

Peramalan Jumlah Pengunjung Wisata Edukasi Museum Menggunakan Kombinasi Moving Average Dan Model Prophet

Lifa^{*1}, Herman Yuliansyah²

^{1,2}Program Studi Informatika, Universitas Ahmad Dahlan, Indonesia
Email: lifa2100018404@webmail.uad.ac.id, herman.yuliansyah@tif.uad.ac.id

Abstrak

Peramalan jumlah pengunjung wisata edukasi museum berperan penting dalam pengelolaan operasional dan strategi berbasis data. Peramalan berfungsi untuk memperkirakan kebutuhan di masa depan, baik dalam hal kuantitas, kualitas, maupun waktu, sehingga pengelolaan sumber daya dapat lebih optimal. Penelitian sebelumnya menerapkan model Prophet untuk peramalan jumlah pengunjung objek wisata. Namun Prophet kurang efektif dalam menghadapi fluktuasi data yang tinggi, terutama saat terjadi perubahan tren secara tiba-tiba. Untuk mengatasi hal tersebut, penelitian ini mengkombinasikan *Moving Average* (MA) sebagai teknik *preprocessing smoothing*, sehingga hasil peramalan Prophet lebih stabil dan akurat. Penelitian ini bertujuan untuk membangun model peramalan dengan mengkombinasikan metode *Moving Average* dan model Prophet. Model ini dievaluasi menggunakan metrik MAE, MSE, RMSE, dan MAPE untuk mengukur tingkat keakuratan hasil peramalan. Data yang digunakan berasal dari jumlah pengunjung Museum Muhammadiyah pada periode 2023–2024. Tahapan penelitian meliputi *cleaning data*, *transformasi log*, *smoothing* dengan *Moving Average*, serta penerapan Prophet dengan parameter *trend*, *seasonality*, dan *holidays*. Model terbaik diperoleh pada dataset pengunjung personal harian dengan MAE 0.15, MSE 0.02, RMSE 0.15, MAPE 5.58% dengan hasil peramalan tertinggi tanggal 12 Januari 2025 sebesar 2.79 pengunjung dan terendah tanggal 8 Mei 2025 sebesar 1.31 pengunjung. pada dataset pengunjung grup per bulan, hasil peramalan tertinggi bulan Januari sebesar 3398 pengunjung dan terendah bulan Mei sebesar 1171 pengunjung, MAPE sebesar 29,10%. Hasil menunjukkan bahwa Model Prophet mampu meramalkan jumlah pengunjung Museum Muhammadiyah dan *Moving Average* mampu meningkatkan performa Prophet. Penelitian ini bermanfaat bagi pengelola museum dalam merencanakan strategi promosi, penjadwalan kegiatan, sehingga dapat meningkatkan kualitas layanan.

Kata kunci: Deret Waktu, Data Smoothing, Forecasting Wisatawan, Machine Learning, Museum Muhammadiyah.

Forecasting the Number of Visitors to Educational Tourism Museums Using a Combination of Moving Average and Prophet Model

Abstract

Forecasting the number of visitors to educational tourism sites, such as museums, plays a crucial role in operational management and data-driven strategies. Accurate forecasting enables better planning for future resource needs in terms of quantity, quality, and timing. Previous studies have applied the Prophet model to forecast tourist visits. However, Prophet is less effective in handling high data fluctuations, especially when sudden trend changes occur. To address this issue, this study incorporates the Moving Average (MA) technique as a smoothing preprocessing step, aiming to improve the stability and accuracy of Prophet's forecasts. This research aims to build a forecasting model that combines Moving Average with Prophet. The model is evaluated using MAE, MSE, RMSE, and MAPE. The dataset consists of visitor numbers to the Muhammadiyah Museum from 2023 to 2024. The research stages included data cleaning, logarithmic transformation, smoothing using the Moving Average method, and the implementation of the Prophet model with trend, seasonality, and holiday parameters. The best-performing model was obtained from the daily personal visitor dataset, with MAE of 0.15, MSE of 0.02, RMSE of 0.15, and MAPE of 5.58%. The highest forecasted number of visitors was 2.79 on January 12, 2025, while the lowest was 1.31 on May 8, 2025. In the monthly group visitor dataset, the highest predicted number of visitors was 3,398 in January and the lowest was 1,171 in May, with a MAPE of 29.10%. The results indicate that the Prophet model is capable of forecasting the number of visitors to the Muhammadiyah Museum, and that the Moving Average technique enhances the performance of the Prophet model. This study is beneficial for museum managers in planning promotional strategies and scheduling activities, thereby improving service quality.

Keywords: *Data Smoothing, Machine Learning, Muhammadiyah Museum, Tourist Demand Forecasting, Time Series Analysis.*

1. PENDAHULUAN

Peramalan jumlah pengunjung wisata edukasi museum berperan penting dalam pengelolaan operasional dan strategi berbasis data. Ketidakpastian jumlah pengunjung dapat menjadi kendala bagi pengelola dalam mengoptimalkan pendapatan dan alokasi sumber daya [1]. Pemanfaatan ekosistem digital untuk Desa Wisata digunakan untuk memaksimalkan potensi desa dalam menjual jasa dan produk usaha kecil menengah [2]. Ekosistem digital ini juga membuka peluang untuk mengumpulkan dan mengelola data kunjungan wisata secara lebih sistematis, yang sangat penting sebagai fondasi analisis tren wisatawan dan peramalan jumlah pengunjung di masa depan. Dengan basis data yang lebih kuat dan terintegrasi, upaya peramalan dan pengembangan strategi wisata berbasis data dapat dilakukan secara lebih akurat [3]. Peramalan berfungsi untuk memperkirakan kebutuhan di masa depan, baik dalam hal kuantitas, kualitas, maupun waktu, sehingga pengelolaan sumber daya dapat lebih optimal. Oleh karena itu, metode peramalan jumlah kunjungan menjadi solusi yang dapat membantu pengelola menganalisis tren historis, mengantisipasi perubahan tren di masa depan, serta meningkatkan kepuasan dan jumlah kunjungan wisatawan [4][5].

Sejumlah penelitian telah membandingkan metode peramalan untuk data jumlah pengunjung wisata. Auliya, dkk. [4] melakukan peramalan jumlah pengunjung objek wisata *Gumul Paradise Island* menggunakan metode Prophet. Hasil penelitian menunjukkan tingkat akurasi yang sangat baik, dengan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 0.613% pada data uji dan data latih, serta 9.758% pada data peramalan dibandingkan data asli tahun 2022. Meskipun model Prophet mampu menangkap pola musiman dengan baik, terdapat penyimpangan prediksi pada bulan April 2022 akibat kebijakan penutupan sementara saat Ramadhan. Penyesuaian *parameter*, seperti pengaturan *holidays*, berperan penting dalam meningkatkan keakuratan peramalan jumlah pengunjung.

Bahauddin, dkk. [5] meramalkan utilitas listrik dan gas dengan menggunakan Python dan *package* *fbprophet*. Data masa lalu yang digunakan yaitu data riil index utilitas listrik dan gas dari semua perusahaan relevan di Amerika Serikat dengan frekuensi perbulan mulai dari Januari tahun 2000 hingga bulan Oktober tahun 2020 untuk melatih model Prophet dan kemudian memprediksi nilai utilitas untuk tahun 2021. Hasilnya menunjukkan bahwa algoritma Prophet mampu memprediksi utilitas dengan tingkat kesalahan rata-rata (*Mean Absolute Error/MAE*) sebesar 14.12 dan akar kesalahan kuadrat rata-rata (*Root Mean Squared Error/RMSE*) sebesar 15.60, yang menandakan tingkat akurasi yang tinggi.

Chandra, dkk. [6] menguji hasil peramalan pemasaran mahasiswa baru berdasarkan wilayah menggunakan metode Prophet dan ARIMA. Dengan dataset yang mencakup data aktual selama 26 tahun, mereka melakukan analisis deret waktu melalui tahap *preprocessing*, seperti transformasi log dan *resampling*. Hasil penelitian menunjukkan bahwa model Prophet lebih unggul dibandingkan ARIMA berdasarkan nilai *Root Mean Squared Error* (RMSE).

Suryoputro, dkk. [7] mengkombinasi penggunaan *library* Prophet dan Geopandas dalam meramalkan dan memvisualisasikan kasus Covid-19 di Indonesia. Model Prophet mampu meramalkan perkembangan kasus Covid-19 dengan skor evaluasi RMSLE 0.68 dan MAE 1070. Geopandas mampu memvisualisasikan data geospasial hasil peramalan secara efektif dalam bentuk peta interaktif per provinsi.

Ramadita, dkk. [8] mengevaluasi prediksi curah hujan di Jakarta menggunakan model *hybrid* DWT-SVR-Prophet. Hasil penelitian menunjukkan bahwa di Stasiun Kemayoran, model *hybrid* dengan kombinasi SVR frekuensi tinggi dan Prophet frekuensi rendah memberikan performa terbaik dengan nilai SMAPE sebesar 36.44%. Sementara itu, di Stasiun Tanjung Priok, model *non-hybrid* Prophet tanpa *Discrete Wavelet Transform* (DWT) menunjukkan hasil terbaik dengan SMAPE sebesar 29.82%. Studi ini menyoroti bahwa penggunaan DWT dapat meningkatkan akurasi prediksi, tetapi efektivitasnya bergantung pada karakteristik data di masing-masing lokasi pengamatan.

Harahap, dkk. [9] meramalkan tren pandemi COVID-19 di Indonesia menggunakan metode Prophet sebelum dan sesudah aturan *New Normal*. Hasil penelitian menunjukkan bahwa model Prophet memprediksi peningkatan jumlah kasus terkonfirmasi sekitar 238.322 dan kematian sekitar 9.609 hingga akhir September 2020. Tingkat kesalahan prediksi yang diukur menggunakan MAPE sekitar 23.9% dan *Mean Absolute Error* (MAE) sekitar 73.12. Analisis ini mengungkapkan bahwa aturan *new normal* berdampak pada lonjakan kasus yang signifikan, sehingga langkah pengendalian pandemi yang lebih ketat diperlukan untuk meminimalkan penyebaran virus.

Ervintyana, dkk. [10] menganalisa penjualan dalam industri perusahaan. Penelitian ini menggunakan metode ARIMA, SVR, FFT, dan Prophet untuk peramalan penjualan, dengan MAPE dan *Root Mean Squared Percentage Error* (RMSPE) sebagai ukuran akurasi. Hasil analisis menunjukkan bahwa ARIMA dan Prophet merupakan

metode terbaik, dengan nilai MAPE dan RMSPE terendah. Selain itu, analisis juga mengidentifikasi adanya pola berulang pada produk yang diteliti setiap kuartal.

Mu'minin [11] mengembangkan peramalan dalam bidang pariwisata. Hal ini didasari oleh sejumlah studi terdahulu yang hanya membandingkan beberapa model prediksi, sementara studi ini membandingkan tiga model, yakni ARIMA, Prophet, dan Glimnet. Dengan demikian, hasil studi ini diharapkan dapat memberikan masukan yang berguna dalam membuat kebijakan pemulihan industri pariwisata di masa pandemi. Namun, studi selanjutnya perlu melibatkan lebih banyak model serta data yang lebih rinci agar hasil prediksinya menjadi lebih akurat. Secara keseluruhan, tinjauan pustaka yang ada mendukung perlunya studi ini untuk mengembangkan ilmu pengetahuan di bidang terkait.

Sitepu, dkk. [12] memprediksikan jumlah mahasiswa baru di masa depan dengan memanfaatkan model Prophet Facebook. Tinjauan yang relevan mencakup konsep runtun waktu, *data science*, serta model Prophet Facebook yang mampu memprediksi perubahan tren secara otomatis dan menghasilkan peramalan yang akurat. studi ini memanfaatkan dasar-dasar analisis runtun waktu dan model peramalan *modern* untuk memprediksi perkembangan jumlah mahasiswa baru berdasarkan pola historis, sehingga diharapkan dapat mendukung pengambilan keputusan di perguruan tinggi. Dengan demikian, kerangka kerja studi ini relevan untuk menjawab permasalahan yang diangkat.

Yuliansyah, dkk. [13] memprediksi kelulusan tepat waktu mahasiswa menggunakan algoritma C4.5 dengan mempertimbangkan empat fitur utama yaitu program studi, IPK, skor bahasa Inggris, dan usia. Penelitian ini menggunakan data mahasiswa tahun ajaran 2008–2014 dan menghasilkan akurasi prediksi sebesar 90% pada data uji sebanyak 300 mahasiswa. Analisis menggunakan *confusion matrix* juga menunjukkan nilai rata-rata *precision* sebesar 52,84%, *recall* 50,68%, dan *F1-score* 51,73%. Penelitian ini menegaskan bahwa pemanfaatan data mining ini menegaskan pentingnya akurasi peramalan dalam mendukung pengambilan keputusan strategis. Peramalan ini dapat membantu universitas dalam mengidentifikasi faktor risiko keterlambatan kelulusan, serta merancang intervensi akademik yang lebih tepat sasaran.

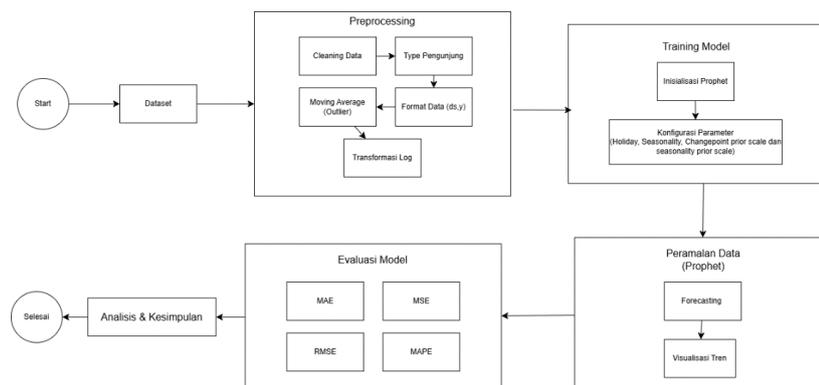
Masalah utama dalam peramalan jumlah pengunjung terletak pada fluktuasi data yang tinggi, yang disebabkan oleh berbagai faktor eksternal seperti musim, hari libur nasional, acara khusus, hingga kebijakan pemerintah. Fluktuasi yang tiba-tiba ini menjadi tantangan tersendiri bagi model peramalan, termasuk Prophet, yang memiliki keterbatasan dalam merespons perubahan tren yang mendadak secara akurat, terutama pada data dengan *interval* harian dan *horizon* waktu pendek. Beberapa penelitian terdahulu [4][9] mencatat adanya deviasi hasil prediksi Prophet ketika terjadi anomali atau lonjakan tiba-tiba, misalnya akibat pandemi atau kebijakan lokal, yang mengindikasikan kurangnya *robust* terhadap *outlier* atau *shifting trend*.

Dalam penelitian ini, model Prophet digunakan sebagai metode utama dalam peramalan jumlah pengunjung. Prophet dipilih karena kemampuannya menangani pola musiman dan perubahan tren secara tiba-tiba [6]. Data jumlah pengunjung Museum Muhammadiyah menunjukkan pola yang berubah-ubah dipengaruhi musim liburan dan hari libur nasional. Prophet memiliki fitur *seasonality* dan *holiday effects* yang bisa mengenali pola tanpa memerlukan banyak tuning manual [14], [15]. Namun, karena tingginya variasi data (*noise*), diperlukan langkah pra-pemrosesan untuk meningkatkan kestabilan model. Oleh karena itu, metode *Moving Average* (MA) diterapkan sebagai teknik *smoothing* untuk meredam fluktuasi jangka pendek dan menghaluskan data sebelum dimasukkan ke dalam model Prophet. Penelitian ini bertujuan untuk membangun model peramalan jumlah pengunjung wisata edukasi Museum Muhammadiyah menggunakan metode *Moving Average* dan model Prophet, serta mengevaluasi performa model dengan metrik MAE, MSE, RMSE, dan MAPE.

Sisa dari makalah ini disusun sebagai berikut. Bagian 2 membahas tahapan penelitian. Bagian 3 menyajikan data eksperimen, realisasi tahap penelitian, dan hasil eksperimen, dan Bagian 4 menyimpulkan temuannya.

2. METODE PENELITIAN

Penelitian ini dilakukan untuk meramalkan jumlah pengunjung wisata edukasi Museum Muhammadiyah menggunakan metode *Moving Average* dan Model Prophet. Tahapan penelitian ini dijelaskan secara sistematis dalam Gambar 1.



Gambar 1. Tahapan Penelitian Peramalan Jumlah Pengunjung Wisata Edukasi Museum Menggunakan Metode *Moving Average* dan Prophet.

Gambar 1 menjelaskan tahapan perancangan sistem peramalan jumlah pengunjung wisata edukasi museum menggunakan model Prophet. Penelitian ini dimulai dari memasukkan data, *preprocessing data*, *training model*, *forecasting*, evaluasi performa model, analisis dan kesimpulan. Penelitian ini menggunakan bahasa pemrograman Python versi 3.11 dan Prophet versi 1.1.6.

2.1. Pengumpulan Data

Data yang digunakan merupakan data jumlah pengunjung objek wisata Museum Muhammadiyah dalam periode 02 Januari 2023 hingga 31 Desember 2024. Data ini diperoleh dalam format Excel (.xlsx) dan terdiri dari dua tipe pengunjung personal dan grup dengan periode harian dan bulanan.

2.2. Preprocessing Data

Sebelum pemodelan, dilakukan *preprocessing data* untuk menghasilkan data yang bersih dan model dengan akurasi baik [14]. *Cleaning data* dilakukan untuk menghapus data kosong atau tidak relevan, sementara transformasi data untuk mengubah format tanggal ke YYYY-MM-DD [16]. Untuk mengatasi *outlier*, digunakan *Moving Average* dan transformasi log, yang membantu mengurangi *noise* dan fluktuasi, sehingga data menjadi lebih halus dan Prophet lebih fokus menangkap pola utama dan meningkatkan stabilitas peramalan [17].

Persamaan 1. *Moving Average*:

$$y_{baru}(t) = \frac{y(t-1)+y(t)+y(t+1)}{N} \tag{1}$$

Persamaan 2. Transformasi log:

$$y' = \log_e(y + 1) \tag{2}$$

Terakhir, dilakukan pembagian data (*splitting*) menjadi data latih dan data uji untuk keperluan evaluasi model.

2.3. Perancangan dan Pelatihan Model

Penelitian ini menggunakan Model Prophet karena kemampuannya dalam menangani data deret waktu yang mampu menangkap tren jangka panjang, pola musiman (*seasonality*) [14], serta efek hari libur. Model Prophet juga memiliki kemampuan mendeteksi *change point*, yaitu titik perubahan dalam tren, yang memungkinkan penyesuaian terhadap perubahan pola jumlah pengunjung. Setelah data diproses, dilakukan tahap pelatihan model menggunakan model Prophet dengan parameter yang telah ditentukan. Model yang telah dilatih kemudian digunakan untuk melakukan peramalan jumlah pengunjung dalam periode waktu tertentu, serta menampilkan visualisasi pola peramalan untuk melihat apakah model mampu menangkap tren dan fluktuasi yang ada dalam data. Untuk prophet, tersedia *library* Prophet yang memungkinkan untuk membuat model yang akurat dan dapat disesuaikan dengan fleksibilitas yang diperlukan untuk data yang kompleks seperti deteksi otomatis *trend* dan *seasonality*, serta penanganan *holidays* [18]. Prophet dihitung dengan Persamaan (3 – 7).

Persamaan 3. Komponen dasar model Prophet:

$$y(t) = g(t) + s(t) + h(t) + \varepsilon(t) \tag{3}$$

Persamaan 4. Fungsi *trend*:

$$g(t) = (k + a(t)T\delta)t + (m + a(t)T\gamma) \tag{4}$$

Persamaan 5. Komponen *seasonality*:

$$s(t) = \sum_{n=1}^N \left(a_n \sin\left(\frac{2\pi nt}{P}\right) + b_n \cos\left(\frac{2\pi nt}{P}\right) \right) \tag{5}$$

Persamaan 6. Efek *holidays*:

$$h(t) = \sum_l \beta_j D_l(t) \tag{6}$$

Persamaan 7. Komponen *error*:

$$\varepsilon(t) = \mathcal{N}(0, \sigma^2) \tag{7}$$

dimana $y(t)$ adalah nilai yang akan diramalkan. $g(t)$ merupakan tren model linear atau fungsi trend kurva pertumbuhan linear atau logistik untuk pemodelan perubahan *non-periodik* dalam seri waktu. $s(t)$ adalah perubahan periodik musiman menggunakan *fourier series* seperti mingguan, bulanan, dan tahunan. $h(t)$ mewakili efek hari libur yang mana perlu ditentukan secara manual oleh pengguna menggunakan *dummy variable* untuk hari-hari tertentu. $\varepsilon(t)$ mewakili komponen *error* dengan menghitung selisih antara peramalan dan data aktual [19].

2.4. Evaluasi Model

Setelah model-model tersebut dibangun, tahap selanjutnya adalah melakukan evaluasi terhadap setiap model. Evaluasi ini akan melibatkan perbandingan kinerja masing-masing model menggunakan metrik evaluasi MAE, MSE, RMSE dan MAPE. Semakin rendah nilai evaluasi yang didapatkan, semakin akurat hasil peramalan [20][21]. Adapun rumus untuk menghitung MAE, MSE, RMSE dan MAPE dapat dilihat pada Persamaan (8-11).

Persamaan 8. Mean absolute error (MAE):

$$MAE = \frac{1}{n} \sum_i^n | \hat{Y}_i - Y_i | \tag{8}$$

Persamaan 9. Mean square error (MSE):

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2 \tag{9}$$

Persamaan 10. Root mean square error (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2} \tag{10}$$

Persamaan 11. Mean absolute percentage error (MAPE):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \times 100 \tag{11}$$

dimana Y_i adalah nilai data asli ke-I. \hat{Y}_i adalah nilai dari hasil peramalan ke-i. n adalah jumlah data. Nilai MAPE menjelaskan bahwa semakin rendah hasil yang diperoleh, semakin baik peramalan yang dihasilkan [21][22]. Berikut adalah kriteria nilai MAPE pada Tabel 1.

Tabel 1. Kriteria Nilai MAPE

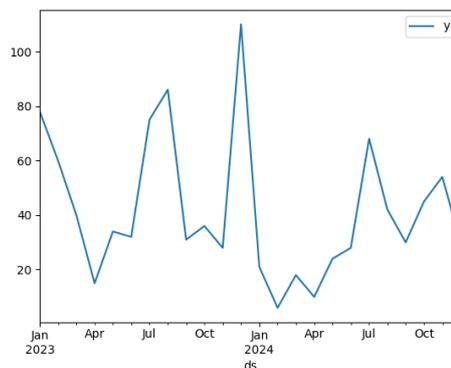
No	Nilai Mape (%)	Kriteria
1	<10	Sangat Baik
2	10-20	Baik
3	20-50	Cukup Baik
4	>50	Buruk

3. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan dataset memiliki dua kategori/tipe pengunjung, yaitu pengunjung personal (individu yang datang sendiri) dan pengunjung grup (rombongan dengan jumlah besar, seperti dari sekolah atau komunitas). Data jumlah pengunjung disajikan dalam bentuk per bulan dan per hari untuk kedua tipe pengunjung. Pada dataset pengunjung personal per bulan menyajikan jumlah pengunjung yang tercatat setiap bulan dari tahun 2023 hingga 2024. Data ini mencerminkan jumlah pengunjung personal yang datang setiap bulan dan divisualisasikan pada Tabel 2 dan Gambar 2.

Tabel 2. Dataset Jumlah Pengunjung Personal per Bulan dari Januari 2023 hingga Desember 2024.

No	Tanggal	Data Aktual 2023	Data Aktual 2024	Data Peramalan 2025
1	Januari	78	21	?
2	Februari	60	6	?
3	Maret	40	18	?
4	April	15	10	?
5	Mei	34	24	?
6	Juni	32	28	?
7	July	75	68	?
8	Agustus	86	42	?
9	September	31	30	?
10	Oktober	36	45	?
11	November	28	54	?
12	Desember	110	30	?

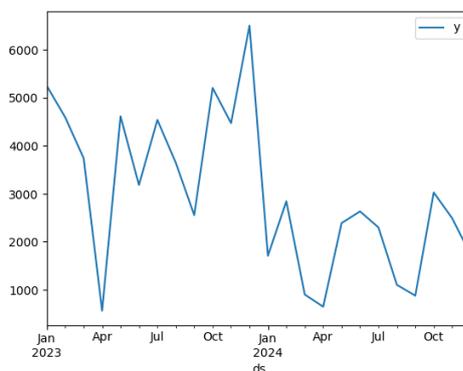


Gambar 2. Grafik Jumlah Pengunjung Personal per Bulan Menunjukkan Tren Penurunan Kunjungan dari Januari 2023 hingga Desember 2024.

Berdasarkan Tabel 2 dan Gambar 2, memperlihatkan grafik pengunjung memiliki pola tren negatif karena mengalami penurunan. Kunjungan Museum Muhammadiyah tertinggi pada bulan Desember 2023 yaitu 110 kunjungan dan terendah pada bulan Februari 2024 yaitu 6 kunjungan. Selanjutnya, pada dataset pengunjung grup per bulan menunjukkan jumlah pengunjung grup yang tercatat setiap bulan dari tahun 2023 hingga 2024. Visualisasi dari data ini dapat dilihat pada Tabel 3 dan Gambar 3.

Tabel 3. Dataset Jumlah Pengunjung Grup per Bulan dari Januari 2023 hingga Desember 2024.

No	Tanggal	Data Aktual 2023	Data Aktual 2024	Data Peramalan 2025
1	Januari	5249	1708	?
2	Februari	4593	2844	?
3	Maret	3741	900	?
4	April	563	647	?
5	Mei	4617	2390	?
6	Juni	3184	2634	?
7	July	4542	2299	?
8	Agustus	3647	1103	?
9	September	2555	876	?
10	Oktober	5208	3028	?
11	November	4473	2492	?
12	Desember	6507	1733	?

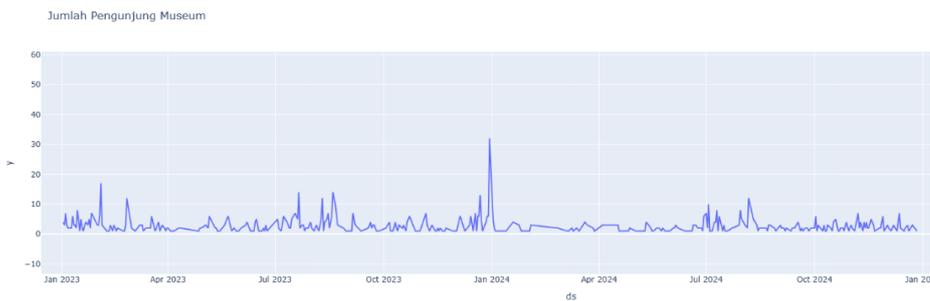


Gambar 3. Jumlah Kunjungan Grup Per Bulan Menurun Drastis dengan Puncak Tertinggi pada Desember 2023 dan Terendah Pada April 2024.

Berdasarkan Tabel 3 dan Gambar 3, dapat dilihat bahwa data memiliki pola tren negatif karena mengalami penurunan. Kunjungan Museum Muhammadiyah tertinggi pada bulan Desember 2023 yaitu 6507 kunjungan dan terendah pada bulan April 2023 yaitu 563 kunjungan. Selanjutnya, pada dataset pengunjung personal per hari menunjukkan jumlah pengunjung personal yang tercatat setiap hari dari tahun 2023 hingga 2024. Visualisasi dari data ini dapat dilihat pada Tabel 4 dan Gambar 4.

Tabel 4. Dataset Jumlah Pengunjung Personal per Hari dari 2 Januari 2023 hingga 27 Desember 2024.

No	Tanggal	Jumlah Pengunjung
1	2023-01-02	4
2	2023-01-03	3
3	2023-01-04	7
4	2023-01-05	3
5	2023-01-06	2
...
348	2025-12-26	???
349	2025-12-27	???
350	2025-12-28	???
351	2025-12-29	???
352	2025-12-30	???
353	2025-12-31	???

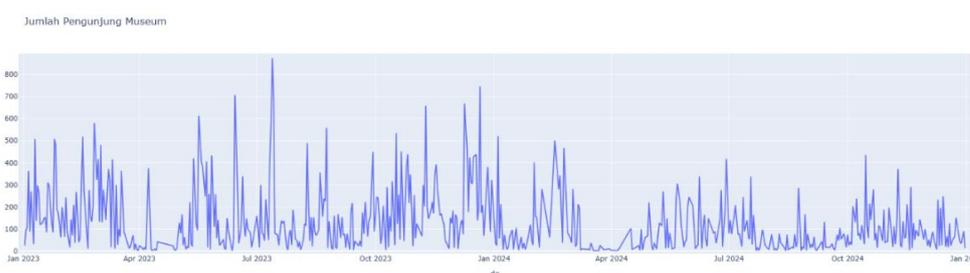


Gambar 4. Fluktuasi Kunjungan Personal per Hari Cukup Signifikan dengan Penurunan Tajam pada Awal 2024 dan Puncak Kunjungan pada Akhir Desember 2023.

Berdasarkan Tabel 4 dan Gambar 4, dapat dilihat bahwa data memiliki pola tren negatif karena mengalami penurunan. Kunjungan Museum Muhammadiyah tertinggi pada tanggal 30 Desember 2023 yaitu 32 kunjungan. Berdasarkan hasil analisis *time series*, terjadi penurunan signifikan jumlah pengunjung pada awal tahun 2024. Selanjutnya, pada dataset pengunjung grup per hari menunjukkan jumlah pengunjung grup yang tercatat setiap hari dari tahun 2023 hingga 2024. Visualisasi dari data ini dapat dilihat pada Tabel 5 dan Gambar 5.

Tabel 5. Dataset Jumlah Pengunjung Grup per Hari dari 2 Januari 2023 hingga 27 Desember 2024.

No	Tanggal	Jumlah Pengunjung
1	2023-01-02	25
2	2023-01-03	97
3	2023-01-04	103
4	2023-01-05	363
5	2023-01-06	88
...
348	2025-12-26	???
349	2025-12-27	???
350	2025-12-28	???
351	2025-12-29	???
352	2025-12-30	???
353	2025-12-31	???



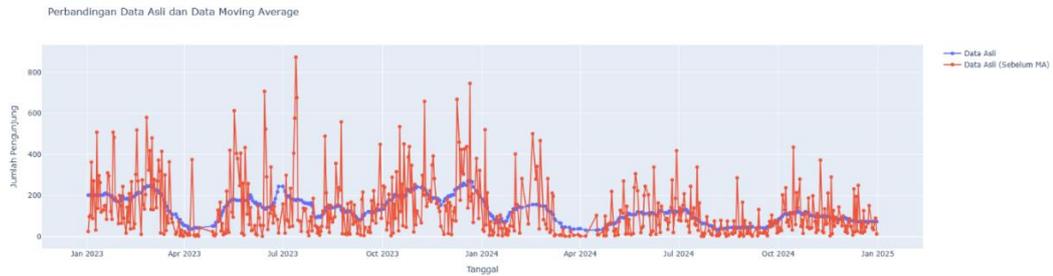
Gambar 5. Kunjungan Grup per Hari Menunjukkan Pola Tidak Stabil dengan Lonjakan pada Juli 2023 dan Penurunan saat Ramadhan dan Idul Fitri.

Pada Tabel 5 dan Gambar 5, menunjukkan data memiliki pola tren negatif karena mengalami penurunan. Kunjungan Museum Muhammadiyah tertinggi pada tanggal 13 Juli 2023 yaitu 873 kunjungan. Berdasarkan hasil analisis *time series*, terjadi penurunan signifikan jumlah pengunjung pada awal tahun 2024. Salah satu penyebab utama adalah kenaikan harga tiket masuk sebesar Rp 30.000, yang dapat mempengaruhi keputusan wisatawan untuk berkunjung. Selain itu, bulan April menunjukkan penurunan lebih lanjut, yang kemungkinan besar dipengaruhi oleh periode Ramadhan dan Hari Raya Idul Fitri. Dataset harian bisa dianalisis berdasarkan hari dalam seminggu (Senin–Minggu). Tujuannya adalah untuk melihat apakah ada hari tertentu yang cenderung memiliki lebih banyak atau lebih sedikit pengunjung. Pengunjung personal cenderung lebih banyak pada hari Sabtu dibandingkan hari kerja. Ini bisa disebabkan karena akhir pekan lebih nyaman untuk wisata. Pengunjung grup lebih sering datang pada hari Selasa–Kamis, terutama dari sekolah atau komunitas yang melakukan studi wisata.

Hari Senin dan Jumat memiliki jumlah pengunjung lebih rendah, kemungkinan karena Senin adalah awal pekan kerja dan Jumat adalah hari menjelang akhir pekan.

3.1. Moving Average dan Transformasi Log

Sebelum membangun model Prophet untuk meramalkan jumlah pengunjung museum, dilakukan *Moving Average* untuk memperhalus data grafik. Berikut hasil dari *Moving Average* dan transformasi log pada Gambar 6.



Gambar 6. Perbandingan Data Aktual dengan Hasil Smoothing Menggunakan Moving Average dan Transformasi Log yang Memperlihatkan Pola Tren Utama Lebih Jelas.

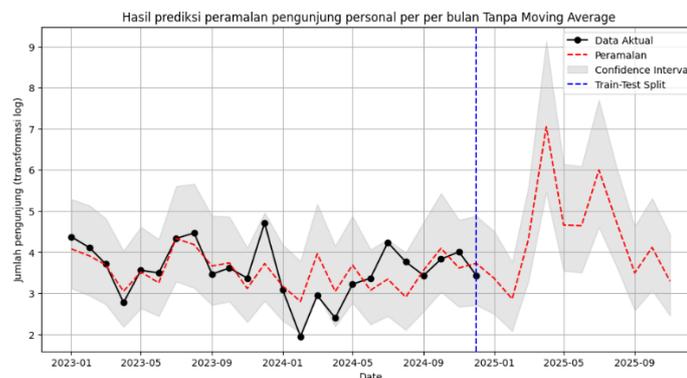
Pada Gambar 6 merupakan visualisasi yang menunjukkan perbandingan data aktual dan data yang sudah dilakukan *Moving Average* dan transformasi log. Garis berwarna biru mewakili hasil *Moving Average* dan transformasi log dan garis berwarna merah merupakan data aktual.

3.2. Model Prophet

Dalam penelitian ini, terdapat perbedaan hasil model Prophet menggunakan parameter dasar (*yearly*, *weekly*, dan *daily seasonality*) dan model dengan parameter tambahan seperti *holidays*, musiman bulanan, dan komponen lainnya.

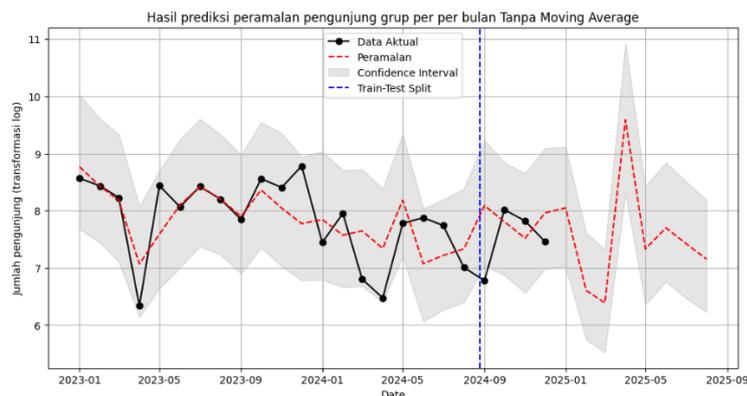
3.2.1. Hasil Peramalan Model Prophet Tanpa Moving Average

Model Prophet juga diuji tanpa *Moving Average* untuk melihat performa peramalan. Pada pengujian ini, digunakan jumlah pengunjung personal per bulan. Hasil peramalan diperoleh dari model Prophet dengan komponen tambahan seperti hari libur, musiman bulanan, *change point prior*, dan *seasonality prior*. Pemisahan data latih dan data uji dilakukan pada tanggal 27 Desember 2024. Pemilihan tanggal ini bukan dilakukan secara acak, melainkan berdasarkan hasil pengujian model Prophet dengan beberapa skenario tanggal *split*. Hasil pengujian menunjukkan bahwa pembagian data pada tanggal ini menghasilkan nilai evaluasi paling baik dibandingkan tanggal lainnya, dengan nilai MAPE sebesar **22.92%**, MAE sebesar 6.88, dan RMSE sebesar 6.88. Sebagai perbandingan, penggunaan tanggal *split* lainnya seperti 14 Juli 2024 dan September 2024 menghasilkan nilai MAPE di atas 37.59%. Oleh karena itu, tanggal 27 Desember 2024 dipilih sebagai batas optimal *split data* karena terbukti memberikan hasil prediksi yang paling akurat, serta berada pada periode dengan pola musiman akhir tahun yang signifikan, sehingga model dapat menangkap tren dan fluktuasi dengan lebih baik. Berikut tampilan visualisasi dari peramalan pengunjung tanpa *Moving Average*, pada Gambar 7.



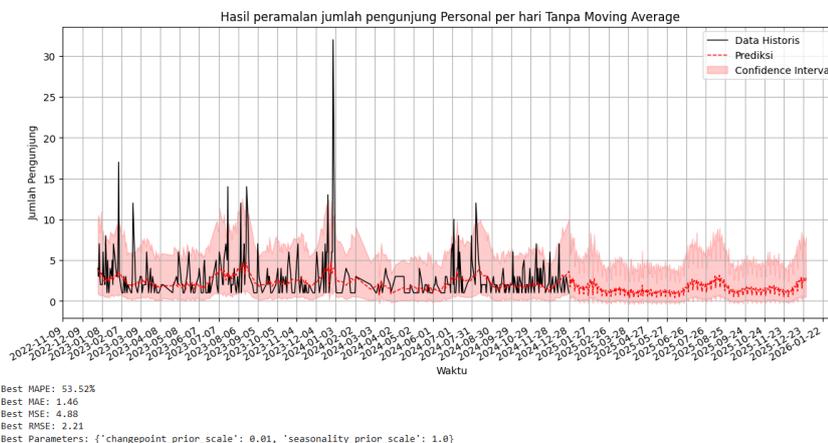
Gambar 7. Hasil Peramalan Jumlah Pengunjung Personal per Bulan tanpa *Moving Average*.

Selanjutnya, dilakukan peramalan pada dataset pengunjung grup per bulan menggunakan model Prophet tanpa *Moving Average* dengan komponen tambahan seperti musiman bulanan. Pemilihan tanggal *split data* latih dan uji pada masing-masing jenis data dilakukan berdasarkan hasil eksperimen beberapa skenario. Untuk data pengunjung grup per bulan, tanggal 25 September 2024 dipilih karena menghasilkan performa terbaik dengan nilai MAPE sebesar 94.05%, lebih rendah dibandingkan skenario tanggal lain seperti 14 Juli 2024 yaitu 112.88%. Hasil evaluasi menunjukkan nilai MAPE yang paling rendah dibandingkan skenario tanggal lainnya, meskipun secara umum performa model Prophet pada data grup tidak sebaik pada data personal. Hal ini diduga karena jumlah pengunjung grup yang fluktuatif dan tidak memiliki pola musiman yang kuat, sehingga model Prophet cenderung kesulitan menangkap pola perubahannya. Oleh karena itu, pemilihan tanggal *split* dilakukan secara data dan hasil eksperimen, berdasarkan evaluasi metrik akurasi untuk memastikan setiap model diuji dengan skenario terbaiknya masing-masing. Visualisasi hasil peramalan ditampilkan pada Gambar 8.



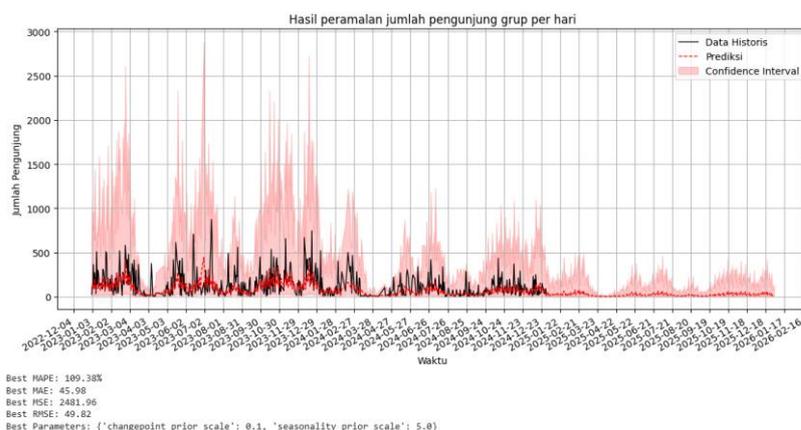
Gambar 8. Hasil Peramalan Jumlah Pengunjung Grup per Bulan tanpa *Moving Average*.

Peramalan juga dilakukan pada dataset pengunjung personal per hari menggunakan model Prophet tanpa *Moving Average* dengan komponen tambahan seperti hari libur, musiman bulanan, *changept prior*, dan *seasonality prior*. Pemisahan data latih dan data uji dilakukan pada tanggal 03 Maret 2024. Pemilihan tanggal ini bukan dilakukan secara acak, melainkan berdasarkan hasil pengujian model Prophet dengan beberapa skenario tanggal *split*. Hasil pengujian menunjukkan bahwa pembagian data pada tanggal ini menghasilkan nilai evaluasi paling baik dibandingkan tanggal lainnya, dengan nilai MAPE sebesar 53.52%, MAE sebesar 1.64, MSE 4.88 dan RMSE sebesar 2.21. Sebagai perbandingan, penggunaan tanggal *split* lainnya seperti 27 Desember 2024 dan 23 Desember 2024 menghasilkan nilai MAPE di atas 198.61%. Oleh karena itu, tanggal 03 Maret 2024 dipilih sebagai batas optimal *split data* karena terbukti memberikan hasil prediksi yang paling akurat, serta berada pada periode dengan pola musiman akhir tahun yang signifikan, sehingga model dapat menangkap tren dan fluktuasi dengan lebih baik. Visualisasi hasil peramalan ditampilkan pada Gambar 9.



Gambar 9. Hasil Peramalan Jumlah Pengunjung Personal per Hari tanpa *Moving Average* Menunjukkan Ketidakesesuaian Tren pada Beberapa Hari Dibanding Data Aktual.

Selain itu, dilakukan peramalan pada dataset pengunjung grup per hari menggunakan model Prophet tanpa metode *Moving Average*. Model tersebut juga menggunakan komponen tambahan seperti hari libur, musiman bulanan, *changepoint prior*, dan *seasonality prior*. Pemisahan data latih dan data uji dilakukan pada tanggal 23 Desember 2024. Pemilihan tanggal ini bukan dilakukan secara acak, melainkan berdasarkan hasil pengujian model Prophet dengan beberapa skenario tanggal *split*. Hasil pengujian menunjukkan bahwa pembagian data pada tanggal ini menghasilkan nilai evaluasi paling baik dibandingkan tanggal lainnya, dengan nilai MAPE sebesar **109.38%**, MAE sebesar 45.98, MSE 2481.96 dan RMSE sebesar 49.82. Sebagai perbandingan, penggunaan tanggal *split* lainnya seperti 31 Desember 2024 dan 03 Maret 2024 menghasilkan nilai MAPE di atas 154.07%. Oleh karena itu, tanggal 23 Desember 2024 dipilih sebagai batas optimal *split data* karena terbukti memberikan hasil prediksi yang paling akurat, serta berada pada periode dengan pola musiman akhir tahun yang signifikan, sehingga model dapat menangkap tren dan fluktuasi dengan lebih baik. Visualisasi hasil peramalan ditampilkan pada Gambar 10.



Gambar 10. Hasil Peramalan Jumlah Pengunjung Grup per Bulan tanpa *Moving Average*.

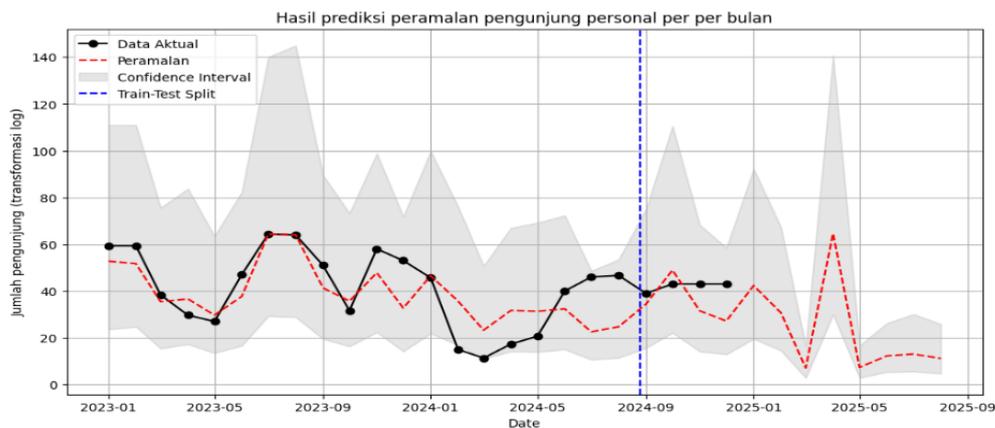
3.2.2. Hasil Peramalan Model Prophet dengan *Moving Average*

Peramalan dilakukan menggunakan model Prophet yang dikombinasikan dengan metode *Moving Average* untuk menstabilkan tren data. Model kemudian diterapkan pada dataset yang telah disiapkan sesuai dengan kategori data masing-masing. Pada dataset pengunjung personal per bulan, peramalan dilakukan menggunakan metode *Moving Average* dan model Prophet dengan komponen tambahan seperti hari libur, musiman bulanan, *changepoint prior*, dan *seasonality prior*. Untuk pemisahan data terhadap performa model, dilakukan serangkaian uji coba dengan *split data* antara data latih dan uji. Berdasarkan hasil pengujian, konfigurasi pemisahan data pada bulan September 2024 menunjukkan performa paling optimal dibandingkan hasil lainnya, seperti bulan Juli dan Desember 2024. Pada pemisahan September 2024, model menghasilkan nilai MAPE sebesar 22.27%, MAE sebesar 9.46, MSE sebesar 109.63, dan RMSE sebesar 10.47. Sementara itu, konfigurasi *split* pada bulan Desember menghasilkan MAPE sebesar 31.69% dan pada Juli sebesar 43.12%. Oleh karena itu, bulan September 2024 dipilih sebagai waktu pemisahan data latih dan uji, karena terbukti menghasilkan akurasi terbaik secara *data-driven*. Pada peramalan jumlah pengunjung Museum Muhammadiyah tipe personal per bulan tahun 2025 diperkirakan akan mencapai puncaknya pada bulan April dengan perkiraan 65 pengunjung dan jumlah terendah pada bulan Maret dan Mei perkiraan 7 pengunjung. Visualisasi hasil peramalan dari model terbaik ditampilkan pada Tabel 6 dan Gambar 11.

Tabel 6. Hasil Peramalan Jumlah Pengunjung Personal per Bulan Menggunakan Prophet dan *Moving Average*.

No	Tanggal	Hasil Peramalan (Orang)
1	Januari	42
2	Februari	31
3	Maret	7
4	April	65
5	Mei	7
6	Juni	12
7	July	13
8	Agustus	11
9	September	17

10	Oktober	13
11	November	15
12	Desember	11

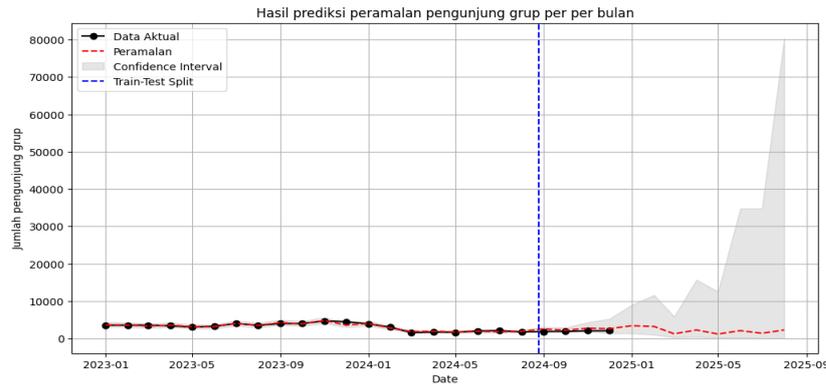


Gambar 11. Hasil Peramalan Jumlah Pengunjung Personal per Bulan Menggunakan Prophet dan *Moving Average*.

Pada dataset pengunjung grup per bulan, peramalan dilakukan menggunakan metode *Moving Average* yang dikombinasikan dengan model Prophet beserta komponen tambahan seperti hari libur, musiman bulanan, *changeoint prior*, dan *seasonality prior*. Untuk Pemisahan data terhadap performa model, dilakukan serangkaian uji coba dengan *split data* antara data latih dan uji. Berdasarkan hasil pengujian, konfigurasi pemisahan data pada bulan September 2024 menunjukkan performa paling optimal dibandingkan hasil lainnya, seperti bulan Juli 2024. Pada pemisahan September 2024, model menghasilkan nilai MAPE sebesar 29.10%, MAE sebesar 565.36, MSE sebesar 346190.12, dan RMSE sebesar 588.38. Sementara itu, konfigurasi *split* pada bulan Juli menghasilkan MAPE sebesar 43.12%. Oleh karena itu, bulan September 2024 dipilih sebagai waktu pemisahan data latih dan uji, karena terbukti menghasilkan akurasi terbaik secara *data-driven*. Pada peramalan tahun 2025 jumlah pengunjung Museum Muhammadiyah diperkirakan akan mencapai puncaknya pada bulan Januari dengan perkiraan 3398 pengunjung dan jumlah terendah pada bulan Mei perkiraan 1171 pengunjung. Visualisasi hasil peramalan dari model terbaik ditampilkan pada Tabel 7 dan Gambar 12.

Tabel 7. Hasil Peramalan Jumlah Pengunjung Grup per Bulan Menggunakan Prophet dan *Moving Average*.

No	Tanggal	Hasil Peramalan (Orang)
1	Januari	3398
2	Februari	3203
3	Maret	1228
4	April	2256
5	Mei	1171
6	Juni	2083
7	July	1372
8	Agustus	2258
9	September	3394
10	Oktober	2877
11	November	3486
12	Desember	2907

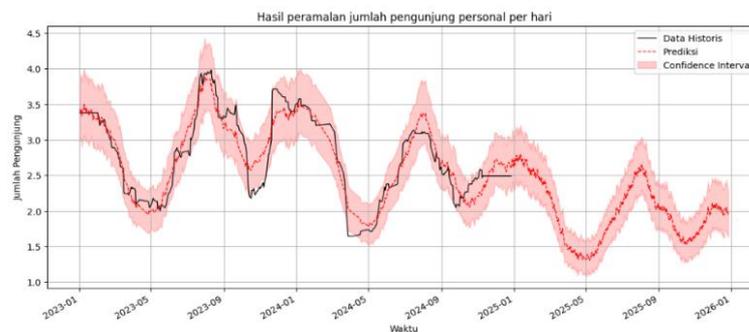


Gambar 12. Hasil Peramalan Jumlah Pengunjung Grup per Bulan Menggunakan Prophet dan *Moving Average*.

Peramalan pada dataset pengunjung personal per hari dilakukan menggunakan metode *Moving Average* yang dikombinasikan dengan model Prophet serta komponen tambahan seperti hari libur, musiman bulanan, *changeoint prior*, dan *seasonality prior*. Hasil pada peramalan tahun 2025 pada Tabel 8 dan Gambar 13, untuk pemisahan data terhadap performa model, dilakukan serangkaian uji coba dengan *split data* antara data latih dan uji. Berdasarkan hasil pengujian, konfigurasi pemisahan data pada bulan 27 Desember 2024 menunjukkan performa paling optimal dibandingkan hasil lainnya, seperti 3 Maret 2024 dan 23 Desember 2024. Pada pemisahan 27 Desember 2024, model menghasilkan nilai MAPE sebesar 5.58%, MAE sebesar 0.15, MSE sebesar 0.02, dan RMSE sebesar 0.15. Sementara itu, konfigurasi *split* pada 3 Maret 2024 menghasilkan MAPE sebesar 22.80%. Oleh karena itu, bulan September 2024 dipilih sebagai waktu pemisahan data latih dan uji, karena terbukti menghasilkan akurasi terbaik secara *data-driven*. Pada tahun 2025 jumlah pengunjung Museum Muhammadiyah terbanyak berdasarkan peramalan adalah 2025-01-12 dengan jumlah sekitar 2.79 pengunjung. Tanggal dengan pengunjung tersedikit berdasarkan peramalan adalah 2025-05-08 dengan jumlah sekitar 1.31 pengunjung. Visualisasi hasil peramalan dari model terbaik ditampilkan pada Tabel 8 dan Gambar 13.

Tabel 8. Hasil Peramalan Jumlah Pengunjung Personal per Hari Menggunakan Prophet dan *Moving Average*.

No	Tanggal	Hasil Peramalan (Orang)
1	2024-12-28	2,630686
2	2024-12-29	2,739612
3	2024-12-30	2,696856
4	2024-12-31	2,615725
5	2025-01-01	2,708787
...
360	2025-12-22	2,039028
361	2025-12-23	2,019631
362	2025-12-24	2,044253
363	2025-12-25	1,965494
364	2025-12-26	1,979612
365	2025-12-27	1,951057

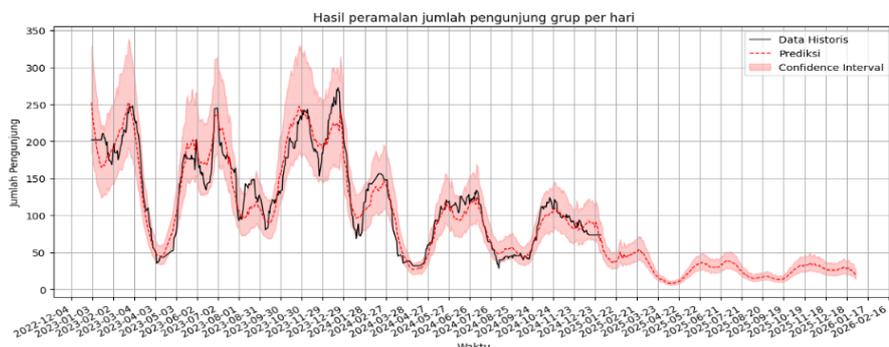


Gambar 13. Hasil Peramalan Jumlah Pengunjung Personal per Hari Menggunakan Prophet dan *Moving Average*.

Peramalan pada dataset pengunjung grup per hari juga dilakukan menggunakan metode *Moving Average* yang dikombinasikan dengan model Prophet serta komponen tambahan seperti hari libur, musiman bulanan, *changeoint prior*, dan *seasonality prior*. Untuk pemisahan data terhadap performa model, dilakukan serangkaian uji coba dengan *split data* antara data latih dan uji. Berdasarkan hasil pengujian, konfigurasi pemisahan data pada bulan 31 Desember 2024 menunjukkan performa paling optimal dibandingkan hasil lainnya, seperti 3 Maret 2024 dan 23 Desember 2024. Pada pemisahan 31 Desember 2024, model menghasilkan nilai MAPE sebesar 6.41%, MAE sebesar 16.38, MSE sebesar 268.46, dan RMSE sebesar 16.38. Sementara itu, konfigurasi *split* pada 3 Maret 2024 menghasilkan MAPE sebesar 19.15%. Oleh karena itu, bulan September 2024 dipilih sebagai waktu pemisahan data latih dan uji, karena terbukti menghasilkan akurasi terbaik secara *data-driven*. Pada peramalan tahun 2025, tanggal dengan pengunjung terbanyak berdasarkan peramalan adalah 2025-01-01 dengan jumlah sekitar 64.79 pengunjung. Tanggal dengan pengunjung paling sedikit adalah 2025-04-11 dengan jumlah sekitar 8.01 pengunjung. Visualisasi hasil peramalan dari model terbaik ditampilkan pada Tabel 9 dan Gambar 14.

Tabel 9. Hasil Peramalan Jumlah Pengunjung Grup per Hari Menggunakan Prophet dan *Moving Average*

No	Tanggal	Hasil Peramalan (Orang)
1	2025-01-01	64,78697
2	2025-01-02	62,24159
3	2025-01-03	54,342
4	2025-01-04	51,98049
5	2025-01-05	51,43364
...
360	2025-12-26	25,13359
361	2025-12-27	24,72884
362	2025-12-28	24,38022
363	2025-12-29	22,0303
364	2025-12-30	20,86785
365	2025-12-31	19,74007



Gambar 14. Hasil Peramalan Jumlah Pengunjung Grup per Hari Menggunakan Prophet dan *Moving Average*.

Gambar 11 sampai dengan Gambar 14 menunjukkan hasil model Prophet yang membandingkan data aktual (garis hitam) dan hasil peramalan (garis merah).

3.3. Evaluasi Model

Hasil peramalan kemudian dibandingkan dengan data aktual, dan tingkat kesalahan dievaluasi menggunakan metrik RMSE, MSE, MAE, dan MAPE. Pada data pengunjung personal per bulan, hasil evaluasi model ditunjukkan pada Tabel 10-11.

Tabel 10. Evaluasi Model pada Data Personal per Bulan Tanpa *Moving Average*

Model Prophet Tanpa <i>Moving Average</i> (Data Pengunjung Personal per Bulan)	MAPE	MAE	MSE	RMSE
Model Prophet Dasar (<i>Weekly & Daily Seasonality</i>)	34.08%	14.36	252.78	15.90
(+) <i>Changepoint Prior & Seasonality_Prior</i>	33.85%	14.28	250.98	15.84
(+) <i>Holidays</i>	41.22%	16.68	314.40	17.73
(+) <i>Holidays + Changepoint Prior & Seasonality_Prior</i>	41.08%	16.64	313.09	17.69
(+) Musiman Bulanan	38.60%	16.86	392.91	19.82
(+) Musiman Bulanan + <i>Changepoint Prior & Seasonality_Prior</i>	38.63%	16.88	393.35	19.83
(+) Komponen Tambahan (Hari Libur + Musiman Bulanan + <i>Changepoint Prior + Seasonality_Prior</i>) Menggunakan <i>Split Data Train & Test</i> pada Tanggal '2024-12-27' (1.0)	22.92%	6.88	47.29	6.88
(+) Komponen Tambahan <i>Nonmoving Average</i> (Hari Libur + Musiman Bulanan + <i>Changepoint Prior + Seasonality_Prior</i>) Menggunakan <i>Split Data Train & Test</i> pada Tanggal '2024-09'	42.30%	17.90	411.41	20.28
(+) Komponen Tambahan (Hari Libur + Musiman Bulanan + <i>Changepoint Prior + Seasonality_Prior</i>) Menggunakan <i>Split Data Train & Test</i> pada Tanggal '2024-07-14'	37.59%	16.51	446.90	21.14

Tabel 11. Evaluasi Model pada Data Personal per Bulan *Moving Average*

Model Prophet dengan <i>Moving Average</i> (Data Pengunjung Personal per Bulan)	MAPE	MAE	MSE	RMSE
Model Prophet Dasar (<i>Weekly & Daily Seasonality</i>)	27.42%	11.55	172.28	13.13
(+) <i>Changepoint Prior & Seasonality_Prior</i>	27.42%	11.55	172.30	13.13
(+) <i>Holidays</i>	27.31%	11.51	169.97	13.04
(+) <i>Holidays + Changepoint Prior & Seasonality_Prior</i>	27.40%	11.54	171.67	13.10
(+) Musiman Bulanan	24.63%	10.42	132.74	13.10
(+) Musiman Bulanan + <i>Changepoint Prior & Seasonality_Prior</i>	24.63%	10.42	132.76	11.52
(+) Komponen Tambahan (Hari Libur + Musiman Bulanan + <i>Changepoint Prior + Seasonality_Prior</i>) Menggunakan <i>Split Data Train & Test</i> pada Tanggal '2024-12-31' (1.0)	31.69%	13.63	185.74	13.63
(+) Komponen Tambahan (Hari Libur + Musiman Bulanan + <i>Changepoint Prior + Seasonality_Prior</i>) Menggunakan <i>Split Data Train & Test</i> pada Tanggal '2024-09'	22.27%	9.46	109.63	10.47
(+) Komponen Tambahan (Hari Libur + Musiman Bulanan + <i>Changepoint Prior + Seasonality_Prior</i>) Menggunakan <i>Split Data Train & Test</i> pada Tanggal '2024-07-14'	43.12%	18.80	445.20	21.10

Model dengan *Moving Average* menghasilkan nilai terendah sebesar MAE 9.46, MSE 109.63, RMSE 10.47, dan MAPE 22.27%, jauh lebih baik dibandingkan model tanpa *Moving Average* pada konfigurasi serupa yang mencapai MAE 6.88, MSE 47.29, RMSE 6.88, dan MAPE 22.92%. Ini menunjukkan bahwa penggunaan *Moving Average* membantu dalam meredam fluktuasi data bulanan dan memperkuat kemampuan model dalam mengenali pola jangka menengah. Sementara itu, hasil evaluasi model pada dataset pengunjung grup per bulan ditunjukkan pada Tabel 12-13.

Tabel 12. Evaluasi Model pada Tipe Pengunjung Grup per Bulan Tanpa *Moving Average*

Model Prophet Tanpa <i>Moving Average</i> (Data Pengunjung Grup per Bulan)	MAPE	MAE	MSE	RMSE
Model Prophet Dasar (<i>Weekly & Daily Seasonality</i>)	94.38%	1222.00	1871342.38	1367.97
(+) <i>Changepoint Prior & Seasonality_Prior</i>	96.10%	1232.45	1938910.44	1392.45
(+) <i>Holidays</i>	96.98%	1238.89	1974813.09	1405.28
(+) <i>Holidays + Changepoint Prior & Seasonality_Prior</i>	96.30%	1233.79	1946915.12	1395.32
(+) Musiman Bulanan	94.05%	1218.82	1857179.05	1362.78
(+) Musiman Bulanan + <i>Changepoint Prior & Seasonality_Prior</i>	94.19%	1219.98	1862854.35	1364.86
(+) Komponen Tambahan (Hari Libur + Musiman Bulanan + <i>Changepoint Prior + Seasonality_Prior</i>) Menggunakan <i>Split Data Train & Test</i> pada Tanggal '2024-09-25'	97.73%	1204.88	2020705.18	1421.52
(+) Komponen Tambahan (Hari Libur + Musiman Bulanan + <i>Changepoint Prior + Seasonality_Prior</i>) Menggunakan <i>Split Data Train & Test</i> pada Tanggal '2024-07-14'	112.88%	1294.45	2703035.21	1644.09

Tabel 13. Evaluasi Model pada Data Grup per Bulan *Moving Average*

Model Prophet dengan <i>Moving Average</i> (Data Pengunjung Grup per Bulan)	MAPE	MAE	MSE	RMSE
Model Prophet Dasar (<i>Weekly & Daily Seasonality</i>)	30.14%	728.62	530883.26	728.62
(+) <i>Changepoint Prior & Seasonality_Prior</i>	30.14%	728.62	530883.26	728.62
(+) <i>Holidays</i>	33.14%	653.10	485187.06	696.55
(+) <i>Holidays + Changepoint Prior & Seasonality_Prior</i>	30.64%	740.81	548795.26	740.81
(+) Musiman Bulanan	34.36%	830.77	690177.82	830.77
(+) Musiman Bulanan + <i>Changepoint Prior & Seasonality_Prior</i>	35.83%	866.32	750512.14	866.32
(+) Komponen Tambahan (Hari Libur + Musiman Bulanan + <i>Changepoint Prior + Seasonality_Prior</i>) Menggunakan <i>Split Data Train & Test</i> pada Tanggal '2024-09-25'	29.10%	565.36	346190.12	588.38
(+) Komponen Tambahan (Hari Libur + Musiman Bulanan + <i>Changepoint Prior + Seasonality_Prior</i>) Menggunakan <i>Split Data Train & Test</i> pada Tanggal '2024-07-14'	43.12%	18.80	445.20	21.10

Hasil dari Tabel 12-13 menghasilkan nilai terendah sebesar MAE 565.36, MSE 346190.12, RMSE 588.38 dan MAPE 29.10%, jauh lebih baik dibandingkan model tanpa *Moving Average* pada konfigurasi serupa yang mencapai MAE 1218.82, MSE 1857179.05, RMSE 1362.78 dan MAPE 94.05%. Ini menunjukkan bahwa penggunaan *Moving Average* membantu dalam meredam fluktuasi data bulanan dan memperkuat kemampuan model dalam mengenali pola jangka menengah. Adapun hasil evaluasi terhadap model Prophet pada dataset pengunjung personal per hari ditampilkan pada Tabel 14-15.

Tabel 14. Evaluasi Model pada Data Tipe Pengunjung Personal per Hari Tanpa *Moving Average*

Model Prophet Tanpa <i>Moving Average</i> (Data Pengunjung Personal per Hari)	MAPE	MAE	MSE	RMSE
Model Prophet Dasar (<i>Weekly & Daily Seasonality</i>)	238.43%	2.38	5.69	2.38
(+) <i>Changepoint Prior & Seasonality_Prior</i>	216.73%	2.47	6.12	2.47
(+) <i>Holidays</i>	313.89%	3.14	9.85	3.14
(+) <i>Holidays + Changepoint Prior & Seasonality_Prior</i>	233.88%	3.27	10.69	3.27
(+) Musiman Bulanan	200.32%	2.00	4.01	2.00
(+) Musiman Bulanan + <i>Changepoint Prior & Seasonality_Prior</i>	178.48%	2.14	4.56	2.14
(+) Komponen Tambahan (Hari Libur + Musiman Bulanan + <i>Changepoint Prior + Seasonality_Prior</i>) Menggunakan <i>Split Data Train & Test</i> pada Tanggal '2024-12-27'	198.61%	2.82	7.93	2.82
(+) Komponen Tambahan (Hari Libur + Musiman Bulanan + <i>Changepoint Prior + Seasonality_Prior</i>) Menggunakan <i>Split Data Train & Test</i> pada Tanggal '2024-03-03'	53.52%	1.46	4.88	2.21

(+) Komponen Tambahan (Hari Libur + Musiman Bulanan + <i>Changepoint Prior</i> + <i>Seasonality Prior</i>) + Menggunakan <i>Split Data Train & Test</i> pada Tanggal '2023-12-23'	295.97%	4.48	29.05	5.39
--	---------	------	-------	------

Tabel 15. Evaluasi Model pada Data Tipe Pengunjung Personal per Hari *Moving Average*

Model Prophet dengan <i>Moving Average</i> (Data Pengunjung Personal per Hari)	MAPE	MAE	MSE	RMSE
Model Prophet Dasar (<i>Weekly & Daily Seasonality</i>)	7.40%	0.18	0.03	0.18
(+) <i>Changepoint Prior & Seasonality_Prior</i>	7.40%	0.20	0.04	0.20
(+) <i>Holidays</i>	6.39%	0.16	0.03	0.16
(+) <i>Holidays</i> + <i>Changepoint Prior & Seasonality_Prior</i>	6.27%	0.17	0.04	0.17
(+) Musiman Bulanan	6.35%	0.16	0.03	0.16
(+) Musiman Bulanan + <i>Changepoint Prior & Seasonality_Prior</i>	6.32%	0.17	0.03	0.17
(+) Komponen Tambahan (Hari Libur + Musiman Bulanan + <i>Changepoint Prior</i> + <i>Seasonality_Prior</i>) + Menggunakan <i>Split Data Train & Test</i> pada Tanggal '2024-12-27'	5.58%	0.15	0.02	0.15
(+) Komponen Tambahan (Hari Libur + Musiman Bulanan + <i>Changepoint Prior</i> + <i>Seasonality_Prior</i>) + Menggunakan <i>Split Data Train & Test</i> pada Tanggal '2024-03-03'	22.80%	0.56	0.49	0.70
(+) Komponen Tambahan (Hari Libur + Musiman Bulanan + <i>Changepoint Prior</i> + <i>Seasonality_Prior</i>) + Menggunakan <i>Split Data Train & Test</i> pada Tanggal '2023-12-23'	17.24%	0.43	0.30	0.54

Hasil dari Tabel 14-15 menghasilkan nilai terendah sebesar MAE 0.15, MSE 0.02, RMSE 0.15, dan MAPE 5.58%, jauh lebih baik dibandingkan model tanpa *Moving Average* pada konfigurasi serupa yang mencapai MAPE 53.52%. Ini menunjukkan bahwa penggunaan *Moving Average* membantu dalam meredam fluktuasi data harian. Adapun hasil evaluasi untuk dataset pengunjung grup per hari ditampilkan pada Tabel 16-17.

Tabel 16. Evaluasi Model pada Data Tipe Pengunjung Grup per Hari Tanpa *Moving Average*

Model Prophet Tanpa <i>Moving Average</i> (Data Pengunjung Grup per Hari)	MAPE	MAE	MSE	RMSE
Model Prophet Dasar (<i>Yearly, Weekly & Daily Seasonality</i>)	273.26%	35.52	1261.94	35.52
(+) <i>Changepoint Prior & Seasonality_Prior</i>	262.35%	35.02	1226.07	35.02
(+) <i>Holidays</i>	399.24%	51.9	2693.72	51.9
(+) <i>Holidays</i> + <i>Changepoint Prior & Seasonality_Prior</i>	399.24%	53.26	2836.49	53.26
(+) Musiman Bulanan + <i>Changepoint Prior & Seasonality_Prior</i>	244.76%	31.99	1023.42	31.99
(+) Musiman Bulanan	254.38%	33.07	1093.55	33.07
(+) Komponen Tambahan (<i>Holidays</i> + Musiman Bulanan + <i>Changepoint Prior</i> + <i>Seasonality_Prior</i>) <i>Train & Test</i> = '2024-12-31'	336.77%	44.78	2005.24	44.78
(+) Komponen Tambahan (Hari Libur + Musiman Bulanan + <i>Changepoint Prior</i> + <i>Seasonality_Prior</i>) <i>Train & Test</i> = '2024-03-03'	154.07%	58.54	7923.26	89.01
(+) Komponen Tambahan (Hari Libur + Musiman Bulanan + <i>Changepoint Prior</i> + <i>Seasonality_Prior</i>) <i>Train & Test</i> = '2023-12-23'	109.38%	45.98	2481.96	49.82

Tabel 17. Evaluasi Model pada Data Tipe Pengunjung Grup per Hari *Moving Average*

Model Prophet dengan <i>Moving Average</i> (Data Pengunjung Grup per Hari)	MAPE	MAE	MSE	RMSE
Model Prophet Dasar (<i>Yearly, Weekly & Daily Seasonality</i>)	17.41%	12.77	162.96	12.77
(+) <i>Changepoint Prior & Seasonality_Prior</i>	13.15%	20.12	404.95	20.12
(+) <i>Holidays + Changepoint Prior & Seasonality_Prior</i>	12.99 %	9.52	90.70	9.52
(+) Musiman Bulanan + <i>Changepoint Prior & Seasonality_Prior</i>	10.73%	18.92	358.08	18.92
(+) Musiman Bulanan	15.52%	11.38	129.57	11.38
(+) Komponen Tambahan (<i>Holidays + Musiman Bulanan + Changepoint Prior + Seasonality_Prior</i>) <i>Train & Test = '2024-12-31'</i>	6.41%	16.38	268.46	16.38
(+) Komponen Tambahan (<i>Hari Libur + Musiman Bulanan + Changepoint Prior + Seasonality_Prior</i>) <i>Train & Test = '2024-03-03'</i>	19.15%	21.62	481.20	21.94
(+) Komponen Tambahan (<i>Hari Libur + Musiman Bulanan + Changepoint Prior + Seasonality_Prior</i>) <i>Train & Test = '2023-12-23'</i>	17.36%	33.19	1349.65	36.74

Hasil dari Tabel 16-17 menghasilkan nilai MAPE terendah sebesar 6.41%, jauh lebih baik dibandingkan model tanpa *Moving Average* pada konfigurasi serupa yang mencapai MAPE 109.38%. Ini menunjukkan bahwa penggunaan *Moving Average* membantu dalam meredam fluktuasi data harian.

3.4. Perbandingan Hasil Pengujian Seluruh Model Peramalan

Hasil terbaik dari setiap dataset pada model Prophet yang dikombinasikan dengan komponen tambahan serta metode *Moving Average* (MA) ditampilkan pada Tabel 18. Setiap model diuji berdasarkan waktu pemisahan data *training* dan *testing* yang berbeda, dan dioptimalkan dengan parameter seperti hari libur, musiman bulanan, *changepoint_prior* dan *seasonality_prior*.

Tabel 18. Hasil Evaluasi Terbaik

Dataset	Model Prophet	MAPE	MAE	MSE	RMSE
Personal per Bulan	Prophet + Hari Libur + Musiman Bulanan + <i>Changepoint Prior + Seasonality_Prior Split Data + MA. Train & Test = '2024-09'</i>	22.27%	9.46	109.63	10.47
Grup per Bulan	Prophet + Hari Libur + Musiman Bulanan + <i>Changepoint Prior + Seasonality_Prior + MA Train & Test = '2024-09-25' (0.86)</i>	29.10%	565.36	346190.12	588.38
Personal per Hari	Prophet + Hari Libur + Musiman Bulanan + <i>Changepoint Prior + Seasonality_Prior + MA. Train & Test = '2024-12-27'</i>	5.58%	0.15	0.02	0.15
Grup per Hari	Prophet + <i>Holidays + Musiman Bulanan + Changepoint Prior + Seasonality_Prior+MA+ Train & Test = 2024-12-31</i>	6.41%	16.38	268.46	16.38

Tabel 18 menunjukkan bahwa model Prophet dengan konfigurasi parameter tambahan dan *Moving Average* mampu memberikan hasil peramalan yang cukup akurat, terutama untuk data harian. Metrik evaluasi terbaik diperoleh pada data pengunjung personal per hari dengan MAPE sebesar 5,58%, yang menunjukkan bahwa pola kunjungan individu harian lebih stabil dan dapat diramalkan dengan baik oleh model. Pada data grup per bulan, performa cukup baik tercapai dengan MAPE sebesar 29,10%, yang kemungkinan disebabkan oleh fluktuasi besar dalam kunjungan kelompok serta keterbatasan data historis. Sementara itu, pada data personal per bulan, MAPE sebesar 22,27% mengindikasikan bahwa data bulanan cenderung memiliki fluktuasi yang lebih tidak stabil dibandingkan data harian, namun masih berada dalam batas toleransi model. Adapun pada data grup per hari, model menghasilkan MAPE sebesar 6,41%, menunjukkan bahwa meskipun variasi kunjungan kelompok harian

lebih tinggi dibandingkan data personal, model tetap mampu menangkap pola pergerakan harian dengan cukup baik.

Prophet berhasil menangkap pola-pola ini dengan baik karena menggunakan *Moving Average* dan parameter yang memungkinkan model menyesuaikan peramalan berdasarkan pola historis. Meskipun model Prophet menunjukkan hasil yang cukup baik, terdapat keterbatasan dalam penelitian ini yaitu keakuratan data hari libur. Model hanya menggunakan data hari libur yang telah ditentukan sebelumnya, sementara liburan tambahan seperti cuti bersama yang dapat mempengaruhi hasil peramalan.

3.5. Diskusi Hasil Peramalan Model

Pada tahap ini membahas interpretasi hasil peramalan, kelebihan dan kelemahan model yang digunakan, serta relevansi temuan penelitian terhadap studi terdahulu. Selain itu, terdapat implikasi hasil penelitian terhadap pengelolaan Museum Muhammadiyah.

3.5.1. Kelebihan dan kelemahan model Prophet

Model Prophet memiliki keunggulan dalam mendeteksi pola *seasonality*, tren jangka panjang, serta perubahan mendadak melalui fitur *change point*. Kemampuan ini relevan dengan karakteristik data jumlah pengunjung museum yang dipengaruhi oleh *holidays*, musim liburan sekolah, dan peristiwa tertentu. Prophet juga memberikan fleksibilitas tinggi dalam penyesuaian komponen *seasonality* dan *holidays*. Namun, Prophet memiliki keterbatasan dalam menghadapi data dengan fluktuasi tajam dan outlier, terutama pada data harian. Hal ini dapat dilihat dari performa model yang kurang optimal pada dataset pengunjung grup harian tanpa *preprocessing*, dengan nilai MAPE mencapai 109.38%.

3.5.2. Perbandingan Prophet vs Prophet + *Moving Average*

Hasil evaluasi menunjukkan bahwa kombinasi *Moving Average* sebagai metode *smoothing* sebelum pemodelan Prophet secara signifikan meningkatkan akurasi peramalan. Contohnya, pada dataset pengunjung personal per hari, model Prophet tanpa *Moving Average* menghasilkan MAPE sebesar 53.52%, sedangkan setelah diterapkan *Moving Average*, nilai MAPE menurun drastis menjadi 5,58%. Hal ini menunjukkan bahwa proses *smoothing* mampu mengurangi *noise* dan memperjelas pola data, sehingga Prophet dapat mempelajari tren utama dengan lebih baik. Dengan demikian, integrasi *Moving Average* meningkatkan ketahanan model dalam menghadapi variabilitas data jangka pendek.

3.5.3. Relevansi terhadap studi sebelumnya

Temuan dalam penelitian ini selaras dengan hasil studi Mutiara Ramadita, dkk. [8], yang menunjukkan bahwa model *hybrid* DWT-SVR-Prophet memberikan hasil prediksi curah hujan yang lebih akurat dibandingkan Prophet saja, terutama pada data dengan pola yang kompleks. Selain itu, penelitian oleh Primawati, dkk. [14] menyimpulkan bahwa kinerja Prophet pada produksi susu sapi harian meningkat secara signifikan apabila didukung oleh teknik *preprocessing* yang tepat. Oleh karena itu, penggunaan *Moving Average* sebagai metode *preprocessing* dalam penelitian ini didukung secara teoritis oleh literatur yang relevan.

3.5.4. Implikasi praktis

Model peramalan yang akurat dapat dimanfaatkan oleh pengelola Museum Muhammadiyah untuk mendukung pengambilan keputusan berbasis data. Hasil penelitian ini memiliki beberapa implikasi praktis. Pertama, hasil peramalan dapat digunakan untuk menyusun strategi operasional, seperti penyesuaian jumlah staf dan jam operasional pada periode dengan prediksi kunjungan tinggi, misalnya pada bulan Juli dan Desember. Selain itu, perencanaan promosi dapat dilakukan lebih efektif pada periode yang diprediksi mengalami penurunan kunjungan, seperti bulan Februari dan bulan Ramadhan. Hasil peramalan juga dapat dimanfaatkan untuk menyusun jadwal kegiatan edukatif atau event khusus pada waktu-waktu yang berpotensi mendatangkan banyak pengunjung. Di samping itu, pengelolaan logistik dan fasilitas, seperti pembukaan loket tambahan atau pengaturan ulang arus pengunjung, dapat dilakukan untuk menjaga pengalaman wisatawan tetap optimal saat terjadi lonjakan pengunjung.

4. KESIMPULAN

Berdasarkan eksperimen dan hasil evaluasi yang telah dilakukan, kombinasi *Moving Average* dan model Prophet dinyatakan mampu untuk melakukan peramalan pengunjung wisata edukasi museum secara akurat dengan catatan bahwa perlu dilakukan penyetelan *hyperparameter*. **Temuan utama** dari penelitian ini menunjukkan bahwa penggunaan *Moving Average* sebagai teknik *smoothing* sebelum pemodelan Prophet secara signifikan meningkatkan hasil peramalan, terutama pada data dengan fluktuasi tinggi. Berdasarkan hasil peramalan yang dilakukan dengan kombinasi metode *Moving Average* dan model Prophet, diperoleh gambaran yang lebih stabil dan akurat terhadap pola jumlah pengunjung Museum Muhammadiyah selama tahun 2025. Model ini terbukti memberikan performa yang lebih baik dibandingkan Prophet tanpa preprocessing, terutama untuk data harian. Pada data pengunjung **personal per bulan**, hasil peramalan menunjukkan bahwa bulan April diprediksi menjadi puncak kunjungan dengan 65 pengunjung, sedangkan jumlah terendah terjadi pada bulan Maret dengan hanya 7 pengunjung, evaluasi model menghasilkan MAPE sebesar 22,27%, termasuk dalam kategori cukup baik. Sementara itu, pada data pengunjung **grup per bulan**, jumlah pengunjung tertinggi diperkirakan terjadi pada bulan Januari dengan 3398 orang, sedangkan yang terendah pada bulan Mei sebesar 1171 orang, nilai MAPE yang diperoleh sebesar 29,10%, mengindikasikan performa yang cukup baik untuk skala bulanan. Pada data pengunjung **personal per hari**, hasil peramalan menunjukkan fluktuasi yang relatif kecil dengan prediksi tertinggi sebesar 2,79 orang pada tanggal 12 Januari 2025 dan terendah sebesar 1,31 orang pada tanggal 8 Mei 2025. Evaluasi model menunjukkan performa sangat baik dengan MAPE 5,58%. Adapun pada data **pengunjung grup per hari**, peramalan tertinggi terjadi pada 1 Januari 2025 dengan 64,79 pengunjung, sedangkan yang terendah pada 11 April 2025 dengan 8,01 pengunjung, model ini memperoleh nilai MAPE sebesar 6,41%, juga menunjukkan kategori peramalan yang sangat baik. Model ini dapat digunakan sebagai dasar pengambilan keputusan strategis oleh pengelola Museum Muhammadiyah dalam hal operasional, promosi, dan penjadwalan kegiatan.

Kontribusi utama dari penelitian ini adalah membuktikan efektivitas kombinasi teknik *smoothing Moving Average* dengan model Prophet dalam meningkatkan stabilitas prediksi deret waktu musiman. Penelitian ini memperkaya pendekatan peramalan jumlah pengunjung museum dengan mengintegrasikan *preprocessing data* berbasis *smoothing*, yang sebelumnya jarang diterapkan pada studi sejenis. Selain itu, penelitian ini memberikan bukti bahwa penggunaan *Moving Average* dapat memperbaiki performa Prophet dalam menangani fluktuasi jangka pendek. Meskipun demikian, penelitian ini memiliki beberapa keterbatasan. Data hari libur yang digunakan terbatas pada hari libur nasional tanpa mempertimbangkan *event-event* lokal atau cuti bersama, yang berpotensi memengaruhi jumlah kunjungan. Berdasarkan hasil dan keterbatasan tersebut, rekomendasi untuk pengembangan ke depan adalah integrasi sistem peramalan ini dengan kalender *event* museum, sehingga model dapat memperhitungkan lonjakan kunjungan pada *event-event* khusus.

Saran untuk penelitian di masa depan adalah dapat menggunakan variabel lain yang berkorelasi sehingga hasil peramalan dari model dapat ditingkatkan. Kemudian, dataset yang digunakan dapat melalui proses tertentu untuk mengurangi dampak yang dihasilkan oleh nilai-nilai outlier. Selain itu, untuk penelitian selanjutnya supaya dapat menyanggah Prophet dengan algoritma *machine learning* yang lain supaya lebih meningkatkan hasil model.

DAFTAR PUSTAKA

- [1] R. Sebastian Santoso and F. Kartika Sari Dewi, "Konfigurasi Model Prophet untuk Prediksi Harga Saham Sektor Teknologi di Indonesia yang Akurat," *Jurnal Buana Informatika*, vol. 15, no. 1, pp. 50–58, Apr. 2024, doi: <https://doi.org/10.24002/jbi.v15i1.8634>.
- [2] H. Yuliansyah, S. Asti Mulasari, F. Tentama, Sulistyawati, L. Nafiati, and T. Wahyuni Sukesi, "Pengembangan dan Pemanfaatan Platform Digital untuk Desa Wisata di Desa Ngoro-oro Gunungkidul," *IJCOSIN: Indonesian Journal of Community Service and Innovation*, vol. 2, no. 1, pp. 56–65, Jan. 2022, doi: <https://doi.org/10.20895/ijcosin.v2i1.414>.
- [3] S. Asti Mulasari *et al.*, "Peningkatan Daya Saing Desa Wisata Ngoro-oro Patuk Gunungkidul," in *Seminar Nasional Hasil Pengabdian kepada Masyarakat*, Yogyakarta, Nov. 2022, pp. 557–564.
- [4] Y. A. Auliya, Y. Nurdiansyah, and A. Puji Astuti, "Peramalan Jumlah Pengunjung Objek Wisata Gumul Paradise Island Kabupaten Kediri Menggunakan Metode Prophet," *Informatics Journal*, vol. 8, no. 1, pp. 37–43, Apr. 2023, doi: <https://doi.org/10.19184/isj.v8i1.35605>.
- [5] A. Bahauddin, A. Dwiki Darmawan, S. Aulia Ihsani, and N. Jahra Izdihar, "Peramalan Utilitas Listrik dan Gas Menggunakan Bahasa Pemrograman Python dan FBProphet," *Journal Industrial Servicess*, vol. 6, no. 2, pp. 93–98, Mar. 2021, doi: <http://dx.doi.org/10.36055/62002>.

- [6] C. Chandra and S. Budi, "Analisis Komparatif ARIMA dan Prophet dengan Studi Kasus Dataset Pendaftaran Mahasiswa Baru," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 6, no. 2, pp. 278–287, Aug. 2020, doi: 10.28932/jutisi.v6i2.2676.
- [7] A. Laksono Suryoputro and S. Yulianto Joko Prasetyo, "Prediksi dan Visualisasi Penyakit COVID-19 Menggunakan Kombinasi Prophet dan GeoPandas," *AITI: Jurnal Teknologi Informasi*, vol. 20, no. 2, pp. 135–149, May 2023, doi: <https://doi.org/10.24246/aiti.v20i2.135-149>.
- [8] M. Ramadita, Mahmudi, and M. Yunita Wijaya, "Prediksi Curah Hujan di DKI Jakarta Menggunakan Model Hybrid (DWT-SVR-Prophet)," *The Indonesian Journal of Computer Science*, vol. 13, no. 5, pp. 8179–8194, Sep. 2024, doi: <https://doi.org/10.33022/ijcs.v13i5.4357>.
- [9] M. Harahap, A. Zaki Andika, A. Mahmud Husein, and A. Dharma, "Analisis Tren dan Perkiraan Pandemi Covid-19 di Indonesia Menggunakan Peramalan Metode Prophet Sebelum dan Sesudah Aturan New Normal," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 9, no. 1, pp. 51–60, Feb. 2022, doi: 10.25126/jtiik.202294060.
- [10] L. Ervintyana Deni Kartika Sari, A. Widjaja, and S. Lie Liliawati, "Analisis Deret Waktu dari Produk yang Terjual Menggunakan Beberapa Teknik Populer," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 9, no. 1, pp. 110–126, Apr. 2023, doi: <http://dx.doi.org/10.28932/jutisi.v9i1.5933>.
- [11] F. Mu'minin, Fauziah, and A. Gunaryati, "Prediksi Kunjungan Wisatawan Mancanegara Melalui Pintu Udara Menggunakan ARIMA, Glnnet, dan Prophet," *Techno.Com*, vol. 21, no. 1, pp. 149–156, Feb. 2022, doi: 10.33633/tc.v21i1.5695.
- [12] F. Theresia Br Sitepu, V. Amelia Prada Sirait, and R. Yunis, "Analisis Runtun Waktu untuk Memprediksi Jumlah Mahasiswa Baru dengan Model Prophet Facebook," *Paradigma - Jurnal Komputer dan Informatika*, vol. 23, no. 1, pp. 99–105, Mar. 2021, doi: <https://doi.org/10.31294/p.v23i1>.
- [13] H. Yuliansyah, R. Adi Putri Imaniati, A. Wirasto, and M. Wibowo, "Predicting Students Graduate on Time Using C4.5 Algorithm," *Journal of Information Systems Engineering and Business Intelligence*, vol. 7, no. 1, p. 67, Apr. 2021, doi: <http://dx.doi.org/10.20473/jisebi.7.1.67-73>.
- [14] A. Primawati, I. Sukaesih Sitanggang, Annisa, and D. Apri Astuti, "Perbandingan Kinerja LSTM dan Prophet untuk Prediksi Deret Waktu (Studi Kasus Produksi Susu Sapi Harian)," *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, vol. 9, no. 3, pp. 428–435, Dec. 2023, doi: <https://doi.org/10.26418/jp.v9i3.72031>.
- [15] Avinash, A. Widjaja, and O. Karnalim, "Analisis Perbandingan Algoritma Machine Learning untuk Forecasting Persediaan Produk Barang Pokok," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 10, no. 2, pp. 361–378, Aug. 2024, doi: <https://doi.org/10.28932/jutisi.v10i2.9357>.
- [16] A. Prayuda and I. Pratama, "Prediksi Jumlah Kedatangan Wisatawan Mancanegara di Indonesia Berdasarkan Pintu Masuk Kedatangan Udara," *Rabit : Jurnal Teknologi dan Sistem Informasi Univrab*, vol. 9, no. 2, pp. 232–241, Jul. 2024, doi: <https://doi.org/10.36341/rabit.v9i2.4787>.
- [17] R. Rachman, "Penerapan Metode Moving Average dan Exponential Smoothing pada Peramalan Produksi Industri Garment," *Jurnal Informatika*, vol. 5, no. 1, pp. 211–220, Sep. 2018, doi: <http://dx.doi.org/10.31311/ji.v5i2.3309>.
- [18] V. Nur Aziza, U. Dyah Syafitri, and A. Fitrianto, "Optimizing Currency Circulation Forecasts in Indonesia: A Hybrid Prophet-Long Short Term Memory Model with Hyperparameter Tuning," *MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, vol. 24, no. 1, pp. 73–84, Nov. 2024, doi: 10.30812/matrik.v24i1.4052.
- [19] G. Totok Suryawan, K. Nurcahyo Putra, P. Mita Meliana, and I. G. Iwan Sudipa, "Performance Comparison of ARIMA, LSTM, and Prophet Methods in Sales Forecasting," *Sinkron : Jurnal dan Penelitian Teknik Informatika*, vol. 8, no. 4, pp. 2410–2421, Oct. 2024, doi: <https://doi.org/10.33395/sinkron.v8i4.14057>.
- [20] D. Hayuningtyas Roosaputri Rizkya and C. Dewi, "Perbandingan Algoritma ARIMA, Prophet, dan LSTM dalam Prediksi Penjualan Tiket Wisata Taman Hiburan (Studi Kasus: Saloka Theme Park)," *KESATRIA: Jurnal Penerapan Sistem Informasi (Komputer & Manajemen)*, vol. 4, no. 3, pp. 507–517, Jul. 2023, doi: <https://doi.org/10.30645/kesatria.v4i3.199>.
- [21] E. Putra Ramdhani and H. Agung Nugroho, "Prediksi Tegangan Catu Daya Automatic Rain Gauge Berdasarkan Seasonality Algoritma Prophet," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 12, no. 1, pp. 80–90, Jan. 2024, doi: <http://dx.doi.org/10.26760/elkomika.v12i1.80>.

- [22] H. Fadhila Fiqa, A. Ratna Dewi, and R. Pandiya, “Perbandingan Metode ARIMA dan Prophet dalam Prediksi Harga Cabai Rawit di Provinsi Jawa Timur,” *Seminar Nasional Sains Data*, vol. 4, no. 1, pp. 850–862, Oct. 2024, doi: <https://doi.org/10.33005/senada.v4i1.350>.