

Forecasting Analysis of Electricity Consumption in East Kolaka and Konawe Districts Using *Prophet* Method

Analisis Peramalan Konsumsi Listrik Di Kabupaten Kolaka Timur Dan Kabupaten Konawe Menggunakan Metode *Prophet*

Nur Ismi Khair¹, Ruslan², Agusrawati³

^{1,2,3}Departemen Statistika, Universitas Haluoleo, Indonesia

Email: ¹nurismikhair09@gmail.com, ²ruslantibandung@gmail.com, ³agusrawati@uho.ac.id

Received: 20 March 2025, revised: 24 April 2025, accepted: 25 April 2025

Abstract

This study aims to determine electricity consumption forecasting in East Kolaka Regency and Konawe Regency using the *Prophet* method. The data used in this study are secondary data obtained from PT PLN ULP Unaaha which consists of data on the amount of monthly electricity consumption from January 2019 to November 2023. The results showed that the *Prophet* method obtained an error calculation value using MAPE of 1.09%. So that the *Prophet* method can be used to forecast electricity consumption in East Kolaka Regency and Konawe Regency.

Keywords: Forecasting, Prophet, Electricity, consumption, MAPE, MSE

Abstrak

Penelitian ini bertujuan untuk mengetahui peramalan konsumsi listrik di Kabupaten Kolaka Timur dan Kabupaten Konawe menggunakan metode *Prophet*. Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari PT. PLN ULP Unaaha yang terdiri dari data jumlah konsumsi listrik bulanan mulai dari Januari 2019 sampai dengan November 2023. Hasil penelitian menunjukkan bahwa metode *Prophet* memperoleh nilai perhitungan *error* menggunakan MAPE sebesar 1.09%. Sehingga metode *Prophet* dapat digunakan untuk meramalkan konsumsi listrik di Kabupaten Kolaka Timur dan Kabupaten Konawe.

Kata Kunci: Peramalan, *Prophet*, Konsumsi, listrik, MAPE, MSE

1. PENDAHULUAN

Peramalan merupakan suatu usaha untuk meramalkan keadaan di masa mendatang melalui pengujian keadaan di masa lalu. Hal ini dapat dilakukan dengan melibatkan pengambilan data masa lalu dan menempatkannya ke masa yang akan datang dengan suatu bentuk model matematis [1]. Studi tentang peramalan mencakup banyak penelitian yang telah meneliti metode alternatif untuk



mengetahui metode mana yang paling efisien. Sejak tahun 1970, metode deret waktu (*time series*) digunakan dalam peramalan. Metode tersebut seperti ARMA, ARIMA, SARIMA, VAR dan sebagainya. Namun, metode tersebut memiliki keterbatasan pada asumsi data yang harus terpenuhi seperti kestasioneran data dan *white noise*, sehingga metode tersebut tidak selalu cocok pada data *real* penelitian yang seringkali ditemukan data yang tidak memenuhi asumsi. Oleh karena itu, beberapa metode peramalan telah dikembangkan selama beberapa dekade tahun terakhir. Diantara metode peramalan tersebut terdapat metode yang tidak memerlukan asumsi yang harus dipenuhi yaitu metode *Fuzzy time series*, *Random Forest*, *SVR*, *Prophet*, dan lain sebagainya.

Prophet adalah *open source software* yang dikembangkan oleh Tim Data Sains Facebook pada tahun 2017 yang dirancang untuk menangani fitur umum data *time series* dan tersedia dalam bentuk *library* di *Python* dan *R*. Dalam model *Prophet*, data *time series* didekomposisi menjadi tiga bagian utama, yaitu tren, musiman, dan hari libur [15]. *Prophet* dirancang untuk menangani data dengan komponen musiman yang kuat dan tren yang tidak linier. *Prophet* memiliki kemampuan untuk menangani berbagai jenis pola musiman (seperti musiman tahunan, mingguan, atau harian) serta pengaruh liburan dan peristiwa penting lainnya. *Prophet* secara otomatis mengidentifikasi komponen musiman dan tren tanpa memerlukan perbedaan atau analisis mendalam seperti pada ARIMA. *Prophet* lebih fleksibel dalam menangani musiman yang tidak teratur, termasuk fluktuasi musiman yang lebih kompleks, seperti variasi yang berbeda antar tahun atau perubahan tren yang lebih halus. Selain itu, *Prophet* memungkinkan kita untuk secara eksplisit memasukkan liburan dan acara penting yang dapat memengaruhi data. *Prophet* adalah pilihan yang sangat baik ketika Anda memiliki data dengan musiman yang rumit, tren yang tidak linier, atau efek liburan yang perlu diperhitungkan.

Listrik merupakan salah satu kebutuhan pokok bagi masyarakat modern. Dalam berbagai sektor kehidupan, mulai dari rumah tangga, industri, hingga pelayanan publik, listrik memainkan peranan yang sangat vital. Dengan meningkatnya kepedulian terhadap hubungan yang erat antara konsumsi listrik dan kelestarian lingkungan, peramalan penggunaan listrik menjadi semakin penting sebagai aspek kunci dari manajemen dan perencanaan energi. Memprediksi konsumsi listrik rumah tangga secara akurat tidak hanya penting bagi perusahaan energi dalam hal alokasi sumber daya dan penjadwalan jaringan, tetapi juga secara langsung berdampak pada manajemen biaya energi untuk pengguna rumah tangga. Namun demikian, peramalan konsumsi listrik rumah tangga menghadapi beberapa tantangan, termasuk kompleksitas deret waktu multidimensi, pengaruh perubahan musim dan cuaca, dan pemodelan ketergantungan jangka panjang [4]. Konsumsi listrik yang terus meningkat menjadi tantangan tersendiri bagi penyedia layanan, khususnya Perusahaan Listrik Negara (PLN), dalam memastikan distribusi yang efisien dan pasokan yang memadai. Di wilayah-wilayah yang sedang berkembang, seperti Kabupaten Kolaka Timur dan Kabupaten Konawe di Provinsi Sulawesi Tenggara, konsumsi listrik mengalami peningkatan seiring dengan pertumbuhan populasi, perkembangan sektor industri, serta peningkatan jumlah rumah tangga yang terhubung dengan jaringan listrik. PLN ULP Unaaha merupakan salah satu unit PLN di Sulawesi Tenggara yang cakupan wilayah kerjanya meliputi Kabupaten Kolaka Timur dan Kabupaten Konawe. Konsumsi listrik di pelayanan PLN ULP Unaaha pada tahun 2019 tercatat sebesar 90,54 gWh dan pada tahun 2020 sebesar 10,25 gWh yang mana terjadi peningkatan. Untuk mengantisipasi peningkatan konsumsi ini, diperlukan metode peramalan yang akurat agar PLN dan pihak terkait dapat merencanakan kebutuhan listrik dan efisiensi distribusi trafo secara *real-time* [12]. Dengan demikian, penelitian ini bertujuan untuk mengetahui hasil peramalan konsumsi listrik di Kabupaten Kolaka Timur dan Kabupaten Konawe menggunakan metode *Prophet*.

2. TINJAUAN PUSTAKA

2.1 Peramalan (Forecasting)

Peramalan merupakan upaya untuk melihat ke masa depan. Ada dua kata yang digunakan untuk menunjukkan metode peramalan numerik, yaitu peramalan dan prediksi. Peramalan adalah proses estimasi dalam situasi yang tidak diketahui. Prediksi adalah istilah yang serupa, tetapi lebih umum dan biasanya mengacu pada estimasi data deret waktu, cross-sectional, atau longitudinal. Risiko dan ketidakpastian merupakan inti dari peramalan dan prediksi. Dalam beberapa tahun terakhir, peramalan telah berkembang menjadi praktik perencanaan permintaan dalam peramalan bisnis sehari-hari untuk perusahaan manufaktur. Peramalan biasanya digunakan dalam diskusi tentang data deret waktu.

Peramalan adalah metode yang digunakan untuk memperamalan nilai di masa depan berdasarkan data masa lalu. Selain itu, peramalan juga dapat dianggap sebagai seni dan ilmu untuk memperamalan kejadian yang akan datang. Aktivitas peramalan dalam konteks bisnis bertujuan untuk memperkirakan penjualan dan penggunaan suatu produk, sehingga produk tersebut dapat diproduksi dalam jumlah yang tepat [3].

Peramalan yang dilakukan umumnya didasarkan pada masa lalu yang kemudian dianalisis dengan menggunakan metode-metode tertentu. Data masa lalu dikumpulkan, dipelajari, dianalisis dan dihubungkan dengan perjalanan waktu, karena adanya faktor waktu tersebut, maka dari data hasil analisis tersebut dapat meramalkan yang terjadi dimasa yang akan datang [2].

2.2 Time Series

Time Series adalah serangkaian titik data yang diindeks secara berurutan dari waktu ke waktu. Bentuk paling umum dari deret waktu adalah urutan pengamatan yang direkam dari waktu ke waktu [17]. Peramalan *time series* adalah bidang penelitian yang bertujuan untuk memprediksi nilai masa depan berdasarkan pola data historis. Hal ini melibatkan analisis titik data berurutan yang dikumpulkan dari waktu ke waktu untuk mengidentifikasi tren, variasi musiman, dan pola dasar lainnya yang dapat membantu mengantisipasi hasil di masa depan. Selama bertahun-tahun, langkah-langkah signifikan telah dilakukan dalam meningkatkan akurasi, ketahanan, dan penerapan teknik prakiraan deret waktu, didukung oleh kemajuan dalam daya komputasi, metode canggih, dan ketersediaan data [9].

2.3 Prophet

Model *Prophet* adalah *open source software* yang dikembangkan oleh Tim Data Sains Facebook pada tahun 2017 [16] yang dirancang untuk menangani fitur umum data *time series* dan tersedia dalam bentuk library di Python dan R [15]. Model ini menggunakan model regresi modular sederhana yang sering bekerja dengan baik dengan parameter default. Model *Prophet* pada awalnya didesain untuk meramalkan data bisnis harian yang mempertimbangkan tiga fitur dasar dari *time series* yaitu potongan tren (*piecewise trends*), beberapa musiman (*multiple seasonality*), dan hari libur (*floating holiday*) [17].


Model *Prophet* berprinsip pada kesederhanaan dan skalabilitas [6] sehingga model ini dirancang secara khusus untuk masalah peramalan bisnis dan sangat baik dalam menangani data yang hilang (*missing data*). Selain itu model *Prophet* juga unggul dalam memproses data periodisitas harian dengan outlier besar dan pergeseran tren dan dapat memodelkan beberapa periode musiman secara bersamaan [17]. Model *Prophet* telah banyak digunakan untuk berbagai macam penelitian seperti prediksi konsentrasi polusi udara di Seoul, Korea Selatan [14], peramalan temperatur udara [16], dan peramalan harga grosir makanan [6].

Berikut beberapa keunggulan dari model *Prophet* menurut Taylor dan Letham :

1. Fleksibilitas yaitu mudah dalam mengakomodasikan data musiman dengan beberapa periode.

2. Tidak perlu mencari nilai yang hilang
3. *Fitting* model yang cepat memungkinkan analisis untuk mengeksplorasi banyak spesifikasi model secara interaktif.
4. Model *Prophet* memiliki parameter yang mudah dipahami dan dapat disesuaikan oleh analisis. Selain itu, bagi analisis yang berpengalaman dengan regresi, dapat dengan mudah memperluas model untuk menambahkan komponen baru.

Model *Prophet* termasuk kedalam *semi-automaticforecast*, dimana dalam model ini terdapat pembagian tugas antara manusia dan otomatisasi. Pembagian tugas tersebut dijelaskan pada Gambar 2.1.



Gambar 2.1. Skema Forecasting Model *Prophet*

Pada model *Prophet*, proses peramalan diawali dengan proses visualisasi data sebagai salah satu gambaran dalam pembentukan model. Proses kedua merupakan pembentukan model dengan melakukan proses *tunning* terhadap parameter *trend*, *seasonal*, *holiday*, dan komponen lainnya. Selanjutnya adalah melakukan evaluasi model peramalan. Jika hasil *Mean Absolute Percentage Error* (MAPE) > 10 % atau model dirasa belum optimum maka proses dapat diulang dari proses *tuning* parameter, jika hasil MAPE < 10% maka proses dapat dilanjutkan ke tahap peramalan. Proses terakhir adalah *surface problems*, ketika terdapat permasalahan yang membutuhkan keterlibatan peneliti, maka peneliti dapat menganalisis hasil peramalan dan tanpa ragu mengubah model [10].

Prophet menggunakan model *time series* yang dapat didekomposisi dengan tiga komponen utama yaitu tren (*trend*), musiman (*seasonality*), dan liburan (*holiday*) dan model *Prophet* mengadopsi model aditif umum untuk fungsi pemulusan dan peramalannya [18] sehingga persamaannya sebagai berikut:

$$Y(t) = g(t) + s(t) + h(t) + \varepsilon \quad (2.1)$$

Dimana $g(t)$ merupakan fungsi tren yang memodelkan perubahan non-periodik dari data *time series*, $s(t)$ merepresentasikan perubahan periodik seperti musiman mingguan dan tahunan, $h(t)$ merepresentasikan efek dari hari libur yang terjadi pada jadwal yang berpotensi tidak teratur selama satu hari atau lebih, dan ε yaitu istilah kesalahan (*error*) yang merepresentasikan setiap perubahan yang tidak diakomodasi oleh model.

Dalam model *Prophet* terdapat beberapa opsi dalam melakukan proses *tunning* parameter *trend/growth* [11], yaitu Saturating Growth dengan menggunakan persamaan :

$$g(t) = \frac{C}{1 + \exp(-k(t - m))} \quad (2.2)$$

Dan *piecewise logistic growth model* dengan persamaan berikut :

$$g(t) = \frac{C_t}{1 + \exp(-(k + a(t)^T \delta)(t - (m + a(t)^T \delta)))} \quad (2.3)$$

Untuk peramalan yang tidak menunjukkan pertumbuhan yang jenuh maka tren model menjadi persamaan berikut :

$$g(t) = (k + a(t)^T \delta)t + (m + a(t)^T \gamma) \quad (2.4)$$

Musiman di *Prophet* dimodelkan oleh deret *Fourier*. Deret ini memiliki periode dan orde yang menentukan fleksibilitas musiman dengan menggunakan persamaan berikut [12]:

$$s(t) = \sum_{n=1}^N \left(a_n \cos\left(\frac{2\pi nt}{P}\right) + b_n \sin\left(\frac{2\pi nt}{P}\right) \right) \quad (2.5)$$

dengan P sebagai periode deret waktu, Dimana P = 365,25 untuk data tahunan, P = 30,5 untuk data bulanan, dan P = 7 untuk data mingguan.

Model hari libur yang didukung oleh *Prophet* menghasilkan matriks regressor

$$Z(t) = [1(t \in D_1), \dots, 1(t \in D_L)] \quad (2.6)$$

sehingga dibuat persamaan berikut

$$h(t) = Z(t)\kappa \quad (2.7)$$

Masing-masing komponen bertanggung jawab untuk menangkap perilaku yang berbeda dalam data deret waktu. Komponen tren menyesuaikan perubahan non-periodik dari waktu ke waktu, memungkinkan pergeseran tren pada titik perubahan yang ditentukan, sehingga meningkatkan kemampuan beradaptasi model. Komponen musiman memperhitungkan perubahan berkala, menggunakan deret Fourier untuk memodelkan pola berulang yang kompleks. Komponen hari libur menangkap penyimpangan dalam data karena hari libur, yang signifikan dalam banyak set data seri. Fleksibilitas dan ketahanan *Prophet* membuatnya efektif untuk menangani pencilaan dan data yang hilang, meningkatkan kegunaannya dalam aplikasi peramalan praktis [5].

2.3 Perhitungan Error

Perhitungan *error* bertujuan untuk mengukur akurasi dari model peramalan yang dibangun dengan membandingkan data uji dan latih yang telah ditentukan sebelumnya [7]. Adapun perhitungan error yang digunakan yaitu :

a. *Mean Absolute Percentage Error* (MAPE)

Nilai *Mean Absolute Percentage Error* (MAPE) dapat dihitung dengan menggunakan persamaan berikut [8] :

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (2.7)$$

Dimana :

y_i = Nilai Aktual

$\hat{y}_i$ = Nilai hasil peramalan

n = Jumlah data

b. *Mean Square Error* (MSE)

Mean Square Error (MSE) dapat dihitung dengan menggunakan persamaan berikut :

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.8)$$

3. METODOLOGI PENELITIAN

3.1 Sumber Data

Penelitian ini menggunakan data sekunder yang diperoleh dari PT. PLN (Persero) UPT Unaaha. Data yang digunakan adalah data jumlah konsumsi listrik bulanan dengan satuan *kilowatt-hour* (kWh) mulai dari Januari 2019 sampai November 2023.

3.2 Langkah Analisis

Adapun langkah-langkah penelitian sebagai berikut :

a. *Preprocessing Data*

Preprocessing data merupakan proses penyiapan data dimana data akan disesuaikan formatnya menjadi format yang diperlukan oleh model *Prophet*. Berikut format data yang diperlukan oleh model *Prophet*:

1. Nama kolom dari kolom waktu harus diubah menjadi “*ds*” dan nama kolom dari kolom nilai harus diubah menjadi “*y*”.
2. Penulisan waktu harus dalam format YYYY-MM-DD atau YYYY-MM-DD HH:MM:SS seperti (2022-06-11) atau (2022-11-22 11:30:12)

b. Inisiasi Lingkungan Komputasi

Pada tahap ini dilakukan pengimporan fungsi yang diperlukan pada *google colab research*. *Library* yang perlu diimpor antara lain *pandas* untuk penginputan dan pengeditan *dataframe*, *matplotlib*, *pyplot* untuk menampilkan visualisasi data, *Prophet* untuk mengakses model *Prophet*, *sklearn.model_selection* untuk melakukan pembagian data dan *sklearn.metrics* untuk menghitung matriks evaluasi.

c. Mendeskripsikan Data Konsumsi Listrik

Mendeskripsikan data konsumsi listrik di kabupaten kolaka timur dan kabupaten konawe dapat dilakukan dengan melihat plot atau grafik data.

d. Input Data dan *Splitting Data*

Pada tahap ini data dimasukkan kedalam lingkungan komputasi dengan menggunakan *library pandas*. Lalu selanjutnya dilakukan *splitting data* yaitu proses membagi dataset menjadi dua bagian yaitu data latih yang digunakan untuk melatih model dan data uji yang digunakan untuk menguji kinerja model. *Splitting data* dilakukan dalam penelitian untuk mengetahui seberapa akurat hasil peramalan melalui model yang dibuat terhadap data aktual konsumsi listrik dan data konsumsi listrik yang diperamalan.

e. Pemodelan

Dalam proses pemodelan ini di lakukan fitting model dengan dengan penyetelan *hyperparameter* untuk menghindari terjadinya *underfitting* dan *overfitting*. Adapun parameter yang di lakukan penyetelan yaitu *changepoint prior scale* dan *seasonality prior scale*.

f. Evaluasi Kinerja Model

Evaluasi kinerja model dilakukan untuk menilai seberapa baik model bekerja dalam memperamalan data yang belum pernah dilihat sebelumnya dalam hal ini model digunakan untuk memperamalan pada data uji. Dari hasil peramalan tersebut dapat dibandingkan dengan data aktual untuk mengukur keakuratannya. Untuk menghitung keakuratan hasil peramalan dilakukan perhitungan error dengan menggunakan *Mean Squared Error* (MSE) dan *Mean Absolute Percentage Error* (MAPE).

g. Identifikasi Gejala *Underfitting* dan *Overfitting*

Pada tahap ini model yang paling cocok dengan data diidentifikasi apakah mengalami gejala *underfitting*, *overfitting*, atau tidak sama sekali. Bila terdapat gejala *underfitting* dan *overfitting*, maka dilakukan pengaturan kembali *hyperparameter* pada model *Prophet*. Gejala *underfitting* dan *overfitting* dapat diidentifikasi dengan cara membandingkan performa model pada data latih dengan performa model pada data uji. Adapun ciri-ciri model yang mengalami *underfitting* ataupun *overfitting* sebagai berikut :

- Gejala *underfitting* ditandai dengan performa model pada data latih dan performa model pada data uji yang buruk
- Gejala *overfitting* ditandai dengan performa model pada data latih yang baik, namun performa model pada data uji buruk dan selisih dari keduanya cukup besar.


h. Peramalan

Pada tahapan ini dilakukan peramalan dengan menggunakan *hyperparameter* terbaik yang telah diperoleh sebelumnya. Peramalan yang akan dilakukan adalah peramalan dengan jangka waktu pendek, karena model *Prophet* memiliki kualitas peramalan yang baik bila jangka waktu peramalannya tidak terlalu panjang. Maka, peramalan yang dilakukan adalah untuk 7 periode ke depan yaitu periode Desember 2023 sampai Juni 2024.

4. HASIL

4.1 Deskripsi Data Konsumsi Listrik Kabupaten Kolaka Timur dan Kabupaten Konawe

Pendeskripsi data konsumsi listrik menggunakan visualisasi data untuk melihat pola yang terbentuk. Berikut grafik yang terbentuk berdasarkan data yang terdiri dari Januari 2019 sampai November 2023.



Gambar 4.1. Grafik Konsumsi Listrik

4.2 Splitting Data

Splitting data yaitu proses membagi dataset menjadi dua bagian yaitu data latih yang digunakan untuk melatih model dan data uji yang digunakan untuk menguji kinerja model. Data splitting dilakukan dalam penelitian untuk mengetahui seberapa akurat hasil peramalan melalui model yang dibuat terhadap data konsumsi listrik asli dan konsumsi listrik yang di peramalan. Pada penelitian ini data terbagi dari Januari 2019 hingga Desember 2022 sebagai data latih dan Januari 2023 sampai November 2023 menjadi data uji.

4.3 Pemodelan

penyetelan hyperparameters dilakukan untuk menentukan nilai optimum dari hyperparameters untuk model tersebut dengan melakukan proses tuning


Tabel 4. 1 Hasil Evaluasi *Tunning hyperparameters*

Changepoint Prior Scale	Seasonality Prior Scale	Seasonality Mode	MSE
0.001	0.01	Additive	0.11852
0.001	0.1	Additive	0.09835
0.001	1	Additive	0.08689
0.001	10	Additive	0.08112
0.01	0.01	Additive	0.11565
0.01	0.1	Additive	0.09526
0.01	1	Additive	0.08603
0.01	10	Additive	0.08607
0.1	0.01	Additive	0.07137
0.1	0.1	Additive	0.05402
0.1	1	Additive	0.04640
0.1	10	Additive	0.04720
0.5	0.01	Additive	0.05359
0.5	0.1	Additive	0.03787
0.5	1	Additive	0.03376
0.5	10	Additive	0.03397

Berdasarkan Tabel 4.1, dapat dilihat bahwa pemilihan *hyperparameter* yang optimal menghasilkan *Mean Squared Error* (MSE) terkecil pada nilai *changepoint prior scale* sebesar 0.5 dan *seasonality prior scale* sebesar 1. Nilai MSE terkecil yang diperoleh adalah 0.03376. Adapun nilai *Mean Absolute Percentage Error* (MAPE) pada model ini sebesar 1.48%. Hal ini menunjukkan bahwa model dengan pengaturan tersebut memberikan kinerja terbaik dalam memperamalan data.

Oleh karena itu, dapat disimpulkan bahwa model dengan pengaturan *hyperparameter* ini mampu memberikan hasil peramalan yang paling akurat.

Dari *hyperparameter* tersebut dapat di lihat hasil peramalan pada data latih. Berikut grafik perbandingan data aktual dan data hasil peramalan pada data latih setelah dilakukan *tunning hyperparameter*.



Gambar 4.2. Perbandingan data aktual dan data peramalan pada data latih

Gambar tersebut menunjukkan perbandingan antara data aktual dan hasil peramalan konsumsi listrik untuk data latih dari periode Januari 2019 hingga Desember 2022. Garis merah mewakili data aktual, sedangkan garis biru mewakili data peramalan. Dari grafik tersebut, terlihat bahwa hasil peramalan mengikuti pola data aktual dengan cukup baik, meskipun terdapat beberapa periode di mana peramalan sedikit berbeda dari data aktual. Hal ini menunjukkan bahwa model peramalan yang digunakan mampu menangkap tren konsumsi listrik dengan akurasi yang cukup tinggi selama periode pelatihan.

4.4 Evaluasi Kinerja Model

Setelah tahap pemodelan, tahap selanjutnya yaitu evaluasi model dengan cara melakukan peramalan menggunakan data uji untuk melihat seberapa baik model bekerja pada data yang belum pernah dilihat sebelumnya.

4.4.1 Contoh Perhitungan Peramalan Menggunakan Data Uji

Perhitungan ini menggunakan nilai-nilai parameter model yang diperoleh berdasarkan iterasi dari hasil *running* program *python* menggunakan *Google Colab Research*. Perhitungan ini mencakup komponen *trend* dan musiman sesuai dengan model *Prophet* yang telah di bangun. Berikut nilai-nilai parameter yang digunakan.

Tabel 4. 2 Nilai Parameter Model *Prophet*

Param	Value
k (<i>k</i>)	0.289989
m (<i>m</i>)	0.669018
Changepoint (<i>S</i>)	[0.02167832, 0.06293706, 0.08391608, 0.12657343, 0.1482575, 0.19090909, 0.21258741, 0.25524476, 0.27692308, 0.31888112, 0.33986014, 0.38251748, 0.4041958, 0.44685315, 0.46853147,

	0.51118881, 0.53286713, 0.57412587, 0.5951049, 0.63776224, 0.65944056, 0.7020979, 0.72377622, 0.76643357, 0.78811189]
Delta (δ)	[-2.98439e-09, 1.03403e-01, 7.45388e-04, 2.92196e-04, 1.74624e-04, 4.23396e-04, -5.43848e-09, -3.75808e-04, 4.13516e-09, 1.79187e-04, 7.45595e-05, 7.89389e-05, 8.41137e-05, 1.6946e-01, 5.99602e-05, -1.18519e+00, -7.87116e-09, 5.9285e-09, 8.94509e-01, 7.42486e-04, 2.79658e-04, -2.30704e-06, -2.64101e-02, 1.44572e-04, -8.29565e-10]
Beta (β)	[0.00032973, 0.0143488, 0.0258449, 0.00176488, 0.128678, -0.0407082, 0.190882, 0.0165945, 0.144182, 0.0360333, 0.0931982, -0.00053665, 0.165426, -0.0247722, 0.172866, 0.0141482, 0.122759, 0.064364, 0.0738339, -0.0297964]
Gamma ($\gamma = -S_j \delta_j$)	[6.46966e-11, -6.50788e-03, -6.25500e-05, -3.69842e-05, -3.69842e-05, -2.58883e-05, -8.08301e-05, 1.15615e-09, 9.59230e-05, -1.14512e-09, -5.71394e-05, -2.53398e-05, -3.01955e-05, -3.39984e-05, -7.57237e-02, -2.80932e-05, 6.05856e-01, 4.12344e-09, -3.40375e-09, -5.32327e-01, -4.73530e-04, -1.84418e-04, 1.61977e-06, 1.91150e-02, -1.10805e-04, 6.53790e-10]
y_scale	10614223
t_scale	1430 days
Start_date	2019-01-01

Parameter k (*Growth Rate*) adalah laju pertumbuhan tren linear awal. *Prophet* mengestimasi k selama proses fitting berdasarkan data. Nilai ini menunjukkan seberapa cepat nilai y meningkat atau menurun seiring waktu sebelum adanya perubahan tren (*changepoint*). Parameter m (*Offset Intercept*) adalah intersep dari *tren linear* pada awal data, yaitu titik awal garis tren jika tidak ada perubahan tren. Dihitung berdasarkan posisi awal data pada waktu $t=0$. *Changepoints* atau titik perubahan adalah titik waktu di mana tren data mengalami perubahan signifikan. *Prophet* secara *default* memilih hingga 25 titik *changepoint* secara otomatis dalam 80% awal data. Delta (δ) merupakan besarnya perubahan laju pertumbuhan (k) setelah masing-masing *changepoint*, estimasi delta diperoleh melalui optimasi saat *fitting*. Beta (β) merupakan Koefisien untuk fungsi musiman (*seasonality*), *Prophet* memodelkan *seasonality* sebagai kombinasi basis *Fourier*. Nilai-nilai beta adalah koefisien hasil fitting terhadap basis tersebut. Jumlah beta bergantung pada *fourier_order* saat menambahkan *seasonality*. Gamma (γ) merupakan koreksi tren akibat delta, dihitung langsung dari delta dan *changepoint* saat *fitting*. y_scale merupakan skala maksimum data target (y) digunakan untuk normalisasi selama pelatihan. t_scale merupakan skala waktu (jumlah hari dari awal ke akhir data) juga digunakan untuk normalisasi waktu (t). Dan *start_date* merupakan tanggal awal data pelatihan.

Berikut contoh perhitungan untuk 1 Januari 2023

1) Identifikasi *trend* (t)

Berdasarkan nilai parameter yang diperoleh dari hasil *running* program, model *trend* yang dihasilkan pada metode *Prophet* ini adalah *linear trend with changepoints*. Oleh karena itu, perhitungan dilakukan dengan menggunakan persamaan (2.4) berikut :

$$g(t) = (k + a(t)^T \delta)t + (m + a(t)^T \gamma)$$

Dimana,

$$\begin{aligned} t &= (\text{forecat_date} - \text{start_date})/t_scale \\ &= ((2023 - 01 - 01) - (2019 - 01 - 01))/1430 \\ &= 1461/1430 \\ &= 1,02167832 \end{aligned}$$

$$a(t)^T \delta = \sum_{j:t>S_j} \delta_j = -0,041327142$$

$$a(t)^T \gamma = \sum_{j:t>S_j} \gamma_j = 0,009360336$$

Maka ,

$$\begin{aligned} g(t) &= (0,289988 + (-0,0413271)) \times 1,02167832 + (0,669018 + 0,0093603) \\ &= 0,932429743 \\ &= 0,932429743 \times y_scale \\ &= 0,932429743 \times 10614223 \end{aligned}$$

$$g(t) = 9897017,2314$$

$g(t)$ hanya untuk $t = 1$ Januari 2023. Jika terdapat perubahan pada $g(t)$ untuk waktu yang berbeda, dapat dikatakan $g(t)$ dinamis. Namun, jika nilai $g(t)$ tetap sama atau hanya sedikit berubah, bisa disimpulkan bahwa pengaruhnya relatif stabil atau konstan.

2) Identifikasi Musiman

Dengan menggunakan persamaan (2.5) berikut :

$$s(t) = \sum_{n=1}^N \left(a_n \cos\left(\frac{2\pi nt}{P}\right) + b_n \sin\left(\frac{2\pi nt}{P}\right) \right)$$

Dimana,

$$\begin{aligned} t &= (\text{forecast date} - \text{start date}) \\ &= ((2023 - 01 - 01) - (2019 - 01 - 01)) \\ &= 1461 \text{ (hari)} \end{aligned}$$

Pendefinisian t pada komponen tren ($g(t)$) berbeda dengan pada komponen musiman ($s(t)$). Komponen $g(t)$ merepresentasikan tren jangka panjang, sehingga t dihitung menggunakan rumus:

$$t = (\text{forecat_date} - \text{start_date})/t_scale$$

Di mana t_scale adalah total panjang rentang waktu data historis. Normalisasi ini dilakukan untuk menjaga stabilitas perhitungan numerik dan mempermudah proses identifikasi titik perubahan tren (changepoints) dalam skala waktu yang panjang. Sebaliknya, pada komponen musiman $s(t)$, yang bersifat periodik dan berulang (misalnya tahunan atau mingguan), nilai t tidak dinormalisasi terhadap panjang data. Hal ini karena $s(t)$ hanya membutuhkan informasi posisi waktu dalam satu siklus musiman, seperti hari ke-1 hingga ke-365 dalam satu tahun. Oleh karena itu, t pada $s(t)$ cukup dihitung sebagai selisih tanggal terhadap titik awal tanpa pembagian terhadap t_scale .

$$\begin{aligned}
s(t) &= \left(a_1 \cos\left(\frac{2\pi t}{365.25}\right) + b_1 \sin\left(\frac{2\pi t}{365.25}\right) \right) + \dots + \\
&\quad \left(a_{10} \cos\left(\frac{20\pi t}{365.25}\right) + b_{10} \sin\left(\frac{20\pi t}{365.25}\right) \right) \\
&= ((0,0003287) \times \cos(25,1327) + (0,0143488) \times \sin(25,1327)) + \dots + \\
&\quad (0,0738339) \times \cos(251,3274) + (-0,0297964) \times \sin(251,3274)) \\
&= 0,000328730 + \dots + 0,036033300 \\
&= 0.02189288 \\
s(t) &= 0.02189288 \times y_{scale} \\
&= 0.02189288 \times 10614223 \\
&= 232375,9792
\end{aligned}$$

3) Peramalan tanggal ke- t

Setelah diperoleh nilai *trend* dan nilai *seasonality*, kedua nilai tersebut dijumlahkan untuk mendapatkan hasil peramalan pada tanggal 1 Januari 2023 dengan persamaan (2.12) berikut.

$$\begin{aligned}
Y(t) &= k + a(t)^T \delta t + (m + a(t)^T \gamma) + \sum_{n=1}^N \left(a_n \cos\left(\frac{2\pi nt}{P}\right) + b_n \sin\left(\frac{2\pi nt}{P}\right) \right) \\
&= 9897017,2314 + 232375,9792 \\
&= 10129393,2106
\end{aligned}$$


Jadi hasil peramalan untuk tanggal 1 Januari 2023 sebesar 10129393,2106

Dengan perhitungan yang sama sehingga di peroleh keseluruhan nilai hasil peramalan pada data uji sebagai berikut.

abel 4. 3 Hasil Peramalan pada Data Uji

Periode	Data Aktual	Data Peramalan
2023-01-01	10123748	10129404
2023-02-01	9104036	9210230
2023-03-01	9920697	10016598
2023-04-01	1043109	10451423
2023-05-01	10699862	10877161
2023-06-01	9854558	9775449
2023-07-01	9949932	9724741
2023-08-01	9854913	9821496
2023-09-01	9698857	9763617
2023-10-01	10713162	10911827
2023-11-01	11125961	10902118

Perbandingan antara data aktual dan hasil peramalan menunjukkan seberapa akurat model *Prophet* dalam memperamalan data jumlah konsumsi Listrik. Dalam beberapa periode, hasil peramalan cukup mendekati data aktual, sementara pada periode lainnya terdapat perbedaan yang lebih signifikan. Berikut grafik perbandingan data aktual dan data hasil peramalan pada data uji.



Gambar 4.3. Perbandingan data aktual dan data peramalan pada data uji

Dari gambar diatas terlihat bahwa hasil peramalan cukup mengikuti tren dari data aktual, meskipun terdapat beberapa perbedaan terutama pada periode antara April hingga Mei 2023 serta pada Oktober hingga November 2023, di mana peramalan sedikit lebih tinggi atau lebih rendah daripada data aktual. Hal ini menunjukkan bahwa model peramalan memiliki kemampuan yang cukup baik dalam memperamalan data uji, meskipun masih ada ruang untuk perbaikan dalam beberapa periode tertentu.

4.4.2 Akurasi Peramalan pada Data Uji

Ketepatan hasil peramalan pada data uji dapat dievaluasi dengan menggunakan *Mean Absolute Percentage Error* (MAPE). Dengan menggunakan persamaan (2.7) di peroleh nilai MAPE sebesar 1,09%. Nilai MAPE di bawah 10% dianggap sebagai kriteria yang sangat baik dalam keakuratan peramalan.

4.5 Identifikasi Gejala *Underfitting* dan *Overfitting*

Berdasarkan hasil evaluasi model, diperoleh nilai MAPE pada data latih sebesar 1.48% dan pada data uji sebesar 1.09%. Kedua nilai ini berada pada rentang di bawah 10%, yang menandakan akurasi yang sangat baik. Oleh karena itu, dapat disimpulkan bahwa tidak terjadi gejala *underfitting* ataupun *overfitting* pada model. Dengan demikian, model tersebut dapat digunakan untuk meramalkan jumlah konsumsi listrik untuk periode berikutnya.

4.6 Peramalan Konsumsi Listrik Periode Berjalan

Setelah mendapatkan nilai *hyperparameters* yang optimum dan tidak terdapat gejala *underfitting* ataupun *overfitting* pada model, selanjutnya melakukan peramalan dengan model tersebut pada 7 periode selanjutnya yaitu pada periode Desember 2023 sampai Juni 2024. Berikut tabel hasil peramalan.

Tabel 4.4. Peramalan Konsumsi Listrik 7 Periode Selanjutnya

Periode	Hasil Ramalan
Desember 2023	9235816
Januari 2024	10499341
Februari 2024	10751684
Maret 2024	11125447
April 2024	11525993
Mei 2024	10399363
Juni 2024	10403227

Tabel diatas menampilkan hasil peramalan konsumsi listrik selama periode berjalan dimulai dari Desember 2023 hingga Agustus 2024. Hasil peramalan menunjukkan bahwa konsumsi listrik pada Desember 2023 diperkirakan mencapai 9235816 kwh. Selanjutnya, pada Januari 2024, konsumsi listrik diperamalan akan meningkat menjadi 10499341 kwh. Peningkatan ini berlanjut pada Februari 2024 dengan konsumsi listrik sebesar 10751684 kwh. Pada Maret 2024, konsumsi listrik diperkirakan meningkat menjadi 11125447 kwh. April 2024 diperkirakan menjadi bulan dengan konsumsi listrik tertinggi, yaitu sebesar 11525993 kwh. Mei 2024 diperkirakan terjadi penurunan menjadi 10399363 kwh. Dan pada Juni 2024, konsumsi listrik diperamalan akan kembali meningkat menjadi 10403227 kwh. Peramalan konsumsi listrik ini diharapkan dapat membantu dalam mengelola pasokan dan permintaan listrik, serta dalam menyusun strategi efisiensi energi yang lebih baik.

5. PEMBAHASAN

Berdasarkan grafik pada gambar 4.1, konsumsi listrik di Kabupaten Kolaka Timur dan Konawe menunjukkan adanya tren peningkatan konsumsi listrik yang cukup linear dan konsisten dari tahun ke tahun. Data dimulai dari tahun 2019 dengan konsumsi listrik sebesar 7.332.529 kwh dan terus meningkat hingga 11.125.961 kwh pada November 2023. Terlihat adanya tren peningkatan konsumsi listrik dengan lonjakan-lonjakan tertentu pada beberapa periode. Ada beberapa faktor yang mungkin menyebabkan lonjakan pada grafik konsumsi listrik tersebut seperti perubahan musiman misalnya saat musim panas ketika penggunaan AC meningkat. Selain itu di beberapa periode, lonjakan konsumsi listrik bisa terjadi karena adanya acara atau perayaan besar yang membutuhkan banyak listrik, seperti festival, konser, atau acara keagamaan.

Pada tahap pemodelan, model *Prophet* akan memilih *trend* dan efek musiman secara otomatis. Untuk efek musiman, *Prophet* akan memilih frekuensi yang mungkin terjadi musiman dalam data. Walaupun data tidak menunjukkan adanya pola musiman yang kuat, namun memasukkan efek musiman kedalam model memberikan akurasi yang lebih baik dibanding tanpa memasukkan efek musiman, dimana hasil akurasi pada model tanpa efek musiman lebih besar di bandingkan dengan model menggunakan efek musiman. Dari hasil otomatisasi *Prophet* mendeteksi *trend* berupa *linear*, kemungkinan efek musiman tahunan dan mode musiman berupa *additive*. Efek hari libur tidak dapat di masukkan kedalam model karena tidak terdapat tanggal-tanggal yang memuat hari libur pada dataset.

Dari hasil peramalan pada data uji diperoleh nilai MAPE sebesar 1,09% sedangkan pada penelitian yang dilakukan oleh Sri Fitriyanti Rezki menggunakan data konsumsi listrik yang sama dengan menggunakan metode *Fuzzy Time Series* model *Markov Chain* menghasilkan nilai MAPE sebesar 2,72% [13]. Dengan demikian, dapat disimpulkan bahwa metode *Prophet* memiliki tingkat keakurasian yang lebih akurat dalam meramalkan konsumsi listrik di Kabupaten Kolaka Timur dan Kabupaten Konawe.

DAFTAR PUSTAKA

- [1] Armi, A. E., Kridalaksana, A. H., & Arifin, Z., 2019. Peramalan Angka Inflasi Kota Samarinda Menggunakan Metode Double Exponential Smoothing (Studi Kasus : Badan Pusat Statistik Kota Samarinda). *Informatika Mulawarman : Jurnal Ilmiah Ilmu Komputer*, Vol. 14(1), No. 21.
- [2] Fauziah, Ningsih, Y. I., & Setiarini, E., 2019. Analisis Peramalan (Forecasting) Penjualan Jasa Pada Warnet Bulian City di Muara Bulian. *Jurnal Ilmiah Ekonomi Dan Bisnis*, Vol. 10(1), No. 61–67.

- [3] Hamirsa, M. H., & Rumita, R., 2022. Usulan Perencanaan Peramalan (Forecating) dan Safety Stock Persediaan Spare Part Busi Champion Type RA7YC-2 (EV-01/EW-01/2) Menggunakan metode Time Series Pada PT Triangle Motorindo Semarang. *Industrial Engineering Online Journal*, Vol. 11(1), No. 1–10.
- [4] Li, Y., 2024. Energy consumption forecasting with deep learning. *Journal of Physics: Conference Series*, 2711(1).
- [5] Maleki, N., Lundström, O., Musaddiq, A., Olsson, T., Ahlgren, F., & Jeansson, J., 2024. Future energy insights: Time-series and deep learning models for city load forecasting. *Applied Energy*, 374(June), 124067.
- [6] Menculini, L., Marini, A., Proietti, M., Garinei, A., Bozza, A., Moretti, C., & Marconi, M. (2021). Comparing Prophet and Deep Learning to ARIMA in Forecasting Wholesale Food Prices. *Forecasting*, Vol. 3(3), No. 644–662.
- [7] Muzakki, M. A., Sabila, M. A., Sundari, S., & Wisnuadhi, B., 2021. Analisis Algoritma Prophet untuk Memprediksi Harga Pangan di Kota Bandung. *Prosiding Industrial Research Workshop and National Seminar*, Vol. 12, No. 659–664.
- [8] Nabillah, I. & Ranggadara, I., 2020. Mean Absolute Percentage Error untuk Evaluasi Hasil Prediksi Komoditas Laut. *JOINS (Journal of Information System)*, Vol. 5(2), No. 250–255.
- [9] Peteleaza, D., Matei, A., Sorostinean, R., Gellert, A., Fiore, U., Zamfirescu, B. C., & Palmieri, F., 2024. Electricity consumption forecasting for sustainable smart cities using machine learning methods. *Internet of Things (Netherlands)*, Vol. 27(June), 101322.
- [10] Pontoh, R. S., Zahroh, S., Nurahman, H. R., Aprillion, R. I., Ramdani, A., & Akmal, D. I., 2021. Applied of feed-forward neural network and facebook Prophet model for train passengers forecasting. *Journal of Physics: Conference Series*, Vol. 1776(1).
- [11] Prakoso, F. B., Darmawan, G., & Bachrudin, A., 2023. Penerapan Metode Facebook Prophet Untuk Meramalkan Jumlah Penumpang Trans Metro Bandung Koridor 1. *ARMADA : Jurnal Penelitian Multidisiplin*, Vol. 1(3), No. 133–147.
- [12] Rahmawati, T., Sudarmana, L., & Priyanto, A., 2020. Penerapan Metode Arima Box-Jenkins Untuk Peramalan Konsumsi Listrik. *Politeknosains*, Vol. XIX(1), No. 6–11.
- [13] Rezki, S. F., 2024. Metode Fuzzy Time Series Markov Chain dan Fuzzy Time Series Chen untuk Peramalan Konsumsi Listrik Studi Kasus : ULP Unaaha. Skripsi, Universitas Halu Oleo.
- [14] Shen, J., Valagolam, D., & McCalla, S., 2020. Prophet forecasting model: A machine learning approach to predict the concentration of air pollutants (PM2.5, PM10, O3, NO2, SO2, CO) in Seoul, South Korea. *PeerJ*, Vol. 8(2).
- [15] Taylor, S. J., & Letham, B., 2017. Business Time Series Forecasting at Scale. *PeerJ Preprints*, Vol. 35(8), No. 48–90.
- [16] Toharudin, T., Pontoh, R. S., Caraka, R. E., Zahroh, S., Lee, Y., & Chen, R. C. (2023). Employing long short-term memory and Facebook prophet model in air temperature forecasting. *Communications in Statistics: Simulation and Computation*, Vol. 52(2), No. 279–290.
- [17] Zamanzadeh Darban, Z., Webb, G. I., Pan, S., Aggarwal, C., & Salehi, M., 2024. Deep Learning for Time Series Anomaly Detection: A Survey. *ACM Computing Surveys*, 57(1).
- [18] Zhao, N., Liu, Y., Vanos, J. K., & Cao, G., 2018. Day-of-week and seasonal patterns of PM2.5 concentrations over the United States: Time-series analyses using the Prophet procedure. *Atmospheric Environment*, Vol. 192(April), No. 116–127.