



# Analisis Prediksi Rasio Elektrifikasi Rumah Tangga Indonesia Menggunakan Algoritma Prophet Pendekatan Logistic Growth

Lifio Syifa Kurniawan\*, Bernadus Very Christioko

Fakultas Teknologi Informasi dan Komunikasi, Program Studi Teknik Informatika, Universitas Semarang, Semarang, Indonesia

Email: <sup>1,\*</sup>lifio@kurniawan@gmail.com, <sup>2</sup>very@usm.ac.id

Email Penulis Korespondensi: lifio@kurniawan@gmail.com

**Abstrak**—Pemerintah Indonesia terus berupaya mencapai akses listrik 100% bagi seluruh rumah tangga, namun ketimpangan antarwilayah masih besar, khususnya di kawasan timur dan Daerah Otonomi Baru. Secara metodologis, peramalan rasio elektrifikasi memiliki tantangan kelangkaan data dan keharusan mempertahankan prediksi di bawah batas absolut 100%. Model konvensional maupun pendekatan non-linier standar seperti *Logistic Regression* dengan *penalization* memiliki keterbatasan dalam menangani deret waktu univariat berukuran sangat kecil dan rentan gagal menangkap tren tanpa titik jenuh yang dinamis. Oleh karena itu, penelitian ini mengusulkan algoritma *Prophet* dengan pendekatan *Logistic Growth* untuk memprediksi rasio elektrifikasi 38 provinsi periode 2026–2030. *Prophet* dipilih karena ketahanannya terhadap data historis minim dan nilai kosong, sementara *Logistic Growth* menetapkan kapasitas maksimum logis  $cap = 100,5\%$  agar prediksi tidak melampaui batas asimtotik 100%. Hasil evaluasi menunjukkan model berkinerja presisi pada wilayah berdata matang, dibuktikan MAPE 0,41% dan RMSE 0,62 di DKI Jakarta. Sebaliknya, prediksi pada DOB seperti Papua Tengah menghasilkan ketidakpastian tinggi dengan kesalahan mencapai 34,30% akibat rentang data awal yang tidak memadai. Proyeksi hingga 2030 mengonfirmasi seluruh Pulau Jawa stabil pada rasio 100,00%, sementara anomali terdeteksi pada Papua Barat Daya yang diproyeksikan merosot hingga 34,65%. Kontribusi utama penelitian ini adalah peramalan *Prophet-Logistic Growth* pertama yang diterapkan pada 38 provinsi Indonesia. Pendekatan ini menawarkan kerangka peramalan yang stabil secara matematis sebagai landasan pendukung keputusan alokasi infrastruktur energi oleh pemerintah, khususnya bila dikombinasikan dengan verifikasi data lapangan pada wilayah berdata minim.

**Kata Kunci:** Elektrifikasi; Forecasting; Logistic Growth; Prophet; Time Series; Indonesia

**Abstract**—The Indonesian government continues striving for 100% household electricity access, yet regional disparities remain significant, particularly in eastern regions and New Autonomous Regions. Methodologically, forecasting the electrification ratio faces the challenge of data scarcity and the need to keep predictions below the absolute 100% ceiling. Conventional models and standard non-linear approaches such as penalized Logistic Regression have limitations in handling very small univariate time series and often fail to capture trends without a dynamic saturation point. This study therefore proposes the Prophet algorithm with a Logistic Growth approach to forecast the electrification ratio across 38 provinces for the 2026–2030 period. Prophet was selected for its robustness to minimal historical data and missing values, while Logistic Growth sets a logical maximum capacity ( $cap = 100.5\%$ ) so that predictions do not exceed the 100% asymptotic limit. The evaluation results show the model performs with precision in regions with mature historical data, evidenced by a MAPE of 0.41% and RMSE of 0.62 in DKI Jakarta. Conversely, predictions for DOB provinces such as Central Papua show high uncertainty, with errors reaching 34.30% due to inadequate initial data ranges. Projections through 2030 confirm that all provinces on Java remain stable at a 100.00% ratio, while an anomaly is detected in Southwest Papua, which is projected to decline sharply to 34.65%. The main contribution of this study is the first Prophet-Logistic Growth forecasting framework applied to 38 Indonesian provinces. This approach offers a mathematically stable forecasting framework as a basis for government decision-making on energy infrastructure allocation, particularly when combined with field-data verification in data-scarce regions.

**Keywords:** Electrification; Forecasting; Logistic Growth; Prophet; Time Series; Indonesia

## 1. PENDAHULUAN

Energi listrik merupakan kebutuhan dasar yang sangat penting untuk memajukan ekonomi, pendidikan, dan kesejahteraan masyarakat [1]. Di Indonesia, pemerintah melalui PLN terus berusaha keras agar seluruh rumah tangga bisa mendapatkan akses listrik hingga mencapai target 100% [2], [3], [4], [5]. Walaupun angka rata-rata nasional saat ini sudah hampir mencapai target tersebut, kenyataannya masih ada ketimpangan yang besar antarwilayah, terutama di kawasan Indonesia Timur dan wilayah pemekaran baru (Daerah Otonomi Baru/DOB) [6]. Dalam pengolahan datanya, memprediksi persentase kelistrikan per provinsi memiliki kesulitan tersendiri. Laju pertumbuhannya secara alami akan melambat ketika angkanya semakin mendekati batas maksimal 100%. Metode prediksi atau *forecasting* biasa sering kali tidak menyadari batasan ini, sehingga menghasilkan tebakan yang tidak masuk akal, misalnya meramalkan angka kelistrikan di atas 100% [7], [8]. Selain itu, data kelistrikan provinsi ini hanya dicatat setahun sekali sehingga jumlahnya sangat sedikit atau *scarce data*, ditambah lagi dengan banyaknya data yang kosong atau *missing values* akibat munculnya provinsi-provinsi baru.

Model konvensional seperti ARIMA atau *Exponential Smoothing* pada dasarnya membutuhkan panjang deret waktu yang memadai untuk mengestimasi parameter tren dan musiman secara stabil, sehingga ketika dipaksakan pada provinsi DOB yang hanya memiliki dua hingga tiga titik data historis, model-model tersebut cenderung menghasilkan estimasi yang tidak stabil atau bahkan gagal konvergen [9]. Penelitian terdahulu yang membandingkan model klasik seperti *Holt-Winters* dan SARIMA dengan *Prophet* pada data permintaan ritel menunjukkan bahwa *Prophet* secara konsisten lebih tangguh terhadap data yang tidak teratur dan bernilai kosong, karena mekanisme *changepoint detection* dan penanganan *missing values*-nya tidak bergantung pada asumsi stasioneritas ketat yang disyaratkan ARIMA maupun pembobotan periode musiman tetap yang disyaratkan *Holt-Winters* [10]. Karakteristik inilah yang menjadikan *Prophet* lebih sesuai dibandingkan ARIMA atau *Exponential Smoothing* untuk konteks data elektrifikasi provinsi di Indonesia, yang selain tahunan dan minim titik data, juga banyak mengandung nilai kosong akibat provinsi induk yang baru



dimekarkan. Sebagai alternatif, teknik imputasi data spasial yang mengisi nilai kosong berdasarkan kemiripan wilayah tetangga atau provinsi induk berisiko memasukkan asumsi kewilayahan yang belum tentu mencerminkan kondisi riil pasca-pemekaran administratif, sehingga penelitian ini memilih pendekatan *univariat Prophet* yang murni memanfaatkan pola historis provinsi itu sendiri tanpa bergantung pada data eksternal yang berpotensi bias [10].

Penelitian-penelitian terdahulu mengenai provinsi DOB pada umumnya juga baru sebatas mendeskripsikan ketimpangan aksesnya secara statistik-deskriptif tanpa mengusulkan mekanisme peramalan kuantitatif yang secara eksplisit mengakomodasi keterbatasan jumlah data tersebut, sehingga kelemahan model konvensional pada wilayah-wilayah ini belum banyak dibahas maupun diuji secara empiris [6].

Untuk mengatasi masalah tersebut, penelitian ini menawarkan solusi dengan menggunakan algoritma *Prophet* yang digabungkan dengan pendekatan *Logistic Growth*. Metode *Prophet* dipilih karena tetap bisa bekerja dengan baik meski ada data yang tidak lengkap atau bolong, sedangkan *Logistic Growth* secara khusus ditambahkan untuk mengunci batas maksimal prediksi di angka 100% [11], [12]. Dengan penggabungan metode ini, diharapkan hasil prediksi persentase rumah tangga berlistrik bisa lebih logis, akurat, dan dapat diterapkan langsung untuk 38 provinsi di Indonesia.

Penelitian dalam lima tahun terakhir juga menunjukkan perkembangan signifikan pada metode *time-series forecasting* di sektor energi sekaligus mengungkap berbagai keterbatasannya. *Hamdoun et al.* [13] menemukan bahwa model *Deep Learning* mampu menghasilkan akurasi tinggi, tetapi memerlukan komputasi besar dan rentan *overfitting* pada data terbatas. *Chavan et al.* [14] menyoroti tantangan ketidakstabilan data dan faktor eksternal, serta adanya *trade-off* antara model statistik seperti ARIMA yang mudah diinterpretasikan dan model kompleks seperti LSTM yang lebih akurat namun kurang transparan. Selain itu, *O'Connor et al.* [15] menunjukkan bahwa kesalahan dalam memahami karakteristik data sering menyebabkan pemilihan model yang tidak tepat sehingga menurunkan reliabilitas hasil peramalan. Ketiga temuan tersebut relevan dengan karakteristik data rasio elektrifikasi pada penelitian ini, yang bersifat tahunan dengan jumlah observasi yang jauh lebih sedikit dibandingkan data harian atau bulanan yang umum digunakan pada studi-studi tersebut, sehingga model perlu tetap akurat meski dilatih dengan titik data yang terbatas.

Berbagai pendekatan baru dikembangkan untuk mengatasi keterbatasan model peramalan. *Liu et al.* [16] memperkenalkan metode *Minimum-Variance Self-Tuning* (MVST) yang lebih efisien secara komputasi dibandingkan *XGBoost* maupun *Prophet* serta adaptif terhadap perubahan data, namun pengujiannya dilakukan pada data beban listrik berfrekuensi tinggi dan belum menyentuh kasus deret waktu tahunan dengan hanya dua hingga tiga observasi seperti pada provinsi DOB. Untuk kondisi *scarce data*, *Xi et al.* [17] mengembangkan model STRLM berbasis Exponential Moving Average yang tetap mampu menghasilkan prediksi akurat pada data historis terbatas, tetapi model tersebut tidak dirancang untuk menangani variabel yang memiliki batas atas fisik seperti rasio persentase, sehingga berpotensi menghasilkan proyeksi yang melampaui 100% jika diterapkan langsung pada data elektrifikasi. Sementara itu, *Shao et al.* [18] menemukan bahwa model *Deep Learning* modern masih mengalami kesulitan dalam menangkap dinamika hubungan antarwilayah yang berubah cepat, sehingga merekomendasikan pendekatan berbasis struktur spasial atau graf yang sekali lagi membutuhkan volume data jauh lebih besar daripada yang tersedia untuk provinsi-provinsi pemekaran baru di Indonesia.

Selain aspek pemilihan metode peramalan yang telah diuraikan di atas, komponen kedua yang mendasari pendekatan penelitian ini adalah karakteristik model *Logistic Growth* itu sendiri. Model *Logistic Growth* menggambarkan pertumbuhan suatu variabel menuju batas kapasitas maksimum sehingga laju pertumbuhan akan melambat saat mendekati titik jenuh. Berbeda dengan model linier yang tidak memiliki batas, pendekatan ini relevan untuk peramalan rasio elektrifikasi karena nilainya secara fisik tidak dapat melebihi 100%. Efektivitas model logistik telah dibuktikan dalam peramalan adopsi teknologi oleh *Shuvra et al.* [19] pada kasus adopsi kendaraan listrik di Amerika Serikat dan produksi energi oleh Jaouadi dan Attia [20] pada kasus produksi energi nasional Mesir, namun kedua studi tersebut diterapkan pada satu unit analisis tunggal (satu negara atau satu wilayah pasar) dan tidak menghadapi persoalan data historis yang sangat pendek maupun heterogenitas ketersediaan data antarwilayah seperti yang dijumpai pada 38 provinsi Indonesia. Integrasinya dengan algoritma *Prophet* memungkinkan penetapan batas atas (*cap*) sehingga hasil prediksi tetap berada dalam rentang yang logis, sebagaimana ditunjukkan pada studi peramalan ekspor hazelnut Turki dan deteksi anomali produksi energi surya [21], [22] meskipun kedua penelitian ini juga belum menguji kestabilan numerik pendekatan *Logistic Growth* pada kondisi data yang hanya terdiri dari dua hingga tiga titik observasi.

Berdasarkan tinjauan di atas, dapat diidentifikasi kesenjangan penelitian (*research gap*) yang jelas. Pertama, studi berbasis *Deep Learning* [13], MVST [16], maupun pendekatan struktur spasial/graf [18] terbukti akurat namun membutuhkan volume data yang jauh melebihi ketersediaan data tahunan provinsi Indonesia, khususnya provinsi DOB yang hanya memiliki dua hingga enam titik data historis. Kedua, model peramalan data terbatas seperti STRLM [17] maupun model klasik ARIMA/Exponential Smoothing [9] tidak dirancang untuk menghormati batas fisik atas suatu variabel, sehingga berisiko menghasilkan proyeksi yang secara konseptual tidak valid (melebihi 100%) apabila diterapkan pada rasio elektrifikasi. Ketiga, penerapan *Prophet* dengan *Logistic Growth* yang sudah ada [19], [20], [21], [22] selama ini terbatas pada satu unit analisis atau domain di luar rasio elektrifikasi (adopsi kendaraan listrik, produksi energi nasional, ekspor komoditas, dan deteksi anomali PV), belum pernah diuji secara sistematis pada peramalan multi-wilayah dengan heterogenitas panjang data historis yang ekstrem seperti kasus 38 provinsi Indonesia. Keempat, penelitian mengenai ketimpangan elektrifikasi di Indonesia [1], [2], [3], [4], [5], [6] pada umumnya bersifat deskriptif-statistik dan belum mengusulkan kerangka peramalan kuantitatif yang secara eksplisit mengakomodasi provinsi hasil pemekaran baru (DOB).



Kelima, sebagian besar penelitian peramalan energi masih berfokus pada konsumsi listrik, harga energi, atau beban harian dengan model yang relatif kompleks [13], [14], [16], [17], [18], sementara penelitian mengenai rasio elektrifikasi tahunan masih sangat terbatas, padahal data ini memiliki karakteristik khusus berupa jumlah observasi yang sedikit, keberadaan provinsi baru dengan data historis terbatas, serta batas maksimum sebesar 100%. Penggunaan model kompleks seperti LSTM atau GNN berpotensi kurang efisien untuk karakteristik data tersebut, sedangkan model konvensional sering mengabaikan batas logis variabel. Kesenjangan kelima ini menegaskan bahwa peramalan rasio elektrifikasi tahunan memerlukan pendekatan yang dirancang khusus, bukan sekadar adaptasi dari model konsumsi atau beban energi yang selama ini banyak diteliti.

Kombinasi *Prophet* dan *Logistic Growth* yang telah diperkenalkan sebelumnya menjadi jawaban langsung atas kelima kesenjangan tersebut, kesenjangan pertama dan kedua teratasi karena pendekatan ini tetap dapat bekerja pada deret waktu tahunan yang sangat pendek tanpa memerlukan volume data besar seperti disyaratkan *Deep Learning*, MVST, atau pendekatan berbasis graf, sekaligus menghormati batas fisik atas 100% yang selama ini diabaikan oleh STRLM maupun ARIMA/*Exponential Smoothing*; sementara kesenjangan ketiga dan keempat teratasi karena kombinasi ini diterapkan secara sistematis pada peramalan multi-wilayah rasio elektrifikasi 38 provinsi Indonesia, domain dan skala analisis yang belum pernah disentuh oleh penelitian *Prophet-Logistic Growth* maupun studi ketimpangan elektrifikasi sebelumnya. Sementara kesenjangan kelima teratasi karena penelitian ini secara khusus merancang pendekatan yang disesuaikan dengan karakteristik rasio elektrifikasi tahunan, jumlah observasi yang sedikit dan batas fisik atas 100%, alih-alih sekadar mengadaptasi model konsumsi atau beban energi yang selama ini mendominasi literatur *time-series forecasting* di sektor energi. Penerapan ini diharapkan menghasilkan prediksi yang melandai secara otomatis saat mendekati batas maksimum, sekaligus memberikan kerangka evaluasi ketidakpastian yang eksplisit bagi provinsi-provinsi DOB yang selama ini belum banyak dikaji. Karakteristik data tahunan dengan jumlah observasi yang sedikit ini menjadi pertimbangan utama dalam pemilihan pendekatan pada penelitian ini, karena model yang membutuhkan data berfrekuensi tinggi (harian/bulanan) untuk estimasi parameter yang stabil tidak dapat diterapkan secara langsung pada konteks data provinsi yang hanya dicatat sekali per tahun.


Tujuan utama penelitian ini adalah menerapkan dan menguji keandalan algoritma *Prophet* dengan pendekatan *Logistic Growth* untuk memprediksi persentase rumah tangga yang dialiri listrik PLN di 38 provinsi di Indonesia dari tahun 2026 hingga 2030. Kinerja model prediksi ini akan diukur tingkat kesalahannya menggunakan perhitungan standar yang umum dipakai dalam kecerdasan buatan yaitu MAE, MSE, RMSE, dan MAPE.

Dari penelitian ini, diharapkan tercipta sebuah rumusan prediksi yang tangguh dan bisa bekerja dengan baik meskipun diterapkan pada wilayah-wilayah yang data masa lalunya sangat sedikit. Pada akhirnya, hasil penelitian ini tidak hanya bermanfaat bagi perkembangan ilmu data atau *Data Science*, khususnya dalam mengolah data yang memiliki batas maksimal tertentu. Lebih dari itu, temuan ini diharapkan bisa memberikan masukan dan panduan yang jelas bagi pemerintah untuk mempercepat pemerataan listrik di daerah pelosok serta provinsi-provinsi pemekaran baru agar lebih tepat sasaran.

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan Penelitian

Penelitian ini dilakukan melalui tahapan yang terstruktur untuk memprediksi rasio elektrifikasi rumah tangga bersumber dari PLN di 38 provinsi di Indonesia. Secara garis besar, tahapan penelitian yang dilakukan diilustrasikan pada Gambar 1.



Gambar 1. Tahapan penelitian

Berdasarkan Gambar 1, penjelasan untuk masing-masing rincian tahapan penelitian dijabarkan dari poin 2.2 hingga 2.6 sebagai berikut:

### 2.2 Pengumpulan Data


Data sekunder diperoleh dari Badan Pusat Statistik (BPS) berupa "Persentase Rumah Tangga menurut Provinsi dan Sumber Penerangan Utama dari Listrik PLN" [23]. Rentang waktu data yang diambil adalah dari tahun 1993 hingga 2025. Data ini mencakup 38 provinsi di Indonesia, termasuk provinsi-provinsi hasil pemekaran baru di wilayah Papua.

### 2.3 Preprocessing Data

Data BPS berbentuk *wide* format dan mengandung nilai kosong yang ditandai simbol strip ("-"). Pada tahap *preprocessing* menggunakan *Python*, simbol tersebut dikonversi menjadi *NaN*, kemudian data diubah ke *long* format agar sesuai dengan

kebutuhan algoritma *Prophet*. Kolom tahun dikonversi ke format *datetime*, sedangkan data kosong dihapus sebelum proses pelatihan model.

Setelah proses *prapemrosesan* selesai, model *Prophet* dikonfigurasi dengan pendekatan *Logistic Growth* untuk memastikan kurva prediksi melandai saat mendekati batas maksimum 100%. Arsitektur dan alur kerja model ditunjukkan pada Gambar 2.



**Gambar 2.** Arsitektur model *Prophet* dengan pendekatan *Logistic Growth*

Sebagaimana ditunjukkan pada Gambar 2, alur kerja model dimulai dari data hasil *preprocessing*, dilanjutkan dengan konfigurasi parameter *Logistic Growth*, penonaktifan komponen musiman, proses pelatihan pada rentang 1993–2025, hingga tahap validasi dan keluaran hasil prediksi tahun 2026–2030.

## 2.4 Pemodelan dan Pelatihan (*Training*)

Seperti yang digambarkan pada Gambar 2, pada tahap ini, algoritma *Prophet* diterapkan pada masing-masing dari 38 provinsi. Sebelum algoritma dijalankan, ada beberapa pengaturan yang disesuaikan karena persentase kelistrikan memiliki batas maksimal yang pasti (tidak mungkin lebih dari 100%). Pengaturan tersebut meliputi:

- Penggunaan *Logistic Growth*: Berbeda dengan model prediksi biasa yang akan terus naik tanpa batas [7], [8], model *Logistic Growth* digunakan agar kurva prediksi melandai saat angkanya mendekati batas maksimal [20], [21], [22].
- Batas Maksimal: Pada tahap penyajian hasil, seluruh nilai prediksi dan interval kepercayaan yang melebihi 100% dinormalisasi menjadi 100%. Langkah ini dilakukan karena rasio elektrifikasi secara konseptual tidak dapat melampaui 100%, sehingga hasil akhir tetap konsisten dengan interpretasi fisik indikator yang dianalisis [19].
- Penonaktifan Pola Musiman: Karena data ini adalah data tahunan yang pertumbuhannya lambat, pola musiman (seperti cuaca atau perilaku harian) dimatikan agar model fokus pada tren jangka panjang.

Nilai parameter *cap* ditetapkan sebesar 100,5% alih-alih tepat 100% karena secara matematis, fungsi *sigmoid* pada persamaan *Logistic Growth* (Persamaan 1) mendekati nilai kapasitas maksimum (*C*) secara *asimtotik* dan tidak pernah benar-benar mencapainya. Jika *cap* diset persis 100, titik data aktual yang bernilai 100% akan berada tepat pada batas asimtot, sehingga proses optimasi parameter *k* (laju pertumbuhan) dan *m* (titik tengah) menjadi tidak stabil secara numerik akibat gradien yang mendekati nol di sekitar batas tersebut. Margin toleransi sebesar 0,5 poin persentase memberikan ruang numerik yang cukup agar algoritma optimasi *L-BFGS* yang digunakan *Prophet* dapat konvergen dengan stabil, tanpa mengubah interpretasi akhir hasil karena seluruh nilai prediksi tetap dinormalisasi ke batas logis 100% pada tahap penyajian hasil.

Pada tahap pelatihan, parameter seperti *yearly\_seasonality*, *weekly\_seasonality*, dan *daily\_seasonality* dinonaktifkan karena dataset bersifat tahunan jangka panjang yang tidak memiliki pola musiman seperti cuaca atau perilaku harian. Persamaan matematis dasar dari komponen tren logistik pada algoritma *Prophet* dapat direpresentasikan pada persamaan (1).

$$g(t) = \frac{C}{1 + \exp(-k(t-m))} \quad (1)$$

Di mana *g(t)* melambangkan nilai peramalan pada waktu *t*, *C* adalah kapasitas maksimum, *k* merepresentasikan laju pertumbuhan, dan *m* adalah parameter pergeseran titik tengah.

## 2.5 Peramalan (*Forecasting*)

Setelah model dilatih menggunakan data dari tahun 1993 hingga 2025, model digunakan untuk memproyeksikan persentase rasio elektrifikasi selama lima tahun ke depan, yaitu mulai dari awal tahun 2026 hingga akhir tahun 2030.





## 2.6 Evaluasi Kinerja Model

Tahap evaluasi dilakukan untuk mengukur kesesuaian model *Prophet-Logistic Growth* pada 38 provinsi, dengan membandingkan data aktual BPS ( $y$ ) dan hasil prediksi model ( $\hat{y}$ ) pada rentang waktu yang sama dengan data pelatihan (evaluasi *in-sample*).

Pendekatan *out-of-sample* dengan pemisahan data latih dan data uji (*time series split*) belum diterapkan pada tahap ini, mengingat sebagian besar provinsi khususnya provinsi DOB di Papua hanya memiliki 2 hingga 6 titik data historis, sehingga penyisihan sebagian data sebagai data uji berisiko membuat data latih semakin tidak mencukupi untuk estimasi parameter model. Konsekuensinya, nilai metrik evaluasi yang dilaporkan mencerminkan kemampuan model dalam menangkap pola data yang telah diamati, bukan kemampuan generalisasi terhadap data yang belum pernah dilihat, sehingga interpretasi hasil terutama pada provinsi dengan data minim perlu dilakukan secara hati-hati.

Perhitungan dilakukan menggunakan pustaka *Scikit-Learn* dengan empat metrik evaluasi, yaitu *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE) [13], [14]. Rumus dari keempat tolak ukur tersebut dijelaskan pada persamaan (2) hingga (5).

- a. MAE mengukur rata-rata selisih absolut antara nilai aktual dan prediksi sebagaimana ditunjukkan pada persamaan (2).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

- b. MSE menghitung rata-rata kuadrat kesalahan sehingga lebih sensitif terhadap penyimpangan besar, seperti pada persamaan (3).

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3)$$

- c. RMSE merupakan akar kuadrat dari MSE sehingga nilai kesalahan kembali ke satuan asli data, sebagaimana pada persamaan (4).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

- d. MAPE mengukur rata-rata persentase kesalahan prediksi terhadap nilai aktual, seperti ditunjukkan pada persamaan (5).

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (5)$$

Keempat metrik tersebut digunakan untuk menilai tingkat keandalan dan akurasi model dalam memprediksi rasio elektrifikasi rumah tangga pada 38 provinsi di Indonesia.

## 3. HASIL DAN PEMBAHASAN

Bagian ini menguraikan hasil dari penerapan model *Prophet* untuk meramalkan persentase rumah tangga yang memiliki akses listrik PLN.

### 3.1 Hasil Pengumpulan dan Preprocessing Data

Data yang diperoleh dari BPS awalnya memiliki 34 kolom (Tahun 1993 hingga 2025) dan 38 baris provinsi. Bentuk data mentah ini menyulitkan komputer untuk membaca tren waktu. Contoh cuplikan data mentah dapat dilihat pada Tabel 1.

**Tabel 1.** Cuplikan data mentah

| Provinsi         | Tahun 1993 | Tahun 1994 | ... | Tahun 2025 |
|------------------|------------|------------|-----|------------|
| ACEH             | 36,48      | 39,23      | ... | 99,49      |
| SUMATERA UTARA   | 50,55      | 57,47      | ... | 99,28      |
| PAPUA PEGUNUNGAN | -          | -          | ... | 20,78      |

Setelah melalui tahap *preprocessing*, data diubah bentuknya menjadi hanya 3 kolom, yaitu Provinsi, ds (kolom waktu), dan y (kolom persentase). Jumlah baris bertambah menjadi 1.254 baris, dan seluruh tanda strip dihapus. Hasil dari proses ini dapat dilihat pada Tabel 2 berikut.

**Tabel 2.** Cuplikan data setelah *preprocessing*

| Provinsi       | ds         | y     |
|----------------|------------|-------|
| ACEH           | 1993-01-01 | 36.48 |
| ACEH           | 1994-01-01 | 39.23 |
| SUMATERA UTARA | 1993-01-01 | 50.55 |



Perbandingan dimensi data sebelum proses *preprocessing* dan sesudah proses *preprocessing* dapat dilihat pada Tabel 3 berikut ini.

**Tabel 3.** Perbandingan dimensi dataset sebelum dan sesudah prapemrosesan

| Parameter Metrik      | Sebelum Prapemrosesan          | Sesudah Prapemrosesan                    |
|-----------------------|--------------------------------|------------------------------------------|
| Struktur Tabel        | Melebar ( <i>Wide Format</i> ) | Memanjang ( <i>Long Format</i> )         |
| Jumlah Kolom          | 34 Kolom                       | 3 Kolom (Provinsi, ds, y)                |
| Jumlah Baris          | 38 Baris                       | 1.254 Baris                              |
| Penanganan Kekosongan | Tanda Strip ("")               | Nilai <i>NaN</i> ( <i>Not a Number</i> ) |

Berdasarkan Tabel 3, proses *prapemrosesan* berhasil mengubah struktur data dari format lebar (34 kolom tahun) menjadi format panjang dengan 3 kolom utama (Provinsi, ds, y), sekaligus mengonversi representasi nilai kosong dari tanda strip menjadi format *NaN* yang dapat diproses langsung oleh algoritma *Prophet*. Transformasi ini turut menambah jumlah baris data dari 38 menjadi 1.254 baris, sesuai kebutuhan format satu observasi per tahun per provinsi.


### 3.2 Implementasi dan Pengujian Model

Pada tahap ini, dijelaskan hasil penerapan model pada 38 provinsi yang dinilai menggunakan dua cara utama yaitu tingkat akurasi model dalam membaca data masa lalu (Metrik Evaluasi Kinerja) dan hasil angka tebakan di masa depan. Kemampuan algoritma selama proses pembelajaran data dari tahun 1993 hingga 2025 diukur menggunakan empat tolak ukur, yaitu *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). Rincian hasil perhitungan untuk seluruh 38 provinsi disajikan pada Tabel 4.

**Tabel 4.** Metrik evaluasi kinerja model *prophet* untuk 38 Provinsi


| Provinsi             | MAE   | MSE    | RMSE  | MAPE (%) |
|----------------------|-------|--------|-------|----------|
| Aceh                 | 2.81  | 22.39  | 4.73  | 3.65     |
| Sumatera Utara       | 2.45  | 9.70   | 3.11  | 3.12     |
| Sumatera Barat       | 1.87  | 6.74   | 2.60  | 2.86     |
| Riau                 | 4.65  | 30.51  | 5.52  | 7.32     |
| Jambi                | 3.09  | 12.77  | 3.57  | 4.75     |
| Sumatera Selatan     | 2.84  | 12.08  | 3.47  | 4.37     |
| Bengkulu             | 4.53  | 24.78  | 4.98  | 6.33     |
| Lampung              | 1.52  | 3.66   | 1.91  | 3.02     |
| Kep. Bangka Belitung | 3.94  | 20.69  | 4.55  | 4.80     |
| Kep. Riau            | 3.29  | 34.34  | 5.86  | 4.55     |
| DKI Jakarta          | 0.40  | 0.38   | 0.62  | 0.41     |
| Jawa Barat           | 1.06  | 1.48   | 1.22  | 1.13     |
| Jawa Tengah          | 1.05  | 1.45   | 1.20  | 1.12     |
| DI Yogyakarta        | 0.86  | 1.02   | 1.01  | 0.89     |
| Jawa Timur           | 1.34  | 2.44   | 1.56  | 1.43     |
| Banten               | 0.60  | 0.68   | 0.83  | 0.63     |
| Bali                 | 1.28  | 2.21   | 1.48  | 1.36     |
| Nusa Tenggara Barat  | 3.41  | 16.06  | 4.01  | 4.36     |
| Nusa Tenggara Timur  | 4.75  | 33.24  | 5.77  | 11.19    |
| Kalimantan Barat     | 3.75  | 22.88  | 4.78  | 6.96     |
| Kalimantan Tengah    | 2.92  | 13.75  | 3.71  | 5.48     |
| Kalimantan Selatan   | 1.15  | 2.29   | 1.51  | 1.52     |
| Kalimantan Timur     | 3.02  | 15.69  | 3.96  | 3.91     |
| Kalimantan Utara     | 0.85  | 1.24   | 1.11  | 0.93     |
| Sulawesi Utara       | 1.32  | 3.68   | 1.92  | 1.48     |
| Sulawesi Tengah      | 3.43  | 16.95  | 4.12  | 5.67     |
| Sulawesi Selatan     | 1.76  | 7.08   | 2.66  | 2.63     |
| Sulawesi Tenggara    | 2.78  | 12.98  | 3.60  | 5.02     |
| Gorontalo            | 3.37  | 15.40  | 3.92  | 4.38     |
| Sulawesi Barat       | 4.50  | 25.84  | 5.08  | 7.34     |
| Maluku               | 5.37  | 63.59  | 7.97  | 7.41     |
| Maluku Utara         | 7.38  | 100.69 | 10.03 | 10.52    |
| Papua Barat          | 2.47  | 8.69   | 2.95  | 3.52     |
| Papua Barat Daya     | 5.30  | 28.43  | 5.33  | 5.86     |
| Papua                | 9.14  | 245.80 | 15.68 | 17.67    |
| Papua Selatan        | 0.06  | 0.00   | 0.06  | 0.09     |
| Papua Tengah         | 12.17 | 148.01 | 12.17 | 34.30    |
| Papua Pegunungan     | 0.12  | 0.01   | 0.12  | 0.69     |

Berdasarkan data pada Tabel 4, model menunjukkan kinerja yang sangat baik pada provinsi-provinsi dengan tingkat elektrifikasi yang telah mendekati kondisi jenuh, khususnya di Pulau Jawa dan Bali. DKI Jakarta memiliki tingkat kesalahan paling kecil dengan nilai MAPE sebesar 0,41%. Tingkat kesalahan yang rendah juga terlihat pada DI Yogyakarta (0,89%), Jawa Tengah (1,12%), dan Jawa Barat (1,13%). Hasil ini menunjukkan bahwa model *Prophet* dengan pendekatan *Logistic Growth* mampu menangkap pola pertumbuhan elektrifikasi secara akurat pada wilayah yang memiliki data historis stabil dan relatif lengkap. Gambaran visual yang menunjukkan stabilnya hasil prediksi di daerah yang ketersediaan listriknya sudah penuh ini bisa dilihat pada Gambar 3.




**Gambar 3.** Grafik *forecasting* provinsi Jawa Barat

Gambar 3 menunjukkan bagaimana garis prediksi (warna biru) mampu mengikuti pola data masa lalu (titik hitam) dengan rapi, serta tidak melewati garis batas maksimal 100%. Sebaliknya, ketidakakuratan atau kejanggalan terbesar ditemukan pada provinsi-provinsi pemekaran baru (DOB) di Papua. Papua Tengah mencatat tingkat kesalahan tertinggi mencapai 34,30%. Namun anehnya, Papua Selatan dan Papua Pegunungan seolah-olah memiliki tingkat kesalahan yang hampir nol (0,09% dan 0,69%). Kondisi janggal ini murni terjadi karena sangat sedikitnya data historis yang tersedia. Model terpaksa membuat tebakan hanya bermodalkan 2 sampai 3 titik data awal, sehingga garis tebakannya menjadi sangat menukik tajam ke atas, seperti yang terlihat pada Gambar 4.



**Gambar 4.** Grafik *forecasting* provinsi Papua Pegunungan

Gambar 4 membuktikan bahwa meskipun datanya sangat minim, algoritma *Prophet* tetap berusaha membuat kurva prediksi yang terus naik mengikuti kemiringan data awalnya. Sementara itu, untuk provinsi kepulauan yang datanya sering naik-turun tidak stabil di masa lalu, seperti Maluku Utara, model menunjukkan rentang ketidakpastian yang sangat lebar seperti yang terlihat pada Gambar 5.




**Gambar 5.** Grafik *forecasting* provinsi Maluku Utara

Gambar 5 menunjukkan tingginya risiko ketidakpastian tebakan di masa depan. Hal ini ditandai dengan area pita berwarna biru muda yang melebar luas karena data masa lalunya di era 2010-an sangat fluktuatif atau naik-turun. Setelah menguji keakuratan model, langkah selanjutnya adalah menggunakan model tersebut untuk memprediksi persentase kelistrikan lima tahun ke depan 2026–2030. Angka hasil tebakan, beserta batas bawah dan batas atas toleransinya, disajikan pada Tabel 5.

**Tabel 5.** Hasil keluaran prediksi

| Provinsi             | Prediksi 2026 (%) | Prediksi 2030 (%) | Interval 2030 (Bawah - Atas) % |
|----------------------|-------------------|-------------------|--------------------------------|
| ACEH                 | 100.00            | 100.00            | 93.82 - 100.00                 |
| SUMATERA UTARA       | 99.70             | 100.00            | 96.05 - 100.00                 |
| SUMATERA BARAT       | 98.99             | 99.60             | 96.19 - 100.00                 |
| RIAU                 | 92.19             | 94.69             | 87.54 - 100.00                 |
| JAMBI                | 96.35             | 97.90             | 93.15 - 100.00                 |
| SUMATERA SELATAN     | 96.74             | 98.11             | 93.87 - 100.00                 |
| BENGKULU             | 96.91             | 98.16             | 91.60 - 100.00                 |
| LAMPUNG              | 98.78             | 99.62             | 97.13 - 100.00                 |
| KEP. BANGKA BELITUNG | 98.42             | 99.30             | 93.27 - 100.00                 |
| KEP. RIAU            | 98.71             | 99.55             | 92.42 - 100.00                 |
| DKI JAKARTA          | 99.96             | 100.00            | 99.26 - 100.00                 |
| JAWA BARAT           | 100.00            | 100.00            | 98.80 - 100.00                 |
| JAWA TENGAH          | 100.00            | 100.00            | 98.99 - 100.00                 |
| DI YOGYAKARTA        | 100.00            | 100.00            | 99.22 - 100.00                 |
| JAWA TIMUR           | 100.00            | 100.00            | 98.39 - 100.00                 |
| BANTEN               | 100.00            | 100.00            | 99.24 - 100.00                 |
| BALI                 | 100.00            | 100.00            | 98.64 - 100.00                 |
| NUSA TENGGARA BARAT  | 98.77             | 99.42             | 94.26 - 100.00                 |
| NUSA TENGGARA TIMUR  | 84.50             | 89.26             | 82.00 - 96.59                  |
| KALIMANTAN BARAT     | 91.52             | 93.86             | 87.68 - 99.80                  |
| KALIMANTAN TENGAH    | 88.97             | 91.76             | 87.21 - 96.45                  |
| KALIMANTAN SELATAN   | 99.50             | 99.92             | 97.93 - 100.00                 |
| KALIMANTAN TIMUR     | 95.31             | 96.53             | 91.80 - 100.00                 |
| KALIMANTAN UTARA     | 97.15             | 98.59             | 97.19 - 100.00                 |
| SULAWESI UTARA       | 100.00            | 100.00            | 97.89 - 100.00                 |
| SULAWESI TENGAH      | 94.24             | 96.21             | 90.69 - 100.00                 |
| SULAWESI SELATAN     | 98.72             | 99.41             | 96.04 - 100.00                 |
| SULAWESI TENGGARA    | 96.34             | 97.95             | 93.25 - 100.00                 |
| GORONTALO            | 97.56             | 98.80             | 93.95 - 100.00                 |
| SULAWESI BARAT       | 93.91             | 96.86             | 90.41 - 100.00                 |
| MALUKU               | 92.18             | 94.18             | 83.80 - 100.00                 |
| MALUKU UTARA         | 89.28             | 91.94             | 79.63 - 100.00                 |
| PAPUA BARAT          | 89.12             | 92.68             | 88.89 - 96.36                  |
| PAPUA BARAT DAYA     | 82.70             | 34.65             | 27.73 - 41.31                  |
| PAPUA                | 55.36             | 58.39             | 37.70 - 78.56                  |
| PAPUA SELATAN        | 79.24             | 93.30             | 93.30 - 93.30                  |
| PAPUA TENGAH         | 48.29             | 50.04             | 50.04 - 50.04                  |
| PAPUA PEGUNUNGAN     | 28.96             | 69.88             | 69.88 - 69.88                  |

Agar tidak memakan banyak ruang pada halaman, Tabel 5 hanya menampilkan ringkasan prediksi untuk awal tahun 2026 dan akhir tahun 2030 di setiap provinsi. Berdasarkan hasil pada Tabel 5, seluruh prediksi telah berada dalam rentang logis 0–100% sesuai karakteristik rasio elektrifikasi rumah tangga [19]. Provinsi-provinsi di Pulau Jawa dan Bali diproyeksikan mempertahankan kondisi elektrifikasi penuh hingga tahun 2030. Sementara itu, sebagian besar provinsi di Sumatera, Kalimantan, dan Sulawesi diprediksi mencapai tingkat elektrifikasi di atas 95%. Namun, hal sebaliknya kembali terjadi di wilayah Papua. Papua Barat Daya yang sebelumnya menunjukkan perkembangan bagus, justru diprediksi akan merosot tajam dari 82,70% di tahun 2026 menjadi hanya 34,65% di tahun 2030. Pola penurunan ini digambarkan secara jelas pada Gambar 6.

**Gambar 6.** Grafik forecasting provinsi Papua Barat Daya





Gambar 6 memperlihatkan bagaimana model murni membaca pola penurunan tajam pada titik data terakhir sebagai tren yang akan terus berlanjut, tanpa mampu membedakan apakah penurunan tersebut mencerminkan kondisi riil di lapangan atau sekadar fluktuasi akibat jumlah observasi yang sangat terbatas pada provinsi hasil pemekaran. Papua Barat Daya baru memiliki data historis untuk tahun 2024 dan 2025 sejak provinsi ini resmi terbentuk, sehingga model pada dasarnya mengestimasi parameter tren hanya berdasarkan dua titik data dan mengekstrapolasinya secara linear ke lima tahun ke depan. Dengan basis data seminim ini, penurunan ekstrem hingga 34,65% pada tahun 2030 lebih tepat diinterpretasikan sebagai bias statistik akibat ekstrapolasi berlebihan dari tren jangka pendek, bukan sebagai proyeksi realita lapangan yang valid. Temuan ini menegaskan bahwa pada kondisi data historis seminim dua titik observasi, model tidak layak dijadikan dasar tunggal pengambilan kebijakan, melainkan sebagai alat pendukung awal (*early-warning*) perlu dikombinasikan dengan verifikasi data lapangan sebelum digunakan untuk keputusan alokasi sumber daya.

### 3.3 Pembahasan

Penerapan *Prophet* dengan pendekatan *Logistic Growth* terbukti sesuai untuk memprediksi rasio elektrifikasi karena indikator ini memiliki batas maksimum 100%. Berbeda dengan model linier yang berpotensi menghasilkan prediksi melebihi batas logis [7], [8], penggunaan *Logistic Growth* dengan kapasitas logistik yang dibatasi memungkinkan kurva prediksi melandai saat mendekati kondisi jenuh tanpa menghasilkan nilai akhir yang melampaui batas logis 100%. Temuan ini sejalan dengan penelitian *Shuvra et al.* [19] yang menunjukkan bahwa model logistik efektif untuk fenomena yang memiliki titik saturasi alami.

Dari sisi kewilayahan, hasil prediksi menunjukkan kesenjangan elektrifikasi yang masih terjadi di Indonesia. Wilayah Barat, khususnya Jawa, Bali, dan sebagian Sumatera, telah menunjukkan kurva yang relatif stabil pada tingkat elektrifikasi tinggi, menandakan akses listrik dasar telah tercapai. Sebaliknya, Nusa Tenggara Timur dan provinsi-provinsi baru di Papua masih menunjukkan ketidakpastian yang tinggi. Prediksi penurunan di Papua Barat Daya serta stagnasi Papua Tengah mencerminkan tantangan pembangunan infrastruktur di wilayah pemekaran. Temuan ini menunjukkan bahwa model *Machine Learning* tidak hanya berfungsi sebagai alat prediksi, tetapi juga sebagai pendukung pengambilan keputusan bagi pemerintah dan PLN dalam menentukan prioritas pembangunan infrastruktur energi [1], [2], [4].

Dibandingkan penelitian sebelumnya, hasil ini memperkuat temuan *Sanjaya et al.* [11] mengenai kemampuan *Prophet* dalam menangani data berpola tidak teratur. Selain itu, kombinasi *Prophet* dan *Logistic Growth* mampu mengatasi kelemahan model konvensional yang cenderung mengabaikan batas fisik data sebagaimana diidentifikasi oleh *Hamdoun et al.* [13], *Chavan et al.* [14], dan *O'Connor et al.* [15]. Dibandingkan pendekatan *Deep Learning* [13], model yang diusulkan lebih ringan secara komputasi namun tetap memberikan akurasi yang kompetitif untuk data tahunan tingkat provinsi. Temuan *Liu et al.* [16] terkait pentingnya efisiensi komputasi serta mengonfirmasi efektivitas model logistik pada fenomena yang memiliki titik jenuh [19]. Penelitian ini memiliki keterbatasan, Pertama, model hanya menggunakan variabel rasio elektrifikasi tanpa mempertimbangkan faktor lain seperti kondisi ekonomi, kepadatan penduduk, dan investasi infrastruktur energi. Kedua, keterbatasan data historis pada provinsi-provinsi baru di Papua menyebabkan tingkat ketidakpastian prediksi yang tinggi. Ketiga, sifat *univariate Prophet* belum mampu menangkap pengaruh antarwilayah. Keempat, evaluasi kinerja model pada penelitian ini bersifat *in-sample*, sehingga nilai MAE, MSE, RMSE, dan MAPE yang dilaporkan berpotensi optimis dibandingkan performa aktual model pada data baru, validasi *out-of-sample* dengan skema *time series split* perlu diprioritaskan pada penelitian lanjutan begitu jumlah observasi per provinsi memungkinkan. Penelitian selanjutnya dapat mengembangkan model hibrida, variabel sosio-ekonomi serta memanfaatkan data dari provinsi induk untuk meningkatkan akurasi prediksi pada daerah pemekaran baru.

## 4. KESIMPULAN

Algoritma *Prophet* dengan pendekatan *Logistic Growth* efektif digunakan untuk memprediksi rasio elektrifikasi rumah tangga di 38 provinsi Indonesia, karena mampu menjaga hasil prediksi tetap dalam batas logis fisik (0–100%). Kinerja model sangat baik di Indonesia Bagian Barat, dengan MAPE terendah di DKI Jakarta (0,41%) dan seluruh Pulau Jawa diproyeksikan mempertahankan rasio listrik penuh hingga 2030. Sebaliknya, model juga berhasil mendeteksi tingginya ketidakpastian di provinsi pemekaran baru (DOB) di Papua akibat keterbatasan data historis, seperti pada Papua Tengah (MAPE 34,30%) dan potensi penurunan tajam di Papua Barat Daya yang perlu menjadi perhatian pembuat kebijakan. Kontribusi penelitian ini terletak pada tiga hal yang menjawab kesenjangan penelitian terdahulu. Pertama, penelitian ini merupakan penerapan pertama *Prophet-Logistic Growth* secara menyeluruh pada 38 provinsi Indonesia, termasuk seluruh provinsi DOB Papua berdata minim yang belum pernah dikaji dalam peramalan kelistrikan. Kedua, penelitian ini merumuskan  $cap = 100,5\%$  sebagai solusi ketidakstabilan numerik model logistik saat data mendekati batas maksimum, justifikasi teknis yang belum diuraikan secara eksplisit pada studi *Prophet-Logistic Growth* terdahulu. Ketiga, penelitian ini menawarkan kerangka analisis ketidakpastian berbasis wilayah yang membedakan provinsi berdata matang (acuan kebijakan) dari berdata minim (perlu verifikasi lapangan), menghasilkan alat pendukung keputusan yang lebih realistis dibandingkan pendekatan terdahulu yang umumnya tidak membedakan tingkat kepercayaan hasil antarwilayah. Berdasarkan temuan ini, model disarankan digunakan sebagai alat pendukung awal (*decision-support tool*), bukan dasar tunggal pengambilan keputusan anggaran infrastruktur energi: untuk provinsi berakurasi tinggi (MAPE < 2%, seperti Jawa, Bali, dan Kalimantan Selatan) hasil model layak dijadikan acuan utama perencanaan jangka menengah, sedangkan untuk provinsi DOB berdata minim, hasil model perlu diverifikasi lebih lanjut melalui survei lapangan atau data PLN



terbaru sebelum dijadikan dasar kebijakan, disertai alokasi survei kelistrikan berkala agar ketersediaan data historis dan akurasi model dapat meningkat di masa depan. Penelitian selanjutnya disarankan menambahkan variabel pendukung lain atau menggabungkan data dari provinsi induk agar prediksi di daerah pemekaran baru menjadi lebih kuat dan stabil.

## REFERENCES

- [1] J. D. Sari, N. A. Sufiawan, B. Rizky, and W. Weriantoni, "Analisis Ketimpangan Pendapatan Terhadap Indeks Pembangunan Manusia Melalui Akses Listrik di Indonesia," *Equilibrium : Jurnal Ilmiah Ekonomi, Manajemen dan Akuntansi*, vol. 11, no. 2, p. 35, Sep. 2022, doi: 10.35906/equili.v11i2.1106.
- [2] T. S. Maxensius, H. F. Ahmad, D. N. Siwage, W. H. Felix, and M. Erla, "Electricity Access and Community Welfare in Indonesia." Accessed: Jul. 12, 2026. [Online]. Available: <https://penerbit.brin.go.id/press/catalog/book/432>
- [3] N. B. Alnavis, R. R. Wirawan, K. I. Solihah, and V. H. Nugroho, "Energi listrik berkelanjutan: Potensi dan tantangan penyediaan energi listrik di Indonesia," *Journal of Innovation Materials, Energy, and Sustainable Engineering*, vol. 1, no. 2, Jan. 2024, doi: 10.61511/jimese.v1i2.2024.544.
- [4] D. K. F. Tampubolon, A. K. Hendriyanto, and B. Mari, "Leveraging solar energy development to achieve 100% electrification ratio in Nusa Tenggara Timur - Indonesia," *IET Conference Proceedings*, vol. 2023, no. 6, pp. 2426–2430, Jul. 2023, doi: 10.1049/icp.2023.1173.
- [5] A. Chrisnahunata, "Akses Listrik, Air Minum, dan Sanitasi serta Modal Manusia di Indonesia," *Journal of Economics Research and Policy Studies*, vol. 3, no. 3, pp. 185–199, Dec. 2023, doi: 10.53088/jerps.v3i3.770.
- [6] F. Leviany and Mayang Anglingsari Putri, "Analyzing the Distribution of Household Electricity Usage in Indonesia Using Two-Way ANOVA," *Journal of Enhanced Studies in Informatics and Computer Applications*, vol. 2, no. 2, pp. 62–69, Jul. 2025, doi: 10.47794/jesica.v2i2.27.
- [7] P. Xie, Y. Shu, F. Sun, and X. Pan, "Enhancing the accuracy of China's electricity consumption forecasting through economic cycle division: An MSAR-OPLS scenario analysis," *Energy*, vol. 293, p. 130618, Apr. 2024, doi: 10.1016/j.energy.2024.130618.
- [8] T. J. Chang, S. Lee, J. Lee, and C.-J. Lu, "An Interval-Valued Time Series Forecasting Scheme With Probability Distribution Features for Electric Power Generation Prediction," *IEEE Access*, vol. 10, pp. 6417–6429, 2022, doi: 10.1109/ACCESS.2022.3142083.
- [9] A. Abdelrahman, "Modeling and Time Series Analysis of Population in Saudi Arabia Using Box-Jenkins (ARIMA) Models: An Analytical Study for the Period 1950–2024," *International Journal of Financial, Administrative, and Economic Sciences*, vol. 4, no. 7, pp. 524–552, Jul. 2025, doi: 10.59992/IJFAES.2025.v4n7p15.
- [10] A. Doğan, "Time Series-Based Demand Forecasting: A Comparative Analysis of Holt-Winters, SARIMA, and Prophet Models on Retail Inventory Data," *İstanbul Ticaret Üniversitesi Sosyal Bilimler Dergisi*, vol. 24, no. 53, pp. 641–668, Sep. 2025, doi: 10.46928/iticusbe.1725584.
- [11] H. Sanjaya, K. Angga, I. Ibnu, R. A. Abdul, Kusri, and M. Dina, "Prediksi Jumlah Kejadian Titik Panas pada Lahan Gambut di Indonesia Menggunakan Prophet," *INFOTECH journal*, vol. 9, no. 2, pp. 354–360, Jul. 2023, doi: 10.31949/infotech.v9i2.6073.
- [12] C. Long, C. Yu, and T. Li, "Prophet-Based Medium and Long-Term Electricity Load Forecasting Research," *J. Phys. Conf. Ser.*, vol. 2356, no. 1, p. 012002, Oct. 2022, doi: 10.1088/1742-6596/2356/1/012002.
- [13] H. Hamdoun, A. Sagheer, and H. Youness, "Energy time series forecasting-analytical and empirical assessment of conventional and machine learning models," *Journal of Intelligent & Fuzzy Systems*, vol. 40, no. 6, pp. 12477–12502, Jun. 2021, doi: 10.3233/JIFS-201717.
- [14] M. Chavan, S. V. Joshi, D. B. Patil, V. G. Kale, P. A. Kharat, and M. Kasar, "Time Series Analysis in Electrical Load Forecasting," *Panamerican Mathematical Journal*, vol. 35, no. 1s, pp. 210–219, Nov. 2024, doi: 10.52783/pmj.v35.1s.2307.
- [15] C. O'Connor, A. Visentin, and S. Prestwich, "Fundamentals of Time Series Analysis in Electricity Price Forecasting," in *ITISE 2025*, Basel Switzerland: The 11th International Conference on Time Series and Forecasting, Aug. 2025, p. 16. doi: 10.3390/cmsf2025011016.
- [16] S. Liu, Z. Yuan, Q. An, and B. Zhao, "A Novel Electric Load Prediction Method Based on Minimum-Variance Self-Tuning Approach," *Processes*, vol. 13, no. 8, p. 2599, Aug. 2025, doi: 10.3390/pr13082599.
- [17] Y. Xi, X. Gan, Z. Zhan, and K. Deng, "Energy Data Forecasting Based on the STRLM Time Series Prediction Model," in *2025 10th International Conference on Electronic Technology and Information Science (ICETIS)*, IEEE, Jun. 2025, pp. 489–494. doi: 10.1109/ICETIS66286.2025.11144172.
- [18] C. Shao et al., "Real-E: A Foundation Benchmark for Advancing Robust and Generalizable Electricity Forecasting," in *Proceedings of the 34th ACM International Conference on Information and Knowledge Management*, New York: ACM, Nov. 2025, pp. 6523–6527. doi: 10.1145/3746252.3761637.
- [19] M. A. Shuvra, R. D. Sledzik, S. Zhang, T. J. Agate, G. Walker, and L. A. Freeman, "Market-Aware-Policy-Agnostic Light Duty EV Adoption Forecast: A Data Driven Logistic Model," in *2024 IEEE Kansas Power and Energy Conference (KPEC)*, IEEE, Apr. 2024, pp. 1–5. doi: 10.1109/KPEC61529.2024.10676051.
- [20] S. Jaouadi and O. Attia, "Forecasting the Energy Production in Egypt Using the Prophet of Facebook," *International Journal of Research and Innovation in Social Science*, vol. IX, no. VII, pp. 1761–1772, 2025, doi: 10.47772/IJRISS.2025.907000144.
- [21] E. Aytac, "Forecasting Turkey's Hazelnut Export Quantities with Facebook's Prophet Algorithm and Box-Cox Transformation," *ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal*, vol. 10, no. 1, pp. 33–47, Feb. 2021, doi: 10.14201/ADCAIJ20211013347.
- [22] S. Guarino, A. Buscemi, V. Di Dio, and V. Lo Brano, "Multiplicative Seasonality Prophet Model for PV Energy Forecasting and Anomaly Detection," in *2025 International Conference on Clean Electrical Power (ICCEP)*, IEEE, Jun. 2025, pp. 215–222. doi: 10.1109/ICCEP65222.2025.11143727.
- [23] Badan Pusat Statistik, "Persentase Rumah Tangga menurut Provinsi dan Sumber Penerangan Utama dari Listrik PLN (Persen)." Accessed: Apr. 10, 2026. [Online]. Available: <https://www.bps.go.id/id/statistics-table/2/ODcjMg==/persentase-rumah-tangga-menurut-provinsi-dan-sumber-penerangan-utama-dari-listrik-pln--persen-.html>