



PAPER – **OPEN ACCESS**

Perbandingan Metode Peramalan Berbasis Pola Tren Musiman untuk Prediksi Permintaan Obat dengan Model Holt-Winter's Exponential Smoothing dan ARIMA

Author : Deevantianto Rafif Wibisono, dkk.
DOI : 10.32734/ee.v7i1.2177
Electronic ISSN : 2654-704X
Print ISSN : 2654-7031

Volume 7 Issue 1 – 2024 TALENTA Conference Series: Energy and Engineering (EE)



This work is licensed under a [Creative Commons Attribution-NoDerivatives 4.0 International License](https://creativecommons.org/licenses/by-nd/4.0/).

Published under licence by TALENTA Publisher, Universitas Sumatera Utara



Perbandingan Metode Peramalan Berbasis Pola Tren Musiman untuk Prediksi Permintaan Obat dengan Model *Holt-Winter's Exponential Smoothing* dan ARIMA

Deevantianto Rafif Wibisono*, Gusti Ayu Ari Rani Damayanthi, Naufal Firmansyah Widiatmoko, Marcello Cristiano

*Departemen Teknik Industri, Universitas Indonesia, Depok, Jawa Barat 16424, Indonesia

deevantianto.rafif@ui.ac.id, gusti.ayu23@ui.ac.id, naufal.firmansyah21@ui.ac.id, marcello.cristiano@ui.ac.id

Abstrak

Obat-obatan memainkan peran penting dalam layanan kesehatan masyarakat, seperti pusat kesehatan masyarakat (Puskesmas). Data yang digunakan dalam penelitian ini bersumber dari Puskesmas Gedong Air di Bandar Lampung, sesuai dengan Keputusan Menteri Kesehatan Republik Indonesia No. 26 tahun 2020 tentang Standar Pelayanan Farmasi di Pusat Kesehatan Masyarakat. Untuk memastikan layanan obat yang optimal, ketersediaannya perlu dipertahankan. Salah satu cara untuk mencapai ini adalah dengan menggunakan metode peramalan. Dalam penelitian ini, dua model peramalan, *Holt-Winters' Exponential Smoothing* dan ARIMA, akan dibandingkan dari segi akurasi dan ketahanan dalam industri kesehatan. Temuan menunjukkan bahwa kedua model memiliki akurasi yang serupa, namun model ARIMA cenderung menunjukkan model yang lebih kuat dibandingkan dengan model *Holt-Winters' Exponential Smoothing*.

Kata Kunci: ARIMA; *Holt's Winter Exponential Smoothing*; Peramalan

Abstract

Public health services like community health centers rely heavily on medicine (Puskesmas). The information utilized in this study are obtained from Gedong Air Puskesmas in Bandar Lampung, as per the Pronouncement of the Clergyman of Strength of the Republic of Indonesia No. 26 of 2020 in regards to the Drug Administration Norms at Local area Wellbeing Focuses. Maintaining its availability is essential for providing the best possible medication services. One method for accomplishing this is by utilizing determining strategies. In this review, two estimating models, *Holt-Winters' Outstanding Smoothing and ARIMA*, will be analyzed with regards to precision and heartiness in medical care industry. The discoveries recommend that the two models has comparative precision, yet the ARIMA model will in general show more strong model contrasted with the *Holt-Winters' Dramatic Smoothing* model.

Keywords: ARIMA; Forecasting; *Holt-Winter's Exponential Smoothing*

1. Pendahuluan

Puskesmas Gedong Air Bandar Lampung merupakan lembaga kesehatan primer yang melayani masyarakat lokal dengan menyediakan layanan medis, perawatan preventif, dan edukasi kesehatan. Meskipun memegang peran yang fundamental, Puskesmas Gedong Air Bandar Lampung menghadapi tantangan dalam memenuhi permintaan obat-obatan dan perlengkapan medis sambil menjaga kualitas perawatan optimal. Masalah seperti ketersediaan obat yang terbatas, dan kurangnya peralatan medis menghambat kemampuan Puskesmas untuk memenuhi kebutuhan kesehatan masyarakat dengan efektif. Meningkatkan manajemen obat adalah poin penting untuk meningkatkan kualitas dan aksesibilitas layanan kesehatan Puskesmas.

Obat memiliki peran penting dalam layanan kesehatan, termasuk di Puskesmas. Ini ditegaskan dalam Keputusan Menteri Kesehatan RI Nomor 26 Tahun 2020 [9] tentang Standar Pelayanan Kefarmasian di Puskesmas. Manajemen efektif dari layanan farmasi sangat penting bagi Puskesmas untuk mengatasi berbagai tantangan, seperti ketersediaan obat, obat kadaluarsa, dan kekurangan stok. Oleh karena itu, perencanaan dan peramalan yang tepat mengenai pasokan obat menjadi kunci untuk mengurangi tantangan ini dan memastikan pengiriman layanan kesehatan yang tidak terputus.

Peramalan dapat dilakukan dengan berbagai cara. Model sederhana, seperti *moving average* telah digunakan oleh prami [10]. Ajieb dalam [1] menggunakan metode *double exponential smoothing* untuk meramal persediaan obat. Beberapa industry yang telah diramalkan menggunakan metode tersebut, seperti besi [6], batu bara [11], dan produk [13] Sementara itu, Khairina [5] dan Maretania [6] menggunakan metode *triple exponential smoothing*. Model ARIMA juga kerap digunakan di beberapa penelitian. Ghosh telah melakukan peramalan dengan menggunakan ARIMA dalam industri makanan [14]. Fadhilah [2] menggunakan metode regresi linier untuk melakukan peramalan.

Penentuan model merupakan hal penting. Penentuan model yang tidak tepat akan mempengaruhi pengambilan keputusan. Selain itu, proses pelatihan model (*training* atau *fitting*) data ke model merupakan hal yang tidak dapat diabaikan. Beberapa penelitian tidak melakukan *splitting* dalam proses pelatihan model sehingga kemampuan model dalam memprediksi tidak dapat diketahui dengan baik [7]. Akibatnya, tujuan penelitian ini adalah untuk membandingkan akurasi dan ketahanan model peramalan yang lebih baik untuk memprediksi kebutuhan obat dengan menggunakan metode yang sesuai. Dalam penelitian ini, model yang digunakan adalah *Holt-Winter's (Triple Exponential Smoothing)* dan ARIMA. Penelitian ini menggunakan data dari periode Januari 2021 – Desember 2023, yang dikumpulkan secara bulanan.

2. Metode Penelitian

Metode ini telah digunakan dalam penelitian sebelumnya, ARIMA dan *Single Exponential Smoothing* untuk memprediksi permintaan obat Paracetamol generic 500mg, dengan ARIMA (1, 0, 0) menunjukkan MAPE 13% dan MSE 283,715 sebagai nilai *error* terkecil. Studi komparasi antar model juga telah dilakukan; Khairina [5] membandingkan *Double Exponential Smoothing* dan *Triple Exponential Smoothing* melalui MAPE, sedangkan Sidqi [13] mengkaji *Single Exponential Smoothing* dan *Triple Exponential Smoothing* menggunakan metrik yang sama. Namun, kelemahan penelitian ini termasuk tidak membagi data menjadi train dan test serta hanya menggunakan MAPE tanpa metrik lain seperti MSE atau MAD, yang kurang efektif untuk data dengan outlier, sehingga mengurangi keakuratan dan *robustness* model dalam menghadapi kondisi masa depan yang beragam.

2.1. Intrinsic Techniques Forecasting

Peramalan dengan teknik intrinsik merupakan teknik peramalan yang menggunakan data historis dari suatu objek dalam kurun waktu tertentu. Tujuan teknik ini adalah mengidentifikasi data dan meramalkan kejadian yang akan mungkin terjadi di masa depan dengan pendekatan analisis statistik dan pemodelan matematika. Salah satu peramalan dengan teknik intrinsik yang sering digunakan yaitu *Exponential Smoothing Techniques* [10].

2.1.1. Exponential Smoothing Techniques

Exponential Smoothing Techniques merupakan metode peramalan pendekatan berbasis eksponensial dengan memberikan bobot pada setiap data masa lalu untuk mengantisipasi hasil masa depan. Metode ini memiliki tiga tipe salah satunya *Triple Exponential Smoothing*. Rumus dari *Exponential Smoothing Techniques* adalah sebagai berikut:

$$F_t = F_{t-1} + \alpha y_t + \alpha (D_{t-1} - F_{t-1}) \quad (1)$$

Penjelasan:

- F_t = Perkiraan permintaan saat ini
- F_{t-1} = Perkiraan permintaan masa lalu
- α = Konstanta eksponensial
- D_{t-1} = Permintaan aktual

2.1.1.1. Triple Exponential Smoothing (TES)

Triple Exponential Smoothing atau dikenal dengan *Holt-Winter's* merupakan metode peramalan yang menggunakan pendekatan statistik dan pemodelan matematika pada data *trend* dan *seasonal*. Selain itu, Metode ini sesuai untuk meramalkan perihail yang bersifat fluktuatif atau berbentuk pola gelombang pasang surut [6]. Rumus persamaan dari *Triple Exponential Smoothing* sebagai berikut:

Persamaan untuk model multiplikatif:

$$s_0 = x_0 \quad (2)$$

$$s_t = \alpha \left(\frac{x_t}{c_{t-L}} \right) + (1 - \alpha)(s_{t-1} + b_{t-1}) \quad (3)$$

$$b_t = \beta(s_t - s_{t-1}) + (1 - \beta)b_{t-1} \quad (4)$$

$$c_t = \frac{\gamma x_t}{s_t} + (1 - \gamma)c_{t-L} \quad (5)$$

$$y_{t+m} = (s_t + mb_t)c_{t-L} \quad (6)$$

Persamaan untuk model additif:

$$s_0 = x_0 \quad (2)$$

$$s_t = \alpha \left(\frac{x_t}{c_{t-L}} \right) + (1 - \alpha)(s_{t-1} + b_{t-1}) \quad (3)$$

$$b_t = \beta(s_t - s_{t-1}) + (1 - \beta)b_{t-1} \quad (4)$$

$$c_t = \gamma(x_t - s_{t-1} - b_{t-1}) + (1 - \gamma)c_{t-L} \quad (7)$$

$$y_{t+m} = s_t + mb_t + c_{t-L} \quad (10) \quad (8)$$

Penjelasan:

S_0 = nilai awal Smoothing process

S_t = nilai Smoothing process pada waktu ke-t

α = Konstanta smoothing (antara 0 hingga 1)

X_t = Nilai observasi aktual pada waktu ke t

y_{t+m} = Ramalan pada m periode ke depan

2.1.2. Autoregressive Integrated Moving Average (ARIMA) Model

Pada pendekatan deret waktu, metode statistik seperti moving average, exponential smoothing, dan ARIMA sering digunakan dalam menentukan peramalan di masa depan. Model ramalan time series dapat dihitung untuk memprediksi permintaan pada suatu objek. Melalui data historis dan bentuk model oleh kinerja perkiraan, metode ARIMA mampu menghitung variasi permintaan musiman dan hasilnya dapat digabungkan faktor musiman dalam model untuk meningkatkan akurasi peramalan. Namun, metode ARIMA memiliki kekurangan dalam meramalkan permintaan musiman dengan variabel besar karena kendala model yang statis dan perlunya observasi dalam jumlah yang besar [4].

Model ARIMA dikenal dengan ARIMA (p, d, q), dimana p, d, q berturut-turut adalah jumlah suku autoregressive, banyaknya selisih (differencing), dan jumlah moving average. Model ARIMA dapat disesuaikan dengan data yang memiliki musiman. Model tersebut disebut dengan Seasonal ARIMA (SARIMA). Model SARIMA biasanya dinotasikan dengan ARIMA (p,d,q)

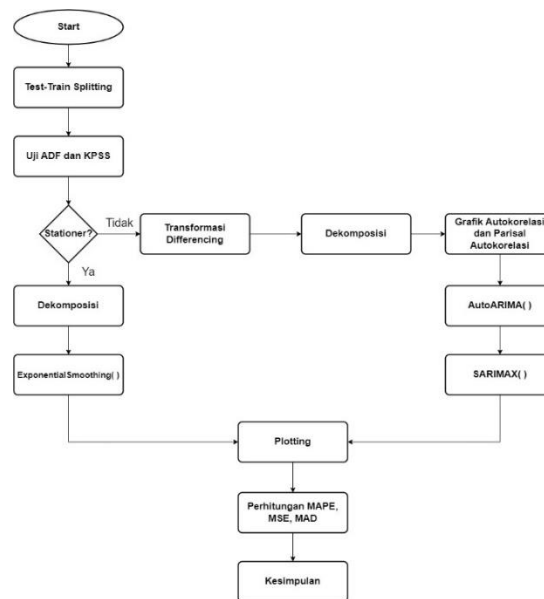
(P,D,Q)_m dengan P, D, dan Q adalah suku autoregresi, selisi, dan moving average persamaan musiman SARIMA serta m sebagai panjang musim. Persamaan ARIMA dapat dilihat di bawah ini

$$ARIMA(p, d, q): y_t = c + \sum_{i=1}^p \varphi_i y_{t-i} + \sum_{i=1}^q \theta_i \epsilon_{t-i} \tag{9}$$

Dengan y_t sebagai nilai pada masa ke- t , c sebagai *intercept*, φ_i , dan θ_i adalah koefisien variabel ke- i untuk masing-masing variabel, dan ϵ_{t-i} adalah residual pada masa ke- $(t - 1)$. Sementara itu, persamaan model SARIMA dapat di lihat di bawah ini.

$$SARIMA(p, d, q)(P, D, Q)_m: y_t = c + \sum_{i=1}^p \varphi_i y_{t-i} + \sum_{i=1}^q \theta_i \epsilon_{t-i} + \sum_{i=1}^P \phi_i y_{t-mi} + \sum_{i=1}^Q \eta_i \epsilon_{t-mi} \tag{10}$$

2.2. Alur Penelitian



Gambar 1. Flow Chart Penelitian

Pembangunan model *forecasting* diawali dengan memecah *dataset* menjadi dua kelompok, yaitu *set train* dan *set test*. Tujuannya adalah agar kemampuan model dalam melakukan prediksi pada masa depan dapat dinilai dengan membandingkan hasil *fitting* menggunakan data *training* dengan data *testing* [7]. Pemisahan data dilakukan di awal agar tidak terjadi kebocoran data, yaitu *dataset test* secara sengaja ataupun tidak dipelajari oleh model [8]. Data permintaan obat dari tahun 2021 s.d. 2023 akan dibagi dengan proporsi 80-20. Artinya, 80% data awal, Januari 2021 s.d. Juni 2023, digunakan untuk *training*, sementara sisanya, 20% akhir atau Juli 2023 s.d. Desember 2023, digunakan untuk *testing*. Setiap proses uji hipotesis, *fitting* transformasi, dan *fitting* model akan dilakukan ke 80% data awal. Selanjutnya, proses *stationary test* dilakukan untuk mengetahui apakah data dipengaruhi oleh waktu. Uji akan dilakukan dengan uji KPSS dan ADF.

Format hipotesis uji ADF

H_0 : Data memiliki unit root

H_1 : Data tidak memiliki unit root

Format hipotesis uji KPSS

H_0 : Data bersifat stasioner

H_1 : Data bersifat non stasioner

Penelitian ini menggunakan nilai tingkat kepercayaan sebesar 95% yang berarti hipotesis ditolak jika kesalahan tingkat satu sebesar 5% lebih besar atau sama dengan p -value. Apabila data bersifat stasioner, yaitu tidak memiliki tren dan musim model yang cocok digunakan adalah *Holt-Winter's Exponential Smoothing*. Sebaliknya, apabila non-stasioner, model yang cocok adalah ARIMA. Apabila uji ADF dan KPSS menyatakan kedua data stasioner, data cenderung bersifat stasioner, begitu juga sebaliknya. Namun, apabila uji ADF mengatakan data bersifat stasioner, tetapi uji KPSS menyatakan data bersifat non stasioner, data tidak bersifat stasioner, tetapi melakukan transformasi *differencing* diindikasikan bersifat stasioner. Apabila ADF menyatakan data bersifat non stasioner dan KPSS bersifat sebaliknya, data memiliki sifat tren stasioner, yaitu tren dapat dihilangkan untuk menghasilkan data yang benar-benar stasioner [3].

Di penelitian ini, apabila setelah dilakukan pengujian ternyata data tidak bersifat stasioner, proses transformasi *differencing* akan dilakukan. Formula proses tersebut adalah sebagai berikut.

$$y'_t = y_t - y_{t-1} \quad (11)$$

2.2.1. Pembentukan Model Holt-Winter's Exponential Smoothing

Model *Holt-Winter's* sangat cocok untuk data yang memiliki tren dan musim. Data tersebut dibentuk oleh tren, musim, dan error. Bentuk tren dan musim bisa aditif atau multiplikatif. Untuk mengetahui hubungan ketiganya, proses dekomposisi dapat dilakukan. Proses ini akan dilakukan dengan menggunakan *package python statsmodel* yang telah diringkaskan oleh *package* lain, yaitu *jcopml*.

Di mana α , β , dan γ masing-masing adalah parameter *smoothing*, tren, dan musiman dengan rentang nilai masing-masing 0 s.d. 1. Parameter s_t , b_t , dan c_t adalah nilai *smoothed statistics*, tren, dan musiman di periode ke- t . Variabel y_t adalah nilai peramalan di waktu ke- t . Proses *fitting* dilakukan dengan menggunakan objek pemrograman dari *statsmodels*. Parameter α , β , dan γ akan dioptimasi oleh objek tersebut. Akan tetapi, parameter lain seperti bentuk tren dan musim akan disesuaikan berdasarkan hasil dekomposisi.

2.2.2. Pembentukan Model Auto Regression Integrated Moving Average (ARIMA)

Pembentukan model ARIMA sedikit berbeda dari proses pembentukan model *Holt-Winter's Exponential Smoothing*. Setelah dipastikan bahwa data bersifat stasioner dari proses *differencing* dan uji hipotesis ADF dan KPSS, proses analisa penentuan parameter dapat dilakukan. Analisa akan menggunakan fungsi autokorelasi dan fungsi parsial autokorelasi. Fungsi autokorelasi dan fungsi parsial autokorelasi dari residual akan dianalisis untuk menentukan parameter p , yaitu jumlah variabel yang digunakan dalam auto regresi dan q , yaitu jumlah variabel yang digunakan dalam *moving average*. Penentuan p dan q didasari oleh jumlah residual yang secara signifikan cukup tinggi nilainya dari nilai residual lainnya. Meskipun dapat ditentukan dengan melihat grafik autokorelasi dan parsial autokorelasi, hasilnya akan dicek dengan pengujian komputasi menggunakan AutoARIMA yang membandingkan kualitas model dari berbagai parameter yang mungkin.

Proses selanjutnya adalah melakukan *fitting* ke model ARIMA. Formulasi persamaan peramalan dapat dilihat di persamaan (9). Dalam studi ini, proses *fitting* akan memanfaatkan *package python*, yaitu *mparima*.

$$ARIMA(p, d, q): y_t = c + \sum_{i=1}^p \varphi_i y_{t-i} + \sum_{i=1}^q \varphi_i \epsilon_{t-i} \quad (9)$$

Namun, untuk mengantisipasi adanya musiman dalam data, analisa oleh komputer akan tetap dilakukan dengan menggunakan objek SARIMAX, yaitu model ARIMA yang menerima adanya musim di dalam data akan digunakan. Objek ini merupakan bagian dari *package statsmodels*. Persamaan peramalan dapat di lihat di persamaan (10). Hasil komputasi dan analisa grafik akan dibandingkan performanya

$$SARIMA(p, d, q)(P, D, Q)_m: y_t = c + \sum_{i=1}^p \varphi_i y_{t-i} + \sum_{i=1}^q \theta_i \epsilon_{t-i} + \sum_{i=1}^P \phi_i y_{t-mi} + \sum_{i=1}^Q \eta_i \epsilon_{t-mi} \quad (10)$$

Setelah proses-proses pembentukan masing-masing model dilakukan, hasil proses akan di *plotting* sehingga hasil peramalan dan data sebenarnya dapat dibandingkan untuk menilai kualitas peramalan. Metrik penilaian yang akan digunakan adalah akurasi dari model dengan menggunakan MAPE, MSE, dan MAD. Penilaian harus memiliki nilai yang baik dari dua set data, yaitu *test* dan *train*. Apabila terdapat perbedaan yang signifikan, terdapat indikasi *overfitting*, yaitu data terlalu baik mempelajari data *test* tetapi tidak dapat memprediksi data pada masa depan.

2.3. Forecasting Error

Saat membuat perkiraan atau proyeksi, kesalahan tidak dapat dihindari, sama halnya dengan teknik peramalan lainnya. Biasanya, kita menilai akurasi prediksi menggunakan tiga ukuran: MAPE, MSE, MAD. MAPE (*Mean Absolute Percentage Error*), mengukur kesalahan prediksi relatif terhadap nilai sebenarnya. Metrik ini lebih populer dari metrik lainnya karena interpretasinya mudah dipahami. MAD (*Mean Absolute Deviation*) mengukur rata-rata perbedaan mutlak antara prediksi dan nilai aktual, memberikan wawasan tentang besarnya kesalahan secara umum tanpa memperhatikan arahnya. Di sisi lain, MSE (*Mean Squared Error*) mengukur rata-rata perbedaan kuadrat antara nilai yang diprediksi dan nilai aktual, menekankan kesalahan besar secara standar.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Actual - Forecast)^2 \tag{12}$$

$$MAD = \frac{1}{n} \sum_{i=1}^n |Actual - Forecast| \tag{13}$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Actual - Forecast}{Actual} \right| \times 100\% \tag{14}$$

3. Pengumpulan Data

3.1. Identifikasi Data

Pada tahap ini, dilakukan identifikasi data yang diperoleh, yaitu penggunaan obat dalam tiga tahun atau 36 bulan. Tahap ini menjelaskan tentang obat yang digunakan.

Tabel 1. Identifikasi obat

Nama Obat	Paracetamol
<i>Units</i>	Drop 100 ml Sirup 120 ml Tablet 500 ml
<i>Frequency of Order</i>	Beberapa kali berdasarkan permintaan puskesmas

4. Hasil dan Pembahasan

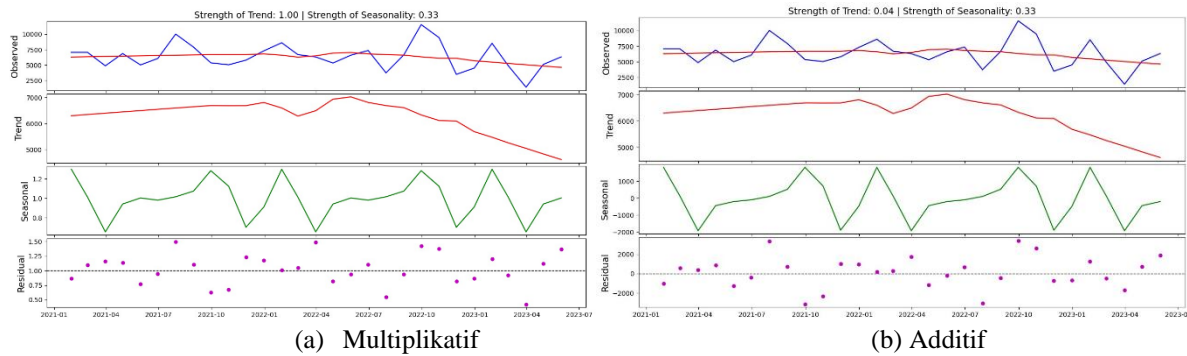
4.1. Uji Stasioneritas

Setelah diuji, nilai *pvalue* uji ADF dan KPSS di atas 5%. Artinya, hipotesis *null* uji ADF dan KPSS ditolak. Intepretasinya, data secara signifikan bersifat *differencing stationery*. Data *time series* masih belum bersifat stasioner, tetapi akan bersifat stasioner jika dilakukan transformasi *differencing*. Hasil ujinya dapat dilihat di tabel 1. Data yang belum ditransformasi ini akan digunakan untuk proses *fitting* ke model Holt’s Winters’ Exponential.

Tabel 2. Hasil uji stasioneritas

Test	Test Statistic	p-value	Critical Value (1%)	Critical Value (5%)	Critical Value (10%)	Reject null
ADF	- 2,059	0,261	-3.711	-2.981	-2.630	FALSE
KPSS	0,2587	0,100	0,739	0,463	0,347	FALSE

4.2. Forecasting menggunakan metode Holt-Winter's



Gambar 2. Dekomposisi Data Permintaan Paracetamol

Hasil dekomposisi sesuai gambar 2 menunjukkan adanya tren yang bersifat multiplikatif dengan nilai tren 1. Sementara itu, pola musiman bisa bersifat additif atau multiplikatif yang sama-sama memiliki kekuatan musiman 0,33. Kedua tipe ini akan dicoba saat proses *fitting* nantinya.

Untuk memperoleh hasil peramalan dengan tingkat kesalahan yang paling rendah, penentuan parameter koefisien α , β , dan γ dalam rumus *Holt-Winter's* sangat krusial. Dengan menggunakan proses optimisasi dari objek statsmodel, Exponential Smoothing(), diperoleh nilai optimal untuk α sebesar 0,005, β sebesar 0,0001, dan γ sebesar 0,24875.

Hasil *fitting* menunjukkan bahwa model dengan tren bertipe additif dan musiman multiplikatif tidak begitu berbeda peforma akurasi dengan tren dan musiman bertipe additif. Akan tetapi, selisih dari hasil nilai *error* train dan test dari tren dan musiman bertipe additif sedikit lebih besar dari tipe lainnya. Selisih MAPE, MSE, MAD untuk model tren additif-musiman multiplikatif dan tren additif adalah berturut-turut 0,0654, 20.744.354, dan 3.064.720. Sementara itu, model Tren Multiplikatif-Musiman Multiplikatif memiliki selisih *error* MAPE, MSE, dan MAD berturut-turut adalah 0.0782, 21.844.257, dan 3.182.793 Dengan demikian, hasil tipe tren multiplikatif-musiman additif cenderung lebih baik dari tipe lainnya.


Tabel 3. Error value menggunakan metode Holt-Winter's Tren Multiplikatif-Musiman Additif

Set	MAPE	MSE	MAD
Train	33,14%	5.171.948	1425,668
Test	39,68%	25.916.302	4490,388

Tabel 4. Error value menggunakan metode Holt-Winter's Tren Multiplikatif-Musiman Multiplikatif

Set	MAPE	MSE	MAD
train	32.95%	5.105.763	1404,03
test	40.77%	26.950.020	4586,823

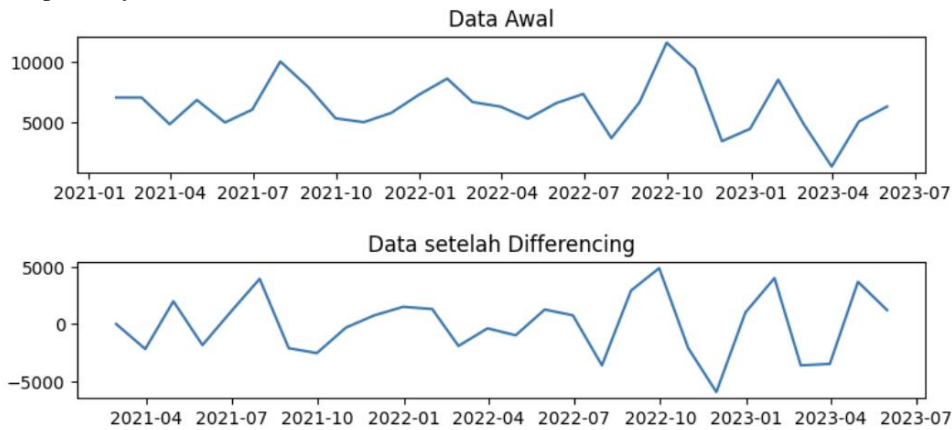
Dari hasil tersebut, model yang dipilih adalah model *Holt-Winter's* tren multiplikatif-musiman aditif. Grafik peramalan data terlihat pada gambar di bawah ini.



Gambar 3. Hasil peramalan menggunakan metode Holt-Winter's

4.3. Forecasting menggunakan metode ARIMA

Langkah awal adalah melakukan transformasi differencing. Hasilnya dapat dilihat di gambar 5. Setelah dilakukan proses differencing, hasil uji stasioner memberikan nilai pvalue dibawah 5% untuk uji ADF, tetapi di atas 5% untuk uji KPSS. Dengan demikian, data sudah sepenuhnya bersifat stasioner.

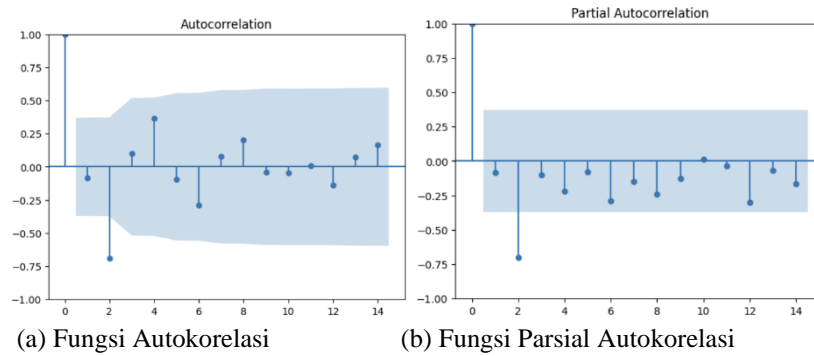


Gambar 4. Hasil transformasi differencing

Tabel 5. Hasil uji stasioneritas

Test	Test Statistic	p-value	Critical Value (1%)	Critical Value (5%)	Critical Value (10%)	Reject null
ADF	-9.129	0	-3.711	-2.981	-2.630	TRUE
KPSS	0.184	0.1	0.739	0.463	0.347	FALSE

Sebelum melakukan fitting model, analisis fungsi autokorelasi dan parsial autokorelasi diperlukan. Hasilnya dapat dilihat di gambar 5 masing-masing fungsi memiliki satu titik residual yang berbeda dari titik lainnya. Dengan demikian, jumlah variabel yang akan digunakan dalam autoregresi dan moving average masing-masing berjumlah satu. Hasil analisis lanjutan adalah mengidentifikasi apakah pola musiman masih ada. Proses ini dapat dilakukan dengan simulasi oleh komputer melalui proses model tuning menggunakan objek pmdarima.auto_arima. Pola musiman tersebut bisa dimodelkan dengan menggunakan masing-masing satu variabel untuk autoregresi P dan Q moving average, variabel differencing, D , dan panjang musiman, m . Hasil simulasi juga akan memberikan output parameter ARIMA, p, d , dan q . Hasil simulasi memiliki sedikit perbedaan dalam menentukan parameter p dan q . Komputer menyatakan bahwa hasil terbaik adalah $(p, d, q) = (2, 1, 2)$. Kedua parameter yang diperoleh dari hasil analisis dan komputer akan di-fit dan dibandingkan hasilnya nanti. Model ARIMA musiman yang digunakan adalah $(P, D, Q)_m = (1, 1, 1)_{12}$.



Gambar 5. Grafik Variabel Regresi

Setelah proses fitting, hasil eror model dengan parameter $ARIMA(1,1,1)(1,1,1)_{12}$ lebih jauh dari *overfit* jika dibandingkan dengan model $ARIMA(2,1,2)(1,1,1)_{12}$. Nilai MSE di model $ARIMA(2,1,2)(1,1,1)_{12}$ sangat berbeda jauh untuk *train set* dan *test set*, yaitu 26.825.714, nilai *error train* 2,6 kali lebih besar, jika dibandingkan dengan model pertama yang hanya 10.135.611, nilai *error train* 5,3 kali lebih besar. Terdapat indikasi *overfitting*, atau kemampuan prediksi yang hanya bagus untuk data *train*, untuk model $ARIMA(2,1,2)(1,1,1)_{12}$. Hasilnya dapat di lihat di tabel 6 dan 7.


Tabel 6. Nilai Error Model $ARIMA(1, 1, 1)(1, 1, 1)_{12}$

Set	MAPE	MSE	MAD
train	38,88%	7.270.899	2225,463
test	33,98%	17.406.510	3614,203

Tabel 7. Nilai Error Model $ARIMA(2, 1, 2)(1, 1, 1)_{12}$

Set	MAPE	MSE	MAD
train	39,34%	6.238.346	2061,82
test	42,55%	33.064.060	4984,47

Hasil peramalan dari model yang terpilih, $Arima(1,1,1) \times (1,1,1)_{12}$, terlihat pada grafik di bawah ini



Gambar 6. Hasil Peramalan dengan Model ARIMA

4.4. Perbandingan Model

Metode *Holt-Winter's* memiliki hasil yang baik dalam melakukan prediksi di data *train set* jika dibandingkan dengan ARIMA. Akan tetapi, model ARIMA memiliki kemampuan yang jauh lebih baik dalam memprediksi data *test*. Selisih skor MAPE dari model *Holt-Winter's*, sebesar 6,54%, jauh lebih besar daripada model ARIMA, sebesar 4,9%. Dalam kasus ini, model ARIMA jauh lebih *robust*, yaitu mampu beradaptasi dalam berbagai kondisi. Selain itu, nilai MSE train lebih dari lima kali dari test untuk model *Holt-Winter's*. Hal ini memperkuat premis bahwa model ARIMA jauh lebih *robust*.

Tabel 8. Perbandingan error value train

Model	MAPE	MSE	MAD
-------	------	-----	-----

Holt-Winter's	33,14%	5.171.948	1425,668
ARIMA	38.88%	7.270.899	2225.463

Tabel 9. Perbandingan *error value test*

Model	MAPE	MSE	MAD
Holt-Winter's	39,68%	25.916.302	4490,388
ARIMA	33.98%	17.406.510	3614.203

4.5. Perbandingan dengan penelitian sebelumnya

Pada penelitian yang pernah dilakukan sebelumnya dalam memprediksi persediaan di PT Suzuki Indomobil Motor dengan metode Holt-Winter's dan ARIMA. Tujuan penelitian dalam paper tersebut yaitu memperoleh hasil peramalan permintaan produksi yang akan dikonversikan dalam menghitung persediaan dan pengadaan bahan baku. Data permintaan produksi mobil yang digunakan berasal dari bulan Januari 2017 – Juni 2019 dan teknik pengambilan sampel yang digunakan yaitu non-probability sampling. Berdasarkan hasil dan pembahasan dari penelitian sebelumnya, metode Holt-Winter's lebih tepat digunakan dalam memprediksi peramalan permintaan produksi karena hasil error rate yang lebih kecil dibandingkan metode ARIMA. Nilai MAPE yang dihasilkan dengan metode Holt-Winter's yaitu 23.06% yang mana nilai tersebut lebih rendah 1.9% dibandingkan nilai MAPE dengan metode ARIMA.

Hasil penelitian dalam paper ini menjelaskan bahwa metode ARIMA lebih tepat dan akurat dalam memprediksi permintaan obat Puskesmas Gedong Air Bandar Lampung tahun 2024. Hal ini disebabkan oleh model ARIMA yang mampu beradaptasi dengan berbagai kondisi pola data dan nilai MSE yang lebih baik dibandingkan dengan model Holt-Winter's. Gap analysis yang dapat diketahui dalam kedua penelitian ini adalah perbedaan data historis permintaan yang digunakan, perbedaan nilai Model ARIMA (p, d, q) yang digunakan pada penelitian saat ini adalah (1, 1, 1) dengan penelitian sebelumnya yaitu (2, 0, 2), dan faktor eksternal seperti kondisi pasar yang mempengaruhi permintaan barang serta data historis permintaan dari objek yang diteliti.

4.6. Usulan Perbaikan

4.6.1. Penyesuaian parameter model ARIMA dan Holt-Winter's dalam forecasting

a. Holt-Winter's

Penetapan parameter α , β , dan γ krusial untuk hasil peramalan yang akurat serta mengendalikan dampak data terbaru, tren, dan musiman. Nilai α besar membuat model responsif terhadap perubahan terbaru, sementara penyesuaian β dan γ mengatasi perubahan tren atau musiman. Optimisasi dalam Holt-Winter's dapat dilakukan melalui teknik Bayesian atau swarm optimization untuk mencari kombinasi parameter optimal [12].

b. ARIMA

Parameter p, d, q dalam model ARIMA mewakili atas peran komponen autoregressive, selisih nilai Y, dan moving average. Penyesuaian parameter terhadap fungsi autokorelasi dan parsial autokorelasi dapat mengoreksi model data dengan pola tren atau stasioner. AutoARIMA sebagai alat untuk menentukan parameter yang optimal dengan cara mengkombinasikan setaip parameter p, d, q dan membandingkan akurasi.

4.6.2. Integrasi faktor eksternal

Faktor eksternal, seperti wabah penyakit seperti COVID-19, regulasi pemerintah, perubahan demografis, dan tren kesehatan masyarakat, memengaruhi peramalan permintaan obat secara signifikan. Menambahkan variabel dan penggunaan data historis dari setiap faktor eksternal ke dalam peramalan dapat meningkatkan akurasi model dan memungkinkanantisipasi terhadap fluktuasi permintaan yang tidak terduga di masa depan.

5. Kesimpulan

Penelitian ini bertujuan untuk mengetahui metode mana yang lebih akurat dalam melakukan peramalan permintaan kebutuhan obat Parasetamol *Drop*, *Syrup*, dan *Tablet* di Puskesmas Gedong Air Bandar Lampung tahun 2024 dengan cara membandingkan kedua metode yaitu *Holt Winter's* dan ARIMA berdasarkan *mean absolute percentage error* (MAPE), *mean absolute deviation* (MAD), dan *mean squared error* (MSE) dari setiap metode. Data yang digunakan dalam studi ini adalah data permintaan obat dari tahun 2021 s.d. 2023.

Proses analisis data dimulai dengan pembagian data menjadi 80% untuk *training* dan 20% untuk *test*. Setelah memeriksa *stationary*, data membutuhkan *differencing* untuk mencapai *stationary* penuh. Berdasarkan hasil *tuning* yang dilakukan pada model *Holt-Winter's Exponential Smoothing* dengan tren-multiplikatif-musiman additif dipilih dalam kasus ini karena tingkat *error* yang lebih rendah. Namun, analisis lebih lanjut mengungkapkan bahwa model ARIMA (1,1,1)(1,1,1)₁₂ lebih *robust*, menghasilkan performa yang lebih konsisten dan selisih *error* yang lebih kecil antara data *train* dan *test*, menunjukkan signifikansi dalam meramalkan data pada masa depan dibandingkan dengan model *Holt-Winter's*.

Referensi

- [1] Ajieb, D. F. (2016). TA : Rancang bangun aplikasi peramalan permintaan obat pada rumah Sakit Petrokimia Gresik menggunakan metode Trend Exponential. Institut Bisnis dan Informatika Stikom Surabaya.
- [2] Fadillah, A. D., Wantuah, A. F., Surya, M. H. B., Azka, M. Z. A., & Nurprawito, D. Improving Inventory Management by Better Forecasting Method for Healthcare Industry Company.
- [3] G, V. K. (2024). Statistical tests to check stationarity in time series. Analytics Vidhya. <https://www.analyticsvidhya.com/blog/2021/06/statistical-tests-to-check-stationarity-in-time-series-part-1/#h-how-do-you-interpret-the-adf-test-results>
- [4] Ghosh, S. (2020). Forecasting of demand using ARIMA model. American Journal of Applied Mathematics and Computing, 1(2), 11-18.
- [5] Khairina, D. M., Daniel, Y., & Widagdo, P. P. (2021, July). Comparison of double exponential smoothing and triple exponential smoothing methods in predicting income of local water company. In Journal of Physics: Conference Series (Vol. 1943, No. 1, p. 012102). IOP Publishing.
- [6] Maretania, I., Alfadri, M. R., Paramesywarie, P. U., & Nurcahyo, R. (2021, August.). Comparison of double exponential and single exponential smoothing accuracy in krakatau steel demand forecasting fitted model. Ieomsociety.org. Retrieved April 29, 2024, from <https://ieomsociety.org/proceedings/2021india/87.pdf>
- [7] Medar, R., Rajpurohit, V. S., & Rashmi, B. (2017). Impact of Training and Testing Data Splits on Accuracy of Time Series Forecasting in Machine Learning. 2017 International Conference on Computing, Communication, Control and Automation (ICCUBEA), 1–6. <https://doi.org/10.1109/ICCUBEA.2017.8463779>
- [8] Nassar, O. (2023). Data Leakage in Machine Learning. <https://doi.org/10.13140/RG.2.2.27468.59528>
- [9] Permenkes No. 26 Tahun 2020. (2020). Peraturan BPK. Retrieved April 26, 2024, from <https://peraturan.bpk.go.id/Details/163004/permenkes-no-26-tahun-2020>
- [10] Prami Swari, M. H., Susila Handika, I. P., & Susila Satwika, I. K. (2021). Comparison of simple moving average, single and modified single exponential smoothing. 2021 IEEE 7th Information Technology International Seminar (ITIS), 1–5.
- [11] Rahmawati, A., Ramadhanti, C. N., Ismia, F. H., & Nurcahyo, R. (2021, August). Comparing The Accuracy of Holt and Brown's Double Exponential Smoothing Method in Forecasting The Coal Demand Of Company X. In Proceedings of the International Conference on Industrial Engineering and Operations Management (pp. 460-469).
- [12] Shahriari, B., Swersky, K., Wang, Z., Adams, R. P., & De Freitas, N. (2015). Taking the human out of the loop: A review of Bayesian optimization. Proceedings of the IEEE, 104(1), 148-175/
- [13] Sidqi, F., & Sumitra, I. D. (2019). Forecasting product selling using Single Exponential Smoothing and Double Exponential Smoothing methods. IOP Conference Series. Materials Science and Engineering, 662(3), 032031. <https://doi.org/10.1088/1757-899x/662/3/032031>
- [14] Zahra, I. A., & Putra, Y. H. (2019, November). Forecasting methods comparison based on seasonal patterns for predicting medicine needs with ARIMA method, single exponential smoothing. In IOP Conference Series: Materials Science and Engineering (Vol. 662, No. 2, p. 022030). IOP Publishing.