

# ANALISIS DERET WAKTU UNIVARIAT

Teori dan Pengolahan Data

Analisis deret waktu merupakan analisis statistika yang digunakan untuk mengolah data observasi atau data amatan yang berbentuk urutan waktu (*sequential*). Data observasi dalam deret waktu berbeda dengan data observasi dalam analisis *cross section*. Jika dalam data *cross section* yang biasanya dianalisis dengan metode regresi, observasi satu dengan observasi lain harus independent atau saling bebas. Hal yang berbeda terjadi pada data deret waktu. Observasi yang berbentuk runtun waktu, antara satu amatan dengan amatan yang lain saling terkait atau memiliki korelasi.

Teknik peramalan atau dikenal dengan *forecasting analysis* merupakan metode statistika yang digunakan untuk pertimbangan dalam pengambilan keputusan berdasarkan hasil prediksi. Dalam bidang industri, teknik peramalan erat kaitannya dengan analisis inventori dan *supply chain*. Hasil peramalan ini digunakan untuk memprediksi *demand* atau permintaan, walaupun tidak semua *demand* dapat diprediksi dengan baik (*predictable*).

Teknik peramalan yang digunakan dapat disesuaikan dengan pola dari data. Pola dari suatu data historis antara lain memiliki pola konstan, pola musiman, dan pola *trend*. Metode peramalan yang dibahas dalam buku ini meliputi model Moving Average, Eksponensial Smoothing, model Dekomposisi, model ARIMA, model Holt-Winter, dan model SARIMA.

Halwa Annisa Khoiri, S.Si., M.Si.



# ANALISIS DERET WAKTU UNIVARIAT

Teori dan Pengolahan Data

Halwa Annisa Khoiri, S.Si., M.Si.



# ANALISIS DERET WAKTU UNIVARIAT

**Penulis:**

**Halwa Annisa Khoiri, S.Si.,M.Si**

**Editor, Perancang Sampul & Penata Letak:**

**Chintya Pralampita Hendrastati, S.T.**

Cetakan Pertama, Desember 2023

Diterbitkan Oleh:

**UNIPMA PRESS**

**Universitas PGRI Madiun**

Jalan Setiabudi No.85 Madiun Jawa Timur 63118

Telp. (0351) 462986, Fax. (0351) 459400

E-mail: [upress@unipma.ac.id](mailto:upress@unipma.ac.id)

**ISBN: 978-623-8095-53-8**

**Link:** <https://kww.unipma.ac.id/buku/1823/analisis-deret-waktu-univariat-teori-dan-pengolahan-data>

# Kata Pengantar



Puji syukur kehadiran Allah SWT atas rahmat dan karunia-Nya sehingga buku yang berjudul “Analisis Deret Waktu Univariat (Teori dan Pengolahan Data)” dapat terselesaikan dengan baik. Buku ini berisi tentang teori-teori dalam peramalan data sekaligus dilengkapi dengan penggunaan Minitab untuk membantu dalam peramalan. Buku ini dibuat sebagai salah satu referensi buku belajar mahasiswa dalam mata kuliah Teknik Peramalan sehingga dapat meningkatkan kemampuan mahasiswa dalam menentukan metode peramalan yang sesuai dengan data.

Harapan dari penulis semoga buku ini dapat memberikan manfaat. Penulis menyadari bahwa dalam pembuatan buku ini masih banyak kesalahan dan kekurangan. Saran dan kritik dari pembaca sangat penulis harapkan demi penyempurnaan karya selanjutnya.

**Salam,**

**Penulis**

# Daftar Isi

Halaman Sampul	
Lembar ISBN	i
Kata Pengantar	ii
Daftar Isi	iii
Daftar Tabel	vi
Daftar Gambar	vii
1. Pengantar Analisis Deret dan Waktu	1
1.1 Definisi Analisis Deret Waktu	3
1.2 Klasifikasi Analisis Deret Waktu	6
1.3 Latihan Soal	8
2. Teknik Peramalan	9
2.1 Definisi dan Manfaat Teknik Peramalan	11
2.2 Pola Data dalam Peramalan	13
2.3 Penggambaran Pola Data dengan Microsoft Excel	16
2.4 Penggambaran Pola Data dengan Minitab	18
2.5 Latihan Soal	21
3. Metode Peramalan Berdasarkan Data Historis	23
3.1 Metode Moving Average	27
3.2 Metode Exponential Smoothing	28
3.3 Pengolahan Data dengan Minitab	33
3.4 Latihan Soal	38





# Daftar Isi

4 . Metode Autoregressive Integrated Moving Average	41
4.1 Pengenalan Metode ARIMA	43
4.2 Stasioneritas Data	46
4.3 Autokorelasi dalam ARIMA	47
4.4 Persamaan Matematis Model ARIMA	49
4.5 Langkah-Langkah Analisis dalam Model ARIMA	53
4.6 Pengujian Model ARIMA	55
4.7 Perhitungan Nilai Error dari Model ARIMA	56
4.8 Analisis Data ARIMA dengan Minitab	57
4.9 Latihan Soal	71
5. Performansi dalam Peramalan	73
5.1 Error dalam Peramalan	75
5.2 Akurasi dalam Peramalan	77
5.3 Pengolahan Data dengan Ms. Excel	80
5.4 Latihan Soal	85
6. Metode Peramalan Seasonal	89
6.1 Metode Dekomposisi	91
6.2 Metode Seasonal – ARIMA (SARIMA)	93
6.3 Metode Holt – Winter	97
6.4 Pengolahan Data dengan Minitab	101
6.5 Latihan Soal	127



# Daftar Isi

7. Peran Peramalan dalam Perencanaan Produksi	131
7.1 Peranan Peramalan dalam Proses Produksi	133
7.2 Peramalan dalam Material Requirement Planning (MRP)	138
Daftar Pustaka	
Lampiran 1	
Lampiran 2	




# Daftar Tabel

Tabel 2.1	Contoh Data untuk Pola Data	16
Tabel 4.1	Kelebihan dan Kekurangan Metode ARIMA	44
Tabel 4.2	Sifat-sifat ACF dan PACF pada Model ARIMA	48
Tabel 5.1	Intepretasi Nilai MAPE terhadap Hasil Peramalan	80
Tabel 5.2	Contoh Data Permintaan	81
Tabel 5.3	Data Perhitungan MSE	81
Tabel 5.4	Data Perhitungan MAD	82
Tabel 5.5	Data Perhitungan MAPE	83
Tabel 5.6	Perbandingan Ukuran Error untuk Beberapa Model Peramalan	83
Tabel 6.1	Perbandingan Model Peramalan untuk Data Musiman	100

# Daftar Gambar

Gambar 1.1	Grafik Perubahan IHSG	7
Gambar 2.1	Contoh Pola Data Permintaan Produk	12
Gambar 2.2	Contoh Pola Data Konstan	14
Gambar 2.3	Contoh Pola Data Trend	14
Gambar 2.4	Contoh Pola Data Seasonal	15
Gambar 2.5	Contoh Pola Data Intermittent	15
Gambar 2.6	Tampilan Menu Insert Chart	16
Gambar 2.7	Tampilan Grafik yang Belum Sesuai	17
Gambar 2.8	Tampilan Menu Select Data	17
Gambar 2.9	Tampilan Akhir Grafik	18
Gambar 2.10	Tampilan Worksheet Minitab untuk Input Data	18
Gambar 2.11	Kotak Dialog Time Series Plot	19
Gambar 2.12	Memasukkan Variabel yang Akan Digambar	19
Gambar 2.13	Plot Grafik dengan Minitab	20
Gambar 3.1	Bagan Hubungan Data Historis Model Peramalan	25
Gambar 3.2	Alur dalam menentukan model peramalan	26
Gambar 4.1	Pola Data Time Series	46
Gambar 4.2	Pola ACF dan PACF	48
Gambar 5.1	Contoh Plot Data Aktual dan Data Peramalan	75
Gambar 5.2	Ilustrasi Ketepatan Data Peramalan	78
Gambar 6.1	Plot Data Seasonal Multiplicative Factors	92
Gambar 6.2	Plot Data Seasonal Additive Factors	93
Gambar 6.3	Flowchart untuk Model SARIMA	96



# **PENGANTAR ANALISIS DERET WAKTU**







## Tujuan Instruksional

1. Mahasiswa memahami pengertian dari analisis deret waktu.
2. Mahasiswa dapat menerapkan analisis deret waktu untuk analisis data dan menarik kesimpulan.
3. Mahasiswa dapat memahami jenis data yang dapat digunakan dalam analisis deret waktu.



### 1.1 DEFINISI ANALISIS DERET WAKTU

Analisis deret waktu merupakan analisis statistika yang digunakan untuk mengolah data observasi atau data amatan yang berbentuk urutan waktu (*sequential*). Data observasi dalam deret waktu berbeda dengan data observasi dalam analisis *cross section*. Jika dalam data *cross section* yang biasanya dianalisis dengan metode regresi, observasi satu dengan observasi lain harus independent atau saling bebas. Hal yang berbeda terjadi pada data deret waktu. Observasi yang berbentuk runtun waktu, antara satu amatan dengan amatan yang lain saling terkait atau memiliki korelasi.



Observasi pertama akan memiliki tingkat korelasi yang tinggi dengan observasi kedua, dan tingkat korelasinya akan semakin menurun terhadap observasi ketiga, keempat, dan seterusnya. Karena observasi deret waktu ini tidak independen, maka diperlukan metode statistika yang sesuai untuk menganalisis data ini.

Analisis deret waktu dikenal juga sebagai analisis time series. Analisis ini biasa digunakan untuk meramalkan data observasi pada periode selanjutnya. Karena antara satu observasi dengan observasi lainnya saling berkorelasi, maka untuk peramalan data sangat dipengaruhi oleh semua data observasi. Tujuan dari analisis deret waktu adalah sebagai berikut.



Analisis deret waktu dikenal juga sebagai analisis *time series*. Analisis ini biasa digunakan untuk meramalkan data observasi pada periode selanjutnya. Karena antara satu observasi dengan observasi lainnya saling berkorelasi, maka untuk peramalan data sangat dipengaruhi oleh semua data observasi.

Tujuan dari analisis deret waktu adalah sebagai berikut.



## **1** **Prediksi**

Prediksi digunakan untuk mendapatkan informasi mengenai nilai prediksi dari observasi di masa yang akan datang berdasarkan nilai observasi saat ini. Contohnya adalah melihat harga emas enam bulan ke depan berdasarkan data tiga tahun terakhir.

## **2** **Pemodelan**

Analisis deret waktu digunakan untuk mendapatkan model stokastik yang sesuai dari suatu kejadian. Contohnya mendapatkan model dari penjualan produk kosmetik, sehingga model ini dapat digunakan untuk mengevaluasi bagaimana minat pasar terhadap produk ini.

## **3** **Penggambaran**

Analisis deret waktu digunakan untuk menggambarkan atau mendeskripsikan suatu kejadian. Contohnya menganalisis harga saham saat pandemi Covid-19 untuk memberikan gambaran apakah menguntungkan jika mengambil investasi saat itu

## **4** **Pengekstrakan informasi**

Data yang dianalisis berdasarkan deret waktu memberikan banyak informasi. Penarikan informasi ini dapat disesuaikan dengan kebutuhan dari analisis. Contohnya data produksi suatu barang dapat digunakan untuk melihat *trend* produksi maupun melihat bagaimana kebutuhan bahan baku di periode selanjutnya.



## 1.2 KLASIFIKASI ANALISIS DERET WAKTU

Dalam analisis deret waktu, terdapat beberapa klasifikasi data yaitu sebagai berikut.

### **a. Ditinjau dari sisi domain**

Berdasarkan domainnya, deret waktu dibedakan menjadi dua yaitu domain waktu dan domain frekuensi. Deret waktu yang memiliki domain waktu artinya data berasal dari proses yang diamati dari waktu ke waktu. Analisis yang digunakan banyak melibatkan istilah auto korelasi, auto kovarians, dan auto regresif.

Deret waktu dengan domain frekuensi artinya data deret waktu merupakan akibat dari adanya komponen siklus yang memiliki frekuensi berbeda.

### **b. Deret waktu kontinu dan diskrit**

Deret waktu kontinu dan diskrit memiliki perbedaan pada pencacatan observasi. Deret waktu kontinu dicatat sepanjang waktu, misalkan data hasil rekaman EEG seorang pasien yang menggambarkan gelombang pada otak pasien. Sedangkan deret waktu diskrit dicatat dalam interval waktu tertentu misalkan per jam. Contohnya adalah data jumlah antrian nasabah di bank dalam lima jam terakhir yang dicatat setiap jam.

### **c. Deret waktu stasioner dan non stasioner**

Deret waktu stasioner dan non stasioner dapat dilihat berdasarkan plot datanya. Data deret waktu stasioner memiliki pola data yang teratur sepanjang waktu, sedangkan data deret waktu non stasioner memiliki data yang berubah ubah sepanjang waktu.

Beberapa contoh data deret waktu antara lain data analisis pergerakan IHSG yang digambarkan dalam Gambar 1.1. Data pergerakan IHSG merupakan contoh dari domain waktu yang kontinu. Untuk stasioneritas dari data IHSG akan menyesuaikan bagaimana kondisi yang terjadi. Data IHSG tidak stasioner apabila ada kejadian luar biasa, misalkan wabah penyakit atau adanya isu politik seperti pemilihan presiden.



**Gambar 1.1** Grafik Perubahan IHSG



# LATIHAN SOAL

1. Berikan contoh studi kasus penerapan analisis deret waktu di bidang industri.

---

---

---

---

---

2. Berikan contoh tujuan analisis deret waktu sebagai alat untuk prediksi.

---

---

---

---

---

3. Carilah suatu grafik yang menggambarkan analisis deret waktu. Berikan penjelasan mengenai domain dan stasioneritas dari grafik.

---


---

---

---

---





# TEKNIK PERAMALAN



## Tujuan Instruksional

1. Mahasiswa memahami teori dasar teknik peramalan.
2. Mahasiswa dapat menginterpretasikan pola data pada peramalan.
3. Mahasiswa dapat menentukan jenis data berdasarkan pola data yang terlihat



### 2.1 DEFINISI DAN MANFAAT TEKNIK PERAMALAN

Teknik peramalan atau dikenal dengan *forecasting analysis* merupakan metode statistika yang digunakan untuk pertimbangan dalam pengambilan keputusan berdasarkan hasil prediksi. Dalam bidang industri, teknik peramalan erat kaitannya dengan analisis inventori dan *supply chain*. Hasil peramalan ini digunakan untuk memprediksi *demand* atau permintaan, walaupun tidak semua demand dapat diprediksi dengan baik (*predictable*).




Salah satu hal yang menjadi ukuran apakah metode peramalan yang digunakan sudah tepat adalah dari akurasi peramalan atau selisih data histori dengan data hasil peramalan. Perbedaan pola data dan kejadian yang menyertai menjadi penyebab model peramalan tidak dapat digunakan dalam jangka waktu yang lama.



**Gambar 2.1** Contoh Pola Data Permintaan Produk  
(Data diambil dari buku Statistical methods for forecasting)

Grafik pada Gambar 2.1 merupakan plot data penjualan obat oleh Perusahaan Lydia E. Pinkham. Puncak penjualan berada pada antara tahun 1920 sampai dengan 1930, namun setelah tahun 1930 terjadi penurunan penjualan. Untuk menghentikan penurunan penjualan, pihak manajemen mengubah metode promosi yang semula menggunakan media koran menjadi promosi dengan menggunakan radio. Strategi ini cukup berhasil karena setelah tahun 1937 penjualan kembali naik.



Pada tahun 1940 muncul perusahaan kompetitor yang menjual produk sejenis, sehingga berakibat pada penurunan penjualan. Berdasarkan studi kasus ini dapat diambil kesimpulan bahwa metode peramalan tidak dapat digunakan dalam jangka waktu yang panjang karena banyak hal yang mempengaruhi pola data. Metode peramalan A akan cocok digunakan untuk periode tertentu, namun pada periode selanjutnya bisa saja metode tersebut sudah tidak dapat digunakan.




## 2.2 POLA DATA DALAM PERAMALAN

Dalam peramalan terdapat beberapa jenis pola data. Pola data yang terbentuk bergantung pada pola data historisnya. Ada beberapa jenis pola data yang sulit untuk diprediksi dan ada beberapa pola data yang mudah untuk diprediksi. Tantangan utama dalam peramalan adalah menentukan model yang tepat untuk memprediksi data di waktu yang akan datang.

Perbedaan pola data ini akan berakibat pada pemilihan metode peramalan yang sesuai. Dalam metode peramalan secara umum dibagi menjadi tiga kelompok yaitu metode kuantitatif, metode kualitatif, dan metode kausal. Pola data yang bermacam-macam, tidak menutup kemungkinan menggabungkan dua metode untuk mendapatkan hasil peramalan yang paling baik. Metode peramalan kuantitatif didekati dengan model *time series* berdasarkan pada data historis. Metode ini sangat bergantung pada jenis data historis yang dimiliki. Metode kualitatif merupakan metode peramalan berdasarkan *judgement* atau pendapat dari orang yang dianggap ahli di suatu bidang. Metode peramalan kualitatif contohnya digunakan dalam meramalkan bagaimana hasil penjualan produk yang baru saja diluncurkan karena tidak ada data historis yang dimiliki. Metode peramalan yang ketiga adalah metode kausal. Metode kausal ini dapat digunakan untuk mengetahui faktor-faktor yang berpengaruh, misalkan faktor yang berpengaruh terhadap penjualan. Faktor yang berpengaruh terhadap penjualan ada dua yaitu faktor eksternal (kompetitor, perubahan dalam lingkungan bisnis, bencana alam) dan faktor internal (promosi, produk baru, jaringan penjualan baru). Dengan menggunakan metode kausal dapat diketahui faktor manakah yang secara signifikan berpengaruh terhadap penjualan.

Berikut ini adalah beberapa jenis pola data yang terbentuk berdasarkan data historisnya.


a. Pola Data Konstan



**Gambar 2.2** Pola Data Konstan

Pola data konstan artinya data historis memiliki nilai yang hampir sama untuk setiap periode. Contoh dari pola data konstan adalah data mengenai kebutuhan pokok. Data ini konstan karena kebutuhan pokok dibutuhkan setiap waktu sehingga jumlahnya relative konstan.

b. Pola Data Trend

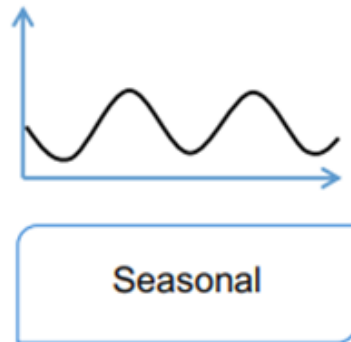


**Gambar 2.3** Contoh Pola Data Trend

Pola data trend artinya jumlah data meningkat atau menurun dalam beberapa periode. Contoh pola data trend adalah peningkatan harga emas karena efek pandemi. Peningkatan harga emas ini terjadi karena emas dipandang sebagai investasi yang paling aman.



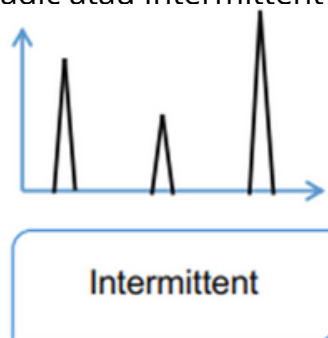
c. Pola Data Seasonal



**Gambar 2.4** Contoh Pola Data Seasonal

Pola data seasonal artinya jumlah data meningkat dan mencapai puncaknya di periode tertentu, kemudian kembali melandai dan kembali mencapai puncak di kelipatan periode selanjutnya, misalnya naik setiap tiga bulan, enam bulan, dan tahunan. Contoh pola data seasonal adalah nilai penjualan tiket kereta api. Jumlah penjualan akan meningkat saat lebaran atau Natal yang membentuk pola hampir sama setiap tahunnya.

d. Pola Data Sporadic atau Intermittent



**Gambar 2.5** Contoh Pola Data Intermittent

Pola data intermittent artinya frekuensi data hanya muncul di periode-periode tertentu. Data yang memiliki pola intermittent ini di beberapa periodenya bernilai nol. Contoh data yang memiliki pola intermittent adalah jumlah permintaan yang masuk ke perusahaan *spare part* kendaraan berat, karena perbaikan atau *maintenance* tidak dilakukan secara teratur untuk setiap periode



## 2.3 PENGGAMBARAN POLA DATA DENGAN MICROSOFT EXCEL

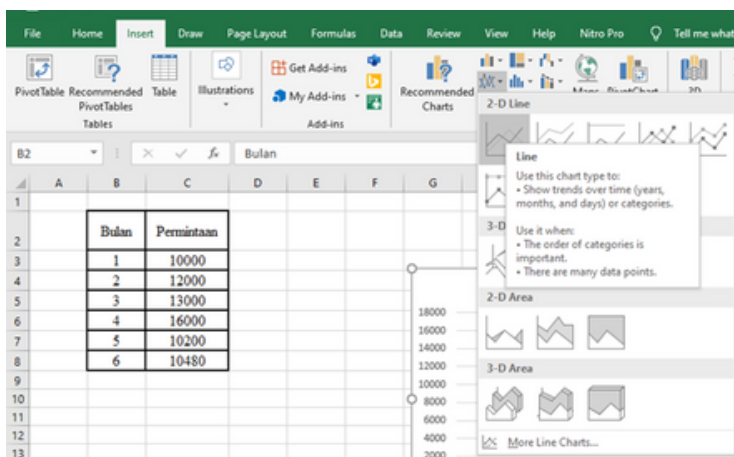
Untuk membuat dan mengetahui pola dari suatu data, data historis yang telah diperoleh dapat digambarkan dengan Microsoft Excel dengan menggunakan sub menu Chart. Langkah-langkahnya adalah sebagai berikut.

- Data yang digunakan merupakan data historis permintaan produk selama enam bulan.

**Tabel 2.1** Contoh Data untuk Pola Data

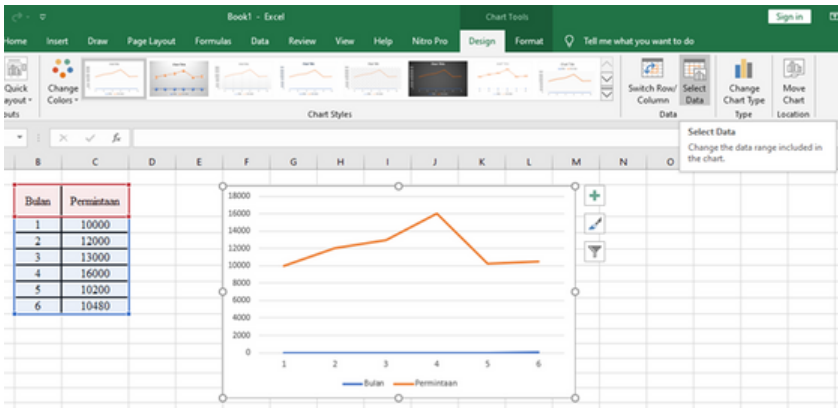
Bulan	Permintaan
1	10000
2	12000
3	13000
4	16000
5	10200
6	10480

- Masukkan data pada bagian a dan pilih menu Insert Line Chart sehingga akan muncul tampilan berikut.



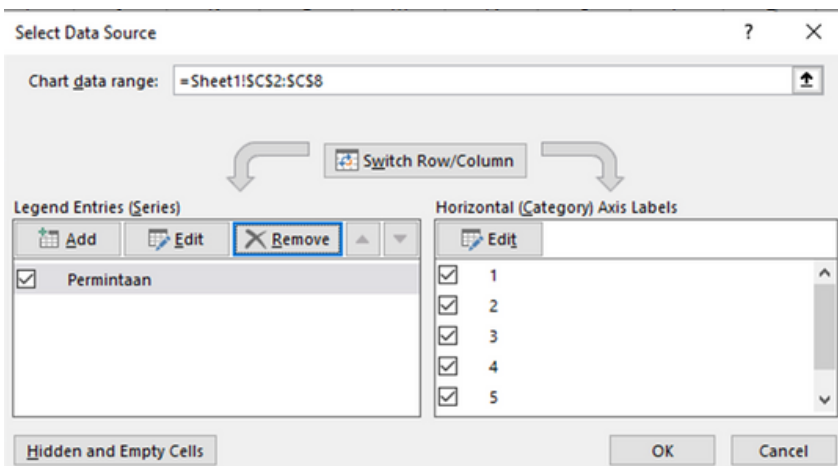
**Gambar 2.6** Tampilan Menu Insert Chart

- c. Jika tampilan grafik belum sesuai, maka dapat disesuaikan melalui menu Select Data berikut.



**Gambar 2.7** Tampilan Grafik yang Belum Sesuai

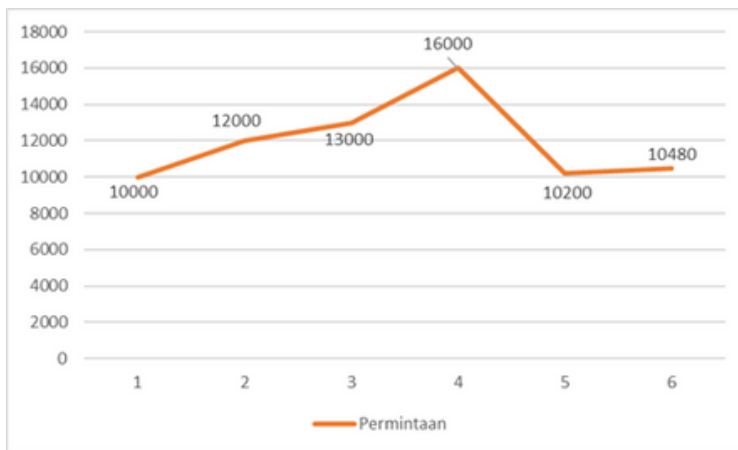
- d. Ubahlah pilihan data agar sesuai, dimana sumbu x adalah bulan atau periode dan sumbu y adalah besarnya permintaan dengan pengaturan pada Select Data sebagai berikut.



**Gambar 2.8** Tampilan Menu Select Data

Pada bagian Chart data range diisi dengan data yang akan digambarkan plot nya. Pada bagian legend entries masukkan frekuensi permintaan dan pada bagian horizontal axis masukkan periode (bulan). Selanjutnya klik Ok.

e. Tampilan akhir dari grafik adalah sebagai berikut.



**Gambar 2.9** Tampilan Akhir Grafik



## 2.4 PENGAMBARAN POLA DATA DENGAN MINITAB

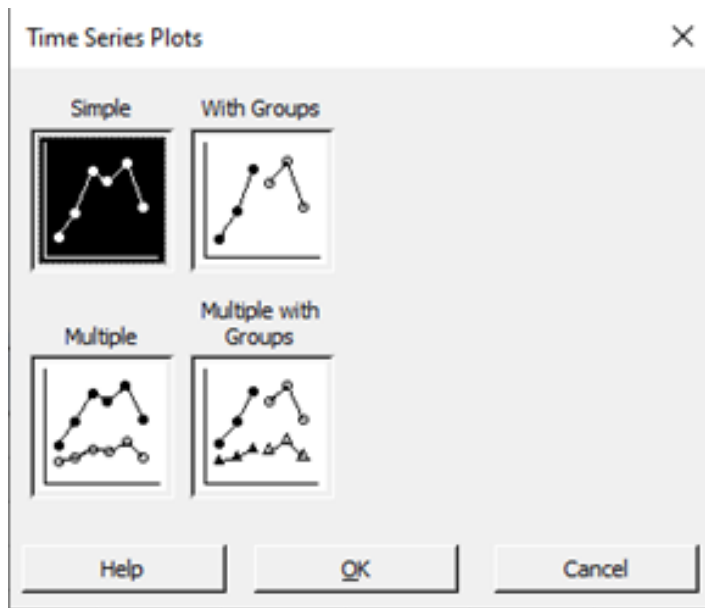
Untuk membuat pola data dengan Minitab, langkah-langkah yang dilakukan adalah sebagai berikut.

a. Menginputkan data pada worksheet Minitab dengan tampilan berikut.

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13
	Bulan	Permintaan											
1	1	10000											
2	2	12000											
3	3	13000											
4	4	16000											
5	5	10200											
6	6	10480											

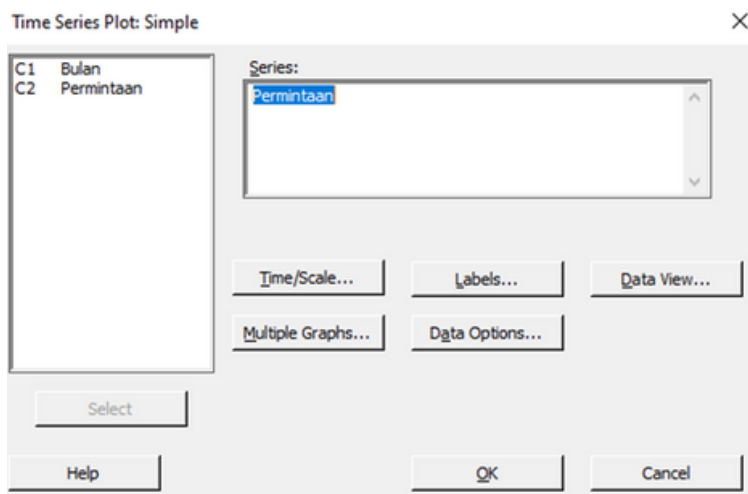
**Gambar 2.10** Tampilan Worksheet Minitab untuk Input Data

- b. Pilih menu Graph Time Series Plot maka akan muncul tampilan seperti pada Gambar 2.11, selanjutnya pilih Simple dan klik OK.



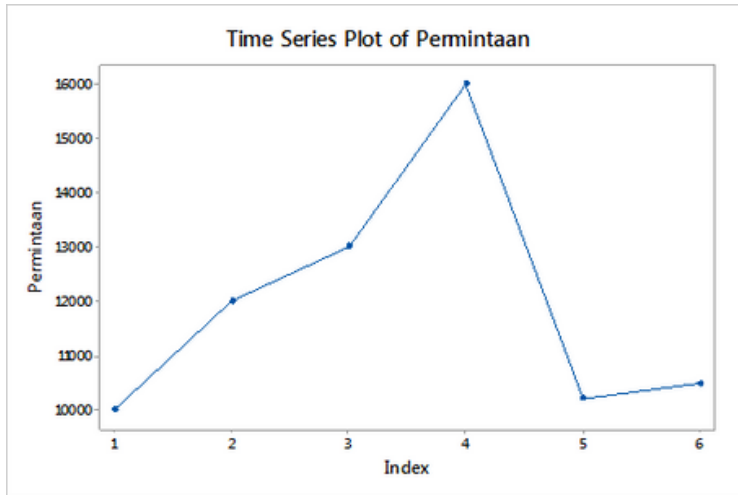
**Gambar 2.11** Kotak Dialog Time Series Plot

- c. Setelah muncul kotak dialog Time Series, isikan nilai yang diminta seperti pada Gambar 2.12. Variabel yang akan digambarkan plot-nya diinputkan pada bagian Series, lalu klik OK.



**Gambar 2.12** Memasukkan Variabel yang Akan Digambar

c. Hasil dari grafik yang digambarkan adalah sebagai berikut.



**Gambar 2.13** Plot Grafik dengan Minitab

Berdasarkan grafik yang ditampilkan pada Gambar 2.9 dan Gambar 2.13 dapat disimpulkan bahwa permintaan memiliki pola trend naik walaupun ada data yang turun pada bulan ke-5.





# LATIHAN SOAL

1. Bagaimanakah peran teknik peramalan dalam menentukan pemesanan bahan baku pada proses produksi?

---

---

---

---

---

2. Berikan contoh data yang memiliki pola data seasonal dan pola data sporadik.

---

---

---

---

---

3. Gambarkan plot untuk data pada Lampiran 1 dan berikan penjelasan jenis dari pola datanya.

---


---

---

---

---





# **METODE PERAMALAN BERDASARKAN DATA HISTORIS**




## Tujuan Instruksional

1. Mahasiswa dapat menggunakan data untuk meramalkan sesuai dengan kebutuhan.
2. Mahasiswa dapat memahami alur dalam peramalan.
3. Mahasiswa dapat meramalkan menggunakan metode sederhana.



### Data Historis

merupakan data lampau yang digunakan sebagai dasar dari penentuan model peramalan untuk periode selanjutnya. Gambaran mengenai peranan data historis dalam menentukan model peramalan adalah sebagai berikut



**Gambar 3.1** Bagan Hubungan Data Historis dengan Model Peramalan

Berdasarkan Gambar 3.1, data historis diwakili oleh data *time series* yaitu suatu data runtun waktu dalam periode tertentu, kemudian data *time series* ini digunakan untuk membentuk model dan selanjutnya model digunakan untuk peramalan di periode selanjutnya.

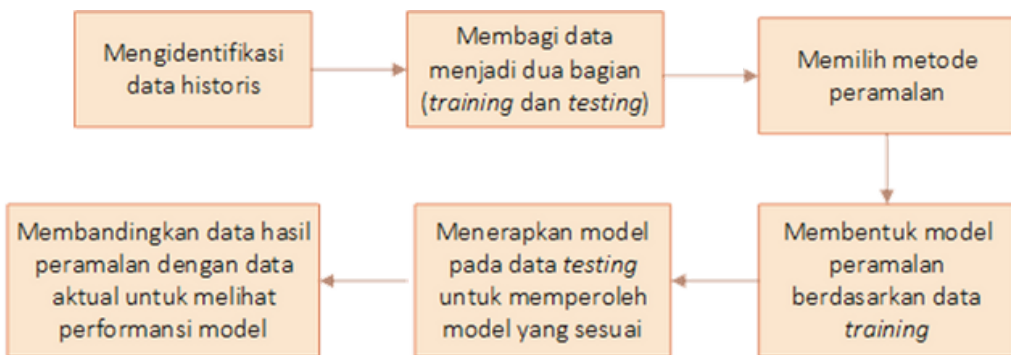
Akurasi dari model sangat bergantung pada data *time series* yang tersedia. Ada beberapa data *time series* yang tidak lengkap atau *missing data* di beberapa periode, sehingga harus dilengkapi terlebih dahulu sebelum digunakan untuk peramalan.

Secara garis besar, alur dari peramalan dengan menggunakan data historis ditampilkan pada Gambar 3.2. Data historis dibagi menjadi dua bagian, yaitu data *training* dan data *testing*.

Data training digunakan sebagai acuan dalam pembentukan model dan biasanya menggunakan 70% dari total periode data historis.



Data testing digunakan untuk melihat performansi model. Performansi ini dilihat dengan cara membandingkan data testing dengan data hasil peramalan, apakah memiliki error yang besar atau kecil.



**Gambar 3.2** Alur dalam menentukan model peramalan



### 3.1 METODE MOVING AVERAGE

Metode *moving average* merupakan metode yang menggunakan rata-rata untuk meramalkan di periode selanjutnya. Rata-rata yang digunakan merupakan rata-rata bergerak sehingga nilainya selalu *update* sesuai dengan periode yang diramalkan. Misalkan MA(3) artinya menggunakan metode *moving average* tiga periode untuk meramalkan data di periode keempat. Jika akan meramalkan data di periode kelima, maka data yang digunakan adalah rata-rata dari data kedua sampai keempat. Berikut adalah contoh data yang dianalisis dengan Metode Moving Average.

#### Contoh 3.1

Bulan	1	2	3	4
Penjualan	10000	12000	13000	16000

Jika periode yang digunakan adalah setiap tiga periode atau tiga bulan, maka saat akan menentukan besarnya penjualan pada bulan ke-5, data yang digunakan adalah rata-rata pada bulan kedua sampai bulan ke-4. Hasil selengkapnya seperti pada Gambar berikut.

Bulan	Penjualan	Forecast
1	10000	
2	12000	
3	13000	
4	16000	
5		13666,67
6		14222,22

$$F_5 = \frac{12000 + 13000 + 16000}{3} = 13666,67$$

$$F_6 = \frac{13000 + 16000 + 13666,67}{3} = 14222,22$$

Pada metode *moving average*, rata-rata yang digunakan untuk peramalan diperbarui sesuai dengan periode yang diramalkan, karena periode yang paling dekat adalah yang paling berpengaruh. Hal inilah yang akhirnya melahirkan metode pengembangan dari *Moving Average* yaitu *Weighted Moving Average* (WMA) dimana periode yang terdekat dengan periode peramalan memiliki bobot yang lebih besar dibandingkan dengan periode-periode sebelumnya. Berikut adalah contoh pengolahan data dengan metode *Weighted Moving Average*.

Bulan	Penjualan	Bobot	Forecast
1	10000		
2	12000	0,17	
3	13000	0,33	
4	16000	0,5	
5			14330

$$F_5 = (12000 \times 0,17) + (13000 \times 0,33) + (16000 \times 0,5) = 14330$$

Dalam metode WMA, bobot yang digunakan untuk masing-masing periode jika dijumlah harus sama dengan satu. Misalkan orde yang digunakan adalah empat periode atau WMA (4), maka bobot juga diberikan pada empat data yang memiliki periode terdekat.



### 3.2 METODE EXPONENTIAL SMOOTHING

Metode *exponential smoothing* merupakan pengembangan dari metode *weighted moving average*. Pada metode *exponential smoothing* digunakan parameter pemulusan yang dapat memperhalus model peramalan. Nilai parameter pemulusan antara 0 sampai dengan 1. Metode ini dibagi menjadi dua berdasarkan tahapannya, yaitu *exponential smoothing* tunggal dan *exponential smoothing* ganda.



## a. Metode Exponential Smoothing Tunggal

Pada metode *exponential smoothing* tunggal, tahapan yang digunakan untuk mendapatkan data ramalan adalah satu tahap, atau hanya dilakukan penghalusan satu kali.

Persamaan matematis dari metode *exponential smoothing* tunggal adalah sebagai berikut.

$$F_t = (1 - \alpha)F_{t-1} + \alpha A_{t-1} \quad (3.1)$$

dengan:

$F_t$  : hasil peramalan pada periode sekarang (periode ke- $t$ )

$F_{t-1}$  : hasil peramalan pada periode sebelumnya (periode ke  $t-1$ )

$A_{t-1}$  : data aktual pada periode sebelumnya (periode ke  $t-1$  )

$\alpha$  : koefisien pemulusan

### Contoh 3.2

Berikut ini adalah contoh data penjualan selama beberapa bulan.

Bulan	1	2	3	4
Penjualan	10000	12000	13000	16000

Koefisien pemulusan ( $\alpha$ ) yang digunakan adalah 0,1. Untuk menghitung periode ke-5 diperlukan data peramalan pada periode ke-4, sehingga untuk menentukan data peramalan pada periode ke-5 diperlukan data peramalan mulai dari periode ke-1 sampai ke-4. Nilai awalan yang digunakan adalah  $F_1 = A_1 = 10000$  , sehingga diperoleh hasil seperti pada tabel berikut.

Bulan	Data Aktual	Data Peramalan
1	10000	10000
2	12000	10000
3	13000	10200
4	16000	10480
5		11032

$$\begin{aligned}
 F_3 &= (0,9 \times F_2) + (0,1 \times A_2) \\
 &= (0,9 \times 10000) + (0,1 \times 12000) \\
 &= 10200
 \end{aligned}$$

Dengan cara yang sama diperoleh jumlah penjualan pada periode ke-5 adalah 11032.

Nilai koefisien pemulusan ( $\alpha$ ) menentukan bagaimana pola dari data peramalan yang terbentuk. Untuk mendapatkan pola data peramalan yang mendekati data aktual perlu dilakukan *trial and error* sehingga diperoleh pola data yang sesuai.

## b. Metode Exponential Smoothing Tunggal

Pada metode *exponential smoothing* ganda dilakukan pemulusan data dua tahap dengan menggunakan satu parameter. Pada pemulusan tahap dua digunakan data yang diperoleh dari pemulusan pertama.

Persamaan yang digunakan adalah sebagai berikut.

$$F''_t = \alpha F_t + (1 - \alpha) F''_{t-1} \quad (3.2)$$

dengan:

$F''_t$  : hasil peramalan pada tahap kedua periode sekarang ( $t$ )

$F''_{t-1}$  : hasil peramalan pada periode sebelumnya (periode ke  $t-1$ )

*Exponential Smoothing* Ganda dapat pula digunakan untuk meramalkan selama periode ke depan, dengan menggunakan data aktual beberapa periode sebelumnya. Persamaan yang digunakan berhubungan dengan persamaan (3.1) dan (3.2) sebagai berikut.

$$a_t = 2F_t - F''_t \quad (3.3)$$

$$b_t = \frac{\alpha}{1-\alpha}(F_t - F''_t) \quad (3.4)$$

$$F_{t+m} = a_t + b_t m \quad (3.5)$$

dengan:

$a_t, b_t$  : konstanta model peramalan

$m$  : Periode yang diramalkan

$F_{t+m}$  : hasil peramalan pada periode ke  $(t + m)$

### Contoh 3.3

Berikut ini adalah contoh data penjualan selama beberapa bulan.

Bulan	1	2	3	4
Penjualan	10000	12000	13000	16000

Koefisien pemulusan ( $\alpha$ ) yang digunakan adalah 0,1. Tentukan nilai peramalan pada periode ke-5, ke-6, dan ke-7 dengan menggunakan *exponential smoothing* ganda.

Hasil dari perhitungan dengan menggunakan Ms. Excel adalah sebagai berikut

Alpha= 0,1						
Periode	Data aktual (At)	Eksponensial Smoothing Tunggal (Ft)	Eksponensial Smoothing Ganda (F't)	at	bt	F(t+m)
1	10000	10000	10000			
2	12000	10000	10000	10000	0,111111	
3	13000	10200	10020	10380	0,113107	10000,11
4	16000	10480	10066	10894	0,115681	10380,11

Nilai untuk *initial value* ditentukan dari data aktual pada periode pertama. Selanjutnya untuk mendapatkan nilai pada *eksponensial smoothing tunggal* digunakan persamaan (3.1), dan untuk mendapatkan nilai pada *eksponensial smoothing ganda* digunakan persamaan (3.2), sebagai contoh misalkan menghitung nilai *eksponensial smoothing ganda* pada periode ketiga.

$$F''_3 = \alpha F_3 + (1 - \alpha)F''_2 = (0,1 \times 10200) + (0,9 \times 10000) = 10020$$

Untuk mendapatkan nilai  $a_t$  digunakan persamaan (3.3), sebagai contoh misalkan dihitung nilai untuk  $a_3$ , maka

$$a_3 = 2F_3 - F''_3 = (2 \times 10200) - 10020 = 10380.$$

Untuk mendapatkan nilai  $b_t$  digunakan persamaan (3.4), sebagai contoh misalkan dihitung nilai untuk  $b_3$ , maka

$$b_3 = \frac{\alpha}{1-\alpha} (F_3 - F''_3) = \frac{0,1}{0,9} (10200 - 10020) = 0,113.$$

Untuk mendapatkan nilai  $F_{t+m}$  digunakan persamaan (3.5), sebagai contoh untuk menentukan data pada periode ke-7, maka digunakan data pada periode ke-4 dengan nilai  $m = 3$

$$F_7 = F_{4+3} = a_4 + (b_4 \times 3) = 10894 + (0,1157 \times 3) = 10894,35$$



### 3.3 PENGOLAHAN DENGAN MINITAB

Metode moving average dan exponential smoothing dapat dianalisis dengan menggunakan Minitab.



#### Metode Moving Average dengan Minitab

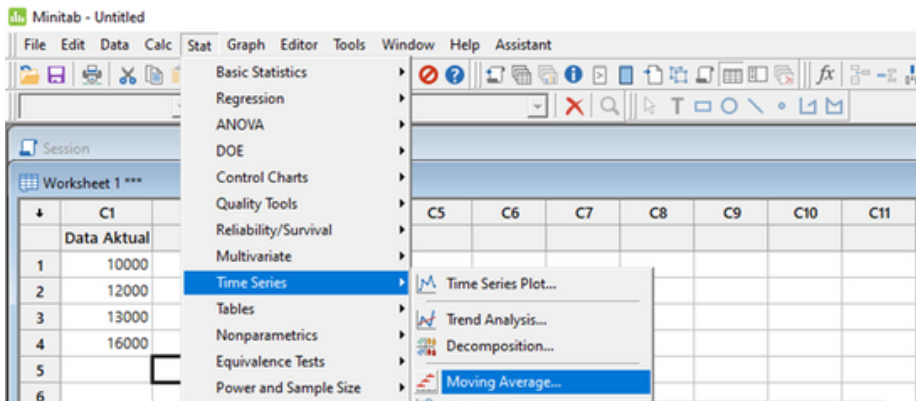


1.

Menginputkan data yang akan dianalisis dengan Minitab. Data yang digunakan sama seperti pada Contoh 3.1

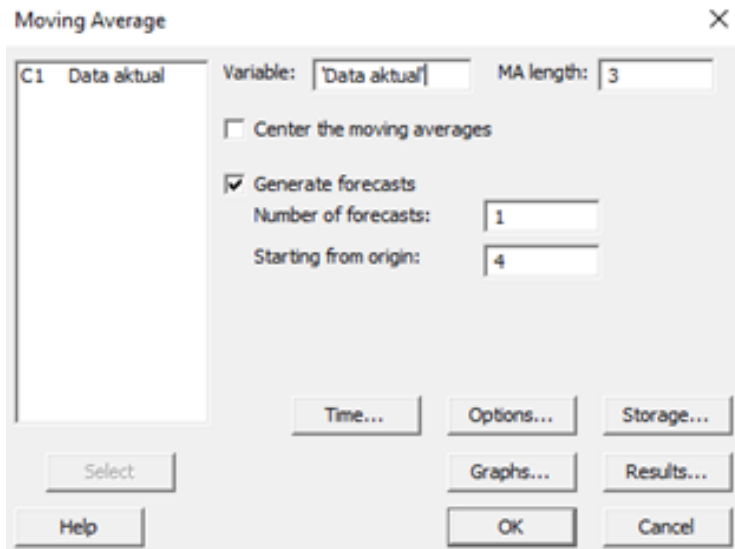
2.

Pilih menu Stat → Time Series → Moving Average untuk menggunakan metode Moving Average



3.

Pada kotak dialog Moving Average, inputkan data pada menu **Variable**, **MA length** menunjukkan orde yang digunakan untuk peramalan. Centang pilihan **Generate Forecast**, lalu isikan jumlah periode yang akan diramalkan pada menu **Number of forecast**, dan isikan periode akhir dari data yang dimiliki pada menu **Starting from origin** untuk menentukan periode awal peramalan, selanjutnya klik OK.



4. Hasil dari analisis ini adalah sebagai berikut



### Forecasts

Period	Forecast	Lower	Upper
5	13666,7	5173,49	22159,8

Hasil peramalan ditampilkan pada bagian forecast dan akurasi dari peramalan dengan menggunakan MA(3) dapat dilihat dari nilai MAPE sebesar 27.



## Metode Exponential Smoothing dengan Minitab



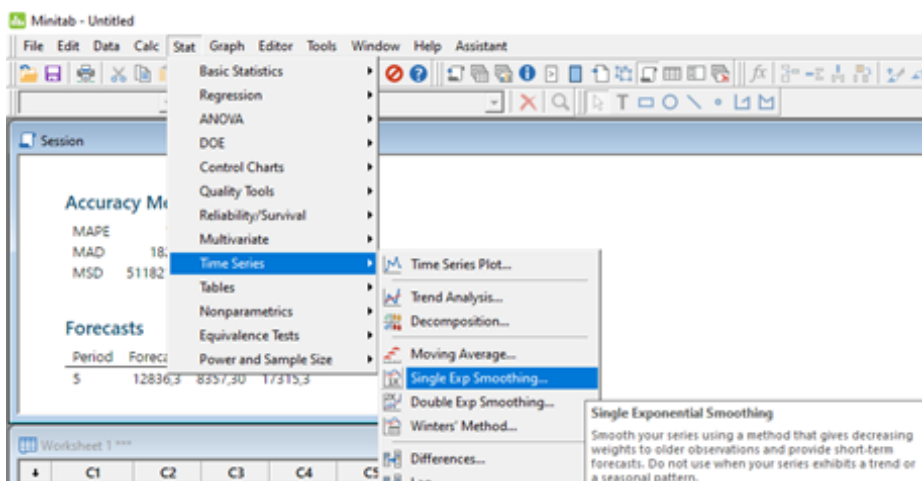
1.

Menginputkan data yang akan diolah dengan menggunakan metode *exponential smoothing*. Data yang digunakan adalah data pada Contoh 3.1 namun ditambahkan dengan enam periode agar dapat dioptimalkan bobotnya dengan menggunakan ARIMA. Adapun data lengkapnya adalah sebagai berikut.

	C1	C2	C3	C4	C5	C6	C7	C8	C9
	Data aktual								
4	16000								
5	12500								
6	13500								
7	10000								
8	11000								
9	10500								
10	16500								

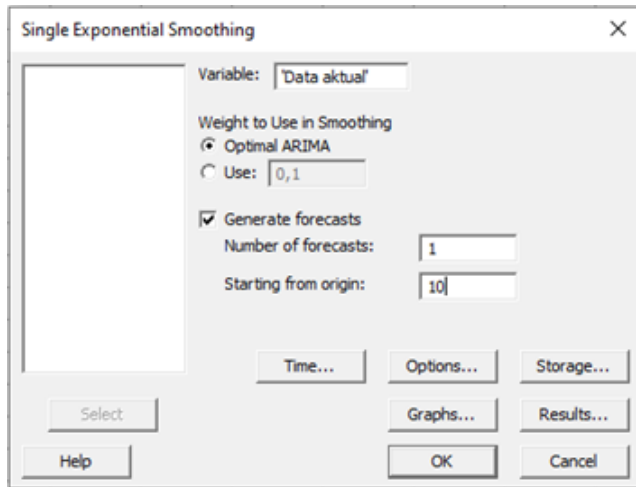
2.

Pilih menu Stat → Time Series → Single Exp Smoothing



3.

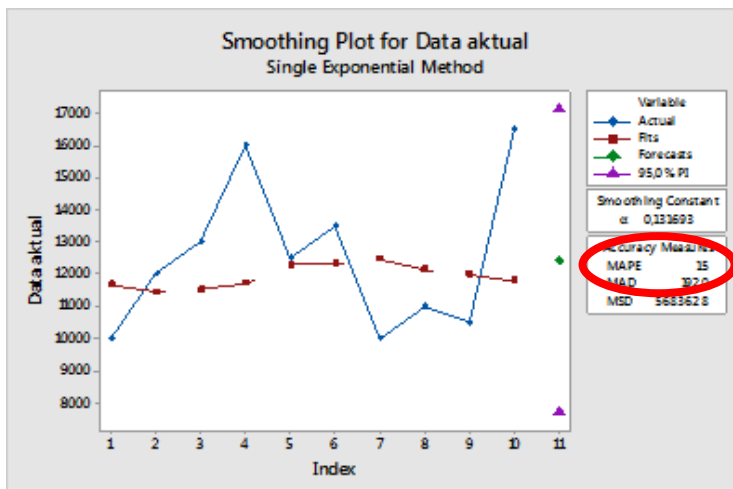
Tampilan dari single exp smoothing adalah seperti berikut.



Pada sub menu **Variable** inputkan data yang akan diolah. Penentuan bobot untuk metode ini dapat dioptimalkan dengan memilih **Optimal ARIMA** sehingga akan memperkecil nilai MAPE, namun menu ini dapat digunakan untuk jumlah periode data yang cukup, jika hanya menggunakan empat periode maka dapat dimasukkan bobotnya pada sub menu **Use**. Untuk meramalkan periode selanjutnya, centang sub menu **Generate Forecasts** seperti pada metode Moving Average, dan klik **OK**.

4.

Output yang dihasilkan adalah sebagai berikut.





## Forecasts

Period	Forecast	Lower	Upper
11	12414,4	7711,60	17117,2

Dengan menggunakan bobot yang sudah dioptimalkan diperoleh hasil peramalan pada periode ke-11 adalah 12414,4 dengan nilai MAPE 15%. Nilai MAPE ini sudah relatif kecil sehingga model ini dapat digunakan untuk meramalkan pada periode selanjutnya.

Materi mengenai ukuran performansi model akan dibahas pada bab selanjutnya.



# LATIHAN SOAL

1. Bagaimana peranan data historis untuk menentukan model peramalan?

---

---

---

---

---

2. Berikut ini adalah data harga emas selama 30 hari saat pandemi Covid-19 (data dapat diakses pada link <https://bit.ly/data-buku-halwa> ) pada Sheet Lat.Soal. Satuan yang digunakan untuk harga emas adalah USD per ounce. Lakukan analisis sebagai berikut.

a. Gambarkan grafik harga emas dalam 30 periode tersebut

---

---

---

---

---

---

---

---

---

---

b. Gunakan metode Moving Average dengan orde 3 untuk membentuk model peramalannya, dan gunakan model tersebut untuk meramalkan periode ke-31 sampai ke-35.

---

---

---

---

---

c. Gunakan metode Exponensial Smoothing Ganda dengan nilai  $\alpha = 0,1$  dan  $\alpha = 0,2$  untuk meramalkan lima periode ke depan.

---

---

---

---

---

c. Bandingkan hasil peramalan antara poin b dan poin c. Manakah metode yang lebih baik jika dilihat berdasarkan grafik hasil peramalan terhadap nilai aktualnya? Berikan penjelasan.

---


---

---

---

---





# **METODE AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA)**




## Tujuan Instruksional

1. Mahasiswa dapat menggambarkan plot time series dari suatu data
2. Mahasiswa dapat menentukan orde dari model ARIMA
3. Mahasiswa dapat menggunakan model ARIMA untuk peramalan




### 4.1 PENGENALAN MODEL ARIMA



Metode ARIMA pertama kali muncul pada abad ke-20 namun diformulasikan ulang oleh Box-Jenkins pada tahun 1970an sehingga metode ini juga dikenal dengan ARIMA Box-Jenkins. Metode ARIMA biasanya digunakan untuk meramalkan data aktual yang memiliki periode panjang (minimal 36 periode bulanan) dan merupakan data lengkap.

Model ARIMA sesuai untuk memperkirakan dalam jangka pendek, sedangkan untuk memperkirakan jangka panjang akurasiya kurang baik. Model ARIMA merupakan salah satu model yang mengabaikan variabel independen, karena untuk memperkirakan menggunakan data masa lalu dan masa sekarang dari variabel dependen. Model ARIMA ini sesuai digunakan dan akan menghasilkan akurasi yang baik jika observasi *time series* berhubungan satu sama lain.

Sesuai dengan namanya, model ARIMA merupakan gabungan analisis untuk autoregressive dan moving average. Metode ARIMA tidak selalu digunakan lengkap karena menyesuaikan dengan pola datanya.



Pada beberapa data, model yang paling sesuai adalah Autoregressive (AR), atau Moving Average (MA), dan ada juga model yang menggunakan keduanya namun tanpa integrated karena datanya sudah stasioner sehingga modelnya menggunakan ARMA.

Metode ARIMA ini memiliki kelebihan dan kekurangan, sama seperti metode-metode peramalan lainnya. Adapun kelebihan dan kekurangan dari metode ARIMA dijelaskan dalam Tabel 4.1.

**Tabel 4.1** Kelebihan dan Kekurangan Metode ARIMA


Kelebihan Metode ARIMA	Kekurangan Metode ARIMA
Banyak software statistika yang menyediakan model Box-Jenkins ARIMA sehingga lebih mudah dalam analisis data menggunakan metode ini.	Metode ini membutuhkan data yang panjang (minimal 36 periode data bulanan dan 156 periode data mingguan) agar diperoleh akurasi peramalan yang baik
Memiliki tingkat akurasi yang cukup tinggi jika digunakan untuk meramalkan data histori dengan periode panjang	Metode ini termasuk dalam short-term forecast yang akurat untuk meramalkan satu hingga tiga periode ke depan
Model ARIMA dapat menggambarkan pattern data yang secara implisit ada di data histori.	Meminimalkan nilai error dalam peramalan dengan menggunakan software menyebabkan model overfitting



**Tabel 4.1** Kelebihan dan Kekurangan Metode ARIMA (Lanjutan)

Kelebihan Metode ARIMA	Kekurangan Metode ARIMA
	Metode ini memerlukan pengetahuan statistika yang baik karena ada banyak pengujian yang dilakukan
	Hasil dari metode ARIMA sulit diinterpretasikan oleh orang yang tidak memiliki pengetahuan statistika cukup baik.

Salah satu kekurangan dari ARIMA adalah membutuhkan periode data yang panjang, hal ini dikarenakan data akan dibagi menjadi dua bagian yaitu data *in-sample* dan data *out-sample*. Data *in-sample* digunakan untuk membentuk model dan data *out-sample* digunakan untuk melakukan validasi model yang terbentuk. Persentase yang biasanya digunakan untuk data *in-sample* dan data *out-sample* berturut-turut adalah 70% dan 30%. Jumlah data yang panjang ini juga disebabkan oleh konsep dalam peramalan, dimana data memiliki autokorelasi atau berkorelasi dengan dirinya sendiri. Korelasi ini terjadi di waktu sekarang dengan masa lampau, maupun sekarang dengan masa yang akan datang.



Konsep autokorelasi sering digunakan dalam analisis data-data di bidang ekonomi.

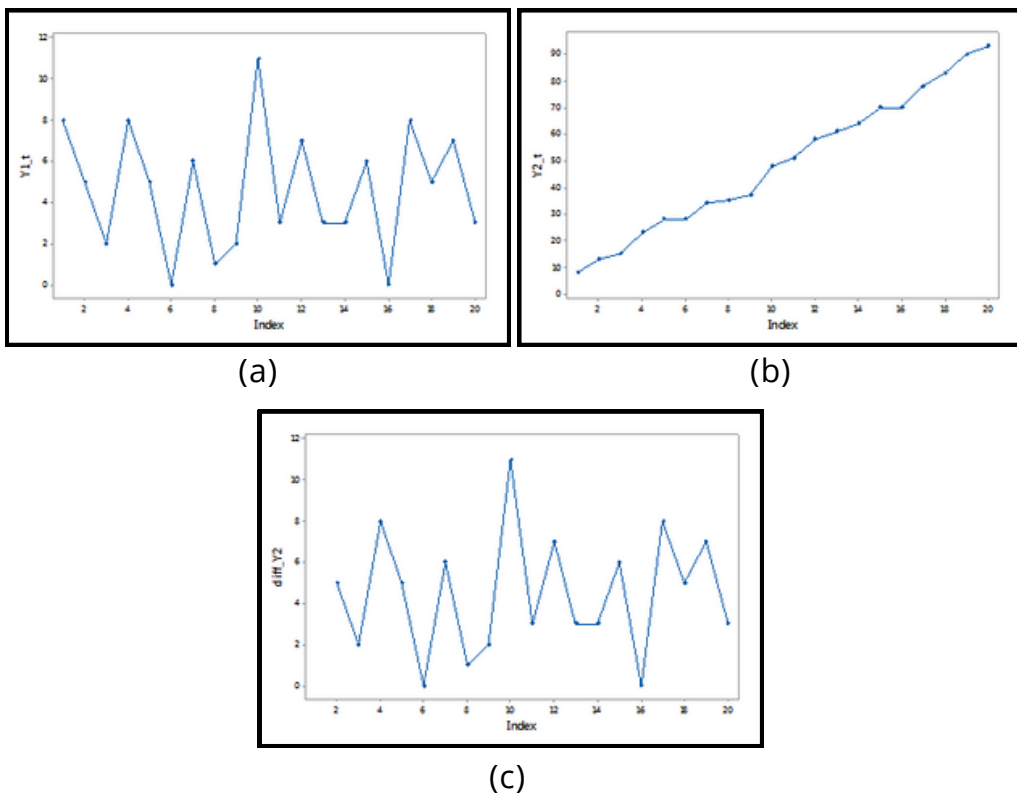
### Contoh Konsep Autokorelasi

Data harga emas. Saat terjadi Covid-19, harga emas naik secara signifikan dimana kenaikan ini berpengaruh terhadap harga emas saat ini. Selain untuk memprediksi harga emas, ARIMA juga dapat digunakan untuk prediksi harga saham dan indikator-indikator finansial lainnya.



## 4.2 STASIONERITAS DATA

Data yang dianalisis dengan ARIMA harus sudah stasioner. Stasioner adalah tidak ada kenaikan atau penurunan data yang ekstrim, artinya data berada pada persekitaran nilai yang sama. Apabila data belum stasioner, maka dilakukan diferensiasi atau menghitung selisih antar periode data sampai dengan data stasioner.



**Gambar 4.1** Pola Data Time Series

- (a) Pola Data Stasioner,
- (b) Pola Data Non-stasioner,
- (c) Pola Data setelah Diferensiasi

Contoh data yang belum stasioner dan sudah stasioner terdapat pada Gambar 4.1.

Pada Gambar 4.1 (a) terlihat bahwa data berada pada persekitaran garis yang sama, sehingga data tersebut sudah stasioner. Gambar 4.1 (b) terlihat bahwa data mengalami kenaikan dan tidak berada pada persekitaran garis yang sama, sehingga data tersebut belum stasioner sehingga harus dilakukan diferensiasi. Data pada Gambar 4.1 (b) dilakukan diferensiasi satu kali sehingga data menjadi stasioner seperti pada Gambar 4.1 (c).




### 4.3 AUTOKORELASI DALAM ARIMA

ACF atau *Autocorrelation Function* merupakan korelasi antar data di dalam *time series* atau korelasi antara data ke- $t$  dengan data ke- $t+k$ , dengan  $k$  menyesuaikan *lag* yang digunakan. Misalkan suatu ACF data menggunakan *lag* 1 artinya nilai  $t$  akan dikorelasikan dengan data  $t+1$  karena nilai  $k=1$ .

Selain menggunakan ACF, dalam ARIMA juga mempertimbangkan PACF untuk menentukan model sesuai dengan pola datanya. PACF atau *Partial Autocorrelation Function* merupakan korelasi parsial antar data di dalam *time series*, yaitu antara data ke- $t$  dengan data ke- $t+k$  dengan terlebih dahulu menghilangkan data antara data ke- $t$  dengan  $t+k$ . Perbedaan antara ACF dan PACF adalah pada ACF saat menentukan korelasi tetap memperhitungkan nilai antara  $t$  dengan  $t+k$ , sedangkan pada PACF menentukan korelasi antara  $t$  dengan  $t+k$  tanpa memperhitungkan nilai antara  $t$  dengan  $t+k$ .

ACF dan PACF dalam ARIMA memiliki dua kemungkinan pola, yaitu *cut-off* dan *dies down*. Pola dalam ACF dan PACF ini yang menentukan orde dari model ARIMA. Pola *cut-off* dan *dies down* ditampilkan dalam Gambar 4.2.



**Gambar 4.2** Pola ACF dan PACF

Pada Gambar 4.2 tampak bahwa pola ACF menunjukkan bahwa data *dies down* atau menurun secara perlahan, sedangkan pola pada PACF menunjukkan bahwa data *cut-off* setelah *lag* ke-2. Jika data masih belum stasioner, maka harus dilakukan *differencing* sebelum dilihat pola ACF dan PACF. Sifat-sifat dari plot ACF dan PACF yang dapat dijadikan acuan dalam menentukan orde ARIMA ditampilkan pada Tabel 4.2.

**Tabel 4.2** Sifat-Sifat ACF dan PACF pada model ARIMA

Proses	Sampel ACF	Sampel PACF
<i>White Noise</i>	Tidak ada yang melewati garis batas interval untuk $lag > 0$	Tidak ada yang melewati garis batas interval untuk $lag > 0$
AR(p)	Menurun menuju nol secara eksponensial	<i>Cut off</i> pada $lag$ ke-p artinya berada di atas garis interval maksimum sampai $lag$ ke-p dan di bawah batas garis interval pada $lag > p$

**Tabel 4.2** Sifat-Sifat ACF dan PACF pada model ARIMA (lanjutan)

Proses	Sampel ACF	Sampel PACF
MA(q)	<i>Cut off</i> pada <i>lag</i> ke-q artinya berada di atas garis interval maksimum sampai lag ke-p dan di bawah batas garis interval pada <i>lag</i> > q	Menurun menuju nol secara eksponensial
ARMA(p,q)	Menurun menuju nol secara eksponensial	Menurun menuju nol secara eksponensial



## 4.4 PERSAMAAN MATEMATIS MODEL ARIMA

### a. Model Autoregressive (AR)

Model autoregressive merupakan bagian dari metode ARIMA yang memiliki orde  $p$  sehingga secara umum dapat dituliskan dengan ARIMA( $p,0,0$ ). Persamaan matematis untuk model AR adalah sebagai berikut.

$$\hat{z}_t = \phi_1 \hat{z}_{t-1} + \phi_2 \hat{z}_{t-2} + \dots + \phi_p \hat{z}_{t-p} + a_t \quad (4.1)$$

Keterangan:

$\phi_p$  : parameter autoregressive ke- $p$

$a_t$  : *white noise* nilai kesalahan pada saat  $t$

$\hat{z}_{t-p}$  : variabel bebas

Variabel bebas dalam persamaan ini adalah variabel yang dimodelkan untuk peramalan, dimana antara variabel  $\hat{z}_t$  dengan  $\hat{z}_{t-p}$  adalah variabel yang sama namun berbeda deret waktunya saja. Nilai  $a_t$  menunjukkan residual atau *error* dari model peramalan yang terbentuk, dimana nilai residual ini tidak dapat dijelaskan pada model. Penentuan orde pada model AR berdasarkan *lag cut off* pada plot PACF.

Langkah-langkah dalam menentukan model AR adalah sebagai berikut.

1. Menentukan model sesuai dengan deret waktu
2. Menentukan nilai orde  $p$  berdasarkan pada plot ACF dan PACF
3. Mengestimasi nilai koefisien dari  $\phi_1, \phi_2, \dots, \phi_k$

Hasil yang diperoleh dari estimasi koefisien digunakan dalam pemodelan matematisnya untuk memprediksi nilai pada beberapa periode selanjutnya. Misalkan dari suatu pengolahan data diketahui bahwa *cut off* terjadi pada plot PACF setelah *lag* kedua sehingga orde dari AR adalah  $p = 2$ , hasil estimasi parameter adalah sebagai berikut  $\phi_1 = 0,45$ ,  $\phi_2 = 0,3$  dan  $\phi_3 = 0,15$ , dan diperoleh model sebagai berikut.

$$\hat{z}_t = 0,45Z_{t-1} + 0,3Z_{t-2} + 0,15Z_{t-3} + a_t \quad (4.2)$$

Model ini dapat digunakan untuk meramalkan nilai pada periode selanjutnya.

## **b. Model Moving Average (MA)**

Model Moving Average merupakan salah satu model dari ARIMA. Model ini dilambangkan dengan MA( $q$ ) dengan  $q$  adalah orde dari MA atau dapat dituliskan dengan ARIMA ( $0,0,q$ ). Nilai  $q$  ditentukan oleh *lag* yang *cut off* pada plot ACF.

Perbedaan antara AR dan MA dapat dilihat pada plot ACF dan PACF data. Suatu data lebih sesuai menggunakan model AR jika plot ACF menunjukkan *dies down* dan plot PACF menunjukkan *cut off* setelah *lag* ke- $p$ , dan suatu data lebih sesuai menggunakan MA jika *dies down* terjadi pada plot PACF dan *cut off* pada plot ACF. Persamaan matematis untuk model MA adalah sebagai berikut.

$$\hat{z}_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (4.3)$$

Keterangan:

$\theta_q$  : parameter *Moving Average*

$a_t$  : *white noise* kesalahan pada saat periode ke- $t$

Berdasarkan pada Persamaan 4.3,  $\hat{z}_t$  dipengaruhi oleh nilai *error* pada periode sebelumnya. Pada model *moving average* diukur *auto* korelasi antara *error* periode saat ini dengan *error* pada periode sebelumnya.

### Contoh Model Moving Average

Apabila nilai  $q = 2$ ,  $\theta_1 = 0,8$ ,  $\theta_2 = 0,3$ , sehingga persamaan untuk MA(2) atau ARIMA(0,0,2) adalah

$$\hat{z}_t = 0,8a_{t-1} - 0,3a_{t-2}$$

## C. Model Auto Regressive Moving Average (ARMA)

Model AR dan model MA tidak selalu sesuai digunakan untuk semua jenis data, sehingga diperlukan penggabungan dari dua model ini. Model gabungan dari AR dan MA untuk jenis data yang sudah stasioner dapat menggunakan model ARMA atau dapat dituliskan dengan ARIMA( $p,0,q$ ).

Persamaan matematis dari model ARMA adalah sebagai berikut.

$$\hat{z}_t = \phi_1 \hat{z}_{t-1} + \phi_2 \hat{z}_{t-2} + \dots + \phi_p \hat{z}_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (4.4)$$

Jenis data yang menggunakan model ini adalah data yang memiliki plot ACF dan PACF menurun secara eksponensial.

**d.**

### **Model Auto Regressive Integrated Moving Average (ARIMA)**

Pola data *time series* tidak selalu berada pada persekitaran garis yang sama, karena terdapat beberapa pola yang memiliki *trend* sehingga datanya belum stasioner. Perbedaan pola data yang stasioner dan belum stasioner ditampilkan pada Gambar 4.1 (a) dan (b). Jika data belum stasioner maka harus dilakukan *differencing* sebelum membentuk model ARIMA. Persamaan matematis untuk model ARIMA sama seperti pada model ARMA, perbedaannya terletak pada penulisan nilai parameter *d*.

Jika pada model ARMA nilai  $d = 0$ , maka pada model ARIMA nilai  $d$  menyesuaikan berapa kali data harus di-*differencing*. Misalkan suatu data di-*differencing* dua kali, maka penulisan untuk modelnya adalah ARIMA(p,2,q).







## 4.5 LANGKAH-LANGKAH ANALISIS DALAM MODEL ARIMA

Untuk mendapatkan model ARIMA, langkah-langkah yang harus dilakukan setelah tahap pengumpulan data adalah sebagai berikut.

### a. Tahap Identifikasi



Pada tahap identifikasi dilakukan deteksi stasioneritas data. Jika data sudah stasioner maka dapat dilanjutkan ke tahap selanjutnya, namun jika data belum stasioner maka harus dilakukan *differencing* agar data stasioner. Setelah data stasioner, dilakukan plot ACF dan PACF untuk menentukan pola dari data, dan menentukan ordo dari model ARIMA.

Ada dua jenis pola data untuk ACF dan PACF, yaitu *cut off* dan *dies down*. Untuk menentukan model yang sesuai dapat dilihat kriteria ACF dan PACF seperti pada Tabel 4.2. Model yang terbentuk pada tahap identifikasi biasanya lebih dari satu model.

### b. Tahap Estimasi Parameter Model

Setelah ordo  $p$  dan  $q$  ditentukan pada tahap identifikasi, tahap selanjutnya adalah menentukan nilai parameter dari model yang terbentuk. Metode estimasi parameter menggunakan kuadrat terkecil atau estimasi parameter non-linear. Penghitungan matematis dengan metode ini memerlukan kemampuan matematis yang tinggi, sehingga untuk menentukannya digunakan bantuan software Minitab.

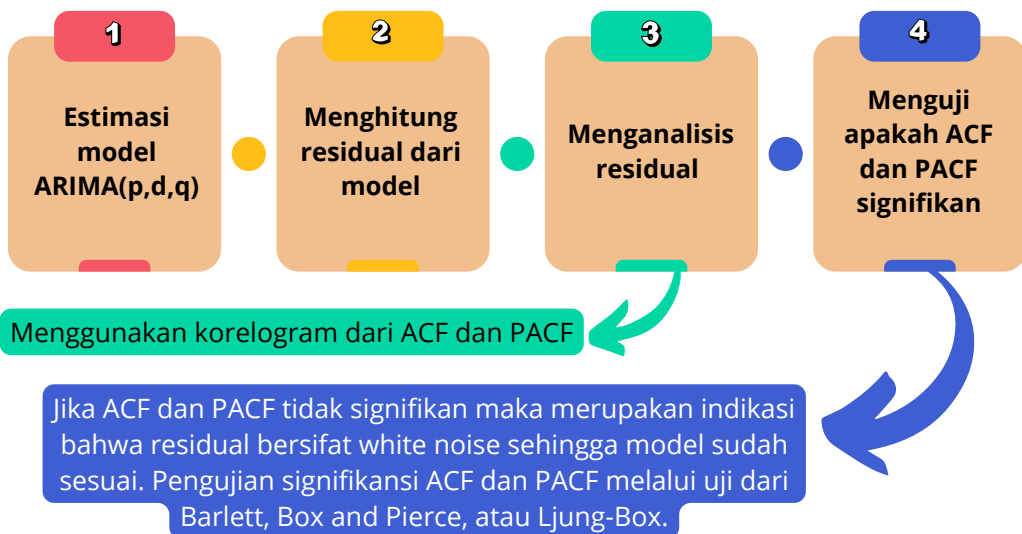
Untuk menentukan parameter yang dapat digunakan, dipilih parameter yang hasil pengujiannya signifikan. Adapun hipotesis yang digunakan untuk pengujian parameter adalah sebagai berikut.

$H_0$  : parameter tidak signifikan  
 $H_1$  : parameter signifikan

Daerah penolakan :  $H_0$  ditolak jika nilai p-value <  $\alpha$   
Harapannya adalah  $H_0$  ditolak sehingga parameter model signifikan

### C. Tahap Evaluasi Model

Model yang terbentuk dari estimasi model selanjutnya dievaluasi dengan menggunakan beberapa kriteria untuk mendapatkan model yang terbaik. Yang dievaluasi adalah residual dari model yang terbentuk. Jika residual bersifat white noise (bersifat acak) maka model yang terbentuk sudah tepat, namun jika residual tidak white noise maka perlu dilakukan penyusunan model lain yang lebih tepat. Langkah-langkah dalam melakukan evaluasi model adalah sebagai berikut.





## d. Tahap Prediksi atau Peramalan

Tahap prediksi merupakan tahapan akhir dari proses peramalan dengan ARIMA. Model yang dapat digunakan untuk meramalkan harus sudah lolos uji kelayakan model, karena akan mempengaruhi nilai ramalan yang dihasilkan. Perkiraan atau peramalan ini dapat digunakan untuk mengetahui gambaran data di periode yang akan datang, namun perlu diingat bahwa ARIMA sesuai jika digunakan untuk peramalan jangka pendek.



### 4.6 PENGUJIAN MODEL ARIMA

Dalam menentukan model yang sesuai, selain diuji dengan menggunakan *white noise* pada residual, juga dilihat berdasarkan signifikansi dari parameter  $p$  dan  $q$ . Perhitungan residual adalah melihat apakah *error* tidak bersifat autokorelasi, berdistribusi normal, dan memenuhi asumsi homoskedastisitas.

Pengujian auto korelasi dapat dilakukan dengan menggunakan Ljung-Box Chi Square Statistics dan dilihat berapakah nilai  $p$ -value dari hasil pengujian tersebut. Nilai dari  $p$ -value akan dibandingkan dengan nilai  $\alpha$ , adapun nilai  $\alpha$  yang diambil antara 5% sampai dengan 10%. Uji hipotesis yang digunakan untuk auto korelasi adalah sebagai berikut.

$H_0$  : residual data tidak terdapat autokorelasi

$H_1$  : residual data terdapat autokorelasi

Jika nilai  $p$ -value pada Ljung Box  $> \alpha$ , maka  $H_0$  diterima artinya tidak terjadi autokorelasi pada residual.

Pengujian distribusi normal dapat dilakukan dengan uji Kolmogorov Smirnov. Dalam pengujian menggunakan Kolmogorov Smirnov nilai yang digunakan adalah nilai *p-value* yang dibandingkan dengan  $\alpha$ . Adapun hipotesis pengujian distribusi normal adalah sebagai berikut.

$H_0$  : residual berdistribusi normal  
 $H_1$  : residual tidak berdistribusi normal

Jika nilai *p-value* pada uji Kolmogorov Smirnov  $> \alpha$ , maka  $H_0$  diterima artinya residual berdistribusi normal.

Pengujian homoskedastisitas dilakukan untuk melihat apakah variasi memenuhi asumsi homogen atau tidak. Pengujian ini dilakukan dengan melihat plot ACF dan PACF dari residual. Jika pada plot ACF dan PACF di awal terdapat lag yang signifikan, maka residual tidak konstan, namun jika sebaliknya maka residual konstan atau homogen.



## 4.7 PERHITUNGAN NILAI ERROR DARI MODEL ARIMA

Dalam menghitung *error* ada beberapa rumus yang dapat digunakan, salah satunya yang dibahas dalam sub-bab ini adalah *Mean Absolute Percentage Error* (MAPE).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right| \times 100\% \quad (4.5)$$

$n$  : jumlah data

$A_i$  : data aktual

$F_i$  : data hasil peramalan

Data hasil peramalan diperoleh dari model peramalan yang sudah dibentuk, sedangkan data aktual diperoleh dari data *testing*. Model yang dipilih adalah model yang memiliki nilai MAPE terkecil dan model inilah yang akan digunakan untuk peramalan periode-periode selanjutnya.



## 4.8 ANALISIS DATA ARIMA DENGAN MINITAB

Dalam menentukan nilai parameter dalam model ARIMA diperlukan perhitungan matematika yang cukup rumit, sehingga untuk mempermudah digunakan software salah satunya adalah Minitab. Dalam sub-bab ini dijelaskan mengenai penerapan model ARIMA untuk meramalkan data. Data yang digunakan adalah data permintaan darah (golongan darah O) yang masuk di UPTD Kota XYZ. Adapun datanya ditampilkan pada lampiran 1.

Ternyata perhitungan menggunakan ARIMA sangat rumit ya!

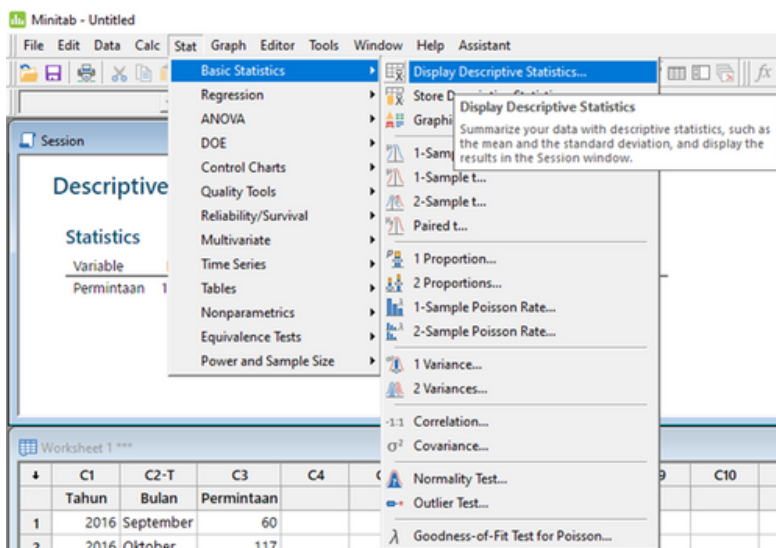
Tenang saja, kita punya banyak software, salah satunya Minitab ©



Langkah-langkah analisis data dengan menggunakan model ARIMA adalah sebagai berikut.

## a. Melakukan analisis deskriptif untuk data

Analisis deskriptif digunakan untuk melihat pola data. Pada minitab pilih menu Stat → Basic Statistics → Display Descriptive Statistics seperti pada gambar berikut.



Output statistika deskriptif untuk data permintaan darah adalah sebagai berikut

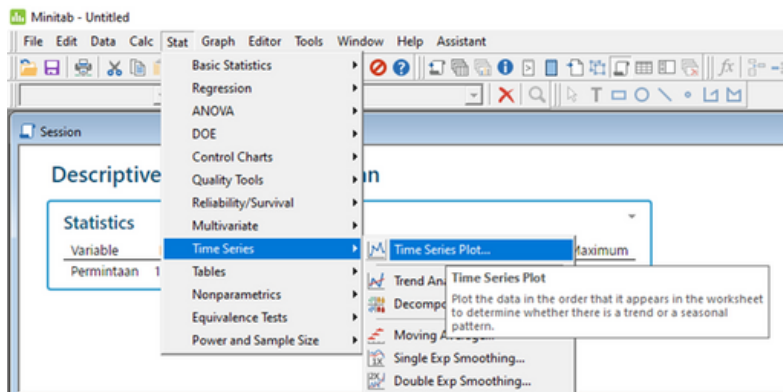
Statistics								
Variable	Mean	SE Mean	StDev	Minimum	Q1	Median	Q3	Maximum
Permintaan	156,16	6,09	45,95	60,00	129,00	154,00	185,00	267,00

(sumber: pengolahan data)


Berdasarkan output tersebut, rata-rata permintaan darah Golongan O adalah 157 kantong dengan simpangan 46 kantong.

## b. Membuat Plot Time Series untuk Data Permintaan Golongan Darah

Plot ini digunakan untuk melihat apakah data sudah stasioner atau belum. *Plot time series* di Minitab dibuat melalui menu Stat → Time Series → Time Series Plot seperti pada tampilan menu di bawah ini.

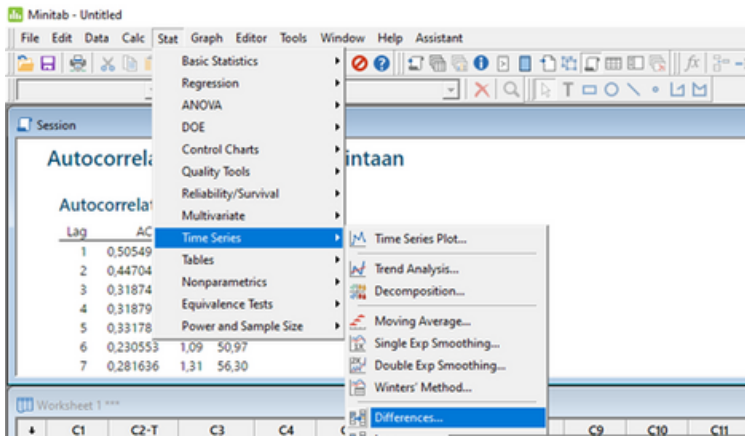


Hasil *plot time series* adalah sebagai berikut.

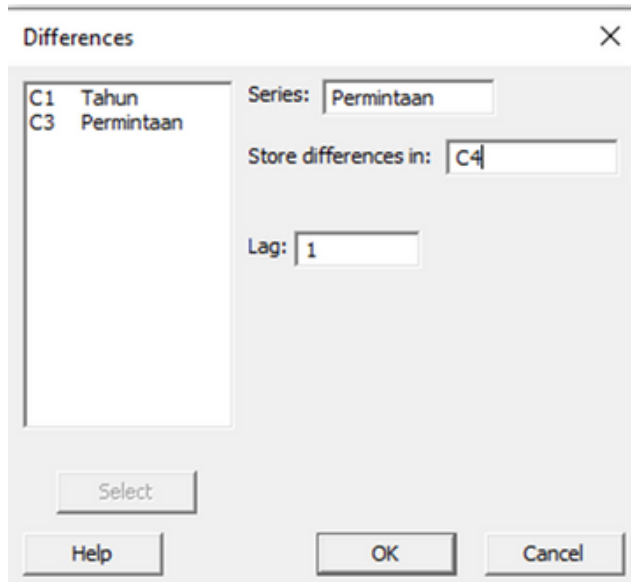


(sumber: pengolahan data)

Berdasarkan pada *plot time series* tampak bahwa data permintaan belum stasioner karena nilai permintaan tidak berada pada persekitaran garis yang sama, sehingga harus dilakukan differencing sebelum menentukan orde model dari plot ACF dan PACF. Untuk melakukan *differencing* dengan menggunakan Minitab adalah melalui menu Stat → Time Series → Differences seperti yang ada pada gambar di bawah ini.

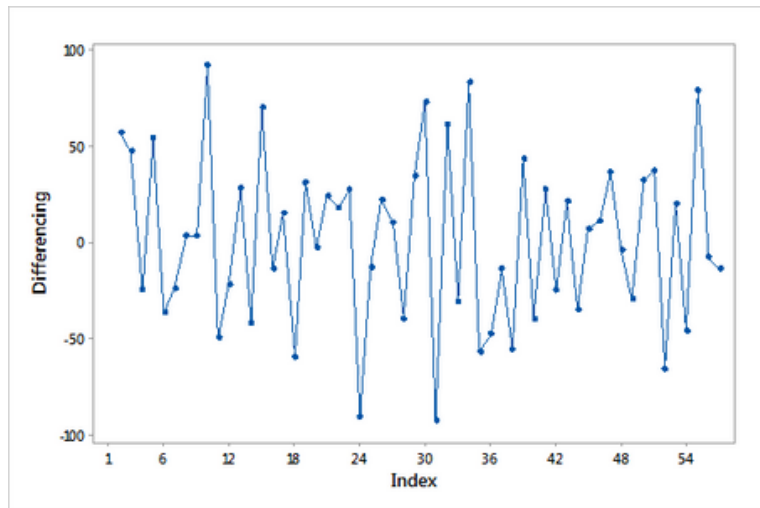


Kotak dialog dari sub menu Differences adalah sebagai berikut.





Pada bagian **Series** diisi dengan data yang akan di-*differencing*, bagian **Store differences in** diisi dengan kolom yang digunakan untuk menempatkan hasil *differencing*, bagian *Lag* diisi dengan beda waktu yang digunakan untuk *differencing* yang biasanya dimulai dengan *Lag* 1. Hasil dari *differencing* inilah yang selanjutnya digambarkan grafik *time series* nya, seperti yang ditampilkan pada gambar berikut.



(sumber: pengolahan data)

Berdasarkan gambar di atas, tampak bahwa data sudah stasioner sehingga dapat dilanjutkan pada langkah selanjutnya yaitu menentukan orde model ARIMA menggunakan plot ACF dan PACF.

### C. Menentukan orde model ARIMA berdasarkan plot ACF dan PACF

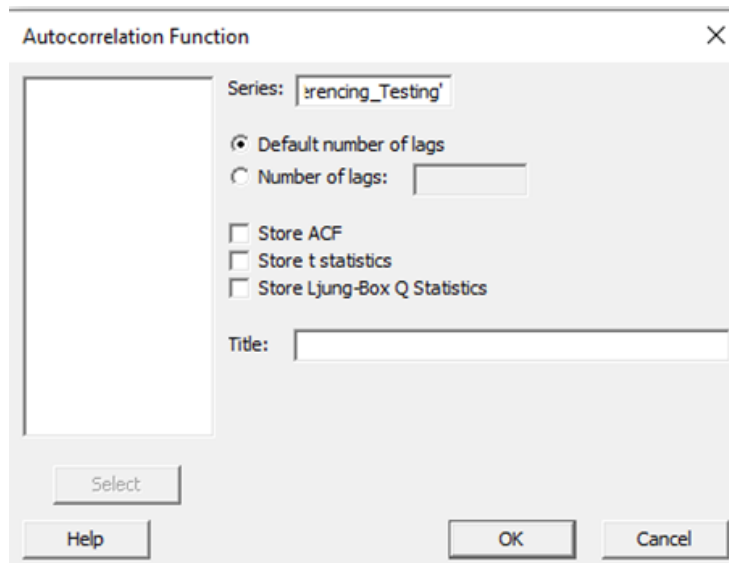
Untuk membuat model ARIMA, data dibagi menjadi dua yaitu data *training* dan data *testing*. Data yang digambarkan ACF dan PACF adalah data *training* (data tahun 2016 sampai 2020) sekaligus digunakan untuk membuat model ARIMA.

## Plot ACF dan PACF

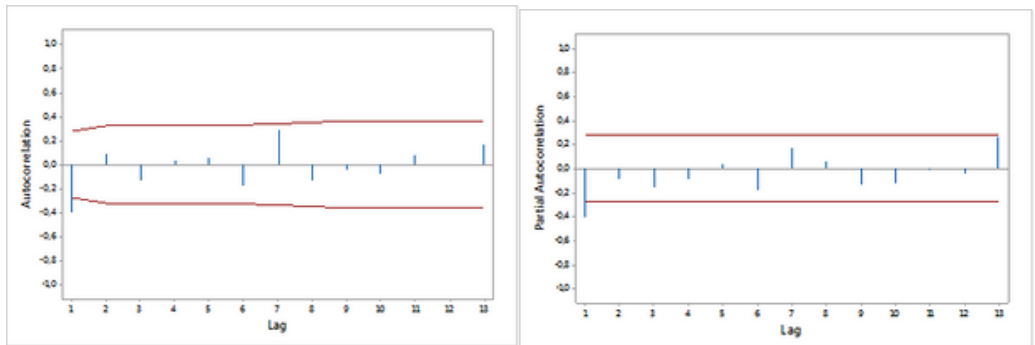
Plot ACF pada Minitab dapat dilakukan pada menu Stat → Time Series → Autocorrelation, sedangkan plot PACF dapat dilakukan pada menu Stat → Time Series → Partial Autocorrelation.

Pada bagian **Series** diisi dengan data testing yang telah di-*differencing* digunakan untuk membentuk model. Jumlah *lags* yang dimunculkan pada plot ACF dapat menyesuaikan kebutuhan dan biasanya yang dipilih adalah **Default number of lags**, namun jika membutuhkan *lags* sampai dengan jumlah tertentu maka dapat diisi pada menu **Number of lags**. Output yang akan ditampilkan dapat dipilih dengan cara mencentang ACF, t-statistics, dan Ljung-Box Q untuk melihat *lags* mana yang signifikan.

Tampilan dari kotak dialog Autocorrelation Function adalah sebagai berikut.



Hasil plot ACF dan PACF untuk data pada Lampiran 1 adalah sebagai berikut.



Berdasarkan plot ACF di atas dapat diketahui bahwa setelah *lag* 1 sudah tidak signifikan. Hasil yang sama diperoleh dari plot PACF dimana setelah *lag* 1 signifikan dan *lag* selanjutnya tidak signifikan. Berdasarkan plot ACF dan PACF maka model yang mungkin terbentuk adalah ARIMA(1,1,0) atau ARIMA(0,1,1) dengan nilai karena data di-*differencing* satu kali.

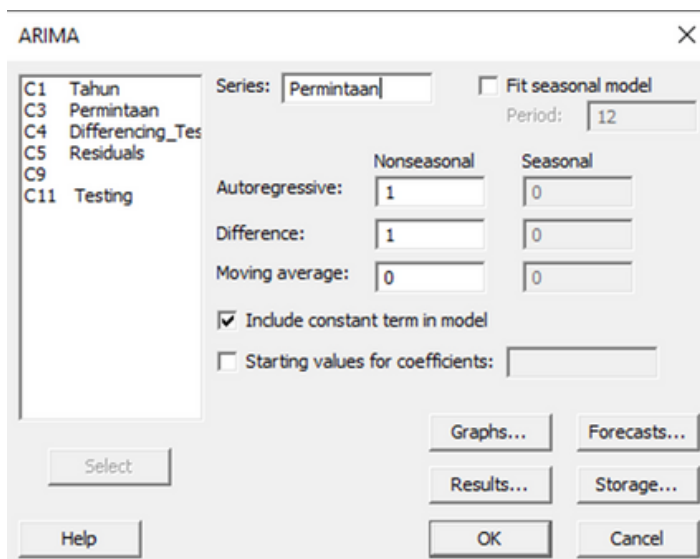
#### d. Penentuan Model Terbaik

Dalam menentukan model terbaik, tahapan yang dilakukan adalah pengujian signifikansi parameter, pengujian residual, dan membandingkan nilai MAPE.

#### Pengujian Signifikansi Parameter

Model terbaik ditentukan berdasarkan signifikansi parameter, kriteria residual, dan nilai MAPE. Misalkan yang diuji adalah ARIMA(1,1,0).

Untuk menguji signifikansi parameter, dapat digunakan Minitab melalui menu Stat → Time Series → ARIMA. Tampilan dari menu ini adalah sebagai berikut.



- ▶ Pada bagian **Series** diinputkan data asli yang digunakan sebagai data training, bukan menggunakan data *differencing* karena data *differencing* hanya digunakan untuk menentukan orde model.
- ▶ Karena tidak ada efek musiman, maka yang diisi hanya bagian **Nonseasonal** saja. Model yang diuji adalah ARIMA(1,1,0) maka pada bagian **Autoregressive** diisi dengan 1, **Difference** diisi dengan 1, dan **Moving Average** diisi dengan 0.

Hasil dari pengujian signifikansi parameter adalah sebagai berikut.

**Final Estimates of Parameters**

Type	Coef	SE Coef	T-Value	P-Value
AR 1	-0,435	0,132	-3,30	0,002
Constant	1,39	5,68	0,24	0,808

Berdasarkan nilai *p-value* dapat disimpulkan bahwa parameter AR signifikan karena nilai *p-value* < 0,05 sehingga dapat dilanjutkan pada tahapan pengujian asumsi klasik.

## Pengujian Asumsi Klasik pada Residual Model

Pengujian asumsi klasik dilakukan pada residual model, sehingga diperlukan data residual dari model. Untuk memunculkan data residual pada model, dipilih kotak **Storage** yang ada pada tampilan ARIMA.

Pilih Storage → Centang pilihan residuals → Klik OK.

Adapun pengujian asumsi klasik adalah sebagai berikut.

1

### Pengujian Autokorelasi

Pengujian autokorelasi dengan menggunakan L-Jung Box yang secara default akan muncul dalam output ARIMA. Berdasarkan data yang dianalisis, hasil dari L-jung Box nya adalah sebagai berikut.

#### Modified Box-Pierce (Ljung-Box) Chi-Square Statistic

Lag	12	24	36	48
Chi-Square	11,31	39,72	47,28	57,08
DF	10	22	34	46
P-Value	0,334	0,012	0,065	0,127

Berdasarkan nilai *p-value* diketahui bahwa nilainya lebih dari  $\alpha$  (5%) sehingga  $H_0$  diterima, artinya tidak terjadi autokorelasi pada residual.

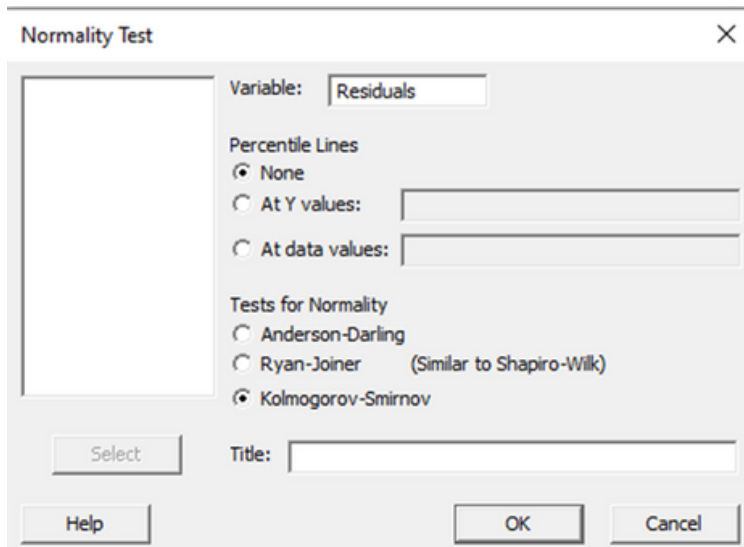
2

### Pengujian Asumsi Distribusi Normal


Pengujian distribusi normal menggunakan metode Kolmogorov Smirnov. Untuk menguji asumsi distribusi normal dengan

Minitab adalah dengan memilih menu Stat → Basic Statistics → Normality Test.

Tampilan dari uji normalitas adalah sebagai berikut.



Pada menu **Variable** diisi dengan data **residuals** dari model. Pada bagian Tests for Normality pilih Kolmogorov-Smirnov, lalu klik OK. Hasil dari pengujian distribusi normal adalah sebagai berikut.




Dengan menggunakan  $\alpha = 5\%$  diketahui bahwa  $p\text{-value} > \alpha$  sehingga residual berdistribusi normal.

### 3

## Pengujian Homoskedastisitas

Pengujian homoskedastisitas bertujuan untuk melihat apakah residual homogen untuk setiap *lag*. Pengujian ini menggunakan plot ACF dan PACF dari residual. Adapun cara pengujiannya adalah dengan menggambarkan ACF dan PACF menggunakan Minitab dengan cara yang sama dengan plot ACF dan PACF saat menentukan orde dari model ARIMA. Hasil plot ACF dan PACF untuk data residual adalah sebagai berikut.



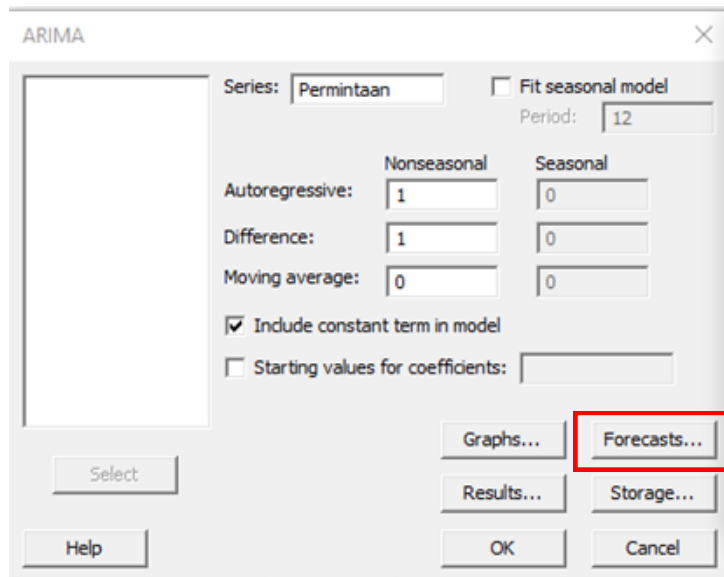
Berdasarkan gambar plot ACF dan PACF di atas, residual memenuhi asumsi homoskedastisitas karena dari *lag* pertama tidak ada yang signifikan atau tidak ada *lag* yang keluar dari garis batas.

### e. Menggunakan Model untuk Meramalkan

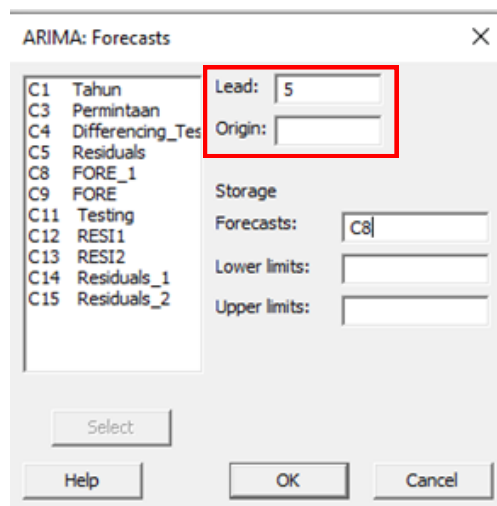
Langkah selanjutnya setelah asumsi residual terpenuhi adalah menggunakan model untuk meramalkan, dimana dalam hal ini salah satu model yang terbentuk adalah ARIMA(1,1,0). Hasil peramalan dengan model ini akan digunakan untuk menghitung nilai MAPE, dimana data aktualnya adalah *data testing* yaitu data permintaan darah pada periode Januari sampai dengan Mei 2021 (Lampiran 1).

Untuk meramalkan dengan menggunakan Minitab langkahnya adalah sebagai berikut.

- Memilih menu Stat → Time Series → ARIMA
- Kotak dialog yang muncul adalah sebagai berikut



Data yang digunakan adalah data permintaan, dan pada menu Forecasts merupakan menu yang digunakan untuk menentukan berapa banyak data yang diramal dan mulai periode ke berapa data akan diramalkan.





Dalam contoh soal ini, jumlah data *training* adalah 52 data dan data *testing* yang akan dibandingkan ada 5 data, sehingga pada bagian **Lead** diisi dengan 5 (karena akan meramalkan lima periode) dan pada bagian **Origin** dapat dikosongi atau diisi dengan 52 (karena data terakhir adalah periode ke-52). Jika peramalan bukan dimulai dari data terakhir, maka Origin diisi sesuai dengan data awal yang dijadikan acuan peramalan. Pada bagian **Storage** digunakan untuk menampilkan data hasil peramalan (dapat dikosongkan).

➤ Setelah semua bagian diisi, lalu klik OK dan akan muncul nilai peramalan sebagai berikut.

Periode	Bulan	Hasil Peramalan	Nilai Asli
53	Januari 2021	136	126
54	Februari 2021	124	80
55	Maret 2021	131	159
56	April 2021	129	151
57	Mei 2021	131	137

## f. Menghitung Nilai MAPE

Nilai MAPE dari model ARIMA(1,1,0) jika dihitung dengan menggunakan Ms.Excel hasilnya adalah sebagai berikut.

Periode	Hasil Peramalan ( $F_i$ )	Nilai Asli ( $A_i$ )	$\left  \frac{A_i - F_i}{A_i} \right $
53	136	126	Januari 2021
54	124	80	Februari 2021
55	131	159	Maret 2021
56	129	151	April 2021
57	131	137	Mei 2021

Nilai MAPE dari model ARIMA(1,1,0) jika dihitung dengan menggunakan Ms.Excel hasilnya adalah sebagai berikut.

$$MAPE = \frac{1}{5} (0,858) \times 100\% = 17,17\%$$

Dengan cara yang sama (poin d sampai dengan f) dilakukan perhitungan untuk model ARIMA(0,1,1). Jika parameter model signifikan dan residual memenuhi semua asumsi, maka model yang dipilih adalah model yang memiliki nilai MAPE lebih kecil.



# LATIHAN SOAL

Perhatikan data pada Lampiran 2 (Data Permintaan Golongan Darah AB). Lakukan analisis sebagai berikut.

a. Gambarkan plot *time series* dari data pada Lampiran 2

---

---

---

---

---

b. Lakukan analisis apakah data pada Lampiran 2 sudah stasioner, jika sudah stasioner maka gambarkan ACF dan PACF nya, namun jika belum maka lakukan differencing

---

---

---

---

---

c. Tentukan model yang sesuai berdasarkan plot ACF dan PACF

---

---

---

---

---

d. Lakukan pengujian signifikansi parameter dan pengujian residual dari semua model yang terbentuk

---

---

---

---

---

e. Hitunglah nilai MAPE untuk setiap model dan berikan kesimpulan manakah model yang paling sesuai

---

---

---

---

---

f. Gunakan model yang paling sesuai untuk meramalkan permintaan darah golongan AB pada bulan Januari sampai dengan Mei 2021.


---

---

---

---

---



# PERFORMANSI DALAM PERAMALAN




## Tujuan Instruksional

1. Mahasiswa dapat memahami jenis-jenis persamaan untuk menghitung error dalam peramalan
2. Mahasiswa dapat menghitung error dalam peramalan menggunakan persamaan yang sesuai




### 5.1 ERROR DALAM PERAMALAN

Metode peramalan merupakan salah satu metode dalam statistika yang digunakan untuk memprediksi. Beberapa metode peramalan dapat digunakan sesuai dengan plot dari data, sehingga model peramalan diharapkan dapat digunakan untuk meramalkan data pada periode selanjutnya. Ilustrasi error dalam peramalan adalah sebagai berikut.



**Gambar 5.1** Contoh Plot Data Aktual dan Data Peramalan

Pada Gambar 5.1 terdapat dua jenis data yaitu data aktual dan data peramalan. Data peramalan diperoleh dari model peramalan yang telah disusun dengan menggunakan data *training*, sedangkan data aktual yang dibandingkan dengan data peramalan adalah data *testing*. *Error* pada peramalan adalah selisih nilai antara data aktual dengan data hasil peramalan, dimana dalam menyusun model peramalan diharapkan akan menghasilkan nilai *error* yang kecil.



Error secara umum adalah selisih antara data aktual dengan data ramalan. Error relatif merupakan selisih antara data aktual dengan data ramalan yang dibandingkan dengan data aktual, sehingga dengan menggunakan *error* relatif dapat diketahui bagaimana perbandingan selisihnya terhadap data asli.

Akurasi merupakan ketepatan tingkat peramalan. Persamaan matematisnya adalah sebagai berikut.

**A. Persamaan Error**

$$\text{Error} = \text{Aktual}_t - \text{Peramalan}_t$$

**B. Persamaan Error Relatif**

$$\text{Error Relatif} = \frac{\text{Aktual}_t - \text{Peramalan}_t}{\text{Aktual}_t} \times 100$$

**C. Persamaan Akurasi**

$$\text{Akurasi} = \left( 1 - \frac{\text{Aktual}_t - \text{Peramalan}_t}{\text{Aktual}_t} \right) \times 100$$



### Contoh 5.1

Diketahui berdasarkan data aktual, jumlah permintaan pada periode 10 adalah 2500, dan berdasarkan hasil peramalan adalah 2000. Hitunglah nilai error, error relatif, dan akurasi

Penyelesaian:

$$\text{Aktual}_{10} = 2500$$

$$\text{Peramalan}_{10} = 2000$$

a. Menghitung Nilai Error

$$\text{Error} = \text{Aktual}_t - \text{Peramalan}_t = \text{Aktual}_{10} - \text{Peramalan}_{10}$$

$$\text{Error} = 2500 - 2000 = 500$$

b. Menghitung Nilai Error Relatif

$$\text{Error Relatif} = \frac{\text{Aktual}_t - \text{Peramalan}_t}{\text{Aktual}_t} \times 100$$

$$\text{Error Relatif} = \frac{2500 - 2000}{2500} \times 100 = 20\%$$

c. Menghitung Nilai Akurasi

$$\text{Akurasi} = \left( 1 - \frac{\text{Aktual}_t - \text{Peramalan}_t}{\text{Aktual}_t} \right) \times 100$$

$$\text{Akurasi} = \left( 1 - \frac{2500 - 2000}{2500} \right) \times 100$$


$$\text{Akurasi} = (1 - 0,2) \times 100 = 80\%$$



## 5.2 AKURASI DALAM PERAMALAN

Akurasi data hasil peramalan menunjukkan keakuratan model dalam peramalan. Model peramalan dapat bersifat bias sehingga kurang sesuai digunakan untuk meramalkan data pada periode selanjutnya.

Model peramalan yang sesuai adalah model peramalan yang tidak bias dan presisi. Gambar 5.2 memberikan gambaran bagaimanakah model yang presisi dan memiliki akurasi yang tinggi.



**Gambar 5.2** Ilustrasi Ketepatan Data Peramalan

Pada Gambar 5.2, hasil peramalan yang diharapkan adalah yang memiliki tingkat akurasi tinggi dan tingkat presisi yang juga tinggi. Akurasi diukur berdasarkan selisih antara hasil peramalan dengan nilai aktual, sedangkan presisi menunjukkan kemampuan model peramalan memberikan hasil yang konsisten.

Dalam memilih model peramalan yang sesuai, terdapat beberapa ukuran atau nilai yang dapat dijadikan salah satu pertimbangan. Nilai tersebut adalah nilai *error* dari hasil peramalan. Secara umum, semakin kecil nilai *error* maka semakin baik suatu model. Evaluasi kesalahan peramalan dapat dihitung dengan menggunakan *Mean Square Error* (MSE), *Mean Absolute Deviation* (MAD), *Mean Absolute Percentage Error* (MAPE).

a. *Mean Square Error* (MSE)

MSE kurang familiar digunakan dalam peramalan karena sulit untuk diinterpretasikan. Selain itu, MSE akan bernilai besar saat digunakan untuk data yang memiliki nilai besar. Persamaan untuk menentukan nilai MSE adalah sebagai berikut.

$$MSE = \frac{1}{N} \sum_{t=1}^N (A_t - F_t)^2 \quad (5.1)$$

dengan:

N : jumlah data

$A_t$  : data aktual pada periode ke-t

$F_t$  : data peramalan pada periode ke-t

b. *Mean Absolute Deviation* (MAD)

MAD mudah untuk divisualisasikan dan intuitif, namun MAD berupa nilai, bukan berupa persentase. Persamaan yang digunakan untuk menentukan MAD adalah sebagai berikut.

$$MAD = \frac{1}{N} \sum_{t=1}^N |A_t - F_t| \quad (5.2)$$

b. *Mean Absolute Percentage Error* (MAPE)

MAPE merupakan nilai pengukur error dalam peramalan yang paling banyak digunakan. MAPE mengukur selisih antara data aktual dengan data peramalan, dimana data aktual yang digunakan adalah data testing. Kelebihan nilai MAPE salah satunya adalah ditampilkan dalam persentase sehingga lebih mudah untuk dibandingkan antara satu model peramalan dengan model yang lainnya. Nilai MAPE mudah untuk diinterpretasikan terutama untuk orang awam.

Persamaan untuk menentukan nilai MAPE adalah sebagai berikut.

$$MAPE = \left( \frac{1}{N} \sum_{t=1}^N \frac{|A_t - F_t|}{A_t} \right) \times 100 \quad (5.3)$$

Kekurangan dari MAPE adalah jika nilai aktual bernilai nol maka tidak akan terdefinisi, sehingga jika pola datanya adalah *intermittent* perhitungan *error* dengan MAPE kurang sesuai, karena pada data *intermittent* nilai data adalah nol di beberapa periode. Jika data tidak memiliki nilai nol, maka MAPE memberikan nilai yang paling mudah digunakan untuk menginterpretasikan *error*. Interpretasi hasil peramalan berdasarkan pada nilai MAPE dijelaskan pada Tabel 5.1

**Tabel 5.1** Interpretasi nilai MAPE terhadap Hasil Peramalan

Nilai MAPE (%)	Interpretasi
≤ 10	Hasil peramalan sangat akurat
10 - 20	Hasil peramalan baik
20 - 50	Hasil peramalan layak (cukup baik)
> 50	Hasil peramalan tidak akurat



## 5.2 AKURASI DALAM PERAMALAN

Untuk menentukan nilai *error* dengan menggunakan MSE, MAD dan MAPE dapat dikerjakan dengan menggunakan Microsoft Excel. Berikut adalah contoh data aktual yaitu data permintaan produk dan data hasil peramalan yang ditampilkan pada Tabel 5.2.

**Tabel 5.2** Contoh Data Permintaan

Periode	Data Aktual	Data Peramalan (Metode A)	Data Peramalan (Metode B)	Data Peramalan (Metode C)
1	15	13,0	12,0	12,4
2	16	14,5	13,7	14,0
3	17	15,5	15,0	15,2
4	19	16,5	16,0	16,2
5	21	18,0	17,3	17,7
6	23	20,0	19,0	19,4

Pada Tabel 5.2 terdapat data peramalan dengan menggunakan metode A, B, dan C. Dalam sub-bab ini akan dijelaskan cara menghitung nilai MSE, MAD, dan MAPE untuk data peramalan dari metode A. Penghitungan nilai *error* untuk data peramalan dari metode B dan metode C dapat ditentukan dengan cara yang sama.

### Perhitungan Nilai MSE

Untuk menghitung nilai MSE, ada beberapa nilai yang diperlukan yaitu sebagai berikut.

**Tabel 5.3** Data Perhitungan MSE

Periode	Data Aktual	Data Peramalan (Metode A)	$A_t - F_t$	$(A_t - F_t)^2$
1	15	13,0	2,00	4,00
2	16	14,5	1,50	2,25
3	17	15,5	1,50	2,25
4	19	16,5	2,50	6,25
5	21	18,0	3,00	9,00
6	23	20,0	3,00	9,00
<b>Jumlah</b>				<b>32,75</b>

Data yang digunakan adalah 6 periode, sehingga untuk mendapatkan nilai MSE dari Metode Peramalan A adalah sebagai berikut.

$$MSE = \frac{1}{N} \sum_{t=1}^N (A_t - F_t)^2 = \frac{1}{6} \sum_{t=1}^6 (A_t - F_t)^2 = \frac{32,75}{6} = 5,46$$

**Perhitungan Nilai MAD**

Untuk menghitung nilai MAD, ada beberapa nilai yang diperlukan yaitu sebagai berikut.

**Tabel 5.4** Data Perhitungan MAD

Periode	Data Aktual	Data Peramalan (Metode A)	$ A_t - F_t $
1	15	13,0	2,00
2	16	14,5	1,50
3	17	15,5	1,50
4	19	16,5	2,50
5	21	18,0	3,00
6	23	20,0	3,00
<b>Jumlah</b>			13,5

Data yang digunakan adalah 6 periode, sehingga untuk mendapatkan nilai MAD dari Metode Peramalan A adalah sebagai berikut

$$MAD = \frac{1}{N} \sum_{t=1}^N |A_t - F_t| = \frac{1}{6} \sum_{t=1}^6 |A_t - F_t| = \frac{13,5}{6} = 2,25$$

## Perhitungan Nilai MAPE

Untuk menghitung nilai MAPE, ada beberapa nilai yang diperlukan yaitu sebagai berikut.

**Tabel 5.5** Data Perhitungan MAPE

Periode	Data Aktual	Data Peramalan (Metode A)	$ A_t - F_t $	$\frac{ A_t - F_t }{A_t}$
1	15	13,0	2,00	0,13
2	16	14,5	1,50	0,09
3	17	15,5	1,50	0,09
4	19	16,5	2,50	0,13
5	21	18,0	3,00	0,14
6	23	20,0	3,00	0,13
<b>Jumlah</b>				0,72

Data yang digunakan adalah 6 periode, sehingga untuk mendapatkan nilai MAPE dari Metode Peramalan A adalah sebagai berikut.

$$\begin{aligned}
 MAPE &= \left( \frac{1}{N} \sum_{t=1}^N \frac{|A_t - F_t|}{A_t} \right) \times 100 = \left( \frac{1}{6} \sum_{t=1}^6 \frac{|A_t - F_t|}{A_t} \right) \times 100 \\
 &= \frac{0,72}{6} \times 100 = 12\%
 \end{aligned}$$

**Tabel 5.6** Perbandingan Ukuran *Error* untuk Beberapa Model Peramalan

Ukuran Error	Metode A	Metode B	Metode C
MSE	5,46	9,50	7,62
MAD	2,25	3,00	2,68
MAPE	12,00%	16,16%	14,42%

Model peramalan yang dipilih adalah model peramalan yang memiliki nilai MSE, MAD, dan MAPE terkecil, sehingga berdasarkan tabel di atas metode peramalan terbaik adalah metode A.



# LATIHAN SOAL

1. Jelaskan bagaimana dampak besarnya nilai error terhadap hasil dalam peramalan.

---

---

---

---

---

2. Berikut ini adalah data permintaan produk selama 10 bulan yang akan digunakan untuk meramalkan periode selanjutnya.

Periode	Data Permintaan
1	143
2	152
3	161
4	139
5	137
6	174
7	142
8	141
9	162
10	180

- a. Hitunglah nilai peramalan pada periode 1 sampai dengan periode 10 dengan menggunakan metode MA(2), WMA(3) dengan bobot masing-masing 0,4 ; 0,3 ; 0,3 dan Eksponensial smoothing tunggal dengan nilai  $\alpha = 0,2$ .

---

---

---

---

---

- b. Gambarkan data aktual dan hasil peramalan dari tiga metode dalam satu grafik.

---

---

---

---

---

- c. Berdasarkan grafik pada bagian b, manakah metode yang paling mendekati data aktual.

---

---

---

---

---

d. Hitunglah nilai MSE, MAD, dan MAPE untuk masing-masing metode.

---

---

---

---

---

e. Berdasarkan hasil perhitungan pada bagian d, manakah metode yang paling sesuai digunakan untuk peramalan data tersebut. Apakah hasilnya sama dengan bagian c?

---


---

---

---

---





# METODE PERAMALAN SEASONAL



## Tujuan Instruksional

1. Mahasiswa memahami konsep musiman pada data peramalan.
2. Mahasiswa dapat menyusun model yang sesuai untuk data peramalan yang memiliki pola musiman.
3. Mahasiswa dapat menentukan model peramalan data musiman yang paling sesuai.



### 6.1 METODE DEKOMPOSISI




Model peramalan yang didapatkan dari metode dekomposisi, yaitu suatu metode peramalan yang memisahkan komponen musiman (*seasonal*), komponen *trend*, komponen siklis, dan komponen *error*. Metode ini sesuai digunakan untuk data yang memiliki pola *trend* sekaligus ada efek musiman.

Persamaan matematika untuk model dekomposisi merupakan gabungan dari unsur musiman, unsur *trend*, dan unsur siklis. Peramalan dengan menggunakan metode dekomposisi ini meramalkan masing-masing komponen secara terpisah kemudian menggabungkannya setelah diperoleh model. Pada metode dekomposisi terdapat dua jenis pola data musiman yang menentukan model manakah yang sesuai. Berdasarkan pola data musimannya, dibagi menjadi dua model yaitu *seasonal multiplicative factors* dan *seasonal additive factors*.

a.

### Model Dekomposisi dengan *Seasonal Multiplicative Factors*

Model ini digunakan jika pola data musiman terdapat *trend* dan nilai musimannya memiliki besaran yang berbeda-beda. Contoh plot data ini seperti pada Gambar 6.1.



**Gambar 6.1** Plot Data *Seasonal Multiplicative Factors*

Persamaan matematika untuk model dekomposisi dengan *seasonal multiplicative factors* adalah sebagai berikut.

$$\text{Nilai Ramalan} = S_t + T_t + C_t + E_t$$

dengan:

$S_t$  = komponen musiman (*seasonal*)

$T_t$  = komponen *trend*

$C_t$  = komponen siklis


$E_t$  = *error*

b.

### Model Dekomposisi dengan *Seasonal Additive Factors*

Model ini digunakan jika data yang diramalkan memiliki efek musiman dan trend namun nilai musimannya memiliki besaran yang sama.





**Gambar 6.2** Plot Data *Seasonal Additive Factors*

Persamaan matematika untuk model dekomposisi dengan *seasonal additive factors* adalah sebagai berikut.

$$\text{Nilai Ramalan} = S_t \times T_t \times C_t \times E_t$$

dengan:

$S_t$  = komponen musiman (*seasonal*)

$T_t$  = komponen *trend*

$C_t$  = komponen siklis

$E_t$  = *error*



## 6.2 METODE SEASONAL - ARIMA (SARIMA)

Model Seasonal-ARIMA (SARIMA) merupakan model gabungan komponen ARIMA yaitu Auto-regressive dan Moving Average serta komponen musiman atau seasonal. Model ini sesuai untuk data yang memiliki data historis panjang dan lengkap, karena model ARIMA akan menghasilkan model yang fit jika memiliki data historis yang panjang. Model ini dapat menggabungkan unsur tren, musiman, autoregresi, dan moving average. Model musiman pada ARIMA dapat diidentifikasi melalui plot ACF pada data stasioner yang signifikan selain pada tiga lag awal, misalkan signifikan pada lag 12 maka terdapat indikasi adanya musiman dengan periode 12.

Orde dalam model SARIMA terdiri dari orde untuk ARIMA dan orde untuk komponen musiman. Dalam menentukan orde yang tepat untuk model SARIMA, langkah-langkah yang dilakukan sama seperti penentuan orde ARIMA yang telah dibahas pada Bab 4, perbedaannya adalah pada metode SARIMA dilakukan dua kali identifikasi orde yaitu untuk orde non musiman dan orde musiman. Notasi umum untuk model SARIMA adalah

$$\text{SARIMA}(p,d,q)(P,D,Q)^s$$

dengan:

- $p$  = orde AR untuk data non-musiman
- $d$  = *differencing* untuk data non-musiman
- $q$  = orde MA untuk data non-musiman
- $P$  = orde AR untuk data musiman
- $D$  = *differencing* untuk data musiman
- $Q$  = orde MA untuk data musiman
- $s$  = periode musiman



Penentuan orde AR dapat dilihat berdasarkan plot PACF, sedangkan orde MA dapat dilihat berdasarkan plot ACF. Orde *differencing* bersesuaian dengan berapa kali *differencing* dilakukan sampai diperoleh data yang stasioner dalam *mean*. Periode musiman diperoleh berdasarkan lag signifikan yang keluar dari plot ACF (selain pada *lag* 1,2,3).

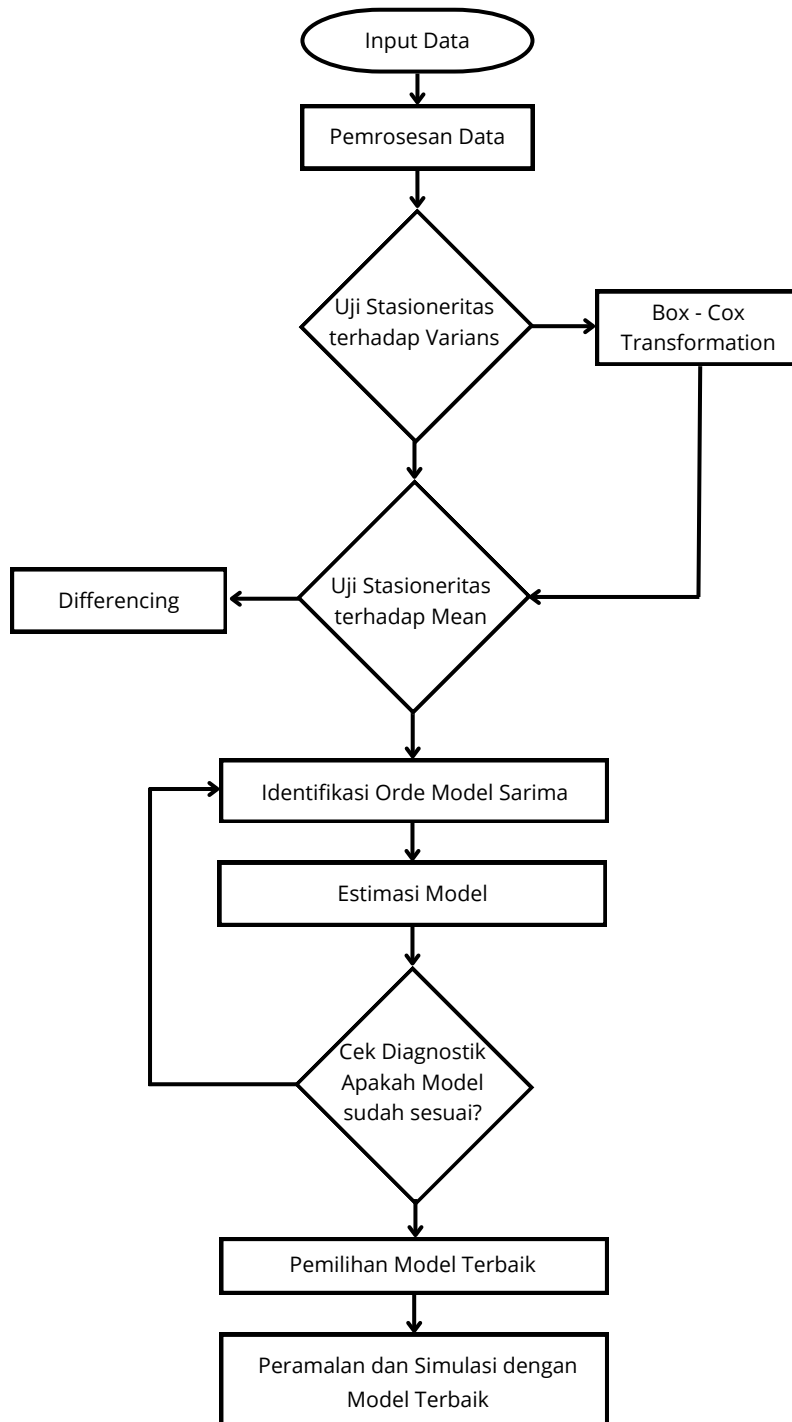
Pemilihan periode musiman menjadi hal yang penting karena akan menentukan akurasi dalam peramalan yang dilakukan dengan model SARIMA.

Menurut Gaynor dan Kirk, penentuan orde dalam SARIMA adalah sebagai berikut.

- ✓ Jika ACF *cut off* setelah *lag* musiman L, *lag* non musiman tidak signifikan dan PACF *dies down*, maka model yang sesuai adalah *seasonal* MA(Q=1) atau SARIMA(0,d,0)(0,D,1)<sup>L</sup>
- ✓ Jika ACF *cut off* setelah *lag* musiman L, *lag* non musiman *cut off* setelah *lag* 1 dan 2, maka model yang sesuai adalah *seasonal* MA (q=1 atau 2 ; Q=1) dan model lengkapnya adalah SARIMA(0,d,1)(0,D,1)<sup>L</sup> atau SARIMA(0,d,2)(0,D,1)<sup>L</sup>
- ✓ Jika ACF *dies down* dan PACF *cut off* setelah *lag* 1 atau 2, *lag* musiman tidak signifikan maka model yang sesuai adalah model *non-seasonal* AR(p=1 atau 2).
- ✓ Jika ACF *dies down* dan PACF *cut off* setelah *lag* musiman L; *lag* non musiman tidak signifikan, maka model yang sesuai adalah *seasonal* AR(P=1) dan model lengkapnya adalah SARIMA(0,d,0)(1,D,0)<sup>L</sup>
- ✓ Jika ACF *dies down* dan PACF *cut off* setelah *lag* musiman L, dan *lag* non musiman *cut off* setelah *lag* 1 atau 2, maka diperoleh model *non seasonal* dan *seasonal* AR(p=1 atau 2 dan P=1) dan model lengkapnya adalah SARIMA (1,d,0)(1,D,0)<sup>L</sup> atau SARIMA (2,d,0)(1,D,0)<sup>L</sup>
- ✓ Jika ACF dan PACF *does down* maka diperoleh model gabungan ARMA atau ARIMA



Proses analisis data peramalan data SARIMA dapat digambarkan pada diagram alir Gambar 6.3.



**Gambar 6.3** Flowchart untuk Model SARIMA



## 6.3 METODE HOLT – WINTER

Model Holt-Winter digunakan untuk meramalkan data yang memiliki pola musiman teratur, sehingga secara eksplisit dapat dilihat periode dari musimannya. Selain sesuai untuk data musiman, model ini juga sesuai untuk data yang memiliki pola data tren sekaligus musiman. Model Holt-Winter memiliki parameter smoothing sehingga akan menghasilkan model yang fit. Prinsip dari metode Holt-Winter adalah memodelkan data yang memiliki tren dan musiman secara bersamaan, sehingga dapat disimpulkan model Holt-Winter memiliki tiga komponen utama yaitu sebagai berikut.

### A. Komponen Tren (Level)

Diperoleh dari nilai rata-rata data historis dalam periode waktu tertentu.

### B. Komponen Musiman (*Seasonal*)

komponen ini mewakili pergerakan atau fluktuasi musiman dari data historis yang memiliki periode sama, misalkan kuartalan atau semesteran.

### C. Komponen Error (Residual)

komponen ini mewakili nilai *error* atau residual dari model peramalan yang dihasilkan.

Dalam Holt-Winter terdapat tiga jenis model berdasarkan pada plot data historisnya, yaitu sebagai berikut.

### (1) Model *Additive Seasonal Factors*

Model ini sesuai untuk data historis yang memiliki pola musiman dengan kecenderungan mengurangi atau menambah nilai data. Persamaan untuk model aditif adalah sebagai berikut.

Estimasi Persamaan *Smoothing*

$$S_t = \alpha \frac{Y_t}{E_{t-L}} + (1 - \alpha)(S_{t-1} + T_{t-1})$$

Estimasi Tren

$$T_t = \beta(S_t - S_{t-1}) + (1 - \beta)T_{t-1}$$

Estimasi Faktor Musiman

$$E_t = \gamma(Y_t - S_t) + (1 - \gamma)E_{t-L}$$

Persamaan umum untuk data peramalan pada period ke-  $(t+p)$  dengan menggunakan model Holt-Winter aditif adalah sebagai berikut

$$\hat{Y}_{t+p} = S_t + pT_t + E_{t-L+p}$$

dengan:

$S_t$  = nilai penghalusan data pada periode ke- $t$

$\alpha$  = konstanta pemulusan untuk data ( $0 < \alpha < 1$ )

$Y_t$  = data aktual pada periode ke- $t$

$E_t$  = data musiman pada periode ke- $t$

$T_t$  = nilai tren data pada periode ke- $t$

- $\beta$  = konstanta pemulusan untuk tren ( $0 < \beta < 1$ )
- $\rho$  = periode peramalan
- $L$  = panjang periode musiman
- $\gamma$  = konstanta pemulusan untuk musiman ( $0 < \gamma < 1$ )

## (2) Model Multiplikatif Seasonal Factors

Model ini sesuai untuk data historis yang memiliki pola musiman dengan kecenderungan meningkat atau menurun bersesuaian dengan peningkatan dan penurunan nilai data. Persamaan matematika untuk model multiplikatif adalah sebagai berikut.

### Estimasi Persamaan *Smoothing*

$$S_t = \alpha \frac{Y_t}{E_{t-L}} + (1 - \alpha)(S_{t-1} + T_{t-1})$$

### Estimasi Tren

$$T_t = \beta(S_t - S_{t-1}) + (1 - \beta)T_{t-1}$$

### Estimasi Faktor Musiman

$$E_t = \gamma \frac{Y_t}{S_t} + (1 - \gamma)E_{t-L}$$

Persamaan umum untuk data peramalan pada periode ke- $t$  dengan menggunakan model Holt-Winter multiplikatif adalah sebagai berikut

$$\hat{Y}_{t+p} = (S_t + pT_t)E_{t-L+p}$$

dengan:

$S_t$  = nilai penghalusan data pada periode ke- $t$

- $\alpha$  = konstanta pemulusan untuk data ( $0 < \alpha < 1$ )
- $Y$  = data aktual pada periode ke- $t$
- $E_t$  = data musiman pada periode ke- $t$
- $T_t$  = nilai tren data pada periode ke- $t$
- $\beta_t$  = konstanta pemulusan untuk tren ( $0 < \beta < 1$ )
- $\rho$  = periode peramalan
- $L$  = panjang periode musiman
- $\gamma$  = konstanta pemulusan untuk musiman ( $0 < \gamma < 1$ )

Penentuan model yang sesuai dari ketiga model ini penting dilakukan agar hasil peramalan akurat.



Ketiga model di atas merupakan model yang sesuai untuk data musiman dan memiliki unsur tren. Setiap model memiliki kelebihan dan kekurangan masing-masing. Perbedaan dari tiga model tersebut dirangkum dalam Tabel 6.1.

**Tabel 6.1** Perbandingan Model Peramalan untuk Data Musiman

Metode Dekomposisi	Metode SARIMA	Metode Holt-Winter
<p><b>Konsep Dasar:</b> Memisahkan data <i>time series</i> menjadi komponen tren, musiman, siklis, dan error</p>	<p><b>Konsep Dasar:</b> SARIMA merupakan perluasan dari model ARIMA, dimana pada SARIMA terdapat efek musiman. Model ini memerlukan identifikasi terpisah antara parameter ARIMA(p,d,q) dan SARIMA(p,d,q)<sup>s</sup></p>	<p><b>Konsep Dasar:</b> Model peramalan yang lebih sederhana dengan menggabungkan unsur tren, unsur musiman, dan unsur level dalam satu model. Unsur-unsur ini diramalkan serentak untuk membentuk model.</p>



**Tabel 6.1** Perbandingan Model Peramalan untuk Data Musiman (Lanjutan)

Metode Dekomposisi	Metode SARIMA	Metode Holt-Winter
<p><b>Keunggulan:</b> Memberikan informasi yang mendalam untuk setiap komponen pada data <i>time series</i></p>	<p><b>Keunggulan:</b> Model SARIMA dapat digunakan untuk meramalkan data musiman dengan pola yang beragam</p>	<p><b>Keunggulan:</b> Model Holt-Winter merupakan model peramalan sederhana yang dapat digunakan untuk data musiman yang memiliki pola relatif teratur.</p>



## 6.4 PENGOLAHAN DATA DENGAN MINITAB

Metode-metode peramalan yang telah dibahas pada sub-bab sebelumnya memiliki kompleksitas penghitungan yang cukup rumit, sehingga untuk memudahkan analisis digunakan bantuan software Minitab. Adapun langkah-langkah analisis data dengan menggunakan Minitab untuk setiap metode peramalan dijelaskan sebagai berikut.


### (1) Metode Dekomposisi dengan Minitab

Data yang digunakan untuk contoh pengolahan data dengan metode dekomposisi merupakan data penjualan berikut.

Bulan	Penjualan	Bulan	Penjualan
1	10.000	10	18.000
2	12.000	11	16.000
3	13.000	12	14.000

Bulan	Penjualan	Bulan	Penjualan
4	16.000	13	11.000
5	19.000	14	12.800
6	23.000	15	12.900
7	26.000	16	17.500
8	30.000	17	21.000
9	28.000	18	25.000

Plot *time series* dari data di atas adalah sebagai berikut



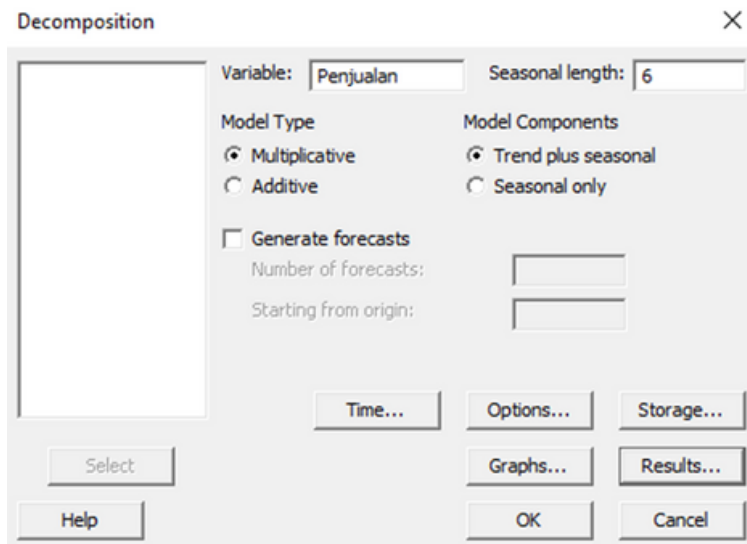
(sumber: pengolahan data)

Berdasarkan plot *time series* data tampak bahwa pola data memiliki efek musiman dan juga tren walaupun tidak terlihat secara signifikan.

Langkah analisis data dengan metode dekomposisi adalah sebagai berikut.

- A** Menginputkan data pada Worksheet Minitab
- B** Pilih menu Stat → Time Series → Decomposition,

maka akan muncul kotak dialog seperti berikut.



Beberapa bagian dari kotak dialog Decomposition adalah sebagai berikut.


- ✿ **Variable**  
digunakan untuk menginputkan kolom data yang akan dianalisis.
- ✿ **Seasonal Length**  
digunakan untuk menginputkan periode musiman dari data, misalkan data historis merupakan data bulanan dan memiliki pola tahunan, maka pada *seasonal length* diisi dengan 12.
- ✿ **Model Type**  
digunakan untuk memilih tipe dari model dekomposisi menggunakan *multiplicative* atau *additive*.
- ✿ **Model Components**  
digunakan untuk memilih unsur yang dimasukkan dalam model, terdiri dari dua jenis yaitu hanya memasukkan unsur musiman (*seasonal only*) atau

memasukkan unsur tren sekaligus musiman (*trend plus seasonal*). Untuk memilih unsur yang akan dimasukkan dalam model dapat disesuaikan dengan pola data historis. Jika dalam contoh data penjualan di atas, komponen yang dominan adalah *seasonal*.

❁ **Generate Forecasts**

digunakan untuk menginputkan pada periode berapa data akan diramalkan (diinputkan pada bagian *Starting from Origin*) dan juga berapa jumlah data yang akan diramalkan (diinputkan pada bagian *Number of forecasts*). Menu ini dapat diisi saat sudah diperoleh model dengan nilai MAPE terkecil.

Berdasarkan data penjualan di atas diperoleh hasil seperti pada gambar di bawah ini. Dengan menggunakan *seasonal length* 6 (data musiman terjadi semesteran) diperoleh nilai MAPE 33%. Berdasarkan pada Tabel 5.1, nilai MAPE 33% masih cukup layak.



(sumber: pengolahan data)



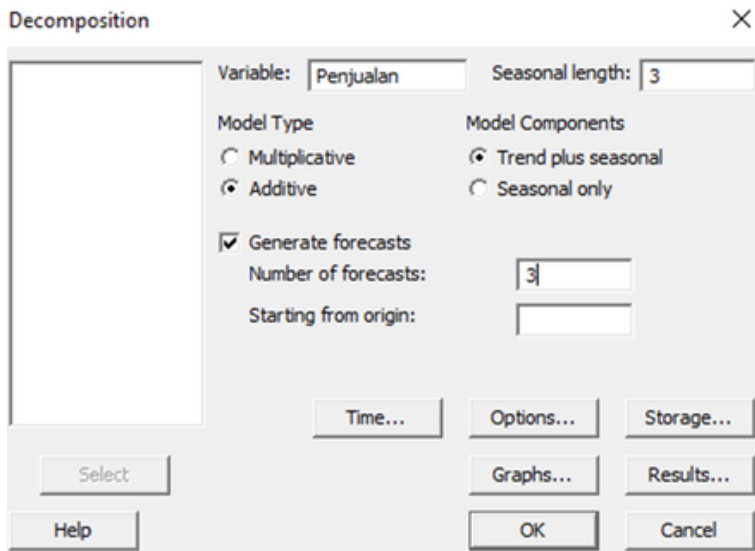
Selain menggunakan *seasonal length* dan model di atas, dilakukan pula perhitungan dengan model yang lain. Adapun hasil dari pengujian model lain dilihat dari nilai MAPE nya adalah sebagai berikut.

Model	Seasonal Length	MAPE
<i>Seasonal only Additive</i>	6	33 %
<i>Seasonal only Multiplicative</i>	6	32 %
<i>Seasonal only Additive</i>	3	30 %
<i>Seasonal only Multiplicative</i>	3	30 %
<i>Trend plus seasonal Additive</i>	3	29 %
<i>Trend plus seasonal Multiplicative</i>	3	29 %


Berdasarkan tabel di atas, model *trend plus seasonal additive* dan *trend plus seasonal multiplicative* memberikan nilai MAPE yang sama yaitu 29%. Jika dilihat berdasarkan plot *time series* model yang lebih sesuai adalah *additive* karena data musiman cenderung memiliki fluktuasi musiman dengan nilai yang relatif tetap untuk setiap *cycle* nya.



Pada bagian (c) diperoleh model yang paling sesuai adalah *trend plus seasonal additive* dengan *seasonal length* 3 sehingga model inilah yang digunakan untuk *forecasting*. *Forecasting* dilakukan melalui menu *Generate Forecasts* dengan mengisi *Number of Forecasts* sebanyak tiga periode karena akan digunakan untuk meramalkan tiga periode, dan *Starting from origin* digunakan untuk menentukan pada periode berapa akan dilakukan peramalan data. Jika pilihan ini tidak diisi, maka Minitab akan mengambil data historis terakhir.




Hasil dari peramalan tiga periode ditampilkan pada gambar grafik di bawah ini. Nilai peramalan untuk masing-masing periode adalah  $\hat{Y}_{19} = 19193,5$  ;  $\hat{Y}_{20} = 19853$  ;  $\hat{Y}_{21} = 20179,2$



(sumber: pengolahan data)

## (2) Metode SARIMA dengan Minitab

Contoh data untuk model SARIMA ini adalah data Indeks Harga Konsumen Kota Semarang (sumber: BPS Kota Semarang) yang ditampilkan pada Lampiran 3. Hasil plot *time series* untuk keseluruhan data IHK adalah sebagai berikut.




(sumber: pengolahan data)

Berdasarkan plot *time series* di atas tampak bahwa di beberapa titik terdapat kenaikan dibandingkan dengan periode yang lain, sehingga terdapat indikasi adanya musiman pada plot di atas. Untuk menentukan peramalan data IHK, data dibagi menjadi dua bagian yaitu data *training* dan data *testing*.

Data training digunakan untuk mengidentifikasi dan membentuk model, sedangkan data testing digunakan untuk melihat performansi dari model saat digunakan untuk peramalan. Dalam contoh ini, data yang digunakan sebagai data training adalah data pada bulan Januari 2014 sampai dengan Desember 2017, sedangkan data yang digunakan sebagai data testing adalah data pada bulan Januari 2018 sampai dengan Desember 2018.

Plot data IHK pada 2017 dan IHK pada 2018 memiliki kemiripan, seperti yang ada pada plot di bawah ini.



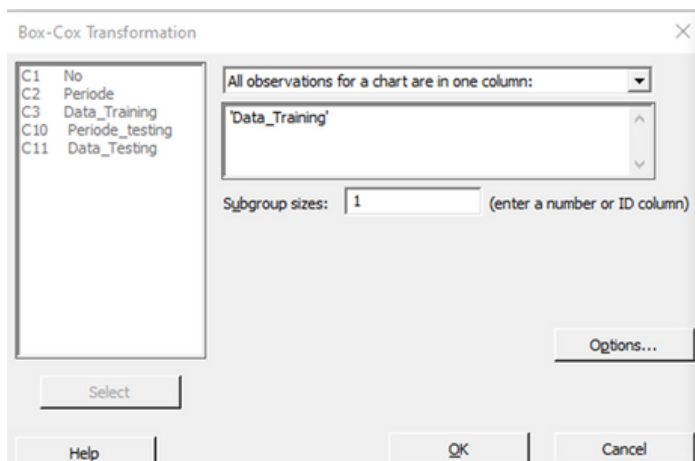
(sumber: pengolahan data)

Langkah-langkah analisis dengan metode SARIMA adalah sebagai berikut.



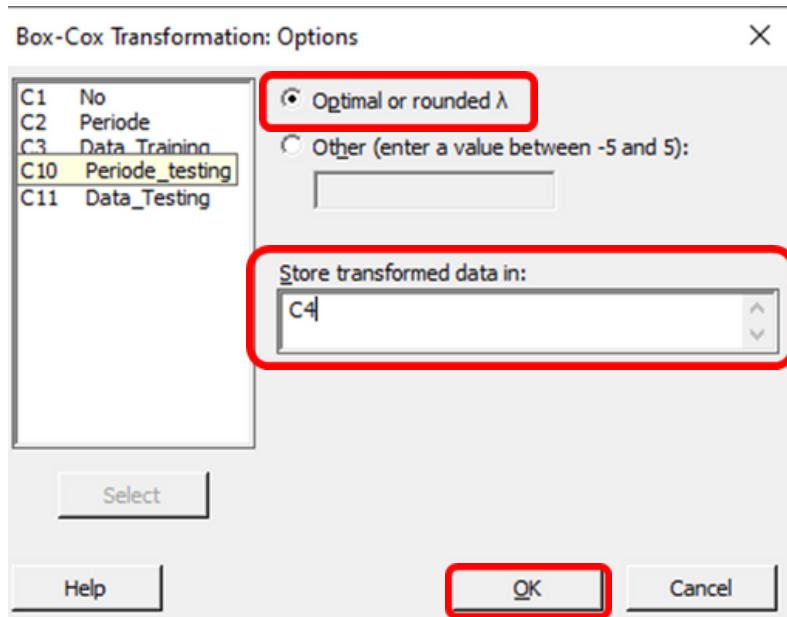
### Uji Stasioneritas Data

yaitu menguji stasioneritas data terhadap varians dan terhadap mean. Uji stasioneritas varians dilakukan dengan melakukan transformasi data dan selanjutnya dilihat nilai *rounded value*. Untuk menguji stasioneritas varians dengan menggunakan Minitab adalah melalui menu **Stat** → **Control Charts** **Box-Cox Transformation** dan muncul kotak dialog berikut.






Data yang diinputkan adalah data *training* dan sub-grup diisi dengan 1. Klik options, maka muncul kotak dialog berikut.




Pilih ***Optimal or rounded  $\lambda$***  dan pilih kolom untuk menempatkan hasil transformasi, lalu klik OK. Hasil dari transformasi data yang pertama adalah sebagai berikut.




Nilai *rounded value* adalah -0,37 sehingga data belum stasioner dalam varians dan harus dilakukan transformasi


kembali menggunakan hasil transformasi sebelumnya (tidak menggunakan data asli). Hasil transformasi kedua adalah sebagai berikut.



Hasil *Rounded Value* pada transformasi kedua sudah sama dengan 1, sehingga dapat dilakukan tahap uji stasioneritas berikutnya yaitu uji stasioneritas terhadap *mean*. Pengujian stasioneritas terhadap *mean* menggunakan data transformasi yang sudah stasioner terhadap varians. Uji stasioneritas *mean* dilakukan dengan menggunakan plot ACF (*Stat* → *Time Series* → *Autocorrelation*). Hasil dari plot ACF adalah sebagai berikut.



Berdasarkan plot ACF, data belum stasioner terhadap mean karena *lag* ACF menurun secara perlahan sehingga dilakukan *differencing* agar data menjadi stasioner. Hasil plot ACF setelah dilakukan *differencing* satu kali adalah sebagai berikut. Berdasarkan plot ACF tampak bahwa data sudah stasioner dalam *mean* karena pada *lag* sudah menurun secara cepat.




(sumber: pengolahan data)




### Mengidentifikasi Orde Model

Pada gambar plot ACF tampak bahwa terdapat indikasi adanya musiman karena *lag* 12 signifikan atau berada di luar garis batas. Untuk menentukan orde dari model SARIMA dilakukan berdasarkan plot ACF dan PACF yang sudah stasioner dalam *mean* (menggunakan *differencing* satu kali) dan plot ACF serta PACF untuk indikasi musiman yang menggunakan data dengan *differencing* 12.

Hasil plot ACF dan PACF untuk data *non seasonal* adalah sebagai berikut.




Plot ACF untuk data non-musiman  
(sumber: pengolahan data)




Plot PACF data non-musiman  
(sumber: pengolahan data)

Untuk menentukan orde musiman dilakukan plot ACF dan PACF untuk data dengan *differencing* 12 dan hasilnya adalah sebagai berikut.



Plot ACF untuk data musiman  
(sumber: pengolahan data)



Plot PACF untuk data musiman  
(sumber: pengolahan data)

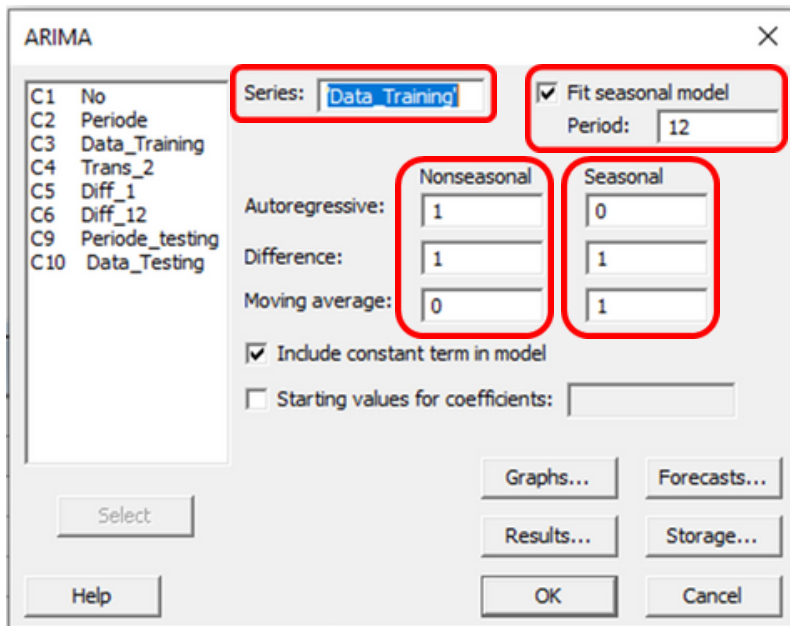
Plot ACF pada data non musiman menunjukkan adanya *dies down* begitu pula dengan plot PACF nya. Untuk plot ACF data musiman menunjukkan *dies down* sedangkan pada PACF mengalami *cut off* pada *lag* 1. Langkah selanjutnya adalah menentukan model yang mungkin berdasarkan plot ACF dan PACF.

Hasil rangkuman model ditampilkan pada langkah selanjutnya disertai dengan hasil estimasi parameternya.



### Estimasi Parameter

Pada tahap estimasi parameter dilakukan pengujian parameter untuk masing-masing model. Misalkan salah satu model yang terbentuk adalah SARIMA(1,1,0)(0,1,1)<sup>12</sup> maka pada Minitab diinputkan sebagai berikut.



Pada bagian **Series**, data yang digunakan adalah data *training* asli bukan menggunakan data *differencing* karena data *differencing* hanya untuk mengidentifikasi model yang sesuai. Menu **Fit seasonal model** dicentang karena data ini mengandung komponen musiman dengan periode 12. Orde untuk data **non musiman** diinputkan pada bagian non seasonal, sedangkan orde yang menunjukkan data musiman diinputkan pada bagian **seasonal**.

Hasil estimasi parameternya adalah sebagai berikut.

### Final Estimates of Parameters

Type	Coef	SE Coef	T-Value	P-Value
AR 1	0,245	0,144	1,71	0,097
SMA 12	0,721	0,185	3,89	0,000
Constant	-0,0956	0,0515	-1,86	0,073

Signifikansi parameter dilihat berdasarkan nilai p-value. Berdasarkan hasil yang muncul pada Minitab diketahui bahwa parameter musiman MA memiliki p-value = 0 atau kurang dari  $\alpha = 5\%$  sehingga signifikan. Untuk parameter non musiman AR memiliki p-value 0,097 atau lebih besar dari  $\alpha = 5\%$  sehingga tidak signifikan, namun jika menggunakan  $\alpha = 10\%$  parameter ini masih signifikan. Dari nilai ini, maka model dapat kita gunakan sebagai perbandingan dengan model yang lain.

Hasil rangkuman uji estimasi parameter untuk beberapa model yang mungkin adalah sebagai berikut.

Model	Parameter	P-value	Signifikansi
SARIMA (1,1,0)(1,1,1) <sup>12</sup>	AR 1	0,100	TS
	SAR 12	0,000	S
	SMA 12	0,001	S
SARIMA (2,1,2)(0,1,1) <sup>12</sup>	AR 1	0,885	TS
	AR 2	0,143	TS
	MA 1	0,643	TS
	MA 2	0,219	TS
	SMA 12	0,002	S
SARIMA (1,1,0)(0,1,1) <sup>12</sup>	AR 1	0,097	S
	SMA 12	0,000	S
SARIMA (0,1,1)(2,1,0) <sup>12</sup>	MA 1	0,000	S
	SAR 12	0,000	S
	SAR 24	0,000	S

Model	Parameter	P-value	Signifikansi
SARIMA (1,1,1)(1,1,1) <sup>12</sup>	AR 1	0,000	S
	MA 1	0,000	S
	SAR 12	0,254	TS
	SMA 12	0,090	S
SARIMA (1,1,1)(1,1,0) <sup>12</sup>	AR 1	0,003	S
	MA 1	0,000	S
	SAR 12	0,000	S
SARIMA (1,1,1)(2,1,0) <sup>12</sup>	AR 1	0,617	S
	MA 1	0,000	S
	SAR 12	0,000	S
	SAR 24	0,000	S
SARIMA (3,1,3)(2,1,0) <sup>12</sup>	AR 1	0,138	TS
	AR 2	0,808	TS
	AR 3	0,796	TS
	MA 1	0,804	TS
	MA 2	0,286	TS
	MA 3	0,309	TS
	SAR 12	0,000	S
	SAR 24	0,000	S
SARIMA (2,1,3)(2,1,1) <sup>12</sup>	AR 1	0,047	S
	AR 2	0,000	S
	MA 1	0,000	S
	MA 2	0,001	S
	MA 3	0,000	S
	SAR 12	0,000	S
	SAR 24	0,000	S
	SMA 12	0,130	TS

\*TS : Tidak signifikan

S : Signifikan

Kesimpulan:

Berdasarkan pengujian estimasi parameter, model yang sesuai adalah model dengan parameter yang signifikan, sehingga berdasarkan tabel di atas model yang sesuai adalah SARIMA(1,1,0) (0,1,1)<sup>12</sup>, SARIMA(0,1,1)(2,1,0)<sup>12</sup>, SARIMA(1,1,1)(1,1,0)<sup>12</sup>, SARIMA(1,1,1) (2,1,0)<sup>12</sup>.





## Uji Diagnostik Model

Langkah selanjutnya setelah dilakukan pengujian parameter adalah uji diagnostik model seperti pada model ARIMA. Pengujian diagnostik model menggunakan nilai residual. Pengujian residual meliputi pengujian distribusi normal dan apakah residual bersifat acak.

### #1 Pengujian Distribusi Normal

Pengujian distribusi normal dilakukan dengan menggunakan uji Kolmogorov Smirnov. Pada Minitab pilih Stat → Basic Statistics → Normality Test, dan muncul kotak dialog berikut.

Normality Test

Variable: Residuals\_1

Percentile Lines

None

At Y values: \_\_\_\_\_

At data values: \_\_\_\_\_

Tests for Normality

Anderson-Darling

Ryan-Joiner (Similar to Shapiro-Wilk)


Kolmogorov-Smirnov

Select

Title: \_\_\_\_\_

Help OK Cancel

Pada bagian **Variable** dimasukkan **data residual model** yang dapat diperoleh dengan mengaktifkan menu **Residuals** pada menu **Storage** ARIMA. Berikut adalah hasil pengujian distribusi normal untuk salah satu model yaitu SARIMA(1,1,0)(0,1,1)<sup>12</sup>



Berdasarkan grafik di atas, diketahui bahwa model SARIMA(1,1,0)(0,1,1)<sup>12</sup> memiliki nilai p-value > 0,150 atau lebih besar dari  $\alpha = 5\%$  sehingga dapat disimpulkan bahwa residual dari model ini berdistribusi normal.

## #2 Pengujian Distribusi Normal

Pengujian ini dilakukan dengan menggunakan nilai Ljung Box yang muncul pada *output* Minitab. Hasil dari pengujian model SARIMA(1,1,0)(0,1,1)<sup>12</sup> adalah sebagai berikut.

### Modified Box-Pierce (Ljung-Box) Chi-Square Statistic

Lag	12	24	36	48
Chi-Square	11,68	31,38	*	*
DF	10	22	*	*
P-Value	0,307	0,089	*	*

Model memenuhi asumsi bersifat acak jika nilai p-value >  $\alpha$ . Berdasarkan hasil di atas diketahui bahwa nilai p-value untuk Ljung Box adalah 0,307 dan 0,089 maka dengan menggunakan  $\alpha = 5\%$  dapat disimpulkan bahwa model ini bersifat acak.

Hasil dari pengujian semua model ditampilkan pada tabel berikut.

Model	Uji Diagnostik	
	Berdistribusi Normal	Acak
SARIMA (1,1,0)(1,1,1) <sup>12</sup>	Ya	Ya
SARIMA (0,1,1)(2,1,0) <sup>12</sup>	Tidak	Ya
SARIMA (1,1,1)(1,1,0) <sup>12</sup>	Tidak	Ya
SARIMA (1,1,1)(2,1,0) <sup>12</sup>	Tidak	Ya

Kesimpulan:

Berdasarkan hasil uji diagnostik diketahui bahwa model yang memenuhi adalah SARIMA(1,1,0)(0,1,1)<sup>12</sup>.



### Perhitungan Nilai MAPE

Pada model SARIMA, nilai MAPE dihitung dengan manual karena Minitab tidak memunculkan nilai MAPE. Penghitungan ini menggunakan rumus seperti yang telah dibahas pada sub-bab 5.3. Data yang digunakan sebagai data aktual adalah data *testing* yaitu data IHK pada bulan Januari sampai Desember 2018. Hasil data peramalan menggunakan model SARIMA(1,1,0)(0,1,1)<sup>12</sup> adalah sebagai berikut.

Periode	Nilai Aktual ( $A_t$ )	Hasil Peramalan ( $F_t$ )	$\left  \frac{A_t - F_t}{A_t} \right $
Januari 2018	130,17	133,88	0,029
Februari 2018	130,65	133,73	0,024
Maret 2018	130,71	133,45	0,021
April 2018	130,74	133,54	0,021
Mei 2018	130,62	133,79	0,024
Juni 2018	131,45	134,11	0,020
Juli 2018	131,60	133,70	0,016

Periode	Nilai Aktual ( $A_t$ )	Hasil Peramalan ( $F_t$ )	$\left  \frac{A_t - F_t}{A_t} \right $
Agustus 2018	130,17	133,88	0,029
September 2018	130,65	133,73	0,024
Oktober 2018	130,71	133,45	0,021
November 2018	130,74	133,54	0,021
Desember 2018	130,62	133,79	0,024
<b>MAPE</b>			<b>31,98%</b>

Berdasarkan Tabel 5.1, model dengan nilai MAPE antara 20% - 50% masih dapat digunakan dan layak untuk digunakan sebagai dasar dari peramalan.



### Hasil Peramalan

Model yang terbaik dan terpilih untuk digunakan dalam peramalan adalah SARIMA(1,1,0)(0,1,1)<sup>12</sup>. Untuk mendapatkan hasil peramalan dengan menggunakan Minitab, dapat dipilih menu Stat → Time Series → ARIMA dan pada bagian Forecasts dapat diinputkan periode yang diramalkan. Sebagai contoh, model ini digunakan untuk meramalkan IHK bulan Januari 2019 sampai dengan Juni 2019. Hasil peramalannya adalah sebagai berikut


Periode	Forecasting
Januari 2019	139,694
Februari 2019	139,561
Maret 2019	139,285
April 2019	139,372
Mei 2019	139,625
Juni 2019	139,948

### (3) Metode Holt-Winter dengan Minitab

Contoh data yang digunakan untuk model Holt-Winter adalah data penjualan dalam 24 bulan sebagai berikut.

Periode	Forecasting	Bulan	Penjualan
1	51	51	51
2	67	67	67
3	65	65	65
4	129	129	129
5	225	225	225
6	272	272	272
7	238	238	238
8	172	172	172
9	143	143	143
10	131	131	131
11	125	125	125
12	103	103	103

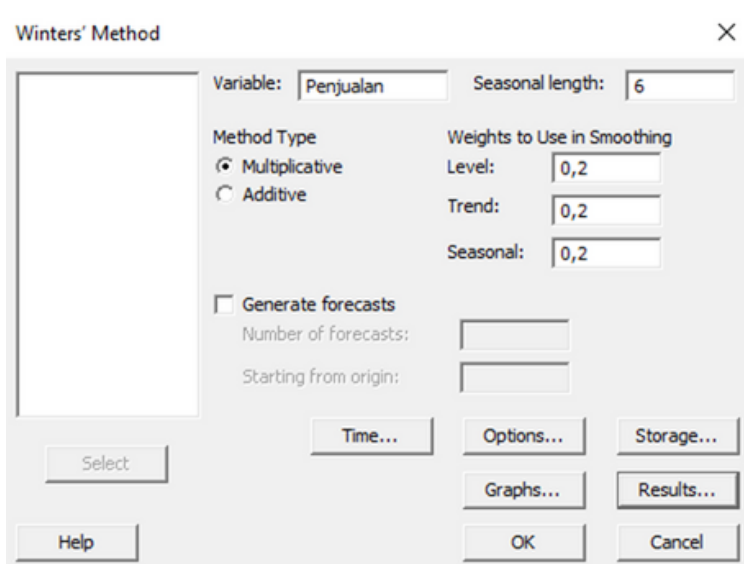
Plot data *time series* dari data di atas adalah sebagai berikut.



Plot data di atas memiliki pola musiman yang relatif mudah untuk diidentifikasi, sehingga sesuai diramalkan dengan model Holt-Winter.

Langkah-langkah analisis model Holt-Winter dengan menggunakan Minitab adalah sebagai berikut.

- A Menginputkan data pada *worksheet* Minitab
- B Model Holt-Winter dapat dipilih melalui menu Stat → Time Series → Winter's Method dan akan muncul tampilan kotak dialog sebagai berikut.



- ✿ **Variable**  
digunakan untuk menginputkan data yang akan diramalkan.
- ✿ **Seasonal Length**  
digunakan untuk menginputkan periode musiman dari data historis.
- ✿ **Method Type**  
terdiri dari dua jenis yaitu *Additive* dan *Multiplicative*. Tipe aditif dipilih jika data memiliki fluktuasi musiman yang

besarannya tetap, sedangkan tipe multiplikatif dipilih jika data memiliki fluktuasi musiman yang besarnya berubah ubah. Apabila fluktuasi musiman sulit untuk diidentifikasi, maka dapat digunakan keduanya dan dibandingkan menggunakan tingkat akurasi manakah yang lebih baik. Pada data contoh, pola data *time series* memiliki fluktuasi musiman yang berbeda, sehingga kemungkinan akan sesuai jika tipe yang digunakan adalah multiplikatif.


### ✿ **Weights to Use in Smoothing**

digunakan untuk menginputkan bobot setiap komponen. Pada bagian ini terdapat tiga komponen yaitu pemulusan level, pemulusan tren, dan pemulusan musiman. Nilai konstanta pemulusan adalah antara 0 sampai dengan 1. Konstanta pemulusan ini berfungsi untuk memperhalus fluktuasi pada data sehingga pola data lebih terlihat, namun tidak disarankan untuk memberikan nilai yang besar pada konstanta karena dapat menghilangkan pola-pola penting dari data. Untuk menentukan bobot yang tepat, dapat dilakukan *trial and error* sampai diperoleh error yang relatif kecil. Perubahan bobot pada konstanta level memberikan perubahan yang signifikan untuk tingkat akurasi dibandingkan dengan perubahan bobot pada konstanta lainnya.

### ✿ **Generate Forecasts**

digunakan untuk menginputkan jumlah data yang akan diramalkan setelah diperoleh model yang paling sesuai.

Berdasarkan pada data penjualan di atas, tipe model yang digunakan adalah model multiplikatif dengan *seasonal length* 6. Plot hasil dari model multiplikatif tersebut adalah sebagai berikut.




Konstanta pemulusan dapat diganti sampai diperoleh nilai *error* yang kecil. Adapun ringkasan hasil analisis untuk data penjualan ini adalah sebagai berikut.

Model	Konstanta	Seasonal Length	MAPE
Multiplikatif	$\alpha = 0,2; \beta = 0,2;$ $\gamma = 0,2$	6	63,5
Multiplikatif	$\alpha = 0,4; \beta = 0,2;$ $\gamma = 0,2$	6	46,81
Multiplikatif	$\alpha = 0,6; \beta = 0,2;$ $\gamma = 0,2$	6	34,61
Multiplikatif	$\alpha = 0,8; \beta = 0,2;$ $\gamma = 0,2$	6	28,28
Multiplikatif	$\alpha = 0,8; \beta = 0,6;$ $\gamma = 0,2$	6	23,27
Multiplikatif	$\alpha = 0,8; \beta = 0,6;$ $\gamma = 0,1$	6	23,04
Aditif	$\alpha = 0,8; \beta = 0,6;$ $\gamma = 0,1$	6	20,96



Berdasarkan hasil yang diperoleh pada tabel, diketahui bahwa MAPE terkecil diperoleh dari model aditif dengan nilai  $\alpha = 0,8$  artinya diperlukan konstanta pemulusan yang besar untuk komponen level,  $\beta = 0,6$  artinya konstanta pemulusan tren juga membutuhkan nilai yang cukup besar, dan  $\gamma = 0,1$  artinya konstanta pemulusan untuk *seasonal* cenderung lebih kecil. Model aditif menunjukkan nilai MAPE yang lebih kecil dibandingkan dengan model multiplikatif sehingga dapat disimpulkan bahwa pola data memiliki fluktuasi musiman yang relatif sama.

- c Meramalkan periode selanjutnya menggunakan model yang terbaik (dengan nilai MAPE terkecil). Pada data ini akan diramalkan tiga periode sehingga pada bagian *number of forecasts* diisi dengan 3. Hasil peramalannya ditampilkan pada grafik di bawah ini. Nilai  $\hat{Y}_{25} = 98,83$ ;  $\hat{Y}_{26} = 1,68$ ;  $\hat{Y}_{27} = -62,48$ . Nilai yang turun secara signifikan dapat dijadikan sebagai salah satu pertimbangan dalam penjualan dan dijadikan sebagai bahan untuk evaluasi sehingga dapat mencegah penurunan yang besar pada periode tersebut.



# LATIHAN SOAL

Jawablah pernyataan berikut dengan Benar atau Salah.

1. Model Holt-Winters sesuai untuk data musiman dengan plot musiman yang tidak teratur.

Benar   Salah

2. Model dekomposisi terdiri dari model aditif dan multiplikatif.

Benar   Salah

3. Model SARIMA dapat digunakan untuk data dengan *lag* ACF *seasonal* yang tidak signifikan.

Benar   Salah

4. Model Holt-Winters meramalkan data musiman dengan cara memisahkan komponen *trend*, *seasonal*, dan level.

Benar   Salah

5. Model SARIMA yang memiliki residual tidak berdistribusi normal tetap dapat digunakan, namun berpotensi menimbulkan hasil peramalan yang bias.

Benar   Salah

6. Model SARIMA dapat menghasilkan nilai peramalan dengan *error* kecil jika data aktual lengkap dan tersedia dalam jangka waktu yang panjang.

Benar   Salah

7. Sebelum digunakan untuk mengidentifikasi orde dari model SARIMA, data harus stasioner dalam varians dan dalam mean.

Benar   Salah

8. Jika data belum stasioner dalam varians, maka data harus *di-differencing*.

Benar   Salah

9. Model Holt-Winter sesuai digunakan untuk data yang memiliki pola musiman teratur.

Benar   Salah

10 Model dekomposisi dapat mempermudah dalam melihat pola data, karena analisis data dilakukan per komponen.

Benar   Salah

NEXT 



# SOAL ANALISIS DATA

Dengan menggunakan data pada Lampiran 2, lakukan analisis sebagai berikut.

A. Gambarkan pola data untuk menunjukkan bagaimana pola perubahan data

---

---

---

---

---

B. Lakukan analisis data dengan menggunakan model dekomposisi

---

---

---

---

---

C. Lakukan analisis data dengan menggunakan model SARIMA

---

---

---

---

---

D. Lakukan analisis data dengan menggunakan model Holt-Winter

---

---

---

---

---

E. Tentukan nilai MAPE untuk masing-masing model pada poin b sampai dengan poin d.

---

---

---

---

---

F. Berdasarkan nilai MAPE tersebut manakah model yang terbaik?

---

---

---

---

---

F. Gunakan model terbaik untuk meramalkan data pada bulan Januari 2021 sampai dengan Mei 2021.

---


---

---

---

---





# PERAN PERAMALAN DALAM PERENCANAAN PRODUKSI





## Tujuan Instruksional

1. Mahasiswa memahami peranan peramalan pada perencanaan produksi.
2. Mahasiswa memahami tahapan produksi dan bagaimana penerapan peramalan dalam produksi.
3. Mahasiswa memahami dan dapat menerapkan teori peramalan dalam *Material Requirement Planning (MRP)*.

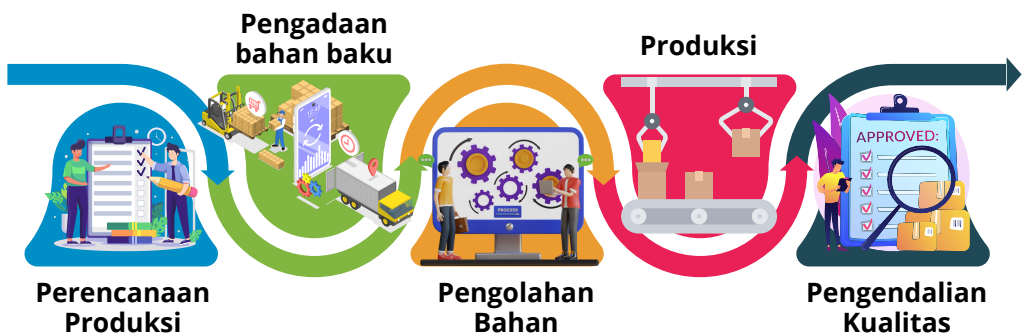


### 7.1 PERANAN PERAMALAN DALAM PROSES PRODUKSI



Proses produksi merupakan serangkaian proses untuk mengubah bahan baku atau bahan mentah menjadi bahan jadi yang siap dipasarkan.

Proses produksi antara satu produk dengan produk yang lain berbeda, bergantung dengan bahan baku dan produk jadi apa yang dihasilkan. Secara umum proses produksi terdiri dari:



### 1 **Perencanaan Produksi**

meliputi identifikasi produk, peramalan permintaan untuk menentukan jumlah produk yang akan diproduksi, penjadwalan produksi dan alokasi sumber daya yang dimiliki

### 2 **Pengadaan Bahan Baku**

meliputi pemilihan dan pembelian bahan baku. Dalam proses pengadaan bahan baku juga mempertimbangkan hasil peramalan permintaan agar jumlah bahan baku yang dipesan dapat memenuhi produksi saat diperlukan

### 3 **Pengolahan Bahan**

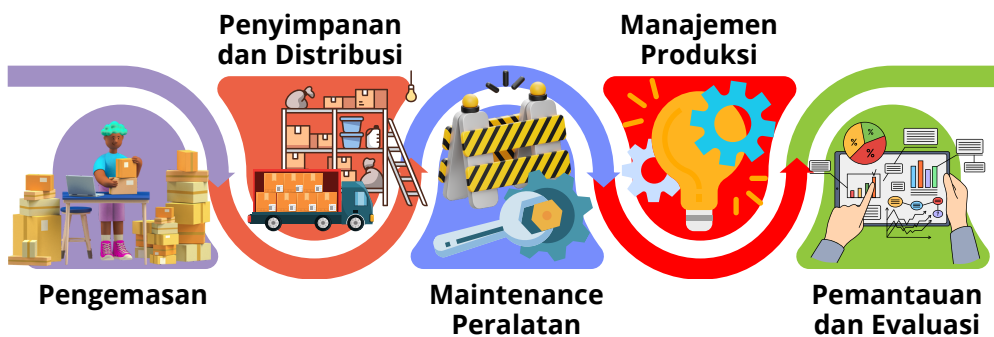
meliputi pemrosesan bahan baku menjadi bentuk yang lebih sesuai untuk proses produksi selanjutnya

### 4 **Produksi**

merupakan proses utama yaitu mengubah bahan baku menjadi produk jadi dengan menggunakan sumber daya yang dimiliki, seperti mesin, peralatan, dan juga tenaga kerja.

### 5 **Pengendalian Kualitas**

merupakan pemeriksaan produk untuk menjaga kualitas produk dan memastikan produk yang dihasilkan sesuai dengan standard. Selain itu, pengendalian kualitas juga dapat mendeteksi adanya produk cacat sebelum sampai di tangan konsumen.



## 6 Pengemasan

merupakan proses yang dilakukan sebelum produk didistribusikan dan dikirimkan.

## 7 Penyimpanan dan Distribusi

merupakan proses penyimpanan dan penyusunan produk sebelum dikirimkan kepada pelanggan.

## 8 Maintenance Peralatan

merupakan proses perbaikan mesin dan peralatan yang digunakan untuk produksi. Tujuan dari *maintenance* adalah untuk pemeliharaan mesin agar tidak terjadi kerusakan saat digunakan untuk produksi, sehingga tidak menghambat produksi.

## 9 Manajemen Produksi

merupakan proses pengawasan dan pengelolaan keseluruhan proses produksi.

## 10 Pemantauan dan Evaluasi

merupakan pemantauan kinerja produksi yang dilakukan dengan membandingkan hasil aktual dengan perencanaan. Evaluasi dilakukan untuk perbaikan atau inovasi pada produksi selanjutnya.

Peramalan dalam proses produksi berperan penting antara lain sebagai berikut.

## ⦿ Merencanakan Keperluan Bahan Baku

Ketersediaan bahan baku yang cukup menjadi salah satu hal yang penting dalam proses produksi. Dengan menggunakan teknik peramalan dapat membantu mengidentifikasi banyaknya bahan baku yang dibutuhkan berdasarkan ramalan permintaan produk di masa depan. Hal ini dapat mengurangi risiko kelebihan atau kekurangan bahan baku selama proses produksi

## **b) Manajemen Persediaan**

Peramalan juga berperan dalam persediaan sehingga lebih efisien. Data yang digunakan adalah peramalan permintaan, dan selanjutnya digunakan untuk mengelola persediaan sehingga tidak menghambat proses produksi dan dapat mengurangi risiko biaya penyimpanan yang tinggi.

## **c) Perencanaan Produksi**

Peramalan membantu untuk merencanakan produksi agar lebih akurat. Data peramalan permintaan dapat dijadikan sebagai dasar untuk mengatur jadwal produksi, optimalisasi penggunaan fasilitas, dan mengurangi risiko adanya kekurangan atau kelebihan produksi.


## **d) Pengelolaan Rantai Pasok**

Dengan melibatkan teknik peramalan dalam perancangan sistem produksi, dapat memberikan efek yang baik pada pengelolaan rantai pasok secara keseluruhan, meliputi perencanaan distribusi, transportasi, dan koordinasi dengan pemasok

Contoh perencanaan produksi dengan menggunakan peramalan adalah sebagai berikut.

### **1) Identifikasi Produk dan Data Historis**

Misalkan suatu industri memproduksi sepatu *sport*. Langkah pertama adalah melakukan identifikasi produk yang akan dibuat, dimana dalam contoh ini adalah sepatu *sport*. Langkah selanjutnya adalah melihat tren penjualan dan tren permintaan sepatu dari data historis.



## 2 Memilih Metode Peramalan

Data historis yang telah diperoleh selanjutnya digambarkan dalam plot *time series* untuk melihat bagaimanakah pola dari datanya. Plot ini penting dilakukan untuk menentukan metode peramalan apa yang sesuai jika permintaan konstan, musiman, atau ada tren kenaikan maupun penurunan.

## 3 Melakukan Analisis Data Historis

Analisis data historis dilakukan untuk mengidentifikasi tren, musiman, atau untuk melihat faktor lain yang bisa mempengaruhi nilai permintaan. Faktor lain yang menentukan antara lain event yang terjadi misalkan permintaan besar terjadi saat musim liburan atau adanya event olahraga besar.

## 4 Menerapkan Model Peramalan

Model peramalan yang sesuai adalah model peramalan dengan nilai error yang kecil. Pemilihan model peramalan didasarkan pada pola dari data historis. Setelah model terpilih, selanjutnya digunakan untuk meramalkan permintaan sepatu sport pada periode selanjutnya.

## 5 Melakukan Verifikasi dan Evaluasi

Verifikasi dilakukan dengan melihat error yang dihasilkan oleh model peramalan yang digunakan. Evaluasi dilakukan untuk melihat performansi model dalam meramalkan permintaan sepatu.

## 6 Merencanakan Produksi

Setelah diperoleh hasil peramalan permintaan selama beberapa periode, selanjutnya data peramalan digunakan untuk merencanakan proses produksi, mulai dari jadwal produksi sampai dengan sumber daya yang digunakan untuk pembuatan sepatu.

## 7 Melakukan Pengawasan

Pengawasan dilakukan selama proses produksi berjalan sehingga dapat segera dilakukan penyesuaian jika ada yang berubah dari perencanaan. Pengawasan dapat dilakukan secara berkala, pengumpulan data historis, dan penyesuaian rencana produksi sesuai kebutuhan.



### 7.2 PERANAN PERAMALAN DALAM MATERIAL REQUIREMENT PLANNING (MRP)

*Material Requirement Planning* (MRP) merupakan sistem perencanaan dalam proses produksi yang menggunakan informasi dari hasil peramalan data historis untuk merencanakan kebutuhan bahan baku, komponen, alat dan mesin yang digunakan guna memenuhi permintaan produk yang akan dihasilkan.

**Contoh dari MRP adalah sebagai berikut.**

#### ***Data Awal:***

Produk utama yang diproduksi adalah sepatu olahraga dengan bahan baku kulit sintetis, sol karet, dan tali sepatu. Proses produksi sepatu olahraga direncanakan dilakukan dalam empat minggu.

#### ***Data Tambahan:***

- Berdasarkan hasil peramalan rata-rata penjualan sepatu adalah 1000 pasang
- Waktu produksi untuk satu pasang sepatu adalah satu minggu.
- Waktu pemesanan bahan baku kurang lebih dua minggu.

- » *Lead time* pengiriman bahan baku kurang lebih satu minggu.
- » Bahan baku yang tersedia hanya cukup untuk memproduksi 200 pasang sepatu.

### ● **Identifikasi Kebutuhan dalam MRP**

Satu pasang sepatu membutuhkan kulit sintetis 1 m<sup>2</sup>, sol karet satu pasang, dan tali sepatu dua meter.

### ● **Menghitung Kebutuhan Bruto**

Misalkan menghitung kebutuhan tali sepatu. Dari hasil peramalan diketahui bahwa permintaan pada periode selanjutnya 1000 pasang sepatu. Tali sepatu dipesan sesuai dengan rencana produksi sehingga tidak ada sisa. Persamaan untuk menghitung kebutuhan bruto adalah sebagai berikut.

$$\text{Kebutuhan bruto} = \frac{(\text{Jumlah penjualan} + \text{persediaan akhir})}{\text{waktu produksi per pasang}}$$

$$\text{Sehingga :} \\ \text{Kebutuhan bruto} = \frac{1000 + 0}{4} = 250 \text{ meter}$$

### ● **Menghitung Kebutuhan Bersih**

Persediaan awal tali sepatu adalah 50 m. Persamaan untuk menghitung kebutuhan bersih adalah sebagai berikut.

$$\text{Kebutuhan bersih} = \text{kebutuhan bruto} - \text{persediaan awal}$$

$$\text{Sehingga :} \\ \text{Kebutuhan bersih tali sepatu} = 250 - 50 = 200 \text{ m}$$

### ● **Menentukan Waktu Pemesanan dan Pengiriman**

Pemesanan dilakukan dua minggu sebelum produksi dimulai dengan *lead time* sekitar satu minggu

### ● **Jadwal Produksi dan Pemesanan**

Jadwal yang disusun adalah sebagai berikut.

Minggu ke-	Aktivitas
1	Pemesanan kulit sintetis, sol karet, dan tali sepatu
2	Pengiriman bahan baku
3	Proses produksi sepatu
4	Proses distribusi sepatu



## DAFTAR PUSTAKA

- Abraham, B. and Ledolter, J. 1983. Statistical methods for forecasting, Wiley series in probability and mathematical statistics; Applied probability and statistics. John Wiley and Sons, New York
- Chopra, S & Meindl, P. 2016. Supply Chain Management: Strategy, Planning, and Operation. 6th edn, Pearson Education, Essex, NE.
- Hyndman, R. J. & Athanasopoulos, G. 2018. Forecasting: principles and practice, 2nd ed. Otexts
- Khoiri, H.A., Isnaini, W., Elyuda, D.R. 2021. Perencanaan Persediaan Darah di Unit Transfusi Darah (UTD) Palang Merah Indonesia Kota Madiun. Jurnal INTECH Vol. 7 No. 2 Hal. 115-120
- Khoiri, H.A., Muttaqin, A.Z., dan Elyuda, D.R. 2021. Analisis Peramalan Permintaan Darah di Unit Transfusi Darah Kota Madiun. Prosiding Seminar Nasional Teknik Industri Universitas Ma Chung Vol. 1 Hal. 24-32
- Vollman, T.E., Berry, W.L., Whybark, D.C., & Jacobs, F.R. 2005. Manufacturing Planning and Control for Supply Chain Management. McGraw-Hill



# Lampiran 1

## Data Permintaan Darah Golongan O

Tahun	Bulan	Permintaan Darah
2016	September	60
	Oktober	117
	November	164
	Desember	139
2017	Januari	193
	Februari	156
	Maret	132
	April	135
	Mei	138
	Juni	230
	Juli	180
	Agustus	158
	September	186
	Oktober	144
	November	214
	Desember	200
2018	Januari	215
	Februari	155
	Maret	186
	April	183
	Mei	207
	Juni	225
	Juli	252
	Agustus	161
	September	148
	Oktober	170
	November	180
	Desember	140

Tahun	Bulan	Permintaan Darah
2019	Januari	174
	Februari	247
	Maret	154
	April	215
	Mei	184
	Juni	267
	Juli	210
	Agustus	162
	September	148
	Oktober	92
	November	135
	Desember	95
2020	Januari	122
	Februari	97
	Maret	118
	April	83
	Mei	90
	Juni	101
	Juli	137
	Agustus	133
	September	103
	Oktober	135
	November	172
	Desember	106
2021	Januari	126
	Februari	80
	Maret	159
	April	151
	Mei	137

# Lampiran 2

## Data Permintaan Darah Golongan AB

Tahun	Bulan	Permintaan Darah
2017	Januari	41
	Februari	20
	Maret	32
	April	27
	Mei	15
	Juni	25
	Juli	31
	Agustus	37
	September	47
	Oktober	18
	November	36
	Desember	59
2018	Januari	33
	Februari	32
	Maret	49
	April	38
	Mei	17
	Juni	24
	Juli	18
	Agustus	23
	September	25
	Oktober	34
	November	14
	Desember	27

Tahun	Bulan	Permintaan Darah
2019	Januari	36
	Februari	46
	Maret	37
	April	20
	Mei	55
	Juni	27
	Juli	41
	Agustus	23
	September	24
	Oktober	14
	November	19
	Desember	13
2020	Januari	20
	Februari	7
	Maret	21
	April	3
	Mei	14
	Juni	29
	Juli	26
	Agustus	7
	September	37
	Oktober	16
	November	28
	Desember	23

# Lampiran 3

## Data IHK Kota Semarang 2014-2018

No	Periode	IHK	No	Periode	IHK
1	Jan-14	110,39	31	Jul-16	122,42
2	Feb-14	110,66	32	Aug-16	121,89
3	Mar-14	110,96	33	Sep-16	121,74
4	Apr-14	110,92	34	Oct-16	122,35
5	May-14	111,2	35	Nov-16	121,88
6	Jun-14	112,15	36	Dec-16	122,25
7	Jul-14	112,85	37	Jan-17	125,97
8	Aug-14	113,31	38	Feb-17	126,53
9	Sep-14	113,77	39	Mar-17	126,35
10	Oct-14	114,4	40	Apr-17	126,63
11	Nov-14	115,95	41	May-17	127,38
12	Dec-14	118,73	42	Jun-17	127,85
13	Jan-15	121,77	43	Jul-17	128,24
14	Feb-15	120,52	44	Aug-17	127,63
15	Mar-15	120,27	45	Sep-17	127,07
16	Apr-15	120,46	46	Oct-17	127,88
17	May-15	120,68	47	Nov-17	128,26
18	Jun-15	120,34	48	Dec-17	129,13
19	Jul-15	119,26	49	Jan-18	130,17
20	Aug-15	118,5	50	Feb-18	130,65
21	Sep-15	117,86	51	Mar-18	130,71
22	Oct-15	117,66	52	Apr-18	130,74
23	Nov-15	117,37	53	May-18	130,62
24	Dec-15	118,16	54	Jun-18	131,45
25	Jan-16	124,59	55	Jul-18	131,6
26	Feb-16	124,34	56	Aug-18	131,45
27	Mar-16	123,67	57	Sep-18	131,57
28	Apr-16	123,6	58	Oct-18	131,94
29	May-16	123,44	59	Nov-18	132,22
30	Jun-16	123,7	60	Dec-18	132,7