

# Prediksi Tegangan Catu Daya *Automatic Rain Gauge* berdasarkan *Seasonality* Algoritma Prophet

ERICH PUTRA RAMDHANI, HAPSORO AGUNG NUGROHO

Sekolah Tinggi Meteorologi Klimatologi dan Geofisika, Indonesia  
Email: [hapsoro.agung@stmkg.ac.id](mailto:hapsoro.agung@stmkg.ac.id)

*Received* 20 September 2023 | *Revised* 11 Oktober 2023 | *Accepted* 29 Oktober 2023

## ABSTRAK

*Automatic Rain Gauge (ARG) adalah sebuah alat yang digunakan untuk melakukan pemantauan dan mengukur curah hujan pada suatu daerah dengan satuan waktu secara otomatis. ARG mampu merekam data curah hujan secara kontinu selama 24 jam. Salah satu elemen kunci dari ARG adalah komponen catu daya. Jika terjadi gangguan pada komponen ini, hal tersebut dapat menghambat proses pengamatan curah hujan yang dijalankan oleh BMKG. Penelitian ini dilakukan untuk meminimalisir terjadinya permasalahan pada catu daya dengan merancang model untuk memprediksi tegangan catu daya ARG dengan memanfaatkan data hasil monitoring menggunakan sensor INA219. Proses prediksi dilakukan dengan menggunakan parameter seasonality daily true, seasonality weekly false, dan seasonality false dan seasonality mode additive dimana diperoleh nilai MAE sebesar 0.21 dan MAPE sebesar 1.67%.*

**Kata kunci:** curah hujan, automatic rain gauge, prediksi, tegangan

## ABSTRACT

*The Automatic Rain Gauge (ARG) is a device utilized to automatically monitor and measure rainfall in a specific area over time intervals. ARG is capable of continuously recording rainfall data for 24 hours. A key element of the ARG is its power supply component. If there is a disruption to this component, it can hinder the process of rainfall observation. Carried out by BMKG. This research is conducted to minimize issues with the power supply by designing a model to predict the voltage of the ARG's power supply using data obtained from monitoring using the INA219 sensor. The prediction process is carried out using parameters such as daily seasonality true, weekly seasonality false, and yearly seasonality false and additive seasonality mode. The obtained MAE value is 0.21 and the MAPE value is 1.67%.*

**Keywords:** rainfall, automatic rain gauge, predict, voltage

## 1. PENDAHULUAN

Curah hujan merupakan ketinggian air hujan yang tidak menguap, meresap, dan mengalir pada suatu tempat yang datar (**Ajr & Dwirani, 2019**). Pengumpulan informasi mengenai curah hujan adalah salah satu tugas yang dilakukan oleh Badan Meteorologi Klimatologi dan Geofisika (BMKG), yang berperan sebagai sumber data yang bernilai dalam berbagai sektor (**Rafi, dkk, 2018**). Proses pengumpulan informasi curah hujan yang dilakukan oleh BMKG dilakukan dengan menggunakan peralatan, seperti penakar hujan OBS, penakar hujan hellman, *automatic weather station*, dan *automatic rain gauge* (ARG) (**Hakim & Dewi, 2021**). ARG merupakan alat pengamatan curah hujan secara otomatis dalam satuan waktu tertentu (**Istiana, dkk, 2020**). Dalam sebuah ARG diperlukan empat komponen utama, yaitu sensor, *data logger*, sistem komunikasi, dan catu daya. Catu daya pada ARG memiliki peran penting untuk mensuplai daya kepada komponen lainnya. Catu daya pada sebuah ARG terdiri dari sebuah baterai, *solar panel*, dan *solar charge controller*. Apabila terdapat kendala pada catu daya, komponen lain dalam ARG tidak dapat berfungsi dengan baik dan dapat mengganggu proses pengumpulan informasi curah hujan (**Rifai, 2021**). Perbaikan atau perawatan perlu dilakukan sedini mungkin untuk menghindari kerusakan atau kendala dalam catu daya (**Setiawan, 2021**).

Gangguan yang mungkin terjadi pada tegangan listrik meliputi kondisi tegangan lebih (*overvoltage*), kondisi tegangan kurang (*undervoltage*), ketidakseimbangan tegangan (*unbalance voltage*), fluktuasi tegangan (*sag* dan *swell*), dan gangguan pemutusan (*interruption*) (**Widarsono, dkk, 2019**). Gangguan-gangguan tersebut menunjukkan adanya penyimpangan tegangan dari kondisi ideal. Gangguan yang sering terjadi pada sebuah catu daya adalah *overvoltage* dan *undervoltage*. *Overvoltage* merupakan kondisi ketika tegangan listrik mengalami peningkatan yang melebihi 110% dari tegangan nominal selama lebih dari 1 menit. *Overvoltage* mampu memicu terjadinya kabel terbakar dan mengakibatkan gangguan maupun kerusakan pada perangkat lainnya (**Firmansyah, dkk, 2016**). Penyebab *overvoltage* dapat berkaitan dengan kelemahan sistem dalam mengatur tegangan yang diinginkan atau ketidakmemadainya kontrol tegangan (**Putri, dkk, 2022**). Di sisi lain, *undervoltage* terjadi ketika tegangan listrik mengalami penurunan lebih dari 90% dari nilai nominalnya dalam jangka waktu yang cukup lama, yaitu lebih dari 1 menit (**Triyanto & Syaepudin, 2023**). Fenomena ini juga mencakup gangguan berdurasi panjang. Tegangan rendah ini seringkali muncul akibat dari perubahan sirkuit, yang merupakan kebalikan dari peristiwa yang menyebabkan *overvoltage*. Selain itu, kelebihan beban pada sirkuit juga bisa menjadi penyebab *undervoltage* (**Arsyad, dkk, 2019**).

Penelitian terkait sistem prediksi menggunakan algoritma Prophet diperlukan sebagai referensi untuk memperoleh hasil yang maksimal. Terdapat beberapa referensi prediksi dengan menggunakan algoritma Prophet untuk memprediksi penggunaan listrik yang dilakukan oleh (**Mosavi, dkk, 2022**). Penelitian lain yang dilakukan oleh (**Nasser, dkk, 2022**) menggunakan algoritma Prophet dan Neural Prophet untuk memprediksi penggunaan daya *photovoltaic*. Penelitian-penelitian tersebut menggunakan data tegangan listrik sebagai acuan pelatihan model prediksi. Pada penelitian yang dilakukan oleh (**Oisy, 2019**) terkait prediksi tegangan pada baterai menggunakan metode *Graph Neural Network* (GNN) didapatkan hasil prediksi dengan nilai *Mean Average Error* (MAE) sebesar 0.56 dengan data sebanyak 127 dan nilai MAE 0.87 dengan menggunakan 32 data. Penelitian yang dilakukan oleh (**Tian, dkk, 2022**) dengan topik penelitian prediksi kapasitas tegangan pada baterai menggunakan metode Seq2seq mendapatkan nilai MAE sebesar 5.27, 14.21, dan 22.99 dan metode Rain Forest mendapatkan nilai MAE sebesar 5.40, 19.60, dan 35.21. Dalam penelitian ini, prediksi tegangan pada catu daya dengan menggunakan algoritma Prophet dilakukan sebagai salah

satu solusi dalam melakukan perawatan pada catu daya ARG dan mendapatkan nilai MAE sebesar 0.21 dimana nilai tersebut lebih baik dari ketiga metode yang disebutkan sebelumnya.

## 2. METODE

### 2.1 Alat dan Bahan

Peralatan yang digunakan untuk prediksi tegangan catu daya ARG yaitu laptop dengan prosesor AMD A10-7400P dengan sistem operasi windows 10 64 bit. Program pendukung lain yang digunakan yaitu Visual Studio Code, DBeaver, bahasa Python, dan SQL. Spesifikasi dari ARG yang digunakan adalah sebagai berikut Raspberry pi 4, Baterai VA12-18, Sensor *Tipping Bucket*, *Smartsolar Charge Controller* MPTT 75/15, dan *Solar Panel*. Data yang digunakan untuk proses *training* dan *testing* adalah data tegangan dan arus listrik hasil pengukuran menggunakan sensor INA219 dari Desember 2022 sampai April 2023 dengan parameter yang digunakan adalah tanggal, waktu, tegangan, dan arus listrik. Berikut adalah gambar dari ARG yang digunakan dalam penelitian ini.



**Gambar 1. *Automatic Rain Gauge***

Berdasarkan Gambar 1 di atas dapat dilihat komponen catu daya terdiri *solar panel*, *smartsolar charge controller*, dan baterai. Baterai adalah bagian utama dari catu daya untuk memberi suplai tegangan listrik ke komponen lain pada ARG. Seiring berjalannya waktu maka kapasitas dari baterai akan menurun. Digunakannya *solar panel* adalah untuk mengisi kembali baterai sehingga tegangan pada baterai tidak mengalami *undervoltage*. Tegangan yang dihasilkan oleh *solar panel* merupakan tegangan *alternating current* (AC) sedangkan tegangan yang dimiliki oleh baterai adalah *direct current* (DC). Oleh karena itu, *smartsolar charge controller* digunakan untuk mengkonversi tegangan yang diberikan oleh *solar panel* kedalam baterai. *Smartsolar charge controller* yang digunakan pada ARG tersebut memiliki fungsi khusus, dimana *smartsolar charge controller* tersebut mampu merekam data tegangan yang dihasilkan oleh *solar panel* dan tegangan pada baterai.

Data validasi yang akan digunakan pada penelitian ini adalah data hasil *monitoring* menggunakan sensor INA219. Data hasil *monitoring* dikirimkan menggunakan protokol MQTT. Protokol MQTT dapat melakukan pengiriman data dengan cepat pada *bandwidth* yang kecil,

protokol ini dapat digunakan pada perangkat dengan sumber daya minimum **(Nugroho, dkk, 2019)**.

## 2.2 Time Series

Seri data rangkaian waktu atau yang lebih dikenal dengan *time series* merujuk pada jenis data yang diperoleh dan disusun berdasarkan urutan kronologis dalam suatu interval waktu yang ditentukan **(Lista, dkk, 2014)**. Metode menggunakan data *time series* merupakan metode analisis prakiraan dengan memanfaatkan pola hubungan antara variabel yang ingin diprediksi dan variabel waktu yang memengaruhinya. Prediksi untuk masa yang akan datang dibentuk dengan bergantung pada nilai variabel dari periode sebelumnya atau kesalahan yang terjadi pada periode sebelumnya sebagai titik acuan. Tujuan utama dari metode prediksi *time series* adalah untuk mengidentifikasi pola yang terdapat dalam data historis dan menerapkan pola-pola tersebut ke masa depan melalui teknik ekstrapolasi **(Robial, 2018)**. Data *time series* mencerminkan perubahan variabel yang diamati dalam interval waktu yang telah ditetapkan sebelumnya. Data *time series* dapat terdiri pengamatan berulang yang serupa terhadap suatu objek atau unit dalam jangka waktu yang tetap, tanpa ada campur tangan yang memengaruhi objek tersebut.

## 2.3 Prophet

Prophet menggunakan *additive regression model* dan *decomposable time series* sehingga Prophet mampu melakukan prediksi berdasarkan riwayat data untuk mengetahui pola yang berulan dengan tiga model utama, yaitu *trends*, *seasonal*, dan *event effect* **(Taylor & Letham, 2017)**. Prophet mampu memberikan hasil yang baik dengan menggunakan data *time series* yang memiliki efek musiman yang kuat dan beberapa riwayat musiman. Hasil prediksi Prophet didapatkan dengan menggunakan Persamaan (1) berikut:

$$y(t) = g(t) + s(t) + h(t) + \varepsilon(t) \quad (1)$$

Keterangan:

$y$  = Forecast/additive regressive model

$g$  = Growth/trend factor

$s$  = Seasonality trend component

$h$  = Holiday trend component

$\varepsilon$  = Error term

Dari persamaan yang disebutkan, model Prophet memanfaatkan informasi dari *trend*, *seasonality*, *holiday*, serta *error* untuk menghasilkan prediksi. *Trend* dalam data mengacu pada perubahan non-periodik dalam *time series*, sementara *seasonality* mencakup variasi yang terjadi secara periodik, seperti pola harian, mingguan, atau tahunan. Komponen *holiday* menggambarkan pengaruh dari hari libur yang berdasarkan kalender, dan *error* mencerminkan fluktuasi yang tidak dapat dijelaskan oleh model. Model Prophet dapat memprediksi data *time series* secara lebih akurat dengan mempertimbangkan semua komponen tersebut.

## 2.4 Error

*Error* atau kesalahan merupakan perbedaan antara nilai yang terukur dengan nilai yang sebenarnya **(Faradiba, 2020)**. Terdapat berbagai metode untuk mengukur *error*, bergantung pada situasi dan tujuan analisis yang ada. Beberapa metode yang digunakan untuk menghitung *error* dalam suatu prediksi, yaitu *Mean Absolute Deviation* (MAD), *Mean Squared Error* (MSE), *Mean Absolute Percentage Error* (MAPE), dan *Mean Absolute Error* (MAE) **(Azmi, dkk, 2020)**. Pendekatan umum yang digunakan untuk mengukur *error* dalam prediksi adalah

MAE untuk mengukur kesalahan dalam skala absolut dan MAPE untuk mengukur kesalahan dalam skala persentase (**Gustriansyah, 2017**).

1) MAE

MAE adalah rata-rata absolut dari selisih antara kedua variabel, perbedaan muncul ketika terdapat variasi antara rata-rata nilai dari kedua variabel tersebut. MAE dihitung dengan Persamaan (2), (**Willmott and Matsuura dalam Ismunarti, dkk, 2020**):

$$MAE = \frac{\sum |X_{1i} - X_{2i}|}{n} \quad (2)$$

Keterangan:

$X_{1i}$  = Nilai sebenarnya pada periode t

$X_{2i}$  = Nilai prediksi pada periode t

n = Jumlah data

2) MAPE

MAPE digunakan untuk menilai tingkat akurasi prediksi. Metrik ini menghitung nilai kesalahan absolut pada setiap periode, kemudian membaginya dengan nilai actual dari periode tersebut, dan akhirnya menghasilkan rata-rata persentase dari nilai nilai absolut tersebut. Nilai MAPE dapat dihitung dengan menggunakan Persamaan (3) berikut (**Hajjah & Marlim, 2021**):

$$MAPE = \sum_{i=1}^n \frac{|X_{1i} - X_{2i}|}{X_{2i}} \frac{1000\%}{n} \quad (3)$$

Keterangan:

$X_{1i}$  = Nilai sebenarnya pada periode t

$X_{2i}$  = Nilai prediksi pada periode t

n = Jumlah data

Nilai akhir MAPE menjelaskan bahwa semakin rendah hasil yang diperoleh, semakin baik prediksi yang dihasilkan. Berikut adalah kriteria umum untuk nilai MAPE (**Hudiyanti, dkk, 2019**).

**Tabel 1. Kriteria Nilai MAPE**

No.	Nilai MAPE (%)	Kriteria
1	<10	Sangat Baik
2	10-20	Baik
3	20-50	Cukup
4	>50	Buruk

## 2.5 Diagram Alir Prediksi

Tahap proses prediksi tegangan catu daya ditunjukkan pada Gambar 2 berikut.



**Gambar 2. Flowchart Skema Proses Prediksi Tegangan Catu Daya**

Meninjau *flowchart* program prediksi pada Gambar 2 di atas. Proses prediksi menggunakan algoritma Prophet pada Visual Studio Code. *Input* data yang digunakan terdiri dari data pengukuran sensor INA219 selama periode Desember 2022 hingga April 2023 untuk prediksi tegangan satu minggu berikutnya. Parameter *seasonality* yang akan digunakan adalah *seasonality daily*, *seasonality weekly*, dan *seasonality yearly* dengan melakukan pengujian pada setiap *seasonality*. Model dengan hasil terbaik pada pengujian parameter *seasonality* akan digunakan pada proses pengujian parameter *seasonality mode*. Parameter *seasonality mode* yang akan digunakan pada penelitian ini adalah *seasonality mode additive* dan *seasonality mode multiplicative*. Pengaturan parameter *seasonality* dan *seasonality mode* terbaik akan digunakan untuk prediksi tegangan catu daya. *Output* program diperoleh estimasi tegangan catu daya untuk satu minggu berikutnya. Pembaruan parameter *seasonality* perlu dilakukan untuk proses prediksi dengan data *monitoring* yang semakin banyak pada waktu yang akan datang.

### 3. HASIL DAN PEMBAHASAN

Penelitian ini dilaksanakan di Gedung E BMKG Pusat dengan objek penelitian yaitu tegangan listrik catu daya ARG. Penelitian dilakukan analisis parameter *seasonality* dan parameter *seasonality mode* algoritma Prophet untuk tegangan catu daya ARG satu minggu yang akan datang. Analisis data menggunakan algoritma Prophet yang diakses menggunakan Visual Studio Code. Parameter *seasonality* yaitu *daily*, *weekly*, dan *yearly* dengan *seasonality* tersebut *on* dan *off*. Berikut hasil dan pembahasan penelitian ini yang disajikan dalam dua bagian yaitu *training* dan validasi. Parameter *seasonality* pada algoritma Prophet adalah parameter yang berfungsi untuk menentukan pola *trend* dari data. Hasil pengujian parameter *seasonality* selanjutnya digunakan pada pengujian parameter *seasonality mode*.

Pengujian model akan dilakukan menggunakan data hasil *monitoring* dengan data waktu yang memiliki interval 1 menit. Pengujian *seasonality* dilakukan untuk memeriksa performa model dalam memprediksi data dengan pola harian, mingguan, dan tahunan, serta mengevaluasi apakah model tersebut dapat mengenali pola yang dimiliki oleh data dengan baik. Pengujian *seasonality mode* dilakukan untuk menentukan bagaimana pengaruh dari *seasonality* ditambahkan kedalam *trend* untuk mendapatkan hasil prediksi. Terdapat dua operasi pada *seasonality mode*, yaitu *additive* dan *multiplicative*.

### 3.1 Training

Berdasarkan parameter *seasonality* yang ditentukan dalam penelitian ini yaitu tiga parameter pelatihan, dua kondisi berbeda, delapan kombinasi parameter, maka keseluruhan ada delapan model prediksi yang diteliti. Adapun hasil *training* semua variasi parameter *seasonality* ditampilkan pada Tabel 2.

**Tabel 2. Nilai dan Persentase *Error Training* Parameter *Seasonality***

Seasonality			MAE	MAPE (%)
Daily	Weekly	Yearly		
False	False	False	0.34	2.80
True	False	False	0.21	1.67
False	True	False	0.34	2.77
False	False	True	11.17	91.79
True	True	False	0.21	1.69
True	False	True	12.62	103.76
False	True	True	11.47	94.30
True	True	True	11.40	93.75

Berdasarkan Tabel 2 parameter *seasonality* yang memiliki nilai error terbaik adalah model yang menggunakan gabungan parameter *seasonality daily true, weekly false, dan yearly false*. Model tersebut mendapatkan nilai MAE sebesar 0.21 dan MAPE sebesar 1.67. Selain itu, berdasarkan Tabel 2 model dengan nilai *error* terbesar adalah model yang menggunakan gabungan parameter *seasonality daily true, weekly false, dan yearly true*. Model tersebut mendapatkan nilai MAE sebesar 12.62 dan MAPE 103.76. Data yang digunakan pada penelitian ini merupakan data hasil *monitoring* selama lima bulan yang dimulai dari bulan Desember 2022 sampai April 2023. Dapat disimpulkan bahwa dengan menggunakan data yang kurang dari dua tahun dan menggunakan parameter *seasonality yearly true* akan mengakibatkan model mengalami kesulitan dalam mengenali pola *trend* data. Sebaliknya karena data *monitoring* adalah data dengan interval waktu 1 menit. Data lebih dekat kedalam *seasonality daily* sehingga pola *trend* data dapat dengan mudah dipahami oleh model.

Hasil model dengan nilai *error* terbaik tersebut akan digabungkan dengan parameter *seasonality mode* untuk menentukan operasi yang akan digunakan dalam mengolah data *trend*. Proses *training* ini terdiri dari dua model yang akan diteliti, yaitu model parameter *seasonality* terbaik dengan menggunakan operasi *additive* dan operasi *multiplicative*. Hasil proses *training* parameter *seasonality mode* ditampilkan pada Tabel 3.

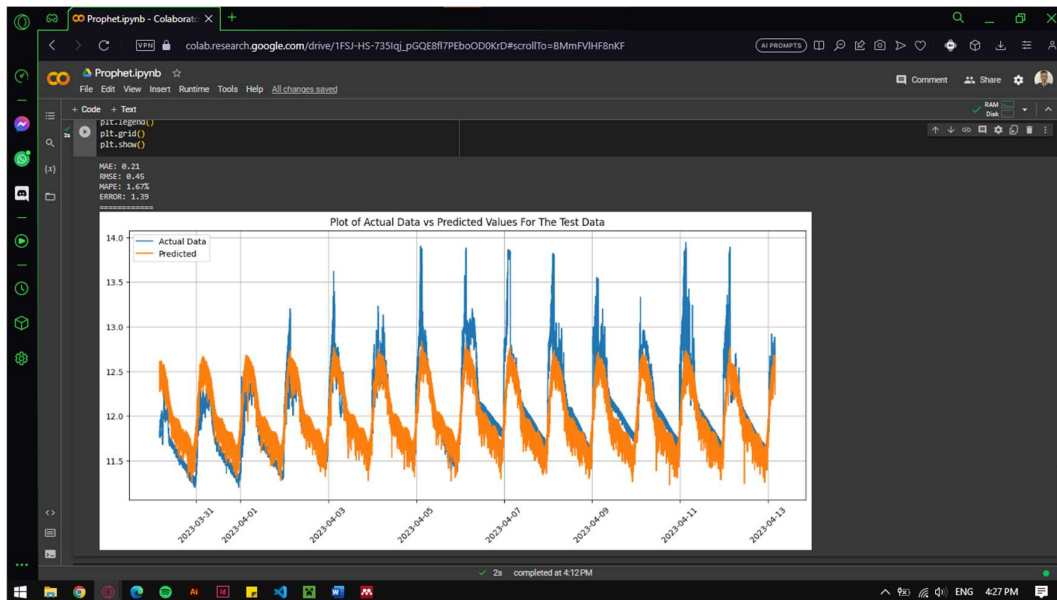
**Tabel 3. Nilai dan Persentase *Error Training Parameter Seasonality Mode***

Seasonality Mode	MAE	MAPE (%)
Additive	0.21	1.67
Multiplicative	0.21	1.68

Berdasarkan Tabel 3 kedua parameter *seasonality mode* mendapatkan hasil yang hampir sama pada MAPE dengan selisih dimana *additive* mendapatkan nilai MAPE 0.1% lebih kecil dari nilai MAPE yang didapatkan oleh *multiplicative*. Nilai MAE yang didapatkan oleh kedua opsi *seasonality mode* adalah sama yaitu 0.21. Dapat disimpulkan bahwa proses operasi terhadap nilai *trend seasonality* tidak memiliki pengaruh besar dengan menggunakan data *monitoring* pada penelitian ini untuk mendapatkan nilai prediksi tegangan. *Seasonality additive* pada sebuah data merupakan pola sebuah data yang selalu konstan dengan *trend* dimana pada data yang digunakan dalam penelitian ini memiliki pola data yang sama setiap hari nya. Sementara itu, *seasonality multiplicative* adalah pola data yang ikut berkembang dengan trend data, misal data memiliki pola yang sama namun memiliki peningkatan seiring berjalannya waktu.

### 3.2 Validasi

Tahap validasi dilakukan untuk menguji hasil parameter *seasonality* dan *seasonality mode* dengan nilai *error* terbaik terhadap data tes. Data tes yang digunakan pada proses validasi merupakan data hasil *monitoring* selama dua minggu. Parameter yang digunakan pada proses validasi adalah parameter *seasonality daily true, weekly false, dan yearly false* dan parameter *seasonality mode additive*. Gambar 2 menunjukkan nilai *error* dan perbandingan data hasil prediksi dan data hasil *monitoring* dalam sebuah grafik.



**Gambar 2. Grafik Validasi Hasil Prediksi dan Hasil *Monitoring***



Berdasarkan Gambar 2 hasil validasi model yang sudah dilakukan menggunakan gabungan ketiga parameter *seasonality* dan parameter *seasonality mode* dengan hasil terbaik pada tahap *training*, menunjukkan bahwa hasil validasi baik nilai MAE dan MAPE mendapatkan nilai yang dapat dibilang memuaskan. Nilai MAE dan MAPE yang didapatkan dengan menggunakan gabungan ketiga parameter *seasonality* dan parameter *seasonality mode* tersebut adalah 0.21 dan 1.67% nilai tersebut sama dengan hasil *training* parameter *seasonality mode additive*. Pada proses ini memiliki nilai MAPE yang termasuk kedalam kriteria akurasi yang sangat baik untuk prediksi tegangan catu daya ARG karena memiliki nilai MAPE <10%.

Gambar 2 menunjukkan hasil prediksi yang mampu mengikuti pola dan mampu memprediksi tegangan catu daya yang semakin melemah seiring berjalannya waktu. Penurunan tegangan di bawah 11.5 Volt mampu diprediksi oleh model. Hasil *monitoring* menunjukkan beberapa kali lonjakan tegangan yang melewati batas 13 Volt. Dalam hal tersebut hasil prediksi masih belum mampu untuk melakukan prediksi kapan terjadinya *overvoltage*. Hasil prediksi yang didapatkan oleh Prophet dapat digunakan sebagai acuan kapan tegangan pada baterai akan menurun. Prediksi dengan menggunakan Prophet dapat dilakukan dengan relative cepat dibandingkan dengan metode lainnya dan menghasilkan nilai prediksi dengan error yang lebih baik dari model lain. Prophet dapat dengan mudah dilakukan konfigurasi terhadap setiap parameter yang akan digunakan dalam prediksi. Prophet sendiri dirancang secara khusus dengan tujuan pengguna dapat menggunakan model tersebut tanpa perlu memiliki pengetahuan pemrograman.

#### 4. KESIMPULAN

Berdasarkan hasil penelitian yang dilakukan, pemodelan *seasonality* dan *seasonality mode* Prophet terbaik untuk memprediksi tegangan catu daya ARG satu minggu yang akan datang pada proses *training* adalah *seasonality daily true, weekly false, dan yearly false* dan *seasonality mode additive* dengan nilai MAE sebesar 0.21 dan MAPE sebesar 1.67%, model Prophet dengan hasil *error* terbesar adalah dengan parameter *seasonality daily true, weekly false, dan yearly true*. Serta pada tahap validasi model Prophet menggunakan gabungan terbaik ketiga parameter *seasonality* dan *seasonality mode* tersebut mendapatkan nilai MAE sebesar 0.21 dan MAPE sebesar 1.67%. Model Prophet mampu melakukan prediksi untuk penurunan tegangan yang akan terjadi pada waktu yang akan datang dan mampu mengikuti pola tegangan catu daya yang terjadi sebelumnya dengan ditunjukkan pada pola penurunan dan peningkatan tegangan yang mengikuti pola hasil *monitoring*. Penelitian lebih lanjut perlu dilakukan dengan menggunakan parameter lain pada algoritma Prophet. Parameter yang digunakan dapat memengaruhi nilai *error* yang dihasilkan. Analisis lebih lanjut terhadap pengaruh perubahan waktu siang dan malam perlu dilakukan untuk mendapatkan pengaruh tegangan yang dihasilkan oleh *solar panel* pada waktu malam hari. Selain itu, analisis data lebih lanjut pada masing-masing komponen catu daya dapat dilakukan dengan tujuan mendapatkan data yang lebih detail pada setiap komponen catu daya.

#### DAFTAR RUJUKAN

- Ajr, E. Q., & Dwirani, F. (2019). Menentukan Stasiun Hujan Dan Curah Hujan Dengan Metode Polygon Thiessen Daerah Kabupaten Lebak. *Jurnal*, 2(2), 139–146.
- Arsyad, B. M., Sofwan, A., & Nugroho, A. (2019). Perancangan Sistem Kontrol Over/Under Voltage Relay Berbasis Mikrokontroler Pada Saluran Tegangan 220Vac. *Transmisi*, 21(1), 25. <https://doi.org/10.14710/transmisi.21.1.25-32>

- Azmi, U., Hadi, Z. N., & Soraya, S. (2020). ARDL METHOD: Forecasting Data Curah Hujan Harian NTB. *Jurnal Varian*, 3(2), 73–82. <https://doi.org/10.30812/varian.v3i2.627>
- Faradiba. (2020). Buku Materi Pembelajaran Metode Pengukuran Fisika. *Buku Materi Pembelajaran Metode Pengukuran Fisika*, 1–223.
- Firmansyah, R. A., Suheta, T., & Sutopo, K. (2016). Perancangan dan Pembuatan Alat Proteksi Terhadap Gangguan Tegangan Lebih Berbasis Mikrokontroler. *Prosiding Seminar Nasional Sains dan Teknologi Terapan*, (pp. 103–110).
- Gustriansyah, R. (2017). Analisis Metode Single Exponential Smoothing Dengan Brown Exponential Smoothing Pada Studi Kasus Memprediksi Kuantiti Penjualan Produk Farmasidi Apotek. *Seminar Nasional Teknologi Informasi Dan Multimedia*, (7–12).
- Hajjah, A., & Marlim, Y. N. (2021). Analisis Error Terhadap Peramalan Data Penjualan. *Techno.Com*, 20(1), 1–9. <https://doi.org/10.33633/tc.v20i1.4054>
- Hakim, A. L., & Dewi, R. (2021). Automatic Rain Detection System Based on Digital Images of CCTV Cameras Using Convolutional Neural Network Method. *IOP Conference Series: Earth and Environmental Science*, 893(1).
- Hudiyanti, C. V., Bachtiar, F. A., & Setiawan, B. D. (2019). Perbandingan Double Moving Average dan Double Exponential Smoothing untuk Peramalan Jumlah Kedatangan Wisatawan Mancanegara di Bandara Ngurah Rai. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 3(3), 2667–2672.
- Ismunarti, D. H., Zainuri, M., Sugianto, D. N., & Saputra, S. W. (2020). Pengujian Reliabilitas Instrumen Terhadap Variabel Kontinu Untuk Pengukuran Konsentrasi Klorofil- A Perairan. *Buletin Oseanografi Marina*, 9(1), 1–8. <https://doi.org/10.14710/buloma.v9i1.23924>
- Istiana, T., Mardyansyah, R. Y., & Dharmawan, G. . B. (2020). Kajian Pemanfaatan IoT Berbasis LPWAN Untuk Jaringan Akuisisi Data ARG. *Elektron : Jurnal Ilmiah*, 12(1), 1–6. <https://doi.org/10.30630/eji.12.1.155>
- Lista, M., Irawan, M. I., Matematika, J., Matematika, F., & Alam, P. (2014). *Perbandingan Metode Fuzzy Time Series Cheng dan Metode Box-Jenkins untuk memprediksi IHSG*. 3(2).
- Mosavi, N. S., Freitas, F., Pires, R., Rodrigues, C., Silva, I., Santos, M., & Novais, P. (2022). Intelligent energy management using data mining techniques at Bosch Car Multimedia Portugal facilities. *Procedia Computer Science*, 201(C), (pp. 503–510).
- Nasser, A., Mansoori, A., Ahmed, F., Ajami, A., & Mousa, M. A. (2022). *A Hybrid Time-Series PV Power Forecasting Model Implementing Facebook Prophet and Neural Prophet*

*Algorithms.*

- Nugroho, H. A., Pratama, R. H., Suharni, S., Sutanto, A. T., & Hariyanto, H. (2019). *Diseminasi Informasi Peringatan Dini Tanah Longsor Berbasis Teknologi Internet of Things*. 335–339. <https://doi.org/10.5614/sniko.2018.38>
- Oisy, N. (2019). L Earning G Raph N Eural N Etnetworks. *Iclr*, 1, 1–5.
- Putri, T. A., Supriyanto, & Hikmat, Y. P. (2022). Pengaruh Kenaikan Tegangan Pada Penyulang Generator Unit 4 PLTP Kamojang Akibat Pelepasan Beban Menggunakan Software ETAP 12.6. 0. *Prosiding The 13th Industrial Research Workshop and National Seminar*, (pp. 13–14).
- Rafi, A. M., Bima Tri Ariyanto, Hairatunisa, & Agus Tri Susanto. (2018). Rancang Bangun Prototype Jaringan Automatic Rain Gauge (ARG) Berbasis Website. *Prosiding Seminar Bumi Dan Atmosfer Stmkg 2018*, (pp. 72–80).
- Rifai, G. (2021). *Sistem Pakar Troubleshooting Automatic Rain Gauge (Arg) Menggunakan Metode Dempster Shafer Dengan Tampilan Berbasis Web*. February, 6.
- Robial, S. M. (2018). Perbandingan Model Statistik pada Analisis Metode Peramalan Time Series (Studi Kasus: PT. Telekomunikasi Indonesia, Tbk Kandatel Sukabumi). *Jurnal Ilmiah SANTIKA*, 8(2), 1–17.
- Setiawan, M. D. A. (2021). *Rancang Bangun Sistem Predictive Maintenance Motor AC (Alternating Current) pada Peralatan High Volume Air Sampler (HVAS) Menggunakan Machine Learning*. 130.
- Taylor, S. J., & Letham, B. (2017). Business Time Series Forecasting at Scale. *PeerJ Preprints* 5:e3190v2, 35(8), 48–90.
- Tian, J., Xiong, R., Shen, W., & Lu, J. (2022). Data-driven battery degradation prediction: Forecasting voltage-capacity curves using one-cycle data. *EcoMat*, 4(5), 1–12. <https://doi.org/10.1002/eom2.12213>
- Triyanto, A., & Syaepudin, W. (2023). Perancangan Sistem Monitoring Tegangan Baterai 110 VDC Berbasis Bylnk Pada Gardu Induk. *JTEIN: Jurnal Teknik Elektro Indonesia*, 4(1), 353–363.
- Widarsono, K., Jauhari, M., & Dzuhuri, A. L. (2019). Relay protection of over voltage, under voltage and unbalance voltage magnitude based on visual basic using Arduino Mega. *Seminar Master*, 4(1), 39–48.