

Estimasi Parameter Model Inflasi untuk Menganalisa Pengaruh Covid-19 Menggunakan GSTAR-Filter Kalman

Miftakhul Janah Seftia Agustina, Sentot Didik Surjanto, dan Erna Apriliani
Departemen Matematika, Institut Teknologi Sepuluh Nopember (ITS)
e-mail: sentotds@matematika.its.ac.id

Abstrak—Pandemi Covid-19 selain mengganggu kesehatan manusia juga dapat mengganggu kesehatan ekonomi di seluruh dunia termasuk Indonesia. Dengan keadaan ekonomi yang tidak stabil akhir-akhir ini, permasalahan inflasi menjadi salah satu fokus penting bagi pemerintah. Inflasi merupakan salah satu indikator penting dalam stabilitas perekonomian bagi suatu negara. Oleh karena itu, perlu adanya pemodelan matematika yang sesuai yang dapat memprediksi inflasi di masa mendatang. Pengaruh Covid-19 terhadap inflasi dapat diamati dengan memperhatikan pergerakan inflasi terhadap Covid-19 berdasarkan plot data inflasi. Selanjutnya data inflasi dimodelkan menggunakan model *Generalized Space Time Autoregressive* (GSTAR) dengan menggunakan pembobotan invers jarak antar lokasi dan pembobotan normalisasi korelasi silang untuk mendapatkan model inflasi yang sesuai. Selanjutnya dilakukan estimasi pada parameter model menggunakan metode Filter Kalman (FK). Hasil akhir menunjukkan bahwa Filter Kalman mampu memperbaiki hasil estimasi pada model GSTAR sehingga didapatkan hasil prediksi yang mendekati data aktual. Hal ini ditunjukkan dengan hasil simulasi dan nilai MAPE yang lebih kecil dari pada nilai MAPE model GSTAR-OLS dan GSTAR-GLS sebesar 0.14302%.

Kata Kunci—Filter Kalman, *Generalized Space Time Autoregressive*, Inflasi, Invers Jarak, Normalisasi Korelasi Silang.

I. PENDAHULUAN

PANDEMI Covid-19 adalah peristiwa menyebarnya penyakit *corona virus* 2019 di seluruh dunia. Penyakit ini disebabkan oleh korona virus jenis baru yang diberi nama SARS-Cov-2. Virus ini tidak hanya mengganggu kesehatan manusia, namun juga mengganggu kesehatan ekonomi di seluruh dunia, termasuk Indonesia. Dampak ekonomi yang ditimbulkan oleh Covid-19 bisa lebih besar dari dampak kesehatan dan pertumbuhan ekonomi akan melambat. Jika terjadi perlambatan ekonomi, maka daya serap tenaga kerja akan berkurang, meningkatnya pengangguran dan kemiskinan. Dengan keadaan ekonomi yang tidak stabil seperti yang terjadi saat ini, permasalahan inflasi menjadi salah satu fokus penting bagi pemerintah. Inflasi dapat diartikan sebagai proses terjadinya kenaikan harga barang dan jasa secara terus menerus yang terjadi secara umum dalam jangka waktu tertentu [1]. Inflasi merupakan suatu proses dalam perekonomian yang tidak dapat dihilangkan, sehingga kebijakan yang dilakukan tersebut hanya sebatas usaha dalam mengendalikan inflasi. Oleh karena itu, perlu adanya pemodelan matematika yang sesuai yang dapat memprediksi inflasi di masa mendatang sehingga kebijakan yang dilakukan oleh pemerintah menjadi lebih terarah.

Terdapat banyak metode *time series* yang dapat digunakan untuk memprediksi data inflasi salah satunya adalah dengan menggunakan model *Generalized Space Time Autoregressive* (GSTAR). Pada penelitian ini untuk mendapatkan model GSTAR akan digunakan dua jenis pembobotan yaitu pembobotan invers jarak antar lokasi dan pembobotan normalisasi korelasi silang. Selanjutnya akan dilakukan estimasi pada parameter model GSTAR dengan menggunakan metode Filter Kalman sehingga didapatkan hasil yang maksimal.

II. METODE PENELITIAN

A. Sumber Data

Data inflasi bulanan Provinsi Jawa Timur, Jawa Barat dan DKI Jakarta. Data yang digunakan adalah data dari bulan Desember 2010-Mei 2021 sebanyak 126 data pada masing-masing provinsi yang selanjutnya dibagi menjadi data *in-sample* dan *out-sample*. Data *in-sample* sebanyak 121 data (Desember 2010-Desember 2020) pada masing-masing provinsi yang digunakan untuk membentuk model, sedangkan data *out-sample* sebanyak 5 data (Januari 2021-Mei 2021) yang digunakan untuk mengecek ketepatan model.

B. Analisis Model dan Estimasi

Pada tahap ini, dilakukan analisis data untuk mendapatkan model GSTAR yang sesuai dengan data. Langkah pertama yang dilakukan yaitu memastikan bahwa data sudah stasioner. Selanjutnya dilakukan analisis menggunakan MPACF. Hasil analisis tersebut dapat digunakan untuk menentukan order *autoregressive* dalam membuat model GSTAR, kemudian dilakukan perhitungan bobot lokasi menggunakan invers jarak dan normalisasi korelasi silang pada model GSTAR. Selanjutnya pada tahap ini dilakukan estimasi parameter menggunakan metode OLS/GLS untuk mendapatkan model GSTAR-OLS/GSTAR-GLS. Setelah model GSTAR-OLS/GSTAR-GLS didapatkan, selanjutnya dilakukan estimasi parameter dari model GSTAR-OLS/GSTAR-GLS dengan menggunakan Filter Kalman.

III. HASIL DAN PEMBAHASAN

A. Analisa data

Dilakukan uji-*t* berpasangan atau *paired t-test* untuk melihat ada atau tidaknya pengaruh selama adanya pandemi Covid-19 terhadap tingkat inflasi. Uji-*t* berpasangan diujikan pada dua kelompok data yaitu data sebelum adanya pandemi Covid-19 (Mei 2019-Desember 2020) dan saat terjadi

Tabel 1.
Hasil estimasi metode OLS dengan pembobot invers jarak

Parameter	Estimasi	Kriteria pengujian	Kesimpulan
Φ_{10}^1	1.00787	11.522	1.98
Φ_{20}^1	0.48783	3.354	1.98
Φ_{21}^1	-0.74257	3.998	1.98
Φ_{10}^2	0.78632	9.160	1.98
Φ_{20}^2	0.64147	4.848	1.98
Φ_{21}^2	-0.97172	5.385	1.98
Φ_{11}^3	0.39158	14.911	1.98
Φ_{20}^3	-0.33055	3.825	1.98

Tabel 2.
Hasil estimasi metode OLS dengan pembobot normalisasi korelasi silang

Parameter	Estimasi	Kriteria pengujian	Kesimpulan
Φ_{10}^1	0.99599	11.632	1.98
Φ_{20}^1	0.51063	3.729	1.98
Φ_{21}^1	-0.81350	4.567	1.98
Φ_{10}^2	0.87089	9.765	1.98
Φ_{20}^2	0.58201	3.347	1.98
Φ_{21}^2	-0.73590	3.315	1.98
Φ_{11}^3	0.40168	15.047	1.98
Φ_{20}^3	-0.36616	4.163	1.98

Tabel 3.
Hasil estimasi metode GLS dengan pembobot invers jarak

Parameter	Estimasi	Kriteria pengujian	Kesimpulan
Φ_{10}^1	0.4104833	H_0 ditolak	Signifikan
Φ_{11}^1	0.6412560	H_0 ditolak	Signifikan
Φ_{20}^1	0.1532613	H_0 ditolak	Signifikan
Φ_{10}^2	0.7801817	H_0 ditolak	Signifikan
Φ_{20}^2	0.3702429	H_0 ditolak	Signifikan
Φ_{21}^2	-0.3501015	H_0 ditolak	Signifikan
Φ_{10}^3	0.3162761	H_0 ditolak	Signifikan
Φ_{11}^3	0.1996791	H_0 ditolak	Signifikan

pandemi *Covid-19* (Januari 2021-Mei 2021). Hasil uji-t berpasangan dimana pada data tingkat inflasi Jawa Timur dan Jawa Barat, sebelum dan saat adanya pandemi *Covid-19* tidak mengalami perbedaan yang signifikan. Artinya pandemi *Covid-19* tidak memberikan pengaruh yang signifikan terhadap tingkat inflasi provinsi Jawa Timur dan Jawa Barat. Sedangkan pada provinsi DKI Jakarta sebelum dan saat adanya pandemi *Covid-19* mengalami perbedaan yang signifikan. Artinya pandemi *Covid-19* memberikan pengaruh yang signifikan terhadap tingkat inflasi provinsi DKI Jakarta.

Selanjutnya dilakukan uji korelasi *pearson* untuk mengetahui tingkat kecenderungan saling mempengaruhi antar lokasi dengan memperhatikan nilai dari koefisien korelasinya [2]. Hasil uji korelasi menunjukkan adanya korelasi positif antar variabel, artinya ketika tingkat inflasi Jawa Timur naik maka tingkat inflasi ada Provinsi Jawa Barat juga akan naik, begitupun sebaliknya antara Jawa Timur-DKI Jakarta dan Jawa Barat-DKI Jakarta. Hal ini menunjukkan terdapat hubungan yang kuat pada tingkat inflasi antar provinsi.

B. Stasioner

Proses *differencing* digunakan ketika data tidak stasioner terhadap rata-rata (*mean*). *Differencing* dilakukan dengan pengurangan data dengan data sebelumnya sampai diperoleh data stasioner [3]. Pada *multivariate time series* kestasioneran data juga dapat dilihat melalui plot MACF dan MPACF untuk mengecek kestasioneran terhadap *mean* serta plot Box-Cox untuk mengecek kestasioneran terhadap varians. Hasil transformasi satu kali menunjukkan bahwa nilai dari *rounded value* dari setiap data sama dengan 1,

artinya data sudah stasioner terhadap varians sehingga tidak perlu dilakukan transformasi kembali [4]. Berdasarkan skema plot MACF dan MPACF terlihat data sudah stasioner terhadap *mean*. Hal ini ditunjukkan dengan banyaknya tanda titik yang muncul dalam plot. Pengecekan stasioner terhadap *mean* juga dapat dilakukan dengan menggunakan uji *Augmented Dickey Fuller*. Hasil uji *Augmented Dickey Fuller* menunjukkan nilai *p-value* pada setiap data kurang dari $\alpha = 0.05$, artinya data sudah stasioner terhadap *mean* sehingga tidak perlu dilakukan *differencing*.

C. Pengidentifikasian Orde GSTAR

Pengidentifikasian orde model GSTAR dilakukan untuk mendapatkan orde *autoregressive*. Orde *autoregressive* ditentukan dengan menggunakan kriteria AIC dengan memperhatikan nilai AIC terkecil. Nilai AIC terkecil didapatkan pada lag ke-2 sehingga orde *autoregressive* yang memungkinkan adalah AR 2 ($p = 2$). Orde spasial yang digunakan pada model GSTAR pada umumnya menggunakan orde 1 dikarenakan untuk orde spasial lebih dari satu sulit untuk diinterpretasikan [5]. Sehingga dapat disimpulkan bahwa model GSTAR pada tingkat inflasi pada tiga provinsi di Pulau Jawa adalah GSTAR (2_1) sebagai berikut [6]:

$$Z(t) = \sum_{k=1}^2 \sum_{l=0}^1 \Phi_{kl} W^{(l)} Z(t-k) + e(t)$$

dapat ditulis sebagai berikut :

$$\begin{bmatrix} Z_1(t) \\ Z_2(t) \\ Z_3(t) \end{bmatrix} = \begin{bmatrix} \Phi_{10}^1 & 0 & 0 \\ 0 & \Phi_{10}^2 & 0 \\ 0 & 0 & \Phi_{10}^3 \end{bmatrix} \begin{bmatrix} Z_1(t-1) \\ Z_2(t-1) \\ Z_3(t-1) \end{bmatrix}$$

Tabel 4.
Hasil estimasi metode GLS dengan pembobot normalisasi korelasi silang

Parameter	Estimasi	Kriteria pengujian	Kesimpulan
Φ_{10}^1	0.5272144	H_0 ditolak	Signifikan
Φ_{11}^1	0.6078424	H_0 ditolak	Signifikan
Φ_{20}^1	0.2738862	H_0 ditolak	Signifikan
Φ_{21}^1	-0.2997152	H_0 ditolak	Signifikan
Φ_{10}^2	0.9924826	H_0 ditolak	Signifikan
Φ_{10}^3	0.3652602	H_0 ditolak	Signifikan
Φ_{11}^3	0.1843874	H_0 ditolak	Signifikan

Tabel 5.
Hasil perhitungan nilai MAPE

	Jawa Timur	Jawa Barat	DKI Jakarta	Rata-rata
GSTAR-OLS invers jarak	2.74261	3.85727	11.77657	6.12548
GSTAR-OLS NKS	2.76637	4.00619	12.58200	6.45152
GSTAR-GLS invers jarak	2.14690	4.03882	11.85626	6.01399
GSTAR-GLS NKS	2.13995	4.03267	12.24893	6.14052

Tabel 6.
Hasil perhitungan nilai MAPE

Provinsi	GSTAR-GLS	GSTAR-Filter Kalman
Jawa Timur	2.14690	0.13403
Jawa Barat	4.03882	0.16604
DKI Jakarta	11.85626	0.12899
Rata-rata	6.01399	0.14302

$$\begin{aligned}
 &+ \begin{bmatrix} \Phi_{11}^1 & 0 & 0 \\ 0 & \Phi_{11}^2 & 0 \\ 0 & 0 & \Phi_{11}^3 \end{bmatrix} \begin{bmatrix} 0 & w_{12} & w_{13} \\ w_{21} & 0 & w_{23} \\ w_{31} & w_{32} & 0 \end{bmatrix} \begin{bmatrix} Z_1(t-1) \\ Z_2(t-1) \\ Z_3(t-1) \end{bmatrix} \\
 &+ \begin{bmatrix} \Phi_{20}^1 & 0 & 0 \\ 0 & \Phi_{20}^2 & 0 \\ 0 & 0 & \Phi_{20}^3 \end{bmatrix} \begin{bmatrix} Z_1(t-2) \\ Z_2(t-2) \\ Z_3(t-2) \end{bmatrix} \\
 &+ \begin{bmatrix} \Phi_{21}^1 & 0 & 0 \\ 0 & \Phi_{21}^2 & 0 \\ 0 & 0 & \Phi_{21}^3 \end{bmatrix} \begin{bmatrix} 0 & w_{12} & w_{13} \\ w_{21} & 0 & w_{23} \\ w_{31} & w_{32} & 0 \end{bmatrix} \begin{bmatrix} Z_1(t-2) \\ Z_2(t-2) \\ Z_3(t-2) \end{bmatrix} + \begin{bmatrix} e_1(t) \\ e_2(t) \\ e_3(t) \end{bmatrix}
 \end{aligned}$$

D. Pembobotan Lokasi

Metode yang digunakan untuk menentukan pembobotan dalam model GSTAR menggunakan pembobotan invers jarak antar lokasi dan pembobotan normalisasi korelasi silang [7]. Pembobotan invers jarak tertera sebagai berikut [8]:

$$W = \begin{bmatrix} 0 & 0.54813 & 0.45187 \\ 0.21151 & 0 & 0.78849 \\ 0.18109 & 0.81891 & 0 \end{bmatrix}$$

Dan pembobotan normalisasi korelasi silang sebagai berikut [7]:

$$W = \begin{bmatrix} 0 & 0.47452 & 0.52548 \\ 0.46230 & 0 & 0.53770 \\ 0.54042 & 0.45958 & 0 \end{bmatrix}$$

E. Pemodelan GSTAR dengan metode OLS

Dilakukan estimasi paramater dengan menggunakan metode OLS dengan meminimumkan jumlah kuadrat terkecilnya [9]. Berdasarkan hasil uji signifikansi parameter menunjukkan bahwa terdapat parameter yang tidak signifikan meliputi $\Phi_{11}^1, \Phi_{11}^2, \Phi_{10}^3$, dan Φ_{21}^3 . Selanjutnya diestimasi kembali parameter yang signifikan dengan menghilangkan parameter yang tidak signifikan. Hasil estimasi dengan pembobot invers jarak tertera pada Tabel 1. Dan hasil estimasi dengan pembobot normalisasi korelasi silang tertera pada Tabel 2. Sehingga didapatkan model

GSTAR(2₁)-OLS dengan bobot invers jarak sebagai berikut :

1. Model GSTAR(2₁)-OLS Jawa Timur :

$$Z_1(t) = 1.00787 Z_1(t-1) + 0.48783 Z_1(t-2)$$

$$-0.40702 Z_2(t-2) - 0.33555 Z_3(t-2) + e_1(t)$$

2. Model GSTAR(2₁)-OLS Jawa Barat :

$$Z_2(t) = 0.78632 Z_2(t-1) - 0.20553 Z_1(t-2)$$

$$+0.64147 Z_2(t-2) - 0.76619 Z_3(t-2) + e_2(t)$$

3. Model GSTAR(2₁)-OLS DKI Jakarta :

$$Z_3(t) = 0.07091 Z_1(t-1) + 0.32067 Z_2(t-1)$$

$$-0.33055 Z_3(t-2) + e_3(t)$$

Sehingga didapatkan model GSTAR(2₁)-OLS dengan bobot normalisasi korelasi silang sebagai berikut :

1. Model GSTAR(2₁)-OLS Jawa Timur :

$$Z_1(t) = 0.99599 Z_1(t-1) + 0.51063 Z_1(t-2)$$

$$-0.38602 Z_2(t-2) - 0.42748 Z_3(t-2) + e_1(t)$$

2. Model GSTAR(2₁)-OLS Jawa Barat :

$$Z_2(t) = 0.87089 Z_2(t-1) - 0.34021 Z_1(t-2)$$

$$+0.58201 Z_2(t-2) - 0.39569 Z_3(t-2) + e_2(t)$$

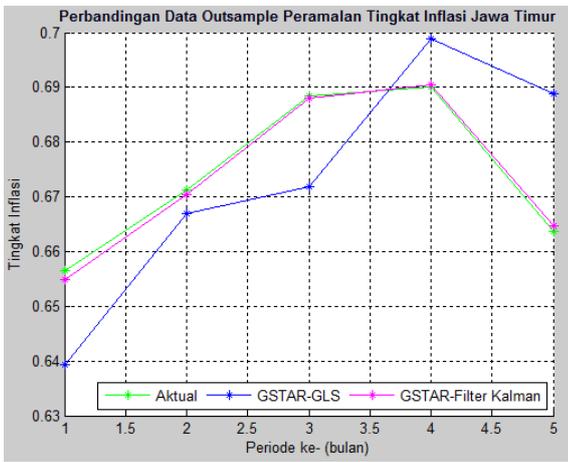
3. Model GSTAR(2₁)-OLS DKI Jakarta :

$$Z_3(t) = 0.21708 Z_1(t-1) + 0.18460 Z_2(t-1)$$

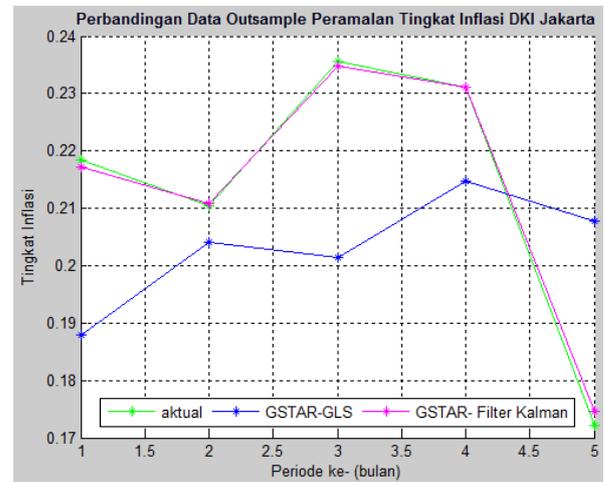
$$-0.36616 Z_3(t-2) + e_3(t)$$

F. Pemodelan GSTAR dengan metode GLS

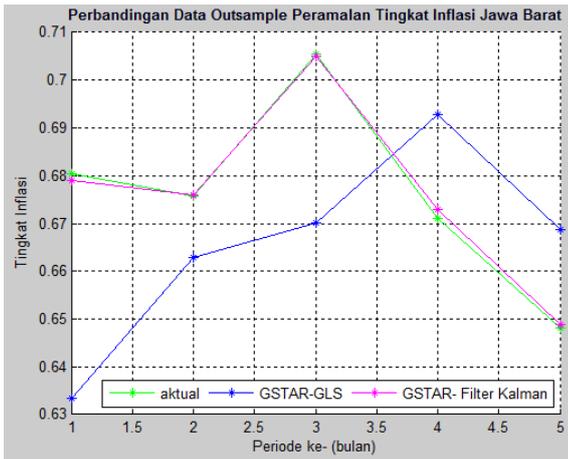
Dilakukan estimasi paramater dengan menggunakan metode GLS. *Generalized Least Square (GLS)* adalah penduga parameter regresi yang memperhatikan adanya



Gambar 1. Perbandingan data *outsample* tingkat inflasi Provinsi Jawa Timur.



Gambar 3. Perbandingan data *outsample* tingkat inflasi Provinsi DKI Jakarta.



Gambar 2. Perbandingan data *outsample* tingkat inflasi Provinsi Jawa Barat.

korelasi dari residual antar persamaan, dimana nilai dari residual diperoleh dari penaksiran *Ordinary Least Square (OLS)* yang nantinya digunakan dalam perhitungan untuk menduga koefisien regresi pada sistem persamaan SUR [10-11]. Berdasarkan hasil uji signifikansi parameter menunjukkan bahwa terdapat parameter yang tidak signifikan meliputi Φ_{11}^2, Φ_{20}^3 , dan Φ_{21}^3 . Selanjutnya diestimasi kembali parameter yang signifikan dengan menghilangkan parameter yang tidak signifikan. Hasil estimasi metode GLS dengan pembobot invers jarak tertera pada Tabel 3. Dan Hasil estimasi metode GLS dengan normalisasi korelasi silang tertera pada Tabel 4. Sehingga didapatkan model GSTAR(2₁)-GLS dengan bobot invers jarak sebagai berikut :

1. Model GSTAR(2₁)-GLS Jawa Timur :

$$Z_1(t) = 0.4104833Z_1(t - 1) + 0.3514906Z_2(t - 1) + 0.2897654Z_3(t - 1) + 0.1532613Z_1(t - 2) + e_1(t)$$

2. Model GSTAR(2₁)-GLS Jawa Barat :

$$Z_2(t) = 0.7801817Z_2(t - 1) - 0.0740495Z_1(t - 2) + 0.3702429Z_2(t - 2) - 0.2760520Z_3(t - 2) + e_2(t)$$

3. Model GSTAR(2₁)-GLS DKI Jakarta :

$$Z_3(t) = 0.0361603Z_1(t - 1) + 0.1635188Z_2(t - 1) + 0.3162761Z_3(t - 1) + e_3(t)$$

Sehingga didapatkan model GSTAR(2₁)-GLS dengan bobot normalisasi korelasi silang sebagai berikut :

1) Model GSTAR(2₁)-GLS Jawa Timur :

$$Z_1(t) = 0.5272144Z_1(t - 1) + 0.2884344Z_2(t - 1) + 0.3194080Z_3(t - 1) + 0.2738862Z_1(t - 2) - 0.1422214Z_2(t - 2) - 0.1574938Z_3(t - 2) + e_1(t)$$

2) Model GSTAR(2₁)-GLS Jawa Barat :

$$Z_2(t) = 0.9924826Z_2(t - 1) + e_2(t)$$

3) Model GSTAR(2₁)-GLS DKI Jakarta :

$$Z_3(t) = 0.0996473Z_1(t - 1) + 0.0847401Z_2(t - 1) + 0.3652602Z_3(t - 1) + e_3(t)$$

Model dengan nilai MAPE terkecil akan dipilih sebagai model terbaik dalam peramalan tingkat inflasi Provinsi Jawa Timur, Jawa Barat dan DKI Jakarta yang selanjutnya digunakan sebagai model dalam estimasi parameter menggunakan metode Filter Kalman. Hasil perhitungan estimasi MAPE tertera pada Tabel 5.

G. Implementasi Filter Kalman

Model terbaik yang didapatkan yaitu GSTAR(2₁)-GLS bobot invers jarak yang dapat dijabarkan sebagai berikut :

$$\begin{bmatrix} Z_1(t) \\ Z_2(t) \\ Z_3(t) \end{bmatrix} = \begin{bmatrix} \Phi_{10}^1 & 0 & 0 \\ 0 & \Phi_{10}^2 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} Z_1(t - 1) \\ Z_2(t - 1) \\ Z_3(t - 1) \end{bmatrix} + \begin{bmatrix} \Phi_{11}^1 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & \Phi_{11}^3 \end{bmatrix} \begin{bmatrix} 0 & 0.548128 & 0.451872 \\ 0.211509 & 0 & 0.788491 \\ 0.181092 & 0.818908 & 0 \end{bmatrix} \begin{bmatrix} Z_1(t - 1) \\ Z_2(t - 1) \\ Z_3(t - 1) \end{bmatrix} + \begin{bmatrix} \Phi_{20}^1 & 0 & 0 \\ 0 & \Phi_{20}^2 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} Z_1(t - 2) \\ Z_2(t - 2) \\ Z_3(t - 2) \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 \\ 0 & \Phi_{21}^2 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0.548128 & 0.451872 \\ 0.211509 & 0 & 0.788491 \\ 0.181092 & 0.818908 & 0 \end{bmatrix} \begin{bmatrix} Z_1(t - 2) \\ Z_2(t - 2) \\ Z_3(t - 2) \end{bmatrix}$$

$$+ \begin{bmatrix} e_1(t) \\ e_2(t) \\ e_3(t) \end{bmatrix}$$

Parameter-parameter yang akan diestimasi adalah parameter yang dinyatakan signifikan pada model GSTAR(2₁) yang diestimasi menggunakan GLS dengan bobot invers jarak, dengan asumsi $(\Phi_{10}^1)_{t+1} = (\Phi_{10}^1)_t$, $(\Phi_{11}^1)_{t+1} = (\Phi_{11}^1)_t$, $(\Phi_{20}^1)_{t+1} = (\Phi_{20}^1)_t$, $(\Phi_{10}^2)_{t+1} = (\Phi_{10}^2)_t$, $(\Phi_{20}^2)_{t+1} = (\Phi_{20}^2)_t$, $(\Phi_{21}^2)_{t+1} = (\Phi_{21}^2)_t$, $(\Phi_{10}^3)_{t+1} = (\Phi_{10}^3)_t$, dan $(\Phi_{11}^3)_{t+1} = (\Phi_{11}^3)_t$. Sehingga dapat dibentuk model sistem dalam waktu diskrit adalah sebagai berikut:

$$x_{t+1} = Ax_t + w_t$$

dapat ditulis sebagai berikut :

$$\begin{bmatrix} Z_1(t) \\ \Phi_{10}^1 \\ \Phi_{11}^1 \\ \Phi_{20}^1 \\ Z_2(t) \\ \Phi_{10}^2 \\ \Phi_{20}^2 \\ \Phi_{21}^2 \\ Z_3(t) \\ \Phi_{11}^3 \\ \Phi_{20}^3 \end{bmatrix}_{t+1} = \begin{bmatrix} 0 & b_{1,2} & b_{1,3} & b_{1,4} & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & b_{5,6} & b_{5,7} & b_{5,8} & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & b_{9,10} & b_{9,11} & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} Z_1(t) \\ \Phi_{10}^1 \\ \Phi_{11}^1 \\ \Phi_{20}^1 \\ Z_2(t) \\ \Phi_{10}^2 \\ \Phi_{20}^2 \\ \Phi_{21}^2 \\ Z_3(t) \\ \Phi_{11}^3 \\ \Phi_{20}^3 \end{bmatrix}_t$$

dengan :

$$A_t = \begin{bmatrix} 0 & b_{1,2} & b_{1,3} & b_{1,4} & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & b_{5,6} & b_{5,7} & b_{5,8} & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & b_{9,10} & b_{9,11} & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}$$

$$b_{1,2} = Z_1(t - 1)$$

$$b_{1,3} = 0.548128Z_2(t - 1) + 0.451872Z_3(t - 1)$$

$$b_{1,4} = Z_1(t - 2)$$

$$b_{5,6} = Z_2(t - 1)$$

$$b_{5,7} = Z_2(t - 2)$$

$$b_{5,8} = 0.21151Z_1(t - 2) + 0.78849Z_3(t - 2)$$

$$b_{9,10} = Z_3(t - 1)$$

$$b_{9,11} = 0.181092Z_1(t - 1) + 0.818908Z_2(t - 1)$$

Model Pengukuran :

$$c_t = Hx_t$$

dengan :

$$H = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \end{bmatrix}$$

Inisialisasi :

$$\hat{x}_0 = \begin{bmatrix} 0.575435 \\ 1.00787 \\ 0.48783 \\ -0.74257 \\ 0.605227 \\ 0.78632 \\ 0.64147 \\ -0.97172 \\ 0.131275 \\ 0.39158 \\ -0.33055 \end{bmatrix}, P_0 = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}$$

dengan nilai awal varians dari noise sistem dan pengukuran $Q = 0.01$ dan $R = 0.001$.

Algoritma Filter Kalman terdiri dari dua tahapan yaitu tahap prediksi (*time update*) dan tahap koreksi (*measurement update*) sebagai berikut [12] :

1) Tahap prediksi :

$$\hat{x}_{t+1}^- = A\hat{x}_t$$

$$+ w_t P_{t+1}^- = A_t P_t A_t^T + Q$$

2) Tahap koreksi :

$$K_{t+1} = P_{t+1}^- H^T (HP_{t+1}^- H^T + R)^{-1}$$

$$\hat{x}_{t+1} = \hat{x}_{t+1}^- + K_{t+1}(c_{t+1} - H\hat{x}_{t+1}^-)$$

$$P_{t+1} = (1 - K_{t+1}H)P_{t+1}^-$$

Perbandingan dilakukan dengan melihat nilai dari MAPE model GSTAR-GLS dengan GSTAR-Filter Kalman dimana model dengan nilai MAPE terkecil adalah model yang terbaik. Hasil perhitungan nilai MAPE tertera pada Tabel 6.

Simulasi Filter Kalman telah dilakukan dengan menggunakan bantuan *software* MatLab. Hasil estimasi data tingkat inflasi nasional menggunakan Filter Kalman dapat dilihat pada Gambar 1 untuk provinsi Jawa Timur, Gambar 2 untuk provinsi Jawa Barat dan Gambar 3 untuk provinsi DKI Jakarta.

IV. KESIMPULAN

Berdasarkan hasil penelitian Tugas Akhir ini, dapat disimpulkan sebagai berikut data inflasi yang mengalami perbedaan yang signifikan saat terjadi pandemi *covid-19* adalah data tingkat inflasi Provinsi DKI Jakarta. Artinya pandemi *Covid-19* mempengaruhi pola pergerakan inflasi pada Provinsi DKI Jakarta.

Model GSTAR(2₁) di estimasi menggunakan metode OLS dan GLS dengan pembobotan invers jarak dan normalisasi korelasi silang. Nilai rata-rata MAPE terkecil terdapat pada model GSTAR(2₁)-GLS bobot invers jarak yaitu sebesar 6.01399%.

Model GSTAR yang di estimasi menggunakan metode Filter Kalman menunjukkan hasil yang lebih baik dikarenakan memiliki nilai MAPE yang lebih kecil dibandingkan dengan model GSTAR(2₁)-OLS dan GSTAR(2₁)-GLS dengan rata-rata nilai MAPE sebesar 0.14302%. Hal ini menunjukkan bahwa hasil peramalan tingkat inflasi dapat diperbaiki menggunakan metode Filter

Kalman. Hal tersebut juga dapat ditunjukkan melalui plot hasil simulasi dimana hasil estimasi Filter Kalman mendekati data aktual.

Adapun saran yang dapat dilakukan pada penelitian selanjutnya, Filter Kalman dapat diaplikasikan pada model *time series* lainnya. Serta dapat dilakukan penelitian terkait model GSTAR menggunakan pembobotan lokasi yang lain, seperti seragam, biner atau normalisasi hasil inferensia korelasi silang parsial.

DAFTAR PUSTAKA

- [1] Suseno and S. Astiyah, *Inflasi*, Jakarta: Bank Indonesia, 2009.
- [2] P. Sahoo, *Probability and Mathematical Statistic*. Louisville: University of Louisville, 2013.
- [3] S. G. Makridakis, S. C. Wheelwright, and V. E. McGee, *Forecasting: Method and Applications*, 2nd ed. New York: John Wiley & Sons, 1983.
- [4] W. Wei, *Time Series Analysis Univariate and Multivariate*. London: Pearson education, 2006.
- [5] D. U. Wutsqa, S. Suhartono, and B. Sutijo, "Aplikasi model generalized space time autoregressive pada data pencemaran udara di Kota Surabaya," *Pythagoras J. Mat. dan Pendidik. Mat.*, vol. 7, no. 2, 2012.
- [6] U. Mukhaiyar and U. S. Pasaribu, "A new procedure for generalized STAR modeling using IAcM approach," *ITB J. Sci*, vol. 44, no. 2, pp. 179--192, 2012.
- [7] S. Suhartono and S. Subanar, "The optimal determination of space weight in GSTAR model by using cross-correlation inference," *Quant. Methods*, vol. 2, no. 2, pp. 45--53, 2006.
- [8] J. R. Prillantika, E. Apriliani, and N. Wahyuningsih, "Comparison between GSTAR and GSTAR-Kalman Filter models on inflation rate forecasting in East Java," in *Journal of Physics: Conference Series*. 2018.
- [9] A. C. Rencher and G. B. Schaalje, *Linier Model in Statistics*. London: John Wiley & Sons, 2008.
- [10] A. S. Prasetya, "Model GSTAR dengan Variabel Eksogen Metrik dan Non Metrik untuk Peramalan Inflasi di Kalimantan," Departemen Matematika: Institut Teknologi Sepuluh Nopember, 2017.
- [11] M. Prastuti and I. D. Ratih, "Kajian simulasi estimasi parameter model GSTAR- GLS untuk data berpola musiman," *Media Bina Ilm.*, vol. 13, no. 12, pp. 1769--1766, 2019.
- [12] F. L. Lewis, L. Xie, and D. Popa, *Optimal and Robust Estimation: With an Introduction to Stochastic Control Theory*. Florida: Crc Press, 2017.