1,1) bernilai -313.7853.

Nilai AIC yang lebih kecil menunjukkan model yang lebih baik dalam menyeimbangkan antara kecocokan model terhadap data dan kompleksitas model. Dalam hal ini, model ARIMA(0,1,1) memiliki nilai AIC yang lebih rendah dibandingkan ARIMA(0,1,0), sehingga model ARIMA(0,1,1) lebih baik untuk digunakan.

Untuk uji residual diperoleh plot berikut.



Gambar 7. Plot Residual untuk Model ARIMA (0, 1, 0)



Gambar 7. Plot Residual untuk Model ARIMA (0, 1, 1)

Kedua model, ARIMA(0,1,0) dan ARIMA(0,1,1), menghasilkan residual yang menyebar acak di sekitar nol dan tidak menunjukkan pola tertentu, tetapi berdasarkan kriteria AIC, ARIMA(0,1,1) lebih unggul. Untuk memastikan, perlu dilakukan Ljung-Box test (untuk autokorelasi) dan uji normalitas residual.

Untuk menguji apakah sisaan berautokorelasi atau tidak akan dilakukan Ljung-Box Test dengan hipotesis:

H_0 : sisaan tidak berautokorelasi

H_1 : sisaan berautokorelasi

Dengan nilai $\alpha = 0,05$, diperoleh hasil untuk model ARIMA(0,1,0) memiliki p-value sebesar 0.01511, sedangkan model ARIMA(0,1,1) memiliki p-value sebesar 0.8557.

Hasil Ljung-Box Test menunjukan nilai p-value Model(0,1,0) < 0.05 , sehingga tolak H_0 atau terima H_1 yaitu sisaan berautokorelasi. Sedangkan Hasil Ljung-Box Test Model (0,1,1) memiliki nilai > 0.05 , sehingga terima H_0 yaitu sisaan tidak berautokorelasi.


Ini menunjukkan bahwa residual yang bersifat *white noise* adalah model ARIMA(0,1,1) sehingga model ARIMA dapat dikatakan sudah baik dan tidak perlu diperbaiki lebih lanjut. Kemudian akan diuji apakah residual dari model ARIMA(0,1,1) berdistribusi normal menggunakan *Shapiro Wilk Normality Test* dengan hipotesis:

H_0 : sisaan menyebar normal

H_1 : sisaan tidak menyebar normal

Dengan nilai $\alpha = 0,05$. Diperoleh hasil dari p-value dari model ARIMA(0,1,1) sebesar 0.08574 yang dimana $0.085740020 > 0,05$ sehingga terima H_0 , sisaan menyebar normal maka model ARIMA (0, 1, 1) dapat digunakan untuk melakukan peramalan.

Dari penggunaan model ARIMA (0, 1, 1) untuk melakukan peramalan selama 12 periode diperoleh hasil.



Gambar 9. Plot Hasil Peramalan Penggunaan Listrik di Bali.

Plot ini menunjukkan hasil peramalan (*forecasting*) dari model ARIMA. Garis hitam merepresentasikan data yang digunakan,

sedangkan garis merah menunjukkan nilai prediksi untuk 12 periode ke depan. Area bayangan dengan garis biru adalah interval kepercayaan, yang mengindikasikan batas bawah dan batas atas prediksi. Dari grafik terlihat bahwa prediksi relatif stabil, dan semakin jauh periode peramalan, semakin lebar interval kepercayaannya, yang berarti ketidakpastian meningkat seiring waktu.

4. KESIMPULAN DAN SARAN

4.1 Kesimpulan

ARIMA adalah peramalan yang menggunakan data dari masa lampau untuk menentukan data dan pola tersebut digunakan untuk peramalan. ARIMA adalah pendekatan peramalan berbasis regresi linier dimana pembuatan model seluruhnya didasarkan pada karakteristik autokorelasi empiris yang diamati tidak dapat sepenuhnya memuaskan. Metode ARIMA digunakan jika terdapat selisih pada deret waktu yang dilakukan analisis dengan model ARMA.

Dari pembahasan yang dilakukan, model ARIMA (0, 1, 1) adalah model yang telah memenuhi semua asumsi yang diperlukan untuk persyaratan peramalan, sehingga ARIMA (0,1,1) dapat digunakan untuk meramalkan penggunaan listrik di Bali untuk 12 bulan berikutnya.

4.2 Saran

Dari hasil peramalan menggunakan ARIMA hasilnya berupa garis lurus, ini menunjukan penggunaan ARIMA kurang cocok untuk peramalan jangka panjang, jadi sebaiknya gunakan metode yang lain.

DAFTAR PUSTAKA

- Maulida Amanasari, Hendra Perdana (2018) meneliti tentang Penerapan Model Filter Kalman Dalam Memprediksi Curah Hujan Kabupaten Kubu Raya.
- Ayu Wulandari (2019) Penerapan Metode Ensemble Filter Kalman Pada Model Pertumbuhan Logistik Menggunakan Fungsi Populasi Parabolik.
- Kevion Kotze, State-Space Modeling
- Mohammad Alfian Alfian Riyadi, Kartika Fithriasari, Dwiatmono Agus Widodo (2016) Data Mining Peramalan Konsumsi Listrik

- dengan Pendekatan Cluster Time Series sebagai Preprocessing
- Kompas.com (2021) Konsumsi Listrik Turun, Menteri ESDM Nego Ulang Kontrak Proyek 35.000 MW
- Sima Siami-Namini, Neda Tavakoli, & Akbar Siami Namin (2018). A Comparison of ARIMA and LSTM in Forecasting Time Series. Google Cendikia.
- R. P. Haining (1976). The Moving Average Model for Spatial Interaction. Transactions of the Institute of British Geographers Vol. 3, No. 2 (1978), pp. 202-225.
- Marita Sulistyaningwarni Nurjamil (2002). Metode Analisis ARIMA Untuk Peramalan Jumlah Penumpang Kereta Api di Pulau Jawa.
- Tirta Indayani & Moh Yamin Darsyah (2018). Pemilihan Model Peramalan Terbaik Menggunakan Model Arima dan Winters Untuk Meramalkan Indeks LQ45. Prosiding Seminar Nasional Mahasiswa Unimus (Vol.1)
- Vincentia Pawestri, Adi Setiawan, & Lilik Linawati (2019) Pemodelan Data Penjualan Mobil Menggunakan Model Autoregressive Moving Average Berdasarkan Metode Bayesian. Jurnal Sains dan Edukasi Sains Vol.2, No.1.
- Ilham Aksan & Khalilah Nurfadilah (2020). Aplikasi Metode Arima Box-Jenkins Untuk Meramalkan Penggunaan Harian Data Seluler. JOMTA Journal of Mathematics: Theory and Applications Vol. 2, No. 1