

PENERAPAN METODE *FACEBOOK PROPHET* UNTUK MERAMALKAN JUMLAH PENUMPANG TRANS METRO BANDUNG KORIDOR 1

Farhan Bagus Prakoso^{1*}, Gungum Darmawan², Achmad Bachrudin³

^{1,2,3}Universitas Padjadjaran

Corresponding Author's e-mail : farhanbp27@gmail.com^{1*}

ARMADA
JURNAL PENELITIAN MULTIDISIPLIN

e-ISSN: 2964-2981

ARMADA : Jurnal Penelitian Multidisiplin

<https://ejournal.45mataram.ac.id/index.php/armada>

Vol. 1, No. 3 March 2023

Page: 133-147

DOI:

<https://doi.org/10.55681/armada.v1i3.416>

Article History:

Received: March, 14 2023

Revised: March, 15 2023

Accepted: March, 21 2023

Abstract : *Trans Metro Bandung (TMB) is one of the most popular public transportation options in Bandung, this is because the price is relatively cheap and the route coverage is wide. In April 2020 the number of TMB corridor 1 passengers decreased significantly due to the COVID-19 pandemic. In addition, the factor of stopping Damri's operations and the factor of holidays are factors that cause fluctuations in the number of TMB passengers. Therefore we need a model that can accommodate the influence of these factors to predict the number of TMB passengers. The Facebook Prophet model is one of the popular forecasting models that has a high degree of accuracy and flexibility. Therefore, forecasting the number of monthly passengers of Trans Metro Bandung corridor 1 in this study uses the Facebook Prophet model. In this study, the Facebook Prophet model produces very good forecasting accuracy with MAPE testing of 4.62% with a coverage of 0.89. The results of forecasting the number of TMB passengers for the next six months have fluctuating results. The lowest value occurred in January 2023 and the highest in August 2022*

Keywords : *Facebook Prophet, Forecasting, Trans Metro Bandung*

Abstrak : *Trans Metro Bandung (TMB) menjadi salah satu pilihan transportasi umum yang cukup populer di Bandung raya, hal ini dikarenakan harganya yang relatif murah dan cakupan rute yang luas. Pada bulan April 2020 jumlah penumpang TMB koridor 1 mengalami penurunan yang signifikan akibat pandemi COVID-19. Selain itu, faktor pemberhentian operasional Damri dan faktor hari libur menjadi faktor penyebab fluktuasi jumlah penumpang TMB. Oleh karena itu diperlukan sebuah model yang dapat mengakomodir pengaruh faktor tersebut untuk meramalkan jumlah penumpang TMB. Model Facebook Prophet menjadi salah satu model peramalan populer yang memiliki tingkat akurasi dan fleksibilitas yang tinggi. Oleh karena itu, peramalan jumlah penumpang bulanan Trans Metro Bandung koridor 1 pada penelitian ini menggunakan model Facebook Prophet. Dalam penelitian ini, model Facebook Prophet menghasilkan akurasi peramalan yang sangat baik dengan MAPE testing sebesar 4,62% dengan coverage sebesar 0,89. Hasil peramalan jumlah penumpang TMB untuk enam bulan ke depan memiliki hasil yang berfluktuasi. Nilai terendah terjadi pada bulan Januari 2023 dan tertinggi pada bulan Agustus 2022.*

Kata Kunci : Facebook Prophet, Peramalan, Trans Metro Bandung


PENDAHULUAN

Trans Metro Bandung (TMB) merupakan salah satu bentuk *Bus Rapid Transit* (BRT) di Kota Bandung yang dioperasikan oleh Badan Layanan Umum Daerah Unit Pelaksana Tugas Angkutan (BLUD UPT Angkutan) Dinas Perhubungan Kota Bandung. Trans Metro Bandung (TMB) menjadi salah satu transportasi umum favorit di Kota Bandung, dikarenakan harganya yang relatif murah jika dibandingkan dengan transportasi umum lainnya dan cakupan rute yang sangat luas.

Sejak adanya pandemi COVID-19 di bulan April 2020, jumlah penumpang Trans Metro Bandung (TMB) mengalami penurunan yang signifikan, hal ini dikarenakan adanya kebijakan pemerintah dalam mengatasi penyebaran virus COVID-19. Salah satu kebijakan pemerintah yang mempengaruhi jumlah penumpang Trans Metro Bandung adalah pembatasan jumlah penumpang maksimum pada kendaraan, hal ini tertuang dalam Surat Edaran Menteri Perhubungan Nomor 11 Tahun 2020 hingga Surat Edaran Menteri Perhubungan Nomor 85 Tahun 2022. Pembatasan jumlah penumpang maksimal saat pandemi COVID-19 merupakan salah satu gambaran kondisi masyarakat saat itu.

Minimnya *load factor* sejak pandemi COVID-19 membuat operator transportasi umum mendapatkan kerugian dalam operasional, salah satunya terjadi pada Perum Damri. Sejak 28 Oktober 2021, Perum Damri Bandung memberhentikan sementara operasional 8 koridor bus kota di Kota Bandung, dua koridor diantaranya memiliki kesamaan rute dengan Trans Metro Bandung (TMB) yakni, Cibiru – Cibeureum dan Cicaheum – Cibeureum. Pemberhentian operasi Damri ini memberikan dampak peningkatan jumlah penumpang pada kedua rute Trans Metro Bandung tersebut seperti pada Gambar 1

Gambar 1. Plot Data



Pada bidang transportasi, hari besar keagamaan dan hari libur nasional memiliki pengaruh cukup besar terhadap jumlah penumpang. Efek dari hari libur ini dapat berulang dalam kurun waktu tertentu dan sering disebut sebagai efek musiman (*seasonal*). Salah satu hari libur yang memiliki pengaruh cukup besar terhadap jumlah penumpang TMB adalah hari raya Idul Fitri, hal ini dapat terlihat pada Gambar 1, dimana pada bulan Mei terjadi penurunan penumpang.

Saat ini, Trans Metro Bandung (TMB) dioperasikan oleh BLUD UPT Angkutan Dinas Perhubungan Kota Bandung, dimana menurut Andreti A.M. (2021) Badan Layanan Umum Daerah (BLUD) harus dapat membiayai operasionalnya secara mandiri, sehingga dibutuhkan layanan yang efektif dan efisien. *Over capacity* dalam layanan Trans Metro Bandung akan mengakibatkan penumpang beralih ke moda transportasi lainnya sehingga BLUD UPT Angkutan akan kehilangan potensi pendapatan dari penumpang yang tidak tertampung. Di sisi lain, *under capacity* akan membuat BLUD UPT Angkutan mengalami kerugian dalam biaya operasional.

Hasil peramalan data jumlah penumpang Trans Metro Bandung akibat adanya faktor pandemi COVID-19, pemberhentian DAMRI, dan efek hari libur dapat diambil sebagai data referensi dalam mengambil kebijakan pengaktifan serta pengefisienan layanan Trans Metro Bandung di masa yang akan datang.

Data jumlah penumpang Trans Metro Bandung termasuk dalam jenis data deret waktu. Berdasarkan Gambar 1, jumlah penumpang Trans Metro Bandung mengalami perubahan arah tren serta perubahan struktur data akibat faktor *eksternal*, oleh karena itu model peramalan yang umum digunakan seperti *Autoregressive Integrated Moving Average* (ARIMA) tidak dapat digunakan, hal ini dikarenakan ARIMA mengasumsikan bahwa kondisi lingkungan akan tetap sama (Montgomery *et al.*, 2015) sehingga ARIMA tidak dapat menjelaskan perubahan struktur data dan perubahan arah tren. Model *Facebook Prophet* menjadi salah satu model peramalan populer yang dapat menggambarkan perubahan arah tren serta perubahan struktur data. *Facebook Prophet model* merupakan hasil pengembangan dari Facebook's Core Data Science Team sebagai salah satu model peramalan yang memiliki desain dapat menangani berbagai fitur dalam *business time series* seperti *multiple strong seasonality, trend changes, outliers, and holidays effect*. (S. J. Taylor & Letham, 2018). Dalam model *Prophet*, data deret waktu didekomposisi menjadi 3 bagian utama yakni *trend, seasonal dan holidays* (S. J. Taylor & Letham, 2018). Model ini sangat baik digunakan jika data *time series* memiliki efek musiman yang kuat dan memiliki beberapa data historis, namun model *prophet* pun masih dapat meramalkan dengan baik data yang tidak memiliki efek *seasonal* (Satrio, *et al.*, 2021). Model ini termasuk kedalam *semi-automatic forecast*, dimana dalam model ini terdapat pembagian tugas antara manusia dan *automated tasks*. Peramalan dengan menggunakan model *Facebook Prophet* telah banyak dilakukan, seperti peramalan jumlah penumpang kereta api (Pontoh, *et al.*, 2021), temperatur udara (Toharudin, *et al.*, 2021), dan pendaftaran mahasiswa baru (Chandra dan Budi, 2020). Oleh karena itu, model *Facebook Prophet* akan digunakan dalam melakukan peramalan terhadap jumlah Penumpang Trans Metro Bandung Koridor 1 yang dipengaruhi oleh faktor pandemi COVID-19, pemberhentian DAMRI, dan efek hari libur.

Tujuan yang ingin dicapai dalam penelitian ini adalah memperoleh model peramalan jumlah penumpang Trans Metro Bandung Koridor 1 dengan menggunakan model *Facebook Prophet* serta mendapatkan hasil peramalan selama enam bulan kedepan. Hasil peramalan ini diharapkan dapat dijadikan referensi dalam menyusun kebijakan layanan Trans Metro Bandung diwaktu yang akan datang.

METODE PENELITIAN

Data Penelitian

Dalam penelitian ini digunakan data sekunder yang diperoleh dari BLUD UPT Angkutan Dinas Perhubungan Kota Bandung, website resmi Open Data Kota Bandung, dan website resmi Kementerian Perhubungan Republik Indonesia. Variabel respon yang digunakan dalam penelitian ini adalah jumlah penumpang bulanan Trans Metro Bandung koridor 1 Cibiru – Cibeureum sejak bulan Januari 2018 hingga bulan Juli 2022, dengan extra regressor berupa jumlah penumpang DAMRI jurusan Elang – Cibiru sejak bulan Januari tahun 2018 hingga bulan Desember 2021, dan jumlah penumpang maksimal dalam penanganan COVID-19 berdasarkan SE Menteri Perhubungan dimana angka 1 menggambarkan kapasitas jumlah penumpang maksimal sebesar 100%, angka 0,7 menggambarkan kapasitas jumlah penumpang sebesar 70% dan angka 0,5 menggambarkan kapasitas jumlah penumpang sebesar 50%

Pembentukan Model Facebook Prophet

Metode peramalan pada penelitian ini akan menggunakan model *Prophet*. Model *Prophet* mengadopsi *generalize additive model (GAM)* untuk menyesuaikan dengan *smoothing and forecasting functions* (Zhao, *et al.*, 2018). Dalam model *Prophet*, data deret waktu didekomposisi menjadi 3 bagian utama yakni *trend, seasonal dan holidays* (S. J. Taylor & Letham, 2018). Maka persamaan model *Prophet* menjadi sebagai berikut :

$$Y(t) = g(t) + s(t) + h(t) + \varepsilon_t \quad (1)$$

Dimana,

$g(t)$ = *Trend / Growth function*

$s(t)$ = *Seasonality function*

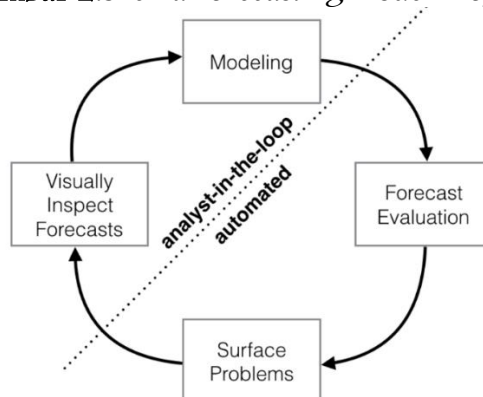
$h(t)$ = *Holiday function*

ε_t = *error*

Model *prophet* menganggap peramalan data deret waktu sebagai curve-fitting exercise dan tidak mempertimbangkan struktur ketergantungan temporal dalam data yang mendasarinya (Malefors, et al., 2020). Model *prophet* memiliki keunggulan dibandingkan dengan model lain, yakni dapat mengakomodasi *multiple period seasonality* (Kumar dan Susan, 2020). Keunggulan lain dari model ini adalah mampu menangani segala jenis trend dan dapat mengatur *degree of smoothness* (Almmal, et al., 2021). Model *prophet* menghasilkan hasil yang baik meskipun terdapat *missing values*, *longer trend*, dan *large outliers* pada dataset (Sunagar, et al., 2020). Model *prophet* dianggap lebih fleksibel dari pada model AR(F)IMA (Papacharalampous & Hristos, 2020).

Algoritma model *Prophet* termasuk kedalam *semi-automatic forecast*, dimana dalam model ini terdapat pembagian tugas antara manusia dan otomatisasi. Pembagian tugas dalam model ini dijelaskan oleh Gambar 2.

Gambar 2. Skema Forecasting model *Prophet*



Sumber : { S. J. Taylor & Letham, 2018)

Pada model *prophet*, proses peramalan diawali dengan proses visualisasi data sebagai salah satu gambaran dalam pembentukan model. Proses kedua merupakan pembentukan model dengan melakukan proses *tunning* terhadap parameter *trend*, *seasonal*, *holiday*, dan komponen lainnya. Selanjutnya adalah melakukan evaluasi model peramalan. Jika hasil *Mean Absolute Percentage Error (MAPE)* > 10 % atau model dirasa belum optimum maka proses dapat diulang dari proses *tuning* parameter, jika hasil MAPE < 10% maka proses dapat dilanjutkan ke tahap peramalan. Proses terakhir adalah *surface problems*, ketika terdapat permasalahan yang membutuhkan keterlibatan peneliti, maka peneliti dapat menganalisis hasil peramalan dan tanpa ragu mengubah model (Pontoh, et al., 2021).

1. *Trend*

Dalam *Prophet* Model, terdapat 4 opsi dalam melakukan proses *tuning parameter trend/growth*, yakni dengan:

a. *Non-linear Saturating Growth*

Pada model *Prophet*, komponen *growth* bertujuan untuk mengetahui bagaimana populasi berkembang. Facebook membuat komponen *growth* semirip mungkin dengan ekosistem alami. *Growth* biasanya dimodelkan dengan menggunakan *logistic growth model* dengan bentuk paling dasar sebagai berikut:

$$g(t) = \frac{C}{1 + \exp(-k(t - m))} \quad (2)$$

Dimana,

C = Carrying capacity

k = Growth rate

m = Offset parameter

Terdapat 2 permasalahan dalam penggunaan *logistic growth model*, yakni *carrying capacity* dan *growth rate* tidak konstan. Sehingga *carrying capacity* dapat diubah menjadi *time-varying capacity* ($C(t)$), dan mendefinisikan vector dari *rate adjustment* menjadi $\delta \in \mathbb{R}^s$, dan vector $a(t) \in \{0,1\}^s$, *rate* pada waktu t menjadi $k + a(t)^T \delta$, sehingga didapat persamaan *piecewise logistic growth model* sebagai berikut:

$$g(t) = \frac{C(t)}{1 + \exp(-(k + a(t)^T \delta)(t - (m + a(t)^T \delta)))} \quad (3)$$

b. Linear Trend with Changepoints

Changepoints adalah momen dimana data berubah arah. Untuk peramalan yang tidak menunjukkan pertumbuhan yang jenuh dan *piece-wise constant rate of growth*, maka *trend* model menjadi persamaan berikut:

$$g(t) = (k + a(t)^T \delta)t + (m + a(t)^T \gamma) \quad (4)$$

Dimana

k = Growth rate

δ = rate adjustments

m = Offset parameter

dan γ_j di buat menjadi $-s_j \delta_j$ untuk membuat fungsi kontinyu.

Changepoint prior scale digunakan untuk mengatur tingkat *fleksibilitas* dari trend. Hal ini bertujuan untuk mengatasi masalah *over fitting* dan *under fitting* (Subashini, et al., 2019).

c. Automatic Changepoint Selection

Model ini digunakan jika kita mengetahui waktu perubahan suatu trend. Proses ini dilakukan secara otomatis dengan melakukan penyaringan kandidat dan seleksi berdasarkan persamaan 3 dan 4

d. Trend Forecast Uncertainty

Ketika model diekstrapolasi melewati sejarah untuk membuat *forecast*, maka *trend* akan memiliki angka konstan. *Generative model forward* dapat digunakan dalam memperkirakan ketidakpastian dalam *forecast trend*. *Changepoints* dimasa depan diambil secara acak sehingga frekuensi rata-rata dari *changepoints* menjadi cocok dalam riwayat. Maka persamaanya menjadi:

$$\forall_j > T, \begin{cases} \delta_j = 0 \text{ w.p. } \frac{T - S}{T}, \\ \delta_j \sim \text{Laplace}(0, \lambda) \text{ w.p. } \frac{S}{t}. \end{cases} \quad (5)$$

2. Seasonality

Dalam *business time series* sering kali memiliki musiman dengan multi periode sebagai akibat dari perilaku manusia. Misalnya waktu kerja 5 hari satu minggu, libur anak sekolah yang terulang setiap tahunnya, Untuk menyesuaikan dan meramalkan efek ini, maka kita memerlukan fungsi *periodic* dari t untuk menentukan *seasonality* (S. J. Taylor &

Letham, 2018) *Fourier series* digunakan dalam model *Prophet* untuk menyediakan model yang fleksibel dari efek *periodic* (Harvey & Shephard, 1993). Dengan P menjadi periode regular yang kita harapkan (misal $P=365.25$ untuk data *seasonal* tahunan atau $P=7$ untuk data *seasonal* mingguan). Sehingga persamaan dari *arbitrary smooth seasonal effect* menjadi:

$$s(t) = \sum_{n=1}^N \left(a_n \cos\left(\frac{2\pi nt}{P}\right) + (b_n \sin\left(\frac{2\pi nt}{P}\right)) \right) \quad (6)$$

Dengan parameter $\beta = [a_1, b_1, \dots, a_n, b_n]^T$
Dimana,

$$a_n = \frac{1}{P} \int_{-P}^P f(x) \cos\left(\frac{2\pi nt}{P}\right) dx$$

$$b_n = \frac{1}{P} \int_{-P}^P f(x) \sin\left(\frac{2\pi nt}{P}\right) dx$$

Pemilihan parameter ini dapat diotomatisasi menggunakan prosedur pemilihan model seperti AIC. Komponen *seasonality* dapat diatur sebagai *additive model* atau *multiplicative model* (Ensafi, et al., 2022). Dalam kasus *multiplicative seasonality*, komponen *growth* $g(t)$ dan komponen *seasonality* $s(t)$ akan berisi *log transformation* (Borges & Nascimento, 2022).

3. Holidays and events

Hari libur atau acara besar dapat memiliki pengaruh yang dapat diprediksi oleh peneliti meskipun tidak mengikuti pola *periodic*. Daftar hari libur dimasukkan ke dalam model dengan mengasumsikan bahwa efek liburan bersifat independent (S. J. Taylor & Letham, 2018). Model *prophet* mengizinkan peneliti untuk menambahkan *custom list* peristiwa masa lalu dan masa depan (Toharudin, et al., 2021). Untuk hari libur (i) dimasa lalu dan masa depan dilambangkan dengan D_i . Lambang t merupakan lamanya hari libur, setiap hari libur dilambangkan dengan κ_i , maka dibentuklah persamaan 3.7 dan 3.8 yang mirip dengan komponen *seasonality* dengan membuat matrik dari regresi :

$$Z(t) = [1(t \in D_1), \dots, (t \in D_L)] \quad (7)$$

Dan

$$h(t) = Z(t)\kappa \quad (8)$$

Dengan $\kappa \sim Normal(0, v^2)$

4. Extra Regressor

Regressor $r(t)$ dapat ditambahkan menjadi bagian linear pada model dengan menambahkan *function* “*add_regressor*”. *Extra regressor* harus sudah diketahui nilai masa lalu dan nilai masa depannya. Model *Prophet* dengan *extra regressor* dapat berupa faktor *additive* atau *multiplicative*. Menurut Sergey (2018) *extra regressor* dalam model *Prophet* dapat dinyatakan dengan persamaan sebagai berikut:

$$r(t) = \beta \frac{\text{regressor}_n(t) - \mu_{\text{regressor}}}{sd_{\text{regressor}}} \quad (9)$$

5. Fitting Models


Ketika komponen *seasonality* dan *holiday* digabungkan menjadi matriks X dan *change point indicators* $a(t)$ pada matriks A , persamaan 3.1 dapat dinyatakan kedalam beberapa baris *Stan code* (S. J. Taylor & Letham, 2018). Stan’s L-BFGS digunakan dalam model *Prophet* untuk menemukan *maksimum a posteriori estimate*.

6. Evaluasi Hasil Peramalan

Setelah proses pembentukan model, selanjutnya model akan dievaluasi dengan menggunakan *time series cross validation* untuk mengukur kesalahan perkiraan pada

data historis dalam model *Prophet*. Pada time series *cross validation*, hasil peramalan akan dibandingkan dengan nilai sebenarnya. Data akan terbagi menjadi tiga bagian seperti pada gambar 3.

Gambar 3. Pembagian data pada *time series cross validation*



Sumber : { facebook.github.io }

Berdasarkan Gambar 3 dapat dilihat bahwa data terbagi menjadi 3 bagian, yakni *intial*, *cutoff*, dan *horizon*. *Initial* digunakan sebagai *training set* untuk melakukan pelatihan pada model. *Cutoff* digunakan sebagai validasi model. Sedangkan *horizon* adalah ramalan yang dibuat untuk setiap titik yang diamati antara *cutoff* + *horizon*. Secara *default*, panjang *initial* adalah tiga kali panjang *horizon*, sedangkan *cutoff* dibuat setiap $\frac{1}{2}$ *horizon*. Pada penelitian ini, peneliti menetapkan panjang *horizon* selama 120 hari dengan 3 titik *cutoff* yang terjadi pada bulan Januari, Februari dan Maret 2022. *Output* yang dihasilkan oleh *cross validation* berupa nilai Y dan nilai *out-of-sample forecast* \hat{Y} . Komputasi statistik yang digunakan dalam penelitian ini untuk menunjukkan performa dari prediksi pada *time series cross validation* model *Prophet* berupa *mean absolute percentage error (MAPE)* dan *coverage*. Jika performa prediksi baik, maka dapat dilakukan peramalan.

7. Tuning Hyperparameters

Tuning hyperparameters bertujuan untuk menemukan nilai optimum dari *hyperparameters* dalam *learning algorithm* pada dataset. Dalam model prophet, hyperparameters yang dapat diatur, seperti *changepoint prior scale*, *seasonality prior scale*, *holidays prior scale*, dan *seasonality mode*. Pada penelitian ini, *hyperparameters* yang diatur berupa *changepoint prior scale* dengan 4 *value* yang berbeda, yakni 0,001; 0,01; 0,1 dan 0,5. Sedangkan *seasonality prior scale* dan *holidays prior scale* diatur dengan 4 *value* yang berbeda, yakni 0,01; 0,1; 1,0 dan 10,0.

8. Peramalan model Prophet

Peramalan dilakukan dengan menggunakan model yang optimum setelah yaitu jaringan yang memiliki nilai kesalahan peramalan terkecil pada *cross validation*. Jika saat proses awal dilakukan transformasi, setelah dilakukan peramalan data harus ditransformasi kembali ke nilai aslinya.

HASIL DAN PEMBAHASAN

Dalam pembentukan model prophet, hal pertama yang dilakukan adalah melakukan inputasi data. Secara default, model prophet hanya dapat membaca data dengan variabel "ds"

sebagai variabel waktu dan variabel “y” sebagai respon, namun kita dapat menambahkan variabel lain sebagai penunjang peramalan. Oleh karena itu, diperlukan pre-processing data untuk mengubah variabel penelitian menjadi variabel “ds” dan variabel “y”. Variabel “ds” harus berbentuk format yang dapat dibaca oleh package Pandas dan variabel “y” harus berbentuk numerik.

Pada penelitian ini pembentukan model dilakukan secara *trial and error* hingga mendapatkan model terbaik yang memiliki nilai kekeliruan terkecil. Berikut merupakan hasil dari beberapa model *prophet* yang terbentuk:

1) Model Prophet 1

Model *Prophet 1* adalah model *prophet* yang terbentuk secara *default* tanpa adanya proses *tuning* komponen. Dalam model *prophet default*, hanya terdapat komponen *trend* dan *seasonal* tanpa adanya komponen *holiday*, sehingga persamaan dari model ini menjadi:

$$Y(t) = (-0,4277 + a(t)^T \delta)t + (0,7989 + a(t)^T \gamma) + X(t)\beta + \varepsilon_t \quad (10)$$

Dengan hasil evaluasi model serta *plot* sebagai berikut:

Model 1	MAPE (%)	Coverage
Data Training	37,49%	0,0
Data Testing	80,41%	

Gambar 4. Hasil evaluasi dan plot model prophet 1

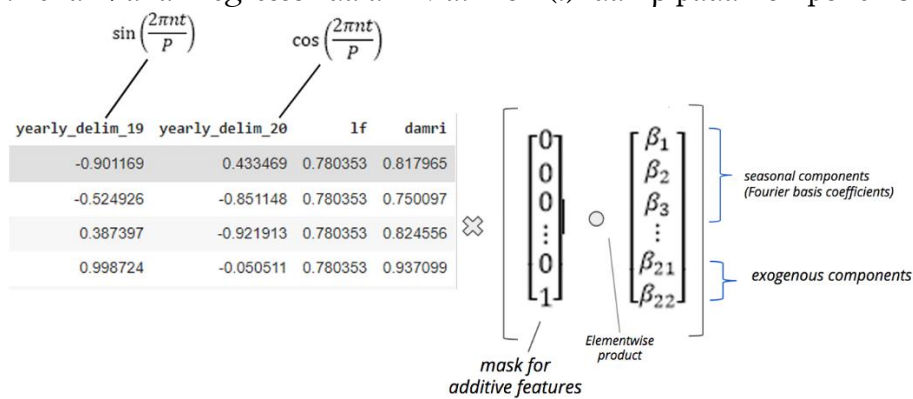


Berdasarkan Gambar 4 model *default prophet* memiliki nilai MAPE pada data *testing* yang sangat besar berkisar 80,41%. Menurut Lewis (1982) peramalan model *default prophet* sangat tidak akurat. Nilai MAPE pada data *training default prophet* berkisar 37,49%, hal ini mengindikasikan bahwa model mengalami *underfitting* hal ini pun terlihat pada *plot* yang membandingkan antara data *actual* dengan data *forecast*. Selain itu, *coverage* (R^2) bernilai 0, artinya komponen *trend* dan *seasonality* pada model hanya menjelaskan 0% model tersebut. Oleh karena itu, perlu adanya proses *tuning* komponen untuk memperbaiki model *prophet* tersebut.

2) Model Prophet 2

Model *Prophet 2* adalah model *prophet* yang terbentuk setelah adanya proses *tuning* komponen berupa penambahan *extra regressor*. Dalam model *prophet 2*, *extra regressor* yang digunakan berupa variabel “lf” dan “damri”. kedua variabel tersebut diasumsikan memiliki hubungan kausalitas dengan jumlah penumpang Trans Metro bandung. Proses *tuning* komponen *extra regressor* diawali dengan pembuatan *data frame* berisi *future date* dan *future value* dari setiap regressor dan digabungkan dengan data historis yang sudah tersedia sebelumnya. Untuk menambahkan *extra regressor* pada model, dibutuhkan *function “add regressor”* yang bertujuan untuk memasukan kedua variabel tersebut kedalam matriks $X(t)$ dan vektor β seperti pada Gambar 5.

Gambar 5. Penambahan regressor dalam Matriks X(t) dan β pada Komponen Seasonality




Persamaan dari model *Prophet 2* ini menjadi:

$$\begin{aligned}
 Y(t) = & ((-0,3773 + a(t)^T \delta)t + (0,7982 + a(t)^T \gamma)) \\
 & + X(t)\beta + \left(0,2091 \frac{lf_n(t) - \mu_{lf}}{sd_{lf}}\right) \\
 & + \left(-0,1022 \frac{lf_n(t) - \mu_{damri}}{sd_{damri}}\right) + \varepsilon_t
 \end{aligned}
 \tag{11}$$

Dengan hasil evaluasi model serta *plot* sebagai berikut:

Model 2	MAPE (%)	Coverage
Data Training	12,25%	0,83
Data Testing	6,41%	

Gambar 6. Hasil evaluasi dan plot model prophet 2



Berdasarkan Gambar 6 model *prophet 2* memiliki nilai MAPE sebesar 6,41% untuk data *testing* dan 12,25% pada *training* dengan *coverage* sebesar 0,833, artinya model memiliki akurasi peramalan yang akurat baik untuk data *training* ataupun data *testing*, serta komponen dalam model *prophet 2* tersebut dapat menjelaskan 83,3% pengaruhnya terhadap jumlah penumpang Trans Metro Bandung. Jika dibandingkan dengan model prophet 1, model *prophet 2* memiliki akurasi peramalan yang lebih tinggi artinya proses *tuning* dengan menambahkan komponen *extraregressor* berhasil meningkatkan akurasi peramalan. Meskipun hasil peramalan sudah akurat, namun model peramalan masih dapat ditingkatkan dengan proses *tuning* komponen lainnya berdasarkan jarak hasil peramalan dengan data aktual pada Gambar 6.

3) Model *Prophet 3*

Model Prophet 3 adalah model prophet yang terbentuk setelah adanya proses tuning komponen berupa penambahan extra regressor dan penambahan efek hari libur yang

terjadi di Indonesia. Proses tuning pada komponen holidays $h(t)$ diawali dengan membentuk data frame berisi variabel “holidays” dan variabel “ds”. Dalam penelitian ini, variabel “holidays” berupa hari libur nasional seperti Tahun baru, Imlek, Nyepi, Wafat Isa Almasih, Hari buruh, Kenaikan Isa Almasih, Waisak, Hari lahir Pancasila, Idul fitri, Kemerdekaan, Idul adha, Tahun baru islam, Maulid Nabi Muhammad SAW, dan Natal sejak tahun 2018 hingga 2023. Sehingga persamaan modelnya menjadi:

$$\begin{aligned}
 Y(t) = & ((-0,3542 + a(t)^T \delta)t + (0,0836 + a(t)^T \gamma)) \\
 & + X(t)\beta + \left(0,2157 \frac{lf_n(t) - \mu_{lf}}{sd_{lf}}\right) \\
 & + \left(-0,1004 \frac{damri_n(t) - \mu_{damri}}{sd_{damri}}\right) + Z(t)\kappa \\
 & + \varepsilon_t
 \end{aligned}
 \tag{12}$$

Dengan hasil evaluasi model serta *plot* sebagai berikut:

Model 3	MAPE (%)	Coverage
Data Training	12,01%	0,89
Data Testing	5,21%	

Gambar 7. Hasil evaluasi dan plot model prophet 3



Berdasarkan Gambar 7 model *prophet 3* memiliki nilai MAPE sebesar 5,17% pada data *testing* dan sebesar 12,05% pada data *training* dengan *coverage* sebesar 0,89. Model *prophet 3* memiliki akurasi peramalan yang sangat baik serta komponen dalam model *prophet 3* tersebut dapat menjelaskan 89% pengaruhnya terhadap jumlah penumpang Trans Metro Bandung. Hasil akurasi dari model *prophet 3* mengalami peningkatan jika dibandingkan dengan model *prophet 3*, artinya penambahan komponen *holidays* cocok terhadap model.

Proses selanjutnya adalah proses *tuning hyperparameters*. Proses ini diawali dengan memilih model dengan nilai *Mean Absolute Percentage Error* (MAPE) terkecil pada *cross validation*. Berikut adalah hasil evaluasi *cross validation* dari model *prophet* yang terbentuk.

Tabel 1 Hasil Evaluasi *Cross Validation* Model *Prophet*

Koridor 1	MAPE Training	MAPE Testing	COVERAGE (R^2)
Model <i>prophet</i> 1	37,49%	80,41%	0,0000
Model <i>prophet</i> 2	12,25%	6,41%	0,89
Model <i>prophet</i> 3	12,01%	5,21%	0,89

Berdasarkan Tabel 1 model peramalan terbaik adalah model *prophet 3* dengan proses *tuning* pada komponen *extra regressor* dan *holidays*. Proses selanjutnya adalah menentukan nilai optimum dari *hyperparameters* untuk model *prophet 3* dengan melakukan proses *looping*. Berikut hasil evaluasi proses *looping hyperparameters*.

Tabel 2 Hasil Evaluasi *looping Hyperparameters*

Changepoint Scale	Prior	Seasonality Scale	Prior	Holidays Scale	Prior	RMSE
0,001		0,01		0,01		2082,644548
0,001		0,01		0,1		492,848258
0,001		0,01		1		545,828877
0,001		0,01		10		523,814723
0,001		0,1		0,01		2500,712284
0,001		0,1		0,1		485,282989
0,001		0,1		1		544,500197
0,001		0,1		10		536,241038
0,001		1		0,01		2482,407614
0,001		1		0,1		314,5555
0,001		1		1		330,33614
0,001		1		10		313,736243
0,001		10		0,01		2532,106813
0,001		10		0,1		287,498947
0,001		10		1		280,812559
0,001		10		10		298,964168
0,01		0,01		0,01		2073,082132
0,01		0,01		0,1		486,08553
0,01		0,01		1		543,359539
0,01		0,01		10		547,243175
0,01		0,1		0,01		2481,52117
0,01		0,1		0,1		491,784763
0,01		0,1		1		539,564393
0,01		0,1		10		544,823284
0,01		1		0,01		2510,232986
0,01		1		0,1		311,713154
0,01		1		1		316,405678
0,01		1		10		309,612326
0,01		10		0,01		2520,18618
0,01		10		0,1		271,677663
0,01		10		1		221,001128
0,01		10		10		215,314316
0,1		0,01		0,01		1578,459735
0,1		0,01		0,1		476,637486
0,1		0,01		1		534,620124

0,1	0,01	10	533,912017
0,1	0,1	0,01	1641,864444
0,1	0,1	0,1	471,141202
0,1	0,1	1	526,407428
0,1	0,1	10	528,455937
0,1	1	0,01	1634,241687
0,1	1	0,1	280,73018
0,1	1	1	294,024637
0,1	1	10	294,527811
0,1	10	0,01	1625,90546
0,1	10	0,1	230,816005
0,1	10	1	215,685522
0,1	10	10	204,380562
0,5	0,01	0,01	584,262223
0,5	0,01	0,1	431,289972
0,5	0,01	1	467,693524
0,5	0,01	10	468,022208
0,5	0,1	0,01	851,404522
0,5	0,1	0,1	416,151334
0,5	0,1	1	454,605226
0,5	0,1	10	458,232405
0,5	1	0,01	852,071438
0,5	1	0,1	268,130657
0,5	1	1	278,880031
0,5	1	10	271,185313
0,5	10	0,01	905,416082
0,5	10	0,1	239,682271
0,5	10	1	227,510736
0,5	10	10	223,438278

Berdasarkan Tabel 2 nilai *changepoint prior scale* optimum untuk model *prophet* 3 sebesar 0.1, sedangkan nilai *seasonality prior scale* dan *holidays prior scale* optimum sebesar 10. Nilai MAPE untuk model ini sebesar 4,62% untuk data *testing* dan 10,99% untuk data *training* dengan coverage sebesar 0,89 sehingga model ini menjadi model terbaik dengan persamaan model menjadi :


$$\begin{aligned}
Y(t) = & ((-0,4475 + a(t)^T \delta)t + (0,5327 + a(t)^T \gamma)) \\
& + X(t)\beta + \left(0,2077 \frac{lf_n(t) - \mu_{lf}}{sd_{lf}}\right) \\
& + \left(-0,0834 \frac{damri_n(t) - \mu_{damri}}{sd_{damri}}\right) + Z(t)\kappa \\
& + \varepsilon_t
\end{aligned} \tag{13}$$

Setelah mendapatkan nilai *hyperparameters* yang optimum, proses selanjutnya adalah melakukan peramalan dengan model tersebut selama enam bulan kedepan. Berikut hasil peramalan dan *plot* jumlah penumpang Trans Metro Bandung selama 6 bulan kedepan.

Tabel 3 Hasil Peramalan Jumlah Penumpang Trans Metro Bandung

Koridor 1	Periode	Jumlah Penumpang (orang)
	Agustus 2022	33.378
	September 2022	27.907
	Oktober 2022	28.101
	November 2022	29.197
	Desember 2022	29.521
	Januari 2023	27.541

Gambar 8. Plot hasil peramalan jumlah penumpang Trans Metro Bandung selama 6 kedepan



Berdasarkan Tabel 3 dan Gambar 8 dapat dilihat bahwa hasil peramalan data jumlah penumpang Trans Metro Bandung dengan model *prophet* cenderung berfluktuasi diangka 27 ribuan - 33 ribuan, dimana jumlah penumpang Trans Metro Bandung tertinggi terjadi pada bulan Agustus 2022 dan terendah pada bulan Januari 2023. Hasil peramalan ini dapat dijadikan bahan pertimbangan Dinas Perhubungan Kota Bandung ataupun pihak terkait dalam menentukan kebijakan yang akan datang.

KESIMPULAN DAN SARAN

Berdasarkan hasil analisis dan pembahasan pada bab sebelumnya, maka dapat ditarik kesimpulan sebagai berikut :

1. Model *prophet* 3 dengan nilai *changpoint prior scale* sebesar 0.1, nilai *seasonality prior scale* dan *holidays prior scale* sebesar 10 merupakan model terbaik untuk meramalkan jumlah penumpang Trans Metro Bandung koridor 1 dengan proses *tuning* berupa penambahan *extra regressor* dan penambahan komponen *holiday*. Persamaan model *prophet* ini menjadi :

$$Y(t) = ((-0,4475 + a(t)^T \delta)t + (0,5327 + a(t)^T \gamma)) + X(t)\beta + \left(0,2077 \frac{lf_n(t) - \mu_{lf}}{sd_{lf}}\right) + \left(-0,0834 \frac{damri_n(t) - \mu_{damri}}{sd_{damri}}\right) + Z(t)\kappa + \epsilon_t$$

Dengan MAPE sebesar sebesar 4,62% untuk data *testing*, 10,99% untuk data *training* dan coverage sebesar 0,89.

2. Penambahan *extra regressor* dalam penelitian ini memberikan peningkatan akurasi peramalan dan coverage yang cukup besar, hal ini dapat terlihat pada model *prophet* 1 yang didalamnya tidak terdapat *extra regressor* dengan model *prophet* 2 dan 3 yang didalamnya terdapat penambahan *extra regressor*. Dengan demikian, jumlah penumpang Damri dan jumlah penumpang maksimal dalam penanganan COVID-19 berdasarkan SE

- Menteri Perhubungan memiliki hubungan *kausalitas* yang tinggi terhadap jumlah penumpang Trans Metro Bandung.
3. Hasil peramalan jumlah penumpang Trans Metro Bandung untuk koridor 1 cenderung berfluktuasi diangka 27 ribu hingga 33 ribu penumpang, dengan jumlah penumpang tertinggi terjadi pada bulan Agustus 2022 dan jumlah penumpang terendah pada bulan Januari 2023. Seluruh hasil peramalan jumlah penumpang Trans Metro Bandung terdapat pada tabel 3.

Berdasarkan hasil penelitian yang telah dilakukan oleh peneliti, terdapat beberapa saran yang dapat peneliti berikan untuk penelitian selanjutnya demi tercapainya hasil penelitian yang lebih baik, yakni:

1. Pada penelitian ini, metode peramalan yang digunakan hanya metode *prophet*. Sebaiknya metode analisis yang digunakan dikombinasikan dan dibandingkan dengan metode metode lain seperti metode *backpropagation*, *LSTM*, *neural prophet*, dan lain-lain.
2. Pada metode *prophet*, data harian lebih cocok digunakan jika dibandingkan penggunaan data bulanan. Hal ini diakibatkan oleh proses *tuning* komponen yang lebih banyak dan efek komponen *holidays* dapat terlihat lebih jelas.

Algoritma *grid search* dan algoritma genetik dapat ditambahkan kedalam model *Prophet* untuk melakukan proses pencarian parameter secara otomatis, sehingga model dapat dijalankan secara *full automatic*.

DAFTAR PUSTAKA

- Alammal, Hesham & Almadany, Wael & Eskandarnia, Elham. (2021). What Prophet Says about Electrical Consumption -Forecasting Techniques for Big Temporal Data. <https://doi.org/10.1049/icp.2021.0863>
- Borges, D., & Nascimento, M. (2022). COVID-19 ICU demand forecasting: A two-stage Prophet-LSTM approach. *Applied Soft Computing*.
- Brockwell, P. J., & Davis, R. A. (2016). Introduction to Time Series and Forecasting - Second Edition. *Springer-Verlag*.
- Ensafi, Y., Amin, S. H., Zhang, G., & Shah, B. (2022). Time-series forecasting of seasonal items sales using machine learning – A comparative analysis. *International Journal of Information Management Data Insights*.
- Harvey, Andrew C, and Neil Shephard. 1993. “[Structural time series models](#).” Handbook of Statistics, (edited by G.S. Maddala, C.R. Rao and H.D. Vinod), Vol. 11:Econometrics: 261-302. North Holland.
- Hyndman, R. J., & Athanasopoulos, G. (2018). Forecasting: Principles and Practice. *Principles of Optimal Design*, 504. <https://otexts.com/fpp2/>
- Kementerian Perhubungan Republik Indonesia. (2022). Surat Edaran Menteri: https://jdih.dephub.go.id/index.php/produk_hukum/timeline/Surat%20Edaran%20Menteri
- Lewis, C. (1982). *Industrial and business forecasting methods*. London: Butterworths Publishing.
- Makridakis S, Wheelwright SC, H. R. (1997). 1 / the Forecasting Perspective. *Forecasting Methods and Applications*, 1–632.
- Makridakis, Wheelwright dan McGee. (1999). Metode dan Aplikasi Peramalan (terjemahan). Jakarta: Binarupa Aksara.
- Malefors, C., Strid, I., Hansson, P.-A., & Eriksson, M. (2020). Potential for using guest attendance forecasting in Swedish public catering to reduce overcatering. *Sustainable Production and Consumption*
- Montgomery, D., Jennings, C., & Kulahci, M. (2015). *Intoduction to TIME SERIES ANALYSIS AND FORECASTING Second Edition*. Canada: John Wiley & Sons,Inc.

- N. Kumar and S. Susan, "COVID-19 Pandemic Prediction using Time Series Forecasting Models," *2020 11th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*, Kharagpur, India, 2020, pp. 1-7
- Papacharalampous, G., & Tyrallis, H. (2020). Hydrological time series forecasting using simple combinations: Big data testing and investigations on one-year ahead river flow predictability. *Journal of Hydrology*.
- Pemerintah Kota Bandung. (2022). Open Data Kota Bandung: http://data.bandung.go.id/index.php/portal/detail_dataset/483100a5-0815-44e8-b21c-2a91fb06ad4b
- Pontoh, R. S., Zahroh, S., Nurahman, H. R., Aprillion, R. I., Ramdani, A., & Akmal, D. I. (2021). Applied of feed-forward neural network and facebook prophet model for train passengers forecasting . *Konferensi Nasional Penelitian Matematika dan Pembelajarannya (KNPMP) V Prophet*. (2022). <https://facebook.github.io/Prophet/>
- Satrio, Christophorus & Darmawan, William & Nadia, Bellatasya & Hanafiah, Novita. (2021). Time series analysis and forecasting of coronavirus disease in Indonesia using ARIMA model and PROPHET. *Procedia Computer Science*. <https://doi.org/10.1016/j.procs.2021.01.036>
- Sergey, M. (2018). *What is Facebook Prophet forecasting model*. kaggle <https://www.kaggle.com/code/smakarychev/what-is-facebook-Prophet-forecasting-model>
- Subashini, A & K, Sandhiya & Saranya, S & Harsha, U. (2019). Forecasting Website Traffic Using Prophet Time Series Model. *International Research Journal of Multidisciplinary Technovation*. 1. 56-63. <https://doi.org/10.34256/irjmt1917>.
- Sunagar, P., Hanumantharaju, R., G.M., S., Kanavalli, A., & Srinivasa, K. (2020). Influence of big data in smart tourism. *Hybrid Computational Intelligence Challenges and Applications*.
- Taylor, B. W. (2013). *Introduction to management science*. Pearson Education.
- Taylor, S. J., & Letham, B. (2018). Forecasting at Scale. *American Statistician*, 72(1), 37–45.
- Toni Toharudin, Resa Septiani Pontoh, Rezzy Eko Caraka, Solichatus Zahroh, Youngjo Lee & Rung Ching Chen (2021): Employing long short-term memory and Facebook prophet model in air temperature forecasting, *Communications in Statistics - Simulation and Computation*
- Zhao, N., Liu, Y., Vanos, J., & Cao, G. (2018). Day-of-week and seasonal patterns of PM2.5 concentrations over the United States: Time-series analyses using the Prophet procedure. *Atmospheric Environment*.