

Pemodelan Energi Listrik yang Dihasilkan oleh PV Menggunakan Metode Time Series dan *Neural Network* untuk Komparasi

Umi Yuliatin¹, Aseptia Surya Wardhana², Astrie Kusuma Dewi³, Chalidia Nurin Hamdani⁴

¹ PEM Akamigas, Indonesia; umi.yuliatin@esdm.go.id

² PEM Akamigas, Indonesia; asepta.wardhana@esdm.go.id

³ PEM Akamigas, Indonesia; astrie.dewi@esdm.go.id

⁴ PEM Akamigas, Indonesia; Chalidia.hamdani@esdm.go.id

ARTICLE INFO

Keywords:

Time Series Analysis;
Neural Network;
Electricity Production

Article history:

Received 2023-06-20

Revised 2023-08-17

Accepted 2023-10-07

ABSTRACT

Renewable energy sourced from the sun has become one of the focal points of alternative renewable energy as fossil energy reserves diminish. Solar energy, which is converted into electricity using photovoltaic technology, is influenced by several variables, particularly weather variables such as temperature, humidity, and solar radiation. This study involves modeling and forecasting the power output of a 100 Watt PV Solar system using Time Series Analysis and Neural Network techniques. The PV solar system is connected to various weather variable measurement sensors, such as a pyranometer, temperature sensor, and humidity sensor. The data collected from these sensors serve as input for calculating the power output of the installed 100 Watt PV system. The power output is observed on an hourly and daily basis. The modeling results indicate that the best model obtained using ARIMA with variables is ARIMA (0,0,2), incorporating all weather variables (Radiation, Humidity, Temperature*, Wind, and Light*) with a MAPE (Mean Absolute Percentage Error) of 2.91%. Meanwhile, for the best Neural Network (LSTM) model, the input variables of radiation, temperature, and intensity achieved a MAPE of 3.41%.

This is an open access article under the [CC BY-NC-SA](#) license.



Corresponding Author:

Umi Yuliatin

PEM Akamigas, Indonesia; umi.yuliatin@esdm.go.id

1. PENDAHULUAN

Energi terbarukan yang bersumber dari matahari menjadi salah satu fokus *alternative energy* terbarukan seiring berkurangnya cadangan energi fosil (Box, Jenkins, dan Reinsel 2008). Energi matahari yang diubah menjadi listrik dengan penggunaan photovoltaic dipengaruhi oleh beberapa variabel, terutama variabel cuaca seperti suhu, kelembapan, dan radiasi matahari. Fungsi temperatur sel sendiri dibangun oleh iradiasi matahari, suhu sekitar, kecepatan angin dan kelembapan. Dengan

demikian digunakan beberapa metode peramalan atau pemodelan untuk memprediksi performa produksi listrik yang dihasilkan oleh PV baik berskala kecil maupun besar.

2. METODE

Time Series Analysis (Box Jenkins)

Model *time series* adalah pendugaan masa depan dilakukan berdasarkan nilai masa lalu dari suatu variable atau kesalahan masa lalu (Box, Jenkins, dan Reinsel 2008). Tujuan model *time series* seperti itu adalah menemukan pola dalam deret data historis dan mengekstrapolasikan pola tersebut ke masa depan (Slutzky 1937).

Proses AR (Autoregressive)

Autoregresi adalah suatu bentuk regresi yang menghubungkan nilai-nilai sebelumnya dengan diri sendiri pada selang waktu (*time lag*) yang bermacam-macam. Suatu model *autoregresi* akan menyatakan suatu ramalan sebagai fungsi dari nilai-nilai sebelumnya (Yule 1926). Model ini pertama kali diperkenalkan oleh Yule pada 1926. Mengacu pada referensi model *time series autoregresi berorde-p* dengan data $X_t, t \in \mathbb{Z}$ memiliki bentuk:

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

atau ditulis dalam bentuk

$$\phi(B)X_t = a_t$$

dimana $\phi(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$, dengan $\phi_1, \phi_2, \dots, \phi_p$ merupakan parameter-parameter AR bilangan real dan B adalah operator backshift. Sedangkan $a_t \sim WN(0, \sigma^2)$.

a. Proses MA (*Moving average*)

Model runtun waktu *moving average* berorde-q pertama kali diperkenalkan oleh Slutzky dan dibahas oleh Wie, ditulis MA(q) adalah $X_t, t \in \mathbb{Z}$ yang memiliki persamaan dengan bentuk :

$$X_t = a_t + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q}$$

atau ditulis $X_t = \theta(B)a_t$, dimana a_t mengikuti proses white noise dengan mean $E(a_t) = 0$ dan variansi $var(a_t) = \sigma^2$

b. Proses ARMA

Metode yang memperhitungkan efek autoregressive dan juga *moving average* (ARMA) dengan model (Box, Jenkins, dan Reinsel 2013) :

$$(1 - \phi_1 B - \dots - \phi_p B^p)(X_t - \mu) = (1 - \theta_1 B - \dots - \theta_q B^q)a_t$$

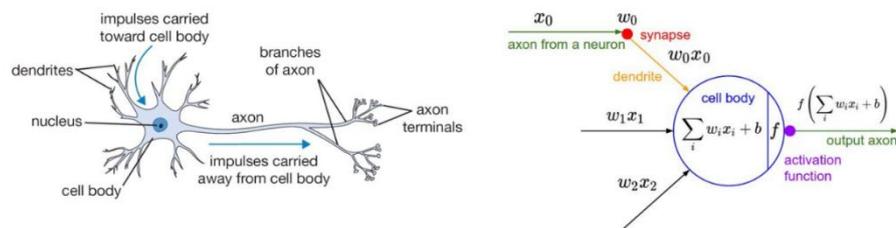
Di mana $a_t, t \in \mathbb{Z}$ adalah white noise dengan mean μ dan variansi σ^2 dan $\phi_1, \phi_2, \dots, \phi_p, \theta_1, \theta_2, \dots, \theta_q \in \mathfrak{R}$. Sedangkan p adalah order autoregressive dan q adalah order *moving average*. Dengan menggunakan operator lag proses ARMA(p,q) dapat ditulis menjadi :

$$\phi(B)X_t = \theta(B)a_t$$

Suatu proses ARMA yang stationer bisa dituliskan sebagai proses MA(∞) sedangkan suatu proses ARMA yang invertible bisa dituliskan sebagai proses AR(∞) (Box, Jenkins, dan Reinsel 2013).

Artificial NN

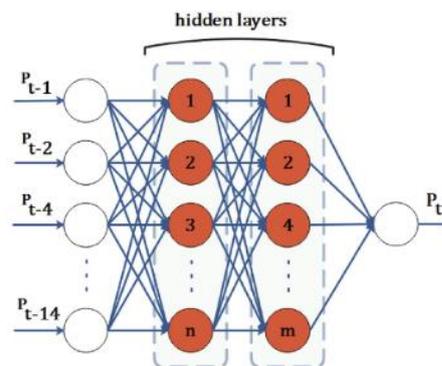
Sebuah Artificial NN mampu mempelajari ketergantungan yang kompleks antara masukan (input) dan keluaran (output). Artificial NN telah banyak digunakan dalam berbagai disiplin penelitian untuk memodelkan fungsi-fungsi nonlinier dan kompleks (Sharadga, Hajimirza, dan Balog 2020).



Gambar 1. Skema Bangunan Neuron

Sumber. <https://medium.com/@samuelsen/pengenalan-deep-learning-8fbb7d8028ac>

Pada *feedforward neural network*, informasi disampaikan dari lapisan masukan (*input layer*) ke lapisan keluaran (*output layer*) melalui lapisan tersembunyi (*hidden layers*) (M. A. Al-Nimr, S. Kiwan, dan H. Sharadga 2018). Dalam penelitian ini, digunakan lapisan *recurrent neural networks layer* karena memiliki respons dinamis terhadap data rangkaian waktu masukan.



Gambar 2. Struktur *Feedforward neural network*

Setiap neuron menerima input dan melakukan operasi *dot product* dengan suatu bobot (*weight*), kemudian menjumlahkannya (*weighted sum*) dengan tambahan sebuah bias. Hasil dari operasi ini digunakan sebagai parameter untuk fungsi aktivasi yang menghasilkan output dari neuron tersebut (Slutzky 1937).

3. HASIL DAN PEMBAHASAN

Statistik Deskriptif

Data pengamatan diambil selama 28 hari yaitu sejak tanggal 13 Oktober 2022 sampai 10 November 2022. Pada tiap-tiap hari-harinya diambil data per 15 menit dari mulai pukul 05:45 sampai 17.00 dimana pada waktu ini matahari menerangi wilayah terpasangnya PV beserta sensor yang sudah dirangkai. Beberapa data hilang sebab tidak terhubung komunikasi antar data maka peneliti melakukan inputasi dengan menggunakan rata-rata pada interval waktu tersebut sedemikian sehingga data seimbang pada tiap harinya memiliki jumlah yang sama.

```

> summary(data)
  Radiasi      Arus      Tegangan  Kelembaban      Suhu
Min. :84.0 Min. :0.230 Min. :5.8 Min. :6.00 Min. :22.87
1st Qu.:295.0 1st Qu.:1.270 1st Qu.:20.3 1st Qu.:13.00 1st Qu.:31.58
Median :300.0 Median :1.290 Median :20.6 Median :19.00 Median :34.50
Mean :293.1 Mean :1.261 Mean :20.2 Mean :28.59 Mean :34.03
3rd Qu.:303.0 3rd Qu.:1.300 3rd Qu.:20.8 3rd Qu.:28.00 3rd Qu.:36.94
Max. :318.0 Max. :1.370 Max. :21.9 Max. :95.00 Max. :42.38

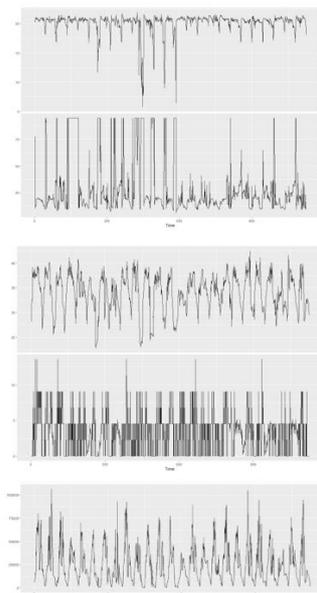
  Angin      Energi      Cahaya  Arus.Tegangan
Min. :0.000 Min. : 9.61 Min. : 195 Min. :1.74
1st Qu.:0.000 1st Qu.: 18.78 1st Qu.: 9437 1st Qu.:25.78
Median :4.520 Median :2132.66 Median :18981 Median :26.57
Mean :3.157 Mean :5997.41 Mean :24402 Mean :25.64
3rd Qu.:4.520 3rd Qu.:11500.15 3rd Qu.:33997 3rd Qu.:27.04
Max. :13.570 Max. :21941.10 Max. :105974 Max. :30.00
NA's :162

```

Gambar 3. Deskriptif Statistik Data Monitoring

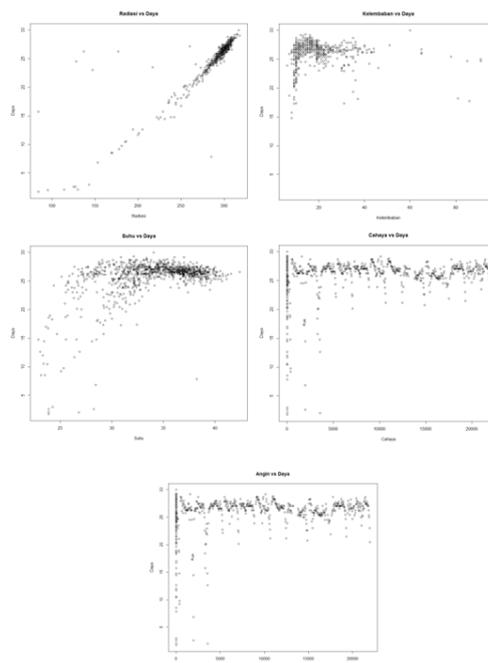
Output di atas menunjukkan rangkuman statistik pada masing-masing variabel. Dalam hal ini data data yaitu Arus. Tegangan merupakan data yang sedang diamati pergerakannya. Sebagaimana kita ketahui bahwa cahaya matahari pada pagi dan sore hari memiliki intensitas yang berbeda dibandingkan pada siang hari. Pada output di atas kita mendapati nilai minimum pada data berada pada angka 1.74 yang mungkin terjadi pada pagi atau sore, dan maksimal berada pada angka 30.00 yang mungkin berada pada siang hari.

Guna melihat pergerakan tiap waktu pengamatannya disajikan dalam grafik yang berada pada lampiran output 1. Pada grafik tampak pergerakan beberapa variabel bernilai besar pada siang hari seperti untuk radiasi, suhu, intensitas cahaya dan juga tegangan. Sedangkan untuk kecepatan angin tidak demikian. Hal ini mengindikasikan hubungan antar variabel yang memungkinkan hubungan yang positif. Untuk mengkonfirmasi keeratn hubungan antar variabel berikut dilakukan analisis regresi dan korelasi.



Gambar 4. Pergerakan Variabel-variabel Penelitian

Guna melihat keeratan hubungan satu-satu antara daya dan beberapa variabel terkait, peneliti melakukan analisis regresi.



Gambar 5. Scatter Plot antara Daya dengan Variabel-variabel Input

Tabel 1. Ringkasan Statistik korelasi Daya dan Variabel Input

Variabel Cuaca	Signifikansi Koefisien Regresi	r^2
Radiasi	Signifikan	0.802
Kelembapan	Signifikan	0.147
Suhu	Signifikan	0.244
Cahaya	Signifikan	0.142
Kecepatan angin	Tidak signifikan	0.0004

Arima

Dalam menjalankan program ARIMA dengan regressor dengan software R, peneliti menggunakan *library 'tseries'*. Dengan menggunakan package '*tseries*' maka R akan otomatis memilih model terbaik dengan menjalankan algoritma ARIMA yaitu diantaranya:

- Cek stasionaritas
- Besaran ACF dan PACF
- Koefisien AR dan MA yang signifikan.
- Kriteria error paling kecil dari diantara opsi yang ada.

Tabel 2. Ringkasan Output ARIMA dengan Regressor Variabel Input

No	Variabel Input	Model Terbaik	Mape	Kategori
1	Radiasi	ARIMA (1,0,1)	3,47%	Baik
2	Kelembapan	ARIMA (0,0,5)	95,11%	Tidak baik
3	Suhu	ARIMA (2,0,1)	12,44%	Baik
4	Cahaya	ARIMA (0,0,1)	63,12%	Tidak baik
5	Kecepatan angin	ARIMA (0,0,5)	96,67%	Tidak baik
6	Suhu dan Radiasi	ARIMA (1,0,1)	3,72%	Baik

7	Radiasi, Kelembaban, Suhu*, Angin dan Cahaya *	ARIMA (0,0,1)	2,91%	Baik
8	Radiasi, Kelembaban, Angin* dan Cahaya*	ARIMA (0,0,2)	2,99%	Baik
9	Radiasi, Kelembaban, Angin *	ARIMA (1,0,1)	3,13%	Baik
10	Radiasi, Kelembaban dan Cahaya	ARIMA (0,0,2)	3,05%	Baik
11	Radiasi, Suhu* dan Cahaya*	ARIMA (0,0,1)	3,11%	Baik

Ket: * tidak signifikan pada taraf 5%.

Tabel di atas merupakan ringkasan dari model terbaik pada masing-masing variabel input. Dari tabel di atas dapat dilihat bahwa kelembaban udara dan kecepatan angin tidak berpengaruh terhadap daya yang dihasilkan. Sebagaimana hasil yang sama diperoleh pada analisis regresi. Begitu juga dengan intensitas cahaya matahari. Kombinasi dari beberapa variabel memberikan model yang lebih baik diantaranya ditunjukkan dengan nilai MAPE yang lebih kecil. Sedangkan MAPE paling kecil ditunjukkan pada model nomor berada pada nomor 7. Akan tetapi pada model ini untuk suhu dan intensitas cahaya tidak memberikan koefisien yang signifikan pada taraf 5%. Untuk model yang signifikan secara keseluruhan ditunjukkan pada model nomor 10, yaitu radiasi, kelembaban dan intensitas cahaya signifikan berpengaruh pada model. Untuk melihat model terbaik dan *forecastnya* untuk beberapa model input yang ada dapat dilihat pada lampiran output.

LSTM

Berbeda dengan model ARIMA, untuk model *neural network* untuk model data time series peneliti menggunakan model LSTM. Beberapa referensi menyebutkan bahwa LSTM adalah model *neural network* yang direkomendasikan untuk data *time series*. Sebab LSTM adalah model non linier maka tidak terdapat koefisien atau parameter yang diestimasi yang dapat direpresentasikan pada pergerakan data. Sedemikian sehingga evaluasi pembelajaran LSTM hanya berdasarkan kriteria error yang dihasilkan. Untuk melihat besaran error MAPE pada masing-masing output dapat dilihat pada tabel berikut ini.

Tabel 3. Perbandingan MAPE pada LSTM

Variabel Input Cuaca	MAPE	
	ARIMAX	LSTM
Radiasi	3,47%	3,74%
Kelembaban	95,11%	3,47%
Suhu	12,44%	7,31%
Cahaya	63,12%	5,19%
Kecepatan angin	96,67%	3,89%
Suhu dan Radiasi	3,72%	3,59%
Radiasi, Kelembaban, Suhu, Angin dan Cahaya	2,91%	3,52%
Radiasi, Suhu dan Cahaya	3,11%	3,41%

Berdasarkan tabel di atas dapat dilihat hampir keseluruhan kemungkinan variabel input memberikan MAPE yang kecil. Berbeda pada ARIMA yang mengekspose model yang baik dan tidak sehingga menghasilkan kriteria error yang bersesuaian. Keseluruhan error yang dihasilkan berada dibawah 10% dan paling rendah dihasilkan pada variabel input ke 8 dengan MAPE sebesar 3,41%. Jika dibandingkan dengan model ARIMA terbaik memberikan MAPE sebesar 3,05%. Dengan demikian dapat disimpulkan model ARIMA mampu memberikan MAPE yang lebih kecil dibandingkan dengan penggunaan *Neural Network* (LSTM). Selain itu kelebihan dari model ARIMA

yang dihasilkan terdapat nilai koefisien variabel input dan parameter AR dan MA yang dapat diterjemahkan dengan baik.

4. KESIMPULAN

Model ARIMA dengan regressor diperoleh model terbaik pada ARIMA (0,0,2) dengan semua variabel cuaca (Radiasi, Kelembaban, Suhu*, Angin dan Cahaya *) terlibat di dalamnya dengan MAPE 2,91%. Sedangkan untuk model dengan variabel input yang keseluruhannya signifikan (Radiasi, Kelembaban dan Cahaya) diberikan pada ARIMA (0,0,2) dengan MAPE 3,04%. Sedangkan untuk model NN (LSTM) terbaik dengan inputan radiasi, suhu dan intensitas dengan MAPE 3,41%. Jika dibandingkan keduanya maka model ARIMA memberikan model yang lebih baik dibandingkan dengan NN (LSTM).

REFERENSI

- Box, George E. P., Gwilym M. Jenkins, dan Gregory C. Reinsel. 2008. *Time Series Analysis*. Wiley. <https://doi.org/10.1002/9781118619193>.
- Box, George E.P., Gwilym M. Jenkins, dan Gregory C. Reinsel. 2013. *Time series analysis: Forecasting and control: Fourth edition. Time Series Analysis: Forecasting and Control: Fourth Edition*. <https://doi.org/10.1002/9781118619193>.
- M. A. Al-Nimr, S. Kiwan, dan H. Sharadga. 2018. "Simulation of a novel hybrid solar photovoltaic/wind system to maintain the cell surface temperature and to generate electricity." *Int. J. Energy Res* 42 (3).
- Sharadga, Hussein, Shima Hajimirza, dan Robert S. Balog. 2020. "Time series forecasting of solar power generation for large-scale photovoltaic plants." *Renewable Energy* 150 (Mei): 797–807. <https://doi.org/10.1016/j.renene.2019.12.131>.
- Slutzky, Eugen. 1937. "The Summation of Random Causes as the Source of Cyclic Processes." *Econometrica* 5 (2): 105. <https://doi.org/10.2307/1907241>.
- Yule, G. Udny. 1926. "Why do we Sometimes get Nonsense-Correlations between Time-Series?--A Study in Sampling and the Nature of Time-Series." *Journal of the Royal Statistical Society* 89 (1): 1. <https://doi.org/10.2307/2341482>.

