

## **FORECASTING KONSUMSI BARANG BARANG PADA STORAGE HOTEL DENGAN METODE AUTOREGRESSIVE INTEGRATED MOVING AVERAGE**

**Christopher Chandra<sup>1</sup>, Alfannisa Annurrullah Fajrin<sup>2</sup>**

<sup>1</sup>Mahasiswa Program Studi Teknik Informatika, Universitas Putera Batam

<sup>2</sup>Dosen Program Studi Teknik Informatika, Universitas Putera Batam

email: [pb170210005@upbatam.ac.id](mailto:pb170210005@upbatam.ac.id)

### **ABSTRACT**

*In this era, hotel has storage as a storing space for every kind of Barangs. Barangs stored in the storage are Barangs being used for the needs of the staffs, also for the needs of hotel's operational. The Barang consumption is running smoothly with resupply. However, there are often mistakes in resupplying the Barangs. For preventing those several mistakes, a reference is needed to be used for controlling the amount of Barangs arrival (monthly) with minding the amount of Barangs in the storage should be. The reference to be used is the forecast of the Barang consumption every month. Forecasting was being done with Autoregressive Integrated Moving Average (ARIMA) method. There are five steps needed to build the ARIMA model, such as plot identification, model identification, model estimation, choosing the best model, and prediction (forecast). The input variable to be used in this research is the rime series from the data of storage's Barang consumption starts from January 2018 until October 2020, and the output variable is the result of the prediction of Barang consumption in the next period.*

*Keywords: Resupply, ARIMA, forecast, consumption, Python.*

### **PENADAHULUAN**

*Storage* bukanlah sebuah fasilitas yang bisa terlepas dari kegiatan operasional dalam sebuah perusahaan. Pada masa ini, hotel memiliki *storage* sebagai sebuah ruangan yang digunakan untuk Penyimpanan berbagai macam barang, baik barang pangan maupun non pangan. Kegiatan operasional pada *storage* sangat mempengaruhi operasional perusahaan tersebut, baik pada kinerja dan kebutuhan karyawan sehari-hari, maupun Pengunjung.

Permasalahan umum yang dapat terjadi pada *storage* perhotelan adalah kekurangan maupun atau kehabisan

*stock* barang secara mendadak, dan yang terburuk adalah ketidakyakinan dalam menambah *stock* (*resupply*) saat menerima kabar dari *supplier* bahwa *stock* barang yang ingin dipesan oleh *storage* tersebut jumlahnya kurang ataupun kosong, dan bahkan bisa juga karena keterbatasan anggaran yang dimiliki oleh perusahaan. Walaupun mengetahui jumlah kebutuhan karyawan secara konstan, petugas *storage* Hotel Pacific Palace tidak bisa mengetahui secara langsung kebutuhan para pengunjung, dikarenakan jumlah pengunjung hotel yang berubah sewaktu-waktu, dan bahkan jumlah event yang

diadakan di hotel tersebut. Sebagai tambahan, salah satu faktor yang menyebabkan ketidak yakinan *resupply* pada storage Hotel Pacific Palace adalah dilakukan secara berlebih atau tidak terkontrol terhadap barang yang mungkin memiliki tingkat konsumsi rendah atau tingkat konsumsi yang tidak berubah terlalu signifikan, maupun terhadap barang yang kurang diperhatikan tanggal kedaluarsanya, sehingga mengakibatkan kekurangan anggaran dalam melakukan *resupply*. Oleh karena itu, perlu dilakukan tindakan preventif dengan *resupply* dini untuk mencegah terjadinya permasalahan-permasalahan tersebut.

Tindakan tersebut dapat didukung dengan prediksi terhadap tingkat konsumsi barang tertentu dengan bantuan Penagolahan data konsumsi kurun waktu lampau yang telah tercatat sebelumnya. Prediksi yang biasanya dilakukan setiap perusahaan adalah prediksi secara periodik, baik tahunan, bulanan, mingguan, maupun harian. Untuk permasalahan dalam melakukan *resupply*, dapat dilakukan prediksi bulanan, yaitu melalui Penagolahan data konsumsi yang dibuat dalam bentuk periode bulanan. Hal terPenating dalam melakukan prediksi adalah jangan sampai memicu perusahaan tersebut untuk mengambil keputusan yang salah apabila hasil prediksi yang diperoleh memiliki nilai error yang besar. Penagolahan data tersebut dapat dilakukan dengan mengaplikasikan berbagai metode, salah satunya adalah *Autoregressive Integrated Moving Average* (ARIMA). ARIMA adalah salah satu dari metode yang sangat baik digunakan dalam menghasilkan prediksi jangka Penadek yang akurat, tetapi tidak untuk prediksi jangka panjang.

Peneliti kembali menegaskan permasalahan yang telah disampaikan sebelumnya, bahwa jika tidak dilakukan antisipasi pada saat *resupply*, maka kegiatan operasional hotel tentunya akan menghadapi hambatan.

### KAJIAN TEORI (Arial 11, Bold, Center, Spasi 1", UPPERCASE)

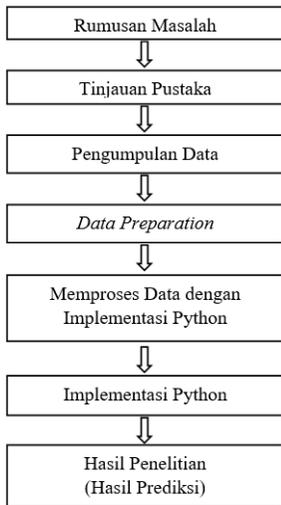
#### 2.1 Autoregressive Integrated Moving Average (ARIMA)

Autoregressive Integrated Moving Average, disingkat dengan ARIMA adalah salah satu algoritma prediksi berdasarkan sebuah ide bahwa informasi mengenai nilai-nilai pada masa lalu yang terdapat dalam deret waktu itu sendiri dapat digunakan untuk memprediksi nilai-nilai pada masa depan. ARIMA juga merupakan sebuah kelas dari model yang menjelaskan sebuah deret waktu berdasarkan nilai-nilai pada masa lalu, yaitu lagnya maupun residual (error) prediksi tersebut, sehingga dapat digunakan persamaan untuk memprediksi nilai-nilai pada masa depan (Prabhakaran, 2019a).

Model ARIMA dikembangkan oleh George Box dan Gwilym Jenkins pada tahun 1970, sehingga model ini juga dikenal dengan Box-Jenkins. Model ini menggambarkan data deret waktu yang bersifat stasioner. Langkah awal yang harus dilakukan sebelum menentukan model ARIMA yang sesuai adalah mengidentifikasi kestasioneran pada mean dan varians data yang digunakan. Jika keduanya tidak stasioner, maka perlu dilakukan pembedaan (diferensiasi) pada mean dan transformasi pada varians terlebih dahulu (Halim, 2006).

#### 2.2 Deret Waktu





**Gambar 1.** Desain Penelitian (Sumber : Data Penelitian, 2020)

**1. Rumusan Masalah**

Merumuskan beberapa masalah yang terdapat pada latar belakang mengenai permasalahan yang terjadi pada saat melakukan resupply pada storage hotel.

**2. Tinjauan Pustaka**

Menelusuri berbagai sumber referensi yang relevan dengan Penelitian yang dilakukan.

**3. Pengumpulan Data**

Memperoleh data beserta informasi yang mendukung Penelitian melalui data konsumsi storage Hotel Pacific Palace Januari 2019 hingga Oktober 2020, juga melalui wawancara secara langsung terhadap Store Manager hotel dengan mengikuti protokol kesehatan.

**4. Data Preparation**

Data dan informasi yang telah diperoleh dipersiapkan terlebih dahulu, apakah data tersebut sudah lengkap, apa yang harus dilakukan jika terdapat data yang kurang lengkap.

**5. Memproses Data dengan Machine Learning Metode ARIMA**

Setelah persiapan data dilakukan, data akan diproses dengan Machine Learning prediksi metode ARIMA.

**6. Implementasi Python**

Implementasi ARIMA dalam pemrosesan data dilakukan dengan bantuan bahasa pemrograman Python, yaitu dengan menggunakan beberapa package yang relevan dalam proses ARIMA. Setelah data selesai diproses, akan dianalisa kembali hasilnya untuk memilih model ARIMA yang cocok terhadap hasil prediksi berdasarkan nilai errornya ataupun keakuratannya.

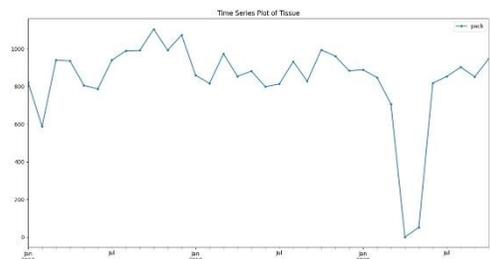
**7. Hasil Penelitian (Hasil Prediksi)**

Hasil prediksi yang diperoleh dapat digunakan sebagai referensi dalam melakukan resupply pada storage untuk ke depannya.

**HASIL DAN PEMBAHASAN**

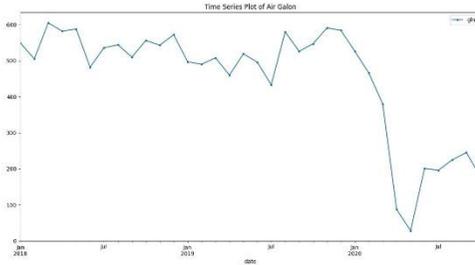
**3.1 Identifikasi Model**

Diambil tingkat konsumsi 5 barang tertinggi dari 14 barang-barang yang digunakan dalam operasional kantor di hotel, yang dimulai dari bulan Januari 2018 hingga Oktober 2020. Tingkat konsumsi tertinggi diambil dari total konsumsi tiap barang selama 34 bulan, angka konsumsi tertinggi di antara 34 bulan tersebut, dan rata-rata konsumsi per-bulannya dibantu dengan Microsoft Excel dengan menggunakan fungsi *Sum*, *Max*, dan *Average*.



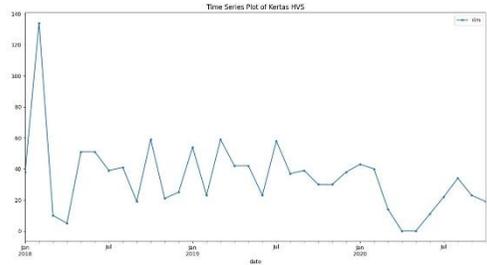
**Gambar 2.** Plot Data Konsumsi Tissue

(Sumber : Data Penelitian, 2020)

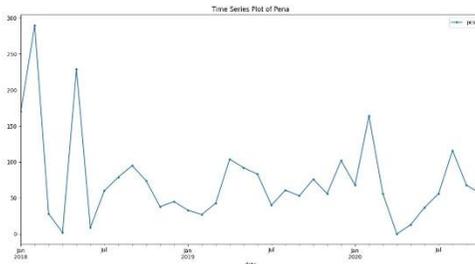


**Gambar 3.** Plot Data Konsumsi Air Galon  
(Sumber : Data Penelitian, 2020)

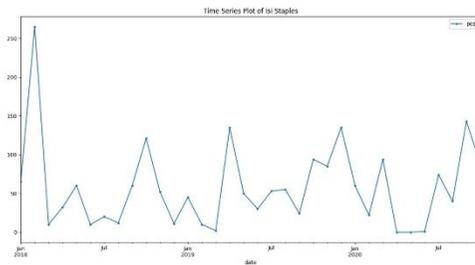
(Sumber : Data Penelitian, 2020)



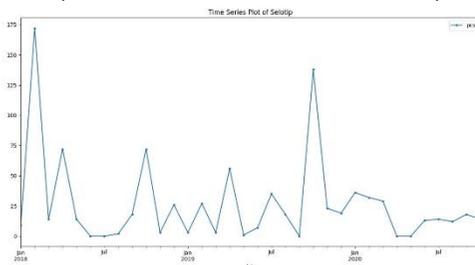
**Gambar 7.** Plot Data Konsumsi Tissue  
(Sumber : Data Penelitian, 2020)



**Gambar 4.** Plot Data Konsumsi Pena  
(Sumber : Data Penelitian, 2020)



**Gambar 5.** Plot Data Konsumsi Isi Staples  
(Sumber : Data Penelitian, 2020)



**Gambar 6.** Plot Data Konsumsi Tissue

Pada plot dari keenam barang tersebut, terdapat Penaurunan tingkat konsumsi dimulai pada bulan maret, hingga mencapai angka 0 pada bulan April 2020 dan Mei 2020. Penaurunan tersebut disebabkan oleh hotel mengalami keadaan bisnis yang tidak baik yang disebabkan oleh pandemi COVID-19, sehingga jumlah Pengunjung hotel yang berkurang berdampak pada kegiatan administrasi di kantor hotel tersebut, juga terjadi Penagurangan jumlah karyawan yang bekerja di sana. Karena keadaan bisnis hotel yang semakin menurun, maka Hotel Pacific Palace memutuskan untuk menghentikan kegiatan operasionalnya sementara dimulai pada bulan April 2020.

### 3.2 Stasioneritas Data

Semua plot yang telah dibuat dari data deret waktu konsumsi 6 barang tersebut perlu diidentifikasi stasioneritasnya sebelum melanjutkan proses analisis deret waktu lebih lanjut. Jika terdapat plot yang belum stasioner, perlu dilakukan diferensiasi terlebih dahulu. Selain melihat pola dari plot secara langsung, identifikasi stasioneritas dapat dilakukan dengan tes *Augmented Dickey Fuller* (ADF), yang berasal dari package *statsmodels* pada Python. Hipotesis nol ( $h_0$ ) dari tes ADF adalah deret waktu tersebut bersifat non-stasioner. Jika nilai p yang didapatkan dari

tes adalah lebih rendah dari level signifikan (0,05), maka  $h_0$  ditolak dan dapat

disimpulkan bahwa deret waktu tersebut sudah stasioner.

**Tabel 1. Tes ADF**

No.	Product	ADF Statistic	Nilai P
1	TISSUE	-3,371168	0,011982
2	AIR GALON	-1,020827	0,745593
3	PENAA	-3,824425	0,002667
4	ISI STAPLES	-5,510485	0,000002
5	SELOTIP	-6,590583	0
6	KERTAS HVS	-5,462222	0,000003

(Sumber : Data Penelitian, 2020)

Dari tabel tersebut, dapat disimpulkan bahwa deret waktu yang memerlukan diferensiasi adalah deret waktu dari air galon. Seperti pada yang telah dijelaskan pada bab 2, cara kerja diferensiasi adalah dengan mencari selisih dari observasi yang dikalkulasikan secara matematis untuk membentuk deret waktu yang baru, dan secara umum diferensiasi dilakukan maksimal dua kali. Namun walaupun deret kelima barang lainnya sudah stasioner, masih diperlukan untuk dilakukan diferensiasi karena orde pada AR (p) dan MA (q) yang didapatkan secara berturut-turut dari plot data asli adalah 0 dan 0, sehingga parameter model prediksi menjadi (0, 0). Parameter tersebut tidak bisa digunakan untuk membangun model prediksi.

Orde diferensiasi yang ideal adalah jumlah diferensiasi minimum yang diperlukan untuk memperoleh deret yang mendekati stasioner, di mana plot autokorelasi mencapai angka nol dengan cepat. Jika pada autokorelasi terdapat nilai positif pada jumlah lag yang banyak, maka

deret tersebut perlu dilakukan diferensiasi lebih lanjut. Tetapi jika lag pertama autokorelasi tersebut bernilai negatif yang sangat besar maka deret tersebut terdiferensiasi secara berlebihan. Penentuan pada orde diferensiasi juga dapat dilakukan dengan tes ADF terhadap deret yang terdiferensiasi, di mana jika nilai p (p-value) di bawah level signifikan (0,05) maka deret terdiferensiasi tersebut sudah stasioner. Salah satu contoh Penelitian yang melandasi cara tersebut adalah Penelitian yang dilakukan oleh As'ad dkk. (2017), di mana dalam Penelitian tersebut juga dilakukan tes ADF terhadap deret terdiferensiasi, hingga mendapatkan orde diferensiasi yaitu 3, dengan nilai p pada masing-masing deret diferensiasi 1, 2 dan 3 secara berturut-turut adalah 0,4427, 0,06441, dan 0,04239.

**Tabel 2.** Nilai Lag 1 ACF

**Tabel 2(a).**

Barang	Nilai Lag 1 ACF
Tissue	0,5518278

**Tabel 2(b).**

Barang	Nilai Lag 1 ACF	
	Diferensiasi 1	Diferensiasi 2
Air Galon	-0,01022753	-0,43086099
Pena	-0,4484332	-0,52482728
Isi Staples	-0,47857533	-0,51130662
Selotip	-0,60250095	-0,63886256
Kertas HVS	-0,4688342	-0,46373431

(Sumber : Data Penelitian, 2020)

**Tabel 3.** Nilai P (Tes ADF) pada Deret Terdiferensiasi

Barang	Nilai P	
	Diferensiasi 1	Diferensiasi 2
Air Galon	0.000002	Air Galon
Pena	0.000081	Pena
Isi Staples	0	Isi Staples
Selotip	0	Selotip
Kertas HVS	0	Kertas HVS

(Sumber : Data Penelitian, 2020)

Berikut ini adalah tabel mengenai ordo diferensiasi yang mungkin dari kelima deret yang telah dievaluasi :

**Tabel 4.** Orde Diferensiasi yang Mungkin

Barang	Orde Diferensiasi (d)
Air Galon	1 and 2

Pena	1
Isi Staples	1 and 2
Selotip	1 and 2
Kertas HVS	1 and 2

(Sumber : Data Penelitian, 2020)

3.3 Fungsi Autokorelasi dan Fungsi Autokorelasi Parsial untuk Identifikasi Model (Orde (p) dan (q))  
Menentukan orde pada AR (p) dan MA (q) secara berturut-turut dilakukan dengan

mengidentifikasi lag yang signifikan, di mana memiliki nilai yang berada di luar daerah arsiran (tidak melewati batas signifikan) pada plot autokorelasi parsial dan autokorelasi. Jika nilai pada lag tersebut berada di luar daerah arsiran, maka dapat dikatakan bahwa lag tersebut sudah signifikan.

**Tabel 5.** Orde AR dan MA yang Mungkin  
**Tabel 5(a).**

Barang	PACF (p)	ACF (d)
Tissue	0 and 1	0

(Sumber : Data Penelitian, 2020)

**Tabel 5(b).**

Barang	Diferensiasi 1		Diferensiasi 2	
	PACF (p)	ACF (d)	PACF (p)	ACF (d)
Air Galon	0	0	0, 1 and 2	0 and 1
Pena	0, 1 and 2	0 and 1	0, 1 and 2	0 and 1
Isi Staples	0 and 1	0 and 1	-	-
Selotip	0 and 1	0 and 1	0, 1 and 2	0 and 1
Kertas HVS	0, 1 and 2	0 and 1	0, 1 and 2	0 and 1

(Sumber : Data Penelitian, 2020)

Berdasarkan hasil evaluasi dari diferensiasi, autokorelasi dan autokorelasi parsial, maka beberapa parameter yang

mungkin dapat digunakan untuk model ARIMA

Terdapat parameter ARIMA pada Pena (1, 2, 1), namun parameter tersebut tidak bisa digunakan untuk model ARIMA karena adanya sebuah *error* pada saat memproses ARIMA *Summary* (pada Python) dengan parameter itu sendiri,

Hasil prediksi di atas dapat diimplementasikan pada kegiatan *resupply* barang di *storage* Hotel Pacific Palace. Jumlah barang yang tersisa pada saat itu harus diketahui terlebih dahulu. Jadi, untuk menghitung jumlah barang yang dibutuhkan untuk *resupply*, dapat dilakukan dengan mengurangi jumlah

### SIMPULAN

Dari parameter model yang telah diperoleh, dapat diasumsikan bahwa terdapat 3 model prediksi, yang terdiri dari sebuah model MA (*Moving Average*) (untuk tissue (0, 1)), 4 model IMA (*Integrated Moving Average*) (untuk air galon (0, 2, 1); isi staples (0, 1, 1); selotip (0, 1, 1), and kertas HVS (0, 1, 1)) and sebuah ARIMA model (untuk Penaa (2, 2, 1)).

Pemrosesan ARIMA dengan Python menggunakan beberapa package yang biasanya digunakan secara umum, yaitu *pandas*, *matplotlib* dan *statsmodels*, kemudian ditambahkan beberapa package lainnya sebagai pelengkap agar kinerja pemrosesan dapat berjalan.

Penagelolaan terhadap *resupplying* barang dapat dilakukan dengan

yang berbunyi : “*The computed initial MA coefficients are not invertible You should induce invertibility, choose a different model order, or you can pass your own start\_params.*”

barang yang didapatkan dari hasil prediksi dengan jumlah barang yang tersisa pada saat itu. Prediksi ini dilakukan sebagai bentuk aplikasi terhadap fungsi *economic lot sizing* (meminimalisir Penaggunaan biaya per unit) dan fungsi persediaan antisipasi (mempersiapkan persediaan musiman).

menghitung jumlah barang yang harus masuk pada saat itu (bulan tersebut).

Metode ARIMA adalah sebuah metode prediksi, namun tidak cocok untuk membuat prediksi jangka Panjang. Sebagai contoh, ketika Penaeliti memproses prediksi untuk beberapa bulan ke depan, terdapat hasil prediksi yang bernilai negatif. Penaeliti menyarankan agar proses ARIMA diulang kembali saat *update* terhadap data konsumsi barang telah dilakukan.

### DAFTAR PUSTAKA

- Adriyan. (2019). *Instalasi Python 3 dan IDE atau Anaconda Distribution pada Windows 10*. DQLab.
- As'ad, M., Wibowo, S. S., & Sophia, E. (2017). PERAMALAN JUMLAH MAHASISWA BARU DENGAN MODEL AUTOREGRESSIVE

INTEGRATED MOVING AVERAGE (ARIMA). *JIMP - Jurnal Informatika Merdeka Pasuruan*, 2, 20–33.

Halim, S. (2006). *Diktat - Time Series Analysis Prakata* (Issue January). Universitas Kristen Petra.

Handoko, T. H. (1999). *Dasar-dasar manajemen produksi dan operasi* (Edisi 1). BPFF UGM.

Indah, D. R., Purwasih, L., & Maulida, Z. (2018). Pengendalian Persediaan Bahan Baku pada PT. Aceh Rubber Industries Kabupaten Aceh Tamiang. *JURNAL MANAJEMEN DAN KEUANGAN*, 7.

Lahu, E. P., & Sumarauw, J. S. . (2017). ANALISIS PENGENDALIAN PERSEDIAAN BAHAN BAKU GUNA MEMINIMALKAN BIAYA PERSEDIAAN PADA DUNKIN DONUTS MANADO. *Jurnal EMBA*, 5.

Prabhakaran, S. (2019a). *ARIMA Model – Complete Guide to Time Series Forecasting in Python*.  
<https://www.machinelearningplus.com/time-series/arima-model-time-series-forecasting-python/>

Prabhakaran, S. (2019b). *Time Series Analysis in Python – A Comprehensive Guide with Examples*.  
<https://www.machinelearningplus.com/time-series/time-series-analysis-python/>

Sudaryono. (2015). *Metodologi Riset di Bidang TI*. Penerbit ANDI.

Sugiyono. (2012). *METODE PENELITIAN KUANTITATIF KUALITATIF DAN R&D* (Cetakan Ke). Penerbit Alfabeta.

Wanto, K. (2016). *ANALISIS INTERVENSI DATA DERET WAKTU UNTUK PERAMALAN PENDAPATAN DOMESTIK*

**BRUTO INDONESIA.**  
**UNIVERSITAS NEGERI JAKARTA.**



**Biodata,**  
Penulis pertama, Christopher Chandra, merupakan mahasiswa Prodi Teknik Informatika Universitas Putera Batam.



**Biodata,**  
Penulis kedua, Alfannisa Annurrullah Fajrin, S.Kom., M.Kom., merupakan Dosen Prodi Teknik Informatika Universitas Putera Batam. Penulis banyak berkecimpung di bidang Artificial Intelligence.