



Pemodelan Jumlah Pengguna Metode Kontrasepsi Jangka Panjang (MKJP) di Provinsi Bengkulu Menggunakan Metode Arima dan Prophet

Agus Veriyansah Dalimunthe^{1*}

¹ Perwakilan BKKBN Provinsi Bengkulu

* Corresponding Author

Article Information

Article History:

Submitted: 12 04 2024

Accepted: 12 09 2024

Published: 12 31 2024

Key Words:

Analisis Time Series

ARIMA Model

Prophet Model

Contraceptive Devices

Long Term Contraceptive Method (MKJP)

DOI:

<https://doi.org/10.33369/diophantine.v3i2.38539>

Abstract

The use of contraceptives, especially Long-Term Contraceptive Methods (MKJP), plays a central role in birth control efforts and family planning. Time series analysis has become a very effective method for identifying and predicting patterns in sequential data such as MKJP usage data. The data used is monthly data on the number of users of MKJP contraceptives (IUD, MOW, MOP and Implant) for the period January 2012 to 2012. December 2023. The aim of this research is to obtain comparative results of the accuracy of forecasting models using the Autoregressive Integrated Moving Average (ARIMA) and Prophet methods and to obtain projected results of MKJP contraceptive users in Bengkulu Province in the coming year. The results show that the ARIMA (0,1,1) model is the best model for forecasting because it has the minimum Mean Absolute Percentage Error (MAPE) and Root Mean Square Error (RMSE) values compared to the Prophet method. The forecast results for the number of MKJP contraceptive users (IUD, MOW, MOP and Implant) in 2024 tend to show a decreasing trend in May 2024 and an increasing trend in March 2024. For IUD contraception, it is known that the number of active family planning (PA) users is the lowest. was May 2024 with a total of 5593 participants, while the highest PA occurred in March 2024, namely 16742 participants. Then for MOW contraception, the lowest number of PAs was in May 2024, amounting to 6028 participants, while the highest PA was in March 2024, amounting to 8417 participants. Furthermore, for MOP contraception, it is known that the lowest number of PAs was in December 2024, amounting to 79 participants, while the peak PA occurred in March 2024, namely 614 participants. And finally, for IMPLANT contraception, it is known that the lowest number of PA was in May 2024, amounting to 26,771 participants, while the highest PA occurred in March 2024, namely 50,957 participants.

1. PENDAHULUAN

Kemajuan inovasi dan informasi saat ini mengalami pertumbuhan yang cepat, data telah menjadi suatu kekayaan yang tak ternilai dalam pengambilan keputusan strategis, terutama dalam konteks perencanaan pembangunan jangka panjang. Pemanfaatan metode statistika, khususnya analisis *time series*, menjadi sebuah kebutuhan mendesak untuk menyelidiki tren dan mengetahui masa depan.

Peramalan *time series* sering kali digunakan sebagai alat dalam menghasilkan informasi yang akan digunakan untuk merumuskan perencanaan kebijakan. Ada beberapa teknik yang bisa dipakai dalam melakukan prediksi *time series*, termasuk: Box-Jenkins *Autoregressive Integrated Moving Average* (ARIMA) *models*, Box-Jenkins *Multivariate Models* dan *Holt-Winters Exponential Smoothing*.

Secara administratif, Provinsi Bengkulu terdiri dari sembilan kabupaten dan satu kota yang masing-masing mempunyai budaya tersendiri. Keberhasilan pelaksanaan program pembangunan keluarga, pengelolaan kependudukan, dan keluarga berencana memerlukan penyusunan kebijakan dan strategi. Salah satunya adalah ketika mengkaji konteks penggunaan MKJP, perlu dipahami bahwa perbedaan sosial, ekonomi, dan budaya ini dapat memengaruhi pilihan dan pola penggunaan kontrasepsi. Perwakilan Badan Kependudukan dan Keluarga Berencana Nasional Provinsi Bengkulu (BKKBN) adalah instansi Pemerintah yang memiliki tugas menyelenggarakan Pembangunan Keluarga, Pengaturan Populasi dan Keluarga Berencana. Sebuah rencana strategis 2024-2029, BKKBN Provinsi Bengkulu akan meningkatkan capaian peserta KB aktif pada Metode KB Jangka Panjang termasuk IUD, Tubektomi, dan Vasektomi dan Implan. Hal ini dilakukan untuk mengurangi penggunaan alat kontrasepsi hormonal dan meningkatkan kesehatan ibu, sebagai opsi alat kontrasepsi jangka panjang memberikan alternatif yang memadai bagi pasangan usia subur yang ingin merencanakan keluarga mereka dengan lebih bijak.

Dalam beberapa tahun terakhir, kesadaran masyarakat terhadap kesehatan reproduksi dan keluarga berencana telah meningkat. Selain itu, masyarakat saat ini telah menyadari pentingnya mengikuti program keluarga berencana. Faktor-faktor yang memainkan peran penting dalam mengubah pola pikir masyarakat terkait kontrasepsi. Di Provinsi Bengkulu, upaya untuk meningkatkan aksesibilitas layanan kesehatan dan pengetahuan mengenai MKJP telah diimplementasikan oleh pemerintah setempat. Namun, sejauh mana upaya ini berhasil dan bagaimana hal itu memengaruhi pola penggunaan MKJP perlu didalami lebih lanjut. Dengan menggunakan analisis *time series* dapat kita pelajari dinamika dan memahami lebih dalam tren penggunaan MKJP.

Seiring perkembangan teknologi dan kemajuan ilmu pengetahuan, analisis *time series* telah menjadi metode yang sangat efektif untuk mengidentifikasi dan meramalkan pola dalam data sekuensial seperti data penggunaan MKJP. Pemerintah memerlukan perencanaan strategi yang berfungsi untuk meningkatkan jumlah pengguna alat kontrasepsi MKJP. Dengan menggunakan prediksi, diharapkan dapat memberikan kondisi masa depan untuk memandu pengambilan keputusan mengenai sejauh mana penggunaan kontrasepsi MKJP di masa depan.

Banyak penelitian telah dilakukan untuk membandingkan berbagai metode *time series* atau deret waktu yang berbeda, terutama perbandingan metode *time series* ARIMA dan Prophet, salah satunya yang dilakukan oleh [1] yang membahas penggunaan pendekatan penggunaan ARIMA dan Prophet pada data Bitcoin dengan interval waktu per jam. Berdasarkan beberapa riset terdahulu, penelitian ini akan melakukan peramalan menggunakan metode ARIMA dan Prophet, ke dalam data pengguna alat kontrasepsi MKJP di Provinsi Bengkulu dari tahun 2012-2023. Selanjutnya, data-data tersebut akan dianalisis sedemikian rupa untuk menentukan tingkat kinerja *time series* atau deret waktu dari pendekatan ARIMA dan Prophet, serta untuk melihat bagaimana proyeksi pengguna alat kontrasepsi MKJP di Provinsi Bengkulu pada tahun yang akan datang.

1.1 Analisis Deret Waktu

Menurut [2] terdapat tiga jenis data, yakni data *time series*, *cross-section*, serta kumpulan data. Data deret waktu merupakan serangkaian observasi dari sebuah faktor yang direkam dalam rentang waktu yang beragam. Jenis data ini secara rutin dikumpul, seperti setiap hari, minggu, bulan, atau tahun. Data *time series* menunjukkan ciri khas berupa pola atau fluktuasi tertentu yang muncul dalam berbagai level. Mengkaji pola-pola ini sangat krusial untuk berbagai aplikasi, termasuk untuk memprediksi pola yang akan muncul di masa depan.

Fokus utama dari pemodelan *time series* adalah mengumpulkan serta mempelajari data dari *time series* guna menciptakan model yang cocok dengan data tersebut. Model tersebut kemudian dimanfaatkan untuk menciptakan estimasi angka-angka di periode yang akan datang, yang dikenal sebagai peramalan (*forecasting*). Proses peramalan *time series* bisa dianggap sebagai upaya untuk meramalkan periode ke depan dengan pemahaman data periode lampau [3].

Analisis deret waktu memungkinkan Anda memahami evolusi satu atau lebih peristiwa dan keterkaitannya serta pengaruhnya terhadap peristiwa lain. Analisis *time series* digunakan sebagai sarana untuk meramalkan kondisi masa depan berdasarkan pola data yang ada. Data pengamatan dalam seri waktu diwakili oleh variabel Z_t , dimana t merupakan indeks waktu dari urutan pengamatan.

1. Stasioneritas Data *Time series*

Dalam data *time series*, akan ditemukan kejadian acak yang dianggap sebagai hasil dari model stokastik dengan struktur yang tidak berubah (*invariant structure*). Rangkaian ini dikenal sebagai *time series* stasioner (*stationary*). Namun, jika struktur stokastik dari *time series* tersebut mengalami perubahan sepanjang waktu (*change over time*), maka *time series* tersebut disebut *time series nonstasioner*.

Keberadaan stasioneritas penting untuk memprediksi data deret waktu. Menurut penelitian [4], stasioneritas berarti data tidak berubah seiring berjalannya waktu. Artinya, peningkatan atau penurunan informasi tidak bergantung pada waktu dan bergerak di sekitar nilai rata-rata yang stabil, dengan fluktuasi yang konstan selama periode waktu tertentu. Deret waktu stasioner adalah kumpulan data yang statistik dasarnya, seperti mean dan varians, adalah tetap [5]. Stasioneritas dibagi menjadi dua bagian yaitu stasioneritas dalam rata-rata dan stasioneritas dalam variansi.

2. Uji *Augmented Dickey-Fuller* (ADF)

Pengujian ADF adalah Pengujian hipotesis yang dijalankan untuk mengetahui suatu *time series* memiliki akar unit. Dalam pengujian ini menggunakan model autoregresi urutan 1 atau AR (1) dan akan mengevaluasi tingkat kepentingan koefisien δ [6]:

$$\Delta Z_t = c + \delta Z_{t-1} + \sum_{j=1}^{p-1} \phi_j \Delta Z_{t-j} + \varepsilon_t. \quad (1)$$

Langkah-langkah uji *Augmented Dickey Fuller* (ADF) adalah sebagai berikut:

1. Hipotesis
 $H_0: \delta = 0$ (Data tidak stasioner dalam rata-rata)
 $H_1: \delta \neq 0$ (Data stasioner dalam rata-rata)
2. Taraf signifikansi: nilai alpha (α)
3. Statistik uji:

$$DF = \frac{\hat{\delta}}{SE(\hat{\delta})} \quad (2)$$

4. Daerah penolakan:

tolak H_0 jika $p\text{-value} < \alpha$.

5. Kesimpulan

Tolak H_0 jika $p\text{-value} < \alpha$, artinya data stasioner dalam rata-rata.

3. Fungsi Autokorelasi dan Autokorelasi Parsial

Fungsi autokorelasi (ACF) menghitung korelasi di antara pengukuran berurutan dalam rangkaian waktu. Fungsi autokorelasi di antara Z_t dan Z_{t-k} dinyatakan sebagai:

$$ACF(k) = \rho_k = \frac{Cov(Z_t, Z_{t-k})}{Var(Z_t)} \tag{3}$$

Batas kritis untuk ACF dan PACF adalah $\pm 1,96/\sqrt{T}$ di mana T merupakan jumlah data dalam rangkaian waktu. Jika nilai-nilai ACF setelah jarak waktu ke- k melebihi batas kepercayaan Z , sehingga rangkaian tersebut dianggap tidak stasioner dan memerlukan proses *differencing*. Sebaliknya, Jika nilai ACF berada dalam batas kepercayaan Z , deret waktu dapat dianggap stasioner.

a. Autocorrelation Function (ACF)

Koefisien autokorelasi adalah suatu fungsi yang menunjukkan besarnya korelasi antara obsevasi pada ke t yang dinotasikan dengan Z_t dengan observasi pada titik waktu sebelumnya yang dinotasikan $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k}$. Suatu proses yang stasioner $\{Z_t\}$ dengan nilai *mean* $\{Z_t\} = \mu$, dan $var(Z_t) = E(Z_t - \mu)^2 = \sigma^2$, dimana nilai tersebut konstan, dan $cov(Z_t, Z_s)$ merupakan fungsi dari perbedaan waktu $|t - s|$. Nilai kovariansi antara Z_t dan Z_{t-k} adalah sebagai berikut:

$$\gamma_k = cov(Z_t, Z_{t+k} - \mu) = E(Z_t - \mu)(Z_{t+k} - \mu)$$

dan autokorelasi antara Z_t dan Z_{t+k} adalah:

$$\rho_k = \frac{cov(Z_t, Z_{t+k})}{\sqrt{var(Z_t)}\sqrt{var(Z_{t+k})}} \tag{4}$$

dengan $var(Z_t) = var(Z_{t+k}) = \gamma_0$, adapun γ_k disebut fungsi autokovarian dan ρ_k disebut fungsi autokorelasi. Untuk proses stasioner, fungsi autokovariansi γ_k dan fungsi autokorelasi ρ_k mempunyai sifat-sifat sebagai berikut [7]:

1. $\gamma_0 = var(Z_t)$; $\rho_0 = 1$
2. $|\gamma_k| \leq \gamma_0$; $|\rho_k| \leq 1$
3. $\gamma_k = \gamma_{-k}$ dan $\rho_k = \rho_{-k}$, untuk semua k

untuk fungsi autokorelasi yang dihitung sesuai pengambilan data dirumuskan sebagai berikut [8]:

$$r_k = \rho_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^{n-k} (Z_t - \bar{Z})^2} \tag{5}$$

Karena r_k merupakan fungsi atas k , maka hubungan koefisien autokorelasi dengan lagnya disebut dengan fungsi autokorelasi dan dinotasikan dengan ρ_k .

b. Parsial Autocorrelation Function (PACF)

Autokorelasi parsial digunakan untuk mengukur tingkat keeratan (*association*) antara Z_t dan Z_{t-k} apabila pengaruh dari *lag* waktu (*time lag*) 1,2,3, ..., $k - 1$ dianggap terpisah. Fungsi autokorelasi parsial adalah suatu fungsi yang menunjukkan besarnya korelasi parsial antara pengamatan pada waktu ke t (dinotasikan Z_t) dengan pengamatan pada waktu-waktu sebelumnya (dinotasikan dengan $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k}$). Fungsi autokorelasi dapat dinyatakan sebagai berikut:

$$\phi_{kk} = corr(Z_t, Z_{t-k} | Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}) \tag{6}$$

Nilai ϕ_{kk} dapat ditentukan melalui persamaan Yule Walker sebagai berikut [9]:

$$\rho_j = \phi_{k1}\rho_{j-1} + \phi_{k2}\rho_{j-2} + \dots + \phi_{kk}\rho_{j-k} \tag{7}$$

untuk $j = 1, 2, 3, \dots, k$, sehingga berlaku persamaan berikut:

$$\rho_1 = \phi_{k1}\rho_0 + \phi_{k2}\rho_1 + \dots + \phi_{kk}\rho_{k-1} \tag{8}$$

$$\rho_2 = \phi_{k1}\rho_1 + \phi_{k2}\rho_0 + \dots + \phi_{kk}\rho_{k-2} \tag{9}$$

⋮

$$\rho_k = \phi_{k1}\rho_{k-1} + \phi_{k2}\rho_{k-2} + \dots + \phi_{kk}\rho_0 \tag{10}$$

berikut adalah bentuk persamaan di atas jika ditulis dalam bentuk matriks:

$$\begin{pmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_k \end{pmatrix} = \begin{pmatrix} 1 & \rho_1 & \rho_2 & \rho_3 & \dots & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \rho_{k-4} & \dots & 1 \end{pmatrix} \begin{pmatrix} \phi_{k1} \\ \phi_{k2} \\ \vdots \\ \phi_{kk} \end{pmatrix}$$

4. Pengujian Diagnostik Model

Pengujian diagnostik model bertujuan untuk membuktikan bahwa model yang dipilih tidak berkorelasi dan berdistribusi normal. Tujuannya adalah untuk mendapatkan model prediksi terbaik. Uji diagnostik dapat dibagi menjadi dua jenis pengujian yaitu uji distribusi normal dan uji *white noise*.

Berikut merupakan hipotesis uji *white noise* dengan menggunakan uji *Ljung-Box*:

1. Hipotesis
 $H_0: \rho_1 = \rho_2 = \dots = \rho_k = 0$ (Residual data bersifat *white noise*)
 H_1 : minimal terdapat satu $\rho_k \neq 0$ (Residual data tidak bersifat *white noise*).
2. Taraf Signifikansi α .
3. Statistik uji,

$$Q = n(n + 2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-k} \tag{11}$$

4. Kriteria penolakan
 tolak H_0 jika $p\text{-value} \leq \alpha$
 terima H_0 jika $p\text{-value} > \alpha$.
5. Kesimpulan
 Tolak H_0 jika $p\text{-value} \leq \alpha$, artinya residual data tidak bersifat *white noise*

Berikut merupakan hipotesis uji distribusi normal dengan menggunakan uji *Anderson Darling*:

1. Hipotesis
 H_0 : Residual berdistribusi normal
 H_1 : Residual tidak berdistribusi normal.
2. Taraf Signifikansi α .
3. Statistik uji,

$$A^2 = -n - \frac{1}{n} \sum_{i=1}^n (2i - 1) \left[\ln(F(X_{(i)})) + \ln(1 - F(X_{(n-i+1)})) \right] \tag{12}$$

4. Kriteria penolakan
 tolak H_0 jika $p\text{-value} \leq \alpha$
 terima H_0 jika $p\text{-value} > \alpha$
5. Kesimpulan
 Tolak H_0 jika $p\text{-value} \leq \alpha$, artinya residual tidak berdistribusi normal.

1.2 Pemodelan Box-Jenkins

Model Autoregressive Integrated Moving Average (ARIMA) sering digunakan dan dirujuk sebagai metode Box-Jenkins dalam analisis deret waktu. Model ARIMA merupakan salah satu metode peramalan kuantitatif dengan pendekatan deret waktu yang diterapkan pada informasi yang memiliki fluktuasi stasioner dalam mean dan *varians* [9,10]. ARIMA terdiri dari empat jenis utama, yaitu:

1. Model Autoregressive (AR)

[11] menyatakan bahwa model autoregresif merujuk pada metode ramalan dimana nilai-nilai sebelumnya dari variabel *time lag* saling berhubungan. Suatu model *time series* dianggap mengikuti proses model autoregresif ketika *lag-lag* pada *plot* ACF menurun dengan pola eksponensial, ketika *lag* yang berbeda dari nol pada *plot* PACF, selanjutnya mengindikasikan parameter p untuk model autoregresif, disebut AR (p), dinyatakan secara umum seperti ini:

$$Z_t = \mu + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + e_t \tag{13}$$

Proses autoregresif diperlukan untuk melakukan pengukuran hubungan antarvariabel antara nilai yang berurutan dari Z_t . Dalam mengidentifikasi gabungan AR dapat diamati dari pola umum ACF dan PACF sebagai berikut [11]:

Tabel 1. Identifikasi Model AR Berdasarkan Pola ACF dan PACF

Proses	ACF	PACF
AR(1)	Penurunan secara eksponensial; pada sisi positif jika $\phi_1 > 0$ dan terbalik pada sisi negatif jika $\phi_1 < 0$	Puncak di <i>lag</i> 1; lalu turun ke nol; puncak positif jika $\phi_1 > 0$, negatif jika $\phi_1 < 0$
AR(p)	Penurunan secara eksponensial atau bergelombang sinus yang dimampatkan. Pola tepatnya bergantung pada tanda dan besar ϕ_1, \dots, ϕ_p .	Puncak di <i>lag</i> 1 hingga p , lalu turun ke nol.

2. Model Moving Average (MA)

Moving Average (MA), sering disebut sebagai rata-rata bergerak, merupakan rangkaian waktu pada titik waktu tertentu yang dipengaruhi oleh kesalahan saat ini dan kesalahan yang diberi bobot pada masa lalu. Suatu deret waktu dipandang sebagai mengikuti proses MA ketika *lag-lag* pada ACF tidak nol, dan *lag* yang signifikan menurun secara eksponensial pada PACF, yang mengacu pada nilai parameter q . Struktur standar dari penyusunan MA dengan order q , atau $MA(q)$, dapat dinyatakan seperti ini:

$$Z_t = \mu + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \tag{14}$$

Persamaan itu menunjukkan bahwa nilai (Z_t) bergantung pada kesalahan sebelumnya bukan nilai variabelnya sendiri. Model *moving average* (MA) dipergunakan untuk mengevaluasi korelasi antara kesalahan dan sisa. Identifikasi metode MA dapat melihat dari pola ACF dan PACF berikut ini [11]:

Tabel 2. Identifikasi Model MA Berdasarkan Pola ACF dan PACF

Proses	ACF	PACF
MA(1)	Puncak di <i>lag</i> 1 lalu turun ke nol; puncak positif jika $\theta_1 < 0$, negatif jika $\theta_1 > 0$	Penurunan secara eksponensial; pada sisi negatif jika $\theta_1 > 0$ dan berbalik-balik tanda mulai dari sisi positif jika $\theta_1 < 0$
MA(q)	Puncak di <i>lag</i> 1 hingga q , lalu turun ke nol	Penurunan secara eksponensial atau gelombang sinus yang dimampatkan pola tepatnya tergantung pada tanda dan besar $\theta_1, \dots, \theta_q$

3. Model *Autoregressive Moving Average* (ARMA)

Model peramalan deret waktu bisa berupa *autoregressive* (AR), *moving average* (MA), atau kombinasi keduanya (ARMA). Formulasi umum dari model ARMA p, q dapat dinyatakan sebagai berikut:

$$\phi_p(B)Z_t = \mu + \theta_q(B)e_t \tag{15}$$

Persamaan tersebut menunjukkan bahwa permintaan bergantung pada nilai persamaan masa lalu dan *error* sebelumnya antara nilai permintaan aktual dengan nilai yang diprediksi. Nilai p dan q dalam model dapat ditentukan dengan menganalisis pola ACF dan PACF dari deret waktu. Secara keseluruhan, ACF dan PACF untuk model tersebut dapat diringkas sebagai berikut [11]:

Tabel 3. Identifikasi Model ARMA Berdasarkan Pola ACF dan PACF

Proses	ACF	PACF
ARMA (p, q)	Penurunan secara eksponensial atau gelombang sinus yang dimampatkan pola tepatnya tergantung pada tanda dan besar $\theta_1, \dots, \theta_q$.	Penurunan secara eksponensial atau gelombang sinus yang dimampatkan pola tepatnya tergantung pada tanda dan besar $\theta_1, \dots, \theta_q$.

4. Model *Autoregressive Integrated Moving Average* (ARIMA)

Model *Autoregressive Integrated Moving Average* (ARIMA) adalah versi non-stasioner dari model ARMA (p, q). Model tersebut memerlukan diferensiasi data untuk mencapai kestasioneran. Dalam model ARMA, diferensiasi orde ke- d dilakukan untuk membuat deret waktu menjadi stasioner. Oleh sebab itu, model ARMA(p, q) diubah menjadi model yang $ARIMA(p, d, q)$. Bentuk umum model $ARIMA(p, d, q)$ adalah seperti berikut:

$$\phi_p(B)(B - 1)^d Z_t = \mu + \theta_q(B)e_t \tag{16}$$

Secara umum, terdapat tiga fase dalam membangun model ARIMA [12]. Langkah pertama adalah mengidentifikasi model ARIMA yang sesuai, Apakah deret waktu tersebut dapat dideskripsikan dengan model *autoregressive* (AR) orde p atau *moving average* (MA) orde q , serta apakah data tersebut non-stasioner sehingga memerlukan *differencing*. Proses identifikasi model yang cocok dapat dilakukan dengan menganalisis ACF dan PACF dari deret waktu. Tahap berikutnya adalah pemilihan model, di mana parameter model AR dan MA akan diestimasi menggunakan metode seperti *least square* dan *maximum likelihood*. Tahap ketiga melibatkan uji diagnostik untuk mengevaluasi kecocokan model yang dipilih untuk proses peramalan. Jika model tidak memenuhi standar kualitas, maka proses akan diulang dari awal. Namun, jika model terbukti memadai, maka dapat dilakukan peramalan tanpa penyesuaian lebih lanjut.

Penentuan model yang optimal bergantung pada evaluasi dua kriteria utama, yaitu *criteria in-sample dan out-sample*. Dalam penilaian *criteria in-sample*, model terbaik sering dipilih berdasarkan nilai terkecil dari AIC (*Akaike Information Criterion*). AIC digunakan untuk mengevaluasi kompleksitas model dengan mempertimbangkan jumlah parameter yang digunakan. Berikut adalah formulasi untuk menghitung nilai AIC [7]:

$$AIC = -2 \ln \hat{\sigma}_a^2 + 2C \tag{17}$$

dengan:

- $\hat{\sigma}_a^2$ = estimasi maksimum likelihood dari σ_a^2
- C = banyaknya parameter dalam model
- n = banyaknya pengamatan

Terlebih lagi, dalam pemilihan model terbaik, alternatif lain adalah menggunakan akurasi berdasarkan kesalahan, Evaluasi tingkat kesalahan menggunakan *Root Mean Square Error* (RMSE) dijelaskan dalam persamaan berikut:

$$RMSE = \sqrt{\frac{1}{R} \sum_{r=1}^R (X_{n+r} - \hat{X}_n(r))^2} \tag{18}$$

Sedangkan perhitungan *Mean Absolute Percentage Error* (MAPE) ditunjukkan dalam persamaan berikut:

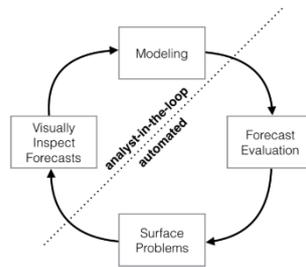
$$MAPE = \frac{\sum_{r=1}^R \left| \frac{X_{n+r} - \hat{X}_n(r)}{X_{n+r}} \right|}{R} \times 100\% \tag{19}$$

1.3 Metode Prophet

Metode Prophet adalah algoritma peramalan *time series* yang dikembangkan oleh *Facebook Research* pada tahun 2017. Algoritma ini dirancang khusus untuk menangani peramalan *time series* dengan skala besar yang sering ditemui dalam aplikasi praktis seperti peramalan penjualan, peramalan lalu lintas web, dan lainnya. Metode Prophet telah menjadi populer di kalangan praktisi data *science* karena kemampuannya dalam menangani beberapa tantangan yang sering muncul dalam peramalan *time series*.

Prophet menggunakan pendekatan yang berbeda dari metode tradisional seperti *Autoregressive Integrated Moving Average* (ARIMA) atau *Exponential Smoothing*. Algoritma ini berdasarkan pada model aditif yang menggabungkan tiga komponen utama dari *time series*: *tren*, musimanitas, dan efek liburan (jika ada). Prophet menggunakan pendekatan penyesuaian terhadap tren yang dapat mengakomodasi tren non-linear, serta memberikan fleksibilitas dalam menangani data dengan jeda yang besar.

Salah satu fitur utama dari Prophet adalah kemampuannya untuk menangani data yang tidak stasioner secara langsung. Dalam banyak kasus, data *time series* mungkin tidak memenuhi asumsi stasioneritas yang diperlukan oleh metode peramalan tradisional. Namun, Prophet dapat menyesuaikan dengan baik terhadap data yang memiliki tren atau fluktuasi yang tidak konstan sepanjang waktu. Benjamin Letham menggambarkan bentuk peramalan berskala terlihat dalam gambar berikut:



Gambar 1. Pola Pendekatan *Forecasting At Scale*

Prophet menggunakan model *time series* yang dapat dipecah menjadi tiga komponen: *trend*, *seasonal*, dan *irregular*. Jadi, formulasi model adalah sebagai berikut:

$$y_{(t)} = g_{(t)} + s_{(t)} + h_{(t)} + \varepsilon_{(t)} \tag{20}$$

Prophet menggunakan waktu sebagai variabel prediktor dan dapat menyesuaikan persamaan deret waktu linear dan non-linear sebagai bagian dari model. Pendekatan aditif digunakan untuk pemodelan musiman, mirip dengan teknik Holt-Winters dalam *Exponential Smoothing*. Prophet melihat masalah peramalan sebagai kurva yang cocok dengan data, daripada bergantung pada hubungan eksplisit antara setiap pengamatan dalam seri waktu.

1.4 Kontrasepsi dan Kesehatan Reproduksi

Asal muasal istilah "kontrasepsi" berasal dari penggabungan kata "kontra" yang artinya mencegah dengan kata "konsepsi" yang merujuk pada pertemuan sel telur dan sel sperma. Dengan demikian, kontrasepsi digunakan untuk mencegah kehamilan dan mengatur jumlah anak yang diinginkan serta mengurangi risiko kematian ibu dan bayi. Manfaat penggunaan kontrasepsi juga termasuk memenuhi hak reproduksi individu dan menghindari kehamilan yang tidak diinginkan. Alat kontrasepsi memiliki variasi bentuk dengan efek samping, indikasi, dan kontraindikasi yang bervariasi. Akibatnya, tingkat keberhasilan atau efektivitas setiap jenis kontrasepsi dapat berbeda-beda.

Penggunaan metode kontrasepsi yang berkualitas dalam program Keluarga Berencana (KB) akan membantu meningkatkan kesehatan reproduksi serta kesehatan seksual. Kesehatan reproduksi merujuk pada kondisi keseluruhan yang meliputi aspek mental, kondisi fisik dan sosial yang memadai, tidak hanya mencakup kondisi bebas penyakit atau kelainan dalam sistem reproduksi, tetapi juga fungsinya dan prosesnya.

Metode kontrasepsi jangka panjang dikenal efektif dan jarang menyebabkan komplikasi atau efek samping dibandingkan dengan metode non-MKJP. Metode kontrasepsi jangka panjang dapat digunakan dalam rentang waktu yang panjang, dari 3 tahun hingga seumur hidup. Terdapat beragam jenis metode kontrasepsi jangka panjang yang tersedia:

1. IUD, *Intrauterine device*
2. Implan.

3. Tindakan bedah medis untuk wanita (MOP).
4. Operasi medis untuk pria (MOP).

2. METODE

Data yang digunakan dalam penelitian ini termasuk data *time series* sekunder tentang pengguna KB MKJP aktif dari BKKBN Provinsi Bengkulu. Data direkap setiap bulan dan dikelompokkan berdasarkan bulan dan nama alat kontrasepsi MKJP dimana setiap jenis alat kontrasepsi memiliki satu dataset dengan 144 data observasi.

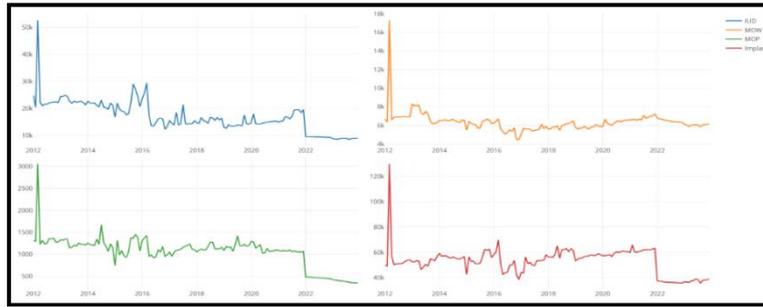
Langkah-langkah yang akan diambil untuk mencapai tujuan penelitian ini adalah sebagai berikut:

1. Mempersiapkan Informasi dan Melakukan Data *Pre-Processing*.
Tindakan pertama yang diambil adalah melakukan observasi data serta memecah data menjadi informasi berdasarkan masing-masing alat kontrasepsi. Setelah itu dilakukan analisis deskriptif sederhana dari data bulanan pengguna alat kontrasepsi MKJP pada masing-masing variabel tunggal alat kontrasepsi MKJP.
2. Melakukan Analisis ARIMA
Dalam analisis deret waktu dengan metode ARIMA, beberapa langkah yang perlu dilakukan meliputi:
 - a. Memisahkan data menjadi data *training* dan data *testing*.
 - b. Uji Stasioneritas Data.
Tahapan selanjutnya adalah melakukan pemeriksaan apakah data deret waktu yang dimiliki bersifat stasioner atau tidak. Data dikatakan stasioner dalam *varians* jika angka λ sebesar satu atau telah melewati nilai satu [13]. Selanjutnya dilakukan uji stasioner dalam *mean*.
 - c. Transformasi Data.
Apabila setelah dilakukan uji stasioneritas data, diketahui bahwa data tidak atau belum stasioner, sehingga transformasi data diperlukan. Ada berbagai macam cara yang bisa dimanfaatkan untuk melakukan perubahan data sehingga data menjadi stasioner, diantaranya *log-scale transformation* atau *time-shifting transformation*.
 - d. Identifikasi Model.
3. Peramalan dengan Menggunakan Metode Prophet
Untuk melakukan analisis deret waktu menggunakan metode Prophet, beberapa tahapan yang akan dilakukan diantaranya:
 - a. Data *Preprocessing*
Sebagai persiapan perlu dilakukan *preprocessing* data sebagai penyiapan data yang akan dimasukkan ke dalam model. Data *preprocessing* sebagai kegiatan agar data siap digunakan dalam sebuah model. Dalam peramalan deret waktu, data akan disiapkan dengan mempertimbangkan komponen 'ds' dan 'y'. komponen 'ds' berisi tanggal atau waktu yang mendefinisikan titik data dalam deret waktu. Komponen 'y' berisi nilai dari variabel yang ingin diprediksi atau dianalisis. Hanya kedua komponen tersebut yang akan dimasukkan ke dalam model, sedangkan komponen lainnya tidak akan digunakan.
 - b. Data *Transformation*
Data *Transformation* dilakukan dengan membagi data menjadi data *training* dan data *testing* guna mengevaluasi keakuratan prediksi model terhadap data asli yang diprediksi, menjadi langkah dasar dalam penilaian kinerja model.
 - c. Menerapkan algoritma *Prophet* dengan menggunakan *Decomposable Time Series Model* yang memiliki tiga komponen utama yaitu *Trend*, *Seasonality*, dan *Holidays*.
 - d. Evaluasi Model
Evaluasi model bertujuan untuk mengevaluasi akurasi prediksi dengan membandingkan data *training* dan *testing*. Evaluasi menggunakan *Mean Absolute Percentage Error (MAPE)* untuk menilai ketepatan prediksi model terhadap data uji.
4. Membandingkan Performa Metode ARIMA dan Prophet
Dilakukan perbandingan untuk menentukan metode mana diantara ARIMA dan Prophet yang merupakan metode peramalan terbaik. Evaluasi dilakukan dengan membandingkan nilai AIC, RMSE dan MAPE dari kedua metode tersebut.
5. Melakukan peramalan pengguna alat kontrasepsi MKJP menggunakan metode terbaik hasil perbandingan performa.

3. HASIL DAN PEMBAHASAN

3.1 Plot Deret Waktu

Plot deret waktu digunakan untuk mengidentifikasi pola data dan dapat dilihat pada Gambar 2.



Gambar 2. Plot deret waktu jumlah pengguna KB aktif alat kontrasepsi MKJP

Berdasarkan Gambar 2 didapatkan bahwa *plot* deret waktu data jumlah pengguna KB aktif setiap bulannya untuk alat kontrasepsi MKJP periode Januari 2012 s.d. Desember 2023 tidak stabil setiap bulannya dan cenderung memiliki pola trend turun. Pada *plot* jumlah pengguna KB aktif alat kontrasepsi MKJP yaitu IUD, MOW, MOP dan IMPLANT terdapat pola tren naik pada bulan Maret tahun 2012 dan cenderung mengalami penurunan setiap bulannya.

3.2 Analisis Deskripsi

Rangkuman analisis statistik deskriptif dari data penelitian terdapat dalam Tabel di bawah:

Tabel 4. Statistik Deskriptif

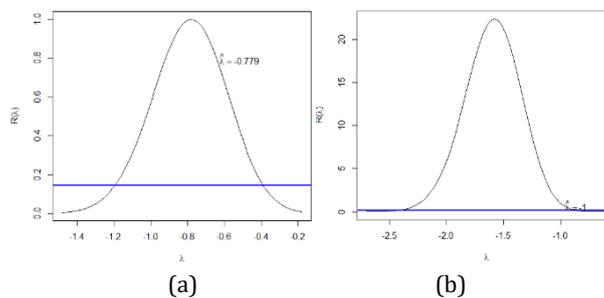
Nama Data	Minimum	Maximum	Mean	St. Dev
IUD	8556	52578	17022.04	5799.331
MOW	4483	17296	6352.21	1105.795
MOP	348	3058	1057.09	347.672
IMPLANT	35967	129933	53048.56	10676.151

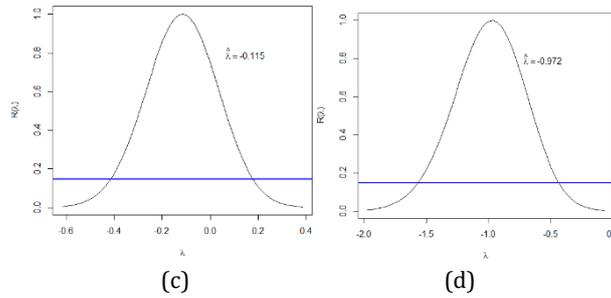
Tabel 4 menunjukkan IUD menunjukkan variasi yang signifikan dalam jumlah pengguna setiap bulannya, dengan rentang antara 8.556 hingga 52.578. Rata-rata penggunaan IUD sebesar 17.022,04, dengan deviasi standar mencapai 5.799,331. Sementara itu, MOW menampilkan variasi yang lebih terbatas dibandingkan dengan IUD, dengan jumlah pengguna berkisar antara 4.483 hingga 17.296. Rata-rata penggunaan MOW adalah 6.352,21, dengan deviasi standar sebesar 1.105,795. Pada kontrasepsi MOP, meskipun memiliki rentang yang lebih kecil, menunjukkan tingkat konsistensi yang cukup baik dalam jumlah penggunaannya. Rentang pengguna MOP berkisar antara 348 hingga 3058, dengan rata-rata 1057.09 dan deviasi standar 347.672. Di sisi lain, Implant memiliki variasi yang paling signifikan di antara jenis kontrasepsi lainnya, dengan rentang antara 35967 hingga 129933. Rata-rata penggunaan Implant mencapai 53048,56, dengan deviasi standar yang cukup tinggi, yaitu 10676.151.

3.3 Uji Stasioneritas Data

1. Stasioner Terhadap Varians

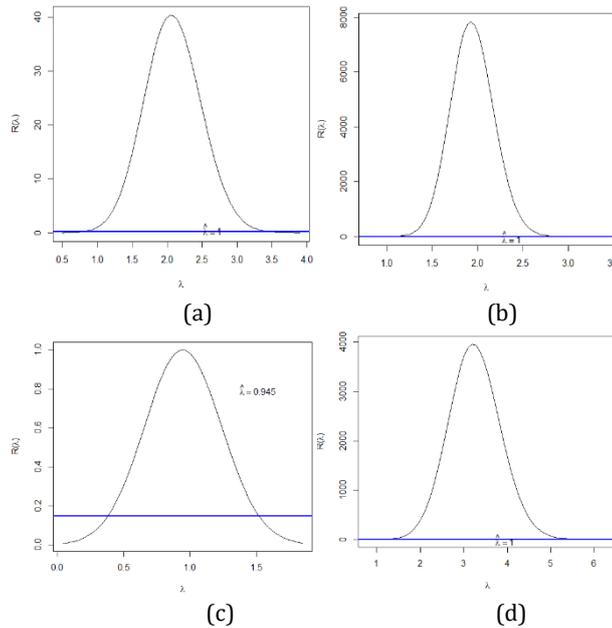
Data stasioner terhadap varians dianalisis menggunakan uji Box-Cox untuk menentukan nilai λ dan mengevaluasi transformasi data. Visualisasi *plot* uji Box-Cox dari jumlah pengguna KB aktif IUD, MOW, MOP, dan Implant dapat dilihat pada Gambar 3:





Gambar 3. Plot uji Box-Cox data aktual (a) IUD, (b) MOW, (c) MOP dan (d) IMPLANT

Hasil uji Box-Cox pada Gambar 3 menunjukkan bahwa nilai λ pada data aktual jumlah pengguna KB aktif alat kontrasepsi MKJP (IUD, MOW, MOP, dan IMPLANT) belum mendekati 1, menunjukkan data belum stasioner terhadap varians dan memerlukan transformasi. Visualisasi *plot* uji Box-Cox setelah transformasi pada data tersebut dapat dilihat pada Gambar 6:



Gambar 4. Plot uji Box-Cox data transformasi (a) IUD, (b) MOW, (c) MOP dan (d) IMPLANT

Dari *plot* uji Box-Cox setelah transformasi data jumlah pengguna KB aktif alat kontrasepsi MKJP (IUD, MOW, MOP, dan IMPLANT) pada Gambar 4, terlihat bahwa nilai λ mendekati 1. Ini menunjukkan bahwa data tersebut telah stasioner terhadap varians setelah dilakukan transformasi.

2. Stasioner Terhadap Mean

Untuk menilai apakah data stasioner terhadap *mean*, digunakan metode *plot* ACF dan PACF serta uji statistik seperti *Augmented Dickey-Fuller* (ADF). Uji ADF melibatkan pengujian hipotesis yang spesifik:

H_0 : Data tidak menunjukkan sifat stasioner terhadap *mean*

H_1 : Data menunjukkan sifat stasioner terhadap *mean*.

Hasil uji ADF berdasarkan level *differencing* yang dilakukan tersaji dalam Tabel 5:

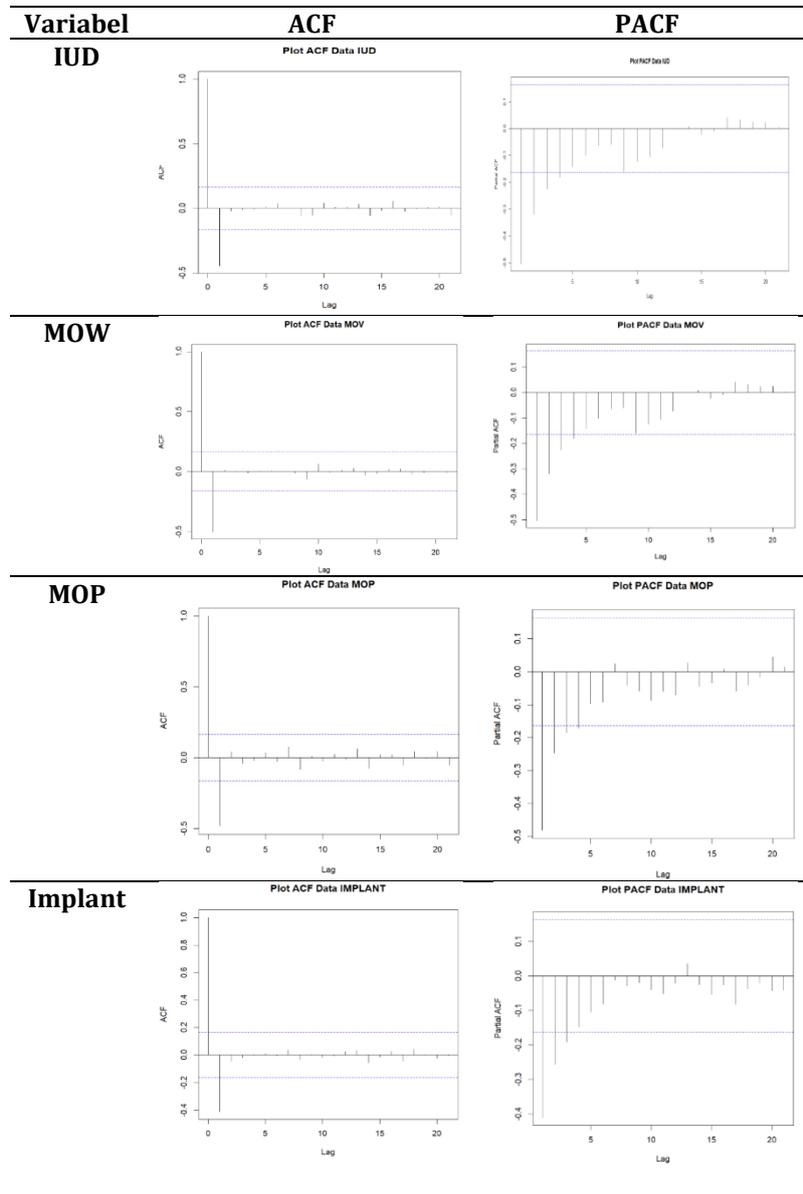
Tabel 5. Hasil uji stasioner terhadap *mean* jumlah PA MKJP

Data	P-value	
	Differencing (d=0)	Differencing (d=1)
IUD	0.08481	0.01
MOW	0.4053	0.01
MOP	0.7152	0.01
Implant	0.5703	0.01

Hasil uji stasioner terhadap *mean* pada Tabel 5 menunjukkan bahwa data jumlah pengguna KB aktif untuk IUD, MOW, MOP, dan Implant menunjukkan stasioner setelah dilakukan *differencing* satu kali (d=1). Nilai *p-value* sebesar 0,01 yang lebih kecil dari tingkat signifikansi α sebesar 0,05, sehingga hipotesis nol ditolak dan data telah stasioner. Kesimpulannya, data jumlah pengguna KB aktif IUD, MOW, MOP, dan Implant telah stasioner terhadap *mean*.

3.4 Identifikasi Model

Identifikasi model sementara melibatkan perkiraan nilai parameter model berdasarkan *plot* ACF dan PACF dari data jumlah pengguna KB aktif IUD, MOW, MOP, dan Implant yang sudah stasioner terhadap mean dan *varians*. Adapun kemungkinan model tersebut adalah AR (p), MA (q) dan ARMA (p, q) untuk model non musiman. Order p non musiman ditentukan melalui *plot* PACF, sedangkan order q non musiman ditentukan melalui *plot* ACF. Berikut adalah *plot* ACF dan PACF non-musiman data jumlah pengguna KB aktif kontrasepsi IUD, MOW, MOP dan Implant adalah sebagai berikut:



Gambar 5. *Plot* ACF dan PACF *differencing* ($d=1$) data (a) IUD, (b) MOW, (c) MOP dan (d) IMPLANT

Pada Gambar 5 *plot* ACF dan PACF non-musiman untuk data jumlah pengguna KB aktif IUD, MOW, MOP, dan Implant dengan *differencing* satu kali ($d=1$), terlihat bahwa kedua *plot* menurun secara eksponensial. Berdasarkan kriteria model non-musiman diperoleh bahwa, model jumlah pengguna KB aktif kontrasepsi IUD, MOW, MOP dan Implant adalah model ARIMA (p, d, q) setelah *differencing* satu kali ($d = 1$).

3.5 Model ARIMA

Uji signifikansi parameter model ARIMA terbaik dapat dilihat pada tabel berikut:

Tabel 6. Uji Signifikansi Parameter Model Terbaik

Model IUD ARIMA (0,1,1)

Parameter	Estimasi	P-value	Keterangan
MA(1) θ_1	-0,6955	$2,2 \times 10^{-16}$	Signifikan
Model MOW ARIMA (0,1,1)			
MA(1) θ_1	-0,8517	$2,2 \times 10^{-16}$	Signifikan
Model MOP ARIMA (0,1,1)			
MA(1) θ_1	-0,7016	$2,2 \times 10^{-16}$	Signifikan
Model IMPLANT ARIMA (0,1,1)			
MA(1) θ_1	-0,7302	$1,817 \times 10^{-9}$	Signifikan

Dari hasil pengujian signifikansi parameter dalam Tabel 9, didapati bahwa $p - value$ semua parameter pada semua model kurang dari $\alpha = 0.05$, mengindikasikan penolakan H_0 dan signifikansi parameter model. Oleh karena itu, dapat disimpulkan bahwa setiap parameter pada model jumlah pengguna KB aktif kontrasepsi IUD, MOW, MOP, dan Implant signifikan pada tingkat signifikansi 5%. Detail persamaan model ARIMA terdapat dalam tabel berikut:

Tabel 7. Model Terbaik ARIMA

Varriabel	Model yang Terbentuk
IUD	$Y_t = -0.6955e_{t-1}$
MOW	$Y_t = -0.8517e_{t-1}$
MOV	$Y_t = -0.7016e_{t-1}$
IMPLANT	$Y_t = -0.6985e_{t-1}$

3.6 Uji Diagnostik Model

Dari beberapa model arima yang terbentuk berdasarkan *plot* ACF dan PACF diperoleh model terbaik dengan nilai AIC terkecil pada setiap variabel adalah sebagai berikut:

Tabel 8. Model ARIMA Terpilih

Variabel	Model	AIC
IUD	ARIMA (0,1,1)	2752.565
MOW	ARIMA (0,1,1)	2379.792
MOP	ARIMA (0,1,1)	1929.62
IMPLANT	ARIMA (0,1,1)	2995.133

1. Uji *White Noise*

Uji Ljung-Box digunakan untuk menentukan apakah galat model adalah *white noise*, dengan hipotesis yang dinyatakan sebagai berikut:

1. Hipotesis

$H_0: \rho_1 = \rho_2 = \dots = \rho_k = 0$ (Residual data bersifat *white noise*)

H_1 : minimal terdapat satu $\rho_k \neq 0$ (Residual data tidak bersifat *white noise*).

2. Taraf Signifikansi $\alpha = 0.05$.

3. Statistik uji

$x - squared = 0.17221$ $p - value = 0.6782$.

4. Kriteria penolakan

tolak H_0 jika $p - value \leq \alpha$

terima H_1 jika $p - value > \alpha$.

5. Kesimpulan

Oleh karena nilai $p - value = 0.6782 \geq 0.05$, artinya residual data bersifat *white noise*.

Hasil uji asumsi residual *white noise* untuk semua model tersedia dalam lampiran 4. Informasi lengkap mengenai uji asumsi residual *white noise* dapat ditemukan dalam Tabel 7 sebagai berikut:

Tabel 9. Uji *White Noise* Semua Model

Variabel	xSquared	Nilai P-value	Keputusan	Keterangan
IUD	0.17221	0.6782	H_0 diterima	Bersifat <i>white noise</i>
MOW	0.050501	0.8222	H_0 diterima	Bersifat <i>white noise</i>
MOP	0.000429	0.9835	H_0 diterima	Bersifat <i>white noise</i>
IMPLANT	0.8576	0.3544	H_0 diterima	Bersifat <i>white noise</i>

Berdasarkan Tabel 7, hasil pengujian *white noise* menunjukkan bahwa semua model jumlah pengguna KB aktif kontrasepsi IUD, MOW, MOP, dan Implant memiliki $p - value$ yang lebih besar dari nilai signifikansi $\alpha = 0.05$, yang mengindikasikan penolakan H_0 . Oleh karena itu, kesimpulannya adalah semua model memenuhi kriteria *white noise*.

2. Uji Normalitas Residual

Untuk mengevaluasi normalitas residual dalam model, uji normalitas seperti uji *Anderson D* dapat dilakukan dengan merumuskan hipotesis sebagai berikut:

1. Hipotesis

H_0 : Residual berdistribusi normal

- H_1 : Residual tidak berdistribusi normal.
- 2. Taraf Signifikansi $\alpha = 0.05$.
- 3. Statistik uji
 $A = 11.431, p - value < 2.2 \times 10^{-16}$.
- 4. Kriteria penolakan
tolak H_0 jika $p - value \leq \alpha$
terima H_0 jika $p - value > \alpha$.
- 5. Kesimpulan
Oleh karena nilai $p - value = 2.2 \times 10^{-16} \leq \alpha = 0.05$ maka H_0 ditolak, artinya residual tidak berdistribusi normal. Berikut merupakan tabel yang diperoleh dari uji normalitas untuk model setiap variable:

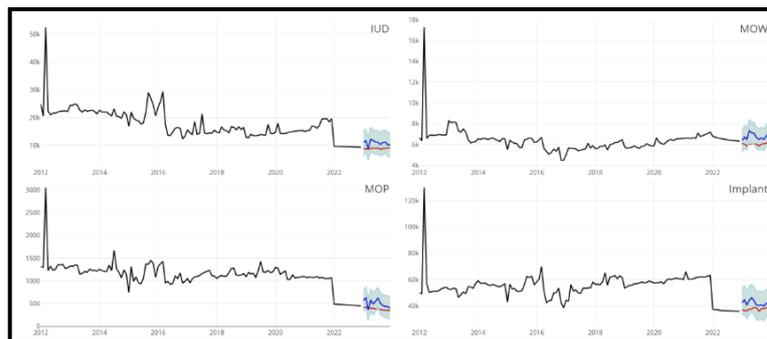
Tabel 10. Hasil Uji Normalitas Residual

Variabel	Nilai A	Nilai P-value	Keputusan	Keterangan
IUD	11.431	2.2×10^{-16}	H_0 ditolak	Tidak berdistribusi normal
MOW	14.129	2.2×10^{-16}	H_0 ditolak	Tidak berdistribusi normal
MOP	11.312	2.2×10^{-16}	H_0 ditolak	Tidak berdistribusi normal
IMPLANT	14.979	2.2×10^{-16}	H_0 ditolak	Tidak berdistribusi normal

Berdasarkan Tabel 8 hasil uji normalitas menunjukkan bahwa $p - value$ untuk semua model jumlah pengguna KB aktif kontrasepsi IUD, MOW, MOP, dan Implant lebih kecil dari nilai $\alpha = 0.05$, yang berarti H_0 tidak dapat ditolak. Dengan demikian, dapat disimpulkan bahwa distribusi dari semua model jumlah pengguna KB aktif kontrasepsi IUD, MOW, MOP, dan Implant, yaitu ARIMA (0,1,1), tidak normal.

3.7 Model PROPHET

Model Prophet merupakan metode yang fleksibel dan intuitif untuk memprediksi jumlah pengguna KB aktif kontrasepsi IUD, MOW, MOP dan Implant menggunakan data deret waktu hal ini dikarenakan prediksi yang dilakukan berdasarkan model aditif dan dirancang untuk menangani tren, musiman, dan hari libur [14]. Untuk lebih jelasnya berikut ditampilkan grafik.



Gambar 6. Plot Deret Waktu Data Training dan Data Testing

Berdasarkan gambar 6 pada *plot* deret waktu data *training* dan data *testing* terlihat pada grafik bahwa nilai-nilai yang berwarna merah adalah data *testing* periode Januari 2023 s.d Desember 2023 untuk jumlah pengguna KB aktif kontrasepsi IUD, MOW, MOP, dan Implant. Berdasarkan grafik yang paling terlihat bedanya adalah disekitar Januari 2022 yang mengalami trend penurunan. Sehingga dari grafik yang ditampilkan secara sederhana bisa disimpulkan bahwa prediksi model masih bisa dikembangkan, karena pada dasarnya nilai prediksi terbaik adalah yang paling mendekati nilai aktualnya. Namun untuk lebih jelasnya dalam penentuan model terbaik perlu melihat evaluasi model.

Algoritma *Prophet* pada penelitian ini dengan menggunakan *Decomposable Time Series Model* yang memiliki tiga komponen utama yaitu *Trend*, *Seasonality*, dan *Holidays*. Sehingga pada pemodelan prophet ini dilakukan optimasi *hyperparameter* untuk mendapatkan model terbaik. Pada model prophet ini paramater yang akan dioptimasi adalah *prior scale (change point, seasonality, holiday)* dan *seasonality (weekly, daily)*.

Tabel 11. Hyperparameter Prophet yang di Optimasi

Hyperparameter	Nilai
<i>change point prior scale</i>	[0,05]
<i>seasonality prior scale</i>	[10]
<i>holiday prior scale</i>	[10]
<i>Seasonality weekly</i>	[True, False]
<i>Seasonality daily</i>	[True, False]

Berdasarkan Tabel 11 memberikan informasi *hyperparameter* yang dioptimasi agar model prophet yang digunakan bisa mencapai performa terbaiknya. Skala superioritas (*superior scale*) bisa merujuk pada nilai atau ukuran yang menunjukkan tingkat keunggulan atau superioritas suatu fenomena atau model dalam analisis tersebut. Dalam konteks

Prophet, *change point prior scale* mengacu pada parameter yang mengontrol fleksibilitas atau jumlah titik perubahan yang dapat dipertimbangkan dalam model peramalan deret waktu. Nilai "*change point prior scale*" adalah faktor skala yang mempengaruhi seberapa sering Prophet akan menemukan titik perubahan dalam data.

Diketahui dalam penelitian ini jika nilai *change point prior scale* ditetapkan pada 0.05, maka prophet akan cenderung menemukan perubahan tren dalam data deret waktu. Nilai 0.05 menunjukkan bahwa prioritas terhadap titik perubahan cukup rendah, sehingga prophet akan cenderung memilih titik perubahan yang lebih signifikan dalam tren data. Dengan mengatur *change point prior scale* pada nilai rendah seperti 0.05, pengguna dapat mengontrol kompleksitas model prophet dan mengurangi kemungkinan *overfitting* terhadap data deret waktu yang mungkin memiliki fluktuasi acak yang tidak signifikan.

Seasonality prior scale digunakan untuk menentukan seberapa besar pengaruh musiman atau *seasonality* pada model peramalan deret waktu. Secara khusus, parameter *seasonality prior scale* dalam Prophet mengontrol seberapa kuat pengaruh musiman pada peramalan. Dengan nilai minimum 10, semakin besar nilainya, semakin besar pengaruh musiman dalam model peramalan, yang berarti prophet akan lebih memperhatikan pola musiman dalam data deret waktu.

Seasonality prior scale dengan nilai 10 dapat diartikan bahwa dalam model prophet yang digunakan untuk peramalan, skala prioritas untuk pengaruh musiman telah ditetapkan pada nilai 10, menunjukkan bahwa pengaruh musiman dianggap cukup signifikan dalam analisis peramalan tersebut. *Holiday prior scale* mengacu pada parameter yang mengatur seberapa besar pengaruh libur atau hari libur (*holidays*) terhadap model peramalan deret waktu. Nilai *holiday prior scale* pada 10 menunjukkan tingkat prioritas yang tinggi terhadap pengaruh hari libur dalam model peramalan.

Nilai *holiday prior scale* ditetapkan pada nilai 10 maka prophet akan memberikan bobot yang signifikan pada pengaruh hari libur dalam proses peramalan. Hal ini berarti prophet akan cenderung memperlakukan hari libur sebagai peristiwa yang memiliki dampak besar pada data deret waktu, sehingga hari libur akan mempengaruhi hasil peramalan dengan cara yang lebih kuat.

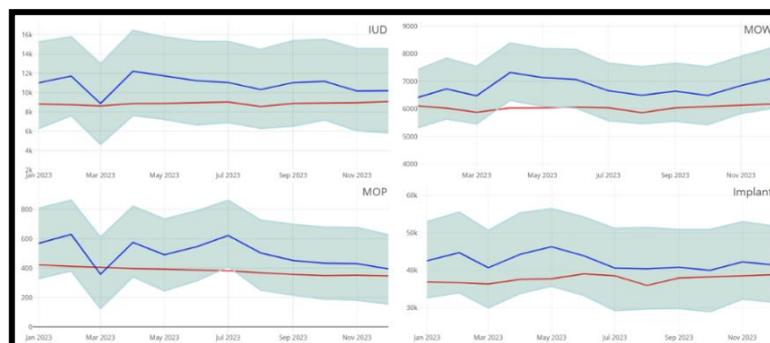
Pengaturan nilai *holiday prior scale* yang tinggi seperti nilai 10 berguna ketika hari libur atau peristiwa khusus memiliki dampak yang signifikan dan dapat diidentifikasi dengan jelas dalam data deret waktu yang dianalisis. Hal ini memungkinkan prophet untuk secara akurat menyesuaikan model peramalan dengan adanya hari libur atau peristiwa serupa yang berpengaruh besar dalam pola data.

Seasonality weekly dengan nilai [*True, False*] pada prophet mengontrol apakah peramalan akan mempertimbangkan pola musiman mingguan atau tidak. Jika diatur sebagai [*True, False*], maka prophet akan mempertimbangkan pola musiman mingguan dalam model peramalan. Sedangkan jika diatur sebagai [*False*] maka prophet tidak akan mempertimbangkan pola musiman mingguan.

Parameter *Seasonality daily* dengan nilai [*True, False*] dalam prophet mengontrol apakah model peramalan akan mempertimbangkan pola musiman harian atau tidak. Jika diatur sebagai [*True*] maka prophet akan mempertimbangkan pola musiman harian dalam model peramalan. Sedangkan jika diatur sebagai [*False*] maka prophet tidak akan mempertimbangkan pola musiman harian.

Pada Lampiran 5 adalah potongan code untuk melakukan peramalan dengan model prophet. Setelah mendefinisikan *hyperparameter* yang akan digunakan untuk melatih model prophet, langkah selanjutnya adalah melakukan perulangan terhadap kombinasi *hyperparameter* yang digunakan. Model terbaik kemudian digunakan untuk melakukan peramalan terhadap data jumlah pengguna KB aktif kontrasepsi IUD, MOW, MOP, dan Implant.

Setelah melakukan pemodelan data maka didapatkanlah *hyperparameter* terbaik dari model prophet yaitu nilai *change point prior scale* adalah [0,05], *seasonality prior scale* dan *holiday prior scale* adalah [10], *Seasonality weekly* adalah [*True, False*] dan *Seasonality daily* adalah [*True, False*].



Gambar 7. Prediksi Model Prophet

Selanjutnya hasil peramalan dari model terbaik setelah proses pelatihan divisualisasikan seperti yang terlihat pada gambar 7 pada model prophet terdapat istilah *uncertainly interval* atau interval ketidakpastian ini adalah interval yang mengukur tingkat ketidakpastian dalam peramalan. *Interval* ini mencerminkan variasi yang mungkin terjadi dalam data atau kesalahan dalam model. pada grafik dapat dilihat bahwa nilai prediksi (biru) menggunakan model prophet kurang

baik karena nilai nya berbeda jauh dengan data testing (merah), serta menunjukkan pola data yang berbeda. Hal ini bisa menjadi indikasi awal bahwa model ARIMA lebih baik daripada model Prophet sehingga perlu dilakukan perbandingan menggunakan uji kebaikan dan keakuratan model.

3.8 Uji Kebaikan dan Keakuratan Model

Pemilihan model optimal didasarkan pada *Akaike Information Criterion* (AIC) dan evaluasi performa peramalan menggunakan *Mean Absolute Percentage Error* (MAPE) serta *Root Mean Square Error* (RMSE). Semakin rendah nilai AIC, MAPE, dan RMSE, semakin baik hasil peramalan. Dari uji diagnostik, terdapat empat model yang sesuai dengan asumsi: IUD ARIMA(0,1,1), MOW ARIMA(0,1,1), MOP ARIMA(0,1,1), dan IMPLANT ARIMA(0,1,1). Berikut adalah perbandingan antara model ARIMA dengan model Prophet berdasarkan nilai MAPE dan RMSE yang lebih rendah, seperti yang tercantum dalam tabel:

Tabel 12. Uji Kebaikan Model ARIMA dan PROPHET

Model	AIC	MAPE	RMSE
IUD	2752.565	10.499	3589.008
MOW	2379.792	6.372	972.648
MOP	1929.620	10.432	201.975
IMPLANT	2995.133	7.060	8381.189
IUD	<i>null</i>	22.903	2190.612
MOW	<i>null</i>	12.181	788.684
MOP	<i>null</i>	33.030	140.930
IMPLANT	<i>null</i>	12.345	5101.892

Berdasarkan hasil uji kebaikan model jumlah pengguna KB aktif kontrasepsi IUD, MOW, MOP dan Implant antara model ARIMA dengan model PROPHET pada tabel 12 diketahui bahwa model ARIMA merupakan model terbaik berdasarkan nilai MAPE terkecil.

3.9 Penerapan Model dan Peramalan

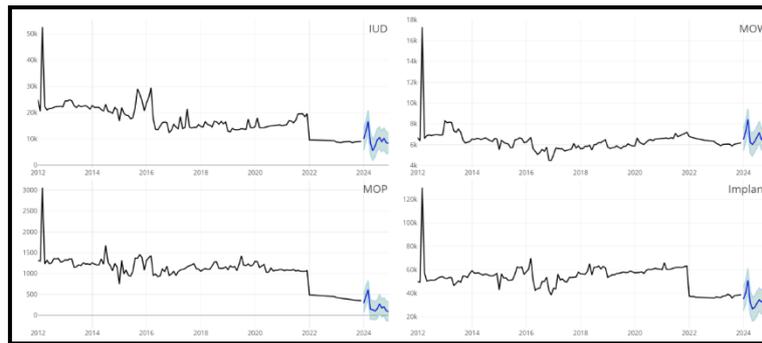
Setelah mendapatkan model terbaik, langkah berikutnya adalah melakukan proses peramalan untuk variabel IUD, MOW, MOP, dan IMPLANT dari Januari hingga Desember 2024, yang tercantum dalam tabel berikut:

Tabel 13. Hasil Peramalan Menggunakan Arima

Bulan	ARIMA				PROPHET			
	IUD	MOW	MOP	Implant	IUD	MOW	MOP	Implant
Jan	8949.53	6128.03	359.89	38241.30	10047	6501	288	35153
Feb	8949.53	6128.03	359.89	38241.30	13041	7276	474	40502
Mar	8949.53	6128.03	359.89	38241.30	16742	8417	614	50957
Apr	8949.53	6128.03	359.89	38241.30	8535	6216	143	32269
Mei	8949.53	6128.03	359.89	38241.30	5593	6028	131	26771
Jun	8949.53	6128.03	359.89	38241.30	7168	6305	97	28151
Jul	8949.53	6128.03	359.89	38241.30	9586	6720	150	31504
Agu	8949.53	6128.03	359.89	38241.30	10507	7149	269	34466
Sep	8949.53	6128.03	359.89	38241.30	9041	6454	177	32655
Okt	8949.53	6128.03	359.89	38241.30	10168	6764	198	33399
Nov	8949.53	6128.03	359.89	38241.30	8617	6453	106	29470
Des	8949.53	6128.03	359.89	38241.30	8345	6202	79	28562

Tabel 13 menunjukkan hasil ramalan jumlah pengguna KB aktif kontrasepsi IUD, MOW, MOP dan Implant periode Januari s.d. Desember 2024. Berdasarkan hasil peramalan menggunakan metode Arima pada variabel IUD diperoleh hasil 8949.53 untuk setiap bulannya, pada variable MOW diperoleh hasil 6128.03, pada variabel MOP diperoleh hasil 359.89 dan pada variabel Implant diperoleh 38241.30. Sedangkan hasil peramalan menggunakan metode Prophet, diperoleh hasil pada variabel kontrasepsi IUD jumlah pengguna KB aktif (PA) bulan dengan nilai terendah adalah bulan Mei 2024 sejumlah 5593 peserta, sedangkan PA tertinggi terjadi pada bulan Maret 2024 yaitu sebanyak 16742 peserta. Kemudian pada kontrasepsi MOW diketahui jumlah pengguna KB aktif (PA) pada Mei terjadi titik terendah 2024 sejumlah 6028 peserta, sedangkan PA pada bulan Maret mencapai titik tertinggi 2024 sejumlah 8417 peserta. Selanjutnya pada kontrasepsi MOP diketahui jumlah pengguna KB aktif (PA) terendah berlangsung saat bulan Desember 2024 sejumlah 79 peserta, sementara puncak PA terjadi pada bulan Maret 2024 yaitu sebanyak 614 peserta. Dan terakhir pada kontrasepsi IMPLANT diketahui jumlah pengguna KB aktif (PA) nilai terendah dicapai pada bulan Mei 2024 sejumlah 26771 peserta, sedangkan PA tertinggi terjadi pada bulan Maret 2024 yaitu sebanyak 50957 peserta. Adapun *plot*

visualisasi ramalan jumlah pengguna KB aktif kontrasepsi IUD, MOW, MOP dan Implant periode Januari s.d. Desember 2024 tergambar pada Gambar 4.8 di bawah ini:



Gambar 8. Plot hasil ramalan jumlah pengguna KB aktif kontrasepsi IUD, MOW, MOP dan Implant periode Januari s.d. Desember 2024

Selanjutnya, jika melihat jumlah pengguna peserta KB MKJP Januari sampai dengan-Mei 2024 Provinsi Bengkulu berdasarkan laporan bulanan yang diterima, jumlah peserta KB IUD tertinggi dibulan Mei 2024. Untuk alat kontrasepsi MOW tertinggi dibulan Mei 2024. Untuk pengguna alat kontrasepsi MOP tertinggi di bulan Januari dan Februari sebanyak 637. Sedangkan Implant penggunaan tertinggi dibulan April 2024. Angka tersebut tidak jauh berbeda dengan hasil peramalan menggunakan metode ARIMA. Berikut hasilnya pada tabel 14.

Tabel 14. Laporan Jumlah Pengguna MKJP Januari Sd Mei 2024

No	Bulan	IUD	MOW	MOP	Implant
1	Januari	9183	7160	637	38246
2	Februari	9212	7212	637	38364
3	Maret	9145	7146	630	38229
4	April	9291	7174	628	38971
5	Mei	9574	7224	619	39835

3. SIMPULAN

Berdasarkan hasil dan pembahasan, maka dapat diambil kesimpulan sebagai berikut:

1. Berdasarkan data jumlah pengguna alat kontrasepsi MKJP (IUD, MOW, MOP dan Implant) model ARIMA (0,1,1) merupakan model terbaik untuk dilakukan peramalan karena memiliki nilai AIC, MAPE dan RMSE lebih rendah dibandingkan dengan pemodelan PROPHET. Pada model IUD ARIMA (0,1,1) dengan nilai MAPE sebesar 10.499, model MOW ARIMA (0,1,1) dengan nilai MAPE sebesar 6.372, model MOP ARIMA (0,1,1) dengan nilai MAPE sebesar 10.432 dan model Implant ARIMA (0,1,1) dengan nilai MAPE sebesar 7.060.
2. Hasil proyeksi pengguna alat kontrasepsi MKJP di Provinsi Bengkulu pada tahun 2024 cenderung menunjukkan adanya trend penurunan pada bulan Mei tahun 2024 dan trend kenaikan pada bulan Maret tahun 2024. Berdasarkan kontrasepsi IUD diketahui jumlah pengguna KB aktif (PA) terendah adalah bulan Mei 2024 sejumlah 5593 peserta, sedangkan PA tertinggi terjadi pada bulan Maret 2024 yaitu sebanyak 16742 peserta. Kemudian pada kontrasepsi MOW jumlah PA terendah pada Mei 2024 sejumlah 6028 peserta, sedangkan PA tertinggi pada bulan Maret 2024 sejumlah 8417 peserta. Selanjutnya pada kontrasepsi MOP diketahui jumlah PA terendah saat bulan Desember 2024 sejumlah 79 peserta, sementara puncak PA terjadi pada bulan Maret 2024 yaitu sebanyak 614 peserta. Dan terakhir pada kontrasepsi IMPLANT diketahui jumlah PA terendah pada bulan Mei 2024 sejumlah 26771 peserta, sedangkan PA tertinggi terjadi pada bulan Maret 2024 yaitu sebanyak 50957 peserta.

REFERENSI

- [1] Yenidoğan, I., Çayır, A., Kozan, O., Dag, T., & Arslan, Ç. *Bitcoin Forecasting Using ARIMA and PROPHET*. 3rd International Conference on Computer Science and Engineering (UBMK), 621-624. 2018
- [2] Damodar N., Gujarati dan Dawn C. Porter. *Basic Econometric* 5th Edition. McGraw –Hill: New York. 2009
- [3] Adhikari, R. & Agrawal, R.K. *An Introductory Study in Time Series Modeling and Forecasting*. First Edition, KAP LAMBERT Academic Publishing, Saarbrucken. 2013
- [4] Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. *Forecasting methods and applications*. John wiley & sons. 2008
- [5] Hanke, J. E., Reitsch, A. G., & Wichern, D. W. *Peramalan Bisnis (Edisi Ketujuh) [Business Forecasting]*. (D. Anantanur, Alih Bahasa). Jakarta: PT. Prenhallindo. 2003

- [6] Primaditya, Vincentius Iwan. *Pemodelan Box-Jenkins (ARIMA) untuk Peramalan Indeks Harga Saham Gabunga*. Magister Manajemen Teknologi Institut Teknologi Sepuluh November. 2014
- [7] William W.S. Wei. *Time series Analysis Univariate and Multivariate Methods*, Addison-Wesley Publishing Company. 2006
- [8] Aswi dan Sukarna. *Analisis Deret Waktu Teori dan Aplikasi*, Makassar: Andira Publisher.2006
- [9] Box, George E.P., et. al. *Time Series Analysis: Forecasting and Control. Fourth Edition*, A John Wiley & Sons, inc., PublisherBO. 2008
- [10] Wie, W. W. S. *Time Series Analysis: Univariate and Multivariate Methods Second Edition. Pearson Education, Inc., SFB 373*(Chapter 5), 837–900. 2006
- [11] Nachrowi, D. N., & Usman, H. *Ekonometrika*. Jakarta: LPFEUI. 2006
- [12] Cryer, J. D., & Chan, Kung-Sik. *Time Series Analysis with Applications in R Second Edition*. New York: Springer. 2008.
- [13] Cryer, J. D. *Time series analysis* (Vol. 286). Boston: Duxbury Press. 1986.
- [14] Taylor, S. J., & Letham, B. *Forecasting at scale*. 2017.