

## BAB II

### TINJAUAN PUSTAKA

#### 2.1. Peramalan (*Forecasting*)

*Forecasting* adalah suatu ilmu yang digunakan untuk meramalkan atau memprediksi kejadian di waktu mendatang. Peramalan dapat dilakukan dengan cara institusi subjektif atau dengan model matematis (Heizer & Render, 2011). Metode peramalan dapat dibagi dalam dua kategori utama, yaitu metode kualitatif dan metode kuantitatif. Metode peramalan kuantitatif dapat diterapkan bila terdapat tiga kondisi berikut, yaitu (Aswi dan Sukarna, 2006):

1. Tersedia informasi tentang masa lalu.
2. Informasi tersebut dapat dikuantitatifkan dalam bentuk data numerik.
3. Diasumsikan bahwa beberapa aspek pola masa lalu akan berlanjut di masa mendatang.

#### 2.2. Metode Deret Waktu (*Time Series*)

Metode *time series* diperkenalkan pada tahun 1970 oleh George E.P. Box dan Gwilym M. Jenkins melalui bukunya yang berjudul *Time Series Analysis: Forecasting and Control*. Data deret waktu merupakan serangkaian data yang berupa nilai pengamatan yang diukur selama kurun waktu tertentu, berdasarkan interval waktu yang tetap (Wei, 2006). Metode *time series* berupaya untuk meramalkan kondisi yang akan datang dengan menggunakan data historis dan mengekstrapolasikan pola tersebut ke masa depan.

Dengan demikian tujuan analisis deret waktu antara lain sebagai berikut (Aswi dan Sukarna, 2006):


1. Meramalkan kondisi di masa yang akan datang.
2. Mengetahui hubungan antarpeubah.
3. Kepentingan kontrol.

Suatu urutan pengamatan memiliki model deret waktu jika memenuhi asumsi berikut (Aswi dan Sukarna, 2006):

1. Interval waktu dapat dinyatakan dalam satuan waktu yang sama (identik).
2. Adanya ketergantungan atau hubungan antara kejadian masa mendatang terhadap masa sebelumnya atau lebih dikenal dengan istilah adanya autokorelasi antara suatu variabel pada waktu tertentu dengan variabel itu sendiri pada waktu-waktu sebelumnya.
3. Data masa depan mengikuti pola data yang terjadi di masa lalu dan hubungan atau keterkaitan di masa lalu dapat ditentukan dengan pengamatan atau penelitian, akurasi yang dihasilkan dari peramalan deret waktu, sangat ditentukan oleh seberapa jauh asumsi-asumsi di atas dipenuhi. Langkah penting dalam memilih suatu metode deret waktu yang tepat adalah dengan mempertimbangkan jenis pola data. Pola data dapat dibedakan menjadi empat jenis (Makrikadis, *et.al.*, 1995) yaitu:

1. *Trend* (Tren)

Pola data *trend* menunjukkan pergerakan data yang cenderung meningkat atau menurun dalam jangka waktu tertentu. Pola data *trend* dapat dilihat pada gambar 2.1



**Gambar 2. 1 Pola Data *Trend***

2. *Seasonal* (musiman)


Pola data musiman merupakan pola data yang berhubungan dengan faktor yang bersifat eventual, seperti libur sekolah atau hari raya. Pola data musiman dapat dilihat pada gambar 2.2



**Gambar 2.2 Pola Data Musiman (*Seasonal*)**

3. *Cycles* (siklus)


Pola data siklus merupakan pola dimana variasi data bergelombang pada durasi yang lebih panjang dan bervariasi dari satu siklus ke siklus yang lain



**Gambar 2.3 Pola Data Siklus (*Cycles*)**

#### 4. Stasionary (stasioner)

Pola data stasioner merupakan pola dimana data berfluktuasi di sekitar nilai rata-rata keseluruhan data dan pola ini tidak membentuk pola yang jelas seperti pola musiman, trend maupun pola siklus.



**Gambar 2.4 Pola Data *Stasionary* (Horizontal)**

### 2.3. *Singular Spectrum Analysis* (SSA)

*Singular Spectrum Analysis* (SSA) adalah teknik analisis deret waktu nonparametrik yang digunakan untuk peramalan. SSA terdiri dari dua tahap yang saling melengkapi, yaitu tahap dekomposisi dan tahap rekonstruksi. Pada tahap dekomposisi, dua langkah utama yang harus dilakukan untuk memperoleh *eigen triple*, yaitu *embedding* dan *singular value decomposition*. Pada tahap rekonstruksi, dua langkah yang harus dilakukan untuk memperoleh deret yang direkonstruksi, yaitu pengelompokan dan *diagonal averaging*.

#### 2.3.1 Dekomposisi

Pada tahap dekomposisi, parameter yang digunakan adalah *Window Length* (L) (Ischak, 2018). Parameter ini berfungsi untuk menentukan banyaknya dimensi matriks lintasan. Nilai L ini merupakan dimensi dari matriks lintasan yang merupakan matriks dari perkalian *Hankel*. Pemilihan *window length* (L) berdasarkan *trial and error*.

### 2.3.1.1 Embedding

*Embedding* merupakan proses dimana data deret waktu asli diubah menjadi *trajectory matrix*, artinya data asli yang merupakan data satu dimensi diubah menjadi bentuk multidimensi. *Trajectory matrix* ( $\mathbf{X}$ ) tersebut memiliki dimensi  $L \times K$ , yang artinya nilai  $L$  (*window length*) menjadi baris matriks dan  $K$  menjadi kolom matriks dimana nilai  $K=N-L+1$ . Tahapan ini memerlukan pemilihan *window length* atau nilai  $L$  dengan rentang  $2 < L < \frac{N}{2}$ , serta asumsi bahwa data deret waktu sepanjang periode  $N$  tidak mengandung data hilang, serta  $X = \{x_i\}; i = 1, 2, \dots, N$ .

*Trajectory matrix* ( $\mathbf{X}$ ) yang terbentuk merupakan matriks Hankel yang artinya bahwa semua elemen di sepanjang diagonal adalah sama. Dengan demikian, dapat dituliskan sebagai:

$$\mathbf{X} = (X_{ij})_{L \times K} = \begin{bmatrix} x_1 & x_2 & \dots & x_K \\ x_2 & x_3 & \dots & x_{K+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & \dots & x_N \end{bmatrix} \quad (2.1)$$

### 2.3.1.2. Dekomposisi Nilai Singular (SVD)

SVD merupakan tahapan kunci dalam metode SSA. SVD diterapkan pada *trajectory matrix* ( $\mathbf{X}$ ) untuk memperoleh hasil dekomposisi *trajectory matrix* yaitu  $\mathbf{X}_i; i = 1, 2, \dots, L$ . Tujuan dari SVD adalah memperoleh pemisahan komponen dalam dekomposisi dari data deret waktu. Penerapan SVD pada dasarnya sama dengan analisis komponen utama (*principal component analysis*) yaitu mereduksi komponen dari data asli serta mengurangi dimensi.

Tahapan SVD dimulai dengan menentukan eigenvalue ( $\lambda_1, \dots, \lambda_L$ ) dari matriks  $\mathbf{S} = \mathbf{X}\mathbf{X}^T$  dimana  $\lambda_1 \geq \dots \geq \lambda_L \geq 0$ , serta eigenvector ( $U_1, \dots, U_L$ ) dari matriks tersebut. Hasil dari penerapan SVD pada  $\mathbf{X}_i$  menghasilkan  $\mathbf{X}_i = U_i D_i V_i'$ .  $U_i$  adalah

matriks ortonormal  $K \times L$ ;  $D_i$  adalah matriks diagonal orde  $L$ ; sedangkan  $V_i = \mathbf{X}^T U_i$   
 $1/\sqrt{\lambda_i}$  adalah matriks ortonormal bujursangkar  $L \times L$ , sehingga menghasilkan

$$\mathbf{X}_i = \sum_{i=1}^d \sqrt{\lambda_i} U_i V_i^T \quad (2.2)$$

Dengan  $i = 1, 2, \dots, d$  dan  $d = \max\{i\}; \lambda_i > 0$

Ketiga komponen dalam matriks  $X_i$  yaitu *singular value*  $\sqrt{\lambda_i}$ , *eigenvector*  $U_i$ , dan *principal component* ( $V_i$ ) disebut *eigen triple* ke- $i$  dari SVD.

Selanjutnya, SVD untuk trajectory matrix  $\mathbf{X}_i$  dapat dituliskan sebagai berikut:

$$\mathbf{X}_i = \mathbf{X}_1 + \mathbf{X}_2 + \dots + \mathbf{X}_d \quad (2.3)$$

### 2.3.2 Rekonstruksi

Pada tahap rekonstruksi terjadi dua tahap pengerjaan, yaitu tahap grouping dan diagonal averaging. Parameter yang memiliki peran penting dalam rekonstruksi adalah *grouping effect* ( $r$ ). Fungsi dari parameter ini adalah menentukan pola pada plot data. Sebelumnya pada tahap dekomposisi dengan penggunaan parameter  $L$ , dan menyajikan serangkaian seri awal yang telah dipisahkan dengan baik pada SVD maka *eigen triples* yang terbentuk akan membantu dalam penentuan parameter *grouping effect*. Hasil dari tahap rekonstruksi akan mendekati hasil peramalan dengan data asli. Oleh karena itu pengelompokan yang tepat dilakukan akan mendukung hasil peramalan dengan baik dengan menunjukkan nilai MAPE dari nilai ramal dengan data asli.

#### 2.3.2.1 Pengelompokan / Grouping

*Grouping* adalah tahap penguraian matriks lintasan  $L \times K$  menjadi beberapa sub-kelompok yaitu tren, musiman/periodik dan noise yang terdapat pada data deret waktu. Pengelompokan berhubungan erat dengan pemecahan matriks  $\mathbf{X}_i$  menjadi



beberapa kelompok dan menjumlahkan matriks dalam masing-masing kelompok. Matriks  $\mathbf{X}_I$  akan dipartisi menjadi  $m$  himpunan bagian yang saling lepas,  $I_1, \dots, I_m$ . Diberikan  $I = \{i_1, \dots, i_p\}$ , maka matriks  $\mathbf{X}_I$  yang dihasilkan sesuai dengan kelompok  $I$  yang didefinisikan sebagai  $\mathbf{X}_I = \mathbf{X}_{i_1} + \dots + \mathbf{X}_{i_p}$ . Matriks ini dihitung untuk  $I = I_1, \dots, I_m$  dan ekspansi (2.2) menyebabkan dekomposisi

$$\mathbf{X} = \mathbf{X}_{I_1} + \dots + \mathbf{X}_{I_m} . \quad (2.4)$$

Prosedur pemilihan himpunan  $I_1, \dots, I_m$  disebut sebagai pengelompokan *eigentriple*. Jika  $m = d$  dan  $I_j = \{j\}$ ,  $j = 1, \dots, d$ , maka pengelompokan yang sesuai disebut elementer (Golyandina dan Zhigljavsky, 2013).

### 2.3.2.2 Diagonal Averaging

Selanjutnya memasuki tahap *diagonal averaging* pada hasil *grouping* sehingga matriks  $\mathbf{X}_{I_1}$  akan ditransformasikan ke dalam seri baru dengan panjang  $N$ . Tujuan dari tahap ini adalah untuk mendapatkan *singular value* dari komponen-komponen yang telah dipisahkan, yang kemudian digunakan dalam peramalan. Untuk mencari nilai rata-rata diagonal matriks dapat digunakan persamaan sebagai berikut:

$$gk \begin{cases} \frac{1}{k+1} \sum_{m=1}^{k+1} y_{m, k-m+2}^* & \text{untuk } 0 \leq k < L^* - 1, \\ \frac{1}{L^*} \sum_{m=1}^{L^*} y_{m, k-m+2}^* & \text{untuk } L^* - 1 \leq k < K^*, \\ \frac{1}{N-k} \sum_{m=k-K^*+2}^{N-K^*+1} y_{m, k-m+2}^* & \text{untuk } K^* \leq k < N. \end{cases} \quad (2.5)$$

dengan

$$L^* = \min(L, K); K^* = \max(L, K)$$

$$N = L + K - 1$$

$$y_{ij}^* = \begin{cases} y_{ij}; & L < K \\ y_{ji}; & \text{selainnya} \end{cases}$$

Persamaan (2.5) merupakan rata-rata dari elemen matriks di sepanjang diagonal  $i+j = k + 2$ .  $K=0$  akan menghasilkan  $g_0 = y_{11}$ ,  $k = 1$  menghasilkan  $g_0 = \frac{y_{12}y_{21}}{2}$ , dan seterusnya.

#### 2.4. Peramalan dalam *Singular Spectrum Analysis* (SSA)

Prinsip-prinsip peramalan dalam *Singular Spectrum Analysis* (SSA) memiliki sifat penting dari dekomposisi SSA jika seri asli  $f_n$  memenuhi rumus *linear recurrent formula* (LRF)

$$f_n = a_1 f_{n-1} + \dots + a_d f_{n-d} \quad (2.6)$$

dimana  $d$  ( $d \leq L$ ) adalah angka dari *nonzero singular values* dari matriks  $\mathbf{X}$ . Dari beberapa dimensi  $d$  dengan beberapa koefisien  $a_1, \dots, a_d$  kemudian untuk setiap  $N$  dan  $L$  terdapat banyak nilai singular  $d$  *nonzero* dalam SVD dari matriks lintasan  $\mathbf{X}$ . Oleh karena itu jika *window length*  $L$  dan  $K = N-L+1$  lebih besar dari  $d$ , maka hanya dibutuhkan lebih banyak  $d$  pada matriks  $\mathbf{X}_i$  untuk merekonstruksi data (Golyandina, 2001). Asumsikan tujuan yang ingin dicapai dengan menggunakan SSA adalah suatu komponen aditif tertentu  $F_N^{(1)}$  dapat diekstrak dari suatu deret  $F_N$ . Dalam algoritma ini, suatu *window length*  $L$  yang sesuai, SVD matriks lintasan diperoleh dari deret  $F_N$  dan *eigen triples*  $(\sqrt{\lambda}, U, V)$  dipilih yang sesuai dengan  $F_N^{(1)}$ . Pada langkah *diagonal averaging*, deret yang direkonstruksi  $F_N^{(1)}$  yang mengestimasi  $F_N^{(1)}$  akan diperoleh (Ete, 2017).

##### 2.4.1. *Reccurent Forecasting*

Algoritma *Reccurent Forecasting* dapat dirumuskan sebagai berikut:

1. Deret waktu  $\mathbf{Y}_{N+M} = (y_1, \dots, y_{N+M})$  didefinisikan dengan



$$y_i = \begin{cases} \bar{x}_i & \text{for } i=1, \dots, N \\ \sum_{j=1}^{L-1} a_j y_{i-j} & \text{for } i=N+1, \dots, N+M \end{cases} \quad (2.7)$$

2. Angka-angka  $\mathbf{Y}_{N+1}, \dots, \mathbf{Y}_{N+M}$  membentuk istilah  $M$  dari *Recurrent Forecasting*.

Jadi, peramalan *Recurrent Forecasting* dilakukan dengan penggunaan langsung LRR dengan koefisien  $\{a_j, j = 1, \dots, L-1\}$ .

Definisikan operator linear  $\mathcal{P}_{\text{Rec}} : \mathbb{R}^L \rightarrow \mathbb{R}^L$  dengan rumus  $\mapsto$

$$\mathcal{P}_{\text{Rec}} \mathbf{Y} = \begin{pmatrix} \bar{Y} \\ \mathbf{R}^T \bar{Y} \end{pmatrix} \quad (2.8)$$

dengan,

$$Z_i = \begin{cases} \bar{X}_i & \text{for } i = 1, \dots, K \\ \mathcal{P}_{\text{Rec}} Z_{i-1} & \text{for } i = K+1, \dots, K+M \end{cases} \quad (2.9)$$

Dapat dilihat bahwa matriks  $\mathbf{Z} = [Z_1 : \dots : Z_{K+M}]$  adalah matriks lintasan dari  $\mathbf{Y}_{N+M}$ . Karena itu (2.9) dapat dianggap bentuk vector dari (2.7).

## 2.5. Ukuran Keباikan Model Peramalan

Dalam melakukan suatu peramalan yang merupakan kegiatan memprediksi masa depan dengan menggunakan data di masa lampau, hasil yang akan didapatkan tidaklah sama dengan data sesungguhnya (Ishcak, 2018). Maka dari itu usaha untuk membuat nilai *error* seminimal mungkin dibutuhkan pada proses peramalan. Salah satu tingkat akurasi peramalan dapat diukur dari nilai *Mean Absolute Percentage Error* (MAPE) yaitu rata-rata persentase kesalahan pertama dari beberapa periode.

Untuk melakukan peramalan dan untuk mengetahui akuratnya sebuah model maka nilai akurasi harus semakin kecil.

$$\text{MAPE} = \frac{\sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|}{n} \times 100\% \quad (2.10)$$

Untuk ketentuan MAPE adalah sebagai berikut :

**Tabel 2. 1 Kriteria nilai MAPE**

MAPE	Keterangan
<10 %	Sangat Baik
<20 %	Baik
<30 %	Cukup Baik
>30%	Tidak Akurat

Sumber : (Lewis, 1997).

## 2.6. Harga beras

Beras berperan besar dalam kehidupan sebagian besar rakyat Indonesia, khususnya golongan menengah ke bawah. Beras tidak hanya menjadi komoditas pangan, juga merupakan komoditas ekonomi, sosial, politik dan budaya di Indonesia. Perekonomian beras merupakan komoditas strategis dan pendukung pesatnya pertumbuhan ekonomi di Indonesia. Kekurangan beras dapat menjadi ancaman terhadap kestabilan ekonomi dan politik. Peningkatan pendapatan mendorong pola konsumsi rumah tangga di daerah yang sebelumnya mengkonsumsi non beras (jagung, ubi-ubian, sagu) bergeser ke beras. Oleh karena itu, pemerintah sangat penting dalam mengendalikan harga dan pasokan beras melalui kebijakan perberasan yang bersifat promotif dan maupun protektif yang punya dampak langsung terhadap kesejahteraan petani.

Indonesia pernah menjadi negara penghasil beras tertinggi di dunia dan mampu menjadi negara swasembada beras. Regulasi terkait beras banyak mengalami perubahan karena kebijakan beras selalu menyangkut harkat hidup seluruh masyarakat Indonesia. Beras juga merupakan ukuran ketahanan pangan

suatu bangsa, oleh karena itu beras menjadi komoditas yang penting untuk diteliti dan terus diupayakan guna mencukupi kebutuhannya dengan produksi dalam negeri. Umumnya volume beras yang diperdagangkan merupakan sisa konsumsi dalam negara. Semakin tidak stabilnya harga beras dunia atau dalam suatu negeri, semakin besar tingkat *self-sufficiency* yang dianut suatu negara.

Komponen pengeluaran konsumsi masyarakat Indonesia, beras mempunyai bobot paling tinggi. Oleh karena itu inflasi nasional sangat dipengaruhi oleh dua perubahan harga beras. Harga beras dalam negeri mengalami peningkatan lebih tinggi daripada harga beras impor, sehingga dapat mengakibatkan berbagai dampak baik bagi produsen maupun konsumen. Munculnya kekhawatiran apabila pemerintah tidak bisa memperkirakan kebutuhan beras nasional secara tepat yang bisa berakibat pada pelonjakan harga beras yang dapat menimbulkan kerugian bagi konsumen maupun petani di Indonesia. Krisis ekonomi dan krisis pangan yang terjadi di tahun 1998 memicu penurunan produksi beras dalam negeri hingga 4,6 persen. Hal itu juga memicu terjadinya kenaikan harga beras. Pemerintah harus berupaya untuk menstabilkan harga pangan terutama beras. Peramalan harga beras dapat membantu upaya untuk menstabilkan harga bahan pokok makanan, sebab jika harga barang tidak stabil dapat menyebabkan inflasi ataupun deflasi