

# Analisis Deret Waktu dari Produk yang Terjual Menggunakan Beberapa Teknik Populer

<http://dx.doi.org/10.28932/jutisi.v9i1.5933>

Riwayat Artikel

Received: 22 Desember 2022 | Final Revision: 12 Maret 2023 | Accepted: 12 Maret 2023

Creative Commons License 4.0 (CC BY – NC)



Laras Ervintyana Deni Kartika Sari<sup>✉#1</sup>, Andreas Widjaja<sup>#2</sup>, Swat Lie Liliawati<sup>#3</sup>

<sup>#</sup> Program Studi Magister Ilmu Komputer, Universitas Kristen Maranatha, Bandung  
Jl. Prof. Drg. Suria Sumantri No. 65, Bandung 40164, Indonesia

<sup>1</sup>laras.ervintyana@gmail.com

<sup>2</sup>andreas.widjaja@maranatha.ac.id

<sup>3</sup>swatlieliliawati@gmail.com

<sup>✉</sup>Corresponding author: laras.ervintyana@gmail.com

**Abstrak** — Penjualan merupakan komponen terpenting dalam suatu perusahaan bidang industri. Hal ini dikarenakan, bila terjadi penjualan berarti terdapat pendapatan ke dalam perusahaan, oleh karena itu penting untuk dilakukan analisis terhadap produk-produk yang terjual agar perusahaan dapat mempersiapkan lebih dini sebelum permintaan terhadap produk tersebut datang, guna dapat menghasilkan pendapatan yang lebih baik. Penelitian ini menggunakan ARIMA (Auto Regressive Integrated Moving Average), SVR (Support Vector Regression), FFT (Fast Fourier Transform) dan prophet sebagai metode-metode untuk peramalan dan menggunakan MAPE (Mean Absolute Percentage Error) dan RMSPE (Root Mean Squared Error) untuk mengukur tingkat akurasi, juga untuk melihat apakah terjadinya seasonality terhadap produk-produk yang di analisis, digunakan `seasonal_decompose`. Produk yang dijadikan penelitian merupakan produk yang memiliki karakteristik produk dengan penjualan berulang. Hasil analisis didapatkan bahwa ARIMA dan Prophet merupakan metode peramalan terbaik, hal ini karena kedua metode tersebut memiliki nilai MAPE dan RMSPE yang terendah. Dan setelah di analisis menggunakan `seasonal_decompose`, didapatkan bahwa semua produk yang diteliti memiliki pola yang berulang di waktu tertentu setiap kuartalnya. Untuk analisis lebih lanjut, dilakukan komparasi head-to-head, di mana 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.

**Kata Kunci** — ARIMA; FFT; prophet; `seasonal_decompose`; SVR.

## *Trend Analysis of Sold Products using some Popular Techniques*

**Abstract** — Sales is the most important component in and industrial company. This is because, income comes into the company if sales is running, therefore it is important to do an analysis of the products sold so that the company can prepare earlier before the demand for these products come, in order to produce better income. This study uses ARIMA (Auto Regressive Integrated Moving Average), SVR (Support Vector Regression), FFT (Fast Fourier Transform) and prophet to forecast and with MAPE (Mean Absolute Percentage Error) and RMSPE (Root Mean Squared Error) as the measure level of accuracy, also to see if there is any seasonality in the product that is being analyzed, `seasonal_decompose` is used. The results of the analysis show that ARIMA and Prophet are the best forecasting methods, this is because both methods have the lowest MAPE and RMSPE value. After being analyzed using `seasonal_decompose`. The characteristic of product used in this research is a product that has repeated sales. It was found that all of the products studied have a

*pattern that repeats itself at a certain time every quarter. For more further analysis, it was done by head-to-head comparison, where 20 product samples of each category was used. By this analysis it was clear that products in Category 1 are better to use ARIMA and products in Category 2 are better to use prophet.*

**Keywords — ARIMA; FFT; Prophet; seasonal\_decompose; SVR.**

## I. PENDAHULUAN

Penjualan merupakan salah satu komponen penting dalam perusahaan, hal ini dikarenakan bila terjadi penjualan, maka perusahaan mendapatkan pemasukan terhadap penjualan tersebut, untuk perusahaan yang bergerak dalam bidang produksi, pemasukan tersebut disebut sebagai penjualan [1]. Oleh karenanya, perlu dilakukan analisis tren untuk dapat mengetahui perkiraan penjualan pada masa yang akan datang, sehingga perusahaan dapat mempersiapkan lebih dini *demand* dari produk-produk yang sedang dibutuhkan dan mengetahui pada masa-masa kapankah *demand* tersebut mengalami kenaikan. Yang dimaksud dengan tren adalah [2] salah satu *tools* atau alat yang digunakan pada statistika untuk memperkirakan keadaan pada masa yang akan datang berdasarkan data masa lampau. Dalam dunia informasi teknologi, hal ini sering dikatakan sebagai *forecasting*. Secara langsung atau tidak, *forecasting* akan membantu banyak pihak yang berkepentingan. Dalam menentukan *forecasting* terdapat banyak sekali model dalam analisis deret waktu. Seperti dikutip dari Taranenko, dkk. [3] *there are no "one-size-fits-all" forecasting algorithm*, dengan demikian tidak ada satu algoritma yang dapat mencakup semua *forecasting*, dibutuhkan model analisis deret waktu lain yang kemudian pada akhirnya akan dijadikan perbandingan atau pendukung terhadap analisis deret waktu tersebut. Terdapat beberapa tujuan dalam penelitian ini, diantaranya, dapat mengetahui model analisis deret waktu mana yang baik dalam mengetahui perkiraan penjualan, mengetahui tingkat akurasi terhadap model analisis deret waktu tersebut, mengetahui prediksi dari produk yang terjual dan mengetahui apakah terdapat kemungkinan *seasonality* dari produk yang terjual.

Dalam penelitian ini, terdapat tiga data yang digunakan yaitu data primer, data sekunder dan data tersier. Data primer yang digunakan merupakan data penjualan dari PT. XYZ selama tiga tahun dari 2019 sampai 2021, di mana penjualan tersebut merupakan penjualan perusahaan kepada distributornya, data penjualan tersebut terdiri dari 139 produk, tetapi tidak semua 139 data tersebut akan dilakukan analisis tren, melainkan lima data yang memiliki penjualan tertinggi selama tiga tahun tersebut. Data sekunder yang digunakan adalah data publikasi jurnal, prosiding atau buku yang diperoleh dengan metode dokumenter, pembacaan jurnal, prosiding dan buku yang sesuai dengan topik yang diangkat. Data tersier yang digunakan adalah Kamus Besar Bahasa Indonesia untuk menerangkan beberapa istilah mengenai ekonomi dan *time series*. Untuk model analisis deret waktu yang diangkat dalam penelitian ini adalah ARIMA (*Auto Regressive Integrated Moving Average*), SVR (*Support Vector Regression*), FFT (*Fast Fourier Transform*) dan *Prophet*. Metode penelitian yang digunakan adalah metode penelitian lapangan atau *field research* yang merupakan penelitian mengenai gejala atau peristiwa yang terjadi terhadap data dengan pendekatan metode kuantitatif.

Telah banyak penelitian *forecasting* menggunakan ARIMA, SVR, FFT dan *Prophet*. Seperti yang dilakukan oleh Pamungkas, dkk. [4] yang memprediksi kasus demam berdarah pada provinsi Jawa Timur menggunakan ARIMA, pada penelitiannya tersebut nilai akurasi dihitung dengan MAPE (*Mean Absolute Percentage Error*) dan mendapatkan hasil 43,51%. Waryanto, dkk. [5] dengan metode yang sama yaitu ARIMA untuk data prediksi penjualan seragam sekolah dengan MAPE berkisar antara 20%-50%, Terdapat juga peramalan ARIMA dengan metode Auto ARIMA di mana metode ini digunakan untuk pencarian otomatis parameter  $p$ ,  $d$  dan  $q$ -nya, seperti yang dilakukan oleh MA, dkk. [6] untuk peramalan COVID-19 di Malaysia sehingga diperoleh  $p = 0$ ,  $d = 1$  dan  $q = 1$  (dapat ditulis dengan notasi ARIMA(0, 1, 1)) dengan MAPE berkisar antara 28.65%.

Pada peramalan menggunakan SVR, terdapat *kernel* yang dapat mempengaruhi hasil dari peramalan, seperti yang dilakukan oleh Cahyono, dkk. [7] terhadap indeks harga konsumen dengan data 01 Januari 2016 sampai 31 Desember 2018, *kernel* yang dipakai adalah *poly*, *rbf*, *sigmoid* dan linear dengan masing-masing MAPE (*Mean Absolute Percentage Error*) *poly* = 22.2239%, *rbf* = 0.1716%, *sigmoid* = 3529.7% dan linear = 1.7185%. Sedangkan penelitian dari Amanda, dkk. [8] mengenai prediksi kurs rupiah terhadap dolar Amerika Serikat, yang menggunakan *kernel* linear dan *poly* mendapatkan hasil MAPE linear = 0.6131% sedangkan *kernel poly* menghasilkan akurasi nilai 0.6135%. Dan Maulana, dkk. [9] dengan menggunakan *kernel rbf*, mendapatkan nilai akurasi RMSE (*Root Mean Squared Error*) = 0.0017. Sehingga untuk SVR ini, *kernel* yang dipakai akan berpengaruh terhadap nilai peramalan.

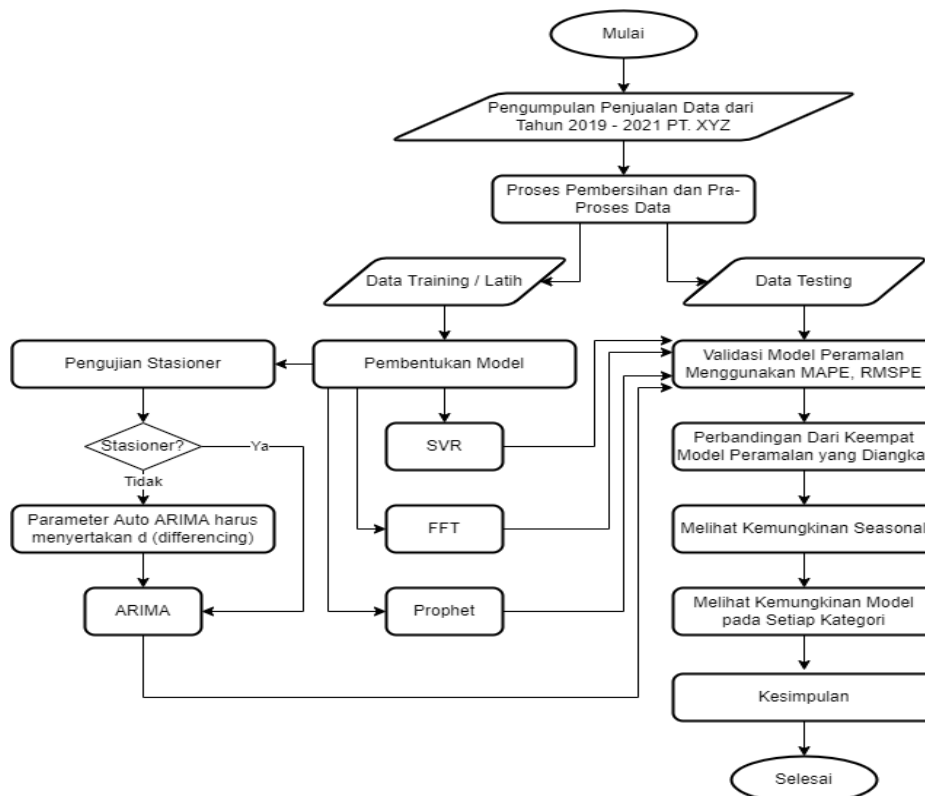
Peramalan menggunakan FFT dilakukan oleh Fumi, dkk. [10], dengan *tools Microsoft Excel*, sehingga dalam penelitiannya Fumi, dkk. dapat melakukan pemilahan dan penghapusan amplitudo agar mendapatkan MAPE terendah, Fumi, dkk. tidak hanya menggunakan FFT, tetapi juga melakukan perbandingan dengan *moving average* dan *exponential smooting*, sehingga didapatkan bahwa peramalan menggunakan FFT adalah yang terbaik dengan MAPE 43% sedangkan *moving average* 55.1%, *exponentian smooting* 55.2%.

*Prophet* yang diperkenalkan oleh *facebook* [11] dilakukan oleh Sitepu, dkk. [12] untuk memprediksi jumlah mahasiswa baru Universitas XYZ dengan 9611 baris data, mendapatkan MAPE yang ‘Sangat Baik’ menurut interpretasi dari Lewis [13], dengan nilai 0.04327567%. Penelitian *Prophet* lainnya datang dari Chandra, dkk. [14], dengan melakukan komparasi *Prophet* dan ARIMA menggunakan data pendaftaran mahasiswa baru tahunan dari 1993 sampai 2019, mendapatkan nilai RMSE *Prophet* lebih kecil dibandingkan ARIMA, seperti hasil peramalan mahasiswa baru untuk wilayah Bandung dengan hasil RMSE ARIMA 0.279 dan *Prophet* 0.135.

Bila dilihat dari penelitian yang sudah ada peramalan ARIMA, SVR, FFT dan *Prophet* menjanjikan hasil yang baik dalam hal peramalan atau *forecasting*, hal ini didasari oleh nilai akurasi MAPE ataupun RMSE penelitian-penelitian tersebut. Sehingga pada penelitian ini pun, keempat model analisis deret waktu tersebut akan diuji untuk mendapatkan peramalan yang cocok untuk data penjualan PT. XYZ. Setelahnya dilakukan pencarian *seasonality* menggunakan *library statsmodels seasonal\_decompose* seperti yang dilakukan oleh Avaznov, dkk. [15], pada data yang diambil dari *smart home* untuk melihat data cuaca, dari *seasonal\_decompose* tersebut didapatkan bahwa terdapat pola berulang. Hal yang sama juga dilakukan oleh Sarkar, dkk. [16], untuk *stock* dan harga komoditas, dari *library* itu juga Sarkar, dkk. menyebutkan terdapat perubahan yang terjadi setiap bulannya, sehingga dapat disimpulkan untuk mengetahui *seasonality* dapat digunakan *library seasonal\_decompose*.

## II. METODE PENELITIAN

Penelitian ini dilakukan melalui beberapa tahapan, pada awal proses akan dilakukan pengumpulan data terlebih dahulu, data yang dikumpulkan adalah data penjualan produk setiap bulannya dari PT. XYZ selama tiga tahun, selanjutnya akan dilakukan proses pembersihan dan pra-proses data, kemudian data penjualan tersebut akan dilakukan pemodelan dengan masing-masing model analisis deret waktu (ARIMA, SVR, FFT dan *Prophet*), hasil masing-masing model dari analisis deret waktu tersebut akan dilakukan komparasi antara data penjualan sebenarnya dengan data penjualan hasil peramalannya menggunakan nilai MAPE (*Mean Absolute Percentage Error*) dan RMSPE (*Root Mean Square Percentage Error*), model yang memiliki nilai MAPE dan RMSPE terkecil yang kemudian akan ditetapkan sebagai pemodelan deret waktu terbaik. Penelitian ini ditutup dengan proses *seasonality* data penjualan, di mana akan dilihat apakah terjadi kenaikan atau penurunan penjualan produk tersebut pada waktu tertentu. Pada akhirnya, akan disimpulkan hasil terhadap penelitian untuk mendapatkan model analisis deret waktu terbaik dan hasil *seasonality*-nya. Penggambaran alur dengan *flowchart* dapat dilihat pada Gambar 1.



Gambar 1. Alur analisis data

### III. HASIL DAN PEMBAHASAN

#### A. Pengumpulan, Pra-Proses Data dan Pembagian Data Training / Latih dan Data Testing

Hal pertama yang dilakukan sebelum dimulainya penelitian ini adalah pengumpulan data yang dibutuhkan. Dalam penelitian ini, data yang dipakai adalah data penjualan dari PT. XYZ selama tiga tahun (36 bulan), dimulai dari Januari 2019 sampai Desember 2021, yang terdiri dari data penjualan bulanan 139 produk dan untuk menjaga kerahasiaan data, nama dan kategori produk yang digunakan akan disamarkan menjadi kode unik. Pada produk ini, terdapat dua kategori, yaitu Kategori 1 dan Kategori 2, di mana masing-masing kategori memiliki jumlah data yaitu:

- Kategori 1 sebanyak 92 produk.
- Kategori 2 sebanyak 47 produk.

Setelah data tersebut terkumpul, kemudian dilakukan pra-proses data. Pra-proses data terdiri dari pembersihan data dan pra-proses data itu sendiri. Pada pembersihan data, akan dilihat dua hal, yaitu melihat apakah terdapat data NA dan mengubah tipe data dari *dataset* ke dalam tipe data yang diperlukan. Gambar 2 menunjukkan bahwa tidak terdapat data NA pada *dataset*, sehingga dapat lanjut ke proses perubahan tipe data.

```
order_period    0  
dist_name       0  
size_name       0  
order           0  
dtype: int64
```

Gambar 2. Melihat data NA dalam *dataset*

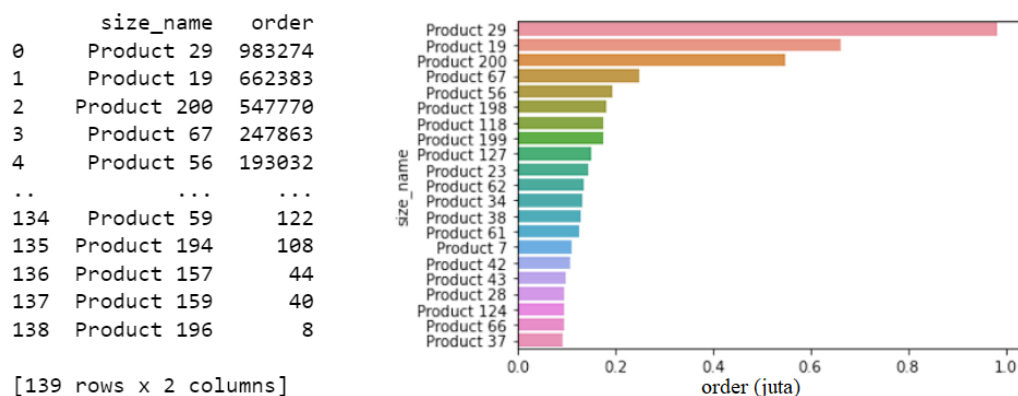
Kolom yang perlu untuk diubah tipe datanya adalah *order\_period* dan *order*, untuk memastikan bahwa tipe data *order\_period* adalah *datetime* dan *order* adalah *integer*, sedangkan kolom lainnya (*dist\_name* dan *size\_name*), cukup dengan tipe data *object* karena kedua kolom ini adalah kolom nama (*string*). Hasil akhir perubahan tipe data ini dapat dilihat pada Gambar 3.

```
<class 'pandas.core.frame.DataFrame'>  
RangeIndex: 44755 entries, 0 to 44754  
Data columns (total 4 columns):  
#   Column          Non-Null Count  Dtype  
---  ---  
0   order_period    44755 non-null  datetime64[ns]  
1   dist_name       44755 non-null  object  
2   size_name       44755 non-null  object  
3   order           44755 non-null  int64  
dtypes: datetime64[ns](1), int64(1), object(2)  
memory usage: 1.4+ MB
```

Gambar 3. Hasil akhir tipe data

Dari 139 jumlah produk dengan penjualan setiap bulannya selama tiga tahun, akan dipilah kembali menjadi lima data produk yang akan dilakukan analisis. Hal ini dikarenakan produk yang memiliki penjualan terbanyak dianggap pantas untuk dilakukan analisis tren atau *forecasting* karena dapat memberikan keuntungan pada perusahaan. Proses ini dilakukan dalam bahasa pemrograman *python*, dengan langkah:

- Melakukan penghapusan sementara terhadap kolom *order\_period* dan *dist\_name*, hal ini dilakukan untuk menjumlahkan keseluruhan jumlah penjualan (kolom *order*) per produknya (kolom *size\_name*) selama tiga tahun, sehingga akan mendapatkan baris data setiap produknya  $\leq 36$ .
- Kemudian dilakukan pengurutan data dengan penjualan terbanyak ke penjualan terendah. Hasil tersebut dapat dilihat pada Gambar 4.



Gambar 4. Hasil perhitungan penjumlahan penjualan dan plotting data

Gambar 4 menunjukkan hasil penjumlahan penjualan dari 139 data (bagan kiri) dan *plotting* data dari 21 produk teratas (bagan kanan) dengan penjualan terbanyak. Maka, lima produk dengan penjualan terbanyak adalah Produk 29, Produk 19, Produk 200, Produk 67 dan Produk 56, di mana Produk 29, Produk 67 dan Produk 56 termasuk dalam Kategori 1 dan Produk 19 dan Produk 200 termasuk dalam Kategori 2.

- Dari kelima produk tersebut dan pada proses sebelumnya telah dilakukan penjumlahan data setiap bulannya dan setelah dilakukan pemeriksaan terhadap jumlah data dari masing-masing produk, didapatkan setiap produknya memiliki 36 jumlah baris data. Hal ini menunjukkan bahwa kelima produk tersebut memiliki penjualan pada setiap bulannya dalam rentang waktu tiga tahun tersebut.

Kelima produk tersebut kemudian dibagi menjadi data *training* dan data *testing*. Rasio yang dipakai dalam penelitian ini adalah 90:10, 90% untuk data *training* dan 10% untuk data *testing*, dengan pertimbangan bahwa data *training* lebih banyak daripada data *testing* [16]. Sehingga dari 36 baris data, 32 akan dijadikan sebagai data *testing* dan 4 akan dijadikan sebagai data *training*.

#### B. Pembentukan Model - ARIMA

Peramalan ARIMA merupakan model peramalan yang terkenal dan umum digunakan yang diperkenalkan oleh Box dan Jenkins pada 1970, model ini terkenal untuk peramalan data yang bersifat non-stasioner [17]. Pada ARIMA, dibutuhkan parameter  $p$ ,  $d$  dan  $q$ , proses ini akan menggunakan Auto ARIMA untuk menghitung nilai  $p$  dan  $q$ , kemudian walaupun ARIMA dapat digunakan untuk model non-stasioner, data tetap akan diidentifikasi apakah data tersebut stasioner atau non-stasioner untuk menentukan apakah perlu menyertakan parameter pencarian  $d$  dalam Auto ARIMA. Akan digunakan juga ketiga kriteria informasi yang dimiliki ARIMA, yaitu AIC (*Akaike's Information Criterion*), BIC (*Bayesian Information Criterion*) dan AICc (*Akaike's Information Criterion Correction*), langkah yang akan dilakukan adalah:

- Pengujian stasioner menggunakan *ADF Test* (*Augmented Dickey-Fuller Test*), yang memiliki fungsi untuk mengecek akar unit (*unit root*) pada *time series* [18] [19].
- Perhitungan  $p$ ,  $d$  (bila ada) dan  $q$  menggunakan masing-masing kriteria informasi (AIC, BIC dan AICc) memakai *library pmdarima* [20], ketiga kriteria informasi tersebut merupakan cara untuk menentukan pemilihan model regresi terbaik [21] dengan perhitungan antara AIC, BIC dan AICc tersebut terendah atau terkecil.
- Perhitungan MAPE dan RMSPE.

Langkah-langkah di atas kemudian diaplikasikan pada setiap produk. Pada pengujian stasioner didapatkan hasil pada Tabel 1, yaitu:

TABEL 1  
HASIL STASIONER DATA


Nama Produk	Stasioner
Produk 29	Non-Stasioner
Produk 19	Non-Stasioner
Produk 200	Stasioner
Produk 67	Non-Stasioner
Produk 56	Non-Stasioner

Setelah diketahui bahwa terdapat data yang tidak stasioner, maka untuk Auto ARIMA, akan disertakan parameter pencarian  $d$  pada parameter *input* yang akan diberikan kepada *library*. Pencarian  $p$ ,  $d$  dan  $q$  akan menggunakan Auto ARIMA dengan *library pmdarima*, sehingga mendapatkan hasil pada Tabel 2.

TABEL 2  
HASIL PREDIKSI PERAMALAN ARIMA

Order Periode	Data Testing	Hasil Prediksi Produk 29		
		AIC	BIC	AICc
01-09-2021	38650	34437	34437	34437
01-10-2021	35557	35281	35281	35281
01-11-2021	37739	36143	36143	36143
01-12-2021	33874	37006	37006	37006
Order Periode	Data Testing	Hasil Prediksi Produk 19		
		AIC	BIC	AICc
01-09-2021	21380	21153	21153	21153
01-10-2021	23400	21666	21666	21666
01-11-2021	21995	22179	22179	22179
01-12-2021	20640	22692	22692	22692
Order Periode	Data Testing	Hasil Prediksi Produk 200		
		AIC	BIC	AICc
01-09-2021	13793	14668	17242	17242
01-10-2021	14080	11763	17023	17023
01-11-2021	17850	12511	16804	16804
01-12-2021	17462	13059	16585	16585
Order Periode	Data Testing	Hasil Prediksi Produk 67		
		AIC	BIC	AICc
01-09-2021	9057	8784	8784	8784
01-10-2021	11105	8984	8984	8984
01-11-2021	6005	9186	9186	9186
01-12-2021	8946	9389	9389	9389
Order Periode	Data Testing	Hasil Prediksi Produk 56		
		AIC	BIC	AICc
01-09-2021	8588	8435	8435	8435
01-10-2021	7850	7853	7853	7853
01-11-2021	8531	7947	7947	7947
01-12-2021	8259	7747	7747	7747

Dari hasil Auto ARIMA pada Tabel 2, didapatkan bahwa beberapa produk yaitu Produk 29, Produk 19, Produk 67 dan Produk 56 menghasilkan prediksi yang sama dengan ketiga kriteria ARIMA (AIC, BIC dan AICc), sedangkan pada Produk 200, hanya kriteria BIC dan AICc saja yang menghasilkan prediksi yang sama. Bila dilakukan penggambaran dengan diagram garis, maka hasil tersebut akan berhimpit satu sama lain. Untuk dapat melihat hasil peramalan model ARIMA ini secara visual, dapat dilihat pada Gambar 5.



Gambar 5. Hasil diagram garis dari model peramalan ARIMA

Setelahnya, dilakukan perhitungan untuk mengetahui tingkat akurasi dari peramalan ARIMA ini, hasil tersebut dapat dilihat pada Tabel 3.

TABEL 3  
MAPE DAN RMSPE HASIL PERAMALAN ARIMA

Nama Produk	AIC			BIC			AICc		
	Parameter	MAPE	RMSPE	Parameter	MAPE	RMSPE	Parameter	MAPE	RMSPE
Produk 29	ARIMA(1, 2, 1)	6.29%	7.46%	ARIMA(1, 2, 1)	6.29%	7.46%	ARIMA(1, 2, 1)	6.29%	7.46%
Produk 19	ARIMA(0, 2, 1)	4.81%	6.24%	ARIMA(0, 2, 1)	4.81%	6.24%	ARIMA(0, 2, 1)	4.81%	6.24%
Produk 200	ARIMA(0, 1, 4)	19.48%	21.46%	ARIMA(0, 1, 0)	14.19%	16.75%	ARIMA(0, 1, 0)	14.19%	16.75%
Produk 67	ARIMA(0, 2, 3)	20.01%	28.3%	ARIMA(0, 2, 3)	20.01%	28.3%	ARIMA(0, 2, 3)	20.01%	28.3%
Produk 56	ARIMA(3, 1, 0)	3.72%	4.7%	ARIMA(3, 1, 0)	3.72%	4.7%	ARIMA(3, 1, 0)	3.72%	4.7%

### C. Pembentukan Model - SVR

Pemodelan kedua yang diangkat pada penelitian ini adalah SVR. Tool yang dipakai pada pembangunan model ini adalah bahasa python dan library dari scikit-learn. Pada SVR, library GridSearchCV akan digunakan untuk memilih hyperparameter, pada parameter masing-masing kernel, dengan rentang nilai yang dapat dilihat pada Tabel 4 [22] [23] [24].

TABEL 4  
RENTANG NILAI GRIDSEARCHCV PADA SVR

Kernel	Parameter	Rentang Nilai
rbf	C	$1 \times 10^n, n = \{-6, -5, \dots, 5, 6\}$
	$\epsilon$	$1 \times 10^n, n = \{0, 1, \dots, 5, 6\}$
	$\gamma$	auto, scale
linear	C	$1 \times 10^n, n = \{-6, -5, \dots, 5, 6\}$
polynomial	C	$1 \times 10^n, n = \{-6, -5, \dots, 5, 6\}$
	$\epsilon$	$1 \times 10^n, n = \{0, 1, \dots, 5, 6\}$
	$\gamma$	auto, scale
	degree	3, 4
	coef0	0, 1
sigmoid	C	$1 \times 10^n, n = \{-6, -5, \dots, 5, 6\}$
	$\epsilon$	$1 \times 10^n, n = \{0, 1, \dots, 5, 6\}$
	$\gamma$	auto, scale

Kernel	Parameter	Rentang Nilai
	<i>coef0</i>	0, 1

Langkah analisis yang akan dilakukan untuk SVR ini adalah:

- Normalisasi data, dengan *library scikit-learn* modul *StandardScaler*, di mana modul ini akan menormalisasikan data menjadi rata-rata nol dan variansi satu, hal ini dibutuhkan karena di dalam data dapat dimungkinkan terdapat nilai yang terlampaui besar ataupun terlampaui kecil, sehingga akan memberikan kesulitan pada saat perhitungan [25].
- Pencarian *hyperparameter* dengan menggunakan *GridSearchCV* dengan rentang pada Tabel 4.
- Peramalan menggunakan model yang terbentuk
- Denormalisasi data (kebalikan proses dari normalisasi data)
- Perhitungan MAPE dan RMSPE.

Langkah-langkah di atas kemudian diaplikasikan kepada masing-masing produk, sehingga didapatkan hasil yang dapat dilihat pada Tabel 5.

TABEL 5  
HASIL PREDIKSI PERAMALAN SVR

Order Periode	Data Testing	Hasil Prediksi Produk 29			
		<i>rbf</i>	<i>linear</i>	<i>polynomial</i>	<i>sigmoid</i>
01-09-2021	38650	28220	20815	24190	27440
01-10-2021	35557	28191	20465	24190	27440
01-11-2021	37739	28149	20103	24190	27440
01-12-2021	33874	28104	19753	24190	27440
Order Periode	Data Testing	Hasil Prediksi Produk 19			
		<i>rbf</i>	<i>linear</i>	<i>polynomial</i>	<i>sigmoid</i>
01-09-2021	21380	19479	18420	16830	18556
01-10-2021	23400	19479	18412	16830	18556
01-11-2021	21995	19479	18404	16830	18556
01-12-2021	20640	19479	18396	16830	18556
Order Periode	Data Testing	Hasil Prediksi Produk 200			
		<i>rbf</i>	<i>linear</i>	<i>polynomial</i>	<i>sigmoid</i>
01-09-2021	13793	15154	12480	14832	14832
01-10-2021	14080	15154	12269	14832	14832
01-11-2021	17850	15154	12052	14832	14832
01-12-2021	17462	15154	11841	14832	14832
Order Periode	Data Testing	Hasil Prediksi Produk 67			
		<i>rbf</i>	<i>linear</i>	<i>polynomial</i>	<i>sigmoid</i>
01-09-2021	9057	7610	9395	7610	6529
01-10-2021	11105	7610	9530	7610	6529
01-11-2021	6005	7610	9669	7610	6529
01-12-2021	8946	7610	9805	7610	6529
Order Periode	Data Testing	Hasil Prediksi Produk 56			
		<i>rbf</i>	<i>linear</i>	<i>polynomial</i>	<i>sigmoid</i>
01-09-2021	8588	6793	6952	6793	6793
01-10-2021	7850	6793	7081	6793	6793
01-11-2021	8531	6793	7214	6793	6793
01-12-2021	8259	6793	7343	6793	6793

Dari hasil SVR tersebut, pada masing-masing *kernel* menghasilkan data yang hampir sama satu sama lainnya, sehingga pada penggambaran menggunakan diagram garis, hasil tersebut akan berhimpit. Untuk dapat melihat hasil SVR ini secara visual, dapat dilihat pada Gambar 6.





Gambar 6. Hasil diagram garis dari model peramalan SVR

Setelahnya, dilakukan perhitungan untuk mengetahui tingkat akurasi dari peramalan SVR ini, hasil tersebut dapat dilihat pada Tabel 6.

TABEL 6  
MAPE DAN RMSPE HASIL PREDIKSI PERAMALAN SVR

Nama Produk	Kernel SVR					MAPE	RMSPE
	rbf						
	C	$\epsilon$	$\gamma$				
Produk 29	$1 \times 10^{-2}$	$1 \times 10^{-5}$	scale			22.54%	22.87%
Produk 19	$1 \times 10^{-6}$	$1 \times 10^{-6}$	auto			10.68%	11.45%
Produk 200	$1 \times 10^{-1}$	$1 \times 10^{-1}$	auto			11.45%	11.81%
Produk 67	$1 \times 10^0$	$1 \times 10^2$	auto			22.28%	23.36%
Produk 56	$1 \times 10^0$	$1 \times 10^1$	auto			18.12%	18.35%
Nama Produk	Kernel SVR					MAPE	RMSPE
	linear						
	C						
Produk 29	$1 \times 10^{-3}$					44.25%	44.31%
Produk 19	$1 \times 10^{-6}$					15.59%	16.05%
Produk 200	$1 \times 10^{-2}$					21.76%	24.22%
Produk 67	$1 \times 10^1$					22.13%	31.74%
Produk 56	$1 \times 10^{-2}$					13.84%	14.32%
Nama Produk	Kernel SVR					MAPE	RMSPE
	polynomial						
	C	$\epsilon$	$\gamma$	degree	coef0		
Produk 29	$1 \times 10$	$1 \times 10^0$	auto	3	0	33.47%	33.64%
Produk 19	$1 \times 10^2$	$1 \times 10^0$	auto	3	0	22.83%	23.09%
Produk 200	$1 \times 10^0$	$1 \times 10^2$	auto	3	0	11.21%	12.23%
Produk 67	$1 \times 10^0$	$1 \times 10^1$	auto	3	0	22.28%	23.36%
Produk 56	$1 \times 10^0$	$1 \times 10^0$	auto	3	0	18.12%	18.36%
Nama Produk	Kernel SVR					MAPE	RMSPE
	sigmoid						
	C	$\epsilon$	$\gamma$	coef0			
Produk 29	$1 \times 10^{-2}$	$1 \times 10^{-2}$	auto	0		24.53%	24.84%
Produk 19	$1 \times 10^1$	$1 \times 10^{-1}$	auto	0		14.92%	15.41%

Produk	$1 \times 10^2$	$1 \times 10^0$	auto	0	11.21%	12.23%
Nama Produk	Kernel SVR				MAPE	RMSPE
	sigmoid					
	$C$	$\epsilon$	$\gamma$	coef0		
Produk 67	$1 \times 10^1$	$1 \times 10^{-2}$	auto	0	26.22%	28.65%
Produk 56	$1 \times 10^2$	$1 \times 10^0$	auto	0	18.12%	18.36%

D. Pembentukan Model – FFT

Pada pembentukan model FFT, tools yang dipakai adalah *Microsoft Excel*, hal ini dikarenakan pada peramalan model FFT, mengikuti peramalan yang sudah berhasil dilakukan oleh Fumi, dkk. [10]. Langkah analisis yang dilakukan untuk FFT ini adalah:


- Dengan *Microsoft Excel*, dihitung *Fourier Analysis* untuk mendapatkan koefisien deret *Fourier* pada data kolom *order*.
- Selanjutnya, dilakukan konversi hasil perhitungan pada langkah sebelumnya, untuk mendapatkan magnitudonya.
- Kemudian, dilakukan perhitungan frekuensi untuk mengetahui banyaknya pengulangan yang terjadi dalam satuan waktu pada data kolom *order period*.
- Lalu dilakukan rekonstruksi ulang menggunakan spektrum yang didapatkan pada langkah pertama sampai ketiga dengan identitas *euler*.
- Terakhir adalah pengurutan semua spektrum dimulai dari nilai amplitudo besar ke kecil dan dilakukan nilai penghapusan pasangan amplitudo kecil sampai mendapatkan nilai MAPE dan RMSPE terbaik.

Langkah-langkah tersebut di atas, kemudian diaplikasikan kepada masing-masing produk, sehingga didapatkan hasil seperti yang terlihat pada Tabel 7.

TABEL 7  
HASIL PREDIKSI PERAMALAN FFT

Order Periode	Data Testing	Hasil Prediksi Produk 29
01-09-2021	38650	26861
01-10-2021	35557	37711
01-11-2021	37739	37669
01-12-2021	33874	32739
Order Periode	Data Testing	Hasil Prediksi Produk 19
01-09-2021	21380	21939
01-10-2021	23400	19593
01-11-2021	21995	20217
01-12-2021	20640	19729
Order Periode	Data Testing	Hasil Prediksi Produk 200
01-09-2021	13793	16790
01-10-2021	14080	18172
01-11-2021	17850	18455
01-12-2021	17462	17605
Order Periode	Data Testing	Hasil Prediksi Produk 67
01-09-2021	9057	5971
01-10-2021	11105	6204
01-11-2021	6005	7172
01-12-2021	8946	9056
Order Periode	Data Testing	Hasil Prediksi Produk 56
01-09-2021	8588	3623
01-10-2021	7850	7141
01-11-2021	8531	9050
01-12-2021	8259	7790

Dilakukan pula penggambaran menggunakan diagram garis untuk dapat melihat hasil peramalan model FFT ini secara visual, hasil tersebut dapat dilihat pada Gambar 7.



Gambar 7. Hasil diagram garis dari model peramalan FFT

Setelahnya, dilakukan perhitungan untuk mengetahui tingkat akurasi dari peramalan FFT ini, hasil tersebut dapat dilihat pada Tabel 8.

TABEL 8  
MAPE DAN RMSPE HASIL PREDIKSI PERAMALAN FFT

Nama Produk	MAPE	RMSPE
Produk 29	10.02%	15.64%
Produk 19	7.85%	9.44%
Produk 200	13.75%	18.23%
Produk 67	24.72%	29.53%
Produk 56	19.65%	29.55%

E. Pembentukan Model – Prophet

Pemodelan terakhir dalam penelitian ini adalah *prophet*. Keunggulan dari *prophet* ini adalah sangat *robust* terhadap data yang memiliki perubahan tren. Pemodelan menggunakan *prophet* ini dilakukan memakai bahasa *python*. Langkah analisis yang dilakukan pada pembuatan model peramalan menggunakan *prophet* ini dikatakan lebih sederhana dibandingkan dengan model-model peramalan lainnya, dengan langkah:

- Perubahan *header* dari *dataset* menjadi ‘ds’ dan ‘y’, di mana ‘ds’ akan mengganti *order\_period* dan ‘y’ akan mengganti *order*.
- Selanjutnya dilakukan *fitting* model dengan data *training* dari masing-masing produk. Di mana *prophet* akan melakukan pembentukan model dengan data *training* tersebut.
- Setelah model terbentuk, lalu dilakukan peramalan menggunakan model tersebut.
- Perhitungan MAPE dan RMSPE.

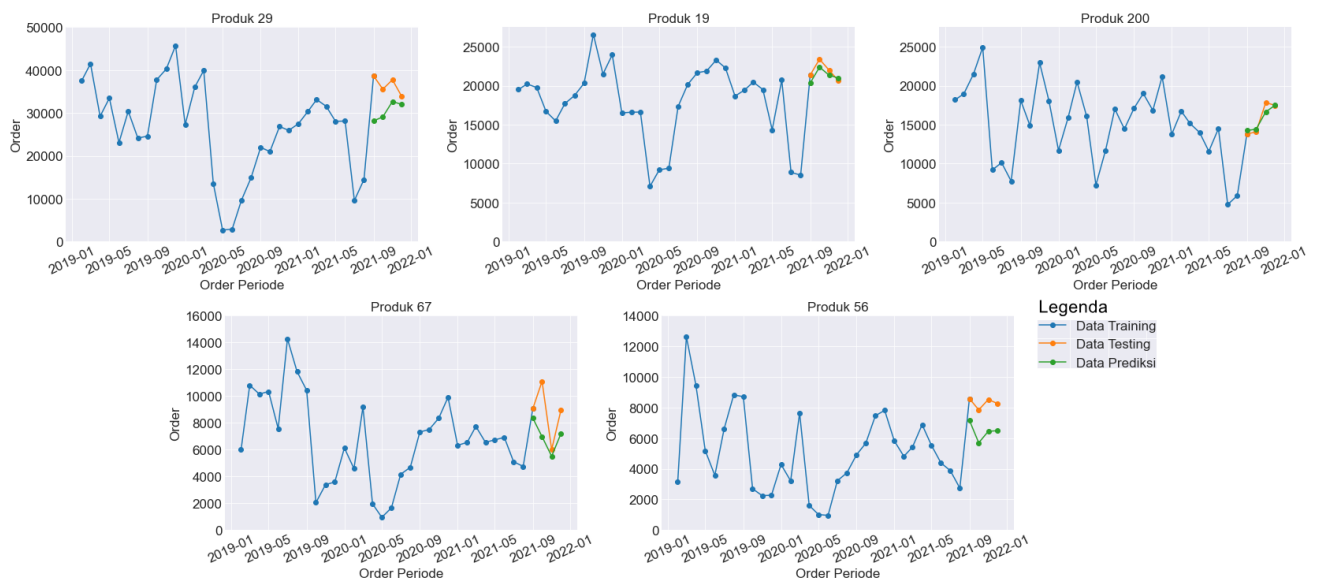
Langkah-langkah tersebut diaplikasikan ke masing-masing produk, sehingga mendapatkan hasil yang dapat dilihat pada Tabel 9.

TABEL 9  
HASIL PREDIKSI PERAMALAN *PROPHET*

Order Periode	Data Testing	Hasil Prediksi Produk 29
01-09-2021	38650	28136
01-10-2021	35557	29001
01-11-2021	37739	32679
01-12-2021	33874	31984
Order Periode	Data Testing	Hasil Prediksi Produk 19
Order Periode	Data Testing	Hasil Prediksi Produk 19

01-09-2021	21380	20350
01-10-2021	23400	22383
01-11-2021	21995	21350
01-12-2021	20640	20987
<b>Order Periode</b>	<b>Data Testing</b>	<b>Hasil Prediksi Produk 200</b>
01-09-2021	13793	14240
01-10-2021	14080	14426
01-11-2021	17850	16646
01-12-2021	17462	17481
<b>Order Periode</b>	<b>Data Testing</b>	<b>Hasil Prediksi Produk 67</b>
01-09-2021	9057	8362
01-10-2021	11105	6973
01-11-2021	6005	5509
01-12-2021	8946	7195
<b>Order Periode</b>	<b>Data Testing</b>	<b>Hasil Prediksi Produk 56</b>
01-09-2021	8588	7161
01-10-2021	7850	5700
01-11-2021	8531	6451
01-12-2021	8259	6491

Dilakukan pula penggambaran menggunakan diagram garis untuk dapat melihat hasil peramalan model *Prophet* ini secara visual, hasil tersebut dapat dilihat pada Gambar 8.



Gambar 8. Hasil diagram garis dari model peramalan *Prophet*

Setelahnya, dilakukan perhitungan untuk mengetahui tingkat akurasi dari peramalan *Prophet* ini, hasil tersebut dapat dilihat pada Tabel 10.

TABEL 10  
MAPE DAN RMSPE HASIL PREDIKSI PERAMALAN *PROPHET*

Nama Produk	MAPE	RMSPE
Produk 29	16.09%	17.89%
Produk 19	3.44%	3.66%
Produk 200	3.14%	3.94%
Produk 67	18.18%	21.76%
Produk 56	22.45%	22.8%

F. Perbandingan Keempat Model Peramalan

Masing-masing pembentukan model analisis deret waktu untuk setiap produk telah dilakukan, Tabel 11 menunjukkan hasil semua model per produknya.

TABEL 11  
HASIL PERBANDINGAN MAPE DAN RMSPE DARI SETIAP MODEL ANALISIS DERET WAKTU PER PRODUK

Nama Produk	MAPE							FFT	Prophet
	ARIMA			SVR					
	AIC	BIC	AICc	rbf	linear	poly	sigmoid		
Produk 29	6.29%	6.29%	6.29%	22.54%	44.25%	33.47%	24.53%	10.02%	16.09%
Produk 19	4.81%	4.81%	4.81%	10.68%	15.59%	22.83%	14.91%	7.85%	3.44%
Produk 200	19.48%	14.19%	14.19%	11.45%	21.76%	11.21%	11.21%	13.75%	3.14%
Produk 67	20.01%	20.01%	20.01%	22.28%	22.13%	22.28%	26.22%	24.72%	18.18%
Produk 56	3.72%	3.72%	3.72%	18.12%	13.84%	18.12%	18.12%	19.66%	22.45%

Nama Produk	RMSPE							FFT	Prophet
	ARIMA			SVR					
	AIC	BIC	AICc	rbf	linear	poly	sigmoid		
Produk 29	7.46%	7.46%	7.46%	22.87%	44.31%	33.64%	24.84%	15.64%	17.89%
Produk 19	6.24%	6.24%	6.24%	11.45%	16.05%	23.09%	15.41%	9.44%	3.66%
Produk 200	21.46%	16.75%	16.75%	11.81%	24.22%	12.23%	12.23%	18.23%	3.94%
Produk 67	28.3%	28.3%	28.3%	23.36%	31.74%	23.36%	28.65%	29.53%	21.76%
Produk 56	4.7%	4.7%	4.7%	18.35%	14.32%	18.36%	18.36%	29.55%	22.8%

Bila dilihat pada Tabel 11, masing-masing produk memiliki model analisis deret waktu dengan MAPE dan RMSPE terbaik antara model ARIMA dan Prophet dibandingkan dengan MAPE dan RMSPE SVR dan FFT, hasil akhir dari perbandingan model ini dapat dilihat pada Tabel 12.

TABEL 12  
HASIL PERBANDINGAN MAPE DAN RMSPE DARI SETIAP MODEL ANALISIS DERET WAKTU PER PRODUK

Nama Produk	Model Analisis Deret Waktu	Kriteria	MAPE	RMSPE
Produk 29	ARIMA	AIC / BIC / AICc, ARIMA(1, 2, 1)	6.29%	7.46%
Produk 19	Prophet	-	3.44%	3.66%
Produk 200	Prophet	-	3.14%	3.94%
Produk 67	Prophet	-	18.18%	21.76%
Produk 56	ARIMA	AIC / BIC / AICc, ARIMA(3, 1, 0)	3.72%	4.7%

Dilakukan pula penggambaran menggunakan diagram garis untuk dapat melihat hasil peramalan model terbaik dari masing-masing produk secara visual, hasil tersebut dapat dilihat pada Gambar 9.




Gambar 9. Hasil diagram garis dari model peramalan terbaik untuk masing-masing produk

### G. Melihat Kemungkinan Seasonal

Hal selanjutnya yang dilakukan pada penelitian ini adalah melihat kemungkinan *seasonal* dari masing-masing kelima produk. Pada analisis *seasonal* ini menggunakan bahasa *python* dan *library* dari *statsmodel* yaitu *seasonal\_decompose*. Langkah analisis yang dilakukan adalah:

- Melakukan *plotting* data secara kuartal, hal ini sebagai hipotesis awal apakah terdapat *seasonal* terhadap data tersebut. Terdapat empat kuartal di setiap tahunnya, kuartal satu dimulai dari Januari – Maret, kuartal dua dimulai dari April – Juni, kuartal tiga dimulai dari Juli – September dan kuartal empat dimulai dari Oktober – Desember.
- Melakukan *seasonal\_decompose*.

Kedua langkah tersebut juga diaplikasikan untuk masing-masing produk. Pada hipotesis awal, didapatkan bahwa terlihat terdapat *seasonality* terhadap masing-masing produk, hal ini ditunjukkan pada Gambar 10.



Gambar 10. Hasil diagram garis dari model peramalan terbaik untuk masing-masing produk


Dari Gambar 10 tersebut didapatkan hipotesis, Produk 29 terjadi kenaikan penjualan setiap tiga bulan, Produk 19 terjadi kenaikan setiap kuartal tiga, Produk 200 terlihat terdapat kenaikan pada setiap kuartalnya, sama seperti Produk 200, Produk 67 seperti terlihat adanya kenaikan setiap kuartalnya dan Produk 56 terlihat kenaikan penjualan setiap awal kuartal.

Untuk lebih jelasnya, kemudian dilakukan *seasonal\_decompose* sehingga didapatkan hasil pada Tabel 13.

TABEL 13  
KEMUNGKINAN *SEASONALITY* UNTUK MASING-MASING PRODUK

Nama Produk	Kemungkinan <i>Seasonality</i>	
	Penjualan Naik	Penjualan Turun
Produk 29	Bulan Maret dan bulan Desember.	Selain kedua bulan tersebut.
Produk 19	Bulan Maret, bulan Oktober dan bulan Desember.	Selain ketiga bulan tersebut.
Produk 200	Bulan Februari, bulan Maret, bulan Juni (tidak naik secara drastis), bulan September dan bulan Desember.	Terjadi penurunan selain dari bulan-bulan tersebut.
Produk 67	Bulan Maret, bulan Juli, bulan September dan bulan Desember.	Selain keempat bulan tersebut.
Produk 56	Setiap awal dan akhir kuartal satu, lalu selalu meningkat pada kuartal tiga dan kuartal empat.	Penurunan pada kuartal dua.

Dan untuk hasil visualisasi diagram garis dari *seasonal\_decompose* bagian *seasonal* ini dapat dilihat pada Gambar 11.



Gambar 11. Hasil *seasonal* dari *seasonal\_decompose*

#### H. Melihat Kemungkinan Model pada Setiap Kategori

Kemudian pertanyaan selanjutnya adalah apakah ada model peramalan antara ARIMA dan *Prophet* yang merupakan metode peramalan terbaik yang dapat dijadikan basis terhadap semua data yang dimiliki dalam penelitian ini. Hal ini merupakan hal terakhir dalam penelitian, maka untuk menjawab pertanyaan tersebut, dilakukanlah analisis dengan metode *head-to-head*. Tujuan dari metode *head-to-head* adalah untuk mendapatkan prediktor apa saja yang dapat menambah keyakinan terhadap metode peramalan yang diangkat ini. Langkah analisis yang dilakukan adalah:

- Mengambil sampel lebih banyak dari masing-masing kategori, yaitu 20 sampel produk sehingga jumlah produk adalah 40 produk. Produk yang diambil adalah produk yang memiliki penjualan terbanyak di setiap kategorinya.
- Melakukan peramalan ARIMA untuk produk pada Kategori 1 dan Kategori 2.
- Melakukan peramalan *Prophet* untuk produk pada Kategori 1 dan Kategori 2.

- Perhitungan MAPE dan RMSPE.
- Perhitungan rata-rata MAPE dan RMSPE.

Hasil dari langkah analisis tersebut didapatkan perhitungan MAPE dan RMSPE pada Tabel 14.

TABEL 14  
PENJUMLAHAN MAPE DAN RMSPE SETIAP KATEGORI

Kategori	ARIMA						Prophet	
	AIC		BIC		AICc		MAPE	RMSPE
	MAPE	RMSPE	MAPE	RMSPE	MAPE	RMSPE		
Kategori 1	308.82%	373.1%	306.29%	371.53%	306.29%	371.53%	356.31%	411.52%
Kategori 2	312.37%	389.4%	329.77%	400.01%	329.77%	400.01%	304.74%	357.69%

Sehingga perhitungan rata-ratanya dapat dilihat pada Tabel 15. Perhitungan rata-rata ini dihitung dengan membagi hasil penjumlahan pada Tabel 14 dengan nilai 20, di mana nilai 20 adalah jumlah sampel produk yang dipakai pada analisis ini.

TABEL 15  
RATA-RATA MAPE DAN RMSPE SETIAP KATEGORI

Kategori	ARIMA						Prophet	
	AIC		BIC		AICc		MAPE	RMSPE
	MAPE	RMSPE	MAPE	RMSPE	MAPE	RMSPE		
Kategori 1	15.44%	18.66%	15.31%	18.58%	15.31%	18.58%	17.82%	20.58%
Kategori 2	15.62%	19.47%	16.49%	20%	16.49%	20%	15.24%	17.88%

Tabel 15 menunjukkan bahwa kecenderungan Kategori 1 lebih baik menggunakan metode peramalan ARIMA dengan koefisien apa pun (AIC, BIC dan AICc), sedangkan untuk Kategori 2, walaupun nilai MAPE pada ARIMA dengan koefisien AIC dan MAPE pada *Prophet* tidak terlalu jauh, tetapi secara keseluruhan dapat disimpulkan bahwa Kategori 2 lebih baik menggunakan metode peramalan *Prophet*.

#### IV. SIMPULAN

Dari penelitian ini, didapatkan kesimpulan bahwa terdapat dua produk yaitu Produk 29 dan Produk 56 yang lebih baik menggunakan peramalan ARIMA dan tiga produk yaitu Produk 19, Produk 200 dan Produk 67 yang lebih baik menggunakan peramalan *Prophet* di mana produk-produk yang diangkat pada penelitian ini adalah produk dengan karakteristik penjualan yang berulang, hal ini dilihat dari nilai akurasi yang didapatkan menggunakan perhitungan MAPE dan RMSPE. Hal ini juga menunjukkan bahwa tidak ada algoritma atau teknik yang “one-size-fits-all”, yang ditunjukkan dengan beberapa produk yang lebih cocok menggunakan ARIMA dan yang lainnya menggunakan *Prophet*. Selain itu, masing-masing dari kelima produk tersebut telah berhasil untuk dilihat kemungkinan terjadinya *seasonal* data dan menunjukkan bahwa kelima produk tersebut memang memiliki *seasonal*. Maka dengan kombinasi penelitian analisis deret waktu dan *seasonality* ini, diharapkan minimalisir *hit* dan *miss*, yang dimaksud dengan *hit* dan *miss* di sini adalah di mana perusahaan sudah mempersiapkan stok banyak tetapi permintaan terhadap produk tersebut sedikit, sehingga stok tersebut akan menjadi sia-sia. Selain itu, dengan metode *head-to-head* juga didapatkan kemungkinan prediktor yang mempengaruhi peramalan ini adalah kategori dari produk tersebut.

Diharapkan dengan penelitian ini, perusahaan dapat mempersiapkan stok dengan lebih tepat sesuai dengan permintaannya. Terutama untuk bagian PPC (*Production Planning and Control*) pada perusahaan, bagian tersebut setidaknya mendapatkan perencanaan, seberapa banyak produksi harian yang harus dicapai guna memenuhi prediksi yang telah dilakukan.

#### UCAPAN TERIMA KASIH

Terima kasih kepada perusahaan yang tidak dapat saya sebutkan namanya di sini, tetapi dengan data tersebut dapat membantu untuk menyelesaikan penelitian ini. Terima kasih juga kepada setiap tim yang telah membantu penelitian dan penulisan makalah jurnal ini sehingga dapat berjalan dengan baik.

#### DAFTAR PUSTAKA

- [1] L. Yuliana, “Dampak Kondisi Pandemi di Indonesia Terhadap Trend Penjualan (Studi Kasus pada PD. Sumber Jaya Aluminium),” *Jurnal Riset Bisnis*, vol. 4, no. 1, pp. 27-38, 2020.
- [2] Y. Ibrahim, *Studi Kelayakan Bisnis*, Jakarta: Rineka Cipta, 2009.



- [3] L. Taranenko, "How To Apply Machine Learning To Demand Forecasting," mobidev, 1 Juli 2021. [Online]. Available: <https://mobidev.biz/blog/machine-learning-methods-demand-forecasting-retail>. [Diakses 27 Maret 2022].
- [4] M. B. Pamungkas dan A. Wibowo, "Aplikasi Metode ARIMA Box-Jenkins untuk Meramalkan Kasus DBD di Provinsi Jawa Timur," *The Indonesian Journal of Public Health*, vol. 13, no. 2, pp. 181-194, 2018.
- [5] H. Waryanto dan D. A. Wanti, "Prediksi Penjualan Seragam Sekolah dengan Menggunakan Metode ARIMA," *Jurnal Statistika dan Matematika*, vol. 1, no. 1, pp. 88-102, 2019.
- [6] T. M. Awan dan F. Aslam, "Prediction of daily COVID-19 cases in European countries using automatic ARIMA model," *Journal of Public Health Research*, vol. 9, no. 3, pp. 227-233, 2020.
- [7] R. E. Cahyono, J. P. Sugiono dan S. Tjandra, "Analisis Kinerja Metode Support Vector Regression (SVR) dalam Memprediksi Indeks Harga Konsumen," *JTIM: Jurnal Teknologi Informasi dan Multimedia*, vol. 1, no. 2, pp. 106-116, 2019.
- [8] R. Amanda, H. Yasin dan A. Prahutama, "Analisis Support Vector Regression (SVR) dalam Memprediksi Kurs Rupiah terhadap Dolar Amerika Serikat," *Jurnal Gaussian*, vol. 3, no. 4, pp. 849-857, 2014.
- [9] N. D. Maulana, B. D. Setiawan dan C. Dewi, "Implementasi Metode Support Vector Regression (SVR) Dalam Peramalan Penjualan Roti (Studi Kasus: Harum Bakery)," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 3, no. 3, pp. 2986-2995, 2019.
- [10] A. Fumi, A. Pepe, L. Scarabotti dan M. M. Schiraldi, "Fourier Analysis for Demand Forecasting in a Fashion Company," *International Journal of Engineering Business Management*, vol. 5, pp. 1-10, 2013.
- [11] I. Yenidoğan, A. Çayır, O. Kozan, T. Dağ dan Ç. Arslan, "Bitcoin Forecasting Using ARIMA and PROPHET," dalam *IEEE 2018 3rd International Conference on Computer Science and Engineering (UBMK)*, Sarajevo, Bosnia and Herzegovina, 2018.
- [12] F. T. BR Sitepu, V. A. P. Sirait dan R. Yunis, "Analisis Runtun Waktu Untuk Memprediksi Jumlah Mahasiswa Baru Dengan Model Prophet Facebook," *Paradigma - Jurnal Komputer dan Informatika*, vol. 23, no. 1, pp. 99-105, 2021.
- [13] C. D. Lewis, *Industrial and Business Forecasting Methods: A Practical Guide to Exponential Smoothing and Curve Fitting*, Boston: Butterworth Scientific, 1982.
- [14] C. Chandra dan S. Budi, "Analisis Komparatif ARIMA dan Prophet dengan Studi Kasus Dataset Pendaftaran Mahasiswa Baru," *JuTISI: Jurnal Teknik Informatika dan Sistem Informasi*, vol. 6, no. 2, pp. 278-287, 2020.
- [15] N. Avazov, J. Lie dan B. Khousainov, "Periodic Neural Networks for Multivariate Time Series Analysis and Forecasting," dalam *IJCNN: International Joint Conference on Neural Networks*, Budapest, Hungary, 2019.
- [16] I. Oktavianti, Ermatita dan D. P. Rini, "Analisis Pola Prediksi Data Time Series menggunakan Support Vector Regression, Multilayer Perceptron dan Regresi Linear Sederhana," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 3, no. 2, pp. 282-287, 2019.
- [17] L. Zhou, "Application of ARIMA model on prediction of China's corn market," *Journal of Physics: Conference Series*, vol. 1941, no. 1, pp. 1-6, 2021.
- [18] statsmodels, "statsmodels.tsa.stattools.adfuller," statsmodels, [Online]. Available: <https://www.statsmodels.org/dev/generated/statsmodels.tsa.stattools.adfuller.html>. [Diakses 2022 September 2022].
- [19] Y. Verma, "Complete Guide To Dickey-Fuller Test In Time-Series Analysis," Developers Corners, 18 Agustus 2021. [Online]. Available: <https://analyticsindiamag.com/complete-guide-to-dickey-fuller-test-in-time-series-analysis/>. [Diakses 20 September 2022].
- [20] Smith, Taylor G., dkk, "pmdarima: ARIMA estimators for Python," 2017. [Online]. Available: <http://www.alkaline-ml.com/pmdarima>. [Diakses 30 Oktober 2022].
- [21] M. Fathurahman, "Pemilihan Model Regresi Bernoulli Terbaik," dalam *Prosiding Seminar Nasional Matematika, Statistika dan Aplikasinya*, Samarinda, 2021.
- [22] L. Villalobos-Arias, C. Quesada-López, J. Guevara-Coto, A. Martínez dan M. Jenkins, "Evaluating Hyper-parameter Tuning using Random Search in Support Vector Machines for Software Effort Estimation," dalam *16th ACM International Conference on Predictive Models and Data Analytics in Software Engineering*, New York, 2020.
- [23] R. Laref, E. Losson, A. Sava dan M. Siadat, "On the optimization of the support vector machine regression hyperparameters setting for gas sensors array applications," *On the optimization of the support vector machine regression hyperparameters setting for gas sensors array applications*, vol. 184, no. 1, pp. 22-27, 2018.
- [24] H. Yasin, A. Prahutama dan T. W. Utami, "Prediksi Harga Saham Menggunakan Support Vector Regression dengan Algoritma Grid Search," *Media Statistika*, vol. 7, no. 1, pp. 29-35, 2014.
- [25] C.-W. Hsu, C.-C. Chang dan C.-J. Lin, "A Practical Guide to Support Vector Classification," National Taiwan University, Taipei 106, 2016.