

PERAMALAN JUMLAH PENUMPANG PENERBANGAN DOMESTIK PADA TIGA BANDARA UTAMA INDONESIA MENGGUNAKAN MODEL *GENERALIZED SPACE TIME AUTOREGRESSIVE (GSTAR)*

Nabila Zahra Tamami^{1*}, Puspita Kartikasari², Deby Fakhriyana³

^{1,2,3} Departemen Statistika, Fakultas Sains dan Matematika, Universitas Diponegoro

*e-mail: nabilanzt@gmail.com

DOI: 10.14710/j.gauss.15.1.243-254

Article Info:

Received: 2024-08-29

Accepted: 2025-12-30

Available Online: 2026-08-12

Keywords:

Airports; number of passengers;

Location weights; GSTAR;

Forecasting; sMAPE

Abstract: Forecasting the number of airplane passengers requires a model related to time and location because the data on the number of airplane passengers is space time series data. Generalized Space Time Autoregressive (GSTAR) is an approach to forecast time series data that show a connection between time and location. The GSTAR model can be applied to data with heterogeneous location characteristics. In this research, the GSTAR model is used to form a forecasting model for the number of domestic flight passengers at three major airports in Indonesia Juanda Airport, Soekarno Hatta Airport, and Hasanuddin Airport, using optimal location weighting. The residual of the GSTAR model satisfies the white noise assumption. The location weights used are uniform weights, inverse distance weights, and cross-correlation normalization. The outcome model is constructed with a first-order differencing, an autoregressive order of 1, and spatial order of 1, resulting in the formation of the GSTAR (1_I)I(1) model. The most optimal model generated is the GSTAR (1_I)I(1) model utilizing inverse distance weights due to its smallest sMAPE value compared to other weightings, which stands at 8,71%. This sMAPE value signifies a highly precise forecast accuracy.

1. PENDAHULUAN

Menurut Subekti (2018) kepuasan penumpang menjadi salah satu indikator tingkat pelayanan bandara. Maskapai perlu melakukan prediksi guna mengetahui seberapa banyak peningkatan jumlah penumpang. Prediksi tersebut dilakukan sebagai bahan pertimbangan untuk perencanaan dan pengelolaan kapasitas penerbangan ketika permintaan tiket meningkat sehingga dapat memaksimalkan keuntungan dan memberikan kenyamanan kepada penumpang. Prediksi jumlah penumpang pesawat membutuhkan suatu model yang berkaitan dengan waktu (Durrah *et al.*, 2018).

Analisis deret waktu adalah proses menganalisis kumpulan data dalam rentang waktu sebelumnya dengan tujuan untuk memahami atau meramalkan situasi yang akan datang (Soejoeti, 1987). Sejumlah data deret waktu dicatat secara simultan di berbagai lokasi, menghasilkan data deret waktu spasial (*space time*). Data deret waktu spasial tidak hanya mencerminkan hubungan dengan peristiwa masa sebelumnya, tetapi juga terkait dengan lokasi khusus (Ardianto, 2014).

Generalized Space Time Autoregressive (GSTAR) merupakan salah satu model memprediksi data deret waktu yang memiliki keterkaitan dalam aspek waktu dan lokasi. Model ini dapat diterapkan dengan lebih fleksibel di lokasi yang memiliki perbedaan (heterogen) (Ruchjana *et al.*, 2012). Data yang memiliki karakteristik heterogenitas lokasi sering kali mengalami proses standarisasi pada matriks bobot lokasi. Suhartono dan Atok (2006) menjelaskan bahwa ada beberapa opsi untuk menetapkan bobot lokasi dalam pemodelan dengan menggunakan GSTAR, yakni dengan bobot seragam dan

bobot *invers* jarak. Suhartono dan Subanar (2006) memperkenalkan pendekatan baru dalam menentukan bobot, yaitu melalui normalisasi korelasi silang.

Penelitian ini bertujuan untuk membangun model dan melakukan prediksi terhadap jumlah penumpang penerbangan domestik pada tiga bandara utama Indonesia menggunakan metode GSTAR dengan bobot seragam, bobot *invers* jarak dan bobot normalisasi korelasi silang.

2. TINJAUAN PUSTAKA

Runtun waktu multivariat merujuk pada gabungan data yang memiliki beberapa variabel pada berbagai titik waktu yang disusun berurutan, sesuai urutan waktu peristiwa dengan rentang waktu yang konsisten (Wei, 2006). Runtun waktu multivariat dapat dinotasikan dengan $Z_{1t}, Z_{2t}, \dots, Z_{Nt}$ dimana Z_{it} adalah variabel ke- i yang tercatat pada waktu t , dengan $i = 1, 2, \dots, N$.

Koefisien korelasi berfungsi untuk mengukur hubungan linier pada dua variabel. Ketika nilai koefisien korelasi mendekati 1 atau -1, hal ini mengindikasikan adanya hubungan yang kuat pada dua variabel tersebut. Sebaliknya, jika nilai mendekati 0, ini menandakan adanya hubungan yang lemah pada keduanya. Uji korelasi yang digunakan adalah uji korelasi *Pearson*, yang dijelaskan sebagai berikut:

Hipotesis:

$H_0 : r_{ij} = 0$ dengan $i = 1, 2, 3, \dots, N$ dan $j = 1, 2, 3, \dots, N$ dengan $i \neq j$ (Tidak terdapat korelasi antar wilayah)

$H_1 : r_{ij} \neq 0$ dengan $i = 1, 2, 3, \dots, N$ dan $j = 1, 2, 3, \dots, N$ dengan $i \neq j$ (Terdapat korelasi antar wilayah)

Statistik Uji:

$$r_{ij} = \frac{n \sum_{j=1}^n \sum_{i=1}^n Z_i Z_j - \sum_{i=1}^n Z_i \sum_{j=1}^n Z_j}{\sqrt{(n \sum_{i=1}^n Z_i^2 - (\sum_{i=1}^n Z_i)^2)} \sqrt{(n \sum_{j=1}^n Z_j^2 - (\sum_{j=1}^n Z_j)^2)}} \quad (1)$$

$$t_{ij} = \frac{r_{ij} \sqrt{n-2}}{\sqrt{1-r_{ij}^2}} \quad (2)$$

dimana n merupakan banyaknya data, r_{ij} merupakan nilai korelasi pada wilayah ke- i dengan wilayah ke- j , Z_i merupakan nilai variabel Z ke- i dan Z_j merupakan nilai variabel Z ke- j .

Kriteria Uji:

H_0 ditolak jika $|t_{ij}| \geq t_{tabel}(\frac{\alpha}{2}, db=n-p-1)$ atau $p\text{-value} < \alpha$ dengan p merupakan banyaknya wilayah dan n merupakan banyaknya data.

Corrado Gini (1884-1965) yang merupakan seorang ahli statistik, demografi, dan sosiolog Italia memperkenalkan indeks gini sebagai metode untuk melihat keheterogenan lokasi. Indeks gini bisa diterapkan untuk membandingkan perubahan dari satu periode ke periode lain atau dari satu lokasi ke lokasi lain. Indeks gini dapat dirumuskan sebagai berikut:

$$G = 1 + \frac{1}{N} - \frac{2}{N^2 \bar{Z}} \sum_{t=1}^N Z_t \quad (3)$$

dengan G mewakili nilai indeks gini, Z_t adalah nilai variabel yang diamati pada waktu ke- t , $\bar{Z}$ adalah rata-rata nilai variabel yang diamati, N adalah banyaknya data pada semua lokasi. Menurut Widayati *et al.* (2023) jika nilai indeks gini mendekati 0 maka kemerataannya

semakin sempurna atau homogen, apabila nilai indeks gini mendekati 1 maka ketidakmerataannya sempurna atau heterogen.

Data dianggap stasioner jika pola data tersebut tetap di dekat rata-rata yang konsisten dan variansinya juga konsisten pada periode waktu tertentu (Makridakis, 1999). Stasioneritas dalam varians dapat diidentifikasi melalui nilai *rounded value*. Nilai *rounded value* sebesar 1 menunjukkan bahwa data memiliki stasioneritas dalam varians. Sebaliknya, jika nilai *rounded value* tidak sama dengan 1, maka data dianggap tidak memiliki stasioneritas dalam varians dan memerlukan transformasi data.

Sementara untuk mengidentifikasi stasioneritas dalam *mean*, uji *Augmented Dickey Fuller* (ADF) dapat digunakan. Selain itu, juga bisa diamati melalui plot *Matrix Autocorrelation Function* (MACF) (Wei, 2006). Data deret waktu dianggap stasioner dalam *mean* jika memiliki rata-rata yang konstan (tidak dipengaruhi oleh waktu), varian yang konstan, dan tidak memiliki autokorelasi (Wei, 2006). Uji *Augmented Dickey Fuller* (ADF) adalah pendekatan formal untuk menguji stasioneritas dalam *mean*. Uji *Augmented Dickey Fuller* (ADF) melibatkan tahap pengujian sebagai berikut:

Hipotesis:

$H_0 : \delta = 0$ (terdapat *unit root* atau data tidak stasioner)

$H_1 : \delta \neq 0$ (tidak terdapat *unit root* atau data stasioner)

Statistik Uji:

$$t_{hitung} = \frac{\hat{\delta}}{SE(\hat{\delta})} \quad (4)$$

$$\text{dengan } SE(\hat{\delta}) = \sqrt{\frac{\sigma^2}{\sum_{t=1}^n (Z_{t-1} - \bar{Z}_{t-1})}}$$

dimana $\hat{\delta}$ adalah estimasi kuadrat kecil dari δ dan $S(\hat{\delta})$ adalah standar error dari δ .

Kriteria Uji:

H_0 ditolak jika $|t_{hitung}| > t_{(\alpha; n-1)}$ atau nilai *p-value* $< \alpha$, n adalah banyak amatan.

Suatu vektor deret waktu dengan n pengamatan $Z_1, Z_2, \dots, Z_n$ digunakan untuk menghitung sampel MACF dengan persamaan MACF dapat dituliskan sebagai berikut (Wei, 2006):

$$\hat{\rho}(k) = [\hat{\rho}_{ij}(k)] \quad (5)$$

dengan $\hat{\rho}_{ij}(k)$ menunjukkan korelasi silang sampel untuk deret ke- i dan ke- j pada lag ke- k yang dapat dinyatakan dengan persamaan:

$$\hat{\rho}_{ij}(k) = \frac{\sum_{t=1}^{n-k} [Z_i(t) - \bar{Z}_i][Z_j(t+k) - \bar{Z}_j]}{[\sum_{t=1}^n [Z_i(t) - \bar{Z}_i]^2 \sum_{t=1}^n [Z_j(t) - \bar{Z}_j]^2]^{\frac{1}{2}}} \quad (6)$$

dimana $\bar{Z}_i$ dan $\bar{Z}_j$ adalah rata-rata suatu deret.

Tiao and Box dalam Wei (2006) memperkenalkan cara untuk merangkum korelasi sampel dengan memakai simbol (+), (-), dan (.). Simbol (+) menunjukkan bahwa nilai $\hat{\rho}_{ij}(k)$ lebih besar dari 2 kali *standard error* (korelasi positif). Simbol (-) menunjukkan bahwa nilai $\hat{\rho}_{ij}(k)$ lebih kecil dari -2 kali *standard error* (korelasi negatif). Simbol (.) menunjukkan bahwa nilai $\hat{\rho}_{ij}(k)$ berada di antara 2 dan -2 kali *standard error* dari $\hat{\rho}_{ij}(k)$ (tidak terdapat korelasi).

Identifikasi model GSTAR melibatkan orde waktu (*autoregressive*) yang bisa diperoleh dengan AIC (*Akaike Information Criterion*). Sementara itu, orde spasial dalam model

GSTAR, biasanya pada orde 1 karena orde yang lebih tinggi cenderung sulit diinterpretasikan (Wutsqa *et al.*, 2010).

Model GSTAR merupakan perluasan dari model STAR, sehingga bentuk umum model GSTAR serupa dengan bentuk umum model STAR. Model GSTAR dengan STAR adalah GSTAR dapat digunakan pada lokasi yang heterogen dalam bentuk matriks bobot. Suatu deret $\{Z(t): t = 0, \pm 1, \pm 2, \dots, \pm n\}$ yang merupakan runtun waktu multivariat dari N lokasi akan mendapatkan GSTAR $(p; l_1, l_2, \dots, l_p)$ sebagai berikut :

$$Z(t) = \sum_{k=1}^p [\Phi_{k0} + \Phi_{k1}W]Z_{t-k} + e(t) \quad (11)$$

dengan,

$Z_{(t)}$: Vektor observasi $(N \times 1)$ pada waktu t

Φ_{k0} : Matriks diag parameter Φ_{k0}

Φ_{k1} : Matriks diag parameter Φ_{k1}

W : Matriks bobot lokasi $(N \times N)$

$e(t)$: Vektor *noise* ukuran $(N \times 1)$

Terdapat beberapa opsi untuk menetapkan bobot lokasi, yakni dengan bobot seragam, bobot *invers* jarak dan bobot normalisasi korelasi silang (Suhartono dan Atok, 2006). Nilai bobot seragam untuk setiap lokasi identik dan memberikan jarak antar lokasi sama. Rumus perhitungan bobot seragam adalah sebagai berikut:

$$w_{ij} = \begin{cases} \frac{1}{N-1}, & i \neq j \\ 0, & i = j \end{cases} \quad (6)$$

Menurut Cliff dan Ord (1983), bobot *invers* jarak diperoleh dengan mengacu pada jarak antar lokasi. Jarak antar lokasi dapat dihitung dengan persamaan sebagai berikut :

$$d_{ij} = \sqrt{(u_i - u_j)^2 + (v_i - v_j)^2} \quad (7)$$

dengan d_{ij} adalah jarak lokasi ke- i dan ke- j , u_i, u_j adalah koordinat garis lintang lokasi ke- i dan ke- j serta v_i, v_j adalah koordinat garis bujur lokasi ke- i dan ke- j .

Pembobotan *invers* jarak antara lokasi i dan j dapat dinyatakan sebagai berikut :

$$w_{ij} = \frac{\frac{1}{d_{ij}}}{\sum_j \frac{1}{d_{ij}}}, \text{ jika } i \neq j \text{ dan } w_{ij} = 0, \text{ jika } i=j \quad (8)$$

Bobot normalisasi korelasi silang diperoleh dengan melakukan normalisasi terhadap korelasi silang antar lokasi pada lag yang sesuai. Penduga korelasi silang pada sampel adalah:

$$r_{ij}(k) = \frac{\sum_{t=k+1}^n [Z_i(t) - \bar{Z}_i][Z_j(t-k) - \bar{Z}_j]}{[(\sum_{t=1}^n [Z_i(t) - \bar{Z}_i]^2)(\sum_{t=1}^n [Z_j(t) - \bar{Z}_j]^2)]^{\frac{1}{2}}} \quad (9)$$

dengan k merupakan orde *autoregressive*. Pembobotan normalisasi korelasi silang antara lokasi i dan j dapat dinyatakan sebagai berikut :

$$w_{ij} = \frac{|r_{ij}(k)|}{\sum_{k \neq 1} |r_{ij}(k)|}, i \neq j \quad (10)$$

Perhitungan parameter model GSTAR dapat dilakukan dengan estimasi parameter menggunakan metode *Ordinary Least Square* (OLS) dengan meminimalkan jumlah kuadrat dari residual (Borovkova, 2008). Nilai estimasi OLS untuk $\hat{\Phi}$ adalah:

$$\hat{\Phi} = [Z^{*T}Z^*]^{-1}Z^{*T}Z \quad (31)$$

Uji t biasanya berguna untuk menilai signifikansi setiap parameter terhadap model. Pengujian signifikansi parameter sebagai berikut :

Hipotesis:

$H_0 : \phi_{k\ell}^{(i)} = 0$ dengan $k = 1, 2, \dots, p$, $i = 1, 2, \dots, N$ dan $\ell = 0, 1, 2, \dots, \lambda_p$ (Parameter tidak signifikan terhadap model)

$H_1 : \text{minimal ada satu } \phi_{k\ell}^{(i)} \neq 0$ dengan $k = 1, 2, \dots, p$, $i = 1, 2, \dots, N$ dan $\ell = 0, 1, 2, \dots, \lambda_p$ (Parameter signifikan terhadap model)

Statistik Uji:

$$t_{hit} = \frac{\phi_{k\ell}^{(i)}}{SE(\phi_{k\ell}^{(i)})} \quad (12)$$

dengan $\phi_{k\ell}^{(i)}$ merupakan estimasi parameter regresi pada lokasi ke- i dengan orde waktu dari AR (p) dan ℓ merupakan orde spasial serta $SE(\phi_{k\ell}^{(i)})$ merupakan standar eror parameter regresi pada lokasi ke- i dengan orde waktu dari AR (p) dan ℓ merupakan orde spasial.

Kriteria Uji:

H_0 ditolak jika $|t_{hit}| > t_{\frac{\alpha}{2}(N-N_p)}$ atau $p\text{-value} < \alpha$ dengan N adalah jumlah observasi dan N_p adalah banyaknya parameter.

Uji kelayakan model berguna untuk melihat apakah model layak digunakan untuk peramalan. Uji residual *white noise* berfungsi untuk mengetahui terdapat tidak terdapatnya korelasi residual antar lag. Asumsi *white noise* dapat ditentukan dengan uji *Ljung Box Pearce* (Wei, 2006). Pengujian *Ljung Box Pearce* dapat dilakukan sebagai berikut:

Hipotesis:

$H_0 : \rho_1 = \rho_2 = \dots = \rho_K = 0$ (Residual *white noise*)

$H_1 : \text{minimal ada satu } \rho_k \neq 0$ dengan $k=1,2,\dots,K$ (Residual tidak *white noise*)

Statistik Uji:

$$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-k} \quad (13)$$

dengan K merupakan lag maksimum, m adalah banyaknya parameter pada model dan $\hat{\rho}_k^2$ adalah autokorelasi dari residual pada lag k .

Kriteria Uji:

H_0 ditolak jika $Q > X_{\alpha;K-m}^2$ atau $p\text{-value} < \alpha$

Pengukuran kesalahan peramalan memiliki tujuan untuk mengevaluasi kinerja model peramalan pada data *testing*. Salah satu metrik pengukuran kesalahan peramalan yang digunakan untuk mengukur akurasi adalah *symmetric Mean Absolute Percentage Error* (sMAPE) (Makridakis dan Hibon, 2000). Nilai sMAPE yang semakin kecil akan memberikan nilai peramalan yang sangat akurat. sMAPE menghitung ukuran persentasi kesalahan dengan rumus sebagai berikut:

$$sMAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Z_t - \hat{Z}_t|}{(|Z_t| + |\hat{Z}_t|)/2} \times 100\% \quad (14)$$

dengan n merupakan banyaknya observasi, Z_t adalah nilai aktual dan $\hat{Z}_t$ adalah nilai hasil peramalan.

3. METODE PENELITIAN

Data dalam penelitian ini berasal dari sumber data sekunder yang diperoleh dari Badan Pusat Statistik (BPS). Data tersebut mencakup Jumlah Penumpang Penerbangan Domestik di Bandara Juanda, Bandara Soekarno Hatta dan Bandara Hassanudin mulai dari Januari 2015 hingga Desember 2022. Data dalam penelitian terbagi menjadi data *training* periode Januari 2015 hingga Desember 2021 dan data *testing* periode Januari 2022 hingga Desember 2022.

Proses analisis dalam penelitian ini dilakukan menggunakan menggunakan *software* Rstudio dan SAS 9.4. Tahapan analisis dalam penelitian ini adalah sebagai berikut:

1. Menentukan data yang digunakan dalam penelitian.
2. Membagi data menjadi data *training* dan data *testing*.
3. Mendeskripsikan korelasi antar lokasi.
4. Melakukan uji heterogenitas setiap lokasi.
5. Mengidentifikasi kestasioneran data, jika prosesnya tidak stasioner, maka dilakukan *transformasi Box-Cox* (untuk non-stasioneritas dalam varian) dan *differencing* (untuk non-stasioneritas dalam *mean*).
6. Menentukan orde GSTAR.
7. Mengaplikasikan pembobotan lokasi pada model GSTAR dengan bobot seragam, bobot *invers* jarak dan bobot normalisasi korelasi silang.
8. Melakukan estimasi parameter model GSTAR berdasarkan setiap bobot lokasi yang telah didapat menggunakan OLS dan melakukan uji signifikansi parameter GSTAR.
9. Melakukan uji kelayakan model GSTAR berdasarkan setiap pembobotan lokasi yang diperoleh menggunakan uji asumsi *white noise*.
10. Melakukan peramalan menggunakan model GSTAR dan menghitung nilai sMAPE untuk setiap pembobotan lokasi yang diperoleh.
11. Menentukan model GSTAR terbaik dengan sMAPE terkecil.

4. HASIL DAN PEMBAHASAN

Hasil analisis statistika deskriptif pada masing-masing variabel jumlah penumpang penerbangan domestik pada Bandara Juanda, Bandara Soekarno Hatta dan Bandara Hasanuddin pada Januari 2015 hingga Desember 2022 disajikan dalam tabel sebagai berikut:

Tabel 1. Statistika Deskriptif Data Jumlah Penumpang Penerbangan Domestik

Bandara	N	Mean	St.Dev	Minimum	Maksimum
Juanda	96	487.422,46	205.981,83	5.397	889.548
Soekarno Hatta	96	1.418.194,01	531.001,50	27.500	2.132.360
Hasanuddin	96	261.865,07	90.818,11	6.663	437.365

Berdasarkan Tabel 1. rata-rata penumpang penerbangan domestik tertinggi yaitu di Bandara Soekarno Hatta sebanyak 1.418.195 penumpang, sedangkan rata-rata penumpang penerbangan domestik terendah yaitu di Bandara Hasanuddin sebanyak 261.866 penumpang. Keragaman tertinggi yaitu di Bandara Soekarno Hatta mencapai 531.001,50. Tabel 1. menunjukkan bahwa standar deviasi ketiga bandara utama tersebut lebih kecil daripada rata-ratanya, artinya tingkat penyimpangannya pun rendah. Nilai maksimum dan nilai minimum ketiga bandara utama mengalami fluktuasi, dengan nilai maksimum tertinggi pada Bandara Soekarno Hatta yaitu 2.132.360 penumpang dan nilai minimum tertinggi terdapat pada Bandara Soekarno Hatta yaitu 27.500 penumpang. Berdasarkan hasil korelasi Pearson, jumlah penumpang penerbangan domestik di Bandara Juanda, Bandara Soekarno

Hatta, dan Bandara Hasanuddin memiliki hubungan yang sangat kuat dan signifikan. Korelasi antara Bandara Juanda dan Bandara Soekarno Hatta sebesar **0,96758**, sedangkan korelasi antara Bandara Juanda dan Bandara Hasanuddin sebesar **0,97273**. Adapun korelasi antara Bandara Soekarno Hatta dan Bandara Hasanuddin sebesar **0,96782**.

Seluruh nilai korelasi tersebut bernilai positif dan mendekati angka satu, sehingga menunjukkan bahwa perubahan jumlah penumpang di satu bandara cenderung searah dengan perubahan jumlah penumpang di bandara lainnya. Selain itu, seluruh hubungan antarbandara memiliki nilai **p-value < 0,0001**, yang berarti korelasi tersebut signifikan secara statistik pada taraf signifikansi 5%. Nilai korelasi antar tiga bandara utama tersebut mendekati 1 atau kurang dari 0,9 maka dapat disimpulkan bahwa terdapat keterkaitan sangat kuat antar satu bandara utama dengan bandara utama yang lain dan dapat dilanjutkan dengan analisis multivariat.

Data pada penerapan model GSTAR harus heterogen. Heterogenitas dari ketiga lokasi dapat dilihat dari perhitungan nilai indeks gini sebagai berikut:

$$G = 1 + \frac{1}{N} - \frac{2}{N^2 \bar{Z}} \sum_{t=1}^N Z_t$$

$$G = 1 + \frac{1}{252} - \frac{2}{252^2(734.693,18)} 185.142.682$$

$$G = 0,996032$$

Berdasarkan hasil perhitungan indeks gini didapatkan hasil indeks gini sebesar 0,996032. Nilai indeks gini yang didapatkan mendekati satu, yang artinya memiliki ketidakmerataan yang tinggi atau dapat dikatakan bahwa lokasi heterogen dan layak digunakan untuk pemodelan GSTAR (Sulistyono *et al.*, 2020).

Pengujian stasioneritas pada penelitian ini adalah stasioneritas dalam varian dan *mean*. Nilai *rounded value* untuk masing-masing lokasi yaitu Bandara Juanda sebesar 1,00, Bandara Soekarno Hatta sebesar 1,00 dan Bandara Hasanuddin sebesar 1,00. Ketiga nilai *rounded value* masing masing lokasi =1 artinya data jumlah penumpang penerbangan domestik Bandara Juanda, Bandara Soekarno Hatta dan Bandara Hasanuddin stasioner dalam varian dan tidak perlu dilakukan transformasi.

Data yang sudah stasioner dalam varian maka dilanjutkan pengujian stasioneritas dalam *mean*. Pengujian stasioneritas dalam *mean* dapat dilihat melalui plot MACF sebagai berikut:

<i>Schematic Representation of Cross Correlations</i>													
Variable/Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
z1	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++
z2	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++
z3	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++
+ is > 2*std error, - is < -2*std error, . is between													

Gambar 1. Plot MACF Data Jumlah Penumpang Penerbangan Domestik

Plot MACF pada Gambar 1. menunjukkan terdapat tanda positif (+). Tanda (+) dalam plot MACF mengindikasikan bahwa adanya korelasi positif, tanda (-) mengindikasikan bahwa adanya korelasi negatif dan tanda (.) mengindikasikan bahwa tidak adanya korelasi. Tabel 4. menunjukkan bahwa data belum stasioner dalam *mean* karena simbol (+) muncul pada setiap lag dalam plot MACF yang artinya terdapat korelasi positif maka perlu dilakukan *differencing* pertama.

<i>Schematic Representation of Cross Correlations</i>													
Variable/Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
z1	+++	-. -	...	...	...	...	...	...	...	...	---	...	+++
z2	+++	...	...	...	...	...	...	...	...	...	...	...	+++
z3	+++	-. -	...	...	...	...	...	...	...	...	---	...	+++

+ is > 2*std error, - is < -2*std error, . is between

Gambar 2. Plot MACF Jumlah Penumpang Penerbangan Domestik Setelah Differencing 1

Plot MACF pada Gambar 2. menunjukkan terdapat tanda positif (+), tanda negatif (-) dan tanda tanda (.). Gambar 2. menunjukkan bahwa data sudah stasioner dalam *mean* setelah dilakukan *differencing* pertama karena simbol (.) lebih banyak muncul dalam plot MACF yang artinya tidak adanya korelasi. Sementara tanda (+) dan (-) pada plot MACF hanya keluar pada lag tertentu.

Pengujian stasioneritas secara formal dalam *mean* untuk setiap variabel menggunakan uji *Augmented Dickey Fuller* (ADF). Pengujian stasioneritas dalam *mean* setelah *differencing* pertama dengan uji *Augmented Dickey Fuller* (ADF) untuk setiap lokasi disajikan pada Tabel 2 berikut:

Tabel 2. Hasil ADF Test

Bandara Utama	<i>p-value</i>	Keputusan	Keterangan
Juanda	0,01	H ₀ ditolak	Stasioner
Soekarno Hatta	0,01527	H ₀ ditolak	Stasioner
Hasanuddin	0,01	H ₀ ditolak	Stasioner

Berdasarkan Tabel 2. diperoleh bahwa untuk nilai *p-value* masing-masing bandara utama memiliki nilai *p-value* kurang dari $\alpha = 0,05$ sehingga dapat disimpulkan bahwa data jumlah penumpang penerbangan domestik pada tiga bandara utama di Indonesia telah stasioneritas dalam *mean*.

Orde waktu dapat ditentukan dengan menggunakan nilai AIC minimum atau terkecil. Adapun untuk nilai AIC dapat dilihat pada Tabel 3. Mengacu Tabel 3. menunjukkan bahwa nilai AIC minimum atau terkecil adalah AR (1) dan MA (0) yaitu sebesar 65,941077 maka orde waktu yang digunakan orde 1. Sedangkan orde spasial yang digunakan orde 1 karena jika lebih dari 1 cenderung susah untuk diinterpretasikan dalam model. Model GSTAR yang terbentuk dan akan digunakan dalam analisis ini adalah GSTAR (1₁)I(1).

Tabel 3. Nilai Akaike Information Criterion (AIC)

Minimum Information Criterion						
Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	66,443775	66,142737	66,241157	66,346611	66,488448	66,695559
AR 1	65,941077	66,032295	66,164927	66,231961	66,428275	66,687978
AR 2	65,988614	66,129420	66,284442	66,390151	66,557576	66,779179
AR 3	66,229189	66,351529	66,394492	66,522998	66,583231	66,664705
AR 4	66,467481	66,507488	66,599657	66,766038	66,799526	67,005792
AR 5	66,569834	66,577820	66,668359	66,838870	67,088539	67,112428

Pemodelan GSTAR (1₁)I(1) pada penelitian ini menggunakan bobot seragam, bobot *invers* jarak dan bobot normalisasi korelasi silang. Hasil perhitungan matriks bobot seragam adalah sebagai berikut:

$$w_{ij} = \begin{bmatrix} 0 & 0,5 & 0,5 \\ 0,5 & 0 & 0,5 \\ 0,5 & 0,5 & 0 \end{bmatrix}$$

Hasil perhitungan matriks bobot *invers* jarak adalah sebagai berikut:

$$w_{ij} = \begin{bmatrix} 0 & 0,5324 & 0,4676 \\ 0,6737 & 0 & 0,3263 \\ 0,6446 & 0,3554 & 0 \end{bmatrix}$$

Hasil perhitungan matriks bobot normalisasi korelasi silang adalah sebagai berikut:

$$w_{ij} = \begin{bmatrix} 0 & 0,5115 & 0,4885 \\ 0,5112 & 0 & 0,4888 \\ 0,4998 & 0,5002 & 0 \end{bmatrix}$$

Estimasi parameter pada penelitian ini menggunakan *Ordinary Least Square* (OLS). Hasil estimasi parameter untuk model GSTAR (1₁)I(1) dengan bobot seragam, bobot *invers* jarak dan bobot normalisasi korelasi silang adalah sebagai berikut:

Tabel 4. Estimasi Parameter Menggunakan *Ordinary Least Square* (OLS)

Bobot	Parameter	Estimasi	t-Hitung	p-value	Keputusan
Bobot Seragam	$\phi_{10}^{(1)}$	-0,8370	-2,745	0.0065	H ₀ ditolak
	$\phi_{10}^{(2)}$	0,3931	3,069	0.0024	H ₀ ditolak
	$\phi_{10}^{(3)}$	-1,1241	-1,678	0.0946	H ₀ diterima
	$\phi_{11}^{(1)}$	0,4981	2,206	0.0283	H ₀ ditolak
	$\phi_{11}^{(2)}$	-1,5667	-3,985	8.95e-05	H ₀ ditolak
	$\phi_{11}^{(3)}$	0,3007	1,390	0.1659	H ₀ diterima
Bobot <i>Invers</i> Jarak	$\phi_{10}^{(1)}$	-0,8357	-2,748	0.006459	H ₀ ditolak
	$\phi_{10}^{(2)}$	0,3793	2,987	0.003109	H ₀ ditolak
	$\phi_{10}^{(3)}$	-1,1187	-1,591	0.112878	H ₀ diterima
	$\phi_{11}^{(1)}$	0,3720	2,210	0.028067	H ₀ ditolak
	$\phi_{11}^{(2)}$	-1,6050	-3,908	0.000121	H ₀ ditolak
	$\phi_{11}^{(3)}$	0,4014	1,300	0.194796	H ₀ diterima
Bobot Normalisasi Korelasi Silang	$\phi_{10}^{(1)}$	-0,8363	-2,749	0.00644	H ₀ ditolak
	$\phi_{10}^{(2)}$	0,3924	3,064	0.00243	H ₀ ditolak
	$\phi_{10}^{(3)}$	-1,1241	-1,679	0,09455	H ₀ diterima
	$\phi_{11}^{(1)}$	0,4888	2,210	0,02806	H ₀ ditolak
	$\phi_{11}^{(2)}$	-1,5404	-3,981	9,09e-05	H ₀ ditolak
	$\phi_{11}^{(3)}$	0,3077	1,390	0,16583	H ₀ diterima

Berdasarkan hasil estimasi parameter semua bobot lokasi pada Tabel 8. diperoleh parameter $\phi_{10}^{(1)}$, $\phi_{10}^{(2)}$, $\phi_{11}^{(1)}$ dan $\phi_{11}^{(2)}$ berpengaruh signifikan terhadap model karena nilai *p-value* kurang dari $\alpha = 0,05$. Sedangkan parameter yaitu $\phi_{10}^{(3)}$ dan $\phi_{11}^{(3)}$ tidak berpengaruh signifikan terhadap model karena nilai *p-value* lebih besar dari $\alpha = 0,05$. Menurut Kostenko dan Hyndman (2008) variabel yang tidak signifikan dapat digunakan untuk peramalan. Sehingga parameter yang tidak signifikan dapat digunakan dalam pemodelan GSTAR (1₁)I(1) semua bobot lokasi untuk peramalan.

Uji kelayakan model penelitian ini adalah uji residual *white noise*. Asumsi *white noise* ini menggunakan uji *Ljung Box Pearce* disajikan pada Tabel 5. Berdasarkan Tabel 5. diperoleh semua nilai *p-value* dari bobot seragam, bobot *invers* jarak dan bobot normalisasi korelasi silang lebih besar dari taraf signifikan $\alpha = 0,05$, sehingga dapat

disimpulkan bahwa asumsi *white noise* terpenuhi pada model GSTAR (1)_I(1) pada setiap bobot lokasi.

Tabel 5. Hasil Uji *Ljung Box Pearce*

Bobot	Lokasi	<i>p-value</i>	Keputusan
Seragam	Bandara Juanda	0,1386	H ₀ diterima
	Bandara Soekarno Hatta	0,4884	H ₀ diterima
	Bandara Hasanuddin	0,6432	H ₀ diterima
<i>Invers</i> Jarak	Bandara Juanda	0,1040	H ₀ diterima
	Bandara Soekarno Hatta	0,4241	H ₀ diterima
	Bandara Hasanuddin	0,1617	H ₀ diterima
Normalisasi Korelasi Silang	Bandara Juanda	0,1380	H ₀ diterima
	Bandara Soekarno Hatta	0,4824	H ₀ diterima
	Bandara Hasanuddin	0,6041	H ₀ diterima

Tingkat akurasi dari hasil peramalan jumlah penumpang penerbangan domestik pada ketiga lokasi dapat diketahui dengan menggunakan nilai sMAPE. Nilai sMAPE hasil peramalan jumlah penerbangan domestik pada ketiga lokasi menggunakan bobot seragam, bobot *invers* jarak dan bobot normalisasi korelasi silang.

Tabel 6. Perbandingan Nilai sMAPE Model GSTAR (1)_I(1) pada Setiap Bobot Lokasi

Bobot Lokasi	sMAPE
Bobot Seragam	8,77%
Bobot <i>Invers</i> Jarak	8,71%
Bobot Normalisasi Korelasi Silang	8,79%

Tabel 7. Peramalan Jumlah Penumpang Penerbangan Domestik pada Tiga Bandara Utama di Indonesia Tahun 2023

Bulan	Juanda	Soekarno	Hasanuddin
Januari	420.418,614	1.658.722,327	252.220,755
Februari	427.461,463	1.644.531,459	217.803,570
Maret	412.775,953	1.649.557,710	256.103,023
April	432.708,439	1.647.286,185	210.175,529
Mei	407.609,487	1.648.923,827	266.387,004
Juni	438.689,895	1.647.246,532	197.243,820
Juli	400.352,812	1.649.213,375	282.395,452
Agustus	447.597,128	1.646.819,377	177.499,186
September	389.388,852	1.649.760,229	306.727,119
Oktober	461.101,751	1.646.139,634	147.521,009
November	372.752,178	1.650.599,424	343.660,353
Desember	481.597,647	1.645.105,242	102.019,647

Berdasarkan Tabel 6. model GSTAR (1)_I(1) dengan bobot *invers* jarak merupakan model yang terbaik untuk meramalkan jumlah penumpang penerbangan domestik pada tiga bandara utama di Indonesia. Hal ini dijelaskan dengan nilai sMAPE model GSTAR (1)_I(1) dengan bobot *invers* jarak lebih kecil dari model GSTAR (1)_I(1) dengan bobot seragam dan

bobot normalisasi korelasi silang yaitu sebesar 8,71%. Model GSTAR (1₁)I(1) dengan bobot *invers* jarak adalah sebagai berikut:

$$Z_{1(t)} = 0,1643 Z_{1(t-1)} + 0,8357 Z_{1(t-2)} + 0,1981 Z_{2(t-1)} - 0,1981 Z_{2(t-2)} + 0,1740 Z_{3(t-1)} - 0,1740 Z_{3(t-2)} + e_{1(t)}$$

$$Z_{2(t)} = -1,0813 Z_{1(t-1)} + 1,0813 Z_{1(t-2)} + 1,3793 Z_{2(t-1)} - 0,3793 Z_{2(t-2)} - 0,5237 Z_{3(t-1)} + 0,5237 Z_{3(t-2)} + e_{2(t)}$$

$$Z_{3(t)} = 0,2587 Z_{1(t-1)} - 0,2587 Z_{1(t-2)} + 0,1427 Z_{2(t-1)} - 0,1427 Z_{2(t-2)} - 0,1187 Z_{3(t-1)} + 1,1187 Z_{3(t-2)} + e_{3(t)}$$

Model ini selanjutnya digunakan untuk meramalakan jumlah penumpang penerbangan domestik pada tiga bandara utama Indonesia pada 12 periode kedepan dari Januari 2023 hingga Desember 2023 yang dapat dilihat pada Tabel 7.

5. KESIMPULAN

Kesimpulan dalam penelitian ini adalah model GSTAR (1₁)I(1) bobot *invers* jarak memberikan nilai peramalan dengan tingkat kesalahan yang lebih rendah dibandingkan dengan model bobot seragam dan bobot normalisasi korelasi silang yaitu sebesar 8,71%.

DAFTAR PUSTAKA

- Ardianto, M. P. (2014). Pemodelan *Generalized Space Time Autoregressive* (GSTAR) pada Tiga Periode Waktu (Studi Kasus Inflasi di Lima Kota Besar di Pulau Jawa). *Jurnal Mahasiswa Statistik*, 2(4), 265 –268.
- Badan Pusat Statistik. (2015-2022). Jumlah Penumpang Penerbangan Domestik di Bandara Utama. Tersedia: <https://www.bps.go.id> (diakses pada tanggal 1 Februari 2023).
- Borovkova, S.A., Lopuhaa, H.P., Ruchjana, B.N. (2008). *Consistency and Asymptotic Normality of Least Square Estimators in Generalized STAR Models*. *Journal compilation Statistica Neerlandica*, Hal. 482-500.
- Durrah, F. I., Yulia, Y., Parhusip, T. P., & Rusyana, A. (2018). Peramalan Jumlah Penumpang Pesawat Di Bandara Sultan Iskandar Muda Dengan Metode SARIMA (*Seasonal Autoregressive Integrated Moving Average*). *Journal of Data Analysis*, 1(1), 1-11.
- Kostenko, A. V., & Hyndman, R. J. (2008). Forecasting without significance tests?. *manuscript, Monash University, Australia*.
- Makridakis, S., & Hibon, M. (2000). The M3-Competition: results, conclusions and implications. *International journal of forecasting*, 16(4), 451-476.
- Mario, M. I. T., Kartiko, K., & Becti, R. D. (2021). Pemodelan *Generalized Space Time Autoregressive* (GSTAR) untuk Peramalan Tingkat Inflasi di Pulau Jawa. *Jurnal Statistika Industri dan Komputasi*, 6(2), 171-184.
- Ruchjana, B. N., Borovkova, S. A., & Lopuhaa, H. P. (2012). Least squares estimation of Generalized Space Time AutoRegressive (GSTAR) model and its properties. In *AIP Conference Proceedings* (Vol. 1450, No. 1, pp. 61-64). American Institute of Physics.
- Soejoeti. (1987). *Analisis Runtun Waktu*. Jakarta: Karunika Jakarta.
- Sofiana, S., Suparti, S., Hakim, A. R., & Triutami, I. (2020). Peramalan Jumlah Penumpang Pesawat di Bandara Internasional Ahmad Yani dengan Metode *Holt Winter's*

- Exponential Smoothing* dan *Metode Exponential Smoothing Event Based*. *Jurnal Gaussian*, 9(4), 535-545.
- Subekti, S. (2018). Kepuasan Penumpang Terhadap Pelayanan Terminal Domestik di Bandar Udara Adi Sucipto Yogyakarta. *Warta Penelitian Perhubungan*, 29(2), 277-288.
- Suhartono dan Atok, R.M. (2006). Pemilihan Bobot Lokasi yang Optimal pada Model GSTAR. *Presented at National Mathematics Conference XIII*. Semarang: Universitas Negeri Semarang.
- Suhartono dan Subanar. (2006). *The Optimal Determination of Space Weight in GSTAR Model by using Cross-correlation Inference*. *Journal of Quantitative Methods: Journal Devoted the Mathematical and Statistical Application in Various Field*. Vol. 2 No.2: pp. 45-53.
- Sulistiyono, A. D., Iriany, A., & Suryawardhani, N. W. (2020). Rainfall forecasting in agricultural areas using GSTAR-SUR model. In *IOP Conference Series: Earth and Environmental Science* (Vol. 458, No. 1, p. 012041). IOP Publishing.
- Wei, W. (2006). *Time Series Analysis : Univariate and Multivariate Methods*. Amerika: Pearson Education, Inc.
- Widayati, T., GS, A. D., Nugroho, N., Rahayu, S., Boari, Y., Syamil, A., ... & Suryahani, I. (2023). *PEREKONOMIAN INDONESIA: Perkembangan & Transformasi Perekonomian Indonesia Abad 21 Terkini*. PT. Sonpedia Publishing Indonesia.