

## BAB II

### TINJAUAN PUSTAKA


#### 2.1 *Time Series*

*Time series* merupakan rangkaian nilai-nilai suatu observasi yang dikumpulkan dan dicatat dari waktu ke waktu secara berurutan. Secara umum pencatatan dilakukan berdasarkan jangka waktu tertentu seperti harian, mingguan, bulanan, tahunan dan sebagainya yang biasanya mempunyai interval waktu yang sama. Analisis *time series* dilakukan untuk menemukan pola variasi masa lampau yang kemudian dapat digunakan untuk memperkirakan nilai di masa mendatang.

Pemilihan metode *time series* yang tepat didasarkan pada tipe pola data yang akan diprediksi. Pola data dibagi menjadi empat komponen diantaranya adalah (Supriyanto,2017):

##### 1. Horizontal


Pola horizontal merupakan pola acak yang disebabkan oleh peristiwa yang tidak dapat diprediksi atau tidak beraturan karena suatu faktor. Plot pola horizontal dapat dilihat pada Gambar 2.1.



**Gambar 2. 1 Tipe Pola Data Horizontal**

## 2. Musiman

Pola musiman merupakan fluktuasi dari data yang terjadi secara periodik seperti mingguan, bulanan atau kuartalan. Pola ini terbentuk akibat beberapa aktivitas dari data dalam suatu periode kecil sehingga grafik yang dihasilkan akan serupa jangka waktu tertentu secara berulang-ulang. Plot pola musiman dapat dilihat pada Gambar 2.2.



**Gambar 2. 2 Tipe Pola Data Musiman**

## 3. *Trend*


Pola *trend* merupakan kecenderungan arah data dalam jangka panjang berupa kenaikan ataupun penurunan. Plot pola *trend* dapat dilihat pada Gambar 2.3.



**Gambar 2. 3 Tipe Pola Data *Trend***

## 4. Siklis

Pola siklis merupakan suatu pola fluktuasi atau siklis dari data deret waktu akibat perubahan kondisi ekonomi, biasanya pola ini dipengaruhi oleh faktor eksternal. Plot pola siklis dapat dilihat pada Gambar 2.4.



**Gambar 2. 4 Tipe Pola Data Siklis**

## 2.2 Peramalan

Peramalan (*forecasting*) merupakan suatu cara untuk memperkirakan suatu nilai pada masa yang akan datang dengan memperhatikan data masa lampau maupun data saat ini. Peramalan menjadi dasar dalam perencanaan jangka panjang bagi suatu perusahaan atau instansi. Keakuratan hasil peramalan akan meningkatkan peluang tercapainya investasi yang menguntungkan. Peramalan berperan penting dalam pengambilan sebuah kebijakan, baik efektif atau tidaknya bisa dilihat dari waktu kebijakan itu diambil. Peramalan dilakukan berdasarkan data masa lampau yang dikumpulkan, kemudian dipelajari, dan dianalisis berdasarkan perjalanan waktu (Lamusa, 2017).

## 2.3 *Singular Spectrum Analysis*

*Singular Spectrum Analysis* (SSA) merupakan metode peramalan yang menggabungkan unsur analisis klasik deret waktu, statistika multivariat, geometri multivariat, sistem dinamik dan proses signal. SSA memiliki tujuan utama untuk mendekomposisikan deret waktu aslinya menjadi sejumlah kecil komponen yang dapat diidentifikasi seperti *trend*, musiman dan *noise*. SSA dapat mengatasi beberapa masalah diantaranya menemukan tren dalam resolusi yang berbeda, *smoothing*, mengekstrak komponen musiman, mengekstrak secara simultan pola

siklis, mengekstrak periodesitas dengan amplitudo yang beragam, menemukan struktur data pada data deret waktu yang pendek dan mendeteksi perubahan titik. Metode SSA terbagi menjadi 2 tahapan utama yaitu dekomposisi dan rekonstruksi (Cahyati, 2017).

### 2.3.1 Dekomposisi

Pada tahap dekomposisi, parameter yang digunakan adalah *window length* ( $L$ ). Parameter  $L$  memiliki fungsi untuk menentukan banyaknya dimensi matriks lintasan. Penentuan nilai  $L$  dilakukan dengan cara pengecekan melalui *trial and error*. Tahap Dekomposisi ini terdiri dari dua tahap yaitu tahap *Embedding* dan tahap *Singular Value Decomposition* (SVD) (Shafira, 2020).

#### 2.3.1.1 Embedding

*Embedding* merupakan tahapan dimana suatu data deret waktu awal diubah menjadi yang berupa data berdimensi satu (vektor) menjadi data yang multidimensi (matriks). Misalkan data deret waktu dengan panjang  $N$  yang dinyatakan dengan  $F = (f_1, f_2, \dots, f_N)$  dimana  $F$  merupakan data deret waktu yang tidak bernilai nol atau tidak terdapat data *missing* yang kemudian data diubah ke dalam bentuk matriks lintasan berukuran  $L \times K$ . Diberikan parameter  $L$  dengan ketentuan nilai  $2 < L < \frac{N}{2}$ , kemudian membentuk nilai  $K = N - L + 1$ .

$$X_i = (f_i, \dots, f_{N+L-1})^T, (1 \leq i \leq K) \quad (2.1)$$

dengan dimensi  $L$ . Apabila dimensi dari  $X_i$  yang ditekankan, maka  $X_i$  dapat disebut sebagai *L-lagged vectors*. Matriks lintasan dari deret  $F$  dapat digambarkan sebagai berikut:

$$X = [X_1: \dots: X_K] = (x_{ij})_{i,j=1}^{L,K} = \begin{pmatrix} f_1 & f_2 & f_3 & \dots & f_K \\ f_2 & f_3 & f_4 & \dots & f_{K+1} \\ f_3 & f_4 & f_5 & \dots & f_{K+2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ f_L & f_{L+1} & f_{L+2} & \dots & f_N \end{pmatrix} \quad (2.2)$$

Lagged vectors  $X_i$  yaitu kolom dari matriks lintasan  $X$ . Baris dan kolom dari  $X$  adalah subderet dari deret asli. Unsur ke-  $(i, j)$  dari matriks  $X$  yaitu  $x_{ij} = f_{i+j-2}$ . Matriks lintasan  $X$  adalah sebuah matriks Hankel. Apabila  $N$  dan  $L$  ditetapkan maka terdapat korespondensi satu-satu antara matriks lintasan dan deret waktu.

### 2.3.1.2 Singular Value Decomposition (SVD)

Tahap selanjutnya yaitu pembentukan *Singular Value Decomposition* dari matriks lintasan  $X$ , yang dimulai dengan menentukan nilai *eigenvalue*  $(\lambda_1, \lambda_2, \dots, \lambda_L)$  dari matriks simetris  $S = XX^T$  dimana  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L > 0$  dengan persamaan  $|S - \lambda I| = 0$ , dan *eigenvector*  $(U_1, U_2, \dots, U_L)$  dari matriks  $S$  yang bersesuaian dengan nilai eigen. Didefinisikan  $d = \max \{i, \text{sehingga } \lambda_i > 0\}$  merupakan *rank* dari matriks  $X$ . Apabila *principal component* dinotasikan dengan  $V_i = \frac{X^T U_i}{\sqrt{\lambda_i}}$ , untuk  $i = 1, \dots, d$ , maka SVD dari matriks lintasan  $X$  dapat ditulis sebagai berikut:

$$X = X_1 + \dots + X_d \quad (2.3)$$

dimana  $X_i = \sqrt{\lambda_i} U_i V_i^T$ . Matriks  $X_i$  mempunyai *rank* 1, oleh karena itu matriks  $X_i$  adalah matriks elementer. Kumpulan  $(\sqrt{\lambda_i}, U_i, V_i)$  disebut *eigen triple* ke- $i$  dari SVD.

### 2.3.2 Rekonstruksi

Tahap Rekonstruksi merupakan tahapan dimana data direkonstruksi menjadi data deret waktu yang baru. Pada tahap ini terdiri dari dua proses yaitu tahap *Grouping* dan tahap *Diagonal Average*. Parameter yang digunakan pada tahap ini adalah *grouping effect* ( $r$ ) yang berfungsi untuk menentukan pola pada plot data.

#### 2.3.2.1 Grouping

Tahap pertama dari rekonstruksi adalah *tahap grouping* yang merupakan himpunan indeks dari  $\{1, \dots, d\}$  menjadi  $m$  grup himpunan bagian yang saling lepas,  $I_1, \dots, I_m$ . Misalkan  $I = \{i_1, \dots, i_p\}$ , maka matriks  $X_I$  yang dihasilkan sesuai dengan kelompok  $I$  yang didefinisikan sebagai  $X_I = X_{i_1} + \dots + X_{i_p}$ . Matriks ini dihitung untuk  $I = I_1, \dots, I_m$  dan ekspansi (2.3) menyebabkan dekomposisi

$$X = X_{I_1} + \dots + X_{I_m} \quad (2.4)$$

Proses pemilihan himpunan  $I_1, \dots, I_m$  disebut sebagai pengelompokan *eigentriple*. Apabila  $m = d$  dan  $I_j = \{j\}$ ,  $j = 1, \dots, d$ , maka pengelompokan yang sesuai disebut elementer.

#### 2.3.2.2 Diagonal Averaging

Tahap terakhir dalam metode SSA adalah mengubah setiap matriks  $X_{I_j}$  dari dekomposisi yang dikelompokkan (2.4) menjadi suatu deret baru dengan panjang  $N$ . Misalkan  $Y$  adalah sebuah matriks berukuran  $L \times K$  dengan unsur-unsur  $y_{ij}$ ,  $1 \leq i \leq L$ ,  $1 \leq j \leq K$ , untuk  $L \leq K$ . Diberikan  $L^* = \min(L, K)$ ,  $K^* = \max(L, K)$ ,  $N = L + K - 1$ ,  $y_{ij}^* = y_{ij}$  jika  $L < K$ , dan  $y_{ij}^* = y_{ij}$  jika  $L > K$ .

*Diagonal averaging* memindahkan matriks  $Y$  ke deret  $g_0, \dots, g_{N-1}$  dengan persamaan sebagai berikut:

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

Persamaan (2.5) berhubungan dengan rata-rata elemen matriks atas anti diagonals  $i + j = k + 2$ . Untuk pilihan  $k = 0$  memberikan  $g_0 = y_{1,1}$ , pilihan  $k = 1$  memberikan  $g_1 = \frac{y_{1,2} + y_{2,1}}{2}$ , dan seterusnya. Perhatikan bahwa jika matriks  $Y$  adalah matriks lintasan dari beberapa deret  $(h_1, \dots, h_N)$ , maka  $g_i = h_i$  untuk semua  $i$ .

Apabila *diagonal averaging* (2.5) diterapkan pada matriks  $X_{I_k}$  yang dihasilkan, maka akan diperoleh suatu deret yang direkonstruksi  $F^{(k)} = (f_1^{(k)}, \dots, f_N^{(k)})$ . Oleh karena itu, deret awal  $f_1, \dots, f_N$  didekomposisi menjadi jumlah dari  $m$  deret yang direkonstruksi:

$$f_n = \sum_{k=1}^m f_n^{(k)}, \quad (n = 1, 2, \dots, N) \quad (2.6)$$

#### 2.4 Neural Network

*Neural Network* merupakan salah satu model nonlinear yang memiliki bentuk fungsional fleksibel dan mengandung parameter yang tidak dapat diinterpretasikan seperti pada model parametrik. NN adalah suatu kumpulan elemen-elemen pemroses yang saling berhubungan yang disebut dengan unit-unit atau syaraf-syaraf. Metode NN telah banyak dikembangkan dan dapat digunakan dalam meramalkan pola masa lampau, karena mempunyai kemampuan dalam mengingat

dan membuat generalisasi dari apa yang telah ada sebelumnya, kemampuannya untuk belajar dan kebal terhadap adanya kesalahan, sehingga dapat mewujudkan sistem yang tahan akan kerusakan dan konsisten bekerja dengan baik. NN dalam bidang statistik mampu mengolah data dalam jumlah besar dan dapat mempunyai nilai akurasi yang cukup tinggi dalam melakukan peramalan (Floronica, 2019).

Secara umum, bentuk arsitektur NN yang paling banyak digunakan dalam aplikasi di bidang teknik atau rekayasa yaitu *MultiLayer Perceptrons* (MLP) yang dikenal sebagai *Feedforward Neural Networks* (FFNN). FFNN dalam pemodelan statistik dapat dipandang sebagai suatu kelas yang fleksibel dari fungsi-fungsi nonlinear. Model ini secara umum bekerja dengan menerima suatu vektor dari input  $x$ , lalu menghitung suatu respon atau output  $\hat{y}(x)$  dengan memproses (*propagating*)  $x$  melalui elemen-elemen proses yang saling terkait. Elemen-elemen proses tersusun dalam beberapa lapis (*layer*) dan data *input*  $x$  mengalir dari satu lapis ke lapis berikutnya secara berurutan. Setiap lapis, input-input ditransformasi kedalam lapis secara *nonlinear* oleh elemen-elemen proses yang kemudian diproses maju ke lapis berikutnya. Pada akhirnya nilai-nilai *output*  $\hat{y}$  yang berupa nilai-nilai skalar atau vektor, dihitung pada lapis output. Bentuk khusus FFNN dengan satu lapis tersembunyi yang terdiri dari  $q$  *unit neuron* dan lapis *output* yang hanya terdiri dari satu *unit neuron* dengan nilai-nilai respon atau *output*  $\hat{y}$  dihitung dengan rumus sebagai berikut:

$$\hat{y}_{(k)} = f^0 \left[ \sum_{j=1}^q \left[ w_1^0 f_j^h \left( \sum_{i=1}^p w_{ji}^h x_{i(k)} + b_j^h \right) + b^0 \right] \right] \quad (2.7)$$

dimana:



$x_{i(k)}$  = variabel *input* sebanyak  $p$ , ( $i = 1, 2, \dots, p$ )

$\hat{y}_{(k)}$  = nilai dugaan dari variabel *output*

$k$  = indeks pasangan data *input-target* ( $x_{i(k)}, y_{(k)}$ ),  $k = 1, 2, \dots, n$

$w_{ji}^h$  = bobot dari *input* ke- $i$  yang menuju *neuron* ke- $j$  pada lapis tersembunyi,  
( $j=1, 2, \dots, q$ )

$b_j^h$  = bias pada *neuron* ke- $j$  pada lapis tersembunyi ( $j = 1, 2, \dots, q$ )

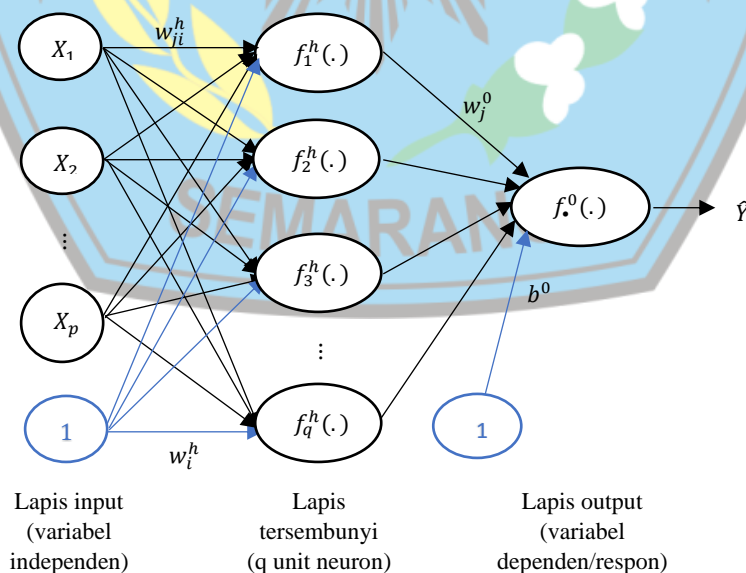
$f_j^h$  = fungsi aktivasi di *neuron* pada lapis tersembunyi

$w_1^0$  = bobot dari *neuron* di lapis tersembunyi menuju *neuron* pada lapis *output*

$b^0$  = bias pada *neuron* di lapis *output*

$f^0$  = fungsi aktivasi pada *neuron* di lapis *output*

Arsitektur FFNN dari persamaan (2.7) digambarkan dalam ilustrasi sebagai berikut (Setyowati, 2018).



**Gambar 2. 5** Arsitektur *Feed Forward Neural Network*

## 2.5 Hybrid Singular Spectrum Analysis-Neural Network

Metode *Singular Spectrum Analysis* secara umum mampu dalam mendekomposisi suatu deret data menjadi pola *trend*, musiman dan *noise*. Hasil dari dekomposisi pola-pola data tersebut yang kemudian dilakukan peramalan dengan menggunakan salah satu metode yaitu *neural network*. Peramalan dilakukan secara agregat yaitu dengan menjumlahkan komponen yang mempunyai pola yang sama sehingga hanya terbentuk tiga pola utama yaitu *trend*, musiman dan *noise*. Jika *noise* yang dihasilkan telah *white noise* maka tidak perlu dilakukan peramalan. Hasil peramalan secara agregat akan dilakukan penjumlahan karena jenis data yang digunakan yaitu dekomposisi sehingga akan terbentuk nilai ramalan (Setyowati, 2018).

## 2.6 Evaluasi Kebaikan Model

Evaluasi kebaikan model dilakukan untuk mengetahui seberapa baik model yang terbentuk dari meramalkan peristiwa pada beberapa periode kedepan. Evaluasi dilakukan dengan melihat nilai keakuratan hasil peramalan, salah satunya menggunakan nilai *Mean Absolute Percentage Error* (MAPE). MAPE merupakan rata-rata persentase kesalahan dalam peramalan dibandingkan dengan nilai aktual. Berikut ini rumus untuk menghitung nilai MAPE.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100\% \quad (2.8)$$

dimana:

$Y_t$  : Nilai aktual pada periode t

$\hat{Y}_t$  : Nilai prediksi pada periode t

$n$  : Jumlah sampel

Kebaikan suatu model hasil peramalan berdasarkan nilai MAPE dikategorikan menjadi beberapa kriteria sebagai berikut.

**Tabel 2. 1 Kriteria kebaikan model berdasarkan nilai MAPE**

MAPE	Kriteria
<10%	Sangat baik
10%-20%	Baik
20%-50%	Cukup Baik
>50%	Buruk

Sumber : (Ervina, 2018).

## 2.7 Transportasi

Transportasi merupakan suatu sistem yang terdiri dari prasarana/sarana dan sistem pelayanan yang memungkinkan adanya pergerakan keseluruhan wilayah sehingga terakomodasi mobilitas penduduk, memungkinkan adanya pergerakan barang, dan memungkinkan adanya akses kesemua wilayah. Transportasi berfungsi untuk menggerakkan atau memindahkan orang atau barang dari satu wilayah ke wilayah lainnya dengan menggunakan sistem tertentu untuk tujuan tertentu. Transportasi memiliki peran yang sangat penting bagi masyarakat karena memudahkan masyarakat dalam berpergian dari tempat lain dalam melakukan aktivitasnya seperti ke sekolah, bekerja, belanja dan sebagainya. Transportasi dibagi menjadi tiga yaitu transportasi darat, transportasi laut dan transportasi udara (Durrah, 2018).

## 2.8 Penumpang

Penumpang merupakan seseorang yang ikut dalam perjalanan dalam suatu jenis transportasi baik itu transportasi darat, transportasi laut maupun transportasi

udara, tetapi tidak termasuk awak yang mengoperasikan dan yang melayani didalam transportasi tersebut. Penumpang dapat dibedakan menjadi dua kelompok yaitu antara lain penumpang yang ikut naik dengan tidak membayar dimana yang mengemudikan adalah keluarga atau kerabat sendiri dan penumpang yang ikut naik dengan cara membayar dimana yang mengemudikan adalah petugas dari suatu transportasi tersebut (Durrach, 2018).

## **2.9 Bandar Udara**

Bandar udara merupakan prasarana bagi angkutan udara yang didalamnya tersedia berbagai macam fasilitas untuk melayani pergerakan pesawat, penumpang, barang ataupun kargo. Menurut Undang-Undang No 1 Tahun 2009 tentang penerbangan, bandar udara adalah kawasan di daratan dan atau perairan dengan batas-batas tertentu yang digunakan sebagai tempat pesawat udara mendarat dan lepas landas, naik turun penumpang, bongkar muat barang, dan tempat perpindahan intra dan antarmoda transportasi, yang dilengkapi dengan fasilitas keselamatan dan keamanan penerbangan, serta fasilitas pokok dan fasilitas penunjang lainnya (Masrifah, 2015).