

Pemodelan *Generalized Space Time Autoregressive* (GSTAR) pada Kasus Stunting di Sulawesi Barat

Nurhidayah¹, Ignasius Presda², Nur Hasmita³, Asrirawan*⁴
^{1,2,3,4}Universitas Sulawesi Barat;
e-mail: asrirawan@unsulbar.ac.id

Abstrak

Data menunjukkan bahwa angka stunting di Indonesia lebih tinggi dari pada toleransi maksimum yang ditetapkan oleh Organisasi Kesehatan Dunia (WHO). Sulawesi barat merupakan salah satu Provinsi di Indonesia dengan angka stunting tertinggi secara nasional. Untuk mengatasi hal tersebut, riset menjadi salah satu cara yang dapat ditempuh. Sehingga pada penelitian ini kami melakukan pemodelan kasus stunting Kabupaten/Kota di Sulawesi Barat dengan model GSTAR. Bobot yang digunakan adalah bobot seragam dan invers jarak dengan model GSTAR yang sesuai adalah GSTAR (1;2). Tingkat peramalan model GSTAR tersebut untuk semua data testing dan training dengan bobot seragam yang memiliki RMSE terkecil berada pada lokasi Mamuju Utara yakni $7,129445 \times 10^{-12}$. Sedangkan dengan bobot invers jarak, nilai RMSE terkecil berada pada lokasi Polewali Mandar yaitu $8,84714 \times 10^{-12}$.

Kata kunci – Stunting, GSTAR, Bobot seragam, Bobot Invers Jarak, Spatio-Temporal

1. PENDAHULUAN

Fenomena stunting merupakan permasalahan gizi utama yang terjadi di Indonesia. Stunting akan menjadi salah satu dari isu-isu strategis yang menjadi prioritas utama kesehatan pembangunan di Indonesia untuk lima tahun kedepan RPJM (2022-2024) dengan target pada tahun 2021 berada pada angka 14% serta Strategi Nasional Percepatan Pencegahan Stunting. Jumlah kasus stunting di Indonesia pada tahun 2019 mencapai 27,6%. Angka itu berhasil ditekan dari 3,78% pada tahun 2013. Namun, angka ini masih lebih tinggi dibandingkan toleransi maksimum stunting yang diterapkan oleh Organisasi Kesehatan Dunia yaitu kurang dari 20% (Pranita, 2021).

Sulawesi barat merupakan provinsi dengan angka stunting tertinggi secara nasional. Kabupaten Polewali Mandar, Majene, dan Mamasa memiliki prevalensi diatas angka 33%. Padahal batas ambang atas yang ditetapkan Badan Kesehatan Dunia (WHO) adalah 20%. Mamuju mempunyai angka prevalensi 30,3%. Dua daerah yang berstatus kuning dengan prevalensi 20% hingga 30%, diurut dari yang memiliki prevalensi tinggi hingga rendah mencakup Mamuju Utara dan Mamuju Tengah (Pratiwi, 2021).

Pengetahuan tentang prediksi dan klasifikasi kasus stunting sangat memungkinkan untuk membantu pengambil kebijakan (*decision maker*) untuk mengembangkan strategi pencegahan terjadinya stunting secara dini di Indonesia. Pemodelan stunting merupakan tantangan bagi ahli pemodelan di Indonesia maupun dunia. Dalam kebanyakan literatur pemodelan stunting hanya pada model prediksi berbasis lokasi (*spatio*) dan klasifikasi secara multivariat. Bustami dan Ampera (2020) menggunakan model regresi logistik berganda untuk mengklasifikasikan kasus stunting anak usia 2-5 di Aceh. Pemodelan regresi logistik untuk kasus stunting juga telah banyak digunakan oleh ahli pemodelan stunting seperti Tesfaw dan Fenta (2021) yang menggunakan model regresi logistik ordinal yang melibatkan variabel independen. Pemodelan stunting berbasis lokasi tanpa melibatkan efek waktu (*temporal*) telah dilakukan oleh Alam, Widyaningsih dan Nurrohman (2021) dengan menggunakan model *geographically weighted logistic regression* (GWLR). Model ini merupakan pengembangan dari regresi logistik yang melibatkan efek spasial lokasi. Selain itu, Djara dan Jaya (2021) juga mengembangkan model berbasis lokasi yakni model Spasial *Autoregressive* (SAR) pada kasus stunting di Nusa Tenggara Timur.

Penelitian ini akan memodelkan kasus stunting tidak hanya melibatkan efek lokasi (*spatio*) tetapi juga efek waktu (*temporal*). Model yang digunakan adalah model *Generalized Space Time Autoregressive* (GSTAR). Pemodelan stunting dengan menggunakan GSTAR merupakan hal baru dan belum pernah

dilakukan oleh peneliti lain. Model GSTAR ini juga telah banyak dikembangkan oleh ahli pemodelan indonesia seperti *Generalized Space Time Autoregressive* (GSTAR) (Ruchjana *et al.*, 2012) (Maisuri *at al.* 2021), *Space Time Autoregressive* (STAR), *Space Time Autoregressive Integrated* (STARI) (Alawiyah, Kusuma dan Ruchjana, 2019). Model GSTAR yang telah dikembangkan untuk mengatasi error yang tidak linear seperti GSTAR-ARCH dan GSTARI-ARCH (Bonar *et al.* 2017).

2. METODE PENELITIAN

2.1 Sumber Data dan Teknik Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari kementerian kesehatan provinsi Sulawesi Barat. Data ini berupa laporan persentase kasus stunting kabupaten di Sulawesi Barat yang meliputi Majene, Mamasa, Polewali Mandar, Mamuju, Mamuju Tengah, Mamuju Utara. Periode data tahunan kasus stunting yang digunakan yaitu mulai pada tahun 2015 hingga tahun 2021. Data ini dibagi menjadi data *in sample* dan data *out sampel* sebagai data *testing*. Data *in sample* digunakan mulai tahun 2015 sampai dengan tahun 2020, sedangkan data *out sample* yakni tahun 2021.

2.2 Waktu dan Lokasi Penelitian

Penelitian ini dilakukan selama 4 (empat) bulan di Perpustakaan Universitas Sulawesi Barat sebagai lokasi pengumpulan literatur, komunikasi tim (protokol kesehatan) dan analisis data.

2.3 Tahapan dan Analisis Data Penelitian

Tahapan analisis yang dilakukan dalam penelitian ini adalah sebagai berikut:

1. Mendeskripsikan data stunting di Sulawesi Barat (*data in sample* dan *out sample*).
2. Memeriksa korelasi antar lokasi.
3. Melakukan identifikasi awal terhadap data *time series*, yaitu pemeriksaan *stasioneritas* data secara *multivariate* dengan uji *Augmented Dickey Fuller* (ADF).
4. Menentukan orde p dan k untuk membangun model GSTAR.
5. Menghitung pembobot seragam dan *invers* jarak berdasarkan langkah (4).
6. Melakukan estimasi parameter dari model GSTAR berdasarkan bobot seragam dan *invers* jarak.
7. Menguji signifikansi parameter model GSTAR berdasarkan bobot seragam dan *invers* jarak.
8. Menguji kelayakan model GSTAR, model dikatakan layak jika memenuhi asumsi varians konstan (*white noise*) menggunakan uji *Ljung Box Pierce*.
9. Menentukan apakah model yang dihasilkan adalah model GSTAR yang terbaik yang dihasilkan dari bobot seragam dan *invers* jarak.
10. Memprediksi dan mengklarifikasi jumlah kasus stunting berbasis lokasi dan waktu.
11. Membuat analisis interpretasi dari hasil ramalan dan klasifikasi.
12. Membuat peta tematik persebaran kasus stunting di Sulawesi barat.
- 13.

2.4 Model Time Series

Model *time series* merupakan sebuah perilaku dari serangkaian waktu berdasarkan nilai lag yang dipilih dan mungkin satu atau lebih input. Sebuah contoh sederhana hubungan lag dengan model *time series* bisa menjadi cukup kompleks. Misalnya, model ARIMA (p,d,q) adalah model prediksi atau peramalan yang termasuk dalam kelompok model linear dan dapat diterapkan pada data yang mempunyai unsur atau pola non-musiman maupun musiman. Model ARIMA (p,d,q) dapat dilihat pada persamaan berikut (Wei, 2006).

$$\phi_p(B)(1-B)^d Z_t = \delta_0 + \theta_q(B)a_t \quad (1)$$

dimana,

$$\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p \text{ dan } \theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q$$

Model ARIMA $(P, D, Q)^s$ digunakan untuk data yang mengandung pola atau unsur musiman S dengan *differencing* atau perbedaan berorde D. Secara umum, model ARIMA yang multiplikatif atau model yang mengandung unsur musiman dan non musiman yang ditulis sebagai model ARIMA $(p,d,q) (P, D, Q)^s$ dapat dilihat sebagai berikut:

$$\phi_p(B)\Phi_p(B^s)(1-B)^d(1-B^s)^D Z_t = \delta_0 + \theta_q(B)\theta_e(B^s)a_t \quad (2)$$

Keterangan:

$$\phi_p(B) = \phi_1 B - \dots - \phi_p B^p$$

$$\Phi_p(B^s) = 1 - \Phi_1 B^s - \dots - \Phi_p B^{ps}$$

$$\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q$$

$$\theta_e(B^s) = 1 - \theta_1(B^s) - \dots - \theta_e B^{es}$$

$$(1-B)^d = \text{pembeda non-musiman berorde } d$$

$$(1-B^s)^D = \text{pembeda non-musiman berorde } D$$

$$\delta_0 = \mu(1 - \phi_1 - \dots - \phi_p)$$

$$\mu = \text{nilai rata-rata data yang sudah stasioner (dengan differencing)}$$

$$a_t = \text{Sisaan white noise dengan nilai rata-rata 0 dan varians } \sigma_a^2, a_t \sim WN(0, \sigma_a^2)$$

2.5 Multivariate Time Series

Multivariate time series adalah kumpulan data yang terdiri dari beberapa variabel yang dicatat secara berurutan dan digunakan dari waktu ke waktu serta berdasarkan urutan dari waktu kejadian dengan menggunakan interval waktu tetap (Wei, 2006). Interval tersebut adalah periode dalam satuan tahun, bulan, minggu, hari, jam, menit, detik atau menggunakan periode waktu lainnya. Kestasioneran data pada model multivariat *time series* dapat dilihat dari plot atau gambar MACF, MPACF dan Box-Cox digunakan untuk melihat kestasioneran yang sifatnya subjektif. Sehingga, salah satu uji kestasioneran yang dapat digunakan adalah uji *Augmented Dicky-Fuller* (ADF) baik untuk memeriksa kestasioneran terhadap varians maupun rata-rata.

2.6 Model Generalized Space Time Autoregressive (GSTAR)

Model *Generalized Space Time Autoregressive* (GSTAR) merupakan salah satu perluasan dari model *Space Time Autoregressive* (STAR). Model ini cenderung lebih fleksibel dalam menentukan orde *autoregressive* (p), karena asumsi parameter *autoregressive* pada model ini berbeda setiap lokasi, sehingga cocok diterapkan pada lokasi yang memiliki karakteristik heterogen (Maisuri, Asrirawan dan Ansar, 2021). Keterkaitan *spasial* atau lokasi dinyatakan oleh matriks pembobot lokasi. Model GSTAR merupakan model dari sejumlah pengamatan (t) yang terdapat pada tiap N lokasi dalam suatu ruang (i=1,2,...,N) terhadap t periode waktu. Efek waktu dirumuskan sebagai model deret waktu dan efek spasial dirumuskan sebagai matriks pembobot lokasi.

Jika diketahui sebuah deret $\{Z(t): t = 0, \pm 1, \pm 2, \dots, T\}$ merupakan sebuah deret waktu *multivariat* dari N komponen, maka model GSTAR dari orde *autoregressive* p dengan orde spasial $\lambda_1, \lambda_2, \dots, \lambda_p$ GSTAR $(p; \lambda_1, \lambda_2, \dots, \lambda_p)$ dalam notasi matriks dapat ditulis sebagai berikut (Wustaq dan Suhartono, 2010):

$$Z(t) = \sum_{s=1}^p \left(\Phi_{s0} + \sum_{k=1}^{\lambda_s} \Phi_{sk} W^{(k)} \right) Z(t-s) + e(t) \quad (3)$$

dimana:

p : Orde waktu *autoregressive*

λ_s : Orde waktu *autoregressive* ke-s dimana $s = 1, 2, 3, \dots, p$

Φ_{s0} : Parameter *autoregressive* pada lag waktu s dan lag spasial 0
dimana $s = 1, 2, 3, \dots, p$

Φ_{sk} : Parameter spasial *regresi* $k = 1, 2, 3, \dots, \lambda_s$

$W^{(k)}$: Matriks $N \times N$ dengan nilai pembobot

$e(t)$: Ukuran vektor *error white noise*

dengan $\Phi_{s_0} = \text{diag}(\phi_{s_0}^1, \dots, \phi_{s_0}^N)$, $\Phi_{s_k} = \text{diag}(\phi_{s_k}^1, \dots, \phi_{s_k}^N)e(t)$ i.i.d. (Identik, independen dan berdistribusi) dan $W^{(k)}$ adalah matriks $N \times N$ dengan nilai pembobot yang dipilih agar memenuhi syarat $W^{(k)} = 0$ dan $\sum_{j \neq i} W_{ij}^{(k)} = 1$. Sebagai contoh persamaan model GSTAR untuk orde waktu dan orde spasial satu dengan menggunakan tiga lokasi berbeda seperti persamaan (4) berikut,

$$Z(t) = \Phi_{10}Z(t-1) + \Phi_{11}W^1Z(t-1) + e(t) \quad (4)$$

dan dalam bentuk matriks, persamaan (5) dapat ditulis sebagai berikut:

$$\begin{pmatrix} Z_1(t) \\ Z_2(t) \\ Z_3(t) \end{pmatrix} = \begin{pmatrix} \phi_{10}^1 & 0 & 0 \\ 0 & \phi_{10}^2 & 0 \\ 0 & 0 & \phi_{10}^3 \end{pmatrix} \begin{pmatrix} Z_1(t-1) \\ Z_2(t-1) \\ Z_3(t-1) \end{pmatrix} + \begin{pmatrix} \phi_{11}^1 & 0 & 0 \\ 0 & \phi_{11}^2 & 0 \\ 0 & 0 & \phi_{11}^3 \end{pmatrix} \begin{pmatrix} 0 & w_{12} & w_{13} \\ w_{21} & 0 & w_{23} \\ w_{31} & w_{32} & 0 \end{pmatrix} \begin{pmatrix} Z_1(t-1) \\ Z_2(t-1) \\ Z_3(t-1) \end{pmatrix} + \begin{pmatrix} e_1(t) \\ e_2(t) \\ e_3(t) \end{pmatrix} \quad (5)$$

Begitu pula dengan GSTAR (p_1) dengan persamaan (6) sebagai berikut (Ruchjana, Borovkova dan Lopuhaa, 2012):

$$Z(t) = \sum_{s=1}^p (\Phi_{s_0} + \Phi_{s_1}W)Z(t-s) + e(t) \quad (6)$$

sebagai contoh, model GSTAR (1_1) dengan persamaan (7) berikut:

$$Z(t) = (\Phi_0 + \Phi_1W)Z(t-s) + e(t) \quad (7)$$

2.7 Pemilihan Bobot Lokasi Model GSTAR

Salah satu permasalahan utama dalam pembentukan model GSTAR adalah dalam menentukan bobot lokasi yang sesuai untuk diterapkan pada data *time series* yang dianalisis. Asrirawan dan Sumantri (2018) menyebutkan terdapat beberapa macam cara pembobotan dalam model GSTAR. Beberapa metode yang dapat digunakan untuk menentukan bobot antara lain adalah bobot seragam dan *invers* jarak.

Bobot seragam merupakan salah satu bobot yang biasanya digunakan pada data yang memiliki lokasi yang sama. Berikut ini adalah perhitungan nilai dari bobot seragam (*uniform*):

$$W_{ij} = \frac{1}{S_i} \quad (8)$$

dengan S_i adalah banyaknya lokasi yang berdekatan dengan lokasi ke- i . Sebagai contoh, matriks pembobotan untuk tiga lokasi adalah sebagai berikut:

$$W_{ij} = \begin{pmatrix} 0 & 1/2 & 1/2 \\ 1/2 & 0 & 1/2 \\ 1/2 & 1/2 & 0 \end{pmatrix}$$

Pembobotan dengan metode *invers* jarak dilakukan dengan jarak sebenarnya antara lokasi di lapangan. Perhitungan bobot dengan metode *invers* jarak diperoleh dari normalisasi hasil *invers* jarak sebenarnya. Penentuan nilai bobot dalam bobot *inver* jarak adalah $W_{ij} = 0$ atau 1 dengan ketentuan sebagai berikut:

$$W_{ij} = \frac{1}{\sum_{j \neq i} \frac{1}{d_{ij}}}, \text{ untuk } j \neq i \text{ dan } W_{ij} = 0 \text{ untuk } i = j$$

dengan d_{ij} dapat dirumuskan menjadi persamaan garis linear pada persamaan (9) berikut:

$$d_{ij} = \sqrt{(u_i - u_j)^2 + (v_i - v_j)^2} \quad (9)$$

dengan d_{ij} merupakan jarak lokasi ke- i dan ke- j , $(u_i - u_j)$ merupakan *latitude* dan $(v_i - v_j)$ adalah *longitude*. Perhitungan bobot jarak dari lokasi A ke lokasi B dengan metode *invers* jarak sebagai berikut:

$$W_{AB} = \frac{\frac{1}{d_{AB}}}{\frac{1}{d_{AB}} + \frac{1}{d_{AC}}} = \frac{\frac{1}{s}}{\frac{1}{s} + 1} = \frac{1}{4}; \quad W_{AB} = \frac{\frac{1}{d_{AC}}}{\frac{1}{d_{AC}} + \frac{1}{d_{AB}}} = \frac{\frac{1}{s}}{\frac{1}{s} + 1} = \frac{3s}{4};$$

2.8 Estimasi Parameter Model GSTAR

Menurut Maisuri, Asrirawan dan Ansar (2021) model *Generalized Space Time Autoregressive* (GSTAR) dapat dinyatakan sebagai suatu model linear dan estimasi dari parameter *autoregressive* model GSTAR dapat dilakukan dengan menggunakan metode kuadrat terkecil yaitu dengan meminimumkan jumlah kuadrat sisaan. Model GSTAR merupakan pemodelan dari sejumlah pengamatan (t) yang terdapat pada tiap N lokasi dalam suatu ruang ($i = 1, 2, \dots, N$) terhadap periode waktu.

$$Z_{i(N \times 1)}(t) = \sum_{k=1}^p \sum_{l=0}^{\lambda k} \Phi_{kl(N \times N)} W_{N \times N}^1 Z_{N \times N}(t - k) + e_{(N \times 1)}(t) \quad (10)$$

Jika diberikan pengamatan $Z_i(t), t = 0, 1, \dots, t$, untuk lokasi $i = 1, 2, \dots, N$ dengan $V_i(t) = \sum_{j=1}^N W_{ij} Z_j(t)$ untuk $i \neq j$, maka model untuk lokasi ke- i dalam model linear dapat dinyatakan dengan persamaan (11):

$$Z_i = Z_i^* \Phi + e_i \quad (11)$$

dalam hal ini

$$Z_i = \begin{pmatrix} Z_i(1) \\ Z_i(2) \\ Z_i(3) \end{pmatrix}, Z_i^* = \begin{pmatrix} Z_i(0) & V_i(0) \\ Z_i(1) & V_i(1) \\ \vdots & \vdots \\ Z_N(t-k) & V_N(t-k) \end{pmatrix}, \Phi = \begin{pmatrix} \Phi_{kl}^i \\ \Phi_{kl}^i \\ \Phi_{kl}^N \end{pmatrix}, e_t = \begin{pmatrix} e_1(1) \\ e_i(2) \\ e_N(t) \end{pmatrix}$$

Estimasi parameter model dengan metode kuadrat terkecil digunakan dengan meminimumkan jumlah kuadrat sisaannya, yaitu: $\hat{\phi} = (Z^* Z^*)^{-1} (Z^* Z)$

$$Z(t) = \begin{pmatrix} Z_1(t) \\ Z_2(t) \\ Z_3(t) \end{pmatrix}, \Phi_0 = \begin{pmatrix} \phi_{10} & 0 & 0 \\ 0 & \phi_{20} & 0 \\ 0 & 0 & \phi_{30} \end{pmatrix}, \Phi_1 = \begin{pmatrix} \phi_{11} & 0 & 0 \\ 0 & \phi_{21} & 0 \\ 0 & 0 & \phi_{31} \end{pmatrix}$$

$$W = \begin{pmatrix} 0 & w_{12} & w_{13} \\ w_{21} & 0 & w_{23} \\ w_{31} & w_{32} & 0 \end{pmatrix}, Z(t-1) = \begin{pmatrix} Z_1(t-1) \\ Z_2(t-1) \\ Z_3(t-1) \end{pmatrix}, \text{ dan } e_t = \begin{pmatrix} e_1(t) \\ e_2(t) \\ e_3(t) \end{pmatrix}$$

2.9 Peramalan Model GSTAR

Perhitungan ramalan untuk satu tahap ke depan membutuhkan proses yang dapat diilustrasikan. Misalkan data deret waktu univariat $\hat{Z}_n(l)$ adalah hasil prediksi atau ramalan satu tahap ke depan dari deret waktu Z_{n+1} dan mengikuti model ARIMA (1,1) dapat dituliskan seperti pada persamaan (12) (Wei, 2006)

$$(1 - \phi_1 B)(Z_t - \mu) = (1 - \theta_1 B)a_1 \quad (12)$$

Untuk $t = n + 1$, diperoleh nilai Z_{n+1} seperti pada persamaan (13)

$$Z_{n+1} = \mu + \phi_1(Z_{n+l-1} - \mu) + a_{n+l} - \theta_1 a_{n+l} \quad (13)$$

karena,

$$\hat{Z}_n(l) = \mu + \phi_1(Z_n - \mu) - \theta_1 a_n$$

dan persamaan untuk hasil peramalan pada satu tahap kedepan menjadi,

$$\hat{Z}_n(l) = \mu + \phi_1(\hat{Z}_n(l-1) - \mu)$$

$$\mu + \phi_1^l [Z_n - \mu] - \phi_1^{l-1} a_n, 1 \geq 2$$

Sehingga model peramalan GSTAR seperti pada persamaan 12 berikut:

$$\hat{Z}(t) = \sum_{s=1}^p [\phi_{s0} Z(t-s)] + \sum_{k=1}^{\lambda s} [\phi_{sk} W^{(k)} Z(t-s)] \quad (14)$$

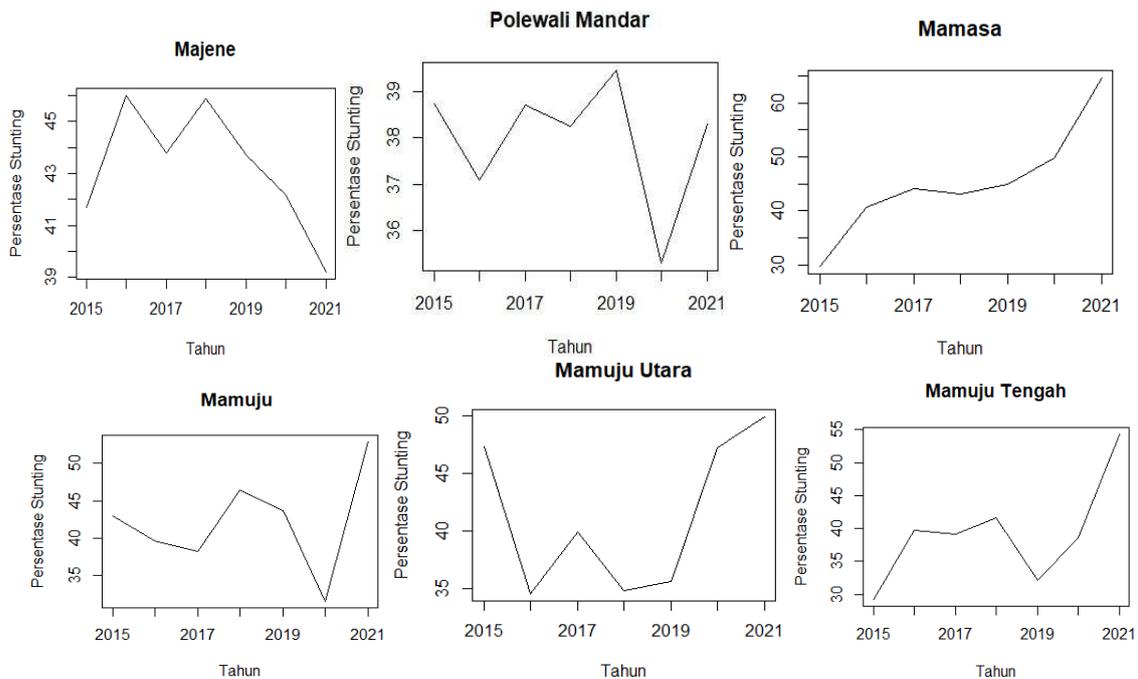
3. HASIL DAN PEMBAHASAN

3.1 Analisis Deskriptif Kasus Stunting

Analisis karakteristik stunting untuk masing-masing Kabupaten/Kota disajikan dalam bentuk statistika deskriptif dan analisis plot *time series* dari tahun 2015-2021. Berdasarkan hasil analisis deskriptif dengan persentase stunting tertinggi adalah Mamuju Tengah dengan persentase kasus terendah yakni 39,25 dan tertinggi yakni 54,31 persen.

3.2 Penentuan Model GSTAR Kasus Stunting

Data yang digunakan pada penelitian ini adalah data persentase kasus stunting di Kabupaten/Kota Sulawesi Barat tahun 2015-2021. Data dibagi menjadi dua bagian untuk melakukan pemodelan kasus stunting, yaitu data tahun 2015-2020 sebagai data *in-sample* sedangkan data tahun 2021 dijadikan data *out-sample*. Untuk melakukan pemodelan GSTAR, langkah awal yang dilakukan adalah mengidentifikasi kestasioneran data. Digunakan *unit root test* dan plot grafik untuk melihat stasioneritas data. Berdasarkan hasil pengujian ADF hanya terdapat satu data yang stasioner. Jika dilihat dari grafik atau plot deret diperoleh bahwa hanya terdapat satu data yang stasioner.



Gambar 1. Plot persentase stunting di 6 Kabupaten/Kota Sulawesi Barat

Berdasarkan Gambar 1. dapat diketahui bahwa pola pergerakan data persentase stunting di Sulawesi Barat cenderung sama yakni mengalami penambahan dan pengurangan yang tidak beraturan. Beberapa data persentase stunting di Sulawesi Barat memiliki hubungan waktu yang sama.

Berdasarkan analisis korelasi, diperoleh bahwa dari ke-6 Kabupaten yang diamati, terdapat 2 Kabupaten yang mempunyai korelasi yang signifikan yakni Majene dengan Mamuju Utara dan Mamasa dengan Mamuju Tengah. Koefisien korelasi yang cukup besar terdapat pada Majene dan Polewali Mandar dengan nilai koefisien sebesar 0,978.

Variabel yang digunakan adalah data persentase stunting Kabupaten/Kota di Sulawesi Barat, sehingga variabel penelitian ini yaitu:

- $Z_1(t)$ = Persentase stunting Majene
- $Z_2(t)$ = Persentase stunting Polewali Mandar
- $Z_3(t)$ = Persentase stunting Mamasa
- $Z_4(t)$ = Persentase stunting Mamuju
- $Z_5(t)$ = Persentase stunting Mamuju Utara
- $Z_6(t)$ = Persentase stunting Mamuju Tengah

Untuk melihat *stasioner* data dalam *mean* dan *varians* maka dilakukan *unit root test* dan memperhatikan plot grafik.

Tabel 1. Uji ADF untuk kestasioneran data

Peubah	<i>Dickey-Fuller</i>	<i>P-Value</i>	<i>Alternative Hypothesis</i>
Majene (Z_1)	0.41	0.99	<i>Non stasioner</i>
Polewali Mandar (Z_2)	-0.55	0.97	<i>Non stasioner</i>
Mamasa (Z_3)	0.01	0.99	<i>Non stasioner</i>
Mamuju (Z_4)	-14.15	0.01	<i>Stasioner</i>
Mamuju Utara (Z_5)	-0.16	0.98	<i>Non stasioner</i>
Mamuju Tengah (Z_6)	-0.99	0.92	<i>Non stasioner</i>

Berdasarkan tabel 1, hanya terdapat satu variabel yang *stasioner*, meskipun begitu tidak dilakukan *differencing* karena keterbatasan jumlah data yang dimiliki. Oleh karena itu, dalam penelitian ini data yang digunakan adalah data yang tidak *stasioner*.

Menurut output dari “*packages* GSTAR” menggunakan aplikasi R didapatkan model GSTAR pada lag 1 dengan nilai AIC sebagai berikut:

Tabel 2. Nilai AIC

Orde	AIC
AR(1)	183
AR(2)	-1023

Berdasarkan tabel 2. diperoleh bahwa model GSTAR yang terbentuk adalah model GSTAR dengan orde 2 atau GSTAR (1;2).

3.3 Menghitung Bobot Lokasi Model GSTAR

Bobot lokasi yang digunakan pada penelitian ini adalah bobot seragam dan bobot *invers* jarak. Bobot seragam mengasumsikan bahwa penambahan persentase kasus stunting di suatu Kabupaten/Kota memiliki pengaruh yang sama terhadap Kabupaten-kabupaten lainnya, dengan kata lain bobot lokasi seragam memberikan nilai bobot yang sama untuk setiap lokasi. Matriks bobot seragam yang digunakan dalam analisis ini adalah sebagai berikut:

$$w_{ij} = w_{ij} = \begin{pmatrix} 0 & 1/5 & 1/5 & 1/5 & 1/5 & 1/5 \\ 1/5 & 0 & 1/5 & 1/5 & 1/5 & 1/5 \\ 1/5 & 1/5 & 0 & 1/5 & 1/5 & 1/5 \\ 1/5 & 1/5 & 1/5 & 0 & 1/5 & 1/5 \\ 1/5 & 1/5 & 1/5 & 1/5 & 0 & 1/5 \\ 1/5 & 1/5 & 1/5 & 1/5 & 1/5 & 0 \end{pmatrix}$$

Penduga parameter model *Autoregressive* menggunakan metode *Ordinary Least Square* (OLS). Dugaan

parameter untuk *autoregressive* sama, yaitu model GSTAR (1;2) dapat ditulis sebagai berikut:

$$Z_j(t) = \phi_{10}Z_{(t-1)} + \phi_{11}W^1Z_{(t-1)} + \phi_{20}Z_{(t-2)} + \phi_{21}W^1Z_{(t-2)} + e_{(t)}$$

Berdasarkan hasil estimasi parameter model GSTAR (1;2) menggunakan bobot seragam, terbentuk model GSTAR(1;2) sebagai berikut:

$$\begin{aligned} \hat{Z}_1(t) &= 0,7889Z_1(t-1) + 0,1889(Z_2(t-1) + Z_3(t-1) + Z_4(t-1) + Z_5(t-1) + Z_6(t-1)) \\ &\quad + 0,4180Z_1(t-2) - 0,2548(Z_2(t-2) + Z_3(t-2) + Z_4(t-2) + Z_5(t-2) \\ &\quad + Z_6(t-2)) \\ \hat{Z}_2(t) &= 0,3097Z_1(t-1) + 0,0463(Z_2(t-1) + Z_3(t-1) + Z_4(t-1) + Z_5(t-1) + Z_6(t-1)) \\ &\quad + 1,338Z_1(t-2) - 1,855(Z_2(t-2) + Z_3(t-2) + Z_4(t-2) + Z_5(t-2) \\ &\quad + Z_6(t-2)) \\ \hat{Z}_3(t) &= -0,8027Z_1(t-1) + 0,0732(Z_2(t-1) + Z_3(t-1) + Z_4(t-1) + Z_5(t-1) + Z_6(t-1)) \\ &\quad - 1,092Z_1(t-2) - 1,444(Z_2(t-2) + Z_3(t-2) + Z_4(t-2) + Z_5(t-2) \\ &\quad + Z_6(t-2)) \\ \hat{Z}_4(t) &= -0,4191Z_1(t-1) - 0,2254(Z_2(t-1) + Z_3(t-1) + Z_4(t-1) + Z_5(t-1) + Z_6(t-1)) \\ &\quad + 2,548Z_1(t-2) + 1,1716(Z_2(t-2) + Z_3(t-2) + Z_4(t-2) + Z_5(t-2) \\ &\quad + Z_6(t-2)) \\ \hat{Z}_5(t) &= -0,3639Z_1(t-1) + 0,3214(Z_2(t-1) + Z_3(t-1) + Z_4(t-1) + Z_5(t-1) + Z_6(t-1)) \\ &\quad - 1,092Z_1(t-2) + 0,8694(Z_2(t-2) + Z_3(t-2) + Z_4(t-2) + Z_5(t-2) \\ &\quad + Z_6(t-2)) \\ \hat{Z}_6(t) &= -3,421Z_1(t-1) + 0,0732(Z_2(t-1) + Z_3(t-1) + Z_4(t-1) + Z_5(t-1) + Z_6(t-1)) \\ &\quad - 1,092Z_1(t-2) - 0,7356(Z_2(t-2) + Z_3(t-2) + Z_4(t-2) + Z_5(t-2) \\ &\quad + Z_6(t-2)) \end{aligned}$$

Bobot invers jarak mengasumsikan bahwa persentase kasus stunting dipengaruhi oleh jauh dekatnya jarak yang dimiliki dengan lokasi lainnya.

Berdasarkan *latitude* dan *longitude* Kabupaten di Sulawesi Barat maka hasil perhitungan bobot *invers* jarak yang dapat dibentuk matriks bobot *invers* jarak sebagai berikut:

$$W_{ij} = \begin{pmatrix} 0 & 0,24208 & 0,31637 & 0,21197 & 0,08916 & 0,14043 \\ 0,27257 & 0 & 0,34793 & 0,17384 & 0,08527 & 0,12038 \\ 0,26476 & 0,25860 & 0 & 0,26269 & 0,08391 & 0,13648 \\ 0,18147 & 0,13217 & 0,26309 & 0 & 0,12578 & 0,29746 \\ 0,13582 & 0,11536 & 0,15274 & 0,22380 & 0 & 0,37225 \\ 0,14788 & 0,11258 & 0,17174 & 0,36590 & 0,25734 & 0 \end{pmatrix}$$

Berdasarkan hasil estimasi parameter model GSTAR (1;2) menggunakan bobot *invers* jarak, dapat dibentuk persamaan model GSTAR (1;2) sebagai berikut:

$$\begin{aligned} \hat{Z}_1(t) &= 0,7109Z_1(t-1) + 0,2210Z_2(t-1) + 0,2888Z_3(t-1) + 0,1934Z_4(t-1) \\ &\quad + 0,0813Z_5(t-1) + 0,1281Z_6(t-1) + 0,5277Z_1(t-2) - 0,3084(Z_2(t-2) \\ &\quad - 0,4029Z_3(t-2) - 0,2699Z_4(t-2) - 0,1135Z_5(t-2) - 0,1788Z_6(t-2)) \\ \hat{Z}_2(t) &= 0,2419Z_1(t-1) + 0,0184Z_2(t-1) + 0,0235Z_3(t-1) + 0,0117Z_4(t-1) \\ &\quad + 0,0057Z_5(t-1) + 0,0081Z_6(t-1) + 1,570Z_1(t-2) - 0,2626(Z_2(t-2) \\ &\quad - 0,3225Z_3(t-2) - 0,1611Z_4(t-2) - 0,0789Z_5(t-2) - 0,111Z_6(t-2)) \end{aligned}$$

$$\begin{aligned}\hat{Z}_3(t) &= -0,9616Z_1(t-1) + 0,1046Z_2(t-1) + 0,1021Z_3(t-1) + 0,10137Z_4(t-1) \\ &\quad + 0,0331Z_5(t-1) + 0,0539Z_6(t-1) - 1,016Z_1(t-2) + 0,7107(Z_2(t-2) \\ &\quad + 0,6943Z_3(t-2) + 0,7050Z_4(t-2) + 0,2252Z_5(t-2) + 0,3662Z_6(t-2)) \\ \hat{Z}_4(t) &= -0,4365Z_1(t-1) + 0,2016Z_2(t-1) + 0,1468Z_3(t-1) + 0,2922Z_4(t-1) \\ &\quad + 0,1396Z_5(t-1) + 0,3304Z_6(t-1) + 2,330Z_1(t-2) + 0,0182(Z_2(t-2) \\ &\quad + 0,0132Z_3(t-2) + 0,0264Z_4(t-2) + 0,0126Z_5(t-2) + 0,0299Z_6(t-2)) \\ \hat{Z}_5(t) &= -0,3826Z_1(t-1) + 0,2026Z_2(t-1) + 0,1721Z_3(t-1) + 0,2278Z_4(t-1) \\ &\quad + 0,3339Z_5(t-1) + 0,5553Z_6(t-1) - 4,330Z_1(t-2) + 0,5827(Z_2(t-2) \\ &\quad + 0,495Z_3(t-2) + 0,6552Z_4(t-2) + 0,9603Z_5(t-2) + 1,5973Z_6(t-2)) \\ \hat{Z}_6(t) &= -3,961Z_1(t-1) - 0,7251Z_2(t-1) - 0,5523Z_3(t-1) - 0,8425Z_4(t-1) \\ &\quad - 1,7951Z_5(t-1) - 1,2655Z_6(t-1) + 0,2447Z_1(t-2) - 0,023(Z_2(t-2) \\ &\quad - 0,01752Z_3(t-2) + 0,0267Z_4(t-2) - 0,0569Z_5(t-2) - 0,04004Z_6(t-2))\end{aligned}$$

Persamaan model GSTAR untuk kasus persentase stunting di 6 Kabupaten/Kota Sulawesi Barat menunjukkan bahwa persentase stunting masing-masing wilayah dipengaruhi oleh persentase stunting pada lokasi yang sama 1 tahun sebelumnya dan 1 tahun sebelumnya pada tiap-tiap lokasi lainnya.

3.4 Uji Asumsi Residual

Dengan menggunakan uji *Ljung Box Pearce* diperoleh kesimpulan bahwa sisaan sudah *white noise*, dikarenakan tidak terdapat *autokorelasi* pada model, hal ini dapat dilihat sebagai berikut:

Tabel 3. Uji *Ljung Boc Pearce*

Bobot	Statistik LB	p-value	Kesimpulan
Seragam	0,51166	0,4744	<i>Non autokorelasi</i>
Invers Jarak	2,0676	0,1505	<i>Non autokorelasi</i>

Tabel 3. menunjukkan bahwa model diatas telah memenuhi uji asumsi *residual white noise*, hal ini terlihat bahwa nilai *p-value* untuk lag-lag tersebut berada diatas $\alpha = 0,05$ dapat disimpulkan bahwa asumsi *residual* terpenuhi.

3.5 Pemilihan Model Terbaik

Perhitung nilai ketepatan peramalannya dengan menggunakan *Root Mean Square Error* (RMSE), berikut untuk model GSTAR (1;2):

Tabel 4. Nilai MSE dan RMSE untuk bobot seragam

Lokasi	MSE	RMSE
Majene	$2,619536 \times 10^{-22}$	$1,618498 \times 10^{-11}$
Polewali Mandar	$4,473638 \times 10^{-22}$	$2,115098 \times 10^{-11}$
Mamasa	$1,873829 \times 10^{-24}$	$1,368879 \times 10^{-12}$
Mamuju	$3,309997 \times 10^{-24}$	$1,81934 \times 10^{-12}$
Mamuju Utara	$5,082898 \times 10^{-23}$	$7,129445 \times 10^{-12}$
Mamuju Tengah	$1,015612 \times 10^{-20}$	$1,007776 \times 10^{-10}$

Tabel 5. Nilai MSE dan RMSE untuk bobot *invers* jarak

Lokasi	MSE	RMSE
Majene	7.279566×10^{-23}	8.532092×10^{-12}
Polewali Mandar	7.827189×10^{-23}	$8,84714 \times 10^{-12}$
Mamasa	3.575187×10^{-23}	$5,979287 \times 10^{-12}$
Mamuju	9.105276×10^{-24}	$3,017495 \times 10^{-12}$
Mamuju Utara	6.287157×10^{-23}	$7,929159 \times 10^{-12}$
Mamuju Tengah	1.296744×10^{-23}	$3,601033 \times 10^{-12}$

Berdasarkan tabel 4. dan tabel 5. diperoleh bahwa tingkat peramalan model GSTAR dengan bobot *invers* jarak yang memiliki RMSE terkecil berada pada lokasi Polewali Mandar yaitu $8,84714 \times 10^{-12}$. Nilai RMSE terkecil pada bobot seragam berada pada lokasi Mamuju Utara yakni $7,129445 \times 10^{-12}$.

4. KESIMPULAN

Model GSTAR (1;2) merupakan model yang tepat untuk melihat keterkaitan jumlah penyebaran kasus stunting di Sulawesi Barat. Semua Kabupaten yang diobservasi memiliki keterkaitan *spasio temporal*. Tingkat ramalan model GSTAR tersebut untuk semua data *in-sample* dan *out-sample* dengan seragam yang memiliki RMSE terkecil berada pada model GSTAR lokasi Mamuju Utara yakni $7,129445 \times 10^{-12}$, dan RMSE terbesar berada pada model GSTAR lokasi Mamuju Tengah yakni $1,007776 \times 10^{-10}$. Sedangkan dengan bobot *invers* jarak yang memiliki RMSE terkecil berada pada model GSTAR lokasi Polewali Mandar yakni $8,84714 \times 10^{-12}$, dan RMSE terbesar berada pada model GSTAR lokasi mamuju yakni $3,017495 \times 10^{-12}$.

Tabel 6. Hasil *forecasting* persentase stunting Kabupaten/Kota di Sulawesi Barat dengan bobot seragam

Waktu	Majene	Polewali Mandar	Mamasa	Mamuju	Mamuju Utara	Mamuju Tengah
2022	42,17	35,32	49,84	31,57	47,23	38,57
2023	46,00	37,10	40,60	39,60	34,60	39,80
2024	43,80	38,70	44,10	38,20	39,90	39,10
2025	43,70	39,45	45,02	43,68	35,62	32,14

Tabel 7. Hasil *forecasting* persentase stunting Kabupaten/Kota di Sulawesi Barat dengan bobot *invers* jarak

Waktu	Majene	Polewali Mandar	Mamasa	Mamuju	Mamuju Utara	Mamuju Tengah
2022	42,17	35,32	49,84	31,57	47,23	38,57
2023	46,00	37,10	40,60	39,60	34,60	39,80
2024	43,80	38,70	44,10	38,20	39,90	39,10
2025	43,70	39,45	45,02	43,68	35,62	32,14

DAFTAR PUSTAKA

Alam, F. K., Widyaningsih, Y., & Nurrohmah, S. (2021). Geographically weighted logistic regression modeling on stunting cases in Indonesia. In *Journal of Physics: Conference Series* (Vol. 1722, No. 1, p. 012085). IOP Publishing.

Alawiyah, M., Kusuma, D., & Ruchjana, B. (2020). MODEL SPACE TIME AUTOREGRESSIVE

INTEGRATED (STARI) UNTUK DATA DEBIT AIR SUNGAI CITARUM DI PROVINSI JAWA BARAT. *BAREKENG: Jurnal Ilmu Matematika Dan Terapan*, 14(1), 147-158. <https://doi.org/10.30598/barekengvol14iss1pp147-158>

- Bonar, H., Ruchjana, B. N., & Darmawan, G. (2017, March). Development of generalized space time autoregressive integrated with ARCH error (GSTARI–ARCH) model based on consumer price index phenomenon at several cities in North Sumatera province. In *AIP Conference Proceedings* (Vol. 1827, No. 1, p. 020009). AIP Publishing LLC.
- Bustami, B., & Ampera, M. (2020). The Identification of Modeling Causes of Stunting Children Aged 2–5 Years in Aceh Province, Indonesia (Data Analysis of Nutritional Status Monitoring 2015). *Open Access Macedonian Journal of Medical Sciences*, 8(E), 657–663. <https://doi.org/10.3889/oamjms.2020.4659>
- Djara, V. A. D., & Jaya, I. G. N. M. (2021). The spatial econometrics of stunting toddlers in Nusa Tenggara Timur Province 2019. *Commun. Math. Biol. Neurosci.*, 2021, Article-ID.
- Maisuri, Asrirawan and Ansar, A. (2021). Forecasting the Number of Confirmed COVID 19 in Indonesia by Using GSTAR Spatio-Temporal Model. *Nasional Seminar Proceeding*. 2021.
- Pranita, E. (2021). *Kasus Stunting Terbanyak Indonesia Tempati Urutan Keempat Dunia*. URL: <https://www.kompas.com/sains/read/2021/05/19/090300723/kasus-stunting-terbanyak-indonesia-tempati-urutan-keempat-dunia?page=all>. Diakses pada tanggal 12 Maret 2022.
- Pratiwi, H. (2021). *Sulawesi Barat Memiliki Jumlah Stunting Tertinggi*. URL: <https://rri.co.id/humaniora/info-publik/1392752/sulawesi-barat-memiliki-jumlah-stunting-tertinggi>. Diakses pada tanggal 12 Maret 2022.
- Ruchjana, B. N., Borovkova, S. A., & Lopuhaa, H. P. (2012, May). 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.
- Salbiah, N., A. (2021). *10 Provinsi Jadi yang Tertinggi Penyumbang Angka Stunting*. URL: <https://www.jawapos.com/nasional/26/10/2021/10-provinsi-jadi-yang-tertinggi-penyumbang-angkastunting/> Diakses pada tanggal 12 Maret 2022.
- Tesfaw, L. M., & Fenta, H. M. (2021). Multivariate logistic regression analysis on the association between anthropometric indicators of under-five children in Nigeria: NDHS 2018. *BMC pediatrics*, 21(1), 1-13.
- Wei, W. S. (2006). Time analysis univariate and multivariate methods. *America: Addison Wesley Publishing Company Inc.*