

# Pemanfaatan Teknik Peramalan Data Deret Waktu pada Inventori Farmasi di Rumah Sakit

<http://dx.doi.org/10.28932/jutisi.v10i2.9352>

Riwayat Artikel

Received: 07 Juli 2024 | Final Revision: 16 Juli 2024 | Accepted: 23 Juli 2024

Creative Commons License 4.0 (CC BY – NC)



Aziz Mu'min<sup>✉#1</sup>, Setia Budi<sup>\*2</sup>, Hapnes Toba<sup>#3</sup>

<sup>#</sup> Program Magister Ilmu Komputer, Universitas Kristen Maranatha  
Jl. Prof. drg. Surya Sumantri, M.P.H. No. 65, Bandung, 40164, Indonesia

<sup>1</sup>2279807@maranatha.ac.id

<sup>2</sup>setia.budi@it.maranatha.edu

<sup>3</sup>hapnes.toba@maranatha.ac.id

✉Corresponding author: 2279807@maranatha.ac.id

**Abstrak** — Manajemen persediaan yang baik sangat penting dalam industri rumah sakit untuk mengatasi masalah persediaan. Metode peramalan persediaan yang tidak efektif dapat menyebabkan kekurangan atau kelebihan persediaan stok. Pada akhirnya, ini dapat berdampak pada anggaran dan ketersediaan barang farmasi di rumah sakit. Metode peramalan tradisional sebelumnya sering kali menunjukkan ketidakakuratan. Penelitian ini menggunakan metode ARIMA (*Autoregressive Integrated Moving Average*) dan *Prophet* untuk mem peramalan permintaan barang farmasi di rumah sakit. Dalam upaya untuk mengevaluasi efektivitas kedua metode, percobaan ini dilakukan terhadap lima barang farmasi. Hasilnya menunjukkan bahwa metode ARIMA menghasilkan kinerja yang lebih baik dibandingkan dengan metode *Prophet*, dengan *error* terkecil dengan nilai 0.07310.

**Kata kunci**— ARIMA; Deret Waktu; Peramalan; Persediaan; *Prophet*.

## *The utilization of time series data forecasting techniques on hospitals pharmaceutical inventory*

**Abstract** — Good inventory management is essential in the hospital industry to overcome inventory problems. Ineffective inventory forecasting methods can lead to shortages or overstocks. Ultimately, this can impact the budget and availability of pharmaceutical items in the hospital. Previous traditional forecasting methods often show inaccuracies. This research uses ARIMA (*Autoregressive Integrated Moving Average*) and *Prophet* methods to forecast the demand for pharmaceutical items in hospitals. In an attempt to evaluate the effectiveness of both methods, an experiment was conducted on five pharmaceutical items. The results showed that the ARIMA method performed better than the *Prophet* method, with the smallest error of 0.07310.

**Keywords**— ARIMA; Forecasting; Inventory; *Prophet*; Time Series.

### I. PENDAHULUAN

Forecasting persediaan merupakan sebuah bagian utama dalam manajemen persediaan dan dalam rantai manajemen persediaan. Berbagai penelitian telah dilakukan pada *forecasting* permintaan dengan teknik *time series data mining* seperti *forecasting* permintaan listrik, penjualan produk makanan, dan jenis produk dan layanan lainnya. Di dalam industri rumah sakit, sangat penting untuk memastikan untuk memastikan ketersediaan barang farmasi untuk menjaga pengeluaran rumah

sakit sesuai dengan anggaran yang telah dialokasikan. Kekurangan dan kelebihan persediaan untuk barang farmasi telah menjadi tantangan di sebagian besar rumah sakit. *Forecasting* permintaan farmasi merupakan pekerjaan yang kompleks yang melibatkan beberapa faktor, seperti variasi musim, kategori barang farmasi dan penggunaan obat-obatan, keragaman geografis konsumen sehubungan dengan terapi yang digunakan oleh para praktisi[1]. Pentingnya peran *forecasting* persediaan barang farmasi dalam memenuhi persediaan yang cukup dapat berpengaruh terhadap penjualan barang farmasi di Rumah Sakit setiap bulannya. Penjualan merupakan salah satu komponen penting dalam Perusahaan [2] [3]. Secara langsung atau tidak, *forecasting* akan membantu banyak pihak yang berkepentingan. Dalam menentukan *forecasting* terdapat banyak sekali model dalam analisis deret waktu [2]. Penelitian ini memiliki tujuan untuk mengetahui model *forecasting* persediaan yang baik terhadap data penjualan yang digunakan. Dalam penelitian ini, diusulkan dua model untuk melakukan *forecasting* persediaan yaitu model ARIMA dan *Prophet*, kemudian dengan dua model ini dibandingkan model mana yang memiliki kinerja yang lebih baik sehingga nantinya model terbaik dapat dipergunakan oleh petugas rumah sakit untuk melakukan *forecasting* persediaan barang farmasi untuk memenuhi kebutuhan rumah sakit. Dalam penelitian ini, data yang digunakan adalah data penjualan barang farmasi dari sebuah rumah sakit dengan rentang waktu selama 3 tahun, mulai dari tahun 2021 hingga tahun 2023. Data ini mencakup informasi mengenai jumlah penjualan setiap barang farmasi dalam periode tersebut. Dengan demikian, data ini memberikan gambaran yang komprehensif tentang tren penjualan, fluktuasi musiman, serta pola permintaan terhadap berbagai barang farmasi di rumah sakit tersebut selama tiga tahun terakhir.

Ada beberapa penelitian yang membahas *forecasting* persediaan, seperti apa yang dilakukan oleh Hussein dkk [1]. Mereka melakukan penelitian *forecasting* persediaan dengan studi kasus di sebuah toko obat. Dalam penelitian ini, empat algoritma *machine learning* yang berbeda untuk analisis deret waktu dieksplorasi dan dibandingkan hasil peramalannya. Hasilnya menunjukkan bahwa *Gaussian Processes (GP)* memberikan hasil yang lebih baik dibandingkan dengan teknik lain yang dieksplorasi, yaitu *Support Vector Machine Regression (SMOreg)*, *Multilayer Perceptron (MLP)*, dan *Linear Regression (LR)*. GP terbukti lebih akurat untuk *forecasting* empat minggu ke depan.

Analisis deret waktu dari produk yang terjual menggunakan beberapa teknik populer dicoba dilakukan oleh Ervintyana dkk[2]. Penelitian ini menggunakan ARIMA (*Autoregressive Integrated Moving Average*), SVR (*Support Vector Regression*), FFT (*Fast Fourier Transform*) dan *Prophet* sebagai metode-metode untuk melakukan peramalan terhadap data penjualan produk suatu perusahaan kepada distributornya. Hasil analisis didapatkan bahwa ARIMA dan *Prophet* merupakan metode peramalan terbaik, hal ini karena kedua metode tersebut memiliki nilai MAPE dan RMSPE yang terendah dibandingkan dengan metode lainnya yang digunakan dalam penelitian ini. Untuk analisis lebih lanjut, dilakukan komparasi *head-to-head*, dimana digunakan 20 sampel produk untuk setiap kategorinya, Maka dihasilkan dari analisis ini bahwa produk pada Kategori 1 lebih baik menggunakan ARIMA dan produk pada Kategori 2 lebih baik menggunakan *Prophet*.

*Forecasting bitcoin* juga dilakukan oleh Yenidogan dkk[4]. Penelitian ini menyajikan semua studi, metodologi, dan hasil tentang peramalan *Bitcoin* dengan metode *Prophet* dan ARIMA menggunakan platform analitik R. Untuk menemukan model peramalan yang paling akurat, metrik kinerja metode *Prophet* dan ARIMA dibandingkan pada *dataset* yang sama. *Dataset* yang dipergunakan dalam penelitian ini adalah data *bitcoin* mulai dari Mei 2016 sampai dengan Maret 2018, berdasarkan pengujian ekstensif, kami melihat bahwa *Prophet* mengungguli ARIMA sebesar 0,94 hingga 0,68 dalam nilai R 2.

Komparasi antara metode *Prophet* dan ARIMA juga dilakukan oleh Chandra dkk [5]. penelitian ini membandingkan metode *Prophet* dan ARIMA untuk meramalkan data pemasaran mahasiswa baru berdasarkan wilayah. *Dataset* yang dipilih untuk penelitian ini menggunakan data aktual selama 26 tahun yang memiliki interval tahunan. Berdasarkan p yang diuji yang telah lakukan, *Prophet* memiliki performa yang lebih baik dibandingkan dengan ARIMA.

Peramalan terhadap data penjualan juga dilakukan oleh Kumar Jha dkk [6], mengusulkan alat *Prophet* untuk peramalan penjualan data supermarket. Penelitian yang diusulkan telah meneliti beberapa model peramalan seperti - Model aditif, model *Autoregressive integrated moving average (ARIMA)*, model *Prophet*. Dari penelitian yang diusulkan, disimpulkan bahwa, *Prophet* adalah model peramalan memiliki kinerja yang lebih baik dengan menghasilkan MAPE 8.3%.

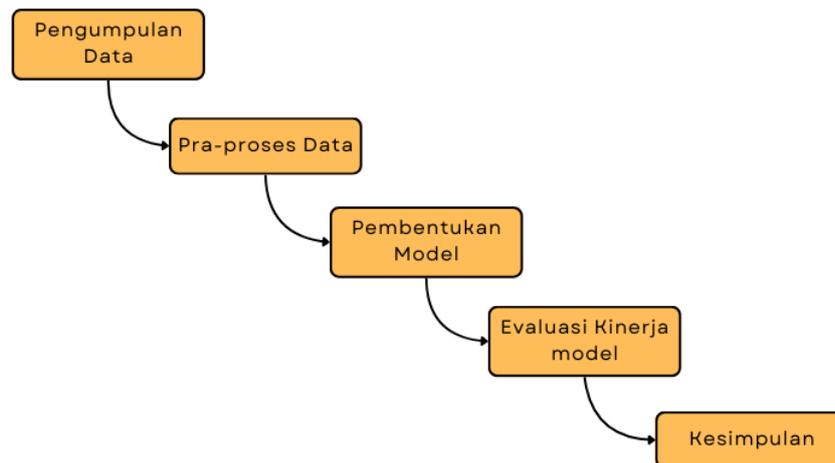
*Forecasting* terhadap permintaan dengan barang farmasi juga dilakukan oleh Fourkiotis dkk [7], mereka melakukan analisis deret waktu statistik, baik model *Triple Exponential Smoothing* maupun peramalan ARIMA menunjukkan hasil yang menjanjikan, dengan model yang pertama, terutama untuk M01AE, memiliki MAPE 29,04% dan model yang kedua unggul untuk M01AB dengan tingkat kesalahan 19,85%. Selain itu, peramalan jangka panjang kami dengan model *Prophet* menunjukkan hasil yang lebih baik, terutama ketika diterapkan pada N05B - kategori obat psikoleptik, yang menunjukkan persentase kesalahan absolut rata-rata (MAPE) sebesar 18,39%. Diskusi seputar model statistik ini menggali efektivitasnya dalam pola yang kompleks dalam penjualan farmasi, dengan model *Prophet* yang menonjol dalam peramalan jangka panjang.

Berdasarkan beberapa penelitian sebelumnya, rumah sakit sering menghadapi tantangan dalam menentukan jumlah pembelian barang farmasi agar tidak terjadi kekurangan atau kelebihan stok. Oleh karena itu, diperlukan teknik *forecasting* yang tepat untuk meramalkan data penjualan dengan akurat. Teknik ini diharapkan dapat membantu rumah sakit dalam mengelola gudang farmasi secara efisien dan memastikan ketersediaan barang sesuai kebutuhan. Penelitian ini bertujuan untuk menemukan metode yang tepat dalam mengatasi masalah kekurangan dan kelebihan persediaan barang farmasi di rumah sakit. Dengan demikian, rumah sakit dapat melakukan peramalan persediaan yang lebih akurat. Hal ini akan membantu

dalam proses pengadaan unit farmasi agar permintaan yang diajukan sesuai dengan kebutuhan sebenarnya. Selain itu, metode yang tepat juga akan mengoptimalkan penggunaan sumber daya dan mengurangi biaya. Akhirnya, penelitian ini diharapkan dapat meningkatkan efisiensi dan efektivitas operasional rumah sakit.

## II. METODE PENELITIAN

Proses penelitian ini terdiri dari beberapa tahapan yang sistematis. Tahapan pertama adalah pengumpulan data, kemudian dilanjutkan dengan pra-proses data dan pembentukan model. Selanjutnya, dilakukan proses *forecasting* menggunakan ARIMA dan *Prophet*, yang diakhiri dengan evaluasi hasil *forecasting* dan penentuan kesimpulan, seperti yang dapat dilihat pada Gambar 1.



Gambar 1. Alur proses penelitian

Pada tahap pertama, dilakukan pencarian data penjualan barang farmasi dari rumah sakit. Rentang waktu yang digunakan untuk pengumpulan data ini mencakup data tahun 2021 hingga tahun 2023. Data ini akan menjadi dasar analisis untuk memahami tren penjualan selama periode tersebut.

Setelah data terkumpul kemudian dilanjutkan ke tahap berikutnya yaitu Pra-proses Data. Ada beberapa cara yang dilakukan dalam tahap ini diantaranya menghapus baris data yang pada salah satu atributnya memiliki nilai kosong, menghapus kolom yang tidak diperlukan, melakukan penyesuaian tipe data yang memiliki format yang tidak sesuai, menghapus data yang memiliki nilai negatif pada kolom jumlah dikarenakan mengindikasikan transaksi retur, penghapusan kode barang OBT00000 ini mengindikasikan bahwa barang yang dijual adalah obat racikan dan dilakukan perubahan periode data yang awalnya merupakan data penjualan harian diubah menjadi periode mingguan. Setelah melalui proses ini kemudian dilakukan analisis data dan dipilih lima barang teratas dengan ketentuan memiliki penjualan pada setiap periode minggunya.

Setelah itu, penelitian ini memasuki tahap pembentukan model yang menggunakan dua metode peramalan, yaitu ARIMA dan *Prophet*. Kedua metode ini digunakan untuk menghasilkan nilai peramalan yang akurat. Kemudian tahap selanjutnya adalah tahap evaluasi, hasil peramalan tersebut diuji kinerjanya untuk mengevaluasi keefektifan masing-masing metode. Pengujian kinerja dilakukan dengan menggunakan dua metode pengujian, yaitu MAE (*Mean Absolute Error*) dan RMSE (*Root Mean Square Error*). Dengan demikian, penelitian ini mengkaji efektivitas kedua metode peramalan melalui pengujian yang komprehensif. Model yang menghasilkan nilai MAE dan RMSE terkecil akan ditetapkan sebagai model deret waktu dengan kinerja terbaik.

## III. HASIL DAN PEMBAHASAN

### A. Pengumpulan Data

Tahap pertama yang dilakukan dalam penelitian ini adalah mengumpulkan data yang dibutuhkan. Data yang dipergunakan dalam penelitian ini diambil dari data penjualan harian barang farmasi dari salah satu rumah sakit di Kabupaten Bandung, dimana rentang waktu data penjualan yang dikumpulkan adalah selama tiga tahun, dimulai dari tahun 2021 sampai dengan tahun 2023. Data penjualan yang diambil ini memiliki jumlah baris data sebanyak 1.776.686 dan mencakup 2.331 jenis barang farmasi. Gambaran data awal yang dikumpulkan untuk penelitian ini dapat dilihat pada Tabel 1.

TABEL 1  
DATA AWAL PENJUALAN BARANG FARMASI

Tanggal	Departemen	Gudang	User	Kode Item	NamaItem	Satuan	Jumlah
01/01/2021	KELAS I :CIKAHURI PAN COVID[KUNING]	5. DEPO FARMASI - RAWAT INAP	*****	OBTUL0039	LOVENOX 20 MG/0.2 ML SYRINGES INJ	SRG	2
01/01/2021	KELAS I :CIKAHURI PAN[KUNING]	5. DEPO FARMASI - RAWAT INAP	*****	OBTUT0043	TREMENZA TAB	TAB	3
01/01/2021	KELAS I :CIKAHURI PAN[KUNING]	5. DEPO FARMASI - RAWAT INAP	*****	OBTUB0010	BECOM ZET TAB (v)	TAB	1
01/01/2021	KELAS I :CIKAHURI PAN[KUNING]	5. DEPO FARMASI - RAWAT INAP	*****	OBTUR0027	RINGER LACTAT INF SANBE (DP)	BAG	6
01/01/2021	KELAS I :CIWALAGRI [CIWA - 9 - 1]	5. DEPO FARMASI - RAWAT INAP	*****	OBTUA0028	AMINOphylline INJ	AMP	1
01/01/2021	KELAS I :CIKAHURI PAN COVID[KUNING]	5. DEPO FARMASI - RAWAT INAP	*****	OBTUL0039	LOVENOX 20 MG/0.2 ML SYRINGES INJ	SRG	2

### B. Pra-proses Data

Dalam tahap ini, dilakukan pra-proses data setelah data yang dibutuhkan dalam penelitian ini terkumpul. Proses pembersihan data ini terdapat beberapa langkah yang dilakukan. Langkah pertama adalah melakukan pengecekan untuk mengetahui apakah terdapat data kosong pada setiap atribut. Hasil pengecekan, seperti yang ditunjukkan pada Gambar 2, mengidentifikasi adanya nilai kosong pada salah satu baris data. Untuk mengatasi hal ini, dilakukan penghapusan baris data yang memiliki nilai kosong, data ini dihapus karena jumlahnya yang sedikit dan dinilai tidak akan mempengaruhi proses selanjutnya.

```
Tanggal      1
Gudang       1
Kode Item    1
NamaItem     0
Jumlah       1
dtype: int64
```

Gambar 2. Menunjukkan contoh atribut yang memiliki data kosong

Setelah membersihkan data dari nilai kosong, langkah selanjutnya adalah menghapus kolom-kolom yang tidak diperlukan untuk menjaga kerahasiaan data. Kolom-kolom yang dihapus termasuk Departemen, User, dan Satuan. Tabel 2 menunjukkan hasil data setelah penghapusan kolom yang tidak diperlukan telah dilakukan.

TABEL 2  
DATA PENJUALAN BARANG FARMASI

Tanggal	Gudang	Kode Item	NamaItem	Jumlah
01/01/2021	5. DEPO FARMASI - RAWAT INAP	OBTUL0039	LOVENOX 20 MG/0.2 ML SYRINGES INJ	2
01/01/2021	5. DEPO FARMASI - RAWAT INAP	OBTUT0043	TREMENZA TAB	3
01/01/2021	5. DEPO FARMASI - RAWAT INAP	OBTUB0010	BECOM ZET TAB (v)	1
01/01/2021	5. DEPO FARMASI - RAWAT INAP	OBTUR0027	RINGER LACTAT INF SANBE (DP)	6
01/01/2021	5. DEPO FARMASI - RAWAT INAP	OBTUA0028	AMINOphylline INJ	1
01/01/2021	5. DEPO FARMASI - RAWAT INAP	OBTUL0039	LOVENOX 20 MG/0.2 ML SYRINGES INJ	2

Setelah menemukan format data yang tidak sesuai pada kolom tanggal, langkah berikutnya adalah menyesuaikan tipe data kolom tersebut. Dilakukan penyesuaian untuk mengubah format date menjadi *datetime* sesuai dengan kebutuhan. Gambar 3 memperlihatkan hasil data setelah tipe data kolom yang sesuai telah diubah menjadi *datetime*.

```
Tanggal      datetime64[ns]
Gudang       object
Kode Item    object
NamaItem     object
Jumlah      float64
dtype: object
```

Gambar 3. Menunjukkan tipe data pada *dataset*

Setelah itu, ditemukan stok dengan nilai negatif yang merupakan hasil dari retur dalam data penjualan barang farmasi. Untuk menjaga akurasi proses *forecasting*, data dengan nilai stok negatif perlu dihapus dari *dataset* yang akan digunakan. Dalam *dataset* ini, teridentifikasi 102.680 baris data dengan nilai stok negatif. Gambar 4 menampilkan contoh data yang mengandung nilai stok negatif dalam *dataset*. Langkah penghapusan data ini penting untuk memastikan analisis dan peramalan yang akan dilakukan.

```

                NamaItem Jumlah
104          ASAM TRANEXamat INJ [Retur] -3.0
495          FUROSEMIDE INJ [Retur] -2.0
791          RILLUS TAB (S) [Retur] -2.0
792          GRANON 3MG/3ML INJ [Retur] -1.0
793          MORPHINE INJ [Retur] -3.0
...
1776573          SANMOL TAB [Retur] -6.0
1776599          SPIRONOLACTONE 100 MG TAB [Retur] -1.0
1776628  SODIUM CHLORIDE (NACL) 0,9 500 ML INF BBRAUN [... -1.0
1776634  SODIUM CHLORIDE (NACL) 0,9 100 ML INF BBRAUN [... -1.0
1776645          TRAMADOL 50 INJ [Retur] -2.0

[102680 rows x 5 columns]
```

Gambar 4. Menunjukkan data dengan nilai minus

Selanjutnya, ditemukan bahwa data dengan kode OBT00000 mengindikasikan bahwa barang yang dijual adalah obat racikan, yang terdiri dari beberapa barang lainnya. Untuk keperluan penelitian ini, data obat racikan ini dianggap tidak relevan dan perlu dihapus dari *dataset*. Dalam *dataset* yang digunakan, tercatat sebanyak 28.032 baris data yang mengandung informasi tentang obat racikan. Penghapusan data obat racikan ini diperlukan untuk memastikan keakuratan dan ketepatan analisis yang akan dilakukan. Setelah dilakukan pra-proses data dimensi data setelah pra-proses ini berubah menjadi berjumlah 1.645.973 baris data.

*Dataset* awal berisi data harian penjualan barang farmasi. Untuk keperluan studi kasus ini, di mana pembelian persediaan farmasi dilakukan mingguan, *dataset* ini kemudian disesuaikan dengan periode mingguan. Setelah *dataset* disesuaikan menjadi periode mingguan, kemudian diurutkan berdasarkan barang yang memiliki penjualan pada setiap minggunya selama tiga tahun. Kemudian dipilihlah lima sampel barang farmasi teratas untuk dilakukan analisis data dan proses pengujian melalui model ARIMA dan *Prophet*. Kelima barang yang dipilih yaitu OBTUC0027, ALKUF0024, OBTUD0042, ALKUT0020, dan OBTUD0011. Data penjualan mingguan untuk lima barang ini ditampilkan pada Gambar 5, yang memperlihatkan lima data teratas yang menunjukkan penjualan setiap minggunya. Kemudian setelah dipilih kelima barang ini dirubah periode data penjualannya menjadi mingguan yang dapat dilihat pada Tabel 3. Kemudian dapat dilihat grafik data penjualan ke lima barang farmasi dengan periode mingguan selama tiga tahun pada Gambar 6.

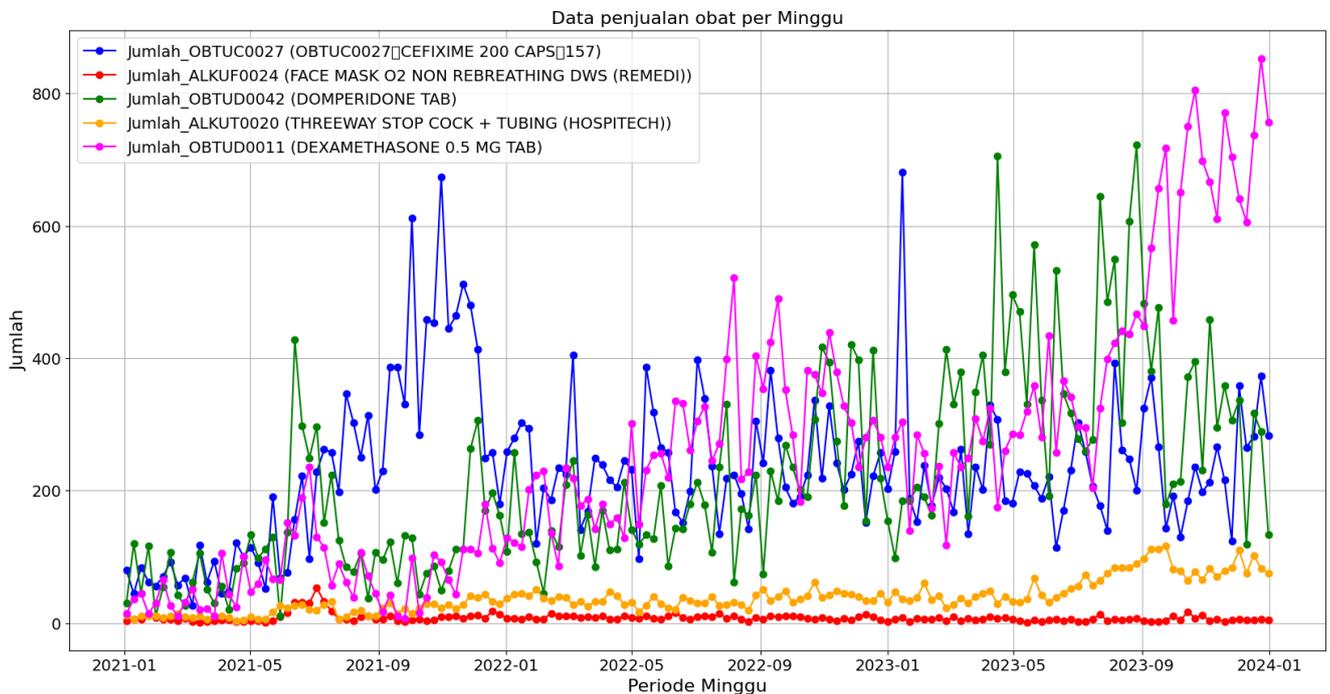
Kode Item	NamaItem	Tanggal	
1135	OBTUC0027	CEFIXIME 200 CAPS	157
271	ALKUF0024	FACE MASK O2 NON REBREATHING DWS (REMEDI)	157
1308	OBTUD0042	DOMPERIDONE TAB	157
635	ALKUT0020	THREEWAY STOP COCK + TUBING (HOSPITECH)	157
1279	OBTUD0011	DEXAMETHASONE 0.5 MG TAB	157
...	...	...	...
541	ALKUS0062	SPIUT 1 CC TUB ONEMED, Box/100	1
549	ALKUS0066	SPIUT 3 CC ONEMED, Box/100	1
2059	OBTUP0073	PULMICORT 0,25 RESP (0.5 MG/2 ML)	1
560	ALKUS0076	STIMUPLEX A 22GX2 (0.70X50MM)	1
598	ALKUS0123	SUTRYL NO 2/0 KODE H37129 (SUTCON)	1

2529 rows x 3 columns

Gambar 5. Data barang farmasi dengan jumlah minggu yang terdapat penjualan

TABEL 3  
PERUBAHAN PENJUALAN BARANG FARMASI MENJADI PERIODE MINGGUAN

Week	Jumlah_OBTUC0027
2023-11-27/2023-12-03	358
2023-12-04/2023-12-10	265
2023-12-11/2023-12-17	282
2023-12-18/2023-12-24	373
2023-12-25/2023-12-31	283
2023-11-27/2023-12-03	358



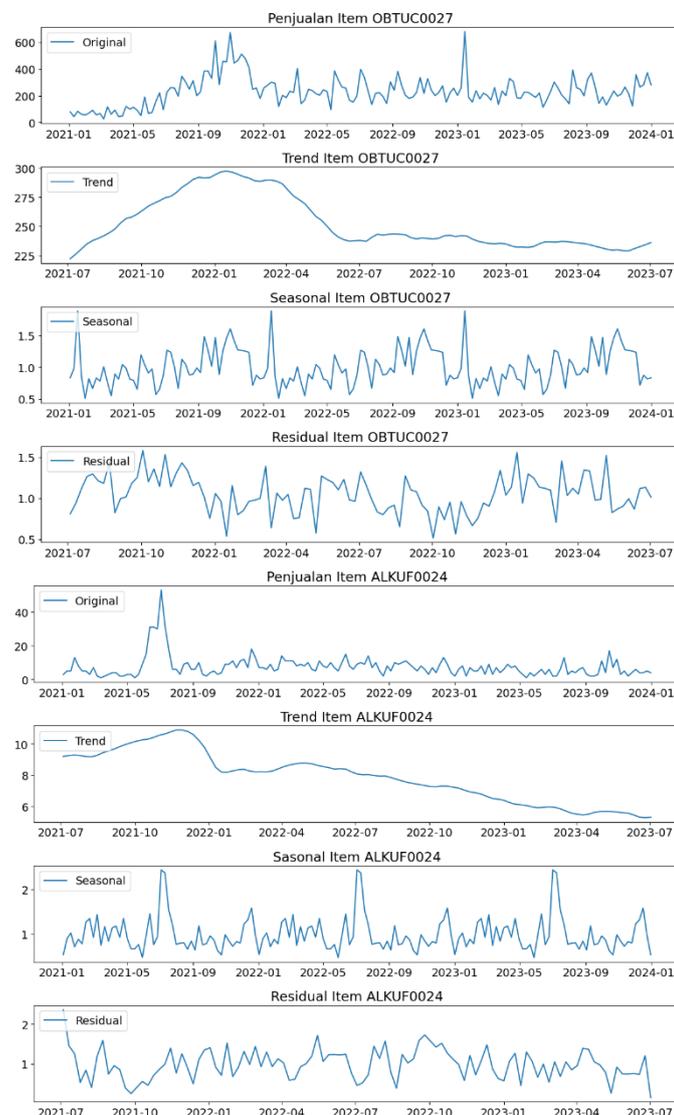
Gambar 6. Grafik data penjualan obat per minggu selama tiga tahun

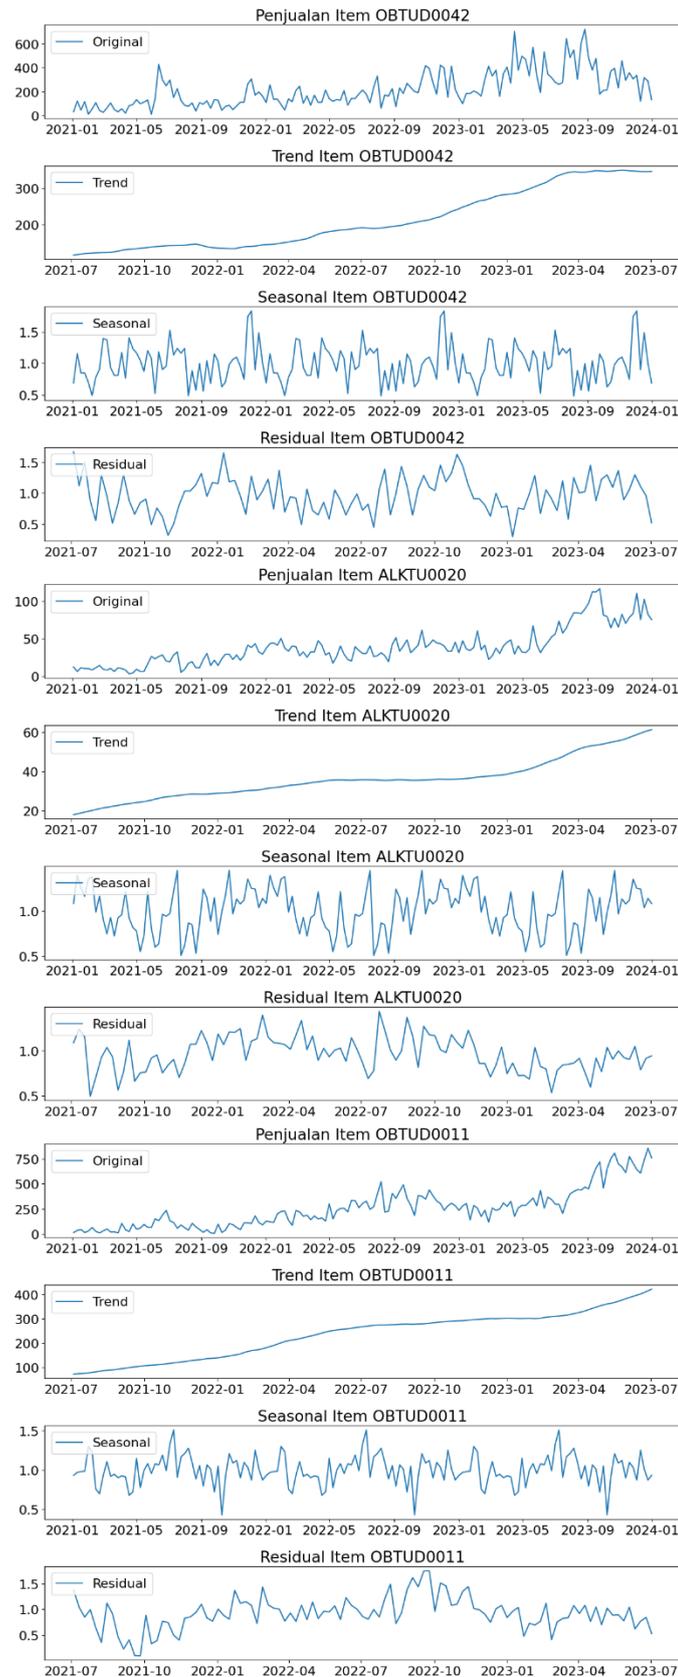
### C. Pembentukan model

#### 1) Time series decomposition

Dekomposisi deret waktu merupakan tugas statistik yang bertujuan untuk mendekonstruksi deret waktu menjadi beberapa komponen, di mana masing-masing komponen merepresentasikan salah satu kategori pola yang mendasarinya. Data deret waktu dapat menunjukkan berbagai pola, dan sering kali sangat membantu untuk membagi deret waktu menjadi beberapa komponen, masing-masing mewakili kategori pola yang mendasarinya. Tiga jenis pola dalam deret waktu adalah tren, musiman, dan siklus. Ketika kita menguraikan deret waktu menjadi beberapa komponen, tren dan siklus sering kali digabungkan menjadi satu komponen yang disebut komponen tren-siklus (sering disederhanakan menjadi komponen tren). Dengan demikian, deret waktu dianggap terdiri dari tiga komponen utama: komponen tren-siklus, komponen musiman, dan komponen *residual*. Komponen *residual* ini mencakup semua variasi lain dalam deret waktu yang tidak dijelaskan oleh komponen tren-siklus dan musiman [8]

Sebelum melakukan pembentukan Model tahapan ini dilakukan terlebih dahulu untuk dapat memahami komponen deret waktu yang ada pada kelima barang yang akan diuji. Tahapan ini sangat menentukan hasil peramalan dari model yang akan digunakan dikarenakan model ini akan dipengaruhi oleh data deret waktu sebelumnya. Untuk menguraikan komponen deret waktu dalam penelitian ini menggunakan *library python statsmodels.tsa.seasonal.seasonal\_decompose*. Fungsi *library* ini menguraikan komponen deret waktu yang ada pada data penjualan setiap barang farmasi yang dapat dilihat pada Gambar 7.





Gambar 7. Grafik dekomposisi komponen deret waktu pada setiap barang farmasi

## 2) Pembentukan Model ARIMA

ARIMA model merupakan salah satu pendekatan matematika yang paling sederhana dan paling banyak digunakan untuk pemodelan deret waktu *non-seasonal* [9]. Model ARIMA sama seperti model deret waktu lainnya, memiliki peramalan yang sesuai bila prediktor dapat mengasumsikan jumlah yang didapat dengan pola masa depan dan tren yang menyerupai pola dan tren saat ini. ARIMA cocok untuk peramalan jangka pendek, 12 bulan atau kurang [5],[10]. Dalam pembentukan model ARIMA dibutuhkan parameter p, d dan q dimana p adalah *Autoregressive* (AR) menggambarkan pola antara satu periode waktu dan periode sebelumnya, d adalah *differencing* atau komponen terintegrasi (I) ini menggambarkan perbedaan dari satu bulan ke bulan berikutnya yang dimodelkan dan q adalah *moving Moving Average* (MA) menggambarkan *error* penyesuaian peramalan baru terhadap kesalahan peramalan sebelumnya [10].

Fungsi `auto_arima` menyesuaikan model ARIMA terbaik dengan deret waktu univariat sesuai dengan kriteria informasi yang diberikan, seperti AIC, AICc, BIC, atau HQIC. Fungsi ini melakukan pencarian dengan otomatis atas kemungkinan model dan urutan musiman dalam batasan yang disediakan, baik secara bertahap atau paralel. Parameter yang digunakan dalam fungsi ini sangat mempengaruhi hasil akhir. Pemilihan parameter yang tepat bertujuan untuk meminimalkan metrik yang diberikan. Oleh karena itu, penting untuk mengatur parameter dengan hati-hati agar mendapatkan hasil yang optimal [11].

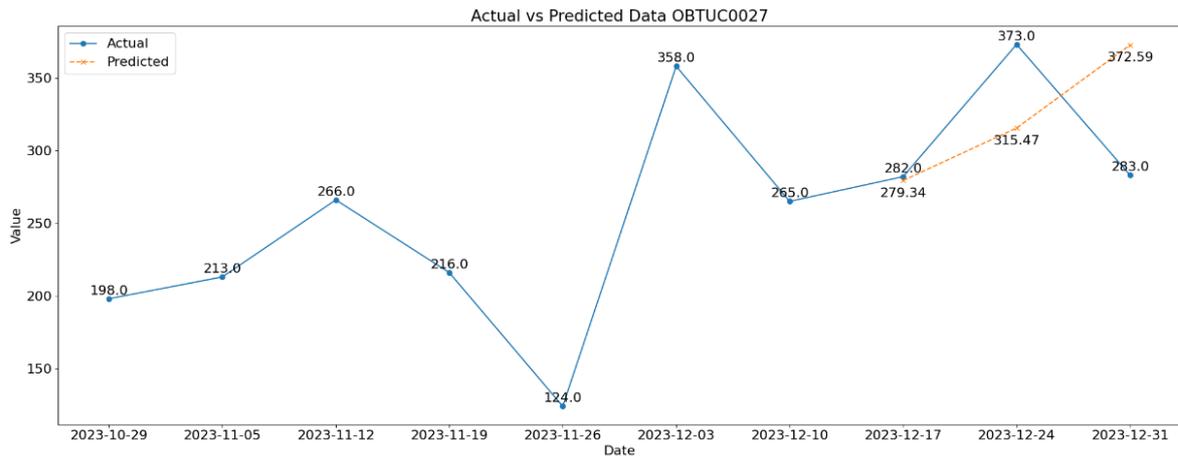
Berikut adalah langkah-langkah yang dilakukan dalam menggunakan Auto ARIMA dalam mencari dan menentukan parameter terbaik (p, d, q) untuk model ARIMA yang akan digunakan dalam analisis *time series*. Tahap pertama adalah melakukan instalasi dan *import library Python* yang dibutuhkan, seperti `pmdarima` dan `pandas`. Setelah itu, dilakukan pengaturan parameter untuk Auto ARIMA sesuai dengan data yang digunakan. Dalam tahap ini, proses Auto ARIMA dapat dipengaruhi oleh data *time series* yang digunakan, misalnya pada barang OBTUC0027 dan ALKUF0024 yang memiliki data tren yang sangat tinggi ditahun pertama. sehingga dalam penelitian ini dilakukan pengaturan parameter d atau *differencing* dalam auto ARIMA secara manual untuk meningkatkan akurasi peramalan. Setelah proses ini dijalankan, Auto ARIMA akan menghasilkan parameter *order* (p, d, q) terbaik untuk model ARIMA, yang dapat dilihat pada Tabel 4.

TABEL 4  
HASIL AUTO ARIMA

Item	Order (p, d, q)
OBTUC0027	(3,2,0)
ALKUF0024	(3,3,0)
OBTUD0042	(1,0,1)
ALKUT0020	(0,1,1)
OBTUD0011	(0,1,3)

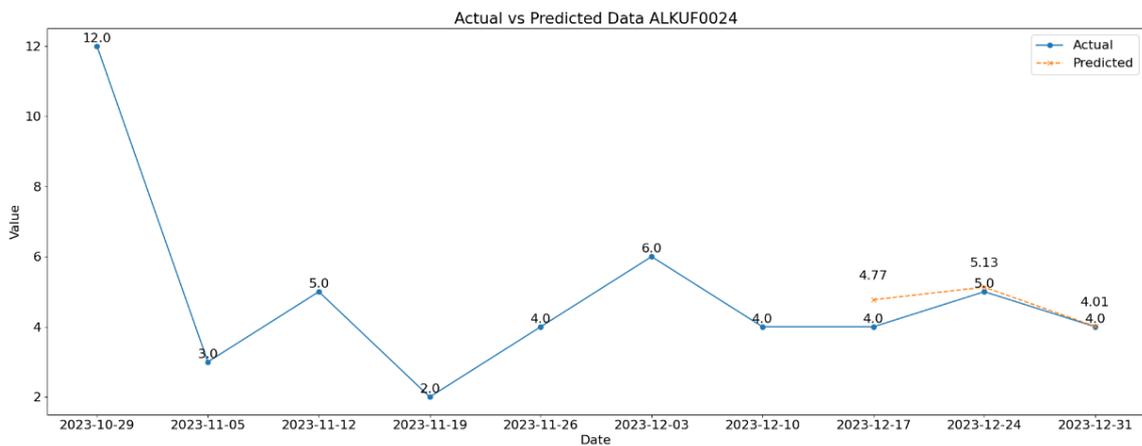
Dalam tahap pembentukan model ARIMA, data penjualan dibagi menjadi dua bagian yaitu data train dan data test. Data test mencakup tiga periode terakhir penjualan, sedangkan data train mencakup penjualan dari awal tahun 2021 hingga sebelum tiga periode terakhir pada tahun 2023. Setelah mengetahui hasil *order* terbaik untuk membuat model ARIMA, langkah selanjutnya adalah melakukan pembentukan model ARIMA terhadap setiap barang yang dipilih. Proses ini melibatkan penentuan parameter ARIMA yang optimal untuk setiap barang berdasarkan data historisnya. Dalam proses ini, parameter ARIMA yang optimal ditentukan melalui analisis data historis untuk masing-masing barang. Hasil dari pembentukan model ARIMA adalah peramalan atau *forecasting* untuk setiap barang.

Hasil peramalan untuk barang OBTUC0027 ini dilakukan dengan model ARIMA *order* (3,2,0). Pada 17 Desember 2023, data aktual adalah 282, sementara hasil peramalan hampir sama yaitu 279.34. Pada 24 Desember 2023, data aktual meningkat signifikan menjadi 373, namun hasil peramalan hanya memperkirakan 315.47. Pada 31 Desember 2023, data aktual turun kembali menjadi 283, sedangkan peramalan memperkirakan hampir sama dengan data aktual sebelumnya, yaitu 372.59. Grafik perbandingan antara data aktual dengan data peramalan tiga periode terakhir pada barang OBTUC0027 dapat dilihat pada Gambar 8.



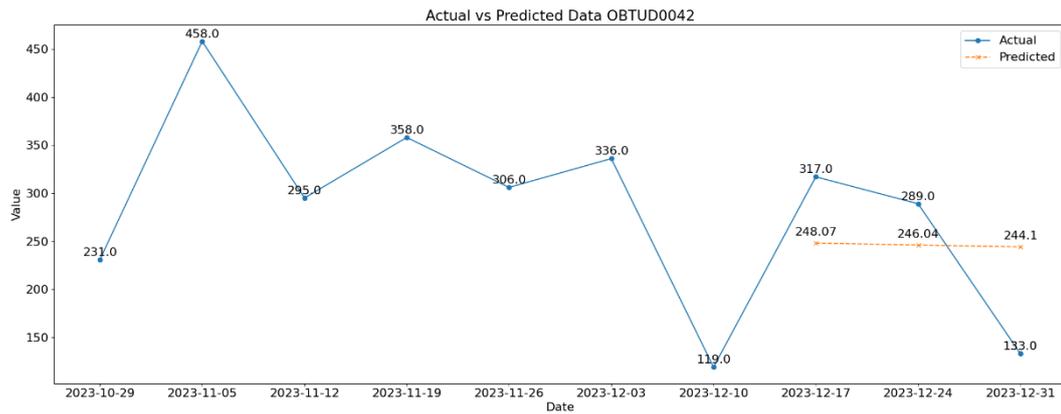
Gambar 8. Grafik perbandingan antara data aktual dengan data peramalan tiga periode terakhir pada barang OBTUC0027

Hasil peramalan untuk barang ALKUF0024 ini dilakukan dengan model ARIMA order (3,3,0). Pada 17 Desember 2023, data aktual adalah 4, sementara hasil peramalan adalah 4.77. Pada 24 Desember 2023, data aktual naik menjadi 5, dengan hasil peramalan yang mendekati, yaitu 5.13. Pada 31 Desember 2023, data aktual kembali menjadi 4, dan hasil peramalan sedikit lebih rendah, yaitu 4.01. Grafik perbandingan antara data aktual dengan data peramalan tiga periode terakhir pada barang ALKUF0024 dapat dilihat pada Gambar 9.



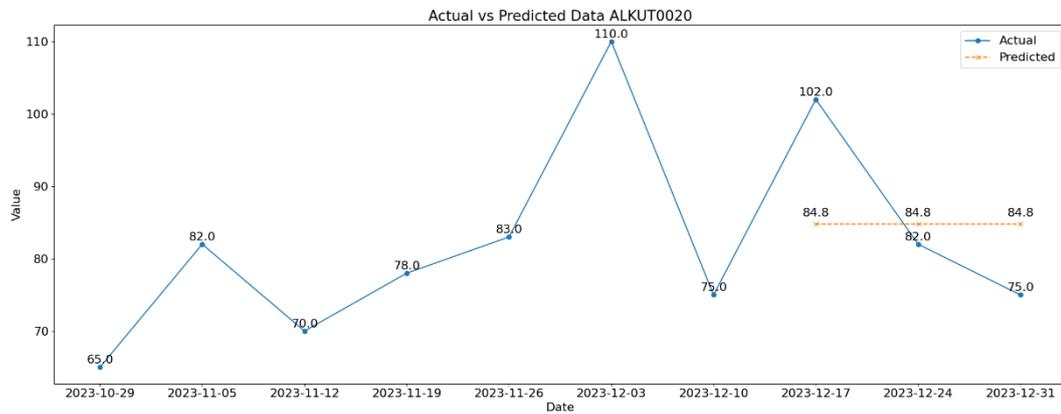
Gambar 9. Grafik perbandingan antara data aktual dengan data peramalan tiga periode terakhir pada barang ALKUF0024

Hasil peramalan untuk barang OBTUD0042 ini dilakukan dengan model ARIMA model (1,0,1). Pada 17 Desember 2023, data aktual adalah 317, sedangkan hasil peramalan lebih rendah pada 248.07. Pada 24 Desember 2023, data aktual menurun menjadi 289, dengan peramalan yang hampir sama yaitu 246.04. Pada 31 Desember 2023, data aktual turun drastis menjadi 133, sementara peramalan tetap stabil pada 244.10. Grafik perbandingan antara data aktual dengan data peramalan tiga periode terakhir pada barang OBTUD0042 dapat dilihat pada Gambar 10.



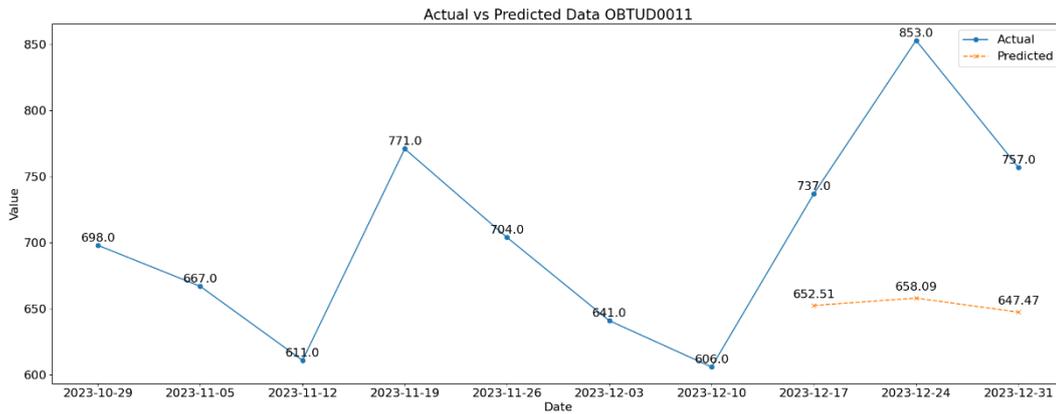
Gambar 10. Grafik perbandingan antara data aktual dengan data peramalan tiga periode terakhir pada barang OBTUD0042.

Hasil peramalan untuk barang ALKUT0020 ini dilakukan dengan model ARIMA model (0,1,1). Pada 17 Desember 2023, data aktual adalah 102, sementara hasil peramalan adalah 84.80. Pada 24 Desember 2023, data aktual menurun menjadi 82, namun hasil peramalan tetap konstan pada 84.80. Pada 31 Desember 2023, data aktual turun lagi menjadi 75, sedangkan peramalan tetap tidak berubah pada 84.80. Grafik perbandingan antara data aktual dengan data peramalan tiga periode terakhir pada barang ALKUT0020 dapat dilihat pada Gambar 11.



Gambar 11. Grafik perbandingan antara data aktual dengan data peramalan tiga periode terakhir pada barang ALKUT0020.

Hasil peramalan untuk barang OBTUD0011 ini dilakukan dengan model ARIMA model (0,1,1). Pada 17 Desember 2023, data aktual adalah 737, sedangkan hasil peramalan lebih rendah pada 652.51. Pada 24 Desember 2023, data aktual meningkat signifikan menjadi 853, namun hasil peramalan hanya sedikit naik menjadi 658.09. Pada 31 Desember 2023, data aktual turun menjadi 757, dengan hasil peramalan yang sedikit lebih rendah pada 647.47. Grafik perbandingan antara data aktual dengan data peramalan tiga periode terakhir pada barang OBTUD0011 dapat dilihat pada Gambar 12.

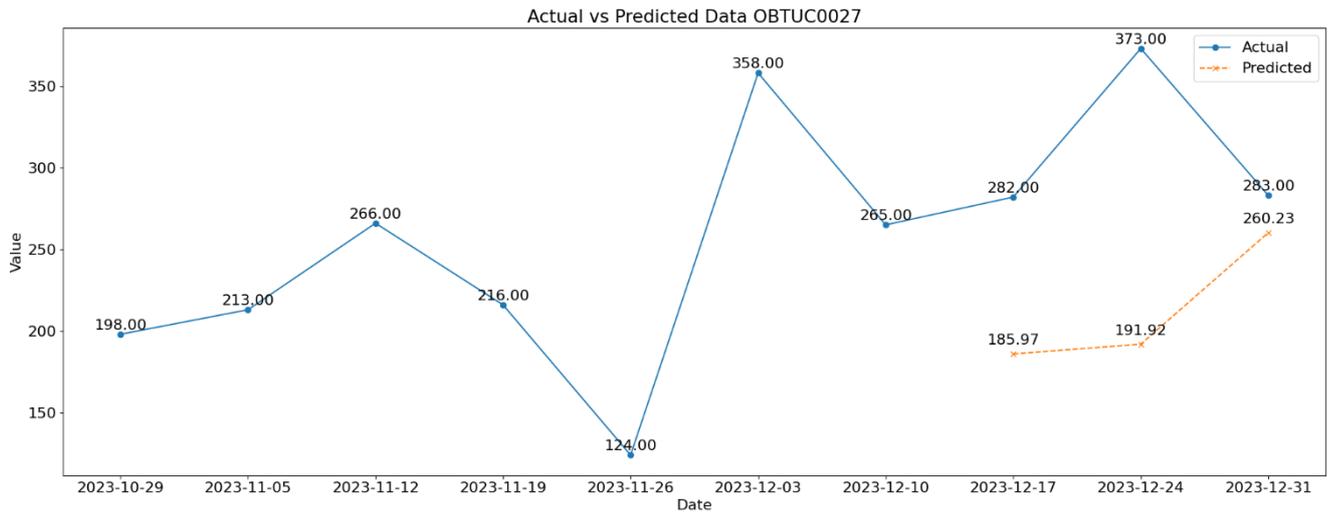


Gambar 12. Grafik perbandingan antara data aktual dengan data peramalan tiga periode terakhir pada barang OBTUD0011.

### 3) Pembentukan model Prophet

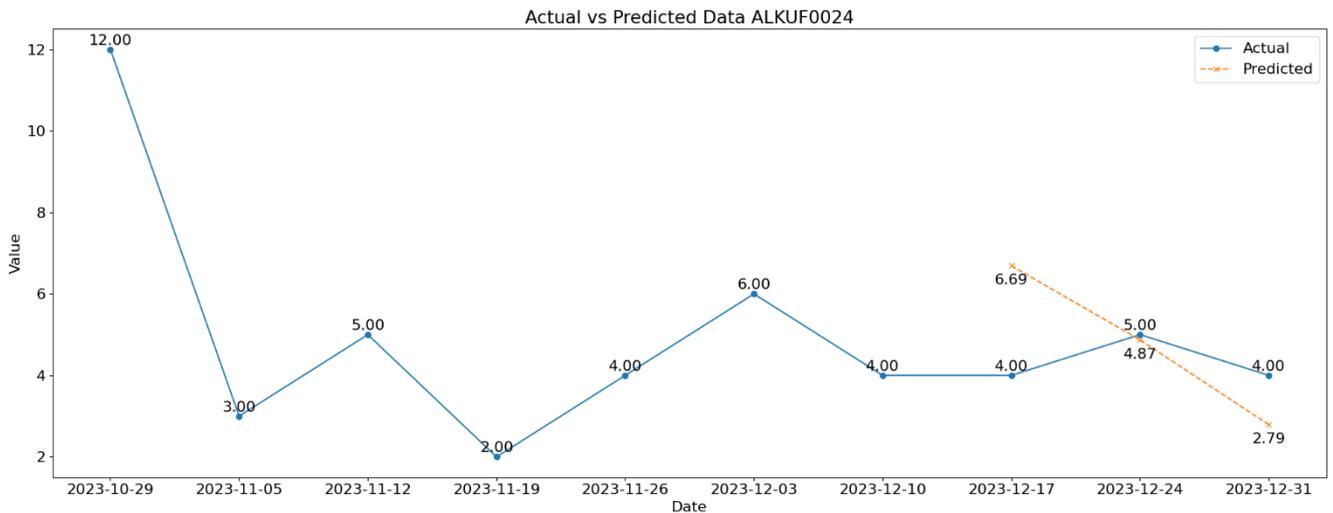
*Prophet* model sebuah alat sumber terbuka yang disediakan oleh *Facebook*, tersedia dalam bahasa *Python* dan *R*. *Prophet* adalah untuk mengembangkan alat peramalan yang fleksibel yang mudah digunakan dan dikonfigurasi. Model dasarnya yaitu untuk menampilkan deret waktu yang dapat diuraikan dengan tiga komponen: *trend*, *seasonal*, dan *irregular components* [8], [10]. *Prophet* menggunakan waktu sebagai repesor dan mencoba untuk menyesuaikan beberapa persamaan deret waktu linear dan nonlinear sebagai komponen fungsi waktu. Pemodelan musiman dianggap sebagai komponen aditif dimana pendekatan yang sama diambil oleh *Exponential Smoothing* dalam teknik *Holt-Winters* [5], [12]. Pembentukan model *Prophet* lebih sederhana dibandingkan dengan menggunakan model *ARIMA*. Langkah pertama adalah menyesuaikan penamaan kolom pada data yang digunakan agar sesuai dengan format yang dibutuhkan oleh *Prophet*. Kolom yang berisi data periode dengan tipe *datetime* diubah namanya menjadi 'ds', sementara kolom yang berisi jumlah *order* diubah namanya menjadi 'y'. Dalam tahap pembentukan model *Prophet*, data penjualan dibagi menjadi dua bagian yaitu data *train* dan data *test*. Data *test* mencakup tiga periode terakhir penjualan, sedangkan data *train* mencakup penjualan dari awal tahun 2021 hingga sebelum tiga periode terakhir pada tahun 2023. Setelah penamaan kolom disesuaikan, dilakukan proses pembentukan model dengan menggunakan *Prophet*. Proses ini menghasilkan data peramalan yang akurat berdasarkan data historis. Tetapi proses *Prophet* ini dapat dipengaruhi oleh data *time series* yang digunakan, misalnya pada barang *OBTUC0027* dan *ALKUF0024* yang memiliki data tren yang sangat tinggi di tahun pertama sehingga mempengaruhi hasil peramalan. Agar didapatkan hasil peramalan yang baik dalam penggunaan model *Prophet* dilakukan proses *detrending* yaitu menghapus tren yang ada dalam data, sehingga menghasilkan hasil peramalan yang lebih baik.

Hasil peramalan untuk barang *OBTUC0027* menunjukkan bahwa pada 17 Desember 2023, data aktual adalah 282, sementara hasil *forecasting* adalah 185.97. Pada 24 Desember 2023, data aktual meningkat menjadi 373, tetapi *forecasting* hanya menunjukkan angka 191.92. Pada 31 Desember 2023, data aktual turun menjadi 283, sementara *forecasting* menunjukkan peningkatan menjadi 260.23. Grafik perbandingan antara data aktual dengan data peramalan tiga periode terakhir pada barang *OBTUC0027* dapat dilihat pada Gambar 13.



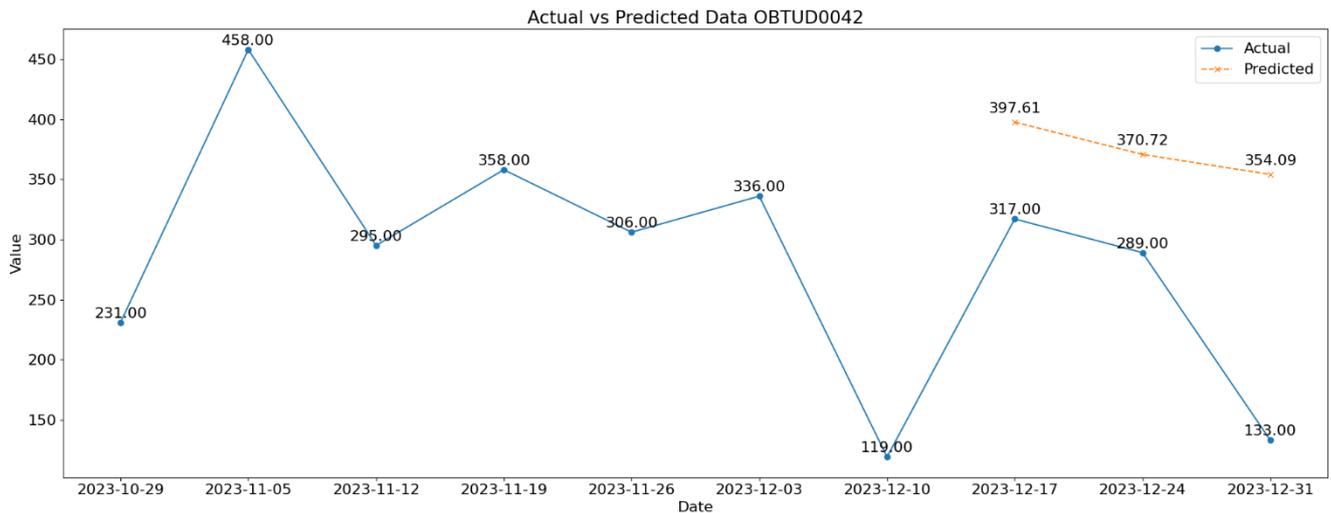
Gambar 13. Grafik perbandingan antara data aktual dengan data peramalan tiga periode terakhir pada barang OBTUC0027.

Hasil peramalan untuk barang ALKUF0024 menunjukkan bahwa pada 17 Desember 2023, data aktual adalah 4, sementara hasil peramalan adalah 6.69. Pada 24 Desember 2023, data aktual naik menjadi 5, dengan peramalan 4.87. Pada 31 Desember 2023, data aktual kembali menjadi 4, sedangkan hasil peramalan adalah 2.79. Grafik perbandingan antara data aktual dengan data peramalan tiga periode terakhir pada barang ALKUF0024 dapat dilihat pada Gambar 14.



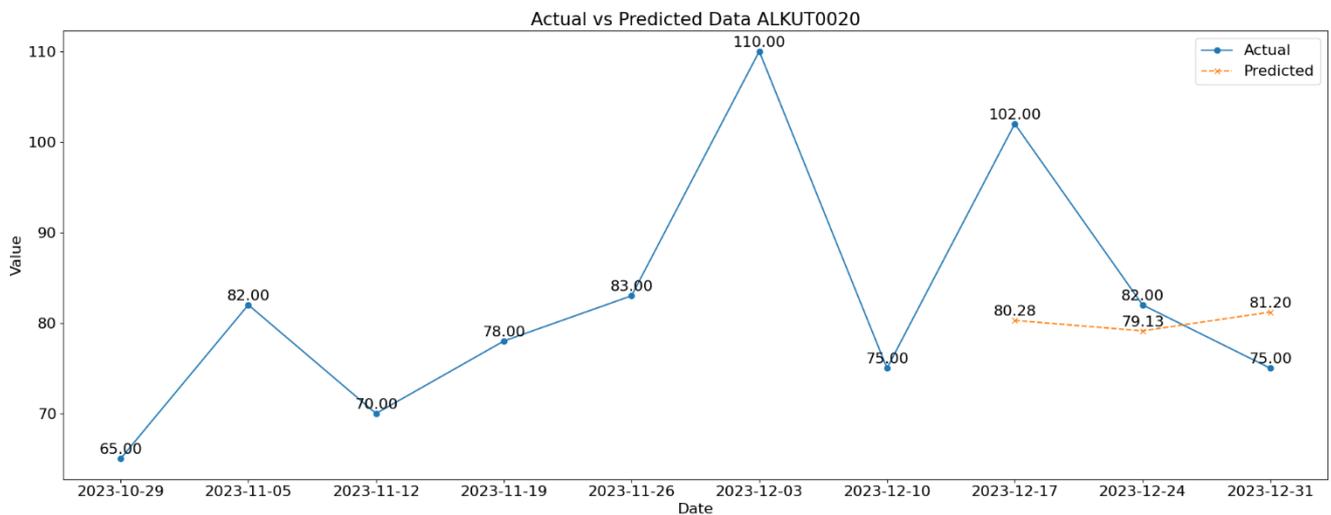
Gambar 14. Grafik perbandingan antara data aktual dengan data peramalan tiga periode terakhir pada barang ALKUF0024.

Hasil peramalan untuk barang OBTUD0042 menunjukkan bahwa pada 17 Desember 2023, data aktual adalah 317, sedangkan hasil peramalan lebih tinggi pada 397.61. Pada 24 Desember 2023, data aktual menurun menjadi 289, dengan peramalan 370.72. Pada 31 Desember 2023, data aktual turun drastis menjadi 133, sementara peramalan tetap tinggi pada 354.09. Grafik perbandingan antara data aktual dengan data peramalan tiga periode terakhir pada barang OBTUD0042 dapat dilihat pada Gambar 15.



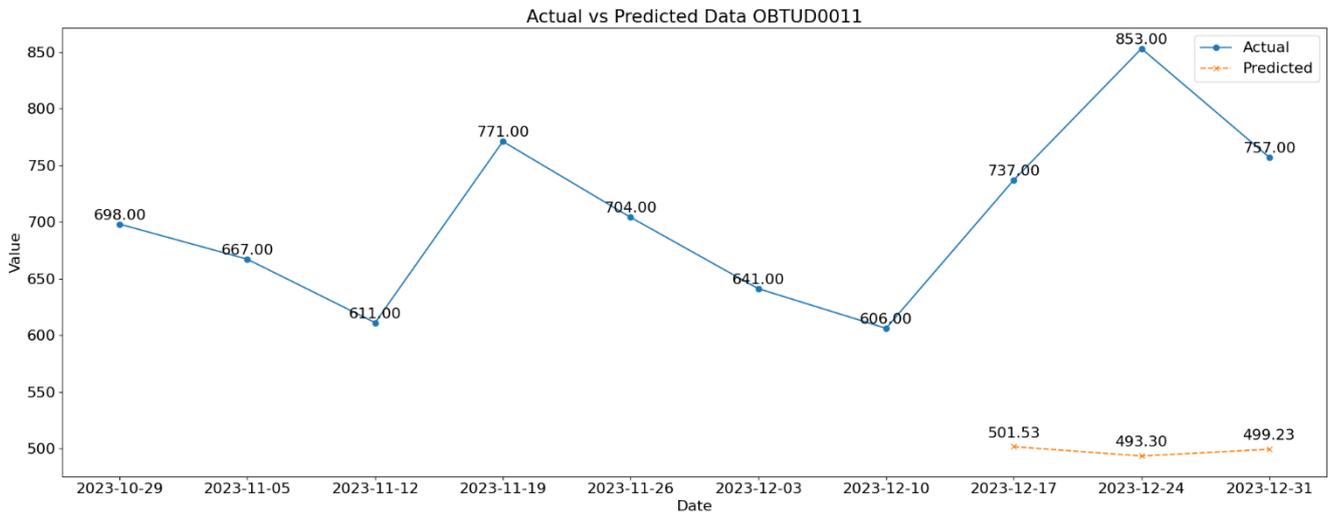
Gambar 15. Grafik perbandingan antara data aktual dengan data peramalan tiga periode terakhir pada barang OBTUD0042.

Hasil peramalan untuk barang ALKUT0020 menunjukkan hasil yang cukup akurat. Pada 17 Desember 2023, data aktual adalah 102, sementara hasil peramalan adalah 80.28. Pada 24 Desember 2023, data aktual turun menjadi 82, dengan peramalan 79.13. Pada 31 Desember 2023, data aktual turun lagi menjadi 75, dengan peramalan sedikit meningkat menjadi 81.20. Grafik perbandingan antara data aktual dengan data peramalan tiga periode terakhir pada barang ALKUT0020 dapat dilihat pada Gambar 16.



Gambar 16. Grafik perbandingan antara data aktual dengan data peramalan tiga periode terakhir pada barang ALKUT0020.

Hasil peramalan untuk barang OBTUD0011 menunjukkan peramalan yang lebih rendah daripada data aktual. Pada 17 Desember 2023, data aktual adalah 737, sedangkan hasil peramalan adalah 501.53. Pada 24 Desember 2023, data aktual naik menjadi 853, tetapi peramalan tetap rendah pada 493.30. Pada 31 Desember 2023, data aktual turun menjadi 757, dengan peramalan sedikit naik menjadi 499.23. Grafik perbandingan antara data aktual dengan data peramalan tiga periode terakhir pada barang OBTUD0011 dapat dilihat pada Gambar 17.



Gambar 17. Grafik perbandingan antara data aktual dengan data peramalan tiga periode terakhir pada barang OBTUD0011.

#### D. Evaluasi kinerja model

Pada tahap ini, dilakukan evaluasi untuk setiap model menggunakan MAE (*Mean Absolute Error*) dan RMSE (*Root Mean Squared Error*). Tujuan dari evaluasi ini adalah untuk melihat kinerja setiap model dalam melakukan *forecasting* dengan membandingkan data hasil *forecasting* terhadap data aktual. MAE adalah rata-rata dari nilai absolut perbedaan antara nilai yang diramalkan ( $\hat{y}_i$ ) dan nilai yang sebenarnya ( $y_i$ ) dimana ( $n$ ) merupakan jumlah data. RMSE adalah akar kuadrat dari rata-rata jumlah kuadrat perbedaan antara nilai yang diramalkan ( $\hat{y}_i$ ) dan nilai yang sebenarnya ( $y_i$ ) dimana ( $n$ ) merupakan jumlah data [13],[14]. Kedua metrik ini digunakan untuk mengevaluasi kinerja model peramalan. Rumus dari kedua metode ini dapat dilihat pada persamaan nomor (1) dan (2) berikut :

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2)$$

Tabel 5 menunjukkan tingkat kesalahan yang menggambarkan kinerja model dalam melakukan *forecasting*. Dari data di Tabel 5, dapat dilihat bahwa model ARIMA memiliki nilai kesalahan yang lebih kecil dibandingkan dengan model *Prophet*. Evaluasi ini memberikan gambaran jelas mengenai kelebihan dan kekurangan masing-masing model dalam berbagai kondisi data.

TABEL 5  
 PERBANDINGAN KINERJA MODEL ARIMA DAN *PROPHET*

Item	ARIMA		<i>Prophet</i>	
	MAE	RMSE	MAE	RMSE
OBTUC0027	0.16008	0.30216	0.20338	0.34550
ALKUF0024	0.07310	0.33374	0.11187	0.42637
OBTUD0042	0.40049	0.73312	0.50570	0.98453
ALKUT0020	0.11112	0.11023	0.12473	0.13344
OBTUD0011	0.16261	0.36057	0.16959	0.36325

Dalam penelitian terkait data *time series*, penggunaan MAE (*Mean Absolute Error*) dan RMSE (*Root Mean Squared Error*) menjadi sangat penting dalam mengevaluasi akurasi peramalan. MAE memiliki keunggulan karena kurang sensitif terhadap *outlier* dan mudah dipahami. Ini disebabkan oleh cara MAE menghitung rata-rata dari kesalahan absolut, yang

memperlakukan semua deviasi secara setara tanpa menekankan lebih pada kesalahan besar. Dengan demikian, MAE cocok digunakan ketika interpretasi sederhana dari besarnya rata-rata kesalahan menjadi prioritas.

Di sisi lain RMSE memberikan penalti lebih tinggi untuk kesalahan besar karena kesalahan tersebut dikuadratkan sebelum dirata-ratakan. Ini membuat RMSE sangat berguna dalam konteks di mana kesalahan besar sangat tidak diinginkan. Selain itu, RMSE dapat didiferensiasikan, yang menguntungkan dalam proses optimasi menggunakan metode berbasis gradien.

Hyndman dan Koehler menekankan bahwa tidak ada satu ukuran akurasi peramalan yang terbaik secara universal. Oleh karena itu, pemilihan antara MAE dan RMSE harus dipandu oleh kebutuhan dan konteks spesifik dari tugas peramalan. Kombinasi penggunaan kedua metrik ini seringkali memberikan penilaian yang lebih komprehensif tentang performa model peramalan, di mana MAE memberikan gambaran umum tentang rata-rata kesalahan dan RMSE menyoroti kesalahan yang lebih besar [14].

#### IV. SIMPULAN

Berdasarkan penelitian yang telah dilakukan, dapat diambil kesimpulan bahwa kedua metode yang telah diuji, yaitu ARIMA dan *Prophet*, dapat menjadi solusi yang efektif bagi rumah sakit dalam mengatasi masalah persediaan barang farmasi. Hal ini terbukti dari hasil peramalan yang dihasilkan oleh kedua model, yang nilai peramalannya mendekati nilai aktual pada tiga periode terakhir di tahun 2023. Penelitian ini juga mendukung hipotesis bahwa tren data masa lalu mempengaruhi peramalan di masa mendatang. Kedua metode melakukan penyesuaian untuk mendapatkan hasil terbaik dalam peramalan barang farmasi OBTUC0027 dan ALKUF0024. Untuk model ARIMA, dilakukan pengaturan manual pada nilai 'd' atau differencing untuk memperoleh hasil peramalan terbaik. Sementara itu, model *Prophet* melakukan *detrending* atau penghapusan tren yang fluktuatif untuk mendapatkan hasil peramalan optimal. Dari evaluasi model menggunakan MAE dan RMSE, terlihat bahwa model ARIMA memiliki kinerja yang lebih baik dibandingkan *Prophet* dalam melakukan *forecasting* untuk kelima barang farmasi ini, dengan nilai *error* terkecil yang diperoleh adalah 0.07310.

Dalam penelitian ini hasil evaluasi ARIMA memiliki kinerja lebih baik dibandingkan *Prophet*. Secara keseluruhan, hasil evaluasi ARIMA dan *Prophet* tergantung pada karakteristik data dan kebutuhan spesifik dari penelitian yang sedang dikerjakan. ARIMA lebih baik dikarenakan dalam penelitian ini data sudah stasioner dengan sedikit data yang memiliki *missing values*, sementara *Prophet* menghasilkan evaluasi yang kurang baik dikarenakan untuk data yang stasioner dan tidak memiliki *missing values*, *Prophet* mungkin kurang akurat dibandingkan dengan metode seperti ARIMA. *Prophet* sering menghasilkan interval ketidakpastian yang lebih lebar karena pendekatannya yang fleksibel dalam menangani data dengan tren yang berubah-ubah dan musiman. Untuk data yang stasioner dan tidak memiliki *missing values*, interval yang lebih lebar ini mungkin tidak memberikan peramalan yang setajam atau seakurat yang dihasilkan oleh ARIMA, yang lebih terfokus pada pola autokorelasi dalam data. Interval ketidakpastian dalam *Prophet* adalah rentang yang mencakup estimasi nilai peramalan beserta ketidakpastiannya. Interval ini biasanya ditentukan oleh parameter tingkat kepercayaan, misalnya 95%, yang berarti bahwa ada keyakinan 95% bahwa nilai sebenarnya akan berada dalam rentang tersebut.

dengan adanya penelitian ini, diharapkan perusahaan dapat merencanakan pembelian stok dengan lebih cepat dan tepat sesuai dengan kebutuhan. Terutama untuk Instalasi Farmasi di Rumah Sakit, bagian tersebut dapat melakukan perencanaan yang lebih baik terkait seberapa banyak pembelian stok setiap minggunya yang harus dicapai agar sesuai dengan peramalan yang telah dilakukan. Peningkatan akurasi dalam perencanaan stok ini akan membantu rumah sakit mengurangi kekurangan atau kelebihan persediaan, sehingga operasional farmasi dapat berjalan lebih efisien. Penggunaan model ARIMA dan *Prophet* dapat dipilih penggunaannya sesuai preferensi yang diharapkan dapat menjadi panduan dalam pengambilan keputusan terkait manajemen persediaan. Selain itu, implementasi teknologi prediktif ini juga bisa meningkatkan kualitas layanan kesehatan yang diberikan oleh rumah sakit. Penelitian ini menunjukkan pentingnya penggunaan analisis data dalam meningkatkan efisiensi dan efektivitas operasional di sektor kesehatan. Dengan demikian, rumah sakit dapat terus berinovasi dan meningkatkan pelayanan kepada pasien.

Selain itu pengembangan penelitian dapat digunakan data-data yang berkorelasi contoh nama klinik yang dikunjungi dan data mengenai penyakit terbanyak dapat digunakan untuk mengembangkan penelitian lebih lanjut. Selain itu, informasi data itu juga dapat menjadi dasar dalam pengembangan penelitian ini. Dengan demikian, penelitian ini dapat memberikan hasil yang lebih akurat dan relevan. Pemanfaatan data tambahan ini akan membantu dalam merencanakan persediaan yang lebih efisien dan efektif.

#### UCAPAN TERIMA KASIH

Terima kasih kepada rumah sakit yang tidak dapat saya sebutkan namanya, akan tetapi dengan data tersebut sangat membantu untuk dapat menyelesaikan penelitian ini. Terima kasih juga kepada setiap tim dan para dosen yang telah membantu penelitian dan penulisan jurnal ini sehingga dapat berjalan dengan baik.

#### DAFTAR PUSTAKA

- [1] B. R. Hussein, A. Kasem, S. Omar, and N. Z. Siau, "A Data Mining Approach for Inventory Forecasting: A Case Study of a Medical Store," *Comput. Intell. Inf. Syst. CIIS 2018 Adv. Intell. Syst. Comput.*, vol. 888, pp. 178–188, 2019.
- [2] L. Ervintyana, A. Widjaja, and S. L. Liliawati, "Analisis Deret Waktu dari Produk yang Terjual Menggunakan Beberapa Teknik Populer," *J. Tek. Inform. dan Sist. Inf.*, vol. 9, no. 1, 2023.
- [3] L. Yuliana, "Dampak Kondisi Pandemi di Indonesia Terhadap Trend Penjualan (Studi Kasus pada PD. Sumber Jaya Aluminium)," *JRB-Jurnal Ris. Bisnis*, vol. 4, no. 1, pp. 27–38, 2020.
- [4] I. Yenidogan, A. Cayir, O. Kozan, T. Dag, and C. Arslan, "Bitcoin Forecasting Using ARIMA and PROPHET," in *2018 3rd International Conference on Computer Science and Engineering (UBMK)*, IEEE, 2018, pp. 621–624.
- [5] C. Chandra and S. Budi, "Analisis Komparatif ARIMA dan Prophet dengan Studi Kasus Dataset Pendaftaran Mahasiswa Baru," *J. Tek. Inform. dan Sist. Inf.*, vol. 6, no. 2, 2020.
- [6] B. K. Jha and S. Pande, "Time Series Forecasting Model for Supermarket Sales using FB-Prophet," in *2021 5th International Conference on Computing Methodologies and Communication (ICCMC)*, IEEE, 2021, pp. 547–554.
- [7] K. P. Fourkiotis and A. Tsadiras, "Applying Machine Learning and Statistical Forecasting Methods for Enhancing Pharmaceutical Sales Predictions," *Forecasting*, vol. 6, no. 1, pp. 170–186, 2024.
- [8] R. J. Hyndman and G. Athanasopoulos, "Forecasting: Principles and Practice 2nd Edition," *OTexts: Online, open-access textbooks*. 2024. [Online]. Available: <https://otexts.com/fpp2/components.html>
- [9] L. Menculini *et al.*, "Comparing Prophet and Deep Learning to ARIMA in Forecasting Wholesale Food Prices," *Forecasting*, vol. 3, no. 3, pp. 644–662, 2021.
- [10] E. Stellwagen and L. Tashman, "ARIMA: The Models of Box and Jenkins," *Foresight Int. J. Appl. Forecast.*, pp. 28–33, 2013.
- [11] T. G. Smith, "6. Tips to using auto\_arima — pmdarima 2.0.4 documentation." 2023. [Online]. Available: [https://alkaline-ml.com/pmdarima/tips\\_and\\_tricks.html](https://alkaline-ml.com/pmdarima/tips_and_tricks.html)
- [12] SolarWinds, "Holt-Winters Forecasting and Exponential Smoothing Simplified," *Orange Matter*. 2019. [Online]. Available: <https://orangematter.solarwinds.com/2019/12/15/holt-winters-forecasting-simplified/>
- [13] R. J. Hyndman and A. B. Koehler, "Another look at measures of forecast accuracy," *Int. J. Forecast.*, vol. 22, no. 4, pp. 679–688, 2006.
- [14] G. James, D. Witten, T. Hastie, and R. Tibshirani, *An Introduction to Statistical Learning*. Springer US, 2021. doi: 10.1007/978-1-0716-1418-1.