

BAB II

TINJAUAN PUSTAKA

2.1. Inflasi

Inflasi adalah kecenderungan naiknya harga barang dan jasa yang berlangsung secara terus menerus. Jika harga barang dan jasa di dalam negeri meningkat, maka inflasi juga akan mengalami kenaikan. Naiknya harga barang dan jasa tersebut menyebabkan turunnya nilai uang. Dengan demikian, inflasi juga mempunyai arti sebagai penurunan nilai uang terhadap barang dan jasa (Badan Pusat Statistik, 2018). Untuk mengukur tingkat inflasi digunakan salah satu indikator yaitu Indeks Harga Konsumen (IHK). IHK adalah indeks yang menghitung rata-rata perubahan harga dari barang dan jasa yang dikonsumsi oleh masyarakat dalam kurun waktu tertentu.

Menurut Badan Pusat Statistik (2018) presentase perubahan indeks atau tingkat inflasi/deflasi setiap bulan diperoleh dengan mengurangkan IHK suatu bulan dengan IHK bulan sebelumnya, kemudian hasilnya dibagi dengan IHK bulan sebelumnya dan dikalikan 100. Tingkat inflasi/deflasi tersebut juga dapat dihitung dari IHK suatu bulan dibagi dengan IHK bulan sebelumnya, hasilnya dikurangi dengan 1, dan dikalikan dengan 100. Penghitungan diatas dijabarkan dengan rumus sebagai berikut :

$$\text{Inf}_n = \frac{\text{IHK}_n - \text{IHK}_{n-1}}{\text{IHK}_{n-1}} \times 100 \quad (2.1)$$

$$\text{Inf}_n = \left(\frac{\text{IHK}_n}{\text{IHK}_{n-1}} - 1 \right) \times 100 \quad (2.2)$$

Dimana :

Inf_n = Tingkat inflasi/deflasi bulan ke-n

IHK_n = Indeks bulan ke-n

$\text{IHK}_{(n-1)}$ = Indeks bulan ke-(n-1)

2.2. Analisis *Time Series*

Analisis *time series* digunakan untuk melakukan analisis data yang mempertimbangkan pengaruh waktu. Data deret waktu dikumpulkan secara periodik berdasarkan urutan waktu, bisa dalam jam, hari, minggu, bulan, kuartal dan tahun. Analisis deret waktu mempunyai banyak manfaat, salah satunya adalah analisis deret waktu dapat dilakukan untuk membantu dalam menyusun perencanaan kedepan (Maulana, 2018).

2.3. Multivariat *Time Series*

Multivariat *time series* merupakan salah satu analisis *time series* yang melibatkan banyak variabel di dalam modelnya. Data *time series* terkadang memiliki keterkaitan antara satu variabel dengan variabel lainnya, misalkan variabel pertumbuhan inflasi dipengaruhi oleh tingkat suku bunga, jumlah uang beredar dan lain sebagainya. Sehingga, dibutuhkan analisis yang lebih dari satu data *time series* yaitu dengan menggunakan multivariat *time series*.

Proses dalam multivariat *time series* sama dengan proses dalam univariat *time series* yaitu dengan memperhatikan stasioneritas data (Hapsari, 2017).

2.4. Variasi Kalender

Model variasi kalender merupakan model *time series* yang digunakan untuk meramalkan data berdasarkan pola musiman dengan periode bervariasi. Di sebagian besar negara-negara Islam, data *time series* bulanan di bidang ekonomi dan bisnis dapat diketahui dengan dua jenis efek kalender, yaitu efek hari kerja atau efek hari perdagangan di setiap bulan, yang biasa disebut sebagai efek perdagangan hari dan efek hari libur seperti tahun baru cina, natal, dan idul fitri dimana penentuan hari raya tersebut berbeda dengan kalender Masehi. Indonesia merupakan salah satu negara yang merasakan variasi kalender terutama saat memasuki bulan Ramadhan. Saat Ramadhan tingkat konsumsi meningkat sehingga pemerintah maupun perusahaan perlu melakukan suatu kebijakan untuk menjaga stok barang agar tetap terjaga.

2.5. Model Space Time Autoregressive (STAR)

Model STAR merupakan suatu model yang dikategorikan berdasarkan lag yang berpengaruh secara linier baik dalam lokasi maupun waktu (Pfeifer dan Deutsch, 1980) seperti yang dikutip oleh (Nurchayani, 2016). Model STAR mengasumsikan bahwa penelitian di waktu sekarang dipengaruhi oleh waktu sebelumnya di lokasi tertentu, lokasi-lokasi yang diteliti adalah sama

sehingga model ini hanya dapat diterapkan pada lokasi yang bersifat homogen (seragam). Dalam notasi matriks, model STAR dengan derajat *autoregressive* p dan derajat spasial $\lambda_1, \lambda_2, \dots, \lambda_p$. STAR ($p ; \lambda_1, \lambda_2, \dots, \lambda_p$) dirumuskan sebagai berikut :

$$Z(t) = \sum_{k=1}^p \sum_{l=0}^{\lambda_k} \phi_{kl} W^{(l)} Z(t-k) + e(t) \quad (2.3)$$

Dengan :

- $Z(t)$: vektor pengamatan ukuran $(n \times 1)$ dari n lokasi pada waktu t
- $Z(t-k)$: vektor pengamatan ukuran $(n \times 1)$ dari n lokasi pada waktu $(t-k)$
- ϕ_{kl} : parameter STAR pada lag waktu k dan lag spasial l
- $W^{(l)}$: matriks pembobot ukuran $(n \times n)$ pada lag spasial l
- λ_k : spasial lag dari bentuk *autoregressive* orde p
- $e(t)$: vektor *noise* $(n \times 1)$ berdistribusi normal dengan mean 0 dan matriks varian-kovarian $\sigma^2 I_N$
- N : banyaknya lokasi pengamatan

(Pfeifer, 1980) seperti yang dikutip oleh Nurcahyani (2016).

2.6. Model Generalized Space Time Autoregressive (GSTAR)

Model GSTAR merupakan pengembangan dari model STAR. Model GSTAR merupakan suatu model yang mempunyai keterkaitan antara waktu dan lokasi dimana lokasi yang diteliti memiliki karakteristik yang tidak seragam (heterogen). Menurut Suhartono dan Subanar (2006) seperti yang dikutip oleh Nurcahyani (2016) secara matematis notasi dari model GSTAR (1:p) adalah sama dengan model STAR (1:p). Perbedaan utama dari model

GSTAR ini terletak pada nilai-nilai parameter pada lag spasial yang sama diperbolehkan berlainan. Sedangkan pada model STAR pada parameter *autoregressive* diasumsikan sama pada semua lokasi. Dalam notasi matriks, model GSTAR dengan derajat *autoregressive* p dan derajat spasial $\lambda_1, \lambda_2, \dots, \lambda_p$. GSTAR ($p; \lambda_1, \lambda_2, \dots, \lambda_p$) dirumuskan sebagai berikut :

$$Z(t) = \sum_{k=1}^p [\phi_{k0} + \phi_{k1}W] Z(t-k) + e(t) \quad (2.4)$$

Dengan :

- $Z(t)$: vektor pengamatan ukuran $(n \times 1)$ dari n lokasi pada waktu t
- $Z(t-k)$: vektor pengamatan ukuran $(n \times 1)$ dari n lokasi pada waktu $(t-k)$
- W : matriks pembobot $(n \times n)$
- ϕ_{k0} : $\text{diag}(\phi_{k0}^1, \dots, \phi_{k0}^n)$ = matriks diagonal parameter *autoregressive* lag time l
- ϕ_{k1} : $\text{diag}(\phi_{k1}^1, \dots, \phi_{k1}^n)$ = matriks diagonal parameter *autoregressive* lag spasial l dan lag time l
- $e(t)$: vektor *noise* $(n \times 1)$ berdistribusi normal dengan mean 0 dan matriks varian-kovarian $\sigma^2 I_N$

(Suhartono dan Subanar, 2006) seperti yang dikutip oleh Nurcahyani (2016).

2.7. Model Generalized Space Time Autoregressive - X (GSTAR-X)

Model GSTAR juga dikembangkan dengan melibatkan variabel eksogenus yang dikenal dengan pemodelan GSTARX. Model GSTARX merupakan model dengan melibatkan variabel eksogen (X) dalam model, sehingga tidak hanya dipengaruhi variabel itu sendiri pada periode waktu dan juga faktor

lokasi tetapi juga dipengaruhi oleh variabel eksogen (X). Dalam notasi matriks, model GSTAR-X ($p; \lambda_1, \lambda_2, \dots, \lambda_p$) dapat ditulis sebagai berikut :

$$Y(t) = \sum_{k=1}^p \sum_{l=0}^{\lambda_k} [\phi_{kl} W^{(l)} Y(t-k)] + Y_{kl} X(t-s+1) + e(t) \quad (2.5)$$

Dengan :

$$Y(t) = Z(t) - Z(t-k); Y(t-k) = Z(t-k) - Z(t-k-1)$$

- N : banyaknya lokasi pengamatan yaitu $i = 1, 2, \dots, n$
- λ_k : orde spasial dari bentuk *autoregressive* orde ke-k
- $Z(t)$: vektor pengamatan berukuran $(n \times 1)$ pada waktu t
- $Z(t-k)$: vektor pengamatan berukuran $(n \times 1)$ pada waktu $(t-k)$
- $X(t)$: vektor variabel eksogen orde ke-l berukuran $(n \times 1)$ pada waktu t
- $X(t-s+1)$: vektor variabel eksogen orde ke-s berukuran $(n \times 1)$ pada waktu $(t-s+1)$
- ϕ_{kl} : $\text{diag} (\phi_{kl}^{(1)}, \dots, \phi_{kl}^{(n)})$ yaitu matriks diagonal parameter *autoregressive* pada waktu k dan lag spasial l berukuran $(n \times n)$
- Y_{kl} : $\text{diag} ((Y_1^{(l)}, \dots, Y_s^{(n)}))$ yaitu matriks diagonal variabel eksogen orde ke-s berukuran $(n \times n)$
- $W^{(l)}$: matriks bobot berukuran $(n \times n)$ pada lag spasial l (dimana $l = 0, 1, \dots$)
- $e(t)$: vektor *noise* $(n \times 1)$ berdistribusi normal dengan mean 0 dan matriks varian-kovarian $\sigma^2 I_N$

Ruchjana (2019).

Menurut Ruchjana dan Borovkova (2008) seperti yang dikutip oleh Ruchjana (2019) menyatakan bahwa parameter model GSTAR dapat di

estimasi menggunakan OLS, pendekatan metode OLS juga dapat digunakan dalam penaksiran model GSTAR yang melibatkan variabel eksogen (X).

2.7.1. Pengecekan Stasioneritas Terhadap *Mean* dan *Varian*

Suatu data dikatakan stasioner pada data *time series* jika nilai *mean* dan *varian* konstan atau tidak mengalami perubahan yang sistematis. Markidakis *et al* (1992) menyatakan bentuk visual dari suatu plot data *time series* seringkali cukup untuk menyakinkan bahwa data tersebut adalah stasioner atau tidak stasioner. Akan tetapi, secara formal untuk mengidentifikasi kestasioneran data dilakukan dengan uji *Augmented Dickey Fuller* (ADF) atau dengan melihat skema matriks korelasi silang MACF dan MPACF. Jika plot MACF dan MPACF turun secara lambat maka data belum stasioner terhadap *mean* sehingga perlu dilakukan *differencing* atau pembedaan. Sebaliknya, data belum stasioner terhadap *varian* jika nilai batas atas dan batas bawah pada lamda kurang dari nol, sehingga perlu dilakukan transformasi *Box Cox* agar data stasioner.

2.7.1.1. Uji *Augmented Dickey Fuller* (ADF)

Uji ADF merupakan pengujian stasioner dengan menentukan apakah data *time series* mengandung akar unit (*unit root*). Uji ADF diperkenalkan oleh David Dickey dan Wayne Fuller dengan model sederhana yang digunakan adalah :

$$\Delta Y_t = B_1 + \delta Y_{t-1} + e_t \quad (2.6)$$

Dengan $\delta = \rho - 1$

Hipotesis yang digunakan adalah :

$H_0 : \delta = 1$ (tidak stasioner)

$H_1 : \delta < 1$ (stasioner)

Dapat dilakukan dengan uji statistik $\tau = \frac{\rho}{SE(\rho)}$. Jika statistik τ

lebih besar dari nilai kritis ADF maka terima H_0 dan simpulkan Y_t mempunyai akar unit (tidak stasioner) dan apabila statistik τ kurang dari nilai kritis ADF dengan taraf nyata tertentu atau p-value < 5 % maka H_0 ditolak dan simpulkan Y_t tidak mempunyai akar unit atau stasioner (Nurchayani, 2016).

2.7.1.2. *Matrix Autocorrelation Function* (MACF)

Suatu vektor deret waktu sebanyak n pengamatan $Z_1, Z_2, \dots, Z_n$ matriks korelasi sampel dinyatakan sebagai berikut :

$$\hat{\rho}(k) = [\hat{\rho}_{ij}(k)] \quad (2.7)$$

dimana $\hat{\rho}_{ij}(k)$ adalah korelasi silang sampel dari komponen deret ke- i dan ke- j yaitu :

$$\hat{\rho}_{ij}(k) = \frac{\sum_{t=1}^{n-k} (Z_{i,t} - \bar{Z}_i)(Z_{j,t+k} - \bar{Z}_j)}{[\sum_{t=1}^n (Z_{i,t} - \bar{Z}_i)^2 \sum_{t=1}^n (Z_{j,t+k} - \bar{Z}_j)^2]^{1/2}} \quad (2.8)$$

dimana $\bar{Z}_i$ dan $\bar{Z}_j$ adalah rata-rata sampel dari komponen deret yang bersesuaian. Fungsi matriks korelasi sangat diperlukan untuk

mengidentifikasi batas orde MA, bila matriks korelasi bernilai nol setelah lag ke-q maka model yang bersesuaian yaitu MA(q). Apabila dimensi dan vektornya semakin besar maka bentuk matriks dan grafik akan semakin kompleks sehingga menyulitkan dalam pengidentifikasian.

Untuk memudahkan maka digunakan simbol yang dinotasikan dengan (+), (-), dan (.) pada matriks korelasi (i,j). Simbol (+) diartikan sebagai $\hat{\rho}_{ij}(k)$ lebih besar dari 2 kali standar error dan menunjukkan memiliki hubungan korelasi positif. Simbol (-) diartikan sebagai $\hat{\rho}_{ij}(k)$ kurang dari -2 kali standar error dan menunjukkan memiliki hubungan korelasi negatif. Sedangkan simbol (.) diartikan sebagai $\hat{\rho}_{ij}(k) \pm 2$ kali standar error dan menunjukkan tidak adanya korelasi (Wei, 2006) seperti yang dikutip oleh Nurcahyani (2016).

2.7.1.3. *Matrix Partial Autocorrelation Function (MPACF)*

Fungsi matriks parsial korelasi sampel sangat diperlukan dalam mengidentifikasi model AR. Korelasi antara $Z(t)$ dan $Z(t+K)$ dapat diketahui setelah ketergantungan linier pada variabel $Z(t+1)$, $Z(t+2)$, ..., $Z(t+k+1)$ dihilangkan. Sebagaimana dirumuskan:

$$\phi_{kk} = \frac{\text{Cov}[(Z_t - \hat{Z}_t), (Z_{t+k} - \hat{Z}_{t+k})]}{\sqrt{\text{Var}(Z_t - \hat{Z}_t)} \sqrt{\text{Var}(Z_{t+k} - \hat{Z}_{t+k})}} \quad (2.9)$$

dimana $\hat{Z}(t)$ dan $\hat{Z}(t+k)$ adalah rata-rata kesalahan kuadrat minimum pada estimasi regresi linier dari $Z(t)$ dan $Z(t+k)$ yang berdasarkan pada $Z(t+1)$, $Z(t+2)$, ..., $Z(t+k-1)$. Korelasi spasial antara $Z(t)$ dan $Z(t+k)$ sama dengan koefisien regresi terakhir $Z(t)$ dan $Z(t+k)$ pada lag ke- k (Wei, 2006) seperti yang dikutip oleh Nurcahyani (2016).

2.7.2. Pemilihan Orde Model GSTAR-X

Menurut Wutsqa (2010) seperti yang dikutip oleh Nurcahyani (2016) menyatakan bahwa pemilihan orde spasial model GSTAR-X pada umumnya dibatasi orde 1, karena orde yang lebih tinggi akan sulit diinterpretasikan. Sedangkan pada orde waktu (*autoregressive*) dapat ditentukan dengan AIC (*Akaike Information Criterion*). Pemilihan orde model terbaik pada GSTAR-X dapat ditentukan dengan melihat nilai AIC terkecil.

2.7.3. Pemilihan Bobot Lokasi Model GSTAR-X

Pada pemodelan GSTAR-X permasalahan yang sering terjadi yaitu terletak pada pemilihan atau penentuan bobot lokasi. Pemilihan bobot lokasi pada model GSTAR-X dibagi menjadi 2 pembobot yaitu bobot lokasi seragam (*uniform*) dan invers jarak.

- a. Bobot Lokasi Seragam (*Uniform*)

Ruchjana (2002) seperti yang dikutip oleh Nurcahyani (2016) mendefinisikan pemilihan bobot lokasi seragam sebagai :

$$W_{ij} = \frac{1}{n_i} \quad (2.10)$$

dengan n_i menyatakan jumlah lokasi yang berdekatan dengan lokasi i pada spasial lag 1. Bobot pada model ini mempunyai sifat-sifat :

$$W_{ij} > 0, W_{ii} = 0, \sum_{j=1}^N W_{ij} = 1, \forall i, \sum_{i=1}^N \sum_{j=1}^N W_{ij} = N$$

Bobot lokasi ini memberikan nilai bobot yang sama pada setiap lokasi. Oleh karena itu bobot lokasi ini sering digunakan pada data yang seragam atau mempunyai jarak yang sama untuk setiap lokasi. Bobot W_{ij} pada lag 1 dinyatakan oleh W berupa matriks $n \times n$ sebagai berikut :

$$W = \begin{bmatrix} 0 & W_{12} & \cdots & W_{1N} \\ W_{21} & 0 & \cdots & W_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ W_{N1} & W_{N2} & \cdots & 0 \end{bmatrix}$$

b. Bobot Lokasi *Invers Jarak*

Nilai bobot lokasi *invers jarak* diperoleh berdasarkan jarak antar lokasi yang sebenarnya. Perhitungan bobot dengan metode *invers jarak* diperoleh dari hasil *invers jarak* sebenarnya kemudian dinormalisasi. Bentuk matriks jarak awal yang terbentuk adalah :

$$M = \begin{bmatrix} m_{AA} & m_{AB} & m_{AC} & m_{AD} \\ m_{BA} & m_{BB} & m_{BC} & m_{BD} \\ m_{CA} & m_{CB} & m_{CC} & m_{CD} \\ m_{DA} & m_{DB} & m_{DC} & m_{DD} \end{bmatrix}$$

Kemudian matriks tersebut distandarisasi dalam bentuk matriks untuk memenuhi sifat bobot $\sum_{j=1}^N W_{ij}^{(l)} = 1$, $j \neq i$. Dengan asumsi jarak yang dekat memiliki hubungan antar lokasi yang kuat maka secara umum bobot invers jarak untuk masing-masing lokasi dapat dinyatakan dengan :

$$W_{ij} = \frac{\frac{1}{m_{ij}}}{\sum_{j=1}^N \frac{1}{m_{ij}}}, j \neq i, \quad (2.11)$$

dengan jumlah pembobot untuk setiap lokasi adalah 1, $\sum_{j=1}^N W_{ij}^{(l)} = 1$ dan $\sum_{i=1}^N \sum_{j=1}^N W_{ij} = N$. Diagonal matriks bobot invers jarak w_{ij} adalah nol, karena untuk suatu lokasi dianggap tidak ada jarak dengan dirinya sendiri. Sehingga bentuk matriks invers jarak yang terbentuk adalah :

$$= \begin{bmatrix} 0 & \frac{\frac{1}{m_{AB}}}{\frac{1}{m_{AB}} + \frac{1}{m_{AC}} + \frac{1}{m_{AD}}} & \frac{\frac{1}{m_{AC}}}{\frac{1}{m_{AB}} + \frac{1}{m_{AC}} + \frac{1}{m_{AD}}} & \frac{\frac{1}{m_{AD}}}{\frac{1}{m_{AB}} + \frac{1}{m_{AC}} + \frac{1}{m_{AD}}} \\ \frac{\frac{1}{m_{BA}}}{\frac{1}{m_{BA}} + \frac{1}{m_{BC}} + \frac{1}{m_{BD}}} & 0 & \frac{\frac{1}{m_{BC}}}{\frac{1}{m_{BA}} + \frac{1}{m_{BC}} + \frac{1}{m_{BD}}} & \frac{\frac{1}{m_{BD}}}{\frac{1}{m_{BA}} + \frac{1}{m_{BC}} + \frac{1}{m_{BD}}} \\ \frac{\frac{1}{m_{CA}}}{\frac{1}{m_{CA}} + \frac{1}{m_{CB}} + \frac{1}{m_{CD}}} & \frac{\frac{1}{m_{CB}}}{\frac{1}{m_{CA}} + \frac{1}{m_{CB}} + \frac{1}{m_{CD}}} & 0 & \frac{\frac{1}{m_{CD}}}{\frac{1}{m_{CA}} + \frac{1}{m_{CB}} + \frac{1}{m_{CD}}} \\ \frac{\frac{1}{m_{DA}}}{\frac{1}{m_{DA}} + \frac{1}{m_{DB}} + \frac{1}{m_{DC}}} & \frac{\frac{1}{m_{DB}}}{\frac{1}{m_{DA}} + \frac{1}{m_{DB}} + \frac{1}{m_{DC}}} & \frac{\frac{1}{m_{DC}}}{\frac{1}{m_{DA}} + \frac{1}{m_{DB}} + \frac{1}{m_{DC}}} & 0 \end{bmatrix}$$

$$= \begin{bmatrix} 0 & W_{12} & W_{13} & W_{14} \\ W_{21} & 0 & W_{23} & W_{24} \\ W_{31} & W_{32} & W_{33} & W_{34} \\ W_{41} & W_{42} & W_{43} & 0 \end{bmatrix}$$

Hapsari (2017).

2.7.4. Estimasi Parameter Model GSTAR-X

Pada dasarnya model GSTAR-X merupakan perluasan dari model GSTAR, sehingga dalam estimasi parameternya, menurut Ruchjana dan Borovkova (2008) seperti yang dikutip oleh Nurcahyani (2016) menjelaskan estimasi parameter model GSTAR dapat diestimasi dengan menggunakan menggunakan *Ordinary Least Square* (OLS), pendekatan metode OLS tersebut dapat juga digunakan dalam penaksiran parameter model GSTAR yang melibatkan variabel eksogen (X). Sehingga bentuk estimasi kuadrat terkecil $\hat{B}_T$ adalah :

$$\hat{B}_T = (X'X)^{-1}X'Y \quad (2.12)$$

2.7.5. Uji Kelayakan Model GSTAR-X

Setelah mendapatkan parameter dan model yang signifikan maka langkah selanjutnya perlu dilakukan uji kelayakan model. Model GSTAR-X dikatakan layak jika memenuhi varian konstan (*white noise*). Pengujian asumsi perlu dilakukan untuk mengetahui apakah residual memenuhi *white noise*. Deret waktu r_t dikatakan *white noise* jika $\{r_t\}$ adalah barisan independen yang identik berdistribusi normal dengan *mean* dan *varian* terbatas. r_t berdistribusi normal dengan *mean* 0 dan *varian* σ^2 , dapat dikatakan jika letak AIC terdapat lag AR(0) dan MA(0), maka residual memenuhi asumsi *white noise* (Tsay, 2005) seperti yang dikutip Nurcahyani (2016). Pemenuhan uji *white noise* dapat dilakukan dengan menggunakan uji *portmanteau* dengan taraf signifikansi sebesar 5%.

2.7.6. Pemilihan Model Terbaik GSTAR-X

Untuk menentukan model terbaik dilakukan dengan RMSE (*Root Mean Square Error*) untuk setiap model dengan nilai RMSE terkecil menyatakan model terbaik. RMSE dirumuskan sebagai berikut :

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{M} \sum_{t=1}^M (Z_t - \hat{Z}_t)^2} \quad (2.13)$$

M adalah banyaknya data ramalan yang dilakukan. Z_t menyatakan data yang sebenarnya dan data hasil ramalan. Nilai RMSE berkisar antara 0 sampai ∞ . Semakin kecil nilai RMSE maka model yang digunakan semakin bagus (Wei, 2006) seperti yang dikutip oleh Nurcahyani (2016).

