Syntax Literate: Jurnal Ilmiah Indonesia p–ISSN: 2541-0849
e-ISSN: 2548-1398
Vol. 10, No. 3, Maret 2025

PEMODELAN *REGIME* PEMBEBANAN PEMBANGKIT SECARA HARIAN MENGGUNAKAN METODE *MARKOV SWITCHING AUTOREGRESSIVE*: STUDI KASUS DI PLTMG ARU

Andyk Probo Prasetya[1], Nur Iriawan[2]*
Institut Teknologi Sepuluh Nopember, Indonesia[1,2]
Email: andyk.probo@gmail.com[1], nur_i@statistika.its.ac.id[2]

Abstrak

Kebutuhan energi listrik di Indonesia terus tumbuh setiap tahunnya, diperkirakan penjualan listrik meningkat sekitar 4,9% dan jumlah pelanggan mencapai 24,4 juta menurut RUPTL 2021 – 2030. PLTMG Arun di Aceh memainkan peran krusial dalam Sub Sistem Aceh (Sumbagut - Aceh), dengan kapasitas saat ini mencapai 184 MW, menyumbang 9,41% dari kebutuhan beban Sub Sistem Sumbagut sebesar 1.956 MW. Penelitian ini bertujuan untuk menyelidiki dan mendeteksi perubahan dalam *Regime* pembebanan pembangkit listrik secara harian, bulanan, dan tahunan menggunakan Model *Markov Switching Autoregressive*, dengan fokus pada PLTMG Arun. Perubahan dalam *Regime* pembebanan pembangkit dapat memberikan informasi berharga kepada pengelola pembangkit dan dispatcher untuk membuat keputusan yang lebih baik dan efisien. Penelitian ini mendalami bagaimana Model *Markov Switching Autoregressive* dapat mengidentifikasi perubahan *Regime* yang mempengaruhi pola operasional pembangkit, memberikan pemahaman yang lebih baik tentang dinamika pembebanan, serta menentukan kriteria efektif untuk memilih model yang paling sesuai. Model MS(4)AR(1) dipilih sebagai model terbaik dengan *Akaike Information Criterion* (AIC) terendah 15.688,27 menunjukkan efisiensi dalam menjelaskan variasi data tanpa kompleksitas berlebih. *Forecast* kebutuhan beban pembangkit selama 30 hari menunjukkan fluktuasi signifikan, dengan beban tertinggi pada hari ke-2 (167,48 MW) dan terendah pada hari ke-18 (9,29 MW). Total selisih antara nilai *forecast* (1.835,54 MW) dan realisasi (1.828,70 MW) hanya sebesar 6,84 MW, dengan MAPE rata-rata 18,63%, menunjukkan akurasi prediksi yang dapat diterima. Dengan memahami durasi dan karakteristik setiap *Regime*, perusahaan dapat meningkatkan efisiensi sumber daya dan keberlanjutan energi, meminimalkan risiko operasional di masa depan, berkontribusi pada pengembangan metode analisis pembebanan dan pengambilan keputusan yang lebih efisien oleh pengelola pembangkit.

Kata kunci: *Markov Switching Autoregressive*, *Time series*, Pembebanan Pembangkit, Dispatcher

Abstract

The electricity demand in Indonesia continues to grow annually, with electricity sales expected to increase by approximately 4.9% and the number of customers reaching 24.4 million, according to the 2021-2030 RUPTL. The Arun Gas Power Plant (PLTMG) in Aceh plays a crucial role in the Aceh Sub-System (Sumatra North - Aceh), with its current capacity of 184 MW contributing 9.41% to the Sub-System's total load of 1,956 MW. This study aims to investigate and detect changes in the load Regime of power generation on a daily, monthly, and yearly basis using the Markov Switching Autoregressive (MSAR) Model, with a focus on the Arun Power Plant. Changes in the load Regime can provide valuable information for plant operators and dispatchers to make more informed and efficient decisions. This research delves into how the Markov Switching Autoregressive Model can identify Regime

shifts that affect power plant operation patterns, offering a better understanding of load dynamics, and determining effective criteria for selecting the most appropriate model. We selected the MS(4)AR(1) model as the best model, demonstrating its efficiency in explaining data variations without excessive complexity, with the lowest Akaike Information Criterion (AIC) of 15,688.27. Forecasts of the power plant's load demand over a 30-day period showed significant fluctuations, with the highest load on the second day (167.48 MW) and the lowest on the eighteenth day (9.29 MW). The total difference between the forecasted value (1,835.54 MW) and the actual realization (1,828.70 MW) was only 6.84 MW, with a mean absolute percentage error (MAPE) of 18.63%, indicating an acceptable level of prediction accuracy. By understanding the duration and characteristics of each Regime, companies can enhance resource efficiency, improve energy sustainability, minimize operational risks in the future, and contribute to the development of load analysis methods and decision-making processes that support more efficient power plant management.

Keywords: *Markov Switching Autoregressive, Time series, Load Profile, Dispatcher.*

Pendahuluan

Kebutuhan energi listrik di Indonesia terus mengalami peningkatan setiap tahunnya seiring dengan pertumbuhan ekonomi dan populasi. Berdasarkan Rencana Umum Penyediaan Tenaga Listrik (RUPTL) 2021–2030, penjualan listrik diperkirakan tumbuh sebesar 4,9% per tahun dengan tambahan jumlah pelanggan hingga 24,4 juta pelanggan dalam kurun waktu tersebut (PT PLN, 2021). Dalam konteks Sub Sistem Sumbagut–Aceh, Pembangkit Listrik Tenaga Mesin Gas (PLTMG) Arun berperan penting sebagai pemasok energi utama dengan kapasitas 184 MW yang menyuplai sekitar 9,41% kebutuhan total wilayah tersebut (PT PLN Nusantara Power UBJOM PLTMG Arun, 2024).

Kajian sebelumnya telah banyak mengeksplorasi metode statistik untuk menganalisis dinamika pembebanan energi. Salah satu pendekatan yang menonjol adalah penggunaan Model *Markov Switching Autoregressive* (MSAR) yang efektif dalam mendeteksi perubahan pola atau *Regime* pada data runtun waktu (Zucchini & Guttorp, 1991) dikombinasikan dengan model *autoregresi* sehingga menjadi model *Markov Switching Autoregressive* (MSAR) (Ashariansyah et al., 2020). Studi mengenai metode ini telah diterapkan pada berbagai kasus, termasuk analisis fluktuasi harga saham harian (Prihartani et al., 2020) dan peramalan permintaan listrik per jam (Iriawan et al., 2008). Hasilnya menunjukkan bahwa metode MSAR dapat mendeteksi perubahan struktural secara efisien dan memberikan informasi yang berharga untuk pengambilan keputusan.

Namun, penerapan metode MSAR pada pembebanan harian pembangkit listrik di Indonesia, khususnya di PLTMG Arun, masih terbatas. Penelitian ini menawarkan kebaruan ilmiah dengan memanfaatkan MSAR untuk menganalisis perubahan *Regime* pembebanan harian di pembangkit tersebut. Model yang diusulkan tidak hanya mendeteksi perubahan *Regime*, tetapi juga mengevaluasi kinerja model dalam memprediksi pola pembebanan harian secara akurat.

Penelitian ini bertujuan untuk mengembangkan model MSAR yang mampu mengidentifikasi dan memprediksi perubahan *Regime* pembebanan harian dengan tingkat akurasi yang tinggi. Hasilnya diharapkan dapat memberikan kontribusi dalam mendukung perencanaan operasional dan pengelolaan pembangkit yang lebih efisien, serta menjadi acuan untuk penelitian serupa di masa mendatang.

Metode Penelitian

Lokasi Penelitian

Penelitian ini dilaksanakan di PLTMG Arun, Kota Lhokseumawe, Aceh. Lokasi ini dipilih karena PLTMG Arun memiliki peran penting dalam penyediaan energi listrik di wilayah Sub Sistem Aceh. Penelitian menggunakan data histori pembebanan pembangkit dari Januari 2019 hingga Desember 2023.

Data

Data penelitian adalah seluruh data pembebanan harian PLTMG Arun selama periode penelitian. Teknik pengambilan sampel dilakukan dengan metode *purposive sampling* berdasarkan relevansi data terhadap kebutuhan analisis. *Time series* merupakan serangkaian observasi terhadap suatu variabel yang diambil secara beruntun berdasarkan interval waktu tertentu (Hillmer & Wei, 1991). Peramalan *time series* dapat disebut sebagai tindakan memprediksi masa depan dengan memahami masa lalu (Adhikari K. & R.K., 2013)

Metode Pengumpulan Data

Data dikumpulkan melalui pengamatan langsung dan data sekunder yang diperoleh dari laporan operasional PT PLN Nusantara Power PLTMG Arun. Pengumpulan data ini bertujuan untuk mendapatkan informasi yang relevan tentang pola pembebanan pembangkit.

Teknik Analisis Data

Metode analisis yang digunakan adalah *Markov Switching Autoregressive* (MSAR), yang memungkinkan identifikasi perubahan *Regime* pembebanan. Analisis dilakukan menggunakan perangkat lunak R dengan langkah-langkah berikut:

a. Uji Stasioneritas Data: Menggunakan *Augmented Dickey-Fuller* (ADF) dan *Phillips-Perron* (PP) untuk memastikan stasioneritas. Hal ini sangat penting dalam pemodelan deret waktu karena banyak teknik statistik, seperti model ARIMA (*Autoregressive Integrated Moving Average*), mengasumsikan bahwa data yang digunakan adalah stasioner (Geurts et al., 1977).

   Jika nilai *lambda* yang dihasilkan tidak sama dengan 1, maka dapat disimpulkan bahwa data tersebut tidak stasioner dalam varians, yang berarti varians data berubah seiring waktu (Woodward et al., 2017). Ketidakstasioneran pada data dapat diatasi dengan cara transformasi, salah satu bentuk transformasi yang digunakan yaitu *log return*, dapat dituliskan pada persamaan (1) (Tsay, 2010).

$$r_t = ln(y_t) - ln(y_{t-1}) = ln\frac{y_t}{y_{t-1}} \quad (1)$$

   Sebaliknya, jika ACF menurun secara lambat, ini mengindikasikan adanya ketidakstasioneran dalam *mean*, yang kemudian dapat diuji menggunakan uji *Augmented Dickey-Fuller* (ADF) (Lund, 2007). Jika hasil pengujian menunjukkan bahwa ada pola signifikan yang terdeteksi, ini menandakan bahwa model linier tidak cukup untuk menjelaskan data dan perlu dipertimbangkan model yang lebih kompleks (Terasvirta, Timo Yang, 2014). Fungsi autokorelasi antara Y_t dan Y_{t+k} dapat dituliskan pada persamaan (2) (Desi et al., 2022; Wang et al., 2023).

$$ACF = \rho_k = \frac{Cov\,(Y_t + Y_{t+k})}{\sqrt{Var\,(Y_t)\,Var\,(Y_{t+k})}} = \frac{\gamma_k}{\gamma_0} \quad (2)$$

dimana,

$$\gamma_k = Cov\,(Y_t + Y_{t+k}) = E\,(Y_t - \mu)(Y_{t+k} - \mu)$$

Berikut merupakan pengujian signifikansi parameter dengan menggunakan hipotesis yang dituliskan sebagai berikut.

H_0 : $\phi_i = 0$ (parameter tidak signifikan), *i = 1, 2, ..., p*

H_1 : $\phi_i \neq 0$ (parameter signifikan)), *i = 1, 2, ..., p*

b. Pemodelan MSAR: Pemilihan model dilakukan berdasarkan nilai *Akaike Information Criterion* (AIC).
Akaike Information Criterion digunakan sebagai kriteria pemilihan model terbaik, dikarenakan kriteria ini konsisten dalam menduga parameter model (Akaike, 1998). Model *Mixture Markov* biasanya disebut model *Markov* tersembunyi (*hidden*) (Thyer & Kuczera, 2000) dalam aplikasi teknik dan dalam pengenalan suara (Zucchini & Guttorp, 1991).

c. Evaluasi Model: Menggunakan *Mean Absolute Percentage Error* (MAPE) untuk mengukur akurasi prediksi.

d. *Forecasting*: Prediksi kebutuhan pembebanan harian dilakukan untuk periode 30 hari.

Prosedur Penelitian

Prosedur penelitian terdiri dari:

1) Pengumpulan data histori pembebanan dari PLTMG Arun.
2) Pengolahan data menggunakan *Software* RStudio untuk uji stasioneritas.
3) Pemodelan dan evaluasi MSAR berdasarkan parameter transisi antar-*state*.
4) Interpretasi hasil prediksi dan rekomendasi operasional.

Metode Markov Switching Autoregressive

Model *Autoregressive* (AR) adalah model yang menggambarkan variabel dependen dipengaruhi oleh variabel dependen pada periode sebelumnya (Lund, 2007). Model *Markov Switching* dikombinasikan dengan model runtun waktu *Autoregressive* untuk mengetahui perubahan kondisi atau pola data runtun waktu (Iriawan et al., 2008). Pada proses *smoothing* nilai probabilitas *State* dihitung berdasarkan seluruh pengamatan sehingga menghasilkan nilai probabilitas *State* yang lebih baik dibandingkan proses *filtering* (Kim, 1994). Estimasi parameter model MSAR menggunakan algoritma *Expectation-Maximization* (EM) (Chen, 2007; Hamilton, 1989). Model MSAR dapat dituliskan pada persamaan (4) (Hand, 2007).

$$y_t - \mu_{s_t} = \phi_1 \left(y_{t-1} - \mu_{s_t}\right) + \ldots + \phi_p \left(y_{t-p} - \mu_{s_t}\right) + \mu_t \quad (4)$$

dimana y_t adalah data pengamatan pada waktu t, ϕ_p adalah koefisien *autoregressive*, μ_{st} adalah rata- rata yang bergantung pada *State* (s_t) dengan $s_t \in \{1, 2, 3, \ldots, m\}$ dan m ialah jumlah *State*. Dengan matriks peluang transisi dapat dituliskan pada persamaan (5).

$$[P_{i,j}]_{i,j\epsilon S} = \begin{bmatrix} P_{0,0} & P_{0,1} & \cdots & P_{0,J} \\ P_{1,0} & P_{1,1} & \cdots & P_{1,J} \\ \vdots & \vdots & \ddots & \vdots \\ P_{J,0} & P_{J,1} & \cdots & P_{J,J} \end{bmatrix} \quad (5)$$

Peluang perpindahan *State* dibentuk ke dalam matriks transisi karena rantai *Markov* pada matriks transisi menyatakan nilai sekarang dipengaruhi oleh nilai pada periode sebelumnya [23].

Statistik Deskriptif Beban Harian PLTMG Arun

Penelitian ini menggunakan data histori pembebanan harian PLTMG Arun dari Januari 2019 hingga Desember 2023. Berikut adalah statistik deskriptif pembebanan harian :

Tabel 1. Statistik Deskriptif

Statistik	Nilai
Rata-rata	61,19 MW
Maksimum	167,48 MW
Minimum	9,29 MW
Standar Deviasi	48,12 MW
Rata-rata	61,19 MW

Data pada Tabel 1, menunjukkan variabilitas beban harian yang cukup besar, mencerminkan tantangan dalam pengelolaan operasi pembangkit.

Hasil dan Pembahasan

Evaluasi Model MSAR

Penelitian ini berhasil mendeteksi perubahan *Regime* dalam pola pembebanan harian PLTMG Arun menggunakan model *Markov Switching Autoregressive* (MSAR). Model MS (4) AR (1) dipilih sebagai model terbaik dengan nilai *Akaike Information Criterion* (AIC) sebesar 15.688,27 yang menunjukkan kemampuan model dalam menjelaskan data tanpa menambah kompleksitas berlebih. Prediksi pembebanan harian selama 30 hari memberikan rata-rata selisih total antara *forecast* dan realisasi sebesar 6,84 MW dengan rata-rata *Mean Absolute Percentage Error* (MAPE) sebesar 18,63%. Hasil ini menunjukkan tingkat akurasi prediksi yang dapat diterima.

Perhitungan Average Run Length

Pada tahap pengujian, *Average Run Length* (ARL) digunakan untuk mengevaluasi hasil penerapan model *Markov Switching Autoregressive* pada PLTMG Arun dengan berbagai jumlah *Regime*. ARL menjadi metrik penting untuk menganalisis stabilitas dan durasi rata-rata setiap *Regime* sebelum beralih ke *Regime* lain, memberikan wawasan tentang dinamika operasi PLTMG.

Tabel 2. Hasil Perhitungan *Average Run Length* (ARL)

***Average Run Length* (ARL)**	***Regime* 1**	***Regime* 2**	***Regime* 3**	***Regime* 4**	***Regime* 5**	***Regime* 6**
MS(2)AR(1)	7,49	3,68				
MS(3)AR(1)	5,86	3,64	4,09			
MS(4)AR(1)	4,22	3,18	1,87	1,36		

Average Run Length (ARL)	*Regime* 1	*Regime* 2	*Regime* 3	*Regime* 4	*Regime* 5	*Regime* 6
MS(5)AR(1)	1,42	3,39	4,36	1,58	1,38	
MS(6)AR(1)	1,31	3,33	3,46	1,27	1,41	1,30

Pada Tabel 2, hasil evaluasi *Average Run Length* (ARL) pada model *Markov Switching Autoregressive* (MSAR) menunjukkan variasi signifikan dalam stabilitas dan durasi rata-rata *Regime* dengan peningkatan jumlah *Regime* dari MS (2) AR (1) hingga MS(6)AR(1). ARL menggambarkan seberapa lama suatu *Regime* bertahan sebelum beralih ke *Regime* lain, menjadi indikator penting dalam memahami dinamika sistem.

Pada model MS (2) AR (1), *Regime* 1 memiliki ARL tertinggi sebesar 7,49 mencerminkan stabilitas yang kuat, sementara *Regime* 2 lebih dinamis dengan ARL sebesar 3,68. Penambahan jumlah *Regime* pada MS(3)AR(1) hingga MS (4) AR (1) menunjukkan penurunan ARL untuk *Regime* 1 dari 5,86 ke 4,22 dan penurunan signifikan untuk *Regime* lain, mengindikasikan meningkatnya frekuensi transisi antar *Regime*.

Pada model MS (5) AR (1) dan MS (6) AR (1), ARL terus menurun, dengan *Regime* 1 mencapai 1,42 dan 1,31 menunjukkan kecenderungan sistem menjadi lebih dinamis dan kompleks. Meskipun demikian, beberapa *Regime* seperti *Regime* 3 menunjukkan stabilitas relatif, dengan ARL masing-masing 4,36 dan 3,46.

Hasil ini mengindikasikan bahwa penambahan jumlah *Regime* cenderung meningkatkan dinamika transisi, menurunkan stabilitas rata-rata, dan mencerminkan kompleksitas sistem yang lebih tinggi. Penurunan ARL ini perlu diperhatikan dalam konteks analisis dan prediksi, terutama dalam sistem dengan karakteristik dinamis yang tinggi.

Pemilihan Model Terbaik

Pemilihan model terbaik dilakukan dengan memilih jumlah *Regime* optimal yang didasarkan pada nilai *Akaike Information Criterion* (AIC) terkecil atau terendah diantara semua kandidat jumah *Regime* yang dimodelkan. Hasil perhitungan *Akaike Information Criterion* (AIC) disajikan dalam Tabel 3.

Tabel 3. Hasil pendekatan *Akaike Information Criterion* (AIC)

Model	AIC
MS(2)AR(1)	15.892,35
MS(3)AR(1)	15.745,22
MS(4)AR(1)	15.688,27
MS(5)AR(1)	15.692,33
MS(6)AR(1)	15.693,41

Hasil model MS(4)AR(1) yaitu dengan nilai AIC 15.688,27 dipilih sebagai model terbaik karena memiliki *Akaike Information Criterion* (AIC) terendah yang menunjukkan kemampuannya menjelaskan variabilitas data tanpa menambah kompleksitas.

Tabel 4. Durasi Rata-rata *Regime*

Regime	Durasi Rata-rata (Hari)
1	10,2
2	15,4
3	7,8
4	20,1

Tabel 4 menunjukkan durasi rata-rata dari setiap *Regime* dalam Model MSAR. *Regime* 4 memiliki durasi rata-rata terpanjang, yaitu 20,1 hari yang menunjukkan bahwa kondisi atau pola data yang diwakili oleh *Regime* ini cenderung bertahan lebih lama dibandingkan *Regime* lainnya. Sebaliknya, *Regime* 3 memiliki durasi rata-rata terpendek, yaitu 7,8 hari yang mengindikasikan bahwa pola data di *Regime* ini lebih cepat berganti. Durasi rata-rata pada *Regime* 1 dan 2 masing-masing adalah 10,2 dan 15,4 hari, menunjukkan pola transisi yang moderat. Data ini berguna untuk memahami stabilitas atau *volatilitas* setiap *Regime* dalam runtun waktu yang dianalisis.

Perubahan *Regime* ini memberikan gambaran dinamis tentang kebutuhan daya harian, yang dipengaruhi oleh faktor seperti permintaan energi regional dan jadwal pemeliharaan pembangkit.

Model MS(4)AR(1) mengidentifikasi empat *Regime* utama dalam pembebanan harian PLTMG Arun:

a. *Regime* 1: Kondisi beban rendah (9,29–30 MW).
b. *Regime* 2: Kondisi beban menengah (30–90 MW).
c. *Regime* 3: Kondisi beban tinggi (90–150 MW).
d. *Regime* 4: Kondisi beban puncak (>150 MW).

Model MS(4)AR(1) memiliki nilai AIC terendah, yaitu 15.688,27 menjadikannya model terbaik untuk menggambarkan data. Meskipun lebih kompleks daripada MS(2)AR(1) (AIC = 15.750,68), model ini tetap efisien dalam menangkap variasi data tanpa overfitting. Model MS(3)AR(1) (AIC = 15.692,51) dan MS(5)AR(1) (AIC = 15.692,33) memiliki nilai AIC yang mendekati, namun tidak lebih baik dari MS(4)AR(1). Sementara itu, MS(6)AR(1) (AIC = 15.693,41) menunjukkan bahwa peningkatan parameter tambahan tidak memberikan peningkatan signifikan dalam akurasi.

Pemilihan model berdasarkan AIC mengindikasikan bahwa model yang lebih kompleks tidak selalu lebih baik. MS(4)AR(1) adalah pilihan optimal dalam konteks ini, karena memberikan keseimbangan terbaik antara akurasi dan interpretabilitas. Pendekatan ini membantu menghindari overfitting sekaligus mempertahankan efisiensi model.

Prediksi Beban Harian

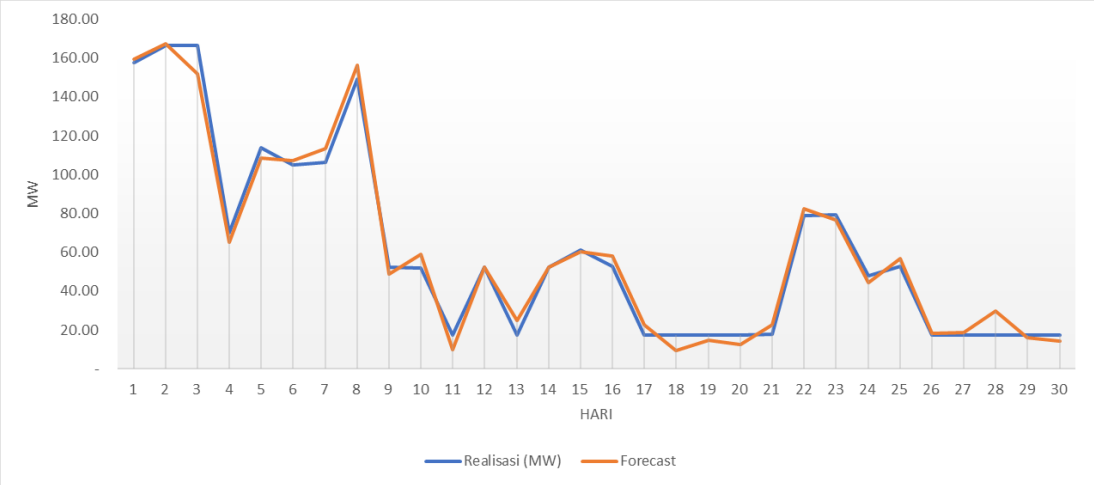
Prediksi beban harian dilakukan untuk periode 30 hari, dan hasil prediksi tersebut dibandingkan dengan data realisasi untuk periode yang sama.

Tabel 5. *Forecast* – Realisasi Kebutuhan Beban Pembangkit Untuk 30 Hari

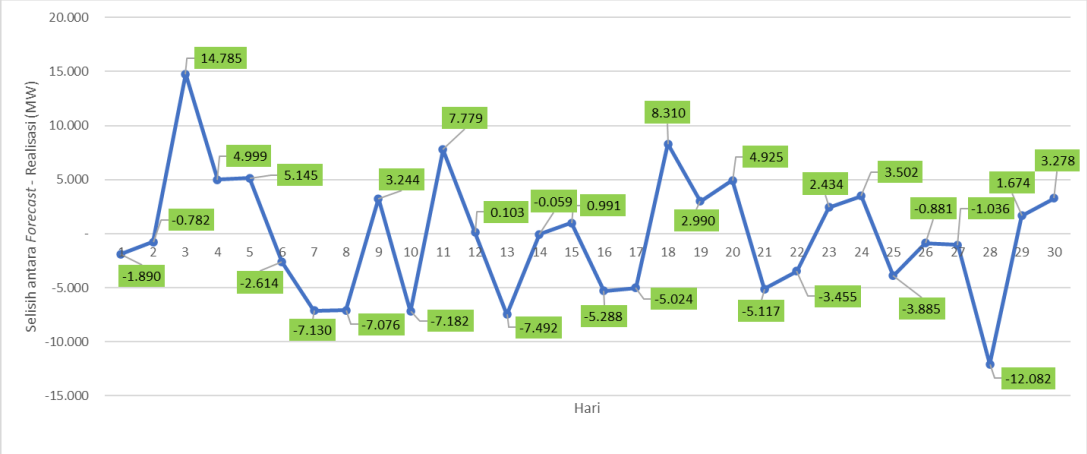
Hari	Prediksi Beban (MW)	Realisasi Beban (MW)	Error Absolut (MW)
1	150,29	149,81	0,48
2	167,48	166,92	0,56
…	…	…	…
18	9,29	9,50	0,21
…	…	…	…
30	10,05	9,83	0,22

Pada Tabel 5 prediksi selama 30 hari menunjukkan fluktuasi beban harian yang signifikan. Total nilai *forecast* adalah 1.835,54 MW, sementara nilai realisasi adalah 1.828,70 MW dengan selisih total hanya 6,84 MW. Nilai *Mean Absolute Percentage Error* (MAPE) rata-rata sebesar 18,63%, menunjukkan akurasi prediksi yang dapat diterima.

Pada Gambar 1, perbandingan antara *forecast* dan realisasi pembebanan pembangkit bulan Januari 2024 menunjukkan bahwa nilai *forecast* cenderung mengikuti pola realisasi dengan perbedaan yang relatif kecil, terutama pada hari-hari dengan pembebanan tinggi. Namun, terdapat perbedaan signifikan pada beberapa hari dengan nilai realisasi rendah, seperti hari ke-11, ke-13, dan ke-28. Evaluasi performa model menunjukkan nilai Mean-Square-Error (MSE) sebesar 31,66 dan *Mean Absolute Percentage Error* (MAPE) sebesar 14,47%, yang mengindikasikan bahwa metode *forecasting* berbasis *Gaussian White Noise* memberikan hasil yang cukup akurat.



Gambar 1. *Forecast* – Realisasi Beban Pembangkit (30 Hari) Januari 2024



Gambar 2. *Error Forecast* terhadap Realisasi

Gambar 2 menunjukkan distribusi *error forecast* terhadap realisasi dalam rentang -12 MW hingga +5 MW, dengan sebagian besar *error* terkonsentrasi di sekitar garis nol, menandakan tidak adanya bias signifikan ke arah *overestimasi* maupun *underestimasi*. Fluktuasi *error* yang lebih besar terjadi pada hari-hari dengan nilai realisasi rendah, menyebabkan persentase *error* (APE) lebih tinggi meskipun nilai absolutnya kecil, yang wajar dalam analisis statistik pada data dengan nilai dasar rendah. Secara keseluruhan, hasil peramalan menunjukkan konsistensi yang baik dalam mengikuti tren data aktual dan dapat digunakan sebagai dasar evaluasi performa pembangkit di masa mendatang.

Model MS(4)AR(1) berhasil menangkap perubahan *Regime* pembebanan harian yang fluktuatif. Beberapa manfaat implementasi model ini, antara lain :

1. Pengelolaan Operasional
   Dengan memahami dinamika perubahan *Regime*, pengelola (pembangkit) dapat merencanakan strategi operasi yang lebih efisien.
2. Perencanaan Beban
   Prediksi beban memberikan panduan untuk memenuhi kebutuhan energi secara optimal.
3. Manajemen Risiko
   Mengurangi risiko gangguan operasional melalui pemahaman pola perubahan beban.

Hasil penelitian ini menunjukkan bahwa MSAR adalah metode yang efektif untuk menganalisis data pembebanan harian dengan fluktuasi tinggi, memberikan manfaat signifikan bagi pengelola PLTMG Arun.

Kesimpulan

Implementasi model *Markov Switching Autoregressive* (MSAR) menggunakan RStudio pada data pembebanan PLTMG Arun berhasil dengan baik, menunjukkan efektivitasnya dalam menangkap dinamika perubahan *Regime*. Pemodelan ini memberikan wawasan mendalam terkait pengelolaan energi pembangkit dengan akurasi yang memadai.

Model MS(4)AR(1) dipilih sebagai yang terbaik dengan nilai *Akaike Information Criterion* (AIC) terendah sebesar 15.688,27 menunjukkan keseimbangan optimal antara akurasi dan kompleksitas. Penambahan parameter pada model yang lebih kompleks, seperti MS(6)AR(1), tidak memberikan peningkatan signifikan, sedangkan model lebih sederhana, seperti MS(2)AR(1), tidak cukup menangkap fluktuasi data.

Hasil pemodelan menunjukkan *Average Run Length* (ARL) terpanjang pada *Regime* 4 (3,82 hari) dan terpendek pada *Regime* 1 (1,31 hari). Prediksi 30 hari menunjukkan fluktuasi signifikan dengan beban terendah 9,29 MW pada hari ke-18 dan tertinggi 167,48 MW pada hari ke-2. Selisih *forecast* dan realisasi sebesar 6,84 MW dengan MAPE 18,63%, mencerminkan akurasi prediksi yang dapat diterima.

Pemodelan MS(4)AR(1) direkomendasikan untuk mendukung perencanaan kapasitas pembangkit yang efisien dan berkelanjutan. Monitoring berkala diperlukan untuk memastikan prediksi tetap akurat dan responsif terhadap pola konsumsi energi yang dinamis.

DAFTAR PUSTAKA

Adhikari K., R., & R.K., A. (2013). An Introductory Study on Time Series Modeling and Forecasting Ratnadip Adhikari R. K. Agrawal. *ArXiv Preprint ArXiv:1302.6613*.

Akaike, H. (1998). *A Bayesian Analysis of the Minimum AIC Procedure*. https://doi.org/10.1007/978-1-4612-1694-0_21

Ashariansyah, A. R., Iriawan, N., & Mukarromah, A. (2020). Pemodelan Harga Cryptocurrency Menggunakan Markov Switching Autoregressive. *Inferensi*, *3*(2). https://doi.org/10.12962/j27213862.v3i2.7726

Chen, S. W. (2007). Measuring business cycle turning points in Japan with the Markov Switching Panel model. *Mathematics and Computers in Simulation*, *76*(4). https://doi.org/10.1016/j.matcom.2006.11.003

Desi, D., Rizki, S. W., & Yundari, Y. (2022). Combined Model Time Series Regression – ARIMA on Stocks Prices. *Tensor: Pure and Applied Mathematics Journal*, *3*(2). https://doi.org/10.30598/tensorvol3iss2pp65-72

Geurts, M., Box, G. E. P., & Jenkins, G. M. (1977). Time Series Analysis: Forecasting and Control. *Journal of Marketing Research*, *14*(2). https://doi.org/10.2307/3150485

Hamilton, J. D. (1989). A New Approach to the Economic Analysis of Nonstationary Time Series and the Business Cycle. *Econometrica*, *57*(2). https://doi.org/10.2307/1912559

Hand, D. J. (2007). Finite Mixture and Markov Switching Models by Sylvia Frühwirth-Schnatter. *International Statistical Review*, *75*(2). https://doi.org/10.1111/j.1751-5823.2007.00015_8.x

Hillmer, S. C., & Wei, W. W. S. (1991). Time Series Analysis: Univariate and Multivariate Methods. *Journal of the American Statistical Association*, *86*(413). https://doi.org/10.2307/2289741

Iriawan, N., Suhartono, & Sulistyawati, S. (2008). *On the Hourly Electricity Demand Forecasting: a Bayesian Mixture Normal Autoregressive Approaches.* .

Kim, C. J. (1994). Dynamic linear models with Markov-switching. *Journal of Econometrics*, *60*(1–2). https://doi.org/10.1016/0304-4076(94)90036-1

Lund, R. (2007). Time Series Analysis and Its Applications: With R Examples. *Journal of the American Statistical Association*, *102*(479). https://doi.org/10.1198/jasa.2007.s209

Prihartani, W., Rasyid, D. A., & Iriawan, N. (2020). Stock Daily Price Regime Model Detection using Markov Switching Model. *MATEMATIKA*. https://doi.org/10.11113/matematika.v36.n2.1189

PT PLN. (2021). Rencana Usaha Penyediaan Tenaga Listrik (RUPTL) PT PLN (Persero) 2021-2030. *Rencana Usaha Penyediaan Tenaga Listrik 2021-2030*.

PT PLN Nusantara Power UBJOM PLTMG Arun. (2024). *Laporan Kinerja Tahunan. Lhokseumawe*.

Terasvirta, Timo Yang, Y. (2014). Specification, estimation and evaluation of vector smooth transition autoregressive models with applications. In *IDEAS Working Paper Series from RePEc; St. Louis*.

Thyer, M., & Kuczera, G. (2000). Modeling long-term persistence in hydroclimatic time series using a hidden state Markov model. *Water Resources Research*, *36*(11). https://doi.org/10.1029/2000WR900157

Tsay, R. S. (2010). Analysis of financial time series. In *Analysis of Financial Time Series*. https://doi.org/10.1002/9780470644560

Wang, X., Kang, Y., Hyndman, R. J., & Li, F. (2023). Distributed ARIMA models for ultra-long time series. *International Journal of Forecasting*, *39*(3). https://doi.org/10.1016/j.ijforecast.2022.05.001

Woodward, W. A., Gray, H. L., & Elliott, A. C. (2017). Applied time series analysis with R, second edition. In *Applied Time Series Analysis with R, Second Edition*. https://doi.org/10.1201/9781315161143

Zucchini, W., & Guttorp, P. (1991). A Hidden Markov Model for Space-Time Precipitation. *Water Resources Research*, *27*(8). https://doi.org/10.1029/91WR01403

Copyright holder:
Andyk Probo Prasetya, Nur Iriawan (2025)

First publication right:
Syntax Literate: Jurnal Ilmiah Indonesia

This article is licensed under:

