

ANALISIS TREN DAN FORECASTING KUNJUNGAN PASIEN BERBASIS FACEBOOK PROPHET UNTUK OPTIMALISASI MANAJEMEN LAYANAN KESEHATAN

Hasna Nailah Azalia¹, Hannie², Azhari Ali Ridha³

¹⁻³Universitas Singaperbangsa Karawang; Jl. HS. Ronggo Waluyo, Puseurjaya, Telukjambe Timur, Karawang, Jawa Barat. 41361; Phone (0267) 641177

Keywords:

Analisis Tren, *Forecasting*, Facebook Prophet, Manajemen Layanan Kesehatan

Correspondent Email:

azaliahsna12@gmail.com

Abstrak. Lonjakan kunjungan pasien yang tak terantisipasi akibat faktor stokastik sering kali menyebabkan hambatan operasional dan penurunan kualitas layanan. Penelitian ini bertujuan melakukan analisis tren dan forecasting kunjungan pasien menggunakan algoritma Facebook Prophet guna mendukung optimalisasi manajemen layanan kesehatan. Dataset yang digunakan bersumber dari Sistem Informasi Manajemen Rumah Sakit (SIMRS) pada salah satu Rumah Sakit Umum Swasta di daerah Sukabumi, mencakup data historis kunjungan pasien harian periode Juli 2023 hingga Desember 2025. Metode penelitian dilakukan melalui tahapan eksperimen dengan menerapkan skenario pembagian data (data splitting) sebesar 80% data latih dan 20% data uji. Hasil penelitian menunjukkan bahwa model Facebook Prophet memiliki performa yang Tangguh terhadap fluktuasi data kunjungan dengan akurasi 79,6%. Metrik evaluasi model menghasilkan nilai Mean Absolute Scaled Error (MASE) sebesar 0,48, rata-rata selisih prediksi (MAE) sebesar 71,83 pasien, dan RMSE sebesar 88,48 pasien. Dengan memisahkan variabel tren dan musiman, ditemukan bahwa pola musiman mingguan merupakan variabel paling dominan yang memengaruhi fluktuasi kunjungan pasien. Hasil forecasting untuk periode Januari 2026 diintegrasikan menjadi sistem peringatan dini melalui penetapan Kapasitas Siaga berbasis Rentang Kesiagaan (± 72 pasien). Implementasi strategi ini memungkinkan manajemen untuk beralih dari pola kerja reaktif menjadi mitigasi risiko operasional yang presisi guna memaksimalkan efisiensi layanan sekaligus mengoptimalkan alokasi sumber daya.



Copyright © [JITET](http://www.jitet.org) (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open access article distributed under terms and conditions of the Creative Commons Attribution (CC BY NC)

Abstract. *Unanticipated patient surges often cause operational bottlenecks and service quality decline. This research utilizes the Facebook Prophet algorithm for trend analysis and forecasting to optimize healthcare management, using daily HIS data from a Sukabumi private hospital (July 2023 – December 2025). Using an experimental approach with an 80:20 data split, the model achieved 79.6% accuracy, a Mean Absolute Scaled Error (MASE) of 0.48, and an MAE of 71.83 patients. Analysis identified weekly seasonality as the dominant factor influencing visit fluctuations. Results for January 2026 were integrated into an early warning system through a “Standby Capacity” framework with a Readiness Range of ± 72 patients. This strategy enables a shift from reactive workflows to precise operational risk mitigation, maximizing service efficiency and resource allocation. By isolating trend and seasonal variables, this study provides a tactical navigation tool for hospital management to proactively address patient demand.*

1. PENDAHULUAN

Di era globalisasi dan digitalisasi kesehatan, banyak sistem pelayanan kesehatan menghadapi tantangan signifikan terkait fluktuasi volume pasien yang datang ke fasilitas kesehatan, terutama dalam hal perencanaan kapasitas dan alokasi sumber daya [1]. Di Indonesia, angka kunjungan pasien ke fasilitas kesehatan, termasuk rumah sakit dan puskesmas, mengalami perubahan dan fluktuasi yang signifikan dari waktu ke waktu.

Tabel 1. Jumlah Kunjungan Pasien Berdasarkan Jenis Pelayanan di Rumah Sakit Rujukan Jawa Barat

Kinerja Pelayanan	Tahun 2021	Tahun 2022	Tahun 2023	Tahun 2024	November 2025
Rawat Jalan	473.413	513.057	568.666	604.025	625.598
Rawat Darurat	18.040	28.970	27.636	32.139	32.933
Rawat Inap	33.277	45.120	49.628	56.983	64.078

(Sumber: [2])

Meskipun tingginya permintaan layanan kesehatan, banyak fasilitas yang masih mengalami kesulitan dalam mengelola antrian dan waktu pelayanan. Situasi ini menyebabkan layanan seringkali menjadi sangat padat tanpa adanya persiapan, sementara di waktu lain kapasitas layanan tidak termanfaatkan secara maksimal. Akibatnya, potensi pemborosan sumber daya (*overstaffing*) atau terjadinya (*under-staffing*) akan muncul. Dalam situasi ini, manajemen antrian menjadi kunci untuk meningkatkan kepuasan pasien dan menurunkan tingkat keluhan terkait dengan layanan yang diberikan [3]. Penelitian oleh Khasanah dan Astuti [4] bahkan menunjukkan bahwa panjangnya antrian berkorelasi negatif dengan kepuasan pasien di puskesmas, sehingga mengidentifikasi kebutuhan akan sistem manajemen yang lebih baik untuk meningkatkan kualitas. Oleh karena itu, kemampuan untuk memprediksi kedatangan pasien adalah hal yang krusial.

Landasan teoritis penelitian ini adalah *time series forecasting* (peramalan deret waktu) dan analitik prediktif dalam manajemen layanan kesehatan. Variabel dependen (Y) adalah jumlah kedatangan pasien, sedangkan variabel independen (X) adalah tren historis, musiman (*seasonality*), akhir minggu (*weekend*), serta faktor eksternal seperti periode libur nasional.

Dari studi literatur, terdapat beberapa celah (*gap*) penelitian yang relevan. Meskipun banyak penelitian menggunakan model deret waktu konvensional untuk prediksi kedatangan pasien, masih sedikit yang memanfaatkan model Facebook Prophet, khususnya dalam konteks fasilitas kesehatan di Indonesia. Selain itu, masih terdapat sedikit penelitian yang secara eksplisit menghubungkan hasil prediksi kedatangan pasien dengan optimalisasi manajemen layanan secara nyata di fasilitas kesehatan Indonesia.

Urgensi penelitian ini terletak pada perbaikan pengalaman pasien dan peningkatan efisiensi operasional. Dengan semakin kompleksnya lingkungan layanan kesehatan, tersedianya model peramalan yang andal, fasilitas kesehatan dapat merencanakan sumber daya manusia, ruang perawatan, dan layanan penunjang lainnya secara lebih proaktif. Penelitian ini diharapkan dapat memberikan kontribusi dalam optimalisasi perencanaan sumber daya fasilitas kesehatan berdasarkan prediksi tren kunjungan pasien.

2. TINJAUAN PUSTAKA

2.1. Kunjungan Pasien

Kunjungan pasien merupakan layanan yang efisiensinya sering terhambat oleh masalah operasional ataupun ketidakpastian jumlah kedatangan harian. Masalah operasional ini muncul karena manajemen fasilitas kesehatan belum dapat memprediksi beban kerja dan alokasi sumber daya yang dibutuhkan secara tepat. Untuk mengatasi inefisiensi ini dan mendukung peningkatan mutu pelayanan, manajemen fasilitas kesehatan perlu melakukan peramalan kunjungan pasien secara akurat [5]. Peramalan ini menjadi tindakan strategis yang fundamental karena hasilnya dapat digunakan sebagai rujukan utama untuk mengambil kebijakan proaktif. Dengan prediksi yang akurat, pihak manajemen dapat secara efektif mengurangi penumpukan pasien dan mengoptimalkan alur pelayanan, sehingga meningkatkan kepuasan dan retensi pasien.

2.2. Manajemen Layanan Kesehatan

Manajemen Layanan Kesehatan merupakan aspek fundamental dan strategis di rumah sakit yang bertujuan meningkatkan kualitas pelayanan dan mengoptimalkan efektivitas

pengambilan keputusan. Keberhasilan manajemen sering diindikasikan oleh loyalitas pasien, yang dipengaruhi kuat oleh kepuasan dan pengalaman pasien selama menerima layanan kesehatan [6]. Untuk mencapai tujuan tersebut dan mengatasi masalah operasional harian, strategi manajemen informasi menjadi esensial. Ini melibatkan pengembangan Sistem Informasi Manajemen Rumah Sakit (SIMRS), optimalisasi Standar Operasional Prosedur (SOP), dan peningkatan Sumber Daya Manusia (SDM) [7]. Pada akhirnya, optimalisasi manajemen layanan kesehatan berpusat pada pemanfaatan sistem informasi dan teknologi untuk meningkatkan efisiensi operasional dan mutu pelayanan, yang secara langsung akan mendukung retensi dan loyalitas pasien.

2.3. Peramalan (*Forecasting*)

Peramalan (*forecasting*) merupakan proses analitis yang memanfaatkan data historis untuk memprediksi suatu keadaan pada periode mendatang melalui penerapan model matematika yang disusun secara sistematis [8]. Proses ini dilakukan dengan menganalisis data yang sudah lampau [9] menggunakan pendekatan kuantitatif yang terstruktur serta mengintegrasikan faktor-faktor kualitatif yang relevan [10]. Tingkat akurasi hasil peramalan sangat memengaruhi kualitas analisis manajerial, karena proyeksi yang dihasilkan menjadi dasar utama dalam proses pengambilan keputusan. Melalui peramalan yang akurat, sebuah organisasi dapat mengidentifikasi potensi perubahan dan menyiapkan strategi antisipatif yang diperlukan [9]. Tujuan utama dari *forecasting* ini adalah untuk mengurangi ketidakpastian dalam pengambilan keputusan, terutama dalam lingkungan yang terus berubah. Secara spesifik, dalam konteks layanan kesehatan, hasil *forecasting* yang akurat dapat membantu pengelolaan operasional fasilitas kesehatan. Hal ini mencakup perencanaan alokasi sumber daya, seperti tenaga medis, ketersediaan ruang perawatan, dan stok obat. Dengan demikian, penerapan *forecasting* memungkinkan pihak manajemen fasilitas kesehatan untuk mengimplementasikan langkah-langkah proaktif dalam menghadapi fluktuasi volume kunjungan pasien [11].

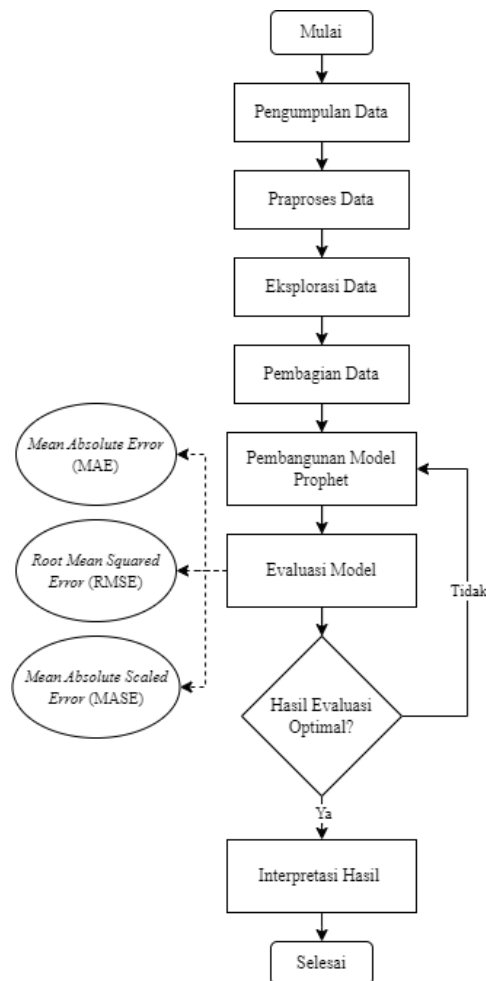
2.4. Facebook Prophet

Facebook Prophet adalah model *machine learning* (ML) terbuka (*open-source*) yang dirilis oleh Facebook pada 23 Februari 2017, dirancang khusus untuk peramalan deret waktu (*time series forecasting*) [12]. Prophet menggunakan pendekatan model regresi aditif modular yang mampu menghasilkan prediksi dengan akurasi tinggi menggunakan parameter yang sederhana dan mudah diinterpretasikan [13]. Model ini direkomendasikan untuk data deret waktu dengan fluktuasi musiman yang kuat (*strong seasonal effects*) dan memiliki rentang data historis yang mencakup beberapa musim [14]. Keunggulan utama Facebook Prophet terletak pada kemudahan penggunaannya sebagai alat peramalan yang ramah pengguna dengan persyaratan konfigurasi yang minimal. Model ini secara otomatis mengelola berbagai aspek peramalan deret waktu, seperti penanganan musim, deteksi tren, dan penanganan nilai pencilan (*outliers*) dalam data. Salah satu keunggulan Model Prophet adalah ketahanannya (*robustness*) yang baik terhadap nilai hilang (*missing values*) dan *outlier*, yang membuat model dapat beradaptasi terhadap pergeseran tren seiring waktu, sehingga proses pembersihan dan penyiapan data dapat dilakukan secara lebih efisien [15]. Model ini menyediakan prediksi yang lebih terinterpretasi karena dekomposisi hasil prediksi memerlukan *data frame* yang terdiri dari dua kolom: *ds* (untuk data tanggal/waktu) dan *y* (untuk nilai numerik yang menjadi target prediksi).

3. METODE PENELITIAN

Penelitian ini menggunakan metode kuantitatif dengan pendekatan analisis deret waktu (*time series analysis*). Pemilihan pendekatan ini didasarkan pada karakteristik data kunjungan pasien yang berurutan secara waktu dan dipengaruhi oleh pola tren, musiman, serta pengaruh hari libur, sehingga semua faktor tersebut perlu dimodelkan. Untuk menilai akurasi model, digunakan metrik kesalahan (*error*) seperti *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Scaled Error* (MASE). Ketiga metrik tersebut memberikan sudut pandang yang berbeda mengenai seberapa baik kualitas prediksi model. Hasil evaluasi ini berfungsi

sebagai dasar untuk menentukan tingkat keandalan model dalam memprediksi kedatangan pasien.



Gambar 1. Tahapan Penelitian

3.1. Pengumpulan Data

Pengumpulan data historis kunjungan pasien diperoleh melalui proses ekstraksi dari *database* Sistem Informasi Manajemen Rumah Sakit (SIMRS). *Dataset* yang dikumpulkan mencakup rentang waktu dari Juli 2023 hingga Desember 2025. Mengingat dinamika kunjungan rumah sakit di Indonesia sangat dipengaruhi oleh regulasi pemerintah dan pola aktivitas masyarakat, penelitian ini juga mengintegrasikan data kalender hari libur nasional serta cuti bersama sebagai variabel eksternal (*holiday effect*). Variabel ini bertujuan untuk mengoptimalkan kapabilitas model Facebook Prophet dalam mengidentifikasi anomali atau fluktuasi tren kunjungan pada periode tertentu [16], sehingga hasil prediksi menjadi lebih akurat dan representatif terhadap kondisi operasional riil di lapangan.

3.2. Praproses Data

Praproses data dilakukan untuk mentransformasi data mentah menjadi format yang siap diintegrasikan ke dalam pemodelan. Tahapan ini dimulai dengan:

1. Pemeriksaan kelengkapan data
2. Penanganan nilai hilang (*missing values*) atau data anomaly
3. Standardisasi struktur data (*ds* untuk kolom waktu dan *y* untuk volume kunjungan pasien).
4. Penyelarasan format tanggal dan agregasi data harian
5. Deteksi pencilon (*outliers*)

Melalui rangkaian praproses ini, integritas dan konsistensi data dapat terjamin, sehingga model mampu melakukan proses pembelajaran (*training*) secara optimal tanpa *noise* dari data yang tidak relevan.

3.3. Eksplorasi Data (EDA)

Eksplorasi data dilakukan untuk memahami karakteristik fundamental deret waktu kunjungan pasien melalui visualisasi tren jangka panjang untuk memahami apakah volume pasien cenderung mengalami kenaikan atau penurunan. Selain itu, dilakukan identifikasi terhadap pola musiman (*seasonality*) dalam siklus mingguan dan tahunan, guna mendeteksi periode-periode tertentu di mana lonjakan pasien secara konsisten terjadi. Tahapan ini juga mengkaji pengaruh hari libur nasional dan cuti bersama untuk memahami pengaruh variabel eksternal terhadap fluktuasi data yang tidak beraturan. Seluruh hasil dalam proses EDA ini menjadi fondasi utama dalam melakukan tala parameter (*parameter tuning*) pada model Facebook Prophet, seperti penentuan tingkat fleksibilitas tren (*changepoint prior scale*) dan penyesuaian intensitas musiman. Dengan demikian, konfigurasi awal model didasarkan pada observasi faktual perilaku data historis yang telah dianalisis.

3.4. Pembagian Data

Pembagian data dilakukan dengan membagi data latih (*training data*) dan data uji (*testing data*) dengan menggunakan metode *time-series split*. Pada penelitian ini, pengujian akan dilakukan menggunakan dua skenario rasio pembagian data, yaitu 80:20 dan 90:10, guna mengevaluasi stabilitas model Facebook Prophet terhadap perbedaan durasi pengujian.

Komparasi tersebut dilakukan untuk menentukan model yang paling representatif dalam menangkap pola musiman (*seasonality*) serta memberikan hasil proyeksi yang relevan bagi manajemen rumah sakit.

3.5. Pembangunan Model Prophet

Algoritma Facebook Prophet dikembangkan dengan mengintegrasikan komponen tren, pola musiman, serta *holiday effects* sebagai variabel eksternal untuk menangkap dinamika kunjungan pasien secara akurat. Proses pelatihan dilakukan menggunakan data latih, yang kemudian dilanjutkan dengan tahapan penyetelan (*tuning hyperparameter*) secara iteratif guna menentukan konfigurasi optimal yang dapat meminimalkan tingkat kesalahan (*error*) serta meningkatkan akurasi prediksi model terhadap data aktual.

3.6. Evaluasi Model

Evaluasi model dilakukan dengan membandingkan antara hasil prediksi dengan data aktual pada fase pengujian. Akurasi peramalan diukur menggunakan metrik *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Scaled Error* (MASE) sebagai indikator performa utama. Kriteria keberhasilan model menitikberatkan pada nilai MASE, di mana nilai $MASE < 1$ menunjukkan bahwa model memiliki performa yang lebih baik dibandingkan metode peramalan sederhana (*Naïve Forecast*). Sementara itu, MAE dan RMSE berfungsi sebagai instrumen pelengkap untuk menyajikan besaran kesalahan aktual dalam satuan jumlah pasien. Apabila performa model belum memenuhi kriteria fungsional tersebut, dilakukan proses tala ulang (*model tuning*) secara iteratif terhadap *hyperparameter* hingga diperoleh hasil peramalan yang optimal.

3.7. Interpretasi Hasil

Interpretasi hasil berfokus pada analisis mendalam terhadap *output* peramalan kunjungan pasien yang dihasilkan oleh konfigurasi model terbaik. Hasil proyeksi tersebut dievaluasi untuk mengidentifikasi pola mendasar serta tren masa depan yang kemudian diterjemahkan menjadi wawasan strategis bagi manajemen rumah sakit. Melalui interpretasi ini, temuan model ditransformasi menjadi rekomendasi operasional yang aplikatif guna

mendukung optimalisasi layanan kesehatan. Hal ini mencakup efisiensi perencanaan jadwal staf medis, mitigasi penumpukan antrean pasien, hingga alokasi sumber daya rumah sakit yang lebih terukur dan berbasis data [17].

4. HASIL DAN PEMBAHASAN

4.1. Hasil Penelitian

Hasil penelitian ini menyajikan implementasi model peramalan kunjungan pasien menggunakan algoritma Facebook Prophet yang tidak hanya menghasilkan angka proyeksi kedatangan pasien, tetapi juga memberikan visualisasi dekomposisi komponen (tren dan musiman) serta perhitungan ambang batas kesiagaan (*safety buffer*) yang dapat digunakan sebagai instrumen pengambilan keputusan strategis bagi manajemen fasilitas kesehatan dalam mengoptimalkan alokasi sumber daya di masa mendatang.


4.1.1. Pengumpulan Data

Variabel utama yang digunakan sebagai target prediksi adalah Jumlah Kunjungan Pasien. Berdasarkan analisis deskriptif, diperoleh hasil sebagai berikut:

- Jumlah data: 898 hari observasi (mencakup 2 siklus tahunan penuh).
- Nilai minimum kunjungan: 6,0 Pasien pada 19 Juli 2023.
- Nilai maksimum kunjungan: 822,0 Pasien pada 27 Mei 2024
- Rata-rata (*Mean*): 351,53 Pasien.
- Median (Q2): 421,00 Pasien.
- Rentang Antar Kuartil: 132,00 (Q1) hingga 521,75 (Q3) Pasien.
- Nilai IQR: 389,75 Pasien.

Observasi ini memberikan dasar yang kuat bagi model Prophet untuk memetakan pola musiman tahunan karena telah melampaui dua siklus penuh. Meski data sangat fluktuatif, distribusi data cenderung berkumpul pada angka tinggi dengan kemiringan negatif (*left-skewed*), sebagaimana ditunjukkan oleh nilai median 421,00 yang lebih besar dari rata-rata 351,53. Hal ini didukung oleh *Boxplot* pada Gambar 2 yang menunjukkan Rentang Antar Kuartil pada kisaran 132,00 (Q1) hingga 521,75 (Q3) dengan nilai *Interquartile Range* (IQR) sebesar 389,75. Karakteristik data yang

menunjukkan variabilitas fluktuasi disertai pola musiman berulang ini menjadi alasan utama pemilihan model Prophet yang dikenal tangguh (*robust*) dalam menghadapi ketidakteraturan tersebut.



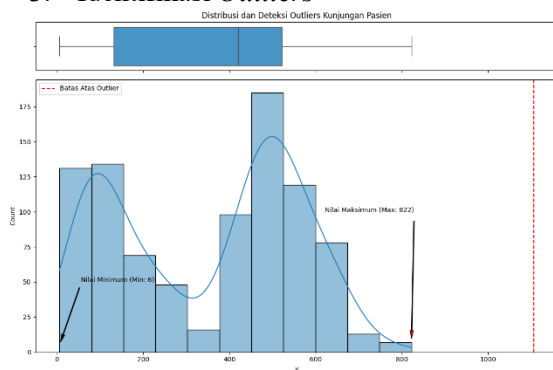
Gambar 2. Sebaran Data Kunjungan Pasien Harian

Gambar 2 menunjukkan garis median yang cenderung mendekati batas atas kotak. Hal ini mengonfirmasi bahwa rumah sakit lebih sering beroperasi pada kapasitas kunjungan yang tinggi, meskipun terdapat beberapa hari dengan kunjungan sangat rendah di awal periode.

4.1.2. Praproses Data

Tahap praproses data dilakukan untuk menjamin kualitas dan kesiapan data kunjungan pasien sebelum diolah oleh model Prophet. Proses ini bertujuan untuk memastikan data bebas dari kesalahan, memenuhi spesifikasi format *input* yang dipersyaratkan, serta memiliki struktur deret waktu yang berkesinambungan. Adapun tahapan praproses yang dilakukan adalah sebagai berikut:

1. Pemeriksaan Data
2. Seleksi Atribut
3. Identifikasi *Outliers*



Gambar 3. Visualisasi Distribusi dan Deteksi *Outliers* Kunjungan Pasien

Visualisasi pada Gambar 3 mengombinasikan *boxplot* dan histogram


dengan kurva *Kernel Density Estimation* (KDE) untuk memberikan gambaran menyeluruh mengenai karakteristik sebaran data. Puncak kepadatan pada *histogram* selaras dengan posisi *interquartile range* (IQR) pada *boxplot*, yang mengonfirmasi bahwa aktivitas operasional utama rumah sakit terpusat pada kisaran 132 hingga 521 pasien. Berdasarkan metode *Tukey's Fences* yang berbasis pada rentang *Interquartile Range* (IQR), batas atas statistik ditetapkan pada angka (1.106) dan batas bawah pada (-452). Merujuk pada ambang batas tersebut, nilai kunjungan minimum (6 pasien) dan maksimum (822 pasien) secara teknis masih berada dalam ambang batas yang dapat diterima dan tidak dikategorikan sebagai pencilan ekstrem. Posisi median yang mendekati kuartil ketiga (Q3) serta ekor histogram yang memanjang ke arah kiri menunjukkan bahwa distribusi data bersifat *left-skewed*. Kondisi ini membuktikan bahwa meskipun terdapat hari-hari dengan kunjungan rendah, tren harian rumah sakit didominasi oleh volume pasien yang tinggi.

Mempertahankan variabilitas data ini bertujuan agar algoritma Prophet dapat mempelajari pola musiman (*weekly and yearly seasonality*), sehingga mampu menghasilkan prediksi yang lebih akurat dan *robust* terhadap fluktuasi di masa depan.

4.1.3. Eksplorasi Data (EDA)

Data yang telah melalui tahap praproses selanjutnya dianalisis secara eksploratif untuk mengidentifikasi dinamika fluktuasi kunjungan yang terjadi sepanjang periode observasi. Analisis ini bertujuan untuk mengekstraksi komponen musiman (*seasonality*) serta tren jangka panjang guna memahami karakteristik ketergantungan antarwaktu (*temporal dependency*) pada data kunjungan pasien. Agar hasil prediksi tidak bias, konfigurasi model Prophet dibangun di atas observasi pola historis yang sistematis. Hal ini memastikan model hanya merespons variasi data yang memiliki keteraturan operasional dan mengabaikan distorsi data yang bersifat acak (*noise*).


1. Identifikasi Tren Jangka Panjang



Gambar 4. Visualisasi Tren Kunjungan Pasien Harian

Analisis dekomposisi pada Gambar 4 menunjukkan bahwa volume kunjungan pasien dipengaruhi oleh dua komponen utama, yaitu tren jangka panjang yang bergerak naik dari Agustus hingga Desember 2025, serta pola musiman mingguan yang fluktuatif namun berulang. Pemisahan kedua komponen ini memberikan landasan akurat bagi manajemen rumah sakit dalam melakukan perencanaan kapasitas dan alokasi sumber daya operasional.

2. Analisis Musiman Mingguan (*Weekly Seasonality*)



Gambar 5. Visualisasi Distribusi Kunjungan Pasien Berdasarkan Hari

Pola fluktuatif harian dijabarkan pada Gambar 5, yang secara spesifik didorong oleh dinamika operasional unit Rawat Jalan. Pada visualisasi tersebut, volume kunjungan mencapai puncaknya pada hari Senin dan mengalami penurunan signifikan setiap hari Minggu serta pada hari libur nasional. Sejumlah titik pencilan (*outliers*) yang berada jauh di bawah kotak utama (IQR) pada hari kerja menunjukkan adanya anomali kunjungan. Setelah dikonfirmasi dengan kalender nasional, titik-titik tersebut bertepatan dengan hari libur nasional dan cuti bersama. Kondisi ini diidentifikasi oleh model Prophet sebagai *holiday effects*, mengingat unit Rawat Jalan tidak beroperasi pada hari libur. Sementara itu, stabilitas layanan pada unit IGD dan Rawat Inap di tengah fluktuasi ekstrem Rawat Jalan

mengonfirmasi bahwa unit poliklinik merupakan faktor penentu utama dalam dinamika operasional rumah sakit selama periode observasi ini.

3. Analisis Korelasi Unit Layanan

Analisis ini dilakukan untuk memvalidasi unit mana yang memiliki pengaruh paling dominan terhadap fluktuasi total kunjungan pasien selama periode observasi.


Tabel 2. Korelasi Unit Terhadap Total Kunjungan

IGD	0.278828
Rawat Inap	0.698472
Rawat Jalan	0.982819
y	1.000000

Berdasarkan hasil perhitungan koefisien korelasi *Pearson* pada Tabel 2, ditemukan bahwa unit Rawat Jalan memiliki nilai korelasi sebesar 0,98 terhadap variabel target (y), yang menunjukkan hubungan linear positif yang sangat kuat. Meskipun korelasi IGD dan Rawat Inap lebih rendah, peran vital unit-unit ini tetap dipertimbangkan dalam konteks stabilitas layanan 24 jam, namun tidak dominan dalam mempengaruhi total kunjungan. Angka korelasi pada unit Rawat Jalan mengonfirmasi temuan visual pada analisis sebelumnya. Hal ini membuktikan bahwa faktor-faktor seperti hari libur nasional dan siklus mingguan yang menjadi karakteristik unit Rawat Jalan menjadi pendorong utama variabilitas data. Oleh karena itu, dominasi ini memberikan dasar yang kuat bagi model Prophet untuk memprioritaskan pola musiman mingguan (*weekly seasonality*) dalam menghasilkan prediksi yang akurat.


4. Dekomposisi Komponen Prophet

Tahap akhir analisis pola dilakukan melalui dekomposisi komponen untuk memisahkan data kunjungan pasien ke dalam beberapa elemen penyusun utama, yaitu: tren (*trend*), musiman mingguan (*weekly seasonality*), musiman tahunan (*yearly seasonality*), dan efek hari libur (*holidays*). Analisis ini bertujuan untuk memvalidasi apakah model mampu menangkap struktur dasar dari data historis secara akurat.




Gambar 6. Grafik Tren Jangka Panjang Kunjungan Pasien

Grafik pada Gambar 6 menunjukkan arah pergerakan tren utama setelah memisahkan efek musiman dan *noise* dari data mentah. Secara keseluruhan, Visualisasi ini membuktikan bahwa pertumbuhan jumlah pasien bukan sekadar fluktuasi acak, melainkan gambaran dari kondisi layanan rumah sakit yang kini telah mencapai fase pola kunjungan yang lebih stabil setelah periode pertumbuhan pesat sebelumnya.



Gambar 7. Analisis Pola Musiman Mingguan Kunjungan Pasien

Visualisasi pada Gambar 7 menunjukkan pola kunjungan berdasarkan hari dalam seminggu. Kesesuaian antara grafik komponen ini dengan analisis *boxplot* pada Gambar 5 menunjukkan bahwa model memiliki sensitivitas yang tinggi dalam menangkap ritme operasional unit Rawat Jalan.



Gambar 8. Pola Musiman Tahunan (*Yearly Seasonality*) Kunjungan Pasien


Hasil dekomposisi waktu pada Gambar 8 menunjukkan pola musiman tahunan (*yearly seasonality*) yang berulang setiap tahunnya. Model Prophet berhasil memisahkan penurunan tajam pada tanggal-tanggal tertentu yang diidentifikasi sebagai hari libur dan cuti nasional melalui fitur *holiday effects*. Dengan memisahkan efek ini, model dapat menjaga stabilitas estimasi tren dan musiman

agar tetap akurat tanpa terdistorsi oleh anomali kunjungan rendah pada hari libur.


Secara keseluruhan, dekomposisi ini menunjukkan bahwa variabilitas kunjungan pasien didominasi oleh siklus musiman mingguan dibandingkan tren jangka panjang. Keberhasilan model dalam memetakan setiap komponen secara terpisah membuktikan bahwa konfigurasi parameter yang dipilih telah selaras dengan karakteristik data aktual, sehingga hasil peramalan (*forecasting*) diharapkan memiliki tingkat bias yang minimal dan reliabilitas yang tinggi.

4.1.4. Pembagian Data

Pembagian *dataset* dilakukan menggunakan metode *sequential split* dengan menguji dua skenario, yaitu rasio 80:20 dan 90:10. Pendekatan kronologis ini dipilih guna menghindari *data leakage* (kebocoran data) serta memastikan model diuji kemampuannya dalam memprediksi data masa depan yang belum pernah dilihat sebelumnya. Data latih (*training set*) digunakan untuk melatih model dalam mengenali tren serta pola musiman, sedangkan data uji (*testing set*) digunakan untuk memvalidasi akurasi prediksi. Melalui pengujian kedua skenario tersebut, dilakukan perbandingan performa model guna menentukan rasio pembagian data yang paling optimal dalam menghasilkan tingkat kesalahan (*error*) terkecil sebelum dilanjutkan ke tahap peramalan.



Gambar 9. Visualisasi Pembagian Data Latih dan Data Uji 80:20



Gambar 10. Visualisasi Pembagian Data Latih dan Data Uji 90:10

Pendekatan *sequential split* ini memisahkan data latih (berwarna biru) dan data uji (berwarna oranye) berdasarkan titik waktu tertentu untuk mensimulasikan kemampuan prediksi model pada data masa mendatang. Perbedaan titik antara kedua skenario ini menjadi faktor krusial dalam tahap evaluasi. Skenario 80:20 memberikan ruang validasi yang lebih komprehensif, sementara skenario 90:10 lebih berfokus pada ketajaman prediksi jangka pendek di akhir *dataset*. Perbandingan visual ini mendasari analisis performa metrik guna menentukan rasio pembagian data yang paling stabil dalam memitigasi risiko kesalahan prediksi.

4.1.5. Pembangunan Model Prophet

Setelah karakteristik data dipahami melalui analisis eksploratif, langkah selanjutnya adalah membangun model prediktif menggunakan algoritma Prophet. Pada tahap ini, pembangunan model dilakukan secara komparatif dengan menerapkan konfigurasi model yang sama pada dua skenario pembagian data, yaitu rasio 80:20 dan 90:10 untuk mengevaluasi stabilitas parameter model terhadap perbedaan durasi data latih dan data uji. Melalui kombinasi parameter yang terspesialisasi tersebut, model Prophet dilatih pada masing-masing skenario untuk membangun pemahaman yang komprehensif terhadap variabel target. Hasil dari tahap implementasi kedua skenario ini menjadi dasar bagi proses perbandingan performa dan pemilihan model *final* pada peramalan kunjungan pasien yang akan dibahas pada bagian selanjutnya.

4.1.6. Evaluasi Model

Tahap evaluasi dilakukan untuk mengukur sejauh mana model Prophet mampu menghasilkan prediksi yang mendekati realitas pada data uji (*testing set*). Pengujian ini krusial untuk memastikan bahwa model tidak hanya menangkap pola historis, tetapi juga memiliki kemampuan generalisasi yang baik terhadap data baru. Tujuannya adalah mengidentifikasi tingkat kesalahan (*error*) yang mungkin muncul, guna menjamin bahwa hasil peramalan tetap berada dalam batas toleransi yang dapat diterima untuk pengambilan keputusan manajerial.


Tahap awal analisis dimulai dengan pengujian komparatif antara skenario 80:20

dan 90:10. Evaluasi performa model yang diukur melalui metrik akurasi *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE) dan *Mean Absolute Scaled Error* (MASE) menunjukkan performa sebagai berikut:

Tabel 1. Perbandingan Performa Model Berdasarkan Rasio Data

Metrik Evaluasi	Skenario 80:20	Skenario 90:10	Selisih
MAE	71.83 Pasien	124.97 Pasien	53.14 Pasien
RMSE	88.48 Pasien	147.12 Pasien	58.64 Pasien
MASE	0.4844	0.8295	0.3451

Berdasarkan Tabel 2, terlihat secara signifikan bahwa skenario pembagian data 80:20 menunjukkan efektivitas yang lebih optimal di seluruh metrik evaluasi jika dibandingkan dengan rasio 90:10. Hasil ini mengindikasikan bahwa proporsi data uji pada rasio 80:20 memberikan cakupan pengujian yang lebih memadai bagi model untuk menunjukkan kemampuan generalisasi terhadap berbagai fluktuasi tren jangka panjang. Meskipun rasio 90:10 memberikan porsi data latih yang lebih besar, hal tersebut justru menyebabkan model mengalami *overfitting* (model menjadi terlalu sensitif terhadap fluktuasi jangka pendek) di akhir periode. Dengan demikian, skenario 80:20 ditetapkan sebagai model final dalam penelitian ini karena terbukti lebih tangguh (*robust*) dan memiliki kemampuan generalisasi yang lebih stabil dalam memprediksi kunjungan pasien pada berbagai rentang waktu.



Gambar 11. Visualisasi Evaluasi Prediksi vs Aktual (Skenario 80:20)

Secara keseluruhan, akurasi visual pada skenario 80:20 membuktikan ketajaman

model dalam menangkap pola data historis dan dinamika kunjungan pasien. Konsistensi data aktual yang tetap berada dalam *uncertainty interval* memberikan justifikasi kuat atas keandalan model untuk digunakan sebagai instrumen proyeksi kunjungan di periode mendatang.

Untuk menguji ketahanan akurasi model terhadap perubahan waktu, dilakukan pengujian *Time Series Cross-Validation* dengan teknik *rolling window*. Pengujian ini memungkinkan evaluasi yang lebih dinamis melalui simulasi performa model untuk memprediksi kunjungan pasien dalam rentang 1 hingga 7 hari ke depan. Hal ini guna memastikan model memiliki performa yang stabil dan tidak hanya unggul pada satu periode waktu tertentu.

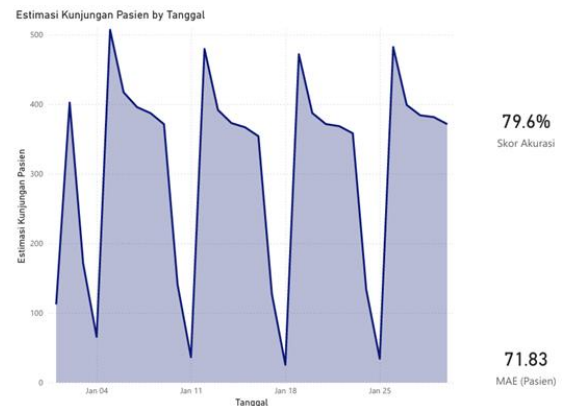
Tabel 2. Performa *Cross-Validation* 80:20

Horizon	MAE	RMSE	MASE
1 days	16.95	21.04	0.11
2 days	235.90	316.17	1.59
3 days	278.82	324.50	1.88
4 days	177.66	219.96	1.20
5 days	176.90	216.74	1.19
6 days	146.73	197.31	0.99
7 days	53.37	53.39	0.36

Hasil pengujian berdasarkan Tabel 3 menunjukkan bahwa model memiliki akurasi sangat tinggi pada prediksi jangka pendek (1 hari) dan siklus mingguan (7 hari), dengan nilai MASE masing-masing sebesar 0,11 dan 0,36. Meskipun terdapat fluktuasi *error* pada hari ke-2 hingga ke-5, performa model secara keseluruhan tetap reliabel untuk digunakan sebagai dasar penentuan manajemen dalam mitigasi risiko operasional rumah sakit.


4.1.7. Interpretasi Hasil

Berdasarkan model terbaik dari skenario 80:20, dilakukan proyeksi kunjungan pasien untuk periode Januari 2026.



Gambar 12. Visualisasi Estimasi Kunjungan Pasien by Tanggal

Visualisasi estimasi ini menunjukkan pola fluktuasi kunjungan pasien yang sangat fluktuatif namun membentuk siklus mingguan yang konsisten, di mana lonjakan tertinggi selalu terjadi setiap awal minggu (hari Senin) dan titik terendah pada akhir pekan. Meskipun data memiliki fluktuasi yang tajam, model Facebook Prophet terbukti sangat adaptif dalam mengenali lonjakan rutin sebagai pola musiman (*weekly seasonality*), bukan sebagai anomali acak. Hal ini dibuktikan dengan skor akurasi sebesar 79,6% dan rata-rata kesalahan (MAE) yang terukur sebesar 71,83 pasien, sehingga hasil peramalan ini dapat berfungsi sebagai pendukung keputusan (*decision support tool*) yang reliabel bagi pihak manajemen rumah sakit. Dengan mengetahui estimasi kunjungan pasien di masa mendatang, pihak operasional dan manajemen dapat melakukan perencanaan sumber daya manusia (SDM), alokasi logistik medis, dan pengaturan fasilitas secara terencana dan berbasis data.



Gambar 13. Proyeksi Estimasi Kedatangan Pasien Bulan Januari 2026

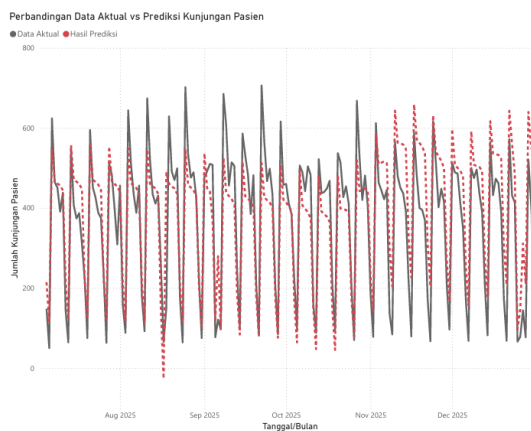
Visualisasi ini berfungsi sebagai *Early Warning System* melalui penetapan Rentang Kesiagaan (± 72 Pasien). Dengan akurasi model sebesar 79,6%, grafik ini

meminimalkan ketidakpastian operasional dengan memberikan dasar bagi manajemen untuk mengoptimalkan jumlah perawat, stok obat-obatan di farmasi, hingga jumlah petugas di bagian pendaftaran, sehingga menciptakan ekosistem layanan yang efisien.

Tabel 3. Perbandingan Rencana Operasional Estimasi dan Kunjungan Aktual Januari 2026

Rentang Tanggal	Estimasi Rata-Rata (Pasien/Hari)	Kapasitas Siaga (Inklusi MAE ±72)	Rata-rata Aktual (Pasien/Hari)
01 – 07 Jan 2026	296	368	346
08 – 14 Jan 2026	311	383	381
15 – 21 Jan 2026	301	372	311
22 – 28 Jan 2026	308	380	339
29 – 31 Jan 2026	376	448	326
01 – 07 Jan 2026	296	368	346

Tabel 4 menyajikan perbandingan antara estimasi rata-rata kunjungan mingguan dengan kunjungan aktual pada bulan Januari 2026 guna mengevaluasi efektivitas Kapasitas Siaga. Dengan menetapkan Kapasitas Siaga (Inklusi MAE ±72), periode operasional dari minggu ke-1 hingga ke-5 berada dalam rentang aman operasional, di mana kapasitas yang disediakan mampu mengakomodasi volume kunjungan aktual. Hal ini membuktikan bahwa integrasi nilai *error* model ke dalam perencanaan kapasitas dapat menjamin ketersediaan layanan rumah sakit tetap terjaga meskipun terdapat fluktuasi kedatangan pasien.



Gambar 14. Perbandingan Data Aktual vs Data Prediksi Kunjungan Pasien

Berdasarkan visualisasi pada Gambar 14, dilakukan analisis komparatif antara Data Aktual (garis abu-abu) dan Hasil Prediksi (garis merah putus-putus) untuk periode Agustus hingga Desember 2025. Keselarasan antara kedua garis ini memberikan kepastian bagi pihak manajemen bahwa model dapat memahami ritme kunjungan pasien. Selisih residual antara kedua garis tersebut dikuantifikasi melalui metrik MAE, yang berfungsi sebagai parameter cadangan (*buffer*) dalam perencanaan sumber daya.

4.2. Pembahasan

Model Prophet terbukti memiliki efektivitas yang sangat baik dalam memproyeksikan kunjungan pasien di rumah sakit dengan capaian akurasi sebesar 79,6% dan nilai MASE keseluruhan sebesar 0,48. Tingginya performa ini berasal dari mekanisme internal Prophet yang memisahkan komponen tren jangka panjang dan pola musiman (*seasonality*) secara independen. Ketangguhan model ini semakin teruji melalui hasil *Cross-Validation*. Meskipun model menghadapi variabilitas harian yang tinggi, Prophet tetap mampu mempertahankan konsistensi estimasi pada tren utama meskipun dihadapkan pada gangguan (*noise*) harian.

Penerapan nilai *Mean Absolute Error* (MAE) sebesar ±72 pasien sebagai instrumen untuk menentukan ‘Kapasitas Siaga’ memberikan nilai strategis bagi manajemen operasional rumah sakit. Dengan mengintegrasikan MAE ke dalam rencana estimasi, pihak manajemen memiliki ‘batas aman’ (*safety buffer*) yang objektif untuk mengalokasikan Sumber Daya Manusia (SDM) dan fasilitas, sehingga risiko kekurangan kapasitas (*under-capacity*) dapat diminimalisir secara signifikan. Hasil skor MASE pada Tabel 3 mengonfirmasi kemampuan model dalam memetakan siklus mingguan, hasil ini memberikan bukti statistik bahwa titik puncak kunjungan rutin terjadi pada awal pekan. Meskipun model menunjukkan performa reliabilitas yang tinggi dalam menangkap pola rutin dan musiman, penelitian ini tetap memiliki batasan operasional terhadap lonjakan ekstrem yang bersifat anomali. Anomali tersebut tetap menjadi tantangan yang memerlukan mekanisme penanganan darurat (*emergency response*) di luar prediksi rutin, mengingat

dinamika data kesehatan yang terkadang dipengaruhi oleh faktor-faktor stokastik seperti kejadian luar biasa atau faktor eksternal lainnya yang tidak terekam dalam data historis.

5. KESIMPULAN

Berdasarkan hasil analisis, pengembangan, dan pengujian model prediksi kunjungan pasien menggunakan algoritma Facebook Prophet dengan data historis harian, diperoleh kesimpulan sebagai berikut:

1. Model Facebook Prophet menunjukkan performa yang sangat andal dalam memprediksi kedatangan pasien setelah melalui tahapan eksperimen pada skenario pembagian data, di mana skenario rasio 80:20 terpilih sebagai model terbaik dengan tingkat generalisasi paling stabil. Berdasarkan metrik evaluasi yang ditetapkan, model menghasilkan nilai *Mean Absolute Scaled Error* (MASE) sebesar 0,48. Secara teknis, model menunjukkan rata-rata selisih prediksi (MAE) sebesar 71,83 pasien dengan skor akurasi mencapai 79,6% dan RMSE sebesar 88,48 pasien. Keunggulan utama model ini terletak pada stabilitasnya, meskipun terdapat fluktuasi harian, saat diuji pada data riil periode Januari 2026, hasil prediksi tetap berada dalam koridor prediksi yang akurat.
2. Hasil peramalan ini mengoptimalkan alokasi sumber daya melalui penetapan Kapasitas Siaga berbasis Rentang Kesiagaan (± 72 Pasien). Implementasi ini memberikan landasan bagi manajemen rumah sakit dalam mengambil keputusan operasional, yaitu: Status Siaga Tinggi yang diaktifkan saat prediksi mendekati ambang batas kapasitas untuk memitigasi lonjakan (puncak kritis). Kemudian Status Efisiensi diaktifkan pada periode kunjungan rendah (*low season*) untuk optimalisasi pemeliharaan fasilitas dan penghematan biaya operasional (*idle resources*).
3. Melalui visualisasi komponen dekomposisi, Facebook Prophet secara efektif membedakan pola kedatangan pasien dan mengidentifikasi bahwa musiman mingguan (*weekly seasonality*) merupakan faktor pengaruh paling signifikan terhadap fluktuasi kunjungan. Lonjakan tertinggi teridentifikasi secara

konsisten terjadi pada awal minggu (hari Senin dan Selasa). Kemampuan Facebook Prophet dalam memisahkan tren pertumbuhan jangka panjang, fluktuasi mingguan, serta dampak akhir pekan dan hari libur nasional (*holiday effects*) memungkinkan manajemen melakukan penyesuaian kapasitas secara antisipatif sebelum fluktuasi pasien terjadi.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Universitas Singaperbangsa Karawang, khususnya Fakultas Ilmu Komputer jurusan Sistem Informasi, serta Ibu Hannie dan Bapak Azhari Ali atas bimbingan dan arahnya selama proses penelitian dan penyusunan jurnal ini.

Terima kasih kepada PT. Astech dan pihak manajemen Rumah Sakit Swasta di Sukabumi yang telah memfasilitasi dan mendukung kelancaran penelitian ini. Terima kasih juga kepada keluarga dan teman-teman yang selalu memberikan dukungan dan motivasinya sehingga penelitian dan jurnal ini dapat terselesaikan dengan baik.

DAFTAR PUSTAKA

- [1] W. D. Astuti, L. J. Jaya, and R. Wasir, "Strategi dan tantangan SDM kesehatan di masa depan: Menghadapi perubahan global dan lokal," *Indones. J. Heal. Sci.*, vol. 4, no. 6s, pp. 822–830, 2024, doi: 10.54957/ijhs.v4i6s.1217.
- [2] R. S. H. Sadikin, "Reviu Pertama Rencana Strategis Bisnis 2025-2029," 2025, [Online]. Available: https://web.rshs.go.id/public_html/wp-content/uploads/2025/12/RSB-2025-2029-Reviu-1-Fix.pdf
- [3] D. A. Ginting, D. Ekawati, and A. Wahyudi, "Analisis Kepuasan Pasien Terhadap Pelayanan Rawat Jalan," 2024. doi: 10.36729/bi.v16i2.1282.
- [4] M. N. Khasanah and Y. P. Astuti, "ANALISIS SISTEM ANTRIAN PADA OPTIMALISASI PELAYANAN PASIEN DI PUSAT KESEHATAN MASYARAKAT," *J. Ilm. Mat.*, vol. 11, no. 2, pp. 198–199, 2022, [Online]. Available: <https://ejournal.unesa.ac.id/index.php/mathunesa/article/view/64649>
- [5] Rahmawati.E.N and Laras.M.A, "PREDIKSI KUNJUNGAN PASIEN RAWAT JALAN DI RSAU dr. SISWANTO LANUD ADI SOEMARMO KARANGANYAR TAHUN

- 2022-2026,” *INFOKES J. Ilm. Rekam Medis dan Inform. Kesehat.*, vol. 13, no. 1, pp. 52–63, 2023.
- [6] R. Ichsan and A. D. Alfiandari, “Keterkaitan Antara Pengalaman Pasien, Kepuasan Pasien, Dan Loyalitas Pasien: Perspektif Manajemen Layanan Kesehatan,” *Indones. J. Bus. Manag.*, vol. 7, no. 2, pp. 340–344, 2025, doi: 10.35965/jbm.v7i2.5952.
- [7] I. Biantara and Dety Mulyanti, “Strategi Manajemen Informasi Layanan Kesehatan Di Rumah Sakit,” *MANABIS J. Manaj. dan Bisnis*, vol. 2, no. 1, pp. 10–18, 2023, doi: 10.54259/manabis.v2i1.1544.
- [8] H. Hassyddiqy and H. Hasdiana, “Analisis Peramalan (Forecasting) Penjualan Dengan Metode ARIMA (Autoregressive Integrated Moving Average) Pada Huebee Indonesia,” *Data Sci. Indones.*, vol. 2, no. 2, pp. 92–100, 2023, doi: 10.47709/dsi.v2i2.2022.
- [9] Rianti Rahayu, “Penerapan Forecasting Dalam Jumlah Kasus Penyakit Malaria Menggunakan Metode Exponential Smoothing,” *J. Inform. dan Teknol. Inf.*, vol. 1, no. 2, pp. 98–103, 2022, doi: 10.56854/jt.v1i2.79.
- [10] S. Yunita, N. A. Mahesti, R. M. B. Sihaloho, and R. Setyadi, “Forecasting Pada Rantai Pasok Pabrik Penggilingan Daging Menggunakan Metode Time Series,” *JURIKOM (Jurnal Ris. Komputer)*, vol. 9, no. 3, p. 761, 2022, doi: 10.30865/jurikom.v9i3.4221.
- [11] Dzaki and A. Athifah, “Implementasi Business Intelligence Berbasis Dashboard Untuk Forecasting dan Classification Diagnosis Pasien Berdasarkan ICD-10 pada RSUD dr. Adnaan WD Payakumbuh,” 2025.
- [12] B. H. Winarno and D. K. H. A. Triyanto, “Penerapan Machine Learning (Model Prophet) Dalam Prediksi Permintaan Produk Untuk Mengoptimalkan Inventori,” *Pros. Snast*, no. November, pp. H168-174, 2024, doi: 10.34151/prosidingsnast.v1i1.5062.
- [13] G. Battineni, N. Chintalapudi, and F. Amenta, “Forecasting of COVID-19 epidemic size in four high hitting nations (USA, Brazil, India and Russia) by Fb-Prophet machine learning model,” *Appl. Comput. Informatics*, vol. 21, no. 1–2, pp. 2–11, 2025, doi: 10.1108/ACI-09-2020-0059.
- [14] 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.
- [15] T. Feng *et al.*, “The comparative analysis of SARIMA, Facebook Prophet, and LSTM for road traffic injury prediction in Northeast China,” *Front. Public Heal.*, vol. 10, 2022, doi: 10.3389/fpubh.2022.946563.
- [16] K. Hidayat, W. Witanti, E. Ramadhan, F. Sains Dan Informatika, and U. Jenderal Achmad Yani, “Analisis Tren dan Prediksi Penjualan Restoran Menggunakan Model Time Series Prophet,” *Metik J.*, vol. 9, no. 2, pp. 457–467, 2025, doi: 10.47002/metik.v9i2.1101.
- [17] I. Nurhakim, A. Voutama, U. S. Karawang, and T. Timur, “Dengan Visualisasi Data Interaktif Di Power BI,” *JITET (Jurnal Inform. dan Tek. Elektro Ter.)*, vol. 13, no. 2, pp. 904–912, 2025, [Online]. Available: <https://journal.eng.unila.ac.id/index.php/jitet/article/view/6355>