

Prediksi Pendapatan Penjualan Makanan Menggunakan Algoritma Autoregressive Integrated Moving Average (ARIMA)

Euis Oktavianti, Haidar Ali

Teknik Informatika, Politeknik Negeri Jakarta

Jl. Prof. DR. G.A. Siwabessy Kampus, Kukusan, Beji, Depok City, West Java 16425, Indonesia

euis.oktavianti@tik.pnj.ac.id, haidar.ali.tik18@mhs.pnj.ac.id

Abstract - Sales of food in the culinary industry is an important part of business continuity. Weather conditions, holidays, seasons, and other factors can affect food sales. Therefore, food companies need to understand these factors to optimize sales. This study aims to predict food sales at Sate Bibali companies using the ARIMA (Autoregressive Integrated Moving Average) algorithm. Daily sales data were obtained from the company for 13 months and then analyzed using the ARIMA algorithm. The results of the study show that the ARIMA algorithm can predict food sales at the Sate Bibali company with fairly good accuracy. The best ARIMA model for predicting food sales has a MAPE value of 23.8% with a distribution of 391 data trains and 30 test data. By utilizing this prediction model, the Sate Bibali company can predict future food sales and take appropriate actions to optimize sale. This case study can be used as a reference for other food companies in utilizing the ARIMA algorithm to predict food sales. Overall, this research provides useful information for food companies in increasing operational efficiency and obtaining higher profits. In addition, this research can be used as a reference for further research in the field of time series forecasting using the ARIMA algorithm in the culinary industry.

Keywords: ARIMA (Autoregressive Integrated Moving Average), Forecasting, Culinary Industry, Food Sales

Abstrak-- Penjualan makanan di industri kuliner merupakan bagian yang penting bagi keberlangsungan bisnis. Kondisi cuaca, hari libur, musim, dan faktor-faktor lainnya dapat mempengaruhi penjualan makanan. Oleh karena itu, perusahaan makanan perlu memahami faktor-faktor tersebut untuk mengoptimalkan penjualan. Penelitian ini bertujuan untuk memprediksi penjualan makanan pada perusahaan Sate Bibali dengan menggunakan algoritma ARIMA (Autoregressive Integrated Moving Average). Data penjualan harian diperoleh dari perusahaan selama 13 bulan dan kemudian dianalisis menggunakan algoritma ARIMA. Hasil penelitian menunjukkan bahwa algoritma ARIMA dapat memprediksi penjualan makanan pada perusahaan Sate Bibali dengan akurasi yang cukup baik. Model ARIMA terbaik untuk prediksi penjualan makanan memiliki nilai MAPE sebesar 23,8% dengan pembagian data train sebanyak 391 dan data test sebanyak 30. Dengan memanfaatkan model prediksi ini, perusahaan Sate Bibali dapat memperkirakan penjualan makanan di masa depan dan mengambil tindakan yang tepat untuk mengoptimalkan penjualan. Studi kasus ini dapat dijadikan referensi bagi perusahaan makanan lainnya dalam memanfaatkan algoritma ARIMA untuk memprediksi penjualan makanan. Secara keseluruhan, penelitian ini memberikan informasi yang berguna bagi perusahaan makanan dalam meningkatkan efisiensi operasional dan memperoleh keuntungan yang lebih tinggi. Selain itu, penelitian ini dapat dijadikan sebagai referensi untuk penelitian lanjutan di bidang time series forecasting menggunakan algoritma ARIMA pada industri kuliner.

Kata kunci: ARIMA (Autoregressive Integrated Moving Average), Forecasting, Industri Kuliner, Penjualan Makanan

I. PENDAHULUAN

Industri makanan adalah komponen vital ekonomi global, dengan jutaan orang mengandalkannya untuk kelangsungan hidup dan mata pencaharian mereka. Karena itu, sangat penting untuk mengoptimalkan penjualan makanan dan meningkatkan efisiensi operasional. Perusahaan makanan harus mampu mengoptimalkan strategi pemasaran dan penjualan makanannya agar dapat

bersaing di pasar yang semakin kompetitif [1]. Makalah ini mengeksplorasi penggunaan algoritma Autoregressive Integrated Moving Average (ARIMA) dalam memprediksi penjualan makanan di Sate Bibali, sebuah perusahaan makanan. ARIMA merupakan model time series yang populer dan banyak digunakan untuk memprediksi data time series [2]. Tujuan dari makalah ini adalah untuk memberikan wawasan berharga bagi perusahaan

makanan yang ingin meramalkan penjualan mereka dan membuat keputusan bisnis yang tepat.

Penelitian ini dilatarbelakangi oleh pengaruh kondisi cuaca, hari libur, dan faktor lainnya terhadap penjualan makanan, yang dapat memiliki konsekuensi yang signifikan terhadap profitabilitas perusahaan makanan. Dengan memahami dan mengoptimalkan faktor-faktor ini, perusahaan makanan dapat meningkatkan efisiensi operasional dan meningkatkan keuntungan.

Tujuan dari penelitian ini adalah untuk menunjukkan keefektifan algoritma ARIMA dalam memprediksi penjualan makanan dan menunjukkan bagaimana hal itu dapat digunakan untuk memperkirakan penjualan di masa depan dan mengambil tindakan yang tepat untuk mengoptimalkannya. Pernyataan tesis dari makalah ini adalah bahwa algoritma ARIMA adalah alat yang efektif untuk memprediksi penjualan makanan dan dapat berkontribusi untuk meningkatkan efisiensi dan profitabilitas perusahaan makanan.

Telah dilakukan penelitian sebelumnya dengan menggunakan metode Autoregressive Moving Average (ARIMA) dalam melakukan prediksi, diantaranya melakukan forecasting Analisis Prediksi Penduduk di Kota Pasuruan diperoleh model ARIMA (1,1,1) dengan nilai MAPE sebesar 1,52% [1].

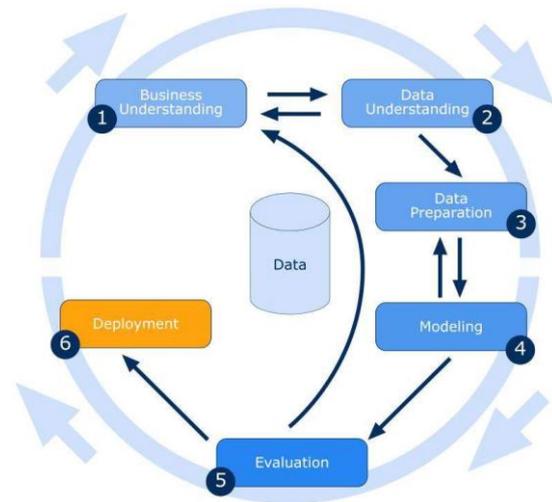
Pada makalah ini, pertama-tama akan diperkenalkan konsep algoritma ARIMA dan penerapannya dalam memprediksi data time-series. Kami kemudian akan menyajikan metodologi yang digunakan dalam penelitian ini, termasuk proses pengumpulan dan analisis data. Kami akan membahas hasil penelitian dan memberikan analisis rinci dari temuan. Akhirnya, kami akan menyimpulkan dengan meringkas poin-poin utama dari makalah ini dan menyoroti implikasinya bagi industri makanan.

Berdasarkan uraian diatas maka peneliti tertarik untuk menentukan model yang terbaik untuk pendapatan penjualan makanan dengan menggunakan metode ARIMA dan mengetahui hasil peramalan atau prediksi pendapatan penjualan Sate Bibali bulan depan dengan menggunakan metode ARIMA.

II. METODE PENELITIAN

Dalam penelitian ini, metodologi data mining CRISP-DM digunakan sebagai pemecah masalah umum untuk bisnis dan penelitian.

Metodologi ini terdiri dari enam tahapan yaitu Business Understanding, Data Understanding, Data Preparation, Modeling, Evaluation, dan Deployment. Proses metodologi ini terdiri dari 6 tahapan yang dapat dijelaskan sebagai berikut.



Gambar 1. CRISP-DM

1. Business Understanding

Pada tahap ini, berbagai tugas dilakukan, termasuk memahami persyaratan dan tujuan bisnis. Ini melibatkan interpretasi pengetahuan untuk mendefinisikan masalah penambangan data dan kemudian merancang rencana dan pendekatan untuk mencapai tujuan penambangan data.

2. Data Understanding

Tahap ini dimulai dengan mengumpulkan data, memberikan deskripsi data, dan menilai kualitasnya.

3. Data Preparation

Selama tahap ini, yang merupakan tahap konstruksi dataset dari data mentah, berbagai tugas dilakukan, seperti pembersihan data, pemilihan data, penanganan catatan dan atribut, dan transformasi data untuk digunakan sebagai masukan dalam tahap pemodelan.

4. Modelling

Pada tahap ini langsung melibatkan Machine Learning untuk menentukan teknik data mining, tools data mining dan algoritma data mining. Penelitian ini menggunakan model Time Series dengan algoritma pilihan ARIMA (Autoregressive Integrated Moving Average). Penggunaan ARIMA didasarkan pada asumsi bahwa data deret waktu yang digunakan harus stasioner, artinya rata-rata

variasi data yang bersangkutan adalah konstan. Namun, ada beberapa hal yang terjadi ketika data tidak stasioner. Untuk mengatasi data yang tidak stasioner dilakukan proses differencing agar data menjadi stasioner. Karena model Autoregressive (AR), Moving Average (MA), dan Autoregressive Moving Average (ARMA) tidak dapat menjelaskan pengertian deferencing, maka digunakan model campuran yang disebut Autoregressive Integrated Moving Average (ARIMA) atau ARIMA(p,d,q) sehingga menjadi lebih efektif dalam menjelaskan proses differencing. Dalam model campuran ini, deret stasioner merupakan fungsi linear dari nilai masa lalu dan nilai masa kini serta kesalahan masa lalu [3].

ARIMA membutuhkan data stasioner untuk penerapannya. Namun, beberapa kumpulan data mungkin tidak stasioner melainkan terintegrasi, membutuhkan prosedur pembedaan. Setelah proses pembedaan, data kemudian dianalisis ARMA (Autoregressive Moving Average). Metode ARIMA melibatkan penggunaan parameter ARIMA (p, d, q), di mana 'd' mewakili jumlah perbedaan yang diterapkan pada data. Persamaan umum ARIMA adalah sebagai berikut.

$$\phi_p(B)(1-B)^d Z_t = \theta_q(B) a_t \quad (1)$$

Keterangan:

- ϕ_p : Proses Autoregressive
- θ_q : Proses Moving Average
- $(1-B)^d$: Operator Pembeda
- d : Tingkat Diferensiasi (sehingga proses menjadi stasioner)
- B : Operatur Langkah Mundur
- Z_t : Penyimpangan Rata-Rata Proses
- a_t : Nilai Error t
- θ_0 : Konstan

Mengetahui baik buruknya suatu proyek dapat dilihat dengan melihat nilai MAPE sebagai berikut.

TABEL I. NILAI MAPE

Nilai	Keterangan
<10%	Hasil prediksi sangat baik
10-20%	Hasil prediksi baik

Nilai	Keterangan
20-50%	Hasil prediksi cukup
>50%	Hasil prediksi buruk

5. Evaluation

Tahap kelima CRISP-DM adalah evaluasi model yang telah dibangun untuk menilai kualitas dan kelayakan model. Pada tahap ini, model diuji dan divalidasi, dan dilakukan perbaikan model jika ditemukan kekurangan [4].

6. Deployment

Tahap akhir dari CRISP-DM adalah mengimplementasikan model yang telah dibangun ke dalam lingkungan bisnis. Pada tahap ini dilakukan implementasi model yang telah dibangun dan monitoring kinerja model yang telah diimplementasikan [4].

III. HASIL DAN PEMBAHASAN

Implementasi sistem pada penelitian ini menggunakan CRISP-DM (Cross Industry Standard Process for Data Mining) sebagai metode dalam data mining pada penelitian ini. Tahapannya meliputi *business understanding, data understanding, data preparation, modeling, evaluation, dan deployment*.

1. Business Understanding

Penerapan data mining pada penelitian ini berhubungan langsung dengan data transaksi Sate Bibali untuk memprediksi pendapatan penjualan dengan periode bulanan, mingguan dan harian. Pengolahan data untuk menghasilkan prediksi nantinya akan menggunakan model ARIMA yang akan dijelaskan lebih lanjut pada tahap pemodelan.

2. Data Understanding

Penelitian ini menggunakan data yang berasal dari back office aplikasi kasir MOKA POS yang digunakan Sate Bibali. Data yang digunakan adalah ringkasan data transaksi periode 1 Maret 2022 sampai dengan 30 April 2023 di dua cabang gerai Sate Bibali yang berlokasi di kawasan Senopati dan Pasar Minggu. Data transaksi ini memiliki variabel seperti outlet, tanggal, waktu, penjualan kotor, diskon, dan lain-lain.

Gambar 2. Data Transaksi

Gambar di atas adalah screenshot data transaksi Sate Bibali yang sudah di export ke file excel. Variabel yang perlu digunakan dalam penelitian ini adalah tanggal yang berarti tanggal dan penjualan bersih yang berarti pendapatan akhir.

3. Data Preparation

Dataset yang memiliki banyak variabel kolom yang tidak diperlukan dalam penelitian ini harus dibersihkan. Data seperti informasi diskon, refund, pajak, dan lainnya tidak diperlukan. Sehingga kolom yang tidak diperlukan perlu dibersihkan terlebih dahulu dari dataset. Namun sebelumnya, dataset tersebut terbagi dari dua gerai berbeda, yakni gerai cabang Senopati dan Pasar Minggu. Sehingga outlet data perlu digabungkan menjadi satu. Pada tahap ini dilakukan penggabungan dan pembersihan data pada Microsoft Excel yang kemudian diekspor dalam bentuk file csv.

TABEL II. DATA PREPROCESSING I

Tanggal	Pendapatan
3/1/2022	3613850
3/1/2022	859000
3/1/2022	58000
3/1/2022	75000
3/1/2022	406000
3/1/2022	65000
3/1/2022	63000
3/1/2022	113000
3/1/2022	58000
...	...
4/30/2023	116000
4/30/2023	122000

Tanggal	Pendapatan
4/30/2023	130000
4/30/2023	10000
4/30/2023	234000

Setelah itu, data dengan tanggal yang sama harus digabungkan menjadi satu dengan menjumlahkan data tersebut pada kolom Penjualan Bersih pada setiap tanggal yang sama. Proses pada tahap ini dilakukan di Jupyter dengan menggunakan bahasa Python.

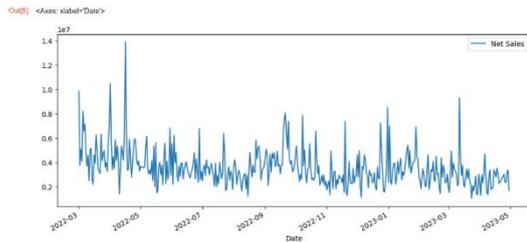
Python memiliki banyak jenis library, salah satunya adalah panda yang dalam hal ini kegunaannya adalah untuk membaca data tipe file csv. Gambar diatas merupakan proses import panda dan membaca dataset yang digunakan dalam penelitian ini. Nama file dataset adalah 'Transaction_Dataset.csv'.

TABEL III. DATA PREPROCESSING II

Tanggal	Pendapatan
3/1/2022	9844850
3/2/2022	3741400
3/3/2022	5080000
3/4/2022	4085700
3/5/2022	8207850
3/6/2022	6563500
3/7/2022	7103750
3/8/2022	4806150
3/9/2022	3697400
...	...
4/26/2023	2327800
4/27/2023	2360700
4/28/2023	3182800
4/29/2023	3368900

Tanggal	Pendapatan
4/30/2023	1673300

Setelah data yang diinginkan diperoleh setelah dilakukan preprocessing data, data tersebut diekspor kembali dalam bentuk file csv yang selanjutnya akan digunakan untuk proses persiapan data pada tahap selanjutnya. Pada tahap ini, data diekspor dengan nama 'Transaction_DatasetNew'.



Gambar 3. Data Plot

Gambar 3 adalah plot data dalam grafik yang menggambarkan perjalanan pendapatan penjualan di Sate Bibali pada periode awal Maret 2022 hingga akhir April 2023.

4. Modelling

Tahapan ini merupakan proses dimana model dengan metode time series terpilih menghasilkan pola informasi yang dapat memudahkan pihak yang berkepentingan untuk mendapatkan prediksi. Pola time series yang digunakan adalah memprediksi pendapatan penjualan dengan parameter yang mempengaruhinya. Tools atau alat dalam pengolahan data mining adalah Jupyter yang berbasis Python. Tahap ini menampilkan dan memberikan informasi kinerja algoritma pada metode time series. Algoritma ARIMA (Autoregressive Integrated Moving Average) merupakan model time series dengan menggunakan parameter AR (autoregressive), I (Integrated), dan MA (Moving Average) sebagai parameter yang ditulis dengan urutan p, d, dan q atau ARIMA(p, d, q).

Syarat penggunaan model ARIMA adalah data harus stasioner. Gambar 4.14 menunjukkan bahwa plot-plot data cukup stasioner sehingga tidak perlu dilakukan pembedaan untuk stasioner data. Stasioneritas data dapat diperiksa dengan melihat *P-Value* di bawah 0,05 pada data plot menggunakan metode tes ADF.

```
In [11]: from statsmodels.tsa.stattools import adfuller
def adf_test(dataset):
    dftest = adfuller(dataset, autolag='AIC')
    print("1. ADF : ", dftest[0])
    print("2. P-Value : ", dftest[1])
    print("3. Num Of Lags : ", dftest[2])
    print("4. Num Of Observations Used For ADF Regression:", dftest[3])
    print("5. Critical Values : ")
    for key, val in dftest[4].items():
        print("%s : %s" % (key, val))
adf_test(df[Net Sales])

1. ADF : -4.571663074582638
2. P-Value : 0.00014562838292160677
3. Num Of Lags : 7
4. Num Of Observations Used For ADF Regression: 413
5. Critical Values :
1% : -3.4462831955497135
5% : -2.8685636962704395
10% : -2.5705114078759914
```

Gambar 4. Jupyter Tes ADF

Uji ADF menunjukkan bahwa *P-Value* pada data yang digunakan adalah 0,0001456. Data dikatakan stasioner karena dengan syarat *P-Value* 0,05.

Kemudian setelah data yang akan digunakan stasioner, langkah selanjutnya adalah mencari dan menganalisis nilai orde p, d, dan q terbaik untuk model ARIMA yang akan dipilih. Ada beberapa cara untuk menganalisis model terbaik, salah satunya adalah dengan menggunakan auto arima di Python.

```
from pmdarima import auto_arima
stepwise_fit = auto_arima(df[Net Sales], trace=True, suppress_warnings=True, d=0, stepwise=False, seasonal=False)

ARIMA(0.0,0,0.0,0,0) : AIC=13969.436, Time=0.05 sec
ARIMA(0.0,1,0.0,0,0) : AIC=13749.793, Time=0.16 sec
ARIMA(0.0,2,0.0,0,0) : AIC=13680.796, Time=0.23 sec
ARIMA(0.0,3,0.0,0,0) : AIC=13659.401, Time=0.33 sec
ARIMA(0.0,4,0.0,0,0) : AIC=13648.545, Time=0.43 sec
ARIMA(0.0,5,0.0,0,0) : AIC=13637.932, Time=0.48 sec
ARIMA(1.0,0,0.0,0,0) : AIC=13285.656, Time=0.16 sec
ARIMA(1.0,1,0.0,0,0) : AIC=13128.696, Time=0.47 sec
ARIMA(1.0,2,0.0,0,0) : AIC=13117.970, Time=0.65 sec
ARIMA(1.0,3,0.0,0,0) : AIC=13117.868, Time=1.18 sec
ARIMA(1.0,4,0.0,0,0) : AIC=13117.868, Time=1.62 sec
ARIMA(2.0,0,0.0,0,0) : AIC=13222.059, Time=0.24 sec
ARIMA(2.0,1,0.0,0,0) : AIC=13123.051, Time=0.63 sec
ARIMA(2.0,2,0.0,0,0) : AIC=13119.514, Time=1.09 sec
ARIMA(2.0,3,0.0,0,0) : AIC=13119.776, Time=1.57 sec
ARIMA(3.0,0,0.0,0,0) : AIC=13203.834, Time=0.37 sec
ARIMA(3.0,1,0.0,0,0) : AIC=13125.051, Time=1.04 sec
ARIMA(3.0,2,0.0,0,0) : AIC=13120.013, Time=1.45 sec
ARIMA(4.0,0,0.0,0,0) : AIC=13181.580, Time=0.43 sec
ARIMA(4.0,1,0.0,0,0) : AIC=13120.526, Time=0.99 sec
ARIMA(5.0,0,0.0,0,0) : AIC=inf, Time=0.51 sec

Best model: ARIMA(1.0,4,0.0,0,0)
Total fit time: 14.127 seconds
```

Gambar 5. Jupyter Auto ARIMA

Gambar di atas menunjukkan bahwa model terbaik untuk model ARIMA yang digunakan adalah ARIMA(1,0,4). Hal ini menunjukkan bahwa nilai model terbaik yang dipilih adalah nilai dengan orde p sama dengan 1, orde d sama dengan 0, dan orde q sama dengan 4.

Langkah selanjutnya adalah membagi dataset menjadi data latih dan data uji. Data latih ini nantinya akan digunakan untuk diolah pada tahap pemodelan berikutnya dengan model ARIMA. Gambar diatas menunjukkan proses pembagian data latih dengan total 391 data dan 30 data uji dari total 421 data yang ada.

```
from statsmodels.tsa.arima.model import ARIMA
model=ARIMA(train['Net Sales'],order=(1,0,4))
model=model.fit()
model.summary()
```

Gambar 6. Jupyter ARIMA Modeling

SARIMAX Results

Dep. Variable:	Net Sales	No. Observations:	391			
Model:	ARIMA(1, 0, 4)	Log Likelihood:	-6093.044			
Date:	Mon, 10 Jul 2023	AIC:	12200.089			
Time:	15:14:29	BIC:	12227.889			
Sample:	0	HQIC:	12211.100			
			- 391			
Covariance Type:	oob					
	coef	std err	z	P> z	[0.025	0.975]
const	3.632e-06	1.03e-09	3.53e-15	0.000	3.64e-06	3.64e-06
ar.L1	0.9807	0.013	74.097	0.000	0.955	1.007
ma.L1	-0.7825	0.052	-14.884	0.000	-0.885	-0.680
ma.L2	-0.0884	0.056	-1.585	0.113	-0.198	0.021
ma.L3	-0.1229	0.073	-1.691	0.091	-0.265	0.020
ma.L4	0.0839	0.059	1.411	0.158	-0.033	0.200
sigma2	1.922e-12	1.46e-14	1.32e-26	0.000	1.93e-12	1.93e-12
Ljung-Box (L1) (Q):	0.04	Jarque-Bera (JB):	918.36			
Prob(Q):	0.84	Prob(JB):	0.00			
Heteroskedasticity (H):	0.71	Skew:	1.83			
Prob(H) (two-sided):	0.06	Kurtosis:	9.56			

Gambar 7. Hasil Modeling ARIMA

Langkah selanjutnya adalah mengolah model ARIMA(1,0,4) pada data train seperti pada Gambar 6. Model tersebut menghasilkan uji signifikansi yang terlampir pada Gambar 7.

5. Evaluation

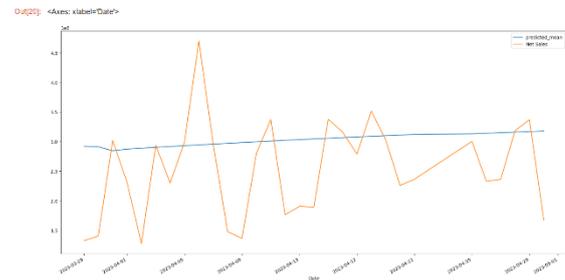
Pengujian model dilakukan dengan menggunakan uji kesesuaian model yang meliputi perbandingan analisis trend forecast dengan data prediksi dan data aktual. Pengujian dilakukan di Jupyter dengan menjalankan perintah predict pada data latih dan data uji. Perintah tersebut akan menampilkan grafik data uji yang diuji terhadap data prediksi dan data aktual. Kemudian pengujian selanjutnya adalah menguji nilai MAPE sebagai indikator tingkat kesalahan pada model yang digunakan. Semakin kecil nilai MAPE yang diperoleh maka semakin baik model tersebut.

```
start=len(train)
end=len(train)+len(test)-1
pred=model.predict(start=start,end=end,typ='levels')
print(pred)
pred.index=df.index[start:end+1]

pred.plot(figsize=(20,10), legend=True)
test['Net Sales'].plot(legend=True)
```

Gambar 8. Jupyter Data Test

Tahapan ini dilakukan dengan memanggil data latih ke dalam variabel awal sebagai data yang telah dilatih dengan model ARIMA(1,0,4) seperti pada Gambar 8. Kemudian dilakukan perbandingan dengan memperhatikan plot data garis dari nilai prediksi dan aktual.



Gambar 9. Jupyter Tes Perbandingan

Perbandingan antara data prediksi dengan data aktual pada data uji menunjukkan perbedaan yang cukup baik dengan rata-ratanya. Perbandingan ini dijelaskan dalam Tabel IV.

TABEL IV. PERBANDINGAN DATA PREDIKSI DAN AKTUAL

Tanggal	Data Aktual (a)	Data Prediksi (t)	Error Absolut (At - Ft)
3/29/2023	1319900	2919065	-1599165
3/30/2023	1402900	2909605	-1506705
3/31/2023	3017700	2843846	173854
4/1/2023	2307800	2871093	-563293
4/2/2023	1273400	2885911	-1612511
4/3/2023	2936400	2900443	35957
4/4/2023	2295800	2914693	-618893
4/5/2023	2990500	2928669	61831
4/6/2023	4699800	2942374	1757426

4/7/2023	2949200	2955814	-6614
4/8/2023	1474000	2968995	-1494995
4/9/2023	1360900	2981921	-1621021
4/10/2023	2798900	2994597	-195697
4/11/2023	3373300	3007029	366271
4/12/2023	1761800	3019220	-1257420
4/13/2023	1902000	3031176	-1129176
4/14/2023	1892800	3042900	-1150100
4/15/2023	3376100	3054398	321702
4/16/2023	3159700	3065674	94026
4/17/2023	2787100	3076732	-289632
4/18/2023	3514100	3087576	426524
4/19/2023	3026900	3098211	-71311
4/20/2023	2255000	3108641	-853641
4/21/2023	2362200	3118868	-756668
4/25/2023	3001900	3128899	-126999
4/26/2023	2327800	3138735	-810935
4/27/2023	2360700	3148381	-787681
4/28/2023	3182800	3157841	24959
4/29/2023	3368900	3167118	201782
4/30/2023	1673300	3176216	-1502916

Tabel IV menunjukkan hasil ramalan metode ARIMA (1,0,4) untuk data uji 30 hari terakhir. Kemudian dilanjutkan dengan perhitungan untuk mendapatkan nilai MAPE.

```
In [23]: from sklearn.metrics import mean_absolute_error, mean_absolute_percentage_error, mean_squared_error
from math import sqrt

mape = mean_absolute_percentage_error(pred, test['Net Sales'])
rmse = sqrt(mean_squared_error(pred, test['Net Sales']))

print(f'mae: {mape}')
print(f'mape: {mape}')

#print(f'rmse: {rmse}')

mae: 713990.2241013729
mape: 0.2376936176864966
```

Gambar 10. Jupyter Test MAPE

Perhitungan nilai MAPE dapat dilakukan seperti pada Gambar 10. Nilai MAPE yang dihasilkan sebesar 0,238 atau setara dengan 23,8%.

Pengujian yang telah dilakukan dengan analisis forecast trend cukup baik. Nilai MAPE yang diperoleh sebesar 23,8% termasuk dalam kategori cukup/layak. Hal ini menunjukkan bahwa model ARIMA(1,0,4) memiliki nilai error yang cukup kecil dan akan digunakan untuk memprediksi pendapatan penjualan Sate Bibali.

6. Deployment

Setelah tahap evaluasi untuk menilai secara detail hasil dari suatu model, kemudian implementasi dari keseluruhan model yang telah dibangun diperketat.

```
model2=ARIMA(df['Net Sales'], order=(1,0,4))
model2=model2.fit()
```

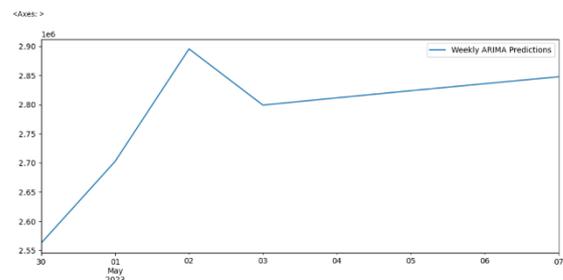
Gambar 11. Jupyter Implementasi Model

Implementasi model dilakukan pada semua data seperti pada Gambar 11. Setelah itu perlu dilakukan plot nilai prediksi untuk data yang menjadi tujuan penelitian ini yaitu prediksi bulanan, mingguan dan harian.

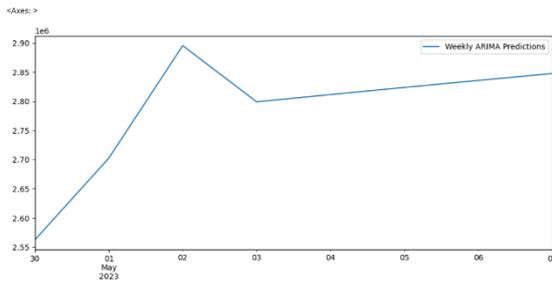
```
index_future_dates=pd.date_range(start='2023-04-30', end='2023-05-30')
#print(index_future_dates)
pred=model2.predict(start=len(df), end=len(df)+30, type='levels', rename=('Monthly ARIMA Predictions'))
#print(comp_pred)
#pred.index=index_future_dates
pred.index = index_future_dates
print(pred)

pred.plot(figsize=(12,5), legend=True)
```

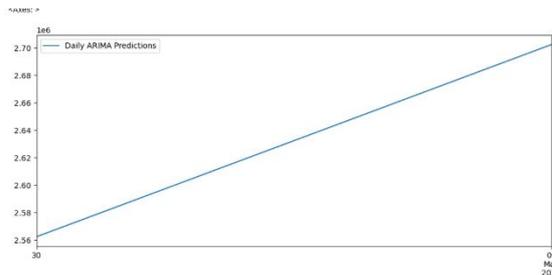
Gambar 12. Jupyter Prediksi



Gambar 13. Plot Prediksi Bulanan



Gambar 14. Plot Prediksi Mingguan



Gambar 15. Plot Prediksi Harian

Implementasi model untuk prediksi bulanan, mingguan dan harian terlampir pada Gambar 12 sampai dengan Gambar 15 Plot pada gambar di atas menunjukkan grafik prediksi tren untuk masa yang akan datang.

IV. KESIMPULAN DAN SARAN

Berdasarkan prosedur metode runtun waktu ARIMA, model yang tepat untuk memprediksi pendapatan penjualan makanan di Sate Bibali adalah model ARIMA(1,0,4). Sementara itu, hasil peramalan pendapatan penjualan makanan periode 1 Maret 2022 sampai dengan 30 April 2023 pada dua cabang gerai Sate Bibali yang berlokasi di kawasan Senopati dan Pasar Minggu dapat disajikan pada Tabel V.

TABEL V. PREDIKSI PENDAPATAN PENJUALAN SATE BIBALI MEI 2023

Tanggal	Pendapatan
4/30/2023	2562300
5/1/2023	2702451
5/2/2023	2895385
5/3/2023	2799018
5/4/2023	2811460
5/5/2023	2823698

5/6/2023	2835735
5/7/2023	2847576
5/8/2023	2859223
5/9/2023	2870680
5/10/2023	2881949
5/11/2023	2893034
5/12/2023	2903938
5/13/2023	2914663
5/14/2023	2925213
5/15/2023	2935590
5/16/2023	2945797
5/17/2023	2955838
5/18/2023	2965714
5/19/2023	2975429
5/20/2023	2984985
5/21/2023	2994384
5/22/2023	3003630
5/23/2023	3012724
5/24/2023	3021670
5/25/2023	3030469
5/26/2023	3039125
5/27/2023	3047639
5/28/2023	3056014
5/29/2023	3064251
5/30/2023	3072354

Berdasarkan Tabel V terlihat data prediksi pendapatan penjualan makanan di Sate Bibali periode Mei 2023 akan meningkat.

Penulis juga menyarankan untuk melanjutkan jenis penelitian yang lain atau dengan menggunakan metode lain seperti SARIMA dan kemudian membandingkan hasil peramalannya. Penelitian selanjutnya juga disarankan untuk menggunakan dataset dengan jangka waktu yang lebih panjang untuk meningkatkan nilai akurasi dari model yang digunakan.

V. REFERENSI

- [1] Leofitri, J., 2021. Sosial Media, Bisnis Kuliner dan Pandemi Covid-19. *PERSPEKTIF* 10, 505–514. <https://doi.org/10.31289/perspektif.v10i2.4743>
- [2] Mardiyah, I., Dianita Utami, W., Rini Novitasari, D.C., Hafiyusholeh, Moh., Sulistiyawati, D., 2021. ANALISIS PREDIKSI JUMLAH PENDUDUK DI KOTA PASURUAN MENGGUNAKAN METODE ARIMA. *BAREKENG J. Ilmu Mat. Dan Terap.* 15, 525–534. <https://doi.org/10.30598/barekengvol15iss3pp525-534>
- [3] M. A. Hasanah, S. Soim, and A. S. Handayani, “Implementasi CRISP-DM Model Menggunakan Metode Decision Tree dengan Algoritma CART untuk Prediksi Curah Hujan Berpotensi Banjir,” *J. Appl. Inform. Comput.*, vol. 5, no. 2, pp. 103–108, Oct. 2021, doi: 10.30871/jaic.v5i2.3200.
- [4] Yudistira, A., Nurkhamid, M., 2021. PENGGUNAAN DATA MINING DALAM HIT RATE IMPORTASI JALUR MERAH DENGAN MODEL DECISION TREE: USE OF DATA MINING IN HIT RATE IMPORTATION OF RED LINE WITH DECISION TREE MODEL. *J. Perspekt. BEA DAN CUKAI* 5, 187–202. <https://doi.org/10.31092/jpbc.v5i2.1297>