

IMPLEMENTASI MODEL FACEBOOK PROPHET DALAM MERAMALKAN JUMLAH PENGUNJUNG WISATA EDUKASI

Ananda Firly Amelia, Ade Eviyanti, Ika Ratna Indra Astutik, Hindarto

Informatika, Universitas Muhammadiyah Sidoarjo

Jl. Raya Gelam No.250, Pagerwaja, Gelam, Kec. Candi, Kabupaten Sidoarjo, Jawa Timur

adeeviyanti@umsida.ac.id

ABSTRAK

Wisata edukasi Kampung Lali Gadget (KLG) menghadapi tantangan operasional akibat fluktuasi jumlah pengunjung yang sangat ekstrem, mencapai 98% antara bulan terendah dan tertinggi. Ketidakpastian ini menjadi kendala bagi pihak pengelola dalam perencanaan kurikulum permainan, bahan ajar, serta alokasi sumber daya manusia. Penelitian ini bertujuan untuk mengimplementasikan model Facebook Prophet guna menghasilkan peramalan jumlah pengunjung yang akurat sebagai panduan operasional. Metode yang digunakan adalah analisis deret waktu menggunakan algoritma Prophet yang dioptimalkan dengan penambahan *extra regressor* berupa hari libur nasional, libur akademik, dan *event* lokal KLG. Untuk mendapatkan model dengan nilai optimum, dilakukan tahapan *hyperparameter tuning* menggunakan metode *Grid Search* pada parameter *prior scale* yang dilanjutkan dengan *manual fine-tuning* untuk menghindari *overfitting*. Hasil penelitian menunjukkan bahwa Model Prophet 3 memberikan akurasi terbaik dengan nilai MAPE sebesar 20,93% (kategori baik). Hasil peramalan selama enam bulan ke depan memprediksi puncak kunjungan pada Januari 2026 sebanyak 1.940 pengunjung dan titik terendah pada April 2026 sebanyak 36 pengunjung. Hasil ini memberikan dasar strategis bagi pengelola dalam pengaturan jadwal relawan dan pemeliharaan fasilitas.

Kata kunci : Peramalan, Wisata Edukasi, Facebook Prophet, Extra Regressor

1. PENDAHULUAN

Wisata edukasi merupakan bentuk kegiatan wisata yang menggabungkan rekreasi dengan proses pembelajaran melalui pengalaman langsung. Pendekatan ini memungkinkan pengunjung memperoleh pengetahuan dan keterampilan secara langsung di lingkungan nyata, sehingga proses belajar menjadi lebih menarik dan bermakna [1]. Salah satu destinasi yang menerapkan konsep ini adalah Kampung Lali Gadget (KLG), salah satu wisata edukasi yang berupaya mengatasi dampak negatif *gadget* dengan memberikan ruang bagi anak – anak untuk beraktivitas tanpa *gadget*. Slogan utamanya bertema "Dolanan Tanpa Gadget" serta mengusung konsep kampung tematik yang berfokus pada permainan tradisional seperti nembang dolanan, egrang, gobak sodor, dakon serta tema permainan berbasis bahan alami seperti, seperti dolanan biting, dolanan banyu, dan dolanan gedebok [2]. Konsep detoks digital menjadikan KLG memiliki daya tarik tersendiri bagi orang tua dan institusi pendidikan yang peduli terhadap tumbuh kembang anak.

Seiring meningkatnya popularitas KLG, jumlah kunjungan menunjukkan fluktuasi yang signifikan dari waktu ke waktu. Berdasarkan data internal pengelola, diketahui fluktuasi jumlah pengunjung pada tahun 2024 mencapai 98% (dari 41 pengunjung pada bulan terendah menjadi 2.281 pengunjung pada bulan tertinggi). Ketidakpastian jumlah pengunjung ini menyebabkan kesulitan dalam merencanakan dan menyiapkan bahan ajar, kurikulum permainan, hingga perencanaan sumber daya manusia, khususnya jumlah relawan yang dibutuhkan. Oleh karena itu, diperlukan

metode peramalan yang akurat untuk mendukung efisiensi dan keberlanjutan operasional KLG.

Sebagai solusi atas permasalahan tersebut, penelitian ini menggunakan Model Prophet, salah satu metode peramalan yang dikembangkan oleh Tim Ilmu Data Facebook (kini Meta). Model ini dipilih karena kemampuannya yang dapat menangani berbagai fitur dalam data time series, didekomposisi menjadi 3 bagian utama yakni komponen *trend*, *seasonality*, dan *holidays* [3]. Selain itu, Prophet juga berfungsi dengan baik jika data time series yang memiliki efek musiman yang kuat, namun model Prophet pun masih dapat meramalkan data yang tidak memiliki efek musiman [4]. Keandalan model ini telah terbukti dalam berbagai studi, seperti peramalan jumlah penumpang Trans Metro Bandung Koridor 1 dengan menggunakan model Facebook Prophet serta mendapatkan hasil peramalan selama enam bulan kedepan, diperoleh evaluasi model dengan nilai MAPE pada data tes 5.21% dan pada data uji 12.01% yang artinya sangat baik [5]. Penelitian tentang peramalan menggunakan model Prophet juga dilakukan pada jumlah calon mahasiswa baru [6] dan jumlah pengunjung museum wisata edukasi [7].

Meskipun penelitian-penelitian tersebut menunjukkan keunggulan Model Prophet dalam menangani data *time series* dengan komponen musiman yang kompleks, belum ada penelitian yang secara spesifik menerapkannya untuk meramalkan jumlah pengunjung yang sangat dipengaruhi oleh program tematik dan isu sosial seperti di KLG, khususnya dengan integrasi faktor eksternal spesifik. Berdasarkan urgensi tersebut, penelitian ini bertujuan untuk menerapkan Algoritma Model Prophet guna

menghasilkan peramalan jumlah pengunjung Kampung Lali Gadget yang akurat. Secara spesifik, penelitian ini berfokus pada optimalisasi model dengan mempertimbangkan pengaruh faktor eksternal (hari libur nasional, libur akademik, dan *event* lokal), menghasilkan prediksi jumlah pengunjung periode 6 bulan ke depan sebagai panduan operasional, serta mengevaluasi akurasi model berdasarkan metrik MAPE (*Mean Absolute Percentage Error*).

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Sejumlah penelitian telah berfokus pada peramalan menggunakan model *Facebook Prophet*,

Prakoso dkk. [5] menerapkan metode *Facebook Prophet* dengan penambahan *extra regressor* berupa hari libur nasional untuk meramalkan jumlah penumpang Trans Metro Bandung. Hasil penelitian mereka menunjukkan tingkat akurasi yang sangat baik dengan nilai MAPE uji sebesar 12,01%.

Putri dan Kristianto [6] menggunakan metode *Facebook Prophet* untuk memprediksi jumlah pendaftar mahasiswa baru di Universitas XYZ dengan dataset harian periode 2020–2023. Melalui pra-pengolahan data berupa *zero-filling*, penelitian ini berhasil menghasilkan model yang akurat dengan rata-rata nilai RMSE sebesar 0,44578.

Kemudian Lifa dan Yuliansyah [7] menggabungkan metode *Moving Average* dan *Prophet* untuk meramalkan pengunjung Museum Muhammadiyah. Hasilnya menunjukkan tingkat akurasi sangat baik pada data harian dengan MAPE sebesar 5,58%, yang menegaskan bahwa penggunaan skala data harian serta penanganan pola musiman yang tepat dapat meningkatkan performa model secara signifikan.

Ridla dkk. [8] melakukan studi komparatif antara metode SARIMA, LSTM, dan *Prophet* untuk memprediksi kedatangan wisatawan dan penumpang bandara. Hasil evaluasi menggunakan RMSE dan MSE menunjukkan bahwa pada dataset tersebut, SARIMA memiliki performa yang lebih unggul dibandingkan LSTM dan *Prophet* dalam menangani data deret waktu bulanan.

Berikutnya, Roosaputri dan Dewi [9] membandingkan algoritma ARIMA, *Prophet*, dan LSTM untuk memprediksi penjualan tiket di Saloka Theme Park. Hasil penelitian menunjukkan bahwa model ARIMA(1,0,1) memberikan performa terbaik dengan nilai RMSE 762,009, mengungguli *Prophet* dan LSTM dalam konteks prediksi penjualan tiket wisata.

Meskipun penelitian mengenai metode *Prophet* terbukti efektif pada berbagai sektor [5] [7], Penelitian terdahulu menunjukkan keterbatasan dalam memodelkan faktor eksternal secara komprehensif. penelitian terdahulu umumnya masih terbatas pada penggunaan hari libur nasional tanpa mempertimbangkan variabel eksternal lokal secara spesifik. Padahal, operasional Kampung Lali Gadget

(KLG) erat kaitannya dengan pola akademik dan agenda internal. Oleh karena itu, penelitian ini berfokus pada optimalisasi model *Prophet* melalui penambahan *extra regressor* berupa hari libur akademik dan *event* lokal untuk meningkatkan akurasi peramalan.

2.2. Time Series Forecasting

Peramalan deret waktu (*time series forecasting*) merupakan teknik analisis data yang digunakan untuk memprediksi nilai di masa depan berdasarkan pola dari data historis. Teknik ini menganalisis data masa lalu hingga titik waktu tertentu sebagai dasar untuk memperkirakan nilai selanjutnya [10]. Peramalan deret waktu banyak digunakan dalam berbagai bidang, seperti peramalan permintaan, analisis keuangan, dan perencanaan operasional.

2.3. Model Facebook Prophet

Model *Prophet* adalah model peramalan yang dikembangkan oleh tim Data Science Facebook pada tahun 2017 dapat dijalankan dalam bahasa R maupun Python. *Prophet* mengadopsi pendekatan *generative additive model* (GAM) untuk memodelkan data, masing – masing komponen ditambahkan (*additive*) untuk melakukan penyesuaian melalui *smoothing* dan peramalan [11]. Sebagaimana dijelaskan oleh [3] bahwa model *Prophet* didekomposisi menjadi tiga komponen utama yakni, *trend*, *seasonality*, dan *holidays*. Sehingga, persamaan umum model *Prophet* adalah sebagai berikut :

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

Dimana,

- $g(t)$ = fungsi *trend* yang memodelkan perubahan yang tidak bersifat periodik
- $s(t)$ = komponen *seasonality* yang menggambarkan perubahan periodik (tahunan)
- $h(t)$ = pengaruh hari libur yang terjadi pada hari – hari tertentu serta dapat ditentukan secara manual oleh pengguna

2.4. Evaluasi Model

- a. MAPE (*Mean Absolute Percentage Error*), merupakan rata – rata kesalahan absolut yang dinyatakan dalam bentuk persentase terhadap nilai aktual. Berikut persamaannya :

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

Dimana,

- y_t = Data aktual periode ke- t
- $\hat{y}_t$ = Peramalan periode ke- t
- n = Jumlah data

Hasil prediksi dengan menggunakan nilai MAPE menunjukkan bahwa semakin kecil persentasenya

maka semakin akurat hasilnya sebagaimana dirincikan dalam Tabel 1.

Tabel 1. Kriteria Nilai MAPE

No	Nilai MAPE (%)	Interpretasi
1	<10	Sangat Baik
2	10 – 20	Baik
3	20 – 50	Cukup Baik
4	>50	Buruk

b. RMSE (Root Mean Squared Error)

Root Mean Absolute Error (RMSE) adalah besarnya tingkat error atau kesalahan hasil prediksi, dimana semakin kecil (mendekati 0) nilai RMSE maka hasil prediksi semakin akurat. RMSE menghasilkan nilai rata – rata kuadrat dari jumlah kesalahan pada model prediksi. Berikut persamaannya :

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}} \quad (3)$$

Dimana,


y_t = Data aktual periode ke- t

$\hat{y}_t$ = Peramalan periode ke- t

n = Jumlah data

3. METODE PENELITIAN

Untuk mencapai tujuan penelitian dalam meramalkan jumlah pengunjung di Kampung Lali Gadget, disusun sebuah kerangka kerja yang terstruktur. Adapun rancangan penelitian ini terdiri dari tujuh tahapan yang meliputi identifikasi masalah, studi literatur, pengumpulan data, *pre-processing data*, pemodelan menggunakan algoritma Prophet, hingga analisis hasil dan penarikan kesimpulan dapat dilihat pada Gambar 1.



Gambar 1. Alur Rancangan Penelitian

3.1. Identifikasi Masalah

Penelitian ini berfokus pada peramalan jumlah pengunjung Kampung Lali Gadget untuk mengatasi ketidakpastian akibat fluktuasi kunjungan yang signifikan. Hasil peramalan ini bertujuan menjadi landasan bagi pengelola dalam mengoptimalkan perencanaan kurikulum permainan, kebutuhan bahan ajar, serta alokasi sumber daya manusia atau relawan di masa mendatang.

3.2. Studi Literatur

Pengumpulan referensi dari berbagai sumber seperti buku, jurnal, dan juga video serta pencarian informasi melalui internet. Literatur yang dikaji mencakup teori mengenai peramalan (*forecasting*) itu sendiri, model Prophet, serta penelitian terdahulu yang relevan dengan subjek ini.

3.3. Pengumpulan Data

Pengumpulan data diambil dari pihak Kampung Lali Gadget berupa data primer kunjungan harian sejak Agustus 2022 – Oktober 2025. Dataset yang akan digunakan yaitu berupa data deret waktu, terdiri dari dua kolom utama yaitu 'tanggal' dan 'jumlah pengunjung' dengan format Excel (.xlsx).

3.4. Pre – Processing Data

Data awal yang didapatkan dari KLG adalah data harian, namun karena konsep operasional KLG yang berbasis reservasi dan kunjungan massal hanya dilakukan pada hari Minggu, data harian sangat *sparse* (banyak nilai 0). Untuk mengatasi noise dan memastikan pola musiman dapat terwakili dengan baik, maka data harian jumlah pengunjung diagregasikan menjadi data bulanan.

Diperlukan tahap *pre-processing* data, proses ini krusial meliputi pembersihan data dengan menghapus kolom yang tidak diperlukan, transformasi tipe data tanggal menjadi *yyy-mm-dd* untuk memastikan data terstruktur dengan baik [12], dan penyesuaian nama kolom agar sesuai dengan format Prophet, yaitu kolom tanggal yang dinotasikan dengan 'ds' dan 'y' untuk jumlah pengunjung.

3.5. Visualisasi Data

Visualisasi data dilakukan melalui pembuatan grafik *time series* untuk menganalisis karakteristik fluktuasi pengunjung. Tahap ini penting sebagai dasar penentuan konfigurasi model Prophet, khususnya dalam pemilihan mode *growth* dan *seasonality*, serta untuk mengidentifikasi anomali yang memerlukan penanganan khusus pada tahap pra-pemrosesan guna menjamin kualitas data latih.

3.6. Training Model

Pengembangan model dilakukan menggunakan algoritma Prophet yang berbasis *Generalized Additive Model* (GAM). Model ini membagi data menjadi tiga komponen utama yaitu tren $g(t)$, musiman $s(t)$, dan hari libur $h(t)$ dengan persamaan umum sebagai berikut [3] :

$$y(t) = g(t) + s(t) + h(t) + \epsilon t. \quad (2)$$

Dalam penelitian ini, komponen tren dimodelkan menggunakan *piecewise linear* karena data tidak menunjukkan batasan kapasitas maksimum (*carrying capacity*). Persamaan :

$$g(t) = (k + a(t)^T \delta)t + (m + a(t)^T \gamma) \quad (3)$$

Dimana k adalah laju pertumbuhan (*growth rate*), δ merepresentasikan penyesuaian laju (*rate adjustments*), dan m merupakan parameter offset. Model Prophet juga memperbolehkan peneliti untuk menambahkan *custom list* atau daftar kustom peristiwa atau kejadian, baik yang telah terjadi maupun yang akan datang [13].

3.7. Evaluasi Model

Setelah model – model tersebut dibangun, tahap berikutnya adalah melakukan evaluasi terhadap model. Kinerja masing-masing model akan diukur dan dibandingkan secara sistematis menggunakan dua metrik utama, yaitu RMSE dan MAPE. Semakin kecil nilai evaluasi yang didapatkan, semakin akurat hasil peramalan [14].

3.8. Peramalan

Setelah model dengan performa terbaik diperoleh, dilakukan peramalan (*forecasting*) terhadap jumlah pengunjung KLG untuk 6 bulan ke depan.

3.9. Analisis Hasil dan Penarikan Kesimpulan


Hasil peramalan akan diolah menjadi implikasi praktis untuk mendukung pengambilan keputusan operasional Kampung Lali Gadget.

4. HASIL DAN PEMBAHASAN

Implementasi model Prophet memerlukan penyesuaian format data dengan mengganti nama kolom waktu menjadi '*ds*' dan kolom target numerik menjadi '*y*' agar dapat diproses oleh Pandas. Oleh karena itu, dilakukan tahap *pre-processing* dengan mengonversi kolom tanggal menjadi '*ds*', kolom jumlah pengunjung menjadi '*y*', serta menghapus kolom yang tidak relevan. Data jumlah pengunjung disajikan dalam bentuk bulanan dari Januari 2023 hingga Oktober 2025, sebagaimana ditampilkan pada Tabel 2 dan Gambar 2.

Tabel 2. Dataset Jumlah Pengunjung Januari 2023 – Oktober 2025

<i>ds</i>	<i>y</i>
01/01/2023	422
01/02/2023	630
01/03/2023	673
01/04/2023	40
...	...
01/10/2025	560



Gambar 2. Grafik Jumlah Pengunjung dari Januari 2023 – Oktober 2025

Gambar 2 memperlihatkan jumlah pengunjung Kampung Lali Gadget terendah pada April 2023 sebesar 40 kunjungan dan tertinggi pada September 2024 dengan hampir 2.000 pengunjung. Dalam penelitian ini, pemodelan dilakukan secara *trial-and-error* untuk memperoleh model terbaik dengan nilai kesalahan terkecil. Berikut disajikan hasil beberapa model Prophet yang telah diuji

4.1. Model Prophet 1

Model Prophet 1 merupakan model standar dengan tren linear dan musiman tahunan tanpa *tuning* komponen hari libur. Implementasi kode untuk Model 1 ditunjukkan pada Gambar 3.


```
model1 = Prophet(
    growth='linear',
    yearly_seasonality=True,
    seasonality_mode='multiplicative'
)
model1.fit(df)
```

Gambar 3. Potongan kode inisialisasi Model 1

Hasil Evaluasi performa Model 1 dan visualisasi disajikan pada Tabel 3 dan Gambar 4.

Tabel 3. Hasil evaluasi model Prophet 1

Model	MAPE (%)
Model Prophet 1	84.14%



Gambar 4. Plot model Prophet 1

Berdasarkan Tabel 3 dan Gambar 4, model menghasilkan MAPE sebesar 84,14% (kategori tidak akurat). Grafik menunjukkan kondisi underfitting, di mana model gagal menangkap pola dasar data aktual. Oleh karena itu, diperlukan penambahan komponen regressor untuk meningkatkan akurasi.

4.2. Model Prophet 2

Model Prophet 2 mengintegrasikan komponen hari libur menggunakan fungsi `add_country_holidays(country_name='ID')` serta *dataframe* eksternal. Komponen ini mencakup hari libur nasional, hari besar keagamaan, dan cuti bersama periode 2023 – 2026. Penambahan ini bertujuan agar model mampu menangkap fluktuasi kunjungan pada momen-momen libur besar di Indonesia. Implementasi kodenya dapat dilihat pada Gambar 5.

```

model2 = Prophet(
    growth='linear',
    yearly_seasonality=True,
    weekly_seasonality=False,
    daily_seasonality=False,
    seasonality_mode='multiplicative',
    holidays=holidays
)


model2.add_country_holidays(country_name='ID')
model2.fit(df2)

```

Gambar 5. Potongan kode penambahan komponen hari libur

Tabel 4. Hasil evaluasi model Prophet 2

Model	MAPE (%)
Model Prophet 2	44.76%



Gambar 6. Plot model Prophet 2

Berdasarkan Tabel 4, penambahan komponen hari libur meningkatkan akurasi secara signifikan dengan penurunan MAPE menjadi 44,76% (kategori cukup baik). Namun, sebagaimana terlihat pada Gambar 6, masih terdapat lonjakan ekstrem pada Januari 2026. Hal ini menunjukkan model masih terlalu sensitif terhadap efek libur nasional, sehingga diperlukan penyesuaian *extra regressor* dan *prior scale* untuk menstabilkan hasil proyeksi.

4.3. Model Prophet 3

Model Prophet 3 dikembangkan dengan menambahkan *extra regressor* berupa *event internal* KLG (Hari Anak, Elingpiade, Festival Tanah Air) dan kalender akademik Dinas Pendidikan Jatim. Penambahan ini bertujuan menangkap variabel non-musiman yang memengaruhi fluktuasi pengunjung. Implementasi kodenya dapat dilihat pada Gambar 7.

```

event_klg = pd.DataFrame({
    'holiday': ['Klinik gadget', 'hari anak', 'elingpiade', 'fest_tanah_air'],
    'ds': pd.to_datetime(['2024-09-03', '2025-07-29', '2025-09-01', '2025-11-19']),
    'lower_window': 0,
    'upper_window': 0
})

holidays_combined = pd.concat([holidays, event_klg], ignore_index=True)

academic_ranges = [
    ('2023-12-26', '2023-12-31'),
    ('2023-06-26', '2023-07-15'),
    ('2023-12-26', '2023-12-30'),
    ('2024-06-24', '2024-07-12'),
    ('2024-12-26', '2024-12-31'),
    ('2025-06-23', '2025-06-29'),
    ('2025-12-22', '2026-01-3')
]

def is_academic_holiday(ds):
    for start, end in academic_ranges:
        if pd.to_datetime(start) <= ds <= pd.to_datetime(end):
            return 1
    return 0

df4['libur_akademik'] = df4['ds'].apply(is_academic_holiday)

model4 = Prophet(
    growth='linear',
    yearly_seasonality=True,
    holidays=holidays_combined,
    holidays_prior_scale=1.0,
    seasonality_mode='multiplicative'
)


model4.add_regressor('libur_akademik')
model4.fit(df4)

```

Gambar 7. Potongan kode penambahan *extra regressor*

Tabel 5. Hasil evaluasi model Prophet 3

Model	MAPE (%)
Model Prophet 3	20.93%



Gambar 8. Plot model Prophet 3

Hasil evaluasi pada Tabel 5 dan Gambar 8 menunjukkan peningkatan performa signifikan dengan MAPE 20,93% (kategori baik). Variabel eksternal ini membuat model lebih adaptif terhadap faktor sosial dan institusional yang memicu lonjakan pengunjung.


Tahap selanjutnya adalah *tuning hyperparameter*. Berdasarkan perbandingan cross-validation pada Tabel 6, Model 3 dipilih sebagai model terbaik untuk tahap optimasi.

Tabel 6. Hasil evaluasi Cross Validation Model Prophet

Model	MAPE (%)
Model Prophet 1	84.14%
Model Prophet 2	44.76%
Model Prophet 3	20.93%

Tahapan *hyperparameter tuning* bertujuan untuk menentukan kombinasi nilai parameter yang paling optimum bagi model terbaik [15], sehingga dapat menghasilkan peramalan jumlah pengunjung yang akurat. Pada tahap ini, dilakukan eksplorasi parameter menggunakan metode *Grid Search* dengan memvariasikan nilai pada tiga parameter utama *Prophet*, yaitu *changepoint_prior_scale*, *seasonality_prior_scale*, dan *holidays_prior_scale*. Rentang nilai variasi yang diuji adalah sebagai berikut: *changepoint_prior_scale* : 0.001, 0.01, 0.1, 0.5; *seasonality_prior_scale* : 0.01; 0.1, 1.0, 10.0; *holidays_prior_scale* : 0.01, 0.1, 1.0, 10.0. Berdasarkan hasil pengujian awal menggunakan metode *Grid Search*, ditemukan bahwa parameter terbaik secara otomatis adalah *changepoint_prior_scale* : 0.5, *seasonality_prior_scale* : 1.0, *holidays_prior_scale* : 10.0, dengan nilai RMSE sebesar 725.44.

Namun, berdasarkan evaluasi visual pada plot komponen model pada Gambar 6, penggunaan parameter tersebut menyebabkan model mengalami *overfitting* terhadap efek hari libur.

Gambar 9. Plot model hasil *tuning hyperparameter*


Hal ini dikarenakan nilai *prior scale* yang terlalu tinggi memberikan bobot yang berlebihan pada variabel hari libur, sehingga model memprediksi lonjakan pengunjung yang ekstrem dan tidak logis secara operasional, yakni mencapai hampir 14.000 pengunjung pada Januari 2026.

Mengingat angka tersebut jauh melampaui kapasitas historis dan daya tampung Kampung Lali Gadget, maka dilakukan langkah *manual fine-tuning* dengan menurunkan nilai *holidays_prior_scale* menjadi 1.0, kemudian *changepoint_prior_scale* menjadi 0.1 dan *seasonality_prior_scale* 1.0. Langkah ini diambil untuk menyeimbangkan angka statistik dengan kondisi nyata lapangan. Hasilnya, model menjadi lebih akurat RMSE turun ke 682 dan pola ramalannya lebih sesuai dengan kapasitas asli Kampung Lali Gadget.

Setelah memperoleh nilai *hyperparameters* yang paling optimum, tahap selanjutnya adalah melakukan peramalan dengan model tersebut selama enam bulan kedepan. Pada Tabel 7 dan Gambar 10 merupakan hasil peramalan dan plot jumlah pengunjung Kampung Lali Gadget selama enam bulan kedepan.

Tabel 7. Hasil Peramalan Jumlah Pengunjung Kampung Lali Gadget

Periode	Jumlah Pengunjung (Orang)
November 2025	1321
Desember 2025	897
Januari 2026	1940
Februari 2026	1101
Maret 2026	478
April 2026	36



Gambar 10. Plot hasil peramalan jumlah pengunjung Kampung Lali Gadget selama 6 bulan kedepan

Hasil peramalan memberikan dasar perencanaan yang strategis bagi pengelola Kampung Lali Gadget dalam pengelolaan sumber daya dan peningkatan kualitas layanan. Dengan rasio ideal 8 relawan untuk setiap 100 pengunjung, kapasitas maksimal 300 pengunjung per hari memerlukan sedikitnya 24 relawan. Mengingat jumlah relawan aktif saat ini sekitar 15 orang, maka pada periode dengan tingkat kunjungan tinggi, seperti bulan Januari dengan prediksi mencapai 1.940 pengunjung, pengelola perlu menyiapkan mekanisme penambahan relawan serta menerapkan pengaturan jadwal kunjungan agar jumlah pengunjung harian tetap berada dalam batas kapasitas yang aman dan optimal.

Selain aspek sumber daya manusia, informasi hasil peramalan juga dapat dimanfaatkan untuk perencanaan operasional, antara lain dengan memastikan kesiapan seluruh alat permainan sebelum memasuki periode puncak, serta memanfaatkan periode dengan kunjungan rendah, seperti bulan April dengan sekitar 36 pengunjung, untuk melakukan pemeliharaan fasilitas, perawatan sarana prasarana, serta evaluasi dan pelaksanaan pelatihan atau pengembangan bagi relawan.

5. KESIMPULAN DAN SARAN

Berdasarkan seluruh rangkaian tahapan penelitian yang telah dilakukan, dapat disimpulkan bahwa implementasi model Facebook Prophet terbukti efektif dalam meramalkan jumlah pengunjung di Kampung Lali Gadget dengan tingkat akurasi yang masuk dalam kategori baik. Keberhasilan ini tidak lepas dari penambahan komponen *extra regressor* berupa hari libur akademik dan *event* lokal yang terbukti sangat krusial dalam meningkatkan performa model. Hal tersebut ditandai dengan penurunan nilai MAPE secara signifikan, yaitu dari 84,14% pada model *default* menjadi 20,93% pada model akhir. Lebih jauh lagi, hasil peramalan ini memberikan panduan praktis bagi pengelola untuk melakukan langkah antisipatif terhadap lonjakan pengunjung, terutama melalui manajemen distribusi relawan dan penjadwalan perawatan fasilitas pada periode kunjungan rendah.

Penelitian selanjutnya disarankan menggunakan dataset yang lebih luas untuk meningkatkan keandalan model, terutama jika menggunakan data bulanan, disarankan juga untuk mengeksplorasi integrasi metode *machine learning* lain untuk menangkap variasi data yang lebih kompleks secara lebih mendalam.

DAFTAR PUSTAKA

- [1] L. Anggraini and S. Chodidjah, "Pengaruh Wisata Edukasi, Niat Perilaku, Dan Lokasi Terhadap Niat Berkunjung Ulang Ke Taman Ismail Marzuki Jakarta," *Hum. Cap. Dev.*, vol. 10, no. 2, pp. 1–17, 2023, [Online]. Available: <https://ejournal.asaindo.ac.id/index.php/hcd/article/view/2468%0Ahttps://ejournal.asaindo.ac.id/>

- index.php/hcd/article/download/2468/1764
- [2] Kampung Lali Gadget, "Tentang Kami," *kampunglaligadget.org*. Accessed: Jan. 30, 2026. [Online]. Available: <https://kampunglaligadget.org/>
- [3] S. J. Taylor and B. Letham, "Forecasting at Scale," *Am. Stat.*, vol. 72, no. 1, pp. 37–45, 2018, doi: 10.1080/00031305.2017.1380080.
- [4] C. B. Aditya Satrio, W. Darmawan, B. U. Nadia, and N. Hanafiah, "Time series analysis and forecasting of coronavirus disease in Indonesia using ARIMA model and PROPHET," *Procedia Comput. Sci.*, vol. 179, no. 2020, pp. 524–532, 2021, doi: 10.1016/j.procs.2021.01.036.
- [5] F. B. Prakoso, G. Darmawan, and A. Bachrudin, "PENERAPAN METODE FACEBOOK PROPHET UNTUK MERAMALKAN," pp. 133–147, 2023.
- [6] E. R. Putri *et al.*, "Penerapan Algoritma Prophet Facebook untuk Memprediksi Jumlah Calon Mahasiswa Baru," vol. 5, no. 4, pp. 1588–1596, 2024.
- [7] H. Yuliansyah, "Peramalan Jumlah Pengunjung Wisata Edukasi Museum Menggunakan Kombinasi Moving Average Dan Model Prophet Program Studi Informatika , Universitas Ahmad Dahlan , Indonesia Forecasting the Number of Visitors to Educational Tourism Museums Using a Combination," vol. 5, no. 7, pp. 2033–2054, 2025.
- [8] M. A. Ridla, N. Azise, and M. Rahman, "PERBANDINGAN MODEL TIME SERIES FORECASTING DALAM MEMPREDIKSI JUMLAH KEDATANGAN WISATAWAN DAN PENUMPANG AIRPORT," vol. 8, no. 1, pp. 1–14, 2023.
- [9] D. Rizkya, H. Roosaputri, and C. Dewi, "Perbandingan Algoritma ARIMA, Prophet, dan LSTM dalam Prediksi Penjualan Tiket Wisata Taman Hiburan (Studi Kasus: Saloka Theme Park)," *J. Penerapan Sist. Inf. (Komputer Manajemen)*, vol. 4, no. 3, pp. 507–517, 2023.
- [10] S. Haben, M. Voss, and W. Holderbaum, "Core Concepts and Methods in Load Forecasting: With Applications in Distribution Networks," *Core Concepts Methods Load Forecast. With Appl. Distrib. Networks*, pp. 1–331, 2023, doi: 10.1007/978-3-031-27852-5.
- [11] S. Kwarteng and P. Andreevich, "Comparative Analysis of ARIMA, SARIMA and Prophet Model in Forecasting," *Res. Dev.*, vol. 5, no. 4, pp. 110–120, 2024, doi: 10.11648/j.rd.20240504.13.
- [12] A. W. Anggraeni, A. S. Fitriani, and A. Eviyanti, "Penerapan Algoritma Support Vector Machine untuk Memprediksi Tingkat Partisipasi Pemilu terhadap Kualitas Pendidikan," *Edumatic J. Pendidik. Inform.*, vol. 8, no. 1, pp. 21–27, 2024, doi: 10.29408/edumatic.v8i1.24838.
- [13] T. Toharudin, R. S. Pontoh, R. E. Caraka, S. Zahroh, Y. Lee, and R. C. Chen, "Employing long short-term memory and Facebook prophet model in air temperature forecasting," *Commun. Stat. Simul. Comput.*, vol. 52, no. 2, pp. 279–290, 2023, doi: 10.1080/03610918.2020.1854302.
- [14] E. P. RAMDHANI and H. A. NUGROHO, "Prediksi Tegangan Catu Daya Automatic Rain Gauge berdasarkan Seasonality Algoritma Prophet," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 12, no. 1, p. 80, 2024, doi: 10.26760/elkomika.v12i1.80.
- [15] J. A. Ilemobayo *et al.*, "Hyperparameter Tuning in Machine Learning: A Comprehensive Review," *J. Eng. Res. Reports*, vol. 26, no. 6, pp. 388–395, 2024, doi: 10.9734/jerr/2024/v26i61188.