

# Analisa Perbandingan Penerapan Metode SARIMA dan Prophet dalam Memprediksi Persediaan Barang PT XYZ

Wawan Gunawan<sup>1</sup>, Misbah Ramadani<sup>2</sup>

<sup>1,2</sup>Fakultas Ilmu Komputer, Teknik Informatika, Universitas Mercu Buana

<sup>1</sup>wawan.gunawan@mercubuana.ac.id, <sup>2</sup>misbahramadhani1@gmail.com

---

## Article Info

### Article history:

Received July 21, 2022

Revised Oct 06, 2022

Accepted Mar 29, 2023

---

### Keywords:

Inventory  
Prediction  
SARIMA  
Prophet  
RMSE

---

## ABSTRACT

*Determining the right level of inventory is very important because it relates to the flow of money and can affect the performance of an organization. Too much inventory of goods can cause accumulation of storage space (warehouse) and reduce capital. The research will use data on sales of tires and wheels to be predicted using the SARIMA and Prophet methods, then the results will be compared for accuracy using RMSE. Based on the research results, it can be concluded that SARIMA (0, 0, 0)x(0, 1, 1, 12) with an RMSE evaluation result of 3.61 is superior to Prophet in predicting Dunlop product sales with an RMSE evaluation result of 4.02. SARIMA has the advantage in prediction because in the process there are features to find the best parameters to be implemented in the model.*

Copyright © 2023 Universitas Indraprasta PGRI.  
All rights reserved.

---

## Corresponding Author:

Wawan Gunawan,  
Department of Informatic,  
Universitas Mercu Buana,  
Jl. Meruya Selatan No. 01 Kembangan.  
Email: [wawan.gunawan@mercubuana.ac.id](mailto:wawan.gunawan@mercubuana.ac.id)

---

## 1. PENDAHULUAN

Manajemen persediaan barang merupakan proses pemantauan dan pengendalian tingkat persediaan barang untuk memastikan terpenuhinya permintaan dari pembeli [1]. Menentukan tingkat persediaan barang yang tepat sangatlah penting dilakukan karena hal tersebut berhubungan dengan arus uang dan dapat mempengaruhi kinerja dari sebuah organisasi. Persediaan barang yang terlalu banyak dapat menyebabkan penumpukan tempat penyimpanan (gudang) dan mengurangi modal. Sebaliknya, apabila terlalu sedikit dapat menyebabkan kehabisan barang yang tersedia sehingga penjualan yang seharusnya terjadi, menjadi terlewatkan dan keuntungan organisasi menjadi berkurang. Jelas bahwa manajemen persediaan barang yang baik sangatlah dibutuhkan dengan berfokus pada dua hal, berjuang untuk meningkatkan kepuasan pelanggan dan menjaga persediaan barang agar tidak terjadinya kekosongan atau penumpukan sambil menjaga biaya untuk persediaan serendah mungkin.

Prediksi persediaan barang merupakan bagian penting dari manajemen proses bisnis. Terlepas dari kerumitan dan pelaksanaan proses peramalan di berbagai bisnis, tujuan yang dimaksudkan tetap sama yaitu untuk memperoleh perkiraan hasil prediksi yang cukup akurat dari permintaan pembeli di masa depan untuk produk atau layanan dengan menggunakan data deret waktu dan keadaan lingkungan saat ini (misalnya, politik, sosial, ekonomi) untuk merencanakan dan mengatur bisnis yang sesuai [2]. Sistem manajemen persediaan barang yang terkomputerisasi memberikan hasil yang lebih efisien dan stabil dengan sedikit usaha dibandingkan dengan sistem manual yang seringkali dapat terjadi *human error* (kesalahan manusia) sehingga pemanfaatan Gudang menjadi kurang efisien [3].

Prediksi deret waktu telah banyak diterapkan di berbagai bidang, seperti alam, energi, keuangan, perawatan kesehatan, transportasi, dan supply chain management (manajemen rantai pasokan)[4][5][6]. Musiman adalah karakteristik dasar dan umum dari sebagian besar metode prediksi deret waktu [7]. Musiman mengartikan bahwa data memiliki kecenderungan mengulangi pola tingkah gerak dalam periode musim. Biasanya dapat berupa mingguan, bulanan, triwulan, semesteran dan tahunan. Faktor-faktor seperti hari libur dan musim liburan secara signifikan mempengaruhi kepekaan pembeli terhadap harga dan keputusan pembelian[8].

*Seasonal Autoregressive Integrated Moving Average (SARIMA)* dan Prophet merupakan metode prediksi yang dikhususkan untuk prediksi deret waktu yang berpola musiman. SARIMA merupakan perluasan dari metode ARIMA. Metode ARIMA dan turunannya adalah sebuah metode yang dapat menangani deret waktu non-stasioner. Pada SARIMA, digunakan *differencing* musiman untuk menghapus data non-stasioner [9]. Sedangkan Prophet melakukan prediksi berdasarkan model aditif dimana trend yang bersifat non-linier dicocokkan dengan deret waktu secara tahunan, mingguan, dan harian, dengan efek liburan[10].

Penelitian menggunakan metode Prophet untuk memprediksi data penjualan yang didapat dari perusahaan retail terbesar di Bosnia dan Herzegovina. *Mean absolute percentage error (MAPE)* digunakan untuk mengevaluasi hasil prediksi. Hasilnya metode PROPHET dapat memprediksi dengan baik untuk jangka waktu 3 bulan dengan MAPE < 15%. [11]

Penelitian mengenai metode ARIMA dan Prophet dengan menggunakan data bitcoin pada May 2016 sampai Maret 2018, menambahkan variable yang dipilih berdasarkan perbedaan korelasi antara mata uang crypto dan mata uang asli. Data tersebut lalu di proses menggunakan metode ARIMA dan PROPHET melalui 3 tahapan : pelatihan, validasi, dan testing. Berdasarkan hasil testing, diperoleh hasil untuk PROPHET sebesar 94% sedangkan ARIMA sebesar 68%. [12]

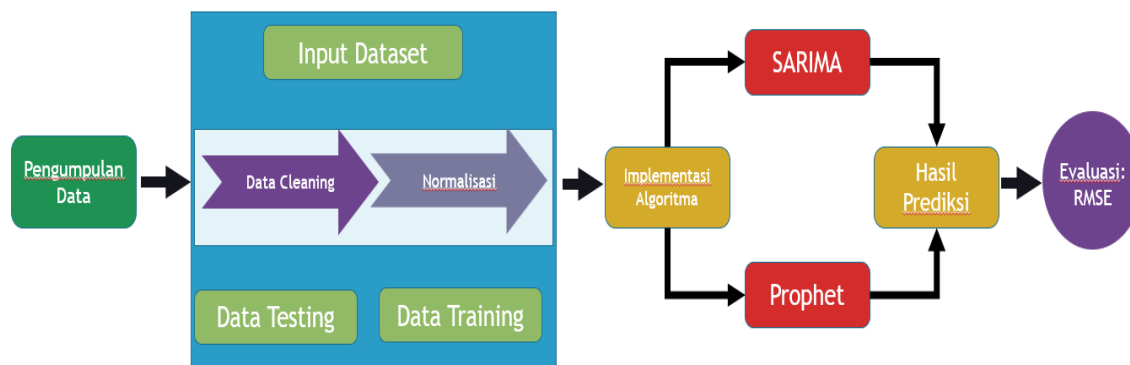
Penelitian dengan metode Prophet dilakukan dengan menggunakan data penjualan supermarket tahun 2014-17 yang didapat dari Kaggel. Dilakukan 4 tahapan metodologi, yaitu : Data Collection, Data Preprocessing, Exploratory Data Analysis, dan Performance Matrices. Berdasarkan hasil evaluasi, Prophet mendapatkan %MAPE terendah (8.3%) dibandingkan ARIMA (14.3%) dan Holt-Winter's (11.8%).[13]

Penelitian merekomendasikan model SARIMA sebagai model untuk memprediksi sistem jaringan listrik. Penelitian tersebut membandingkan 4 algoritma, diantaranya adalah SARIMA, Prophet, holt-winter, dan GM. Dari keempat algoritma tersebut, evaluasi *Root Mean Squarred Error (RMSE)* SARIMA merupakan yang terendah dengan hasil 258.85. Prophet dan holt-winter masing-masing mendapatkan hasil 749.288 dan 809.89. sedangkan GM mencapai 1710.95, yang mana 6x lebih besar dibandingkan SARIMA.[14]

Berdasarkan studi diatas, peneliti akan menggunakan data penjualan ban dan velg PT XYZ untuk diprediksi menggunakan metode SARIMA dan Prophet yang kemudian hasilnya akan dibandingkan keakuratannya menggunakan RMSE.

## 2. METODE

Penelitian ini menggunakan metode kuantitatif dan merupakan penelitian terapan atau *applied research* karena hasil penelitian dapat secara langsung diterapkan untuk memecahkan permasalahan yang terjadi, yaitu dalam kasus ini adalah mengenai manajemen persediaan barang. Pada penelitian ini menggunakan bahasa program python untuk mengolah data. Peneliti menjabarkan tahapan-tahapan yang dilakukan dalam bentuk diagram alir seperti yang nampak pada Gambar 1.



Gambar 1. Metode Penelitian

## 2.1. Data Collection

Dataset didapat dari PT XYZ yang berisikan data penjualan ban dan velg pada tahun 2021 selama 5 bulan, yaitu Juni, Juli, Agustus, September, dan Oktober. Data yang berjumlah 854 tersebut memiliki 4 kolom, yaitu Tanggal, Nama, Kategori, dan Jumlah seperti yang ditampilkan pada tabel 1.

Tabel 1. Dataset Penjualan

	<b>tanggal</b>	<b>nama</b>	<b>kategori</b>	<b>jumlah</b>
0	2021-06-01	Achilles 235-3539	ban	12
1	2021-06-01	Achilles 245-3539	ban	14
2	2021-06-01	Hankook 30-9535	ban	15
3	2021-06-01	Toyo 235-7036	ban	16
4	2021-06-01	pirelli 265-45-20	ban	18
.....	.....	.....	.....	.....
848	2021-10-31	dunlop 215-6536	ban	4
849	2021-10-31	sav 3332.535	ban	4
850	2021-10-31	falken 185-6535	ban	4
851	2021-10-31	maxxis 3332.535	ban	2
852	2021-10-31	dunlop 215-5537	ban	1

## 2.2. Preprocessing

### a. Data Cleaning

Proses ini dilakukan untuk menghapus data yang tidak digunakan, sehingga data menjadi lebih siap untuk selanjutnya dilakukan normalisasi.

### b. Normalisasi Data

Data dikelompokkan menjadi nama merk nya, contohnya “Dunlop LM705 185/55 R16” diubah menjadi “Dunlop” seperti terlihat pada tabel 2.

Tabel 2. Normalisasi Dataset Penjualan

	<b>tanggal</b>	<b>nama</b>	<b>kategori</b>	<b>jumlah</b>
0	2021-06-01	Achilles	ban	6
1	2021-06-01	Achilles	ban	2
2	2021-06-01	Hankook	ban	4
3	2021-06-01	Toyo	ban	4
4	2021-06-01	pirelli	ban	4
.....	.....	.....	.....	.....
848	2021-10-31	dunlop	ban	4
849	2021-10-31	sav	ban	4
850	2021-10-31	falken	ban	4
851	2021-10-31	maxxis	ban	2
852	2021-10-31	dunlop	ban	1

### c. Transformasi Data

Data yang telah dilakukan normalisasi selanjutnya ditransformasi menjadi berisikan variable tanggal dan nama nama dari tiap produk. Sehingga data akhir berjumlah 136 dengan berbagai kolom produk yang siap untuk diprediksi seperti tampak pada gambar 2.

tanggal	acc	achilles	at	avantec	bbc	berg	bf	bfgr	brave	bridgestone	...	simex	sirex	ssw	strada	ta	te	terrano	toyo	xtragrip	yokohama
2021-06-01	4	4	15	7	8	1	11	7	5	12	...	15	14	11	13	15	2	11	4	13	11
2021-06-02	4	1	13	9	12	12	11	12	12	4	...	1	14	8	7	7	5	3	5	4	11
2021-06-03	4	2	12	7	12	12	4	1	15	6	...	1	1	1	5	8	11	15	15	8	1
2021-06-04	4	3	1	9	8	7	1	11	5	5	...	12	12	8	9	14	4	9	12	4	3
2021-06-05	11	1	7	2	5	5	14	11	3	4	...	4	4	1	5	14	9	2	9	12	12
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
2021-10-27	4	2	12	12	14	8	9	14	15	3	...	5	5	6	15	8	9	7	3	15	9
2021-10-28	14	15	7	4	7	5	9	7	5	5	...	4	14	13	4	15	7	15	14	6	9
2021-10-29	6	5	13	4	10	6	3	15	4	5	...	3	15	7	6	2	15	7	6	5	4
2021-10-30	4	14	1	4	2	15	7	4	11	13	...	15	4	7	8	10	7	5	3	11	4
2021-10-31	6	15	6	10	9	3	14	6	12	2	...	3	5	8	5	11	4	12	2	5	5

136 rows × 68 columns

Gambar 2. Transformasi Dataset

d. Data latih dan data uji

Setelah semua data telah diproses dan mendapatkan data dengan berisikan nama produk dan tanggal, maka selanjutnya dipilih produk dunlop sebagai perwakilan produk untuk diprediksi seperti terlihat pada tabel 3. Kolom dunlop dibuat menjadi dataset terpisah yang berisikan 2 variable yaitu tanggal dan jumlah, yang kemudian variable jumlah diganti namanya menjadi y. Data latih digunakan untuk membuat model yang kita gunakan, sedangkan data uji digunakan untuk menguji performa dan juga mengetahui kebenaran terhadap model yang sudah kita buat.

Tabel 3. Data Produk Dunlop

date	y
2021-06-01	3
2021-06-02	11
2021-06-03	2
2021-06-04	2
2021-06-05	10
.....	.....
2021-10-27	8
2021-10-28	12
2021-10-29	2
2021-10-30	4
2021-10-31	2

Data produk dunlop tersebut dibagi menjadi data latih dan data uji dengan rasio 80:20 seperti pada Gambar 3.

```
train = data_dunlop[:110]
test = data_dunlop[110:]
print(train.shape)
print(test.shape)

(110, 1)
(26, 1)
```

Gambar 3. Data Latih dan Data Uji

2.3. Implementasi Algoritma SARIMA dan Prophet

diimplementasikan menggunakan 2 algoritma, yaitu algoritma SARIMA dan Prophet.

Tahapan implementasi:

a. SARIMA

Data diproses untuk dites kestasioneritasannya dan dilakukan deferensiasi apabila data tersebut tidak stasioner. Setelah data stasioner kemudian dilakukan pencarian parameter terbaik untuk diimplementasikan pada model SARIMA untuk mendapatkan hasil prediksi.

Berikut adalah rumus dari SARIMA :

$$\text{ARIMA } (p, d, q) \times (P, D, Q)S \quad (1)$$

p = AR non-musiman

d = diferensiasi non-musiman

q = MA non-musiman

P = AR musiman

D = diferensiasi musiman

Q = MA musiman

S = rentang waktu pengulangan pola musiman

b. Prophet

Melakukan perubahan nama kolom tanggal menjadi ds pada data latih produk dunlop, karena model Prophet hanya bisa diimplementasikan pada data yang memiliki variabel 'ds' dan 'y'. Setelah data diimplementasikan, dihasilkan hasil prediksi yang kemudian akan di evaluasi.

Berikut adalah rumus dari Prophet :

$$y(t) = g(t) + s(t) + h(t) + \varepsilon(t) \quad (2)$$

Keterangan :

y = peramalan

g = faktor pertumbuhan/trend

s = komponen trend seasonalitas

h = komponen trend liburan

$\varepsilon$  = kesalahan

Dimana :

$$g(t) = \frac{c}{1 + \exp(-k(t-m))} \quad (3)$$

Keterangan :

C = daya dukung

k = laju pertumbuhan

m = parameter penawaran

$$s(t) = \sum_{n=1}^N \left( a_n \cos\left(\frac{2\pi nt}{P}\right) + b_n \sin\left(\frac{2\pi nt}{P}\right) \right) \quad (4)$$

Keterangan :

P = periode waktu

$$h(t) = [1(t \in D_1), \dots, 1(t \in D_L)] \kappa \quad (5)$$

Keterangan :

D = set dari tanggal liburan di masa lalu dan masa depan

t = waktu saat sedang liburan

$\kappa$  = perubahan hari libur saat prediksi

#### 2.4. Evaluasi

Evaluasi dilakukan dengan menggunakan RMSE (*Root Mean Squared Error*). Hasil evaluasi digunakan sebagai acuan untuk menganalisa perbandingan antara kedua metode tersebut.

$$RMSE = \sqrt{\frac{\sum_{t=1}^N (F_t - A_t)^2}{N}} \quad (6)$$

Keterangan :

$N$  = banyak data

$A_t$  = ukuran data asli

$F_t$  = nilai prediksi


$\Sigma$  =summation (Jumlahkan keseluruhan nilai)

### 3. HASIL DAN PEMBAHASAN

Pada bagian ini, kami menyajikan prediksi deret waktu dengan menggunakan riwayat data penjualan produk PT XYZ. Data yang di analisis merupakan data penjualan produk brand Dunlop dari bulan Juni sampai Oktober 2022. Dataset berisi jumlah penjualan produk perhari dari awal sampai akhir periode. Data kemudian diproses menyesuaikan persyaratan dari model prediksi dan data yang kosong diisi dengan metode pendekatan void fill, yaitu dengan pengisian maju dan pengisian mundur apabila cocok dan pendekatan tersebut diperlukan. Pengisian maju berarti mengisi nilai yang kosong dengan data sebelumnya. Pengisian mundur berarti mengisi nilai yang kosong dengan data berikutnya. Plot deret waktu mengilustrasikan adanya penjualan produk yang tidak konstan. Selain itu juga terdapat juga tingkat fluktuasi musiman dan fluktuasi acak yang tidak konstan dari waktu ke waktu. Jika tingkat fluktuasi mean dan variansnya tidak konstan, maka data deret waktu dapat dikatakan tidak stasioner. Proses differencing dilakukan untuk menangani situasi seperti ini sebelum menuju ke proses peramalan. Parameter yang diperlukan juga dimasukkan ke model untuk perkiraan yang lebih tepat. Ada tiga langkah utama yaitu uji stasioner, identifikasi model, dan evaluasi hasil prediksi.


#### 3.1. Uji Stasioner

Proses pertama yang dilakukan adalah uji stasioner. Dilakukan visualisasi data latih dari penjualan produk Dunlop selama periode Juni sampai Oktober 2022, sehingga lebih mudah untuk melihat alur dari pergerakannya. Hal itu dapat membantu menentukan perlakuan selanjutnya terhadap data tersebut.



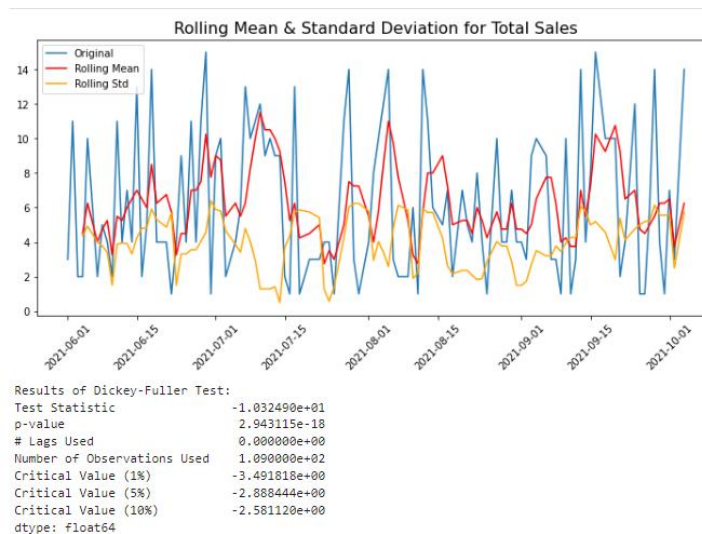
Gambar 4. Visualisasi Data Dunlop

Berdasarkan hasil visualisasi data penjualan produk Dunlop, dapat diasumsikan bahwa terjadi penurunan dan kenaikan yang cukup signifikan pada data tersebut seperti yang terlihat pada Gambar 4, selanjutnya untuk memvalidasi asumsi tersebut, dilakukan analisa lanjutan dengan menggunakan *seasonal decompose* untuk mengetahui tren dan pola musiman.



Gambar 5. Seasonal Decomposition


Dapat dilihat dengan jelas pada Gambar 5 bahwa terdapat pola musiman dan terjadi tren pembelian turun dan naik pada data yang digunakan. Hal tersebut menandakan bahwa data tersebut tidak stasioner. Untuk mengkonfirmasi observasi visual tersebut, selanjutnya dilakukan percobaan hipotesis menggunakan Dickey-Fuller. Terdapat 2 hipotesis, yaitu hipotesis nol dan hipotesis alternatif. Hipotesis nol adalah data tidak stasioner apabila  $p\text{-value} > 0.05$  dan hipotesis alternatif apabila  $p\text{-value} < 0.05$ . [15]



Gambar 6. Tes Stasioneritas Dickey-Fuller

Berdasarkan hasil tes stasioneritas dengan Dickey-Fuller pada Gambar 6, didapatkan hasil yaitu  $p\text{-value}$  sebesar 2.94, lebih besar daripada 0.05, yang artinya gagal dalam menolak hipotesis 0 dan mengkonfirmasi bahwa data tidak stasioner. Diperkuat dengan mean dan varian, garis merah dan kuning pada grafik, yang tidak konstan. Garis biru (original) pada grafik adalah data penjualan produk Dunlop.

Setelah terkonfirmasi bahwa data tidak stasioner, langkah selanjutnya yaitu menghapus tren dan membuat data menjadi stasioner. Salah satu metode yang dapat digunakan yaitu dengan diferensiasi. Angka dari berapa kali dilakukannya diferensiasi adalah nilai  $d$  pada arima. Apabila dengan diferensiasi pertama grafik sudah konstan dan mean sudah stasioner maka tidak perlu melakukan diferensiasi kedua.



Gambar 7. Data Stasioner

Pada Gambar 7 menunjukkan mean dan varian yang hampir konstan cukup dengan satu kali differensiasi, yang berarti data sudah stasioner dan siap untuk selanjutnya diimplementasikan pada masing-masing model prediksi, yaitu SARIMA dan Prophet.

**3.2. Identifikasi Model**

Hasil aktual peramalan model SARIMA dan Prophet ditampilkan pada gambar 9 dan 10.

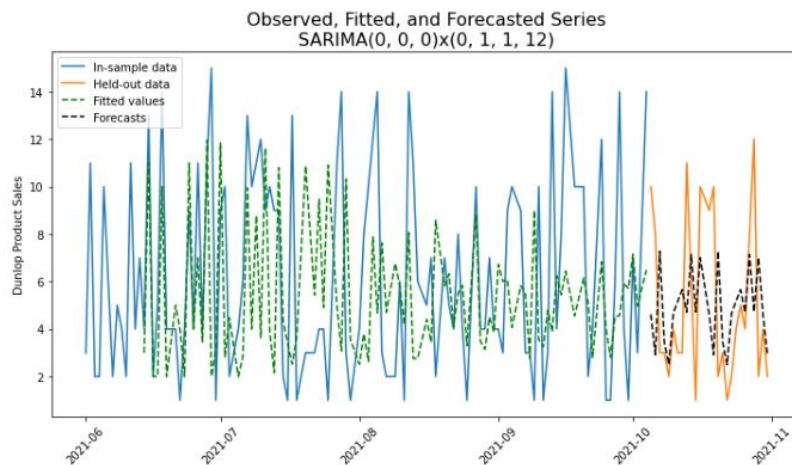
**SARIMA**

Dicari parameter sarima menggunakan gridsearch untuk diterapkan pada rumus 1, didapatkan hasil berdasarkan *Akaike Information Criterion* (AIC) and *Bayesian Information Criterion* (BIC) bahwa SARIMA(0, 0, 0)x(0, 1, 1, 12) merupakan model terbaik. Nilai AIC dan BIC yang mencerminkan seberapa baik model cocok dengan data. Semakin rendah nilai AIC dan BIC, semakin cocok model dengan data yang digunakan. Hasil ditampilkan pada Gambar 8.

	AIC
SARIMA(0, 0, 0)x(0, 1, 1, 12)	264.369920
SARIMA(0, 0, 0)x(1, 1, 1, 12)	264.807644
SARIMA(0, 0, 1)x(0, 1, 1, 12)	266.266620
SARIMA(1, 0, 0)x(0, 1, 1, 12)	266.284195
SARIMA(0, 0, 1)x(1, 1, 1, 12)	266.724511
-----	
	BIC
SARIMA(0, 0, 0)x(0, 1, 1, 12)	269.539855
SARIMA(0, 0, 0)x(1, 1, 1, 12)	272.562546
SARIMA(0, 0, 1)x(0, 1, 1, 12)	274.021522
SARIMA(1, 0, 0)x(0, 1, 1, 12)	274.039098
SARIMA(0, 0, 1)x(1, 1, 1, 12)	277.064381

Gambar 8. Hasil AIC dan BIC

Parameter tersebut lalu diimplementasikan pada model SARIMA dengan hasil prediksi ditampilkan pada Gambar 9.



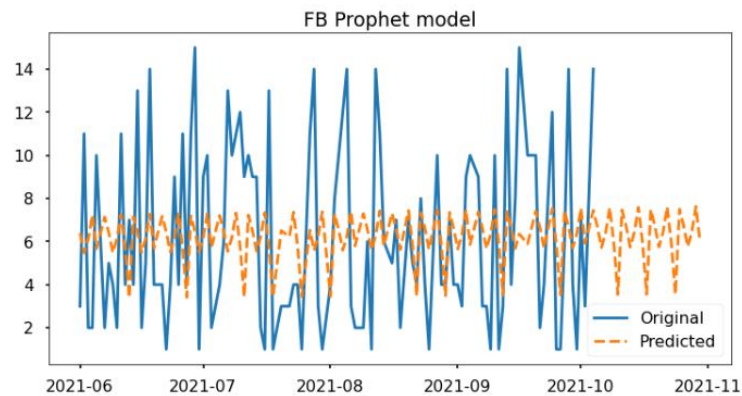
Gambar 9. Hasil Prediksi SARIMA



Hasil dari prediksi di visualisasikan kedalam bentuk grafik, garis hijau (Fitted values) adalah nilai prediksi, sedangkan garis biru merupakan data penjualan produk Dunlop. Garis hitam (Forecasts) merupakan nilai prediksi selama 1 bulan kedepan yang dibandingkan dengan data historis yang berwarna oren (Held-out data) dari penjualan yang digunakan untuk memvalidasi model.

### *Prophet*

Data latih yang telah diproses juga diimplementasikan pada metode Prophet sesuai dengan rumus 2, hasil implementasi tersebut dapat dilihat pada Gambar 10.



Gambar 10. Hasil Prediksi Prophet

### 3.3. Evaluasi RMSE

Setelah hasil prediksi didapat, selanjutnya dilakukan evaluasi dengan RMSE menggunakan Rumus 6 seperti yang ditampilkan pada Gambar 11.

```
def error_metrics(y_fcast, y_test):
    print(f'RMSE: {np.sqrt(np.mean((y_test - y_fcast)**2))}')
```

Gambar 11. RMSE

Evaluasi hasil prediksi metode SARIMA dan Prophet dalam memprediksi persediaan barang menggunakan data produk Dunlop disajikan dalam Tabel 4.

Tabel 4. Hasil Evaluasi Model

Model	RMSE
SARIMA(0,0,0)x(0,1,1,12)	3.61
Prophet	4.02

Berdasarkan tabel di atas, dapat dilihat bahwa hasil prediksi penjualan produk Dunlop SARIMA(0, 0, 0)(0, 1, 1, 12) mendapatkan evaluasi RMSE sebesar 3,61 dan Prophet mendapatkan evaluasi RMSE sebesar 4.02.

## 4. PENUTUP

### 4.1. Simpulan

Berdasarkan hasil penelitian dapat disimpulkan bahwa SARIMA (0, 0, 0)x(0, 1, 1, 12) dengan hasil evaluasi RMSE 3,61 lebih unggul dibanding Prophet dalam memprediksi penjualan produk Dunlop dengan hasil evaluasi RMSE 4,02. SARIMA memiliki keunggulan dalam memprediksi karena pada prosesnya terdapat fitur untuk mencari parameter terbaik untuk diimplementasikan pada modelnya. Dengan mengetahui penjualan pada periode selanjutnya berdasarkan hasil prediksi dengan metode terbaik, PT XYZ dapat mengatur alokasi persediaan barangnya dengan lebih baik

### 4.2. Saran

Dalam proses preprocessing data, dilakukan pengelompokkan data menjadi perproduct sehingga membuat data menjadi semakin sedikit. Penelitian selanjutnya disarankan untuk menggunakan data yang lebih besar agar hasil prediksi dapat semakin akurat.

## UCAPAN TERIMAKASIH

Peneliti mengucapkan terima kasih kepada semua pihak yang telah membantu kelancaran pembuatan jurnal ini, terutama kepada Universitas Mercu Buana.

## DAFTAR PUSTAKA

- [1] G. Priniotakis and P. Argyropoulos, "Inventory management concepts and techniques," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 459, no. 1, 2018, doi: 10.1088/1757-899X/459/1/012060.
- [2] G. Merkuryeva, A. Valberga, and A. Smirnov, "Demand forecasting in pharmaceutical supply chains: A case study," *Procedia Comput. Sci.*, vol. 149, pp. 3–10, 2019, doi: 10.1016/j.procs.2019.01.100.
- [3] B. S. S. Tejesh and S. Neeraja, "Warehouse inventory management system using IoT and open source framework," *Alexandria Eng. J.*, vol. 57, no. 4, pp. 3817–3823, 2018, doi: 10.1016/j.aej.2018.02.003.
- [4] M. Abolghasemi, E. Beh, G. Tarr, and R. Gerlach, "Demand forecasting in supply chain: The impact of demand volatility in the presence of promotion," *Comput. Ind. Eng.*, vol. 142, no. July 2019, p. 106380, 2020, doi: 10.1016/j.cie.2020.106380.
- [5] T. T. H. Phan and X. H. Nguyen, "Combining statistical machine learning models with ARIMA for water level forecasting: The case of the Red river," *Adv. Water Resour.*, vol. 142, no. June, 2020, doi: 10.1016/j.advwatres.2020.103656.
- [6] F. Petropoulos, S. Makridakis, and N. Stylianou, "COVID-19: Forecasting confirmed cases and deaths with a simple time series model," *Int. J. of Forecasting*, vol. 38, pp. 439–452, 2022.
- [7] W. Zhou, Y. Cheng, S. Ding, L. Chen, and R. Li, "A grey seasonal least square support vector regression model for time series forecasting," *ISA Trans.*, vol. 114, pp. 82–98, 2021, doi: 10.1016/j.isatra.2020.12.024.
- [8] L. Guo, W. Fang, Q. Zhao, and X. Wang, "The hybrid PROPHET-SVR approach for forecasting product time series demand with seasonality," *Comput. Ind. Eng.*, vol. 161, no. February, p. 107598, 2021, doi: 10.1016/j.cie.2021.107598.
- [9] G. Box, "Box and Jenkins: Time Series Analysis, Forecasting and Control," *A Very Br. Aff.*, no. October 1919, pp. 161–215, 2013, doi: 10.1057/9781137291264\_6.
- [10] S. J. Taylor and B. Letham, "Business Time Series Forecasting at Scale," *PeerJ Prepr.* 5e3190v2, vol. 35, no. 8, pp. 48–90, 2017.
- [11] I. Yenidogan, A. Cayir, O. Kozan, T. Dag, and C. Arslan, "Bitcoin Forecasting Using ARIMA and PROPHET," *UBMK 2018 - 3rd Int. Conf. Comput. Sci. Eng.*, no. February 2019, pp. 621–624, 2018, doi: 10.1109/UBMK.2018.8566476.
- [12] E. Žunić, K. Korjenić, K. Hodžić, and D. Đonko, "Application of Facebook's Prophet Algorithm for Successful Sales Forecasting Based on Real-world Data," *Int. J. Comput. Sci. Inf. Technol.*, vol. 12, no. 2, pp. 23–36, 2020, doi: 10.5121/ijcsit.2020.12203.
- [13] B. Kumar Jha and S. Pande, "Time Series Forecasting Model for Supermarket Sales using FB-Prophet," *Proc. - 5th Int. Conf. Comput. Methodol. Commun. ICCMC 2021*, no. Iccmc, pp. 547–554, 2021, doi: 10.1109/ICCMC51019.2021.9418033.
- [14] Y. Yan, B. Li, J. Xiao, Y. Liang, Y. Shang, and K. Zhou, "Comparative Study on Prediction Algorithms for Power Grid System Access Failure Times," *IOP Conf. Ser. Earth Environ. Sci.*, vol. 252, no. 3, 2019, doi: 10.1088/1755-1315/252/3/032183.
- [15] F. X. ;G. D. R. Diebold, "On the power of Dickey-Fuller tests against fractional alternatives," *Econ. Lett.*, vol. 35, pp. 155–160, 1990.