

# Forecasting Produksi Energi PLTS 1 kWp Menggunakan Mesin Pembelajaran Dengan Algoritma Support Vector Machine

HASANUDIN GUFRON<sup>1</sup>, DANI RUSIRAWAN<sup>2</sup>, LITA WIDYAWATI<sup>3</sup>

Institut Teknologi Nasional Bandung  
Email: [hasanudin.bblm@gmail.com](mailto:hasanudin.bblm@gmail.com)

## ABSTRAK

Isu krisis energi menuntut orang mencari sumber energi alternatif, PLTS menjadi pilihan yang menjanjikan untuk menjawab tantangan krisis energi tersebut. Namun PLTS tergantung oleh kondisi cuaca, sangat sulit memperkirakan berapa produksi energi pada suatu system PLTS. Penelitian peramalan produksi energi 1kWp menggunakan mesin pembelajaran dan *support vector machine* (SVM) telah dilakukan dan dibandingkan dengan model *multiple linear regression* (MLR), model peramalan dengan pendekatan deret waktu, data training periode Januari – Desember 2021 dan data tes periode Januari – Mei 2022. Konstruksi ramalannya adalah hasil produksi tiga hari kebelakang meramalkan produksi energi hari berikutnya. Hasil evaluasi MAPE pada data training SVM dan MLR adalah 19.79% dan 23.96%, sedangkan pada testing 21,79% dan 20.45%. Hasil peramalan harian diakumulasi perbulan dan dievaluasi, hasilnya MAPE 4.13% dan 5.56% masing-masing untuk SVM dan MLR. Kedua model SVM dan MLR layak dikembangkan lebih lanjut pada *forecasting* PLTS 1 kWp berdasarkan data deret waktu.

**Kata kunci:** *plts, support vector machine, machine learning, forecasting*

## ABSTRACT

*The issue of the energy crisis requires people to look for alternative energy sources, SPP is a promising choice to answer the challenges. However SPP depends on weather conditions, it is very difficult to estimate energy production. Research on forecasting 1kWp energy production using machine learning and SVM has been carried out and compared with MLR, forecasting models with a time series approach, training data for the period January – December 2021 and test data for the period January – May 2022. MAPE evaluation results on SVM and MLR training data were 19.79% and 23.96%, while testing was 21.79% and 20.45%. Daily forecasting results are accumulated monthly and evaluated, the results are MAPE 4.13% and 5.56% for SVM and MLR, respectively. Both SVM and MLR models deserve to be further developed in forecasting PLTS 1 kWp based on time series data.*

**Keywords:** *plts, support vector machine, machine learning, forecasting*

### 1. PENDAHULUAN


Isu krisis energi yang ditandai oleh kenaikan harga yang sangat tinggi dua sumber energi primer yaitu batu bara dan gas alam (**Effendi, 2021**) menuntut kita mencari sumber energi alternatif, PLTS dengan memanfaatkan energi surya menjadi pilihan yang menjanjikan untuk menjawab tantangan krisis energi tersebut. Indonesia memiliki potensi yang sangat besar energi baru terbarukan, seperti yang dilaporkan dalam Indonesia Energy Outlook 2019 total potensi energi terbarukan ekuivalen 442 GW dan setengah diantaranya adalah potensi energy surya, profil potensi energi terbarukan di Indonesia dapat dilihat pada Tabel 1. (**Suharyati et al., 2019**).

**Tabel 1. Potensi Energi Terbarukan (Suharyati et al., 2019)**

Jenis Energi	Potensi
Tenaga Air	94,3 GW
Panas Bumi	28,5 GW
Bioenergi	PLT Bio: 32,6 GW dan BBN: 200 Rbu Bph
Surya	207,8 GWp
Angin	60,6 GW
Energi Laut	17,9 GW

Energi surya sebagai potensi energi terbesar dalam bauran sumber energi terbarukan memiliki tantangannya sendiri, yaitu produksi energinya sangat tergantung dari kondisi lokal atmosfer atau cuaca, yang mencakup uap air, awan dan polusi (**Yulianto, 2017**) sehingga produksi energinya sangat sulit diperkirakan, tidak seperti pembangkit listrik konvensional, sumber daya tidak dapat diakses dan dipenuhi sesuai permintaan (**Wolff et al., 2017**)

Untuk menjawab tantangan estimasi produksi energi pada suatu system PLTS penelitian mengenai peramalan produksi pada PLTS muncul sebagai ide brilian (**Sobri et al., 2018**). Para peneliti melakukan dua metode pendekatan yaitu menggunakan persamaan analitik dan metoda statistik dengan metoda *machine learning* (ML), selain itu ada juga dengan pendekatan campuran atau *hybrid* model, (**Antonanzas et al., 2016**) melaporkan *forecasting* produksi energi pada PLTS 72% menggunakan model statistik, 17% menggunakan model *hybrid*, dan 11% menggunakan model fisika, seperti pada Gambar 1



**Gambar 1. Distribusi Kajian Forecasting Produksi Energi Berdasarkan Metod (Antonanzas et al., 2016)**

ML sendiri adalah cabang artificial intelligent (AI) yang secara sistematis menerapkan algoritme untuk mensintesis hubungan mendasar antara data dan informasi. Tujuan ML adalah untuk memprediksi kejadian atau skenario masa depan yang tidak diketahui oleh computer **(Awad & Khanna, 2015)**

Pada tahun 1959, ML digambarkan oleh Arthur Samuel sebagai "bidang studi yang memberikan komputer kemampuan untuk belajar tanpa diprogram secara eksplisit" Dia menyimpulkan bahwa kebutuhan akan banyak upaya pemrograman terperinci ini dihilangkan karena komputer belajar dari pengalaman **(Samuel, 1959)**. Adapun dalam proses pembelajaran yang dimaksud suatu usaha dalam mendapatkan kecerdasan melalui tahap latihan, validasi, dan pengujian **(Putra, 2020)**.

Penelitian ini mengusulkan pembuatan model *Forecasting* produksi energi pada PLTS 1 kWp ITENAS yang berdasarkan data produksi energy harian secara deret waktu, untuk memprediksi periode selanjutnya. Algoritma Support Vector Machine (SVM) digunakan pada pembelajaran mesin untuk membuat model memprediksi masa depan dengan. SVM dengan pengembangan analisa regresi menjadi Support Vector Regression (SVR) adalah salah satu metoda pembelajaran yang dikembangkan dari teori statistik yang memiliki kinerja terbaik untuk mengklasifikasikan data yang tidak linier dibandingkan metoda lain **(Shi et al., 2012)**

SVM memiliki kinerja yang lebih baik dari model multiple linear regression dan artificial neural network (ANN) seperti dilaporkan oleh (Abuella & Chowdhury, 2016) dalam laporannya mengenai peramalan *solar power* dengan variabel cuaca.

Dalam laporan peneliti lain, dilaporkan bahwa model peramalan SVM yang menggabungkan semua fitur input mampu menghasilkan prediksi lebih baik dari model pedekatan fisika dan memiliki akurasi yang sama dengan PV model simulasi **(Wolff et al., 2016)**

Sebagaimana model *machine learning* pada umumnya, model selalu dibangun dengan konstruksi data dibagi menjadi dua yaitu data latih dan data tes, pada penelitian ini data latih adalah produksi energi Januari – Desember 2021 dan data tes adalah produksi energi Januari – Mei 2022.

Selanjutnya dalam artikel ini metoda membangun model *forecast* dengan SVM berdasarkan data deret waktu, hasil evaluasi pada data latih dan data tes akan dipaparkan, juga hasil evaluasi *forecast* periode bulanan sebagai dasar evaluasi model *forecast* apakah sangat baik, baik, layak atau buruk.

## 2. METODOLOGI

### 2.1 Tinjauan Sistem


Sistem PLTS yang dikaji adalah PLTS Itenas 1 kWp, tepatnya berkolasi di *rooftop* Gedung Fakultas Arsitektur dan Desain, menggunakan 4 buah modul surya berkapasitas masing-masing 265 Wp ditanam secara permanen menggunakan rangka baja dengan sudut kemiringan 12° menghadap utara, dan dengan *grid-connected system*. Letak geografis PLTS Itenas 1 kWp dijelaskan pada tabel 2 dan foto fisik PLTS-nya pada Gambar 2. **(HIDAYAT et al., 2019)**.

**Tabel 2. Letak geografis PLTS ITENAS 1 kWp**

Lokasi, Kota	Bandung			
Negara, Kawasan	Indonesia, Asia Tenggara			
	Desimal	Derajat	Menit	
Latitude	-6,92	-6	55	+ = Utara, - = Selatan
Longitude	107,60	107	36	+ = Timur, - = Barat <i>Greenwich</i>
Altitude	698	Meter diatas permukaan laut		
Tilt angel	12	Azimut		



(a)



(b)

**Gambar 2. (a) PLTS ITENAS 1 kWp, (b) Skema on-grid connected PLTS ITENAS 1 kWp**

**(HIDAYAT et al., 2019)**

## 2.2 Data

Penelitian ini mengobservasi data rekaman harian produksi energi di PLTS Itenas pada rentang Januari 2021 – Mei 2022. Pengunduhan data dilakukan per 30 hari lalu di organisir menjadi data set dalam bentuk file *spread sheet* dengan bentuk data 516 baris dan dua kolom, yang terdiri dari kolom tanggal dan jumlah produksi energi (kWh) pada tanggal tersebut seperti ditunjukkan pada tabel 3.

Pada pembuaran model peramalan dengan data deret waktu, kestasioneritasan data sangat penting karena berpengaruh luar biasa pada bagaimana data dirasakan dan diramalkan. Saat meramalkan masa depan, sebagian besar model deret waktu berasumsi bahwa setiap titik tidak tergantung satu sama lain. Suatu data bersifat stasioner jika sifat statistik suatu system tidak berubah seiring waktu **(Rasheed, 2020)**

Pengujian kestasioneritasan secara statistik dilakukan dengan 3 metode, yaitu pengujian data *outlier* untuk mencari data dengan nilai ekstrim, pencilan, atau tidak mengikuti pola umum pada data set yang diobservasi, karena asumsi kenormalan data dipengaruhi oleh *outlier* (Srinadi, 2014). Kedua pengujian distribusi normal yang bertujuan untuk menilai apakah sebaran data yang diobservasi terdistribusi normal atau tidak **(Januarsjaf, 2019)**. Ketiga pengujian *Augmented Dickey Fuller test* (ADF *test*) yang merupakan metode pengujian populer saat ini karena adanya kemungkinan autokorelasi pada *error term* jika data tidak stasioner telah dipertimbangkan **(Aktivani, 2021)**

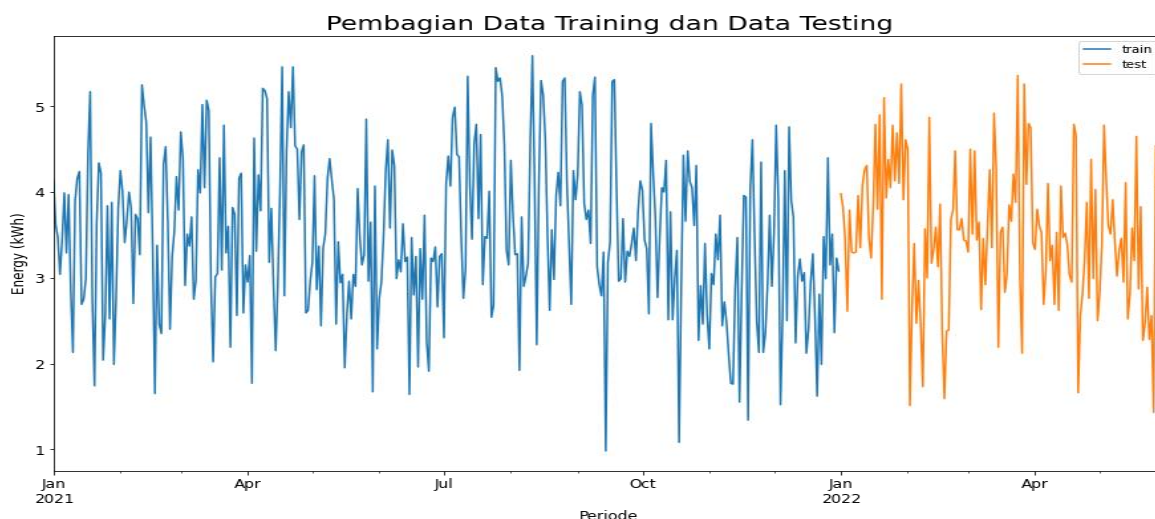
**Tabel 3. Data yang diobservasi**

	Date	Energi (kwh)
0	2021-01-01	4.14
1	2021-01-02	3.62
2	2021-01-03	3.47
3	2021-01-04	3.04
4	2021-01-05	3.44
...	...	...
511	2022-05-27	4.54
512	2022-05-28	4.09
513	2022-05-29	4.32
514	2022-05-30	2.07
515	2022-05-31	2.78

516 rows x 2 columns

### 2.3 Split Data Training dan Data Tes

Data set dibagi menjadi data training dan data tes, pembagian data tidak dilakukan secara random, tapi dengan cara periodical 1 tahun penuh, dengan tujuan data *training* pada rentang Januari s.d Desember 2021 bisa membaca pola *seasonal* dan *trend* pada data *test* tahun berikutnya Januari s.d Mei 2022. Profil prduksi energi harian pada data training dan data test diplot kedalam grafik seperti pada Gambar 3.

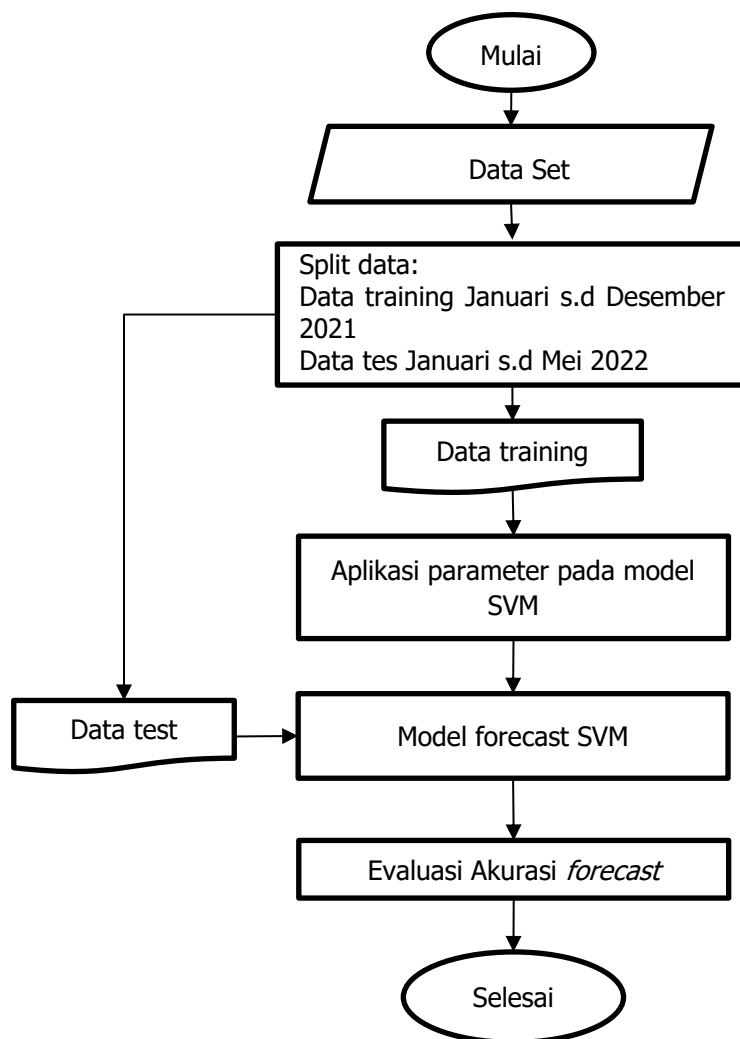


**Gambar 3 Profil Produksi Energi PLTS ITENAS 1 kWp pada data training dan data test**

Grafik berwarna biru adalah profil produksi energi harian selama satu tahun penuh Januari - Desember 2021 sebagai data training, dan grafik warna oranye adalah sebagai data test.

## 2.4 Pemodelan Machine Learning SVM

Model *machine learning* SVM dibuat berdasarkan kerangka kerja yang ditunjukkan oleh Gambar 4.



**Gambar 4 Diagram Alir Pembuatan Model SVM**

Pada pembuatan model deret waktu SVM untuk memprediksi masa yang akan datang dilakukan dengan pendekatan data hasil produksi energi 3 hari sebelumnya memprediksi hari berikutnya. Data – data hari sebelumnya didefinisikan sebagai *feature* atau variabel bebas dan data hari berikutnya didefinisikan sebagai label atau target yang merupakan variabel terikat akibat *feature* yang terjadi.

Data set akan di bagi menjadi dua bagian, yaitu sebagai data *training* dan data *test*. Adapun sebagai data training akan digunakan data periode Januari – Desember 2021, dan data test periode Januari – Mei 2022. Data *training* dikenalkan atau dilatihkan pada algoritma SVM untuk mengenali pola berdasarkan *features* untuk memprediksi target.

Model *machine learning* SVM dibuat menggunakan *notebook Colab* yang merupakan *platform* terbuka dari Google LLC untuk mengeksekusi Python di browser Google Chrome, persamaan – persamaan matematik pada algoritma SVM ini akan dikerjakan secara komputasi

## 2.5 Evaluasi Model Forecast

Performa model peramalan bisa diukur oleh beberapa metode statistik populer, pada penelitian ini akan menggunakan model evaluasi metoda Mean Absolute Percentage Error (MAPE). Evaluasi MAPE merupakan ukuran kesalahan relative yang digunakan untuk mengetahui persentase penyimpangan (error) hasil prediksi dari nilai sebenarnya. Pengukuran persentase *error* memiliki kelebihan menjadi *scale-independent* dan sering digunakan untuk membandingkan performa peramalan antara kumpulan data yang berbeda (Nabillah & Ranggadara, 2020). Pengukuran performa menggunakan MAPE akan menghasilkan nilai berupa persentase. Semakin kecil nilai MAPE maka akan semakin bagus peramalan tersebut. Adapun rumus dari MAPE adalah sebagai berikut:

$$MAPE(y, \hat{y}) = \left( \frac{1}{n} \sum_{i=0}^n \left( \frac{|y - \hat{y}|}{y} \right) \right) \times 100\% \quad (2-1)$$

Nilai MAPE memiliki interpretasi pada suatu model yang dibuat, seperti dilaporkan oleh (Montaño Moreno et al., 2013), mengenai interpretasi nilai MAPE disajikan pada tabel 4.

Tabel 4. Interpretasi nilai MAPE

MAPE(%)	Interpretation
<10	Akurasi peramalan tinggi
10 – 20	Peramalan baik
20 – 50	Peramalan layak/memadai
>50	Peramalan buruk

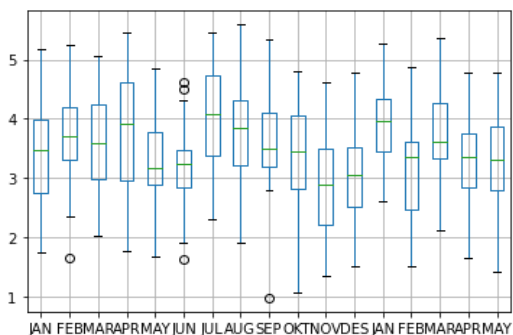
(Montaño Moreno et al., 2013)

## 3. HASIL DAN PEMBAHASAN

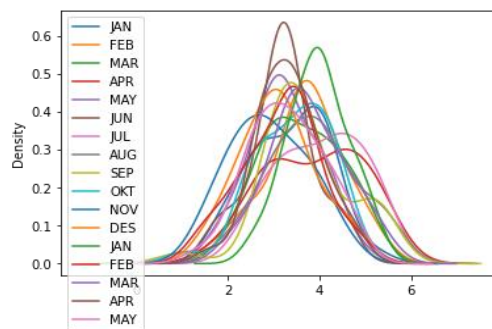
### 3.1 Preprocessing Data

Hasil pengujian data *outlier* pada sebaran bulan, dengan metoda *box-plot*, terdapat beberapa data *outlier* pada bulan Februari, Juni, dan September 2021. Sebaran data *outlier* ditunjukkan pada Gambar 5. Gambar 6, menunjukkan profil grafik distribusi normal perbulan ditampilkan dalam satu grafik.


Lalu dilakukan pengujian distribusi normal secara keseluruhan yang hasilnya ditunjukkan pada pada Gambar 7, pada Gambar 7 grafik cenderung simetris membentuk lonceng, sehingga bisa dikatakan bahwa data telah stasioner, dengan demikian beberapa data *out-lier* pada bulan Februari, Juni, dan September bisa diabaikan dan masuk dalam observasi pembuatan model SVM dan LR



Gambar 5 Hasil pengujian data outlier



Gambar 6. Grafik distribusi normal per bulan



Gambar 7. Grafik distribusi normal Januari 2021 s.d Mei 2022

Pengujian berikutnya dengan fungsi *Adfuller Test* yang merupakan pengujian secara kuantitatif. Hasilnya ditunjukkan pada table 4.1. Dengan melihat table 4.1 *P-Values* bernilai 0, sehingga hipotesa 0 ditolak, dengan kata lain data tersebut sudah stasioner.

Tabel 5 Hasil Pengujian Adfuller Test

ADF Statistic :	-9.022006
P-Values :	0.000000
Lag Number :	3
Observed :	512
Critical Values :	1%: -3.443 5%: -2.867 10%: -2.570

Dari hasil ketiga metode pengujian kestasioneran data, dapat diambil kesimpulan bahwa data original tersebut sudah stasioner dan layak sebagai data set pembuatan model *forecasting*.


### 3.2 Pelatihan Model SVM Pada Data Training

Sebelum melakukan pelatihan model, perlu didefinisikan terlebih dahulu pada data deret waktu mana yang bertindak sebagai *feature* dan sebagai target. konstruksi model *forecast* adalah mendefinisikan 3 hari sebelumnya adalah *feature* dan hari berikutnya adalah target. Sehingga



## Forecasting Produksi Energi PLTS 1 kWp menggunakan Mesin Pembelajaran dengan Algoritma Support Vector Machine

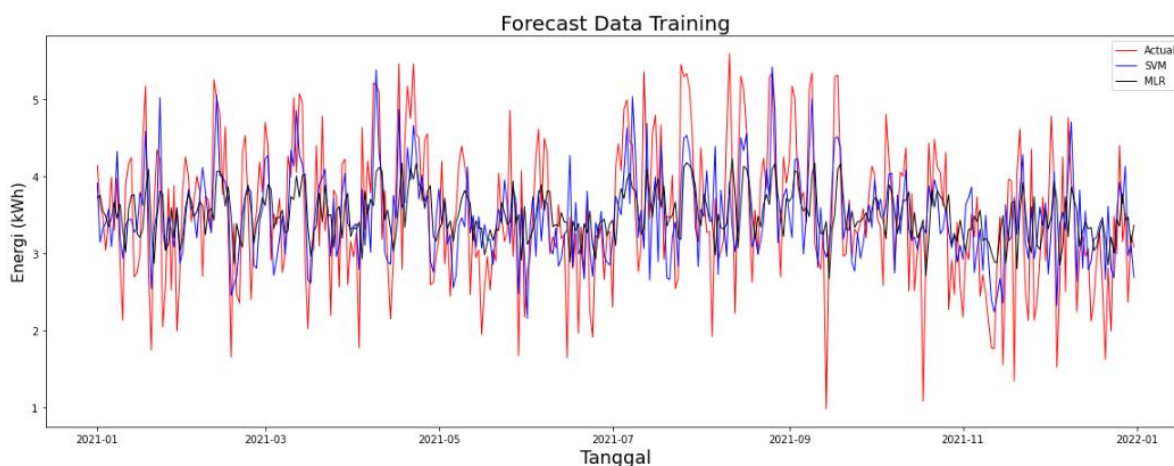
data perlu direkonstruksi sehingga memiliki 3 feature dan 1 target. Prosesnya seperti ditunjukkan pada Gambar 8.



**Gambar 8. (a) Merubah deret waktu menjadi np array 4 kolom, (b) Data *feature*, dan (c) Data target**

Setelah data direkonstruksi menjadi *feature* dan target, selanjutnya model SVM dilatih dengan data tersebut, sehingga mendapatkan model *forecast SVM*. Model *forecast SVM* diuji dengan data latih untuk melihat akurasi dan diplot pada grafik dengan membandingkan dengan data latih aktual.

Hasil plot model *forecast SVM* berdasarkan data latih dapat dilihat pada Gambar 9 disandingkan dengan model *Multiple Linear Regression (MLR)* sebagai pembandingan. Grafik berwarna merah adalah data aktual, grafik berwarna biru adalah hasil forecast model SVM, dan grafik berwarna hitam adalah forecast model MLR.



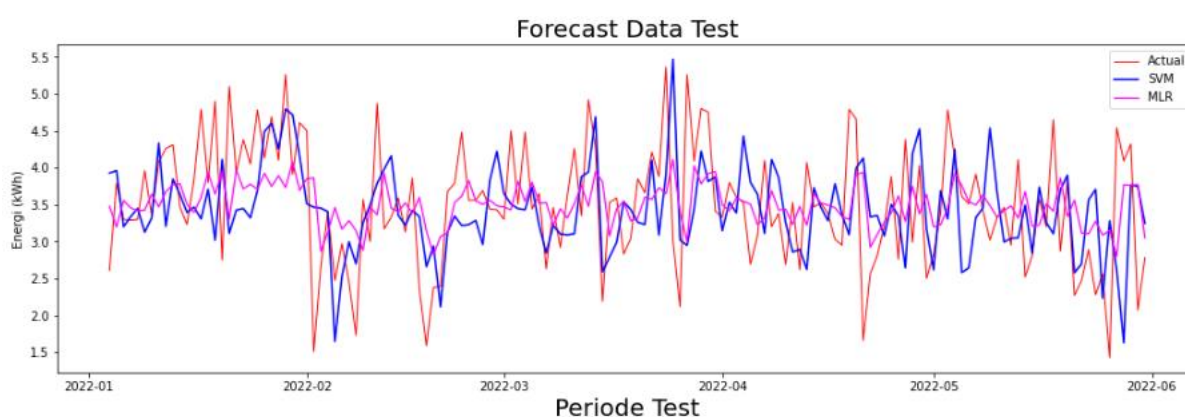
**Gambar 9. Hasil Forecast Data Training**

Dari Gambar 9 bisa dilihat bahwa hasil *forecast SVM* mengikuti pola pergerakan data aktual, begitu halnya dengan model MLR meskipun tidak terlalu *fit* dengan data aktual. Terlihat secara jelas bahwa pada produksi energi kurang dari 2 kWh, grafik prediksi tidak dapat memprediksi secara akurat, hal ini disebabkan oleh algoritma model menganggap bahwa itu adalah *out lier*. Namun secara keseluruhan untuk mengetahui seberapa percaya diri model *forecast SVM* yang telah dilatih, dilakukan evaluasi MAPE, dan hasilnya adalah 19.57% untuk SVM dan 22.96% untuk MLR. Hasil yang cukup baik dan wajar untuk sebuah model *forecasting*.

### 3.3 Forecast Model SVM Pada Data Tes

Selanjutnya model yang telah dilatih, diaplikasikan untuk melakukan *forecasting* pada data tes, yaitu periode Januari – Mei 2022. Hasil *forecasting* SVM pada data test dan data aktual diplot dalam grafik yang ditunjukkan pada Gambar 10 untuk mengetahui gambaran kualitatif antara hasil *forecasting* dan data aktual.


Grafik berwarna merah adalah data aktual, grafik berwarna biru adalah hasil *forecast* SVM, dan grafik berwarna ungu adalah hasil *forecast* MLR. Tampak bahwa hasil forecasting SVM lebih berani untuk melakukan *fitting* puncak dan lembah dibandingkan dengan model MLR yang relative berada ditengah dalam rentang standar deviasinya. Hasil evaluasi MAPE pada data tes yaitu 21.79% untuk SVM dan 20.45% untuk MLR. MAPE Hasil *forecasting* pada data tes tidak terlalu jauh dengan hasil *forecasting* pada data training, hal ini menunjukkan bahwa model telah dilatih baik pada data training.



Gambar 10 Hasil Forecast Data Test.

### 3.4 Forecast Keseluruhan Data


Model SVM dan MLR di aplikasikan untuk melakukan *forecast* pada keseluruhan data observasi, untuk mengetahui performanya secara umum. Kedua model melakukan *forecast* secara harian, Hasil *forecast* pada seluruh data ditunjukkan pada Gambar 11. Grafik berwarna merah adalah data aktual, grafik berwarna biru adalah hasil *forecast* SVM, dan grafik berwarna ungu adalah hasil *forecast* MLR. Hasil evaluasi MAPE pada data seluruh 20.19% untuk SVM dan 22.16% untuk MLR. MAPE kedua model dalam kategori peramalan baik, namun model SVM menunjukkan performa lebih baik dari model MLR.



Gambar 11 Hasil Forecast Pada Seluruh Data

### 3.5 Forecast Periode Bulanan

Hasil *forecast* model SVM dan MLR pada seluruh data harian di kelompokkan berdasarkan bulan lalu dijumlahkan produksinya per bulan, mulai dari bulan Januari 2021 sampai bulan Mei 2022. Pembahasan periode bulanan untuk melihat berapa error yang terjadi. Hasilnya diplot dengan diagram batang ditunjukkan pada Gambar 12.



Gambar 12 Hasil Forecast Periode Bulanan

Dari Gambar 12 terlihat bahwa hasil forecast perbulan memiliki error yang kecil, dilihat dari dekatnya puncak antar batang diagram, perbedaan mencolok hanya pada bulan Juni 2022 dan Januari 2022.

Berdasarkan data aktual produksi energi periode Januari 2021 sampai Mei 2022 adalah 1807.88 kWh, hasil forecast SVM 1790.92 kWh, dan forecast MLR 1807.77 kWh. Secara keseluruhan data kedua model memiliki error yang sangat kecil. Evaluasi MAPE SVM adalah 4.13% dan MLR 5.56%. Dengan demikian kedua model memiliki error yang kecil untuk forecast periode bulanan dan dalam kategori "akurasi peramalan tinggi".

## 4. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan, dapat disimpulkan bahwa algoritma SVM dapat diimplementasikan untuk meramal produksi energi PLTS 1 kWp berdasarkan data deret waktu. Dalam peramalan produksi energi harian evaluasi MAPE pada data training masing – masing sebesar 19.79% dan 23.96%, sedangkan pada data tes adalah masing – masing sebesar 21.79% dan 20.45%, sehingga kedua model disimpulkan dalam kategori layak untuk melakukan peramalan produksi energi berdasarkan data deret waktu.

Hal menarik ditemukan ketika seluruh data peramalan produksi energi diakumulasi per bulan dan dibandingkan dengan data aktual, ditemukan bahwa persentase absolut errornya kecil dan jika dirata-ratakan persentase errornya (MAPE) adalah 4.13% dan 5.56% masing – masing untuk model SVM dan MLR. Sehingga disimpulkan bahwa secara akumulatif bulanan

hasil peramalan model SVM dan MLR dalam kategori tingkat peramalan tinggi berdasarkan interpretasi hasil peramalan.

Berdasarkan hasil performa pada data training, testing, keseluruhan data, dan akumulasi produksi energi bulanan, algoritma *machine learning* SVM dan MLR keduanya layak dikaji lebih lanjut untuk peramalan produksi energi PLTS 1 kWp.

## DAFTAR RUJUKAN

- Abuella, M., & Chowdhury, B. (2016). Solar power forecasting using support vector regression. *2016 International Annual Conference of the American Society for Engineering Management, ASEM 2016*.
- Aktivani, S. (2021). Uji Stationeritas Data Inflasi Kota Padang Periode 2014-2019. *Jurnal Statistika Industri Dan Komputasi*, 6(1), 26–33.
- Antonanzas, J., Osorio, N., Escobar, R., Urraca, R., Martinez-de-Pison, F. J., & Antonanzas-Torres, F. (2016). Review of photovoltaic power forecasting. *Solar Energy*, 136, 78–111. <https://doi.org/10.1016/j.solener.2016.06.069>
- Awad, M., & Khanna, R. (2015). *Efficient Learning Machine: Theories, Concepts, and Applications for Engineers and Systems Designers*. apress.
- Effendi, B. S. (2021). *Analisis Krisis Energi Dunia 2021 dan Lesson Learned bagi Indonesia*. Mediaindonesia.Com. <https://mediaindonesia.com/opini/444518/analisis-krisis-energi-dunia-2021-dan-lesson-learned-bagi-indonesia>
- HIDAYAT, F., RUSIRAWAN, D., & FAJAR TANJUNG, I. R. (2019). Evaluasi Kinerja PLTS 1000 Wp di Iteas Bandung. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 7(1), 195. <https://doi.org/10.26760/elkomika.v7i1.195>
- Januarsjaf, A. (2019). *Stat Uji Normalitas Data*. RStudio. <https://rpubs.com/aswinjanuarsjaf/514884>
- Montaño Moreno, J. J., Palmer Pol, A., Sesé Abad, A., & Cajal Blasco, B. (2013). El índice R-MAPE como medida resistente del ajuste en la previsión. *Psicothema*, 25(4), 500–506. <https://doi.org/10.7334/psicothema2013.23>
- Nabillah, I., & Ranggadara, I. (2020). Mean Absolute Percentage Error untuk Evaluasi Hasil Prediksi Komoditas Laut. *JOINS (Journal of Information System)*, 5(2), 250–255. <https://doi.org/10.33633/joins.v5i2.3900>
- Putra, J. W. G. (2020). *Pengenalan Konsep Pembelajaran Mesin dan Deep Learning Edisi 1.4 (17 Agustus 2020)*. 4, 45–46.
- Rasheed, R. (2020). *Why Does Stationarity Matter in Time Series Analysis? Towards Data Science*. <https://towardsdatascience.com/why-does-stationarity-matter-in-time-series-analysis-e2fb7be74454>
- Samuel, A. L. (1959). Eight-move opening utilizing generalization learning. (See Appendix B, Game G-43.1 Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal*, 210–229.
- Shi, J., Lee, W. J., Liu, Y., Yang, Y., & Wang, P. (2012). Forecasting power output of photovoltaic systems based on weather classification and support vector machines. *IEEE Transactions on Industry Applications*, 48(3), 1064–1069. <https://doi.org/10.1109/TIA.2012.2190816>
- Sobri, S., Koohi-Kamali, S., & Rahim, N. A. (2018). Solar photovoltaic generation forecasting methods: A review. *Energy Conversion and Management*, 156(December 2017), 459–497. <https://doi.org/10.1016/j.enconman.2017.11.019>
- Srinadi, G. A. M. (2014). Pengaruh Outlier Terhadap Estimator Parameter Regresi dan Metode Regresi Robust. *Prosiding Konferensi Nasional Matematika XVII - 2014, June 2014*, 1259–

1266.

- Suharyati, Pambudi, H. S., Wibowo, J. L., & Pratiwi, N. I. (2019). *Indonesia Energy Outlook 2019* (S. Abdurrahman, M. Pertiwi, & Walujanto (eds.)). Dewan Energi Nasional.
- Wolff, B., Kühnert, J., Lorenz, E., Kramer, O., & Heinemann, D. (2016). Comparing support vector regression for PV power forecasting to a physical modeling approach using measurement, numerical weather prediction, and cloud motion data. *Solar Energy*, *135*, 197–208. <https://doi.org/10.1016/j.solener.2016.05.051>
- Wolff, B., Sauer, J., Kramer, O., & Parisi, J. (2017). *Support Vector Regression for Solar Power Prediction*. April.
- Yulianto, B. (2017). *Memanen Energi Matahari*. Penerbit ITB.