

PERAMALAN CURAH HUJAN DI PROVINSI SUMATERA BARAT MENGGUNAKAN VECTOR AUTOREGRESSIVE - GENERALIZED SPACE TIME AUTOREGRESSIVE (VAR-GSTAR)

Mesyi Mardhatillah¹, Indah Manfaati Nur², Prizka Rismawati Arum³

¹²³Program Studi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam

Universitas Muhammadiyah Semarang

Email : mesyimardatillah@gmail.com

ABSTRAK

Curah hujan adalah banyaknya air hujan yang jatuh pada permukaan bumi suatu daerah dalam kurun waktu tertentu. Curah hujan di Indonesia sangat tinggi karena letak Indonesia secara geografis berada diantara dua samudera yaitu Samudera Pasifik dan Samudera Hindia. Sumatera Barat memiliki curah hujan yang sangat tinggi. Oleh karena itu, untuk memperoleh prediksi curah hujan di 4 Stasiun Provinsi Sumatera Barat dibutuhkan suatu model persamaan. Salah satu model *time series* multivariat yang menghubungkan keterkaitan anatar waktu dan lokasi, dengan data berpola *seasonal* adalah *Vector Autoregressive-Generalized Space Time Autoregressive* (VAR-GSTAR). Model ini terdiri dari 2 orde yaitu orde waktu yang diperoleh dari model VAR dan orde spasial yang diperoleh dari model GSTAR. Keterkaitan antar ruang pada model ini ditunjukkan dengan pembobotan lokasi. Berdasarkan hasil analisis model terbaik VAR-GSTAR yaitu model VAR-GSTAR(2,1) dengan pembobot lokasi invers jarak. Hasil ramalannya dengan melihat tingkat akurasi *Mean Absolute Percentage Error* (MAPE) pada tiap-tiap lokasi. Stasiun Klimatologi GAW Bukit Kototabang Palupuh sebesar 17,96% memiliki tingkat peramalan yang baik, Stasiun Klimatologi Sicincin sebesar 10,35% memiliki tingkat peramalan yang baik, Stasiun Meteorologi Minangkabau Pariaman sebesar 14,60% memiliki tingkat peramalan yang baik dan nilai MAPE Stasiun Teluk Bayur Padang sebesar 9,71% dapat diinterpretasikan bahwa tingkat akurasi peramalannya sangat akurat.

Kata Kunci : Curah Hujan, *Vector Autoregressive, Generalized Space Time Autoregressive.*

ABSTRACT

Rainfall is the amount of rain that falls on the earth's surface in a certain period of time. Rainfall in Indonesia is very high because Indonesia is geographically located between two oceans, namely the Pacific Ocean and the Indian Ocean. West Sumatra has very high rainfall. Therefore, to obtain predictions of rainfall at 4 stations in West Sumatra Province, an equation model is needed. One of the multivariate time series models that connects the relationship between time and location, with seasonal patterned data is the Vector Autoregressive-Generalized Space Time Autoregressive (VAR-GSTAR). This model consists of 2 orders, namely the time order obtained from the VAR model and the spatial order obtained from the GSTAR model. The relationship between spaces in this model is indicated by location weighting. Based on the results of the analysis, the best model of VAR-GSTAR is the VAR-GSTAR(2,1) model with the inverse distance weighting location. The prediction results are based on the accuracy of the Mean Absolute Percentage Error (MAPE) at each location. GAW Bukit Kototabang Palupuh Climatology Station of 17.96% has a good forecasting rate, Sicincin Climatology Station of 10.35% has a good forecasting rate, Minangkabau Pariaman Meteorological Station of 14.60% has a good forecasting rate and the MAPE value of Teluk Station Bayur Padang of 9.71% can be interpreted that the level of forecasting accuracy is very accurate.

Keywords : *Rainfall, Vector Autoregressive, Generalized Space Time Autoregressive.*

PENDAHULUAN

Indonesia merupakan negara yang berada di garis khatulistiwa, garis yang membagi dua bagian bumi secara vertikal. Hal ini menjadikan Indonesia sebagai daerah pertemuan sirkulasi utara-selatan (*Hadley*) dan sirkulasi barat-timur (*Walker*). Menurut Saputro (2009) gangguan terhadap salah satu sistem sirkulasi ini akan mempengaruhi cuaca dan iklim di Indonesia. Indonesia memiliki iklim tropis yang terdapat dua musim yaitu musim kemarau dan musim penghujan.

Menurut Lippsmiere (1980) iklim tropis Indonesia mempunyai kelembaban relatif (RH) yang sangat tinggi, rata-rata suhu tahunan umumnya berkisar 23°C dan dapat naik sampai 38°C pada musim kemarau, dan curah hujan yang tinggi. Curah hujan di Indonesia sangat tinggi karena letak Indonesia secara geografis berada diantara dua samudera yaitu Samudera Pasifik dan Samudera Hindia. Besarnya intensitas curah hujan yang diterima Indonesia dipengaruhi oleh besarnya penguapan yang dihasilkan oleh kedua samudera tersebut melalui interaksi antara suhu atmosfer dengan air samudera (Ambar, 2015).

Menurut Asdak (1995) besarnya curah hujan yang turun di wilayah tropis umumnya bervariasi dari tahun ke tahun dan bahkan dari musim ke musim dalam kurun waktu satu bulan. Keragaman dan penyebaran curah hujan dipengaruhi oleh berbagai faktor seperti letak geografi, aliran udara atas, dan topografi (Hilario, 2009).

Karakteristik topografi atau ketinggian tempat sangat menentukan variasi curah hujan di suatu wilayah dan memiliki pengaruh yang signifikan terhadap curah hujan yang terjadi di wilayah tersebut (Sartono, 2010). Umumnya curah hujan lebih besar terjadi di wilayah yang menghadap angin atau wilayah yang terletak di depan gunung, sedangkan wilayah yang terletak di belakang gunung. Menurut Handoko (1994) berdasarkan variasi ketinggian, semakin tinggi tempat, curah hujannya relatif tinggi. Salah satu wilayah Indonesia yang memiliki kondisi topografi yang tinggi yaitu Sumatera Barat.

Curah hujan mempunyai keragaman yang besar, baik dalam skala ruang maupun dalam skala waktu. Salah satu pemodelan *time series* yang banyak digunakan untuk data curah hujan adalah *Autoregressive Integrated Moving Average* (ARIMA). Namun, model ARIMA hanya bersifat *univariate* sehingga tidak memperhatikan faktor

lokasi. Oleh karena itu perlu diterapkan pemodelan yang sesuai untuk memprediksi curah hujan yang bersifat *multivariate* dan mempunyai keragaman yang besar baik dalam skala ruang maupun skala waktu.

Peramalan suatu informasi yang bersifat *multivariate* salah satunya adalah model yang dikembangkan oleh Cristoper A. Sims pada tahun 1980 yaitu model *Vector Autoregressive* (VAR). Model *Vector Autoregressive* (VAR) merupakan perluasan dari model ARMA. Menurut Wutsqa dan Suhartono (2010) model ini menjelaskan keterkaitan antar pengamatan pada variabel tertentu pada suatu waktu dengan pengamatan pada variabel itu sendiri pada waktu-waktu sebelumnya, dan juga keterkaitannya dengan pengamatan pada variabel lain pada waktu-waktu sebelumnya. Pada penelitian sebelumnya peramalan menggunakan metode VAR telah dilakukan oleh Desvina (2014) yang meramalkan curah hujan di Indramayu. Hasil peramalan diperoleh bahwa curah hujan mengalami kenaikan dan penurunan yang tidak signifikan dari hari ke hari di Indramayu.

Penelitian di atas terbatas pada waktu sebelumnya dan belum memperhatikan pengaruh faktor lokasi geografis. Data yang menggabungkan keterkaitan waktu dan lokasi (*data space time*) pada data *time series multivariate* dikenal dengan model *Space Time Autoregressive* (STAR) yang dikenalkan oleh Preifer dan Deutch tahun 1980. Penerapan model ini dilakukan oleh Kamarianakis and Prastacos (2005) pada kasus transportasi dan Kyryakidis dan Journel (1999) pada data Geostatistik.

Model STAR cenderung tidak fleksibel ketika dihadapkan pada lokasi yang memiliki karakteristik yang berbeda. Model yang lebih fleksibel dari model STAR adalah model *Generalized Space Time Autoregressive* (GSTAR). Model ini dikembangkan oleh Borovka, Lopuhaa dan Ruchjana (2002) yang mana model GSTAR adalah model STAR dengan asumsi bahwa asumsi parameter *autoregressive* dan parameter *time series* tidak harus bernilai sama atau homogen di setiap lokasi. Penelitian yang dilakukan oleh Suhartono (2005) dengan membandingkan model VARMA dan model GSTAR dimana hasilnya menunjukkan bahwa peramalan dengan model GSTAR lebih akurat dibandingkan dengan model VARMA. Dalam penelitian tersebut pada proses pembentukan

model dari segi teori diperoleh informasi bahwa model VARMA lebih fleksibel.

Kajian yang dilakukan di atas terbatas pada data *time series multivariate* yang stationer, tetapi belum mengikutsertakan pola musiman atau *seasonal*. Contoh data *time series multivariate* yang mempunyai pola *seasonal* diantaranya seperti data banyaknya wisatawan, data penumpang pesawat dan data hidrologi seperti curah hujan dan debit air. Dengan hal ini, untuk menangani data yang berpola musiman atau *seasonal* pada kasus data *time series multivariate* atau sama halnya dengan menggabungkan hubungan antara waktu dan lokasi yang memiliki pola *seasonal* yaitu dengan mendapatkan model *time series multivariate* dengan pola *seasonal*. Model tersebut dikenal dengan nama model *Vector Autoregressive-Generalized Space Time Autoregressive* (VAR-GSTAR). Model VAR-GSTAR merupakan model *Vector Autoregressive* (VAR) dengan skema respon prediktor yang direpresentasikan dalam skema *Generalized Space Time Autoregressive* (GSTAR).

Penelitian sebelumnya dilakukan oleh Wutsqa dan Suhartono (2010) yang mana membandingkan model VARMA dengan model VAR-GSTAR pada data pariwisata. Hasil dari penelitian tersebut menyebutkan bahwa model VAR-GSTAR memberikan hasil yang realitis karena model VARMA tidak dapat mengakomodasi lag-lag *seasonal* pada orde model. Penelitian yang sama juga dilakukan oleh Waqi'ah (2017) dengan membandingkan model VAR-GSTAR dengan model GSTAR pada data pariwisata di Kabupaten Jember. Hasil penelitian menghasilkan bahwa peramalan data pariwisata di Kabupaten Jember menggunakan VAR-GSTAR lebih baik daripada model GSTAR. Hilma (2017) melakukan penelitian mengenai peramalan volume kendaraan yang masuk ke Kota Bandung dengan VAR-GSTAR, hasilnya menunjukkan bahwa model VAR-GSTAR dengan menerapkan bobot lokasi normalisasi korelasi silang pada data volume kendaraan yang masuk ke Kota Bandung lebih baik daripada sistem bobot lokasi lainnya.

Curah hujan di stasiun wilayah Sumatera Barat merupakan data *seasonal* bulanan. Pergerakan curah hujan mempunyai keterkaitan pada waktu-waktu sebelumnya dan juga mempunyai keterkaitan antar stasiun yang biasa disebut dengan hubungan spasial. Oleh karena itu, peneliti tertarik untuk mengkaji suatu pemodelan yang dapat menggambarkan keterkaitan antar

waktu dan lokasi pada data curah hujan berdasarkan penentuan bobot lokasi yang memberikan nilai terbaik.

TINJAUAN PUSTAKA

1. Curah Hujan

Curah hujan adalah banyaknya air hujan yang jatuh pada permukaan bumi suatu daerah dalam kurun waktu tertentu. Curah hujan adalah ketinggian air hujan yang terkumpul dalam penakar hujan pada tempat yang datar, tidak menyerap, tidak meresap dan tidak mengalir (BMKG, 2020). Satuan yang digunakan untuk mengukur curah hujan adalah milimeter (mm). Menurut Badan Meteorologi, Klimatologi, dan Geofisika (BMKG, 2020) Satu milimeter hujan berarti air hujan yang turun di wilayah seluas satu meter persegi akan memiliki ketinggian satu milimeter jika air hujan tidak meresap, mengalir, atau menguap.

2. *Vector Autoregressive* (VAR)

Model *Vector Autoregressive* (VAR) merupakan gabungan dari beberapa model AR (*Autoregressive*), dimana model ini membentuk vektor antara variabel yang saling mempengaruhi (Sims, 1972). Model VAR(1) adalah model VAR berorde 1 artinya variabel bebas dari model tersebut hanyalah satu nilai lag dari variabel tak bebasnya. Model VAR dapat dituliskan sebagai berikut (Tsay, 2014 :349).

$$Y_t = \phi_0 + \Phi Y_{t-1} + \varepsilon_t$$

Dengan ϕ_0 =Vektor konstanta ke- m , Φ = matriks $m \times m$, $Y_t = Y_t - \mu$, $\mu = E(Y_t)$, ε_t = Vektor $m \times 1$ dari residual pada waktu ke- t , Y_t = Vektor $m \times 1$ dari variabel pada waktu ke- t , Y_{t-1} = Vektor $m \times 1$ dari variabel pada waktu ke- $(t - 1)$.

3. *Generalized Space Time Autoregressive* (GSTAR)

Model *Generalized Space Time Autoregressive* (GSTAR) merupakan generalisasi dari model *Space Time Autoregressive* (STAR). Model ini dikembangkan oleh Borovka, Lopuhaa dan Ruchjana (2002) yang mana model GSTAR adalah model STAR dengan asumsi bahwa asumsi parameter *autoregressive* dan parameter *time series* tidak harus bernilai sama atau homogen di setiap lokasi. Suatu deret

$\{Y(t): t = 0, 1, 2, \dots\}$, merupakan sebuah deret waktu multivariate dari T pengamatan, maka persamaan model GSTAR untuk orde waktu $AR(p)$ dan orde spasial 1 dengan menggunakan 3 lokasi yang berbeda adalah sebagai berikut.

$Y_{(t)} = \phi_{10}Y(t-1) + \phi_{11}W^{(l)}Y(t-1) + \varepsilon_t$
 dengan: $Y_{(t)}$ = vektor random berukuran $(T \times 1)$ pada waktu t , ϕ_{10} = matriks koefisien parameter waktu, ϕ_{11} = matriks koefisien spasial, $W^{(l)}$ = nilai matriks pembobot ukuran $(m \times m)$ pada lag spasial ke- l .

4. VAR-GSTAR

Model *Vector Autoregressive-Generalized Space Time Autoregressive* (VAR-GSTAR) merupakan model peramalan pada suatu data *time series multivariat* yang menggabungkan interdependensi waktu dan lokasi. Model VAR-GSTAR adalah model yang direpresentasikan ke dalam model GSTAR. Model VAR(p) dituliskan sebagai berikut.

$$Z_i(t) = \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + \varepsilon_t$$

dengan: $Z_i(t)$ = nilai observasi pada daerah i waktu ke- t , ϕ_1 = matriks koefisien berukuran $m \times m$, ε_t = vektor sisaan berukuran $m \times 1$ terhadap waktu ke- t .

5. Stasioneritas Model

Asumsi stasioneritas sangat penting pada analisis *time series*. Sifat-sifat statistik di masa yang akan datang dapat diramalkan berdasarkan data yang telah terjadi di masa lalu. Stasioneritas berarti bahwa tidak terdapat terdapat perubahan yang signifikan pada data. Menurut Makridarkis (1995: 351) fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan, tidak tergantung pada waktu dan variasi dari fluktuasi tersebut. Pengujian stasioneritas dari model yaitu uji akar unit (*unit root test*) dengan melihat nilai *Augmented Dickey Fuller* (ADF).

6. Identifikasi Model

Model VAR-GSTAR mempunyai dua orde yaitu orde waktu yang diperoleh dari model VAR dan orde ruang yang ditentukan dari model GSTAR. Model ini menggunakan orde ruang (λ_s), karena orde ruang yang lebih tinggi sulit untuk diinterpretasikan. Penentuan panjang lag optimal yang akan digunakan

dalam model VAR dapat ditentukan berdasarkan kriteria *Akaike Information Criterion* (AIC). Lag yang akan dipilih adalah model dengan nilai AIC yang paling kecil. Menurut Tsay (2005: 41) nilai AIC dapat menggunakan rumus berikut.

$$AIC = \ln\left(\frac{JKS}{n}\right) + \frac{2K^2}{n}$$

dimana: JKS = jumlah kuadrat sisaan, n = banyak data, K = jumlah parameter pada model

7. Bobot Lokasi pada Model VAR-GSTAR

a. Bobot Normalisasi Korelasi Silang

Bobot normalisasi korelasi silang menggunakan hasil normalisasi korelasi silang antar lokasi pada lag waktu yang bersesuaian (Suhartono & Atok, 2006). Pembobot normalisasi korelasi yang dikenalkan oleh Suhartono dan Subanar (2006) dituliskan sebagai berikut.

$$W_{ij}(k) = \frac{r_{ij}(k)}{\sum_{k=1}^p |r_{ik}(k)|}$$

dimana $i \neq j, k = 1, 2, \dots, p$ dan taksiran dari korelasi silang pada data sampel dirumuskan sebagai berikut.

$$r_{ij}(k) = \frac{\sum_{t=k+1}^n [z_i(t) - \bar{z}_i][z_j(t-k) - \bar{z}_j]}{\sqrt{(\sum_{t=1}^n [z_i(t) - \bar{z}_i]^2) (\sum_{t=1}^n [z_j(t) - \bar{z}_j]^2)}}$$

dimana $z_i(t)$ merupakan data waktu ke- t pada daerah i , $z_j(t)$ merupakan data waktu ke- t pada daerah j dan k adalah lag waktu ke- k . Untuk memenuhi ketentuan bahwa jumlah elemen dalam matriks korelasi harus bernilai satu, maka perlu dilakukan normalisasi.

b. Bobot Inverse Jarak

Nilai dari bobot inverse jarak diperoleh dengan menggunakan perhitungan berdasarkan jarak sebenarnya antara lokasi dengan cara menginverskan jaraknya. Lokasi yang berdekatan mendapatkan nilai bobot yang lebih besar. Jarak yang digunakan pada bobot inverse jarak adalah satuan derajat lintang dan derajat bujur. Bobot inverse jarak dirumuskan sebagai berikut.

$$w_{ij} = \frac{w_{ij}^*}{\sum_{k=1}^p W_{ik}^*}$$

Dimana

$$w_{ij}^* = \begin{cases} \frac{1}{d_{ij}}, & i \neq j \\ 0, & i = j \end{cases}$$

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

dengan w_{ij} adalah nilai bobot dari lokasi i dan j , d_{ij} adalah jarak dari lokasi i ke j , (u_i, u_j) adalah koordinat dari garis lintang dan (v_i, v_j) adalah koordinat dari garis bujur.

8. Estimasi Parameter

Menurut Wutsqa & Suhartono (2010) proses penentuan estimasi parameter untuk memperoleh nilai sisaan yang bersifat *white noise* secara multivariate dapat digunakan metode kuadrat terkecil (*least square*), 2SLS (*Two Stage Least Squares*) atau SUR (*Seemingly Unrelated*). Pada penelitian ini metode yang digunakan untuk mengestimasi parameter adalah metode kuadrat terkecil (*least square*). Berdasarkan hasil estimasi parameter model VAR-GSTAR dengan metode kuadrat terkecil diperoleh bahwa estimator untuk $\hat{\Phi}$ adalah $(Z^*{}'Z)^{-1}(Z^*{}'Z)$.

9. Uji White Noise

Uji *white noise* digunakan untuk mengetahui ada tidaknya korelasi nilai sisa antar lag. Pemeriksaan sisaan yang bersifat *white noise* dapat dilakukan dengan menggunakan uji *Ljung and Box*. Langkah-langkah pengujian *white noise* dengan uji *Ljung-Box* adalah sebagai berikut.

$$Q_{LB} = n(n+2) \sum_{k=1}^n \left(\frac{1}{n-k} \right) \hat{p}_k^2$$

10. Verifikasi Model

Verifikasi model digunakan memastikan ukuran ketepatan model, setelah dinyatakan mempunyai sisaan yang bersifat *white noise*. Salah satu cara untuk menentukan model terbaik dapat dilakukan dengan menggunakan *Root Mean Square Error* (RMSE).

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

dimana Z_t adalah data actual, \hat{Z}_t adalah data prediksi dengan suatu sistem pembobotan lokasi yang dipilih, dan n adalah banyaknya data. Model yang dipilih adalah model yang

memiliki nilai RMSE terkecil.

11. Validasi Model

Validasi Model dengan menggunakan nilai MAPE atau Mean Absolute Percentage Error merupakan ukuran kesalahan nilai dugaan model yang dinyatakan dalam bentuk rata-rata persentase absolut residual. Persamaan MAPE di bawah ini sebagai berikut.

$$MAPE = \frac{100\%}{M} \sum_{t=1}^M \left| \frac{Z(t) - \hat{Z}(t)}{Z(t)} \right|$$

METODE PENELITIAN

1. Sumber Data

Jenis data yang digunakan dalam penelitian ini adalah data sekunder. Data diperoleh melalui publikasi lembaga pemerintahan resmi yakni dari Badan Pusat Statistik (BPS) Provinsi Sumatera Barat. Data yang digunakan adalah data curah hujan di 4 stasiun pengamatan dengan periode bulan Januari 2015 sampai dengan Desember 2020

2. Variabel Penelitian

Data curah hujan di 4 stasiun pengamatan yaitu Stasiun Meteorologi Minangkabau Pariaman (SMMP), Stasiun Teluk Bayur Padang (STBP), Stasiun Klimatologi Sicincin (SKPP) dan Stasiun Klimatologi GAW Bukit Kototabang Palupuh (SGAW). Data curah hujan dibagi menjadi data *in-sample* dan data *out-sample*. Data *in-sample* digunakan untuk membentuk suatu model, sedangkan data *out-sample* digunakan untuk memeriksa daya ramal yang terbentuk dari data *in-sample* atau untuk validasi model yang terbentuk dari data *out-sample*.

3. Analisis Data

Tahapan analisis yang digunakan dalam penelitian ini adalah:

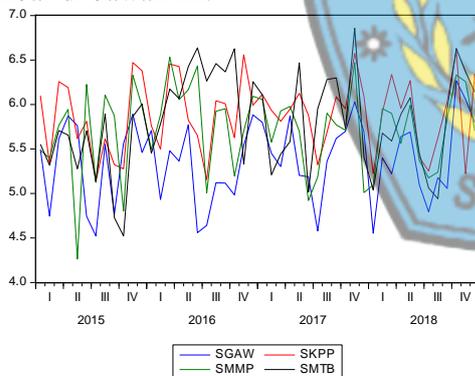
- Identifikasi data *in-sample* dengan melihat plot deret waktu
- Memeriksa kestasioneran data dengan uji akar unit (*unit root test*) dengan melihat nilai *Augmented Dickey Fuller* (ADF).
- Identifikasi model, mengidentifikasi model dilakukan dengan menggunakan orde model VAR yaitu dipilih model dengan nilai AIC yang terkecil..

- Melakukan pemodelan dengan pembobot lokasi, yaitu bobot normalisasi korelasi silang dan bobot inverse jarak.
- Mengestimasi parameter dengan menggunakan metode kuadrat terkecil.
 - Melakukan uji kelayakan model dengan *Uji Ljung and Box* untuk menguji apakah model memiliki sisaan yang bersifat *white noise*.
 - Verifikasi model VAR-GSTAR dengan melihat nilai RMSE.
 - Validasi Model dengan data *out-sampel* menggunakan nilai MAPE.
 - Peramalan

HASIL DAN PEMBAHASAN

1. Identifikasi Data

Identifikasi data dilakukan dengan melihat plot data *time series*. Data yang digunakan dalam penelitian ini adalah data curah hujan di 4 lokasi stasiun pengamatan di Provinsi Sumatera Barat. Plot data curah hujan di Stasiun Meteorologi Minangkabau Pariaman, Stasiun Teluk Bayur Padang, Stasiun Klimatologi Sicincin dan Stasiun Klimatologi GAW Bukit Kototabang Palupuh periode Januari 2015-Desember 2018 disajikan pada gambar di bawah ini.



Gambar 1. Plot Data Curah Hujan

atas terlihat bahwa jenis pola data yang terkandung yaitu pola musiman, pola ini terjadi terjadi bilamana suatu deret dipengaruhi oleh faktor musiman (misalnya kuartal, tahunan, bulanan). Pola musiman terjadi apabila terdapat data naik turun terjadi secara berkala.

2. Pemeriksaan Kestasioneran

Syarat utama yang harus terpenuhi dalam deret waktu adalah kestasioneran data. Diketahui bahwa data curah hujan di Provinsi Sumatera Barat tidak stasioneritas maka dilakukan

transformasi atau *differencing*. Setelah dilakukan *differencing* kemudian untuk melihat kestasioneran data dapat dilakukan uji akar unit (*unit root test*) dengan melihat nilai *Augmented Dickey Fuller* (ADF).

Tabel 1 ADF Test

Lokasi	ADF	p_value
SGAW	-5,6148	0,01
SKPP	-6,6115	0,01
SMMP	-5,4224	0,01
STB	-4,0897	0,01402

di atas terlihat bahwa hasil uji *Augmented Dickey Fuller* (ADF) di 4 stasiun di Provinsi Sumatera Barat diperoleh nilai ADF di setiap lokasi lebih kecil dari $\alpha = 0,05$ atau nilai $p_value < \alpha = 0,05$ sehingga H_0 ditolak artinya data sudah stasioner atau tidak mengandung *unit root* pada masing-masing lokasi.

3. Identifikasi Model

Penentuan orde *autoregressive* pada model VAR-GSTAR dapat dilakukan dengan menggunakan orde model VAR(p). Penentuan panjang lag optimal yang akan digunakan dalam model VAR dapat ditentukan berdasarkan kriteria *Akaike Information Criterion* (AIC).

Tabel 4. 1 Nilai AIC masing-masing Lag

Lag	0	1	2	3	4
AIC	6,669502	6,175719	5,443048	5,575791	6,051828

terlihat bahwa nilai Lag dengan nilai *Akaike Information Criterion* (AIC) yang paling kecil adalah Lag 2. Diperoleh informasi bahwa orde waktu model VAR-GSTAR pada data curah hujan di Provinsi Sumatera Barat adalah 2. Model dengan orde ruang (λ_s) = 1 karena orde ruang yang lebih tinggi sulit untuk diinterpretasikan. Sehingga model yang sesuai adalah VAR-GSTAR(2,1), dapat ditulis sebagai berikut.

$$Y(t) = \Phi_{20}Y(t-1) + \Phi_{21}W^{(1)}Y(t-1) + e(t)$$

4. Pembobot Lokasi

a. Bobot Normalisasi Korelasi Silang

Bobot normalisasi korelasi silang menggunakan korelasi silang antar lokasi pada lag waktu yang bersesuaian (Suhartono &

Atok, 2006). Hasil perhitungan pembobot lokasi normalisasi korelasi silang dapat dilihat pada matriks di bawah sebagai berikut.

$$W = \begin{bmatrix} 0 & -0,1749 & -0,3143 & -0,2336 \\ -0,0163 & 0 & -0,1161 & 0,0510 \\ 0,0345 & -0,0962 & 0 & 0,0245 \\ -0,1914 & -0,2647 & -0,2208 & 0 \end{bmatrix}$$

b. Bobot Invers Jarak

Nilai dari bobot inverse jarak diperoleh dengan menggunakan perhitungan berdasarkan jarak sebenarnya antara lokasi dengan cara menginverskan jaraknya. Jarak yang digunakan pada bobot inverse jarak adalah satuan derajat lintang dan derajat bujur. Hasil perhitungan pembobot lokasi invers jarak dapat dilihat pada matriks di bawah sebagai berikut.

$$W = \begin{bmatrix} 0 & 0,2676 & 0,2191 & 0,1798 \\ 0,2256 & 0 & 0,2536 & 0,1874 \\ 0,1472 & 0,2541 & 0 & 0,2652 \\ 0,1532 & 0,2290 & 0,2844 & 0 \end{bmatrix}$$

5. Estimasi Parameter

a. Estimasi Parameter dengan Bobot Normalisasi Korelasi Silang

Tabel 3. Estimasi Parameter Bobot Normalisasi Korelasi Silang

Parameter	Estimasi	Standar Error	t-value	p_value
ϕ_{10}^2	0,6804	0,1422	4,78	0,0003
ϕ_{11}^2	0,3703	0,2313	1,60	0,1111
ϕ_{20}^2	0,0055	0,2125	0,02	0,9792
ϕ_{21}^2	0,7166	0,1061	6,75	0,0001
ϕ_{30}^2	-1,6856	0,7559	-2,23	0,0269
ϕ_{31}^2	-1,2184	0,4496	-2,71	0,0073
ϕ_{40}^2	-1,5546	0,3338	-4,65	0,0006
ϕ_{41}^2	-2,007	0,7556	-2,65	0,0086

Nilai estimasi parameter dikatakan signifikan apabila nilai p_value kurang dari $\alpha = 0,05$. Berdasarkan Tabel 3 di atas terlihat bahwa parameter ϕ_{11}^2 dan ϕ_{20}^2 memiliki nilai p_value lebih dari $\alpha = 0,05$ sehingga dilakukan kembali seleksi parameter yang signifikan untuk mendapatkan model terbaik. Hasil estimasi dengan parameter yang signifikan dapat dilihat pada Tabel 4 di bawah ini sebagai berikut.

Tabel 4. Hasil Estimasi dengan Parameter Signifikan

Parameter	Estimasi	Standar Error	t-value	p_value
ϕ_{10}^2	0,6804	0,1424	4,77	0,0003
ϕ_{21}^2	0,7166	0,1063	6,73	0,0002
ϕ_{30}^2	-1,6856	0,7570	-2,22	0,0272
ϕ_{31}^2	-1,9367	0,0280	69,16	0,0002
ϕ_{40}^2	-1,5632	0,0232	67,34	0,0002
ϕ_{41}^2	-2,007	0,7568	-2,65	0,0086

Berdasarkan Tabel 4.4 di atas terlihat bahwa semua parameter memiliki nilai p_value kurang dari $\alpha = 0,05$ artinya semua parameter pada model dapat digunakan untuk mendapatkan model VAR-GSTAR dengan bobot lokasi normalisasi korelasi silang. Berikut persamaan untuk tiap lokasi sebagai berikut.

- $y_1(t) = 0,6804y_1(t-1) + e_1(t)$
- $y_2(t) = -0,0116y_1(t-1) - 0,0831y_3(t-1) + 0,0365y_4(t-1) + e_1(t)$
- $y_3(t) = -1,6856y_3(t-1) - 0,0668y_1(t-1) + 0,1863y_2(t-1) - 0,0475y_4(t-1) + e_1(t)$
- $y_4(t) = -1,5632y_4(t-1) + 0,3842y_1(t-1) + 0,5313y_2(t-1) + 0,4432y_3(t-1) + e_1(t)$

b. Estimasi Parameter dengan Bobot Invers Jarak

Tabel 5. Estimasi Parameter Bobot Invers Jarak

Parameter	Estimasi	Standar Error	t-value	p_value
ϕ_{10}^2	0,3464	0,2015	1,71	0,0873
ϕ_{11}^2	1,1443	0,3542	3,23	0,0014
ϕ_{20}^2	0,3090	0,2488	1,24	0,2157
ϕ_{21}^2	0,9589	0,3467	2,76	0,0062
ϕ_{30}^2	-0,0346	0,2228	-0,15	0,8766
ϕ_{31}^2	1,3678	0,2960	4,62	0,0007
ϕ_{40}^2	0,4318	0,1795	2,40	0,0147
ϕ_{41}^2	0,9180	0,2911	3,15	0,0019

Nilai estimasi parameter dikatakan signifikan apabila nilai p_value kurang dari $\alpha = 0,05$. Berdasarkan Tabel 4.5 di atas terlihat bahwa parameter ϕ_{10}^2 , ϕ_{20}^2 dan ϕ_{30}^2 memiliki nilai p_value lebih dari $\alpha = 0,05$ sehingga dilakukan kembali seleksi parameter yang signifikan untuk mendapatkan model terbaik. Hasil estimasi dengan parameter yang signifikan dapat dilihat pada Tabel 6 di bawah ini sebagai berikut.

Tabel 6 Hasil Estimasi dengan Parameter Signifikan

Parameter	Estimasi	Standar Error	t-value	p_value
ϕ_{11}^2	1,7514	0,0272	64,21	0,0002
ϕ_{21}^2	1,3898	0,0197	70,28	0,0002
ϕ_{31}^2	1,3219	0,01932	68,41	0,0002
ϕ_{40}^2	0,4318	0,1802	2,39	0,0176
ϕ_{41}^2	0,9180	0,2923	3,14	0,0019

Berdasarkan Tabel 6 di atas terlihat bahwa semua parameter memiliki nilai p_value kurang dari $\alpha = 0,05$ artinya semua parameter pada model dapat digunakan untuk mendapatkan model VAR-GSTAR dengan bobot lokasi invers jarak. Berikut menjadi persamaan untuk tiap lokasi sebagai berikut.

- 1) $y_1(t) = 0,4318y_4(t-1) + 0,4686y_2(t-1) + 0,3837y_3(t-1) + 0,3149y_4(t-1) + e_1(t)$
- 2) $y_2(t) = 0,3135y_1(t-1) + 0,3521y_3(t-1) + 0,2604y_4(t-1) + e_1(t)$
- 3) $y_3(t) = 0,1945y_1(t-1) + 0,3358y_2(t-1) + 0,3505y_4(t-1) + e_1(t)$
- 4) $y_4(t) = 0,1406y_1(t-1) + 0,2102y_2(t-1) + 0,2610y_3(t-1) + e_1(t)$

6. Uji White Noise

Uji *white noise* digunakan untuk mengetahui ada tidaknya korelasi nilai sisa antar lag. Pemeriksaan sisaan yang bersifat *white noise* dapat dilakukan dengan menggunakan uji *Ljung and Box*. Berikut hasil uji *Ljung and Box* (LB) untuk model VAR-GSTAR(2,1) dengan pembobot lokasi normalisasi korelasi silang dan bobot invers jarak disajikan pada Tabel 7 di bawah ini sebagai berikut.

Tabel 7. Hasil Uji Asumsi *White Noise*

Pembobot Lokasi	Asumsi <i>White Noise</i>
Normalisasi Korelasi Silang	<i>White Noise</i>
Invers Jarak	<i>White Noise</i>

Berdasarkan Tabel 4.7 pembobot lokasi normalisasi korelasi silang dan pembobot lokasi invers jarak telah memenuhi asumsi *White Noise* karena nilai $LB > \chi_{1-\alpha; k}^2$ tabel atau nilai *X-squared* lebih besar dari nilai p_value .

7. Verifikasi Model

Verifikasi model digunakan memastikan ukuran ketepatan model, setelah dinyatakan mempunyai sisaan yang bersifat *white noise*. Salah satu cara untuk menentukan model terbaik dapat dilakukan dengan menggunakan *Root Mean Square Error* (RMSE). Nilai RMSE antara 0 sampai ∞ . Semakin kecil nilai RMSE maka model yang digunakan semakin bagus (Wei, 2006). Hasil pengukuran kebaikan model dengan kedua pembobot dilihat pada Tabel 4.8 sebagai berikut.

Tabel 8. Nilai RMSE

Pembobot Lokasi	RMSE
Normalisasi Korelasi Silang	10,1342
Invers Jarak	1,66018

Berdasarkan Tabel 8 di atas terlihat bahwa model VAR-GSTAR(2,1) dengan pembobot lokasi invers jarak memiliki nilai RMSE yang lebih kecil dibandingkan model VAR-GSTAR(2,1) dengan pembobot lokasi normalisasi korelasi silang. Oleh karena itu, model terbaik yang digunakan pada curah hujan di Provinsi Sumatera Barat adalah model VAR-GSTAR(2,1) dengan pembobot lokasi invers jarak.

8. Validasi Model

Validasi model digunakan untuk mengukur kesalahan nilai dugaan model. Menurut Pandawa *et.al.* (2015) MAPE atau *Mean Absolute Percentage Error* merupakan ukuran kesalahan nilai dugaan model yang dinyatakan dalam bentuk rata-rata persentase absolut residual. Menurut Zainun dan Majid (2003) kemampuan peramalan sangat baik jika memiliki nilai MAPE kurang dari 10% dan mempunyai kemampuan peramalan yang baik

jika nilai MAPE kurang dari 20%. Hasil nilai MAPE adalah sebagai berikut.

Tabel 9. Nilai MAPE

Pembobot Lokasi	MAPE
Normalisasi Korelasi Silang	93,12%
Invers Jarak	13,15%

Berdasarkan Tabel 9 terlihat bahwa model VAR-GSTAR(2,1) dengan bobot lokasi invers jarak memiliki nilai MAPE yang lebih kecil dibandingkan model VAR-GSTAR(2,1) dengan pembobot lokasi normalisasi korelasi silang. Nilai MAPE model VAR-GSTAR(2,1) dengan bobot invers jarak memiliki nilai MAPE kurang dari 20% hal ini menunjukkan kemampuan peramalan yang baik. Oleh karena itu, model yang digunakan pada curah hujan di Provinsi Sumatera Barat di 4 stasiun pengamatan di masa yang akan datang adalah model VAR-GSTAR(2,1) dengan pembobot lokasi invers jarak.

9. Peramalan

Salah satu tujuan dalam analisis data *time series* adalah untuk meramalkan nilai pengamatan dimasa yang akan datang. Hasil tingkat akurasi peramalan untuk masing-masing lokasi berdasarkan nilai MAPE disajikan dalam Tabel 4.10 di bawah ini sebagai berikut.

Tabel 10. Hasil MAPE Tiap Lokasi

SGAW	SKPP	SMMP	SMTB
17,96%	10,35%	14,60%	9,71%

Berdasarkan Tabel 10 terlihat bahwa nilai MAPE Saklim GAW Bukit Kototabang Palupuh sebesar 17,96% memiliki tingkat peramalan yang baik, nilai MAPE Staklim Sicincin sebesar 10,35% memiliki tingkat peramalan yang baik, nilai MAPE Stamet Minangkabau Pariaman sebesar 14,60% memiliki tingkat peramalan yang baik dan nilai MAPE Stasiun Teluk Bayur Padang sebesar 9,71% dapat diinterpretasikan bahwa tingkat akurasi peramalannya sangat akurat.

KESIMPULAN

1. Model *Vector Autoregressive-Generalized Space Time Autoregressive* (VAR-GSTAR) dengan bobot lokasi terbaik pada data curah hujan di Provinsi Sumatera Barat adalah Model VAR-GSTAR(2,1) dengan

pembobot lokasi inver jarak. Modelnya untuk tiap lokasi yaitu:

- a. $y_1(t) = 0,4318y_4(t-1) + 0,4686y_2(t-1) + 0,3837y_3(t-1) + 0,3149y_4(t-1) + e_1(t)$
- b. $y_2(t) = 0,3135y_1(t-1) + 0,3521y_3(t-1) + 0,2604y_4(t-1) + e_1(t)$
- c. $y_3(t) = 0,1945y_1(t-1) + 0,3358y_2(t-1) + 0,3505y_4(t-1) + e_1(t)$
- d. $y_4(t) = 0,1406y_1(t-1) + 0,2102y_2(t-1) + 0,2610y_3(t-1) + e_1(t)$

Hasil ramalan data curah hujan di Provinsi Sumatera Barat menggunakan model *Vector Autoregressive-Generalized Space Time Autoregressive* (VAR-GSTAR) dengan bobot lokasi invers jarak terlihat bahwa nilai MAPE Saklim GAW Bukit Kototabang Palupuh sebesar 17,96% memiliki tingkat peramalan yang baik, nilai MAPE Staklim Sicincin sebesar 10,35% memiliki tingkat peramalan yang baik, nilai MAPE Stamet Minangkabau Pariaman sebesar 14,60% memiliki tingkat peramalan yang baik dan nilai MAPE Stasiun Teluk Bayur Padang sebesar 9,71% dapat diinterpretasikan bahwa tingkat akurasi peramalannya sangat akurat.

DAFTAR PUSTAKA

- Asdak C. (1995). *Hidrologi dan Pengelolaan Daerah Aliran Sungai*. Gajah Mada University Press. Yogyakarta.
- Asmoro, Ambar. (2015). *Analisis pengaruh curah hujan terhadap Fluktuasi hasil produksi tanaman padi DAS Bengawan Solo hulu bagian tengah tahun 1986-2045*. Skripsi Program studi Geografi Fakultas Geografi Universitas Muhammadiyah Surakarta, pp. 1.
- Aswi & Sukarna. (2006). *Analisis Deret Waktu Teori dan Aplikasi*. Makasar: Andira Publisher.
- Badan Pusat Statistik Provinsi Sumatera Barat. (2016). *Provinsi Sumatera Barat Dalam Angka 2016*. Padang: BPS Provinsi Sumatera Barat

- Badan Pusat Statistik Provinsi Sumatera Barat. (2017) . *Provinsi Sumatera Barat Dalam Angka 2017*. Padang: BPS Provinsi Sumatera Barat
- Badan Pusat Statistik Provinsi Sumatera Barat. (2018) . *Provinsi Sumatera Barat Dalam Angka 2018*. Padang: BPS Provinsi Sumatera Barat
- Badan Pusat Statistik Provinsi Sumatera Barat. (2019) . *Provinsi Sumatera Barat Dalam Angka 2019*. Padang: BPS Provinsi Sumatera Barat
- Badan Pusat Statistik Provinsi Sumatera Barat. (2020) . *Provinsi Sumatera Barat Dalam Angka 2020*. Padang: BPS Provinsi Sumatera Barat
- Badan Pusat Statistik Provinsi Sumatera Barat. (2021) . *Provinsi Sumatera Barat Dalam Angka 2021*. Padang: BPS Provinsi Sumatera Barat
- Badan Meteorologi Klimatologi dan Geofisika Stasiun Klimatologi. (2020). *Kriteria Curah Hujan Bulanan*. Jakarta: BMKG.
- Borovkova S., Lopuhaa H. P., and Ruchjana B. N., (2008), *Consistency and Asymptotic Normality of Least Squares Estimators of Generalized STAR Models*, *Statistica Neerlandica*, 62, nr 4, p. 482-508
- Haerdle, W.K, Prastyo, D.D. & Hafner, C.M. (2014). *Support Vector Machines with Evolutionary Model Selection for Default Prediction*, in *The Oxford Handbook of Applied Nonparametric and Semiparametric Econometrics and Statistics*, eds. Racine, JS, Su, L, and Ullah, A, Oxford University Press, 346-373.
- Handoko. (1994). *Klimatologi dasar landasan pemahaman fisika atmosfer dan unsur-unsur iklim*. PT. dunia pustaka jaya. Jakarta.
- Hilario, Flaviana et all. (2009). *El Niño Southern Oscillation in the Philippines: Impacts, Forecasts, and Risk Management.*, *Philippine Journal of Development*, number 66, First Semester, Vol. XXVI, No. 1, pp 10.
- Kamarianakis Y & Prastacos PP. 2005. *Space-time modeling of Traffic flow*. *Computers and Geosciences*. 31: 119-133.
- Kyryakidis PC & Journel AG. 1999. *Geostatistical Space-time model: A review*. *Math. Geol.* 31(6): 651-683.
- Makridakis, S., Wheelwright, S.C., dan McGee, V.E. (1995). *Metode dan Aplikasi Peramalan*. Jakarta: Erlangga.
- Miller, S. J. (2006). *The Method of Least Square*. Mathematics Department Brown University Providence, RI 02912.
- Pfeifer P. E. and Deutsch S. J., (1980). *A three stage iterative procedure for space- time modeling*. *Technometrics*. 22(1):35-47.
- Ruchjana, B. N. (2002). *Pemodelan Kurva Produksi Minyak Bumi menggunakan Model Generalisasi STAR*. Bogor: Forum Statistika dan Komputasi IPB.
- Sartono Marpaung. (2010). *Pengaruh Topografi Terhadap Curah Hujan Musiman Dan Tahunan Di Provinsi Bali Berdasarkan Data Observasi Resolusi Tinggi*. *Prosiding Seminar Penerbangan dan Antariksa 2010 Sub Seminar Sains Atmosfer dan Iklim*, 104-110, Serpong. Pusat Pemanfaatan Sains Atmosfer dan Iklim LAPAN.