

**IMPLEMENTASI MODEL *GENERALIZED SPACE TIME*
AUTOREGRESSIVE MUSIMAN PADA CURAH HUJAN DI
KOTA BATU**

SKRIPSI

**OLEH
ACHMAD HILMI FUADY
NIM 19610097**



**PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2024**

**IMPLEMENTASI MODEL *GENERALIZED SPACE TIME*
AUTOREGRESSIVE MUSIMAN PADA CURAH HUJAN DI
KOTA BATU**

SKRIPSI

**Diajukan Kepada
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang
untuk Memenuhi Salah Satu Persyaratan
dalam Memperoleh Gelar Sarjana Matematika (S.Mat)**

**Oleh
Achmad Hilmi Fuady
NIM. 19610097**

**PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2024**

**IMPLEMENTASI MODEL *GENERALIZED SPACE TIME*
AUTOREGRESSIVE MUSIMAN PADA CURAH HUJAN DI
KOTA BATU**

SKRIPSI

**Oleh
Achmad Hilmi Fuady
NIM. 19610097**

Telah Diperiksa dan Disetujui Untuk Diuji
Malang, 20 Juni 2024

Dosen Pembimbing I,



Prof. Dr. Hj. Sri Harini, M.Si.
NIP. 19731014 200112 2 002

Dosen Pembimbing II,



Dr. H. Imam Sujarwo, M.Pd.
NIP. 19630502 198703 1 005

Mengetahui,
Ketua Program Studi Matematika




Dr. Elly Susanti, M.Sc.
NIP. 19741129 200012 2 005

IMPLEMENTASI MODEL GENERALIZED SPACE TIME AUTOREGRESSIVE MUSIMAN PADA CURAH HUJAN DI KOTA BATU

SKRIPSI

Oleh
Achmad Hilmi Fuady
NIM. 19610097

Telah Dipertahankan di Depan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
untuk Memperoleh Gelar Sarjana Matematika (S.Mat.)

Tanggal 27 Juni 2024

Ketua Penguji : Dr. Fachrur Rozi, M.Si.


Anggota Penguji 1 : Ria Dhea Layla Nur Kharisma, M.Si.

Anggota Penguji 2 : Prof. Dr. Hj. Sri Harini, M.Si.

Anggota Penguji 3 : Dr. H. Imam Sujarwo, M.Pd.



Mengetahui,
Ketua Program Studi Matematika



Dr. Elly Susanti, M.Sc.
NIP. 19741129 200012 2 005

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Achmad Hilmi Fuady
NIM : 19610097
Program Studi : Matematika
Fakultas : Sains dan Teknologi
Judul Skripsi : Implementasi Model Generalized Space
Time Autoregressive Musiman pada Curah
Hujan di Kota Batu

Menyatakan dengan sebenar-benarnya bahwa skripsi yang saya tulis ini benar-benar merupakan hasil karya sendiri, bukan merupakan pengambilan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan dan pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka. Apabila di kemudian hari terbukti atau dapat dibuktikan ini hasil jiplakan, maka saya bersedia menerima saksi atas perbuatan tersebut.

Malang, 20 Juni 2024

Saya membuat pernyataan.



Achmad Hilmi Fuady
NIM. 19610097

MOTO

عش کریمہ او مت شہیدا

KATA PENGANTAR

Assalamu 'alaikum Warahmatullahi Wabarakatuh

Alhamdulillah ala kulli hal, segala puji bagi Allah Swt. atas rahmat, taufik, serta hidayah-Nya, sehingga penulis mampu menyelesaikan skripsi yang berjudul “Implementasi Model *Generalized Space Time Autoregressive* (GSTAR) Musiman pada Curah Hujan di Kota Batu”. *Shalawat* serta salam senantiasa tercurahkan kepada baginda kita yang mulia, yakni Nabi Muhammad saw. beserta keluarga, sahabat, dan umatnya.

Pada proses pembuatan skripsi ini, banyak pihak yang telah ikut serta dalam memberikan bimbingan, arahan, dan masukan kepada penulis. Oleh karena itu penulis mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Prof. Dr. H. M. Zainuddin, M.A., selaku rektor Universitas Islam Negeri Maulana Malik Ibrahim.
2. Prof. Dr. Hj. Sri Harini, M.Si., selaku dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim dan selaku dosen pembimbing I yang telah memberikan berbagai pengetahuan, pengalaman, arahan serta nasihat kepada penulis.
3. Dr. Elly Susanti, S.Pd., M.Sc., selaku ketua Program Studi Matematika, Universitas Islam Negeri Maulana Malik Ibrahim.
4. Dr. H. Imam Sujarwo, M.Pd., selaku dosen pembimbing II yang telah memberikan nasihat, ilmu, dan arahan kepada penulis.
5. Seluruh dosen Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang.

6. Bapak, Ibu dan seluruh keluarga yang senantiasa mendo'akan, memberikan dukungan dan semangat, serta kasih sayang sehingga proposal skripsi ini dapat diselesaikan oleh penulis.
7. Rekan-rekan penulis yang sama-sama berjuang mengerjakan skripsi serta saling memberikan dukungan dan semangat.
8. Seluruh rekan-rekan Program Studi Matematika angkatan 2019, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang.
Semoga Allah memberikan rahmat serta karunia-Nya kepada kita semua.

Semoga skripsi ini dapat bermanfaat bagi penulis sendiri dan para pembaca.

Aamiin.

Wassalamu'alaikum Warahmatullahi Wabarakatuh

Malang. 20 Juni 2024

Penulis

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PENGANTAR	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTO	vi
KATA PENGANTAR	vii
DAFTAR ISI	ix
DAFTAR GAMBAR	xi
DAFTAR TABEL	xii
LAMPIRAN	xiii
ABSTRAK	xiv
ABSTRACT	xv
المخلص	xvi
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	5
1.3 Tujuan Penelitian	5
1.4 Manfaat Penelitian	5
1.5 Batasan Masalah	6
BAB II KAJIAN TEORI	7
2.1 <i>Data Time Series</i>	7
2.2 Kestasioneran	7
2.2.1 Differencing	9
2.2.2 Transformasi	10
2.2.3 <i>Matrix Autocorrelation Function (MACF) dan Matrix Partial Autocorrelation Function (MPACF)</i>	13
2.3 <i>Generalized Space Time Autoregressive (GSTAR)</i>	15
2.3.1 Uji Pengaruh Spasial	16
2.3.1.1 Uji Autokorelasi Spasial	16
2.3.1.2 Uji Heterogenitas Spasial	17
2.3.2 Penentuan Orde Model SGSTAR	18
2.3.3 Pemilihan Bobot Lokasi pada model SGSTAR	19
2.3.4 Estimasi Parameter pada Model SGSTAR	22
2.3.5 Uji Kesesuaian Model	24
2.3.5.1 Uji White Noise	24
2.3.5.2 Uji Residual Berdistribusi Normal Multivariate	25
2.4 Evaluasi Model	26
2.4.1 <i>Mean Squared Error (MSE)</i>	26
2.4.2 <i>Root Mean Square Error (RMSE)</i>	27
2.5 Curah Hujan	27
2.6 Konsep Curah Hujan dalam Al-Quran	28
2.7 Kajian Topik dan Teori Pendukung	30
BAB III METODE PENELITIAN	32
3.1 Jenis Penelitian	32
3.2 Data dan Sumber Data	32

3.3 Tahapan Penelitian	33
3.4 <i>Flowchart</i> Penelitian	34
BAB IV HASIL DAN PEMBAHASAN.....	35
4.1 Analisis Deskriptif.....	35
4.2 Pembagian Data <i>Training</i> dan <i>Testing</i>	37
4.3 Uji Kestasioneran Data.....	37
4.4 Uji Pengaruh Spasial	39
4.4.1 Uji Autokorelasi Spasial	39
4.4.2 Uji Heterogenitas Lokasi	40
4.5 Perhitungan Bobot Lokasi Model SGSTAR.....	42
4.6 Penentuan Orde Model SGSTAR	44
4.6.1 Estimasi Parameter dengan Metode <i>Ordinary Least Square</i>	47
4.7 Uji Kesesuaian Model SGSTAR.....	52
4.8 Akurasi Model.....	54
4.9 Bertafakur Tentang Hujan dalam Al-Qur'an	57
BAB V PENUTUP	59
5.1 Kesimpulan	59
5.2 Saran.....	61
DAFTAR PUSTAKA.....	62
LAMPIRAN	64
RIWAYAT HIDUP.....	72

DAFTAR GAMBAR

Gambar 2.1 Contoh Plot Data yang Tidak Stasioner.....	8
Gambar 2.2 Contoh Plot Data yang Stasioner.....	8
Gambar 3.1 Diagram Alir Model GSTAR.....	34
Gambar 3.2 Diagram Alir Model GSTAR.....	34
Gambar 4.1 Plot Data Curah Hujan di 3 Kecamatan Kota Batu	36
Gambar 4.2 Jarak Tiap Lokasi Pengamatan pada Peta	42
Gambar 4.3 Plot Model SGSTAR(8)-I(1)6 dengan Bobot Seragam.....	56

DAFTAR TABEL

Tabel 2.1	Parameter Transfromasi Beserta Transformasinya	11
Tabel 4.1	Statistika Deskriptif Data Curah Hujan di 3 Kecamatan Kota Batu Periode Januari 2019 - September 2023	35
Tabel 4.2	Uji ADF Data Curah Hujan di 3 Kecamatan Kota Batu.....	38
Tabel 4.3	Plot MACF Data Curah Hujan di 3 Kecamatan Kota Batu	38
Tabel 4.4	Korelasi Data Curah Hujan di 3 Kecamatan Kota Batu	39
Tabel 4.5	Korelasi Curah Hujan di 3 Kecamatan Kota Batu	40
Tabel 4.6	Jarak Antar Lokasi Pengamatan.....	43
Tabel 4.7	MPACF Data Curah Hujan 3 Kecamatan di Kota Batu.	44
Tabel 4.8	Nilai AIC dari Beberapa Model.	45
Tabel 4.9	Estimasi Parameter Model GSTAR(7 ₁) Bobot lokasi Seragam.....	47
Tabel 4.10	Hasil Estimasi Parameter Model GSTAR Bobot Invers Jarak	48
Tabel 4.11	Hasil Uji Ljung-Box dengan p-value	53
Tabel 4.12	Hasil Uji Kolmogorov-Smirnov.....	53
Tabel 4.13	Nilai MSE dan RMSE Model pada Masing-Masing Bobot	54

LAMPIRAN

Lampiran 1 Data Curah Hujan di 3 Kecamatan Kota Batu Periode Januari 2019-September 2023	64
Lampiran 2 Tabel Uji ADF	65
Lampiran 3 Tabel MACF sebelum didifferencing	66
Lampiran 4 Tabel Durbin Watson	66
Lampiran 5 Output Rstudio Uji Autokorelasi Correlation Pearson	68
Lampiran 6 Output Rstudio Hasil Uji Kesesuain Model	68
Lampiran 7 Matriks Model SGSTAR(8)-I(1)6 dengan Bobot Seragam	69
Lampiran 8 Matriks Model SGSTAR(8)-I(1)6 dengan Bobot Invers Jarak ...	70

ABSTRAK

Fuady, Achmad Hilmi. 2024. Implementasi Model Generalized Space Time Autoregressive Musiman pada Data Curah Hujan di Kota Batu. Skripsi. Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Islam Maulana Malik Ibrahim Malang. Pembimbing: (I) Prof. Dr. Sri Harini, M.Si., (II) Dr. H. Imam Sujarwo, M.Pd.

Kata kunci: Time Series, GSTAR Musiman, Curah Hujan, Seragam

Curah hujan merupakan data spasial termportal yang merupakan data yang tidak hanya berhubungan dengan waktu lampau, tetapi juga berhubungan dengan lokasi pengamatan. Sehingga kurang akurat jika hanya menggunakan metode time series yang hanya bergantung pada data masa lampau. Oleh karena itu, dalam penelitian ini digunakan metode Generalized Space Time Autoregressive (GSTAR) musiman guna menghasilkan model yang lebih akurat. Penelitian ini bertujuan untuk mengetahui pola dan karakteristik dari curah hujan di Kota Batu dengan perbandingan dua bobot yakni, seragam dan invers jarak. dua variabel utama dalam penelitian ini yaitu data curah hujan (mm) dan jarak lokasi pengamatan (km). Adapun langkah-langkah analisis meliputi uji stasioneritas data, uji pengaruh spasial, perhitungan bobot lokasi, penentuan orde model SGSTAR, estimasi parameter menggunakan *Ordinary Least Square*, uji kesesuaian model, dan akurasi model. Hasil penelitian menunjukkan bahwa model SGSTAR terbaik adalah model SGSTAR(8)-I(1)⁶ bobot lokasi seragam dengan nilai RMSE 78.4230. Dari model yang didapatkan dapat diketahui bahwa curah hujan di tiga kecamatan Kota Batu saling mempengaruhi satu lokasi dengan lokasi lainnya. Selain itu curah hujan di tiga Kecamatan Kota Batu juga dipengaruhi oleh curah hujan pada hari-hari sebelumnya.

ABSTRACT

Fuady, Achmad Hilmi. 2024. Implementation of the Seasonal Generalized Space-Time Autoregressive Model on Rainfall Data in Batu City. Thesis. Mathematics Study Program, Faculty of Science and Technology, Universitas Islam Maulana Malik Ibrahim Malang. Supervisors: (I) Prof. Dr. Sri Harini, M.Si., (II) Dr. H. Imam Sujarwo, M.Pd.

Keywords: Time Series, Seasonal GSTAR, Rainfall, Uniform

Rainfall is thermal spatial data which is data that is not only related to past time, but also related to the location of observation. So it is less accurate if you only use the time series method which only relies on past data. Therefore, in this research the seasonal Generalized Space Time Autoregressive (GSTAR) method is used to produce a more accurate model. This research aims to determine the pattern and characteristics of rainfall in Batu City with a comparison of two weights, namely, uniform and inverse distance. The two main variables in this research are rainfall data (mm) and distance to the observation location (km). The analysis steps include data stationarity test, spatial influence test, location weight calculation, determining the SGSTAR model order, parameter estimation using Ordinary Least Square, model suitability test, and model accuracy. The research results show that the best SGSTAR model is the SGSTAR(8)-I(1)⁶ uniform location weight model with an RMSE value of 78.4230. From the model obtained, it can be seen that rainfall in the three sub-districts of Batu City influences one location and another. Apart from that, rainfall in three Batu City sub-districts is also influenced by rainfall in previous days.

الملخص

فوادي، أحمد حلمي. 2024. تطبيق نموذج الانحدار التلقائي الموسمي المعمم الزماني والمكاني على بيانات هطول الأمطار في مدينة باتو. البحث العلمي. قسم الرياضيات، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج، مالانج. المشرفة: (أولى) أ.د. سري هارينبي، الماجستير، الحاج.، والمشراف الثاني (2) د. إمام سوجرووا، الماجستير.

الكلمات المفتاحية: السلاسل الزمنية، الموسمية، هطول الأمطار، الانتظام

هطول الأمطار هي بيانات مكانية حرارية وهي البيانات التي لا تتعلق بالزمن الماضي فحسب، بل تتعلق أيضاً بموقع الرصد. لذا فهي أقل دقة إذا كنت تستخدم طريقة السلاسل الزمنية فقط تعتمد على البيانات السابقة. لذلك، في هذا البحث تم استخدام طريقة الانحدار الذاتي المعمم للزمان والمكان (*GSTAR*) لإنتاج النموذج الأكثر دقة. يهدف هذا البحث إلى تحديد النمط وخصائص هطول الأمطار في مدينة باتو مع مقارنة وزنين هما المسافة المنتظمة والمسافة العكسية. المتغيران الرئيسيان في هذا البحث هما بيانات هطول الأمطار (مم) والمسافة إلى موقع المراقبة (كم). تتضمن خطوات التحليل اختبار ثبات البيانات، واختبار التأثير المكاني، وحساب الوزن الموقع، وتحديد ترتيب نموذج *SGSTAR*، وتقدير المعلمة باستخدام المربع الأصغر العادي، واختبار ملاءمة النموذج، ودقة النموذج. ظهرت نتائج البحث أن أفضل النموذج *SGSTAR* هو نموذج وزن الموقع الموحد $SGSTAR(8)-I(1)^6$ بقيمة *RMSE* تبلغ 78.4230. من النموذج الذي تم الحصول عليه، يمكن ملاحظة أن هطول الأمطار في المناطق الفرعية الثلاثة لمدينة باتو يؤثر على موقع وآخر. وبصرف النظر عن ذلك، فإن هطول الأمطار في 3 مناطق فرعية لمدينة باتو يتأثر أيضاً بهطول الأمطار في الأيام السابقة.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Semakin berjalannya waktu, data tidak lagi hanya bergantung pada waktu lampau, tetapi juga dapat berkaitan dengan lokasi pengamatan. Data semacam ini disebut data *spatial temporal*. Model *spatial temporal* diperkenalkan pertama kali oleh Cliff pada tahun 1975. Model tersebut kemudian dikembangkan menjadi model *Space Time Autoregressive* (STAR) oleh Pfeifer dan Deutsh pada tahun 1980 dengan karakteristik lokasi pengamatan diasumsikan sama (Ruchjana, 2019). Model STAR jika dihadapkan pada lokasi pengamatan yang bersifat heterogen, maka model ini kurang baik untuk digunakan. Hal ini mengakibatkan model tersebut memiliki kekurangan pada fleksibilitas parameternya. Oleh karena itu, untuk mengatasi kekurangan tersebut model STAR kemudian dikembangkan menjadi model GSTAR oleh Borovka, Lopuhaa, dan Ruchjana (2002) dengan menjadikan karakteristik lokasi pengamatan bersifat heterogen (Irawati & Yasin, 2015).

Perbedaan terkait karakteristik parameter lokasi pengamatan menjadi perbedaan mendasar antara model GSTAR dan STAR. Tentunya model GSTAR lebih fleksibel dibandingkan dengan model STAR, karena pada model GSTAR lokasi pengamatan boleh diasumsikan tidak sama sehingga memungkinkan parameter model GSTAR yang berbeda di tiap lokasi. Sebelum melakukan estimasi parameter model, dilakukan penentuan matriks bobot lokasi terlebih dahulu. Penentuan bobot lokasi merupakan langkah yang harus dilakukan sebelum tahap estimasi parameter model. Terdapat 4 cara untuk menentukan matriks bobot lokasi

diantaranya yaitu, bobot seragam, bobot biner, *invers* jarak, dan semivariogram (Borovkova & Nurani, 2002). Dalam menentukan bobot lokasi semua nilainya bergantung dari jarak antar lokasi pengamatan satu ke lokasi pengamatan lainnya, sehingga nilai matriks bobot yang dihasilkan pada tiap lokasi berbeda. Hal tersebut mengindikasikan bahwa penentuan bobot lokasi merupakan salah satu faktor penting dalam membentuk suatu model GSTAR

Pengaplikasian model GSTAR dalam data runtun waktu multivariat, salah satunya adalah pada data curah hujan. Hujan merupakan butir air yang jatuh dari atmosfer karena telah terjadinya proses kondensasi uap air yang dipengaruhi oleh iklim. Keberadannya sangat penting dalam kehidupan makhluk hidup di bumi untuk memenuhi kebutuhan air. Hal ini sangat berkaitan erat dengan provinsi dengan penduduk terbanyak, salah satunya Jawa Timur. Kota Batu merupakan salah satu kota di Provinsi Jawa Timur, sehingga informasi tentang curah hujan sangat berguna bagi penduduknya untuk memulai aktivitas di luar rumah.

Pada fenomena hujan terdapat banyak pelajaran yang dapat diambil. Salah satunya adalah kasih sayang Allah yang begitu luas sehingga menjadikan hujan sebagai turunya rahmat Allah bagi seluruh makhluk-Nya. Sebagaimana yang telah Allah jelaskan dalam firman-Nya pada surah Az-Zukhruf ayat 11 yang berbunyi:

وَالَّذِي نَزَّلَ مِنَ السَّمَاءِ مَاءً بِقَدَرٍ فَأَنْشَرْنَا بِهِ بَلْدَةً مَيْتًا ۚ كَذَلِكَ تُخْرَجُونَ

“Dan Yang menurunkan air dari langit menurut kadar (yang diperlukan) lalu Kami hidupkan dengan air itu negeri yang mati, seperti itulah kamu akan dikeluarkan (dari dalam kubur).

Pada ayat tersebut dijelaskan bahwa banyak manfaat yang didapat dari fenomena hujan. Negeri yang awalnya mati, tandus dan kering, oleh Allah dijadikan negeri tersebut hidup dengan turunya hujan. Tanah yang awalnya tandus menjadi

tanah yang subur dan dapat tumbuh di atasnya tumbuh-tumbuhan. Hewan-hewan yang kehausan dapat menghapuskan dahaganya dengan Allah turunkan hujan kepadanya. Itu semua karena rahmat Allah dengan segala kasih sayang-Nya kepada makhluk-Nya menjadikan turunnya hujan sebagai berkah. Meskipun seringkali hamba-Nya masih berbuat maksiat kepada-Nya, tetapi Allah tetap tidak pandang bulu dalam memberikan rasa kasih sayang-Nya. Tentunya masih banyak lagi pelajaran, hikmah, dan manfaat yang diperoleh dari fenomena hujan bagi mereka yang mau bertafakur tentang hujan. Berdasarkan hal itulah, mendorong penulis untuk melakukan penelitian dengan mengangkat judul. “Implementasi Model *Generalized Space Time Autoregressive* musiman pada Curah Hujan di Kota Batu”.

Beberapa penelitian serupa juga dilakukan Irawati & Yasin (2015) dengan judul “Peramalan Indeks Harga Konsumen 4 Kota di Jawa Tengah Menggunakan Model *Generalized Space Time Autoregressive* (GSTAR)”.

Penelitian ini membahas model GSTAR terbaik dan hasil peramalan pada data Indeks Harga Konsumen (IHK) di Purwokerto, Solo, Semarang, dan Tegal. Hasil penelitian tersebut diperoleh model terbaik adalah GSTAR $(1_1)I(1)$ menggunakan bobot normalisasi korelasi silang. Dari model yang diperoleh disimpulkan bahwa hanya IHK Purwokerto yang dipengaruhi waktu-waktu sebelumnya atau tidak dipengaruhi kota lain, namun dapat mempengaruhi kota lain. Sebaliknya, IHK Surakarta, Semarang, dan Tegal saling mempengaruhi. Penelitian selanjutnya dilakukan oleh Adam dkk (2017) yang berjudul “Penerapan Model GSTAR (1,1) Untuk Data Curah Hujan”. Data curah hujan yang digunakan pada penelitian tersebut adalah Kota Sintang dan model GSTAR yang digunakan adalah GSTAR (1_1) metode *Ordinary Least Square* (OLS) untuk bobot *invers* jarak.

Penelitian serupa dengan menambahkan unsur musiman pada model juga dilakukan oleh Ronny dkk (2015) dengan judul “Pemodelan *Generalized Space Time Autoregressive (GSTAR) Seasonal* pada Data Jumlah Wisatawan Mancanegara Empat Kabupaten di Jawa Tengah”. Penelitian ini membahas model GSTAR dengan unsur musiman terbaik dan hasil peramalan pada data jumlah wisatawan mancanegara di Kabupaten Magelang, Wonosobo, Surakarta, dan Karanganyar. Berdasarkan perbandingan nilai RMSE terkecil didapatkan model terbaik yaitu $GSTAR(1_1) - I(1)^{12}$ dengan kedatangan wisatawan internasional di Surakarta dipengaruhi oleh wisatawan mancanegara di kabupaten lain. Penelitian selanjutnya tentang model *Seasonal Generalized Space Time Autoregressive (SGSTAR)* juga dilakukan oleh Aisha dkk (2016) dengan judul “Pemodelan *Seasonal Generalized Space Time Autoregressive (SGSTAR)* (Studi kasus: Produksi Padi di Kabupaten Demak, Boyolali, dan Grobogan)”. Hasil penelitian tersebut didapatkan model terbaik adalah $GSTAR(3_1) - I(1)^3$ dengan bobot lokasi seragam. Model tersebut menunjukkan bahwa setiap lokasi dipengaruhi oleh lokasi itu sendiri. Penelitian serupa dengan pengaplikasian pada objek curah hujan dilakukan oleh Eko dkk (2019) dengan judul “Pemodelan *Generalized Space Time Autoregressive (GSTAR) Seasonal* pada Data Curah Hujan Empat Kabupaten di Jawa Tengah”. Empat kabupaten yang dimaksud diantaranya yaitu Kabupaten Jepara, Kudus, Pati dan Grobogan. Hasil penelitian tersebut berdasarkan nilai RMSE terkecil diperoleh model terbaik yaitu $(1_1) - I(1)^{12}$ dengan bobot lokasi *invers* jarak. Hubungan antara lokasi ditunjukkan pada curah hujan di Kabupaten Pati dipengaruhi oleh curah hujan di kabupaten lain.

1.2 Rumusan Masalah

Adapun rumusan masalah pada penelitian ini adalah sebagai berikut:

1. Bagaimana model GSTAR curah hujan di Kota Batu dengan bobot lokasi seragam dan *invers* jarak?
2. Bagaimana akurasi perbandingan model GSTAR dengan bobot lokasi seragam dan *invers* jarak?

1.3 Tujuan Penelitian

Adapun tujuan pada penelitian ini adalah sebagai berikut:

1. Mendeskripsikan dan menganalisis model GSTAR dalam memodelkan data curah hujan di Kota Batu.
2. Menentukan bobot lokasi terbaik pada model GSTAR dengan membandingkan nilai akurasi.

1.4 Manfaat Penelitian

1. Sebagai bahan masukan dan informasi oleh peneliti selanjutnya jikalau menggunakan metode serupa.
2. Menerapkan ilmu yang sudah dipelajari selama masa perkuliahan untuk melatih kemampuan di masa yang akan datang di dunia kerja.
3. Membantu masyarakat sekitar dalam memahami pola curah hujan di Kota Batu sehingga dapat mengantisipasi dampak yang tidak diinginkan

1.5 Batasan Masalah

Adapun batasan masalah pada penelitian ini adalah sebagai berikut:

1. Data pada penelitian ini adalah data curah hujan pada periode Januari 2019 hingga September 2023 di 3 kecamatan di Kota Batu, yaitu Kecamatan Batu, Bumiaji, dan Junrejo.
2. Pembobot lokasi yang digunakan adalah bobot invers jarak dan seragam.
3. Estimasi parameter yang digunakan adalah *Ordinary Least Square* (OLS).
4. Identifikasi orde spasial dibatasi hanya pada orde satu.

BAB II

KAJIAN TEORI

2.1 Data Time Series

Time series diartikan sebagai rangkaian data yang diperoleh dari hasil pengamatan pada suatu peristiwa dengan urutan waktu tertentu. *Time series* digolongkan ke dalam peramalan kuantitatif karena *time series* menggunakan data historis di dalam analisisnya. *Time series* terbagi menjadi dua, yaitu *univariate* dan *multivariate* berdasarkan jumlah variabel yang diamati.


Berbeda dengan *univariate time series* yang merupakan data urutan dari deret waktu yang diukur dari waktu ke waktu pada interval yang beragam dan hanya terdiri dari satu data variabel dependen pada data yang diamati. Sedangkan *multivariate time series* adalah model yang mendeskripsikan korelasi antara beberapa variabel dari waktu ke waktu pada interval yang beragam. Menurut (Wei, 2006) *multivariate time series* merupakan serangkaian data yang terdiri atas beberapa variabel yang diperoleh dari waktu ke waktu pada suatu kejadian dengan interval waktu yang sama. Beberapa proses pada *multivariate time series* sama seperti halnya dengan proses pada *univariate time series* yaitu dengan menentukan kestasioneran data.

2.2 Kestasioneran


Stasioner merupakan kondisi dimana data tidak terdapat perubahan yang signifikan pada rata-rata dan varian, atau dapat dikatakan data tidak mengalami *tren* naik maupun turun. (Widarjono, 2009) menyatakan bahwa data dikatakan stasioner jika:

1. $E(Y_t) = \mu$ (rata-rata konstan).
2. $Var(Y_t) = E(Y_t - \mu)^2 = \sigma^2$, varians Y konstan.
3. $Cov(Y_t, Y_{t+k}) = [(Y_t - \mu)(Y_{t+k} - \mu)] = Y_k$.

Plot data runtun waktu dapat memberikan informasi pada peneliti tentang kestasioneran suatu data. Suatu data stasioner terhadap rata-rata jika hasil plotnya menunjukkan hasil horizontal. Hal ini dapat diketahui dengan melihat plot data yang rata-ratanya menunjukkan kondisi ketetapan pada nilai rata-rata yang konstan. Kondisi ini menandakan ketidakbergantungan pada waktu maupun variansi yang berubah-ubah.



Gambar 2.1 Contoh Plot Data yang Tidak Stasioner



Gambar 2.2 Contoh Plot Data yang Stasioner

Data yang stasioner terhadap rata-rata terlihat dari tidak adanya tren naik maupun turun, sehingga tidak perlu dilakukan *differencing* untuk menstasionerkan data. Sedangkan untuk varian, data dikatakan stasioner terhadap varian jika plot

data konstan dan tidak terdapat fluktuasi yang berubah-ubah dari waktu ke waktu. Data yang tidak stasioner terhadap rata-rata perlu penanganan agar data menjadi stasioner terhadap rata-rata. Solusi dari data yang tidak stasioner terhadap rata-rata adalah differensiasi data.

2.2.1 Differencing

Differencing dapat membantu menstabilkan rata-rata runtun waktu dengan menghilangkan perubahan pada tingkat runtun waktu, dan dengan demikian menghilangkan atau mengurangi tren atau musiman. *Differencing* diartikan sebagai suatu proses menghitung selisih nilai data dari periode data dengan data periode sebelumnya. Rumus *differencing* data didefinisikan sebagai berikut:

$$y'_t = y_t - y_{t-s} \quad (2.1)$$

dimana:

y'_t : Nilai dari variabel Y pada waktu t yang sudah terdifferencing.

s : Periode musiman.

Jika data yang sudah didifferencing masih belum stasioner terhadap rata-rata maka perlu didifferencing lagi sebanyak d-kali hingga data menjadi stasioner. Hal ini dikarenakan tahap differensiasi merupakan tahapan olah data dengan menghitung nilai perbedaan antara Y_t dan Y_{t-1} sehingga dapat dipastikan bahwa unsur *tren* akan hilang. Namun, ada beberapa kasus yang unsur *tren*-nya belum hilang setelah dilakukan *differencing*. Oleh karena itu perlu dilakukan differencing pada data yang telah differencing sebelumnya. Tetapi perlu diketahui bahwa *differencing* yang dilakukan berulang kali tidaklah disarankan. Pada umumnya paling banyak dilakukan *differencing* adalah dua kali. Hal ini

disebabkan jika semakin tinggi tingkat *differencing* yang dilakukan, maka model akan semakin kompleks (Chang & Dickey, 1994). Jika *differencing* kedua tidak berhasil menjadikan data stasioner, mungkin ada baiknya jika dilakukan transformasi data terlebih dahulu sebelum *didifferencing*. Jika dituliskan secara matematis maka *differencing* diperoleh sebagai berikut:

$$y'_t = (y_t - y_{t-1}) - (y_{t-1} - y_{t-2}) \quad (2.2)$$

Menurut (Makridakis et al., 1998) notasi yang mempengaruhi untuk memindahkan data dari satu periode ke belakang ialah notasi B pada y_t , dimana B merupakan Operator *Backshift* yang diidentifikasi sebagai $By_t = y_{t-1}$. Notasi ini memudahkan dalam penulisan rumus differensiasi. Maka jika ditulis dengan operator *backshift* diperoleh sebagai berikut:

$$Y'_t = (1 - B)^d y_t \quad (2.3)$$

dengan:

Y'_t : Nilai data aktual setelah *didifferensiasi*

d : Banyaknya *differensiasi*

y_t : Nilai data aktual pada periode ke- t

2.2.2 Transformasi

Selain stasioner terhadap rata-rata, data juga harus stasioner terhadap varian. Suatu data dikatakan stasioner terhadap varian jika fluktuasi data tetap dari waktu ke waktu atau tidak terdapat fluktuasi data yang besar. Data yang tidak stasioner terhadap varian diperlukan transformasi data (Wei, 2006). Untuk mengetahui data stasioner terhadap varian dapat diketahui dengan melihat grafik transformasi *box-cox*. Dalam grafik transformasi *box-cox* terdapat nilai *rounded value* (disimbolkan

λ) yang harus bernilai 1, jika nilai *rounded value* belum bernilai 1 maka data belum stasioner terhadap varian dan harus ditransformasi lagi sampai nilai *rounded value*-nya bernilai 1. Apabila $\lambda = 1$ maka data tidak perlu ditransformasi (Makridakis, dkk., 1998). Untuk suatu parameter λ , tranformasi *box-cox* didefinisikan sebagai berikut:

$$g(y) = \begin{cases} \frac{y_t^\lambda - 1}{\lambda}, \lambda \neq 0 \\ \log(y), \lambda = 0 \end{cases} \quad (2.4)$$

dimana:

$g(y)$: Nilai transformasi *box-cox*

y_t^λ : Nilai data aktual pada periode ke- t

λ : Nilai parameter

Nilai parameter (λ) dapat digunakan sebagai acuan transformasi data.

Adapun nilai λ yang dapat digunakan adalah sebagai berikut:

Tabel 2.1 Parameter Transfromasi Beserta Transformasinya

Parameter Transformasi	Transformasi
0	$\ln Y_t$
0.5	$\sqrt{Y_t}$
1	Y_t

Cara lain untuk mengetahui kestasioneran data dapat dilakukan dengan uji akar unit (*unit rood test*). Sebuah unit root adalah parameter *Autoregressive* (AR) dari model statistik deret waktu bernilai 1. Pada penelitian ini digunakan salah satu jenis uji akar unit (*unit rood test*) yaitu *Augmentsed Dickey Fuller* (ADF). Uji ADF pertama kali diperkenalkan oleh Dickey dan Fuller pada tahun 1979 dan merupakan pengujian kestasioneran data dengan mengetahui apakah terdapat

unsur akar unit (*unit root*) pada data *time-series* atau tidak (Nurchayani, 2016). Jika terdapat akar unit pada data, maka data tersebut tidak stasioner. Persamaan uji ADF adalah sebagai berikut:

$$\Delta Y_t = \alpha_0 + \gamma y_{t-1} + \beta_i \sum_{i=1}^p \Delta y_{t-i+1} + \varepsilon_t \quad (2.5)$$

dimana:

ΔY_t : Bentuk dari *first difference*.

y_{t-1} : Data aktual pada waktu ke- t-1.

β_i : Parameter.

α_0 : *Intercept*.

p : Jumlah *lag*.

ε_t : *Error* pada waktu ke- t.

Pada model Generalized Space Time Autoregressive (GSTAR) uji stasioneritas dapat dilakukan dengan melihat plot *Matrix Autocorrelation Function* (MACF) dan plot *Matrix Partial Autocorrelation Function* (MPACF). Data dikatakan stasioner terhadap rata-rata jika plot MACF dan MPACF turun secara lambat (*dies down exponential*), maka data tidak perlu dilakukan *differencing* untuk menstasionerkan data. Sedangkan untuk varian, data dikatakan stasioner terhadap varian jika plot data konstan dan tidak terdapat fluktuasi yang berubah-ubah dari waktu ke waktu. Data yang tidak stasioner terhadap varian diperlukan transformasi data (Wei, 2006).

2.2.3 Matrix Autocorrelation Function (MACF) dan Matrix Partial

Autocorrelation Function (MPACF)

MACF merupakan salah satu uji kestasioneran data multivariat dengan mengidentifikasi batas orde vektor *moving average* (MA) sebagai matriks korelasi. Bila matriks korelasi setelah *lag* ke- q bernilai nol, maka model yang sesuai adalah MA(q). Persamaan *Matrix Autocorrelation Function* (MACF) didefinisikan sebagai berikut:

$$\hat{\rho}(k) = [\hat{\rho}_{ij}(k)] \quad (2.6)$$

Dengan $\hat{\rho}_{ij}(k)$ adalah korelasi silang sampel untuk komponen deret ke- i dan ke- j yang dinyatakan dalam persamaan berikut:

$$\hat{\rho}_{ij}(k) = \frac{\sum_{t=1}^{T-k} (Z_{i,t} - \bar{Z}_i)(Z_{j,t-k} - \bar{Z}_j)}{\left[\sum_{t=1}^{T-k} (Z_{i,t} - \bar{Z}_i)^2 \sum_{t=1}^{T-k} (Z_{j,t} - \bar{Z}_j)^2 \right]^{\frac{1}{2}}} \quad (2.7)$$

Dimana $\bar{Z}_i$ dan $\bar{Z}_j$ adalah rata-rata sampel dari komponen deret yang bersesuaian. $\hat{\rho}_{ij}(k)$ adalah varian dan kovarian dari korelasi silang sampel deret waktu ke- i dan ke- j pada lag k , sedangkan $Z_{i,t}$ dan $Z_{j,t}$ masing-masing adalah data pengamatan di lokasi i dan data pengamatan di lokasi j pada waktu ke- t .

Pada MACF semakin besar nilai vektor dan dimensinya maka akan semakin kompleks dan rinci bentuk matriks dan grafiknya. Hal tersebut tentunya akan menyulitkan dalam proses penganalisaan. Wei (2006) memiliki metode yang memudahkan proses penganalisaan dengan cara menggunakan simbol yang dinotasikan dengan $(.)$, $(-)$, dan $(+)$ pada matriks korelasi sampel i dan j . Untuk keterangan masing-masing simbol didefinisikan sebagai berikut:

- (.) : Nilai $\hat{\rho}_{ij}(k)$ diantara ± 2 kali standar error (tidak korelasi)
- (-) : Nilai $\hat{\rho}_{ij}(k)$ kurang dari -2 kali standar error (korelasi negatif)
- (+) : Nilai $\hat{\rho}_{ij}(k)$ lebih besar dari 2 kali standar error (korelasi positif)

Fungsi matriks korelasi parsial (Matrix Partial Autocorrelation Function) digunakan untuk mengidentifikasi orde autoregressive (AR). Korelasi antara Z_t dan Z_{t+k} bisa diketahui setelah ketergantungan linier pada masing-masing peubah dihilangkan. MPACF pada lag ke-s dinotasikan dengan $\rho(s)$ dan diartikan sebagai koefisien matriks terakhir jika data diaplikasikan pada model VAR(s). Hal ini merupakan perkembangan daripada kasus univariate, sehingga $\rho(s) = \phi_{kk}$ pada kasus multivariate dan didefinisikan sebagai berikut (Wei, 2006):

$$\phi_k = \frac{\text{cov}[(Z_t - \hat{Z}_t), (Z_{t+k} - \hat{Z}_{t+k})]}{\sqrt{\text{var}(Z_t - \hat{Z}_t)} \sqrt{\text{var}(Z_{t+k} - \hat{Z}_{t+k})}} \quad (2.8)$$

Pada kasus univariate time series, partial autocorrelation function (PACF) akan terputus setelah lag ke-p pada model vector autoregressive(p). Sama halnya dengan kasus multivariate time series, dimana MPACF juga akan terputus setelah lag ke-p dalam model VAR(p). Sama seperti pada kasus univariate, untuk identifikasi model pada kasus multivariate juga dapat dilihat dari pola atau matrix partial autocorrelation function (MPACF) dan matrix autocorrelation function (MACF) (Wei, 2006).

2.3 Generalized Space Time Autoregressive (GSTAR)

Model *Generalized Space Time Autoregressive* (GSTAR) termasuk ke dalam salah satu metode analisis data *multivariate time series*, dimana model ini merupakan suatu model yang berhubungan atau berkaitan dengan waktu dan lokasi pengamatan. Model GSTAR sendiri merupakan jalan keluar dari model STAR yang lokasi pengamatannya diasumsikan sama. Oleh karena itu, model GSTAR lebih fleksibel daripada model STAR, karena pada model STAR parameter lokasinya bersifat homogen, sedangkan pada model GSTAR parameter lokasi pengamatannya dapat menyesuaikan atau berubah-ubah. Dengan kata lain lokasi pengamatan pada model GSTAR bersifat heterogen. Persamaan model $GSTAR(p_{\lambda_1, \lambda_2, \dots, \lambda_p})$ didefinisikan sebagai berikut (Fransiska, dkk., 2020):

$$\overrightarrow{Z_n(t)} = \sum_{k=1}^p [\Phi_{k0} + \sum_{l=1}^{\lambda p} \Phi_{kl} W^{(l)}] + Z(t-k) + \overrightarrow{\varepsilon}_t \quad (2.9)$$

dimana:

$\overrightarrow{Z_n(t)}$: Vektor pengamatan pada waktu ke-t lokasi ke-n ($n \times 1$).

λp : Orde spasial variabel endogen dengan dejabat s.

$\overrightarrow{\Phi_{k0}}$: Vektor intersep atau matriks diagonal parameter autoregressive dengan $diag(\phi_{k0}^1, \dots, \phi_{k0}^n)$.

Φ_{kl} : Matriks koefisien variabel endogen pada lag ke-k dan lag spasial l berukuran $p \times p$ $diag(\phi_{k1}^1, \dots, \phi_{k1}^p)$.

$W^{(l)}$: Matriks pembobot spasial ($n \times n$), sehingga $w_{ij} = 0$ dan $\sum_{i \neq j} w_{ij} = 1$.

$\overrightarrow{\varepsilon}_t$: Vektor galat pada waktu ke-t dengan ukuran ($n \times 1$).

Jika data mengandung pola musiman, maka model yang digunakan adalah model *Seasonal Generalized Space Time Autoregressive* (SGSTAR). Pada model

ini dimasukkan unsur musiman pada model GSTAR. Secara matematis model SGSTAR($(p; \lambda_1, \lambda_2, \dots, \lambda_p)^s$) didefinisikan sebagai berikut (Shaliha Mansoer & Wilandari, 2016):

$$\begin{aligned} \overrightarrow{Z_n(t)} = \sum_{k=1}^p [\Phi_{k0} Z(t-k) + \sum_{l=1}^{\lambda_p} \Phi_{kl} W^{(l)} Z(t-1) \\ + \Phi_{k0}^s Z(t-s) + \sum_{l=1}^{\lambda_k} \Phi_{kl}^s W^{(l)} Z(t-s)] + \overrightarrow{\varepsilon_t} \end{aligned} \quad (2.10)$$

Dengan Φ_{k0}^s adalah matriks parameter waktu periode musiman s , sedangkan Φ_{kl}^s adalah matriks parameter spasial periode musiman s .

2.3.1 Uji Pengaruh Spasial

2.3.1.1 Uji Autokorelasi Spasial

Uji autokorelasi merupakan alat uji untuk menentukan ada atau tidaknya korelasi pada *error* dalam suatu data aktual ke- i terhadap *error* data periode ke- $i-1$. Dengan kata lain uji ini mengukur keeratan hubungan antara 2 variabel yang bersifat kuantitatif, karena variabel independen dan dependen dapat menjadi hubungan positif, negatif, atau bahkan tidak berhubungan. Permasalahan autokorelasi mengakibatkan $Cov(\varepsilon_t, \varepsilon_{t-s}) \neq 0$, hal ini dapat menimbulkan korelasi antar *error* dari suatu data aktual dengan data aktual lainnya (Risza, dkk., 2018). Ketika terjadi autokorelasi maka akan menghasilkan matriks varian-kovarian *error* sebagai berikut:


$$V^* = E[\varepsilon \varepsilon'] = \begin{bmatrix} \sigma^2 & \sigma_{12} & \cdots & \sigma_{1n} \\ \sigma_{21} & \sigma^2 & \cdots & \sigma_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{n1} & \sigma_{n2} & \cdots & \sigma^2 \end{bmatrix} \quad (2.11)$$

Jika tidak terjadi autokorelasi diantara *error* pada matriks varian-kovarian *error*, maka elemen-elemen matriks tersebut selain diagonal utama

bernilai 0. Salah satu metode untuk melakukan uji autokorelasi adalah dengan menggunakan metode Uji Durbin Watson yang didefinisikan sebagai berikut (Risza et al., 2018):

$$d = \frac{\sum_{t=2}^n (e_t - e_{t-1})^2}{\sum_{t=1}^n e_t^2} \quad (2.12)$$

Dengan statistik uji dalam bentuk visual sebagai berikut:



Dengan keterangan sebagai berikut:

- $0 < d < d_L$: autokorelasi positif.
- $4 - d_L < d < 4$: autokorelasi negatif.
- $2 < d < 4 - d_U$ atau $d_U < d < 2$: tidak ada korelasi.
- $d_L \leq d \leq d_U$ atau $4 - d_L \leq d \leq 4 - d_L$: tidak dapat disimpulkan.

2.3.1.2 Uji Heterogenitas Spasial

Uji ini disebabkan karena terdapat perbedaan karakteristik antar lokasi pengamatan. Uji ini digunakan untuk mengetahui keragaman lokasi pengamatan. Seperti yang telah dijelaskan bahwa model GSTAR merupakan model dengan lokasi pengamatan yang bersifat heterogen. Metode yang digunakan untuk melakukan uji heterogenitas spasial adalah indeks gini. Uji hipotesis yang digunakan adalah sebagai berikut:

H_0 : lokasi pengamatan bersifat homogen.

H_1 : lokasi pengamatan bersifat heterogen.

H_0 ditolak jika $G_i = 1$ dengan keterangan statistik uji yang digunakan adalah sebagai berikut (Balqis, dkk., 2020):

$$G_i = 1 + \frac{1}{n} - \frac{2}{(n^2 \hat{y}_i)} \sum_{i=1}^N Y_i \quad (2.13)$$

dimana:

Y_i : Nilai data yang diamati.

$\hat{y}_i$: Rata-rata nilai data yang diamati.

n : Jumlah data sampel.

N : Jumlah variabel yang diamati.

2.3.2 Penentuan Orde Model SGSTAR

Pada tahap penentuan orde model SGSTAR akan digunakan orde model VAR(p). Identifikasi model VAR dapat ditentukan dengan nilai lag optimum. Pada persamaan (2.6) *lag* disimbolkan dengan p , sehingga panjang persamaan tergantung dari lag yang didapat. Semakin besar panjang lag maka semakin panjang persamaan model VAR yang diperoleh dan semakin banyak pula jumlah parameter yang harus diduga. Oleh karena itu akan dipilih nilai lag yang optimal pada model VAR. Penentuan lag optimum dapat menggunakan AIC (*Akaike Information Criterion*). Lag optimal ada pada nilai terkecil yang didapat dari perhitungan nilai AIC. Untuk persamaan AIC (*Akaike Information Criterion*) sendiri adalah sebagai berikut (Wutsqa et al., 2012):

$$AIC(P) = \ln[\hat{\Sigma}_p] + \frac{2}{T} p K^2 \quad (2.14)$$

dimana:

K : Banyak variabel.

T : Banyaknya pengamatan.

$\hat{\Sigma}_p$: Matriks dugaan varian-kovarian residual.

2.3.3 Pemilihan Bobot Lokasi Pada model SGSTAR

$W^{(k)}$ pada model GSTAR merupakan matriks pembobot dengan ukuran $n \times n$. pembobot yang dipilih harus memenuhi syarat $w_{ii}^{(k)} = 0$ dan $\sum_{i \neq j} w_{ii}^{(k)} = 1, 2, \dots, n$. Karena lokasi pengamatan data bersifat heterogen, maka diperlukan standarisasi. Oleh karena itu, bobot jumlah pada semua entri di setiap barisnya harus bernilai satu. Pemilihan bobot lokasi merupakan tahap yang penting pada penentuan model GSTAR. Tingkat kesalahan terkecil pada pembobot yang membentuk model merupakan pembobot yang baik untuk digunakan. Pada tahap ini berguna untuk menentukan model pada setiap lokasi pengamatan. Macam-macam bobot adalah sebagai berikut:

1. Bobot Seragam

Bobot seragam sering diartikan sebagai data yang lokasi pengamatannya sama atau berdekatan. Dapat diartikan lokasi pengamatan pada model diasumsikan sama atau bersifat homogen, sehingga nilai bobot pada tiap lokasi bernilai sama. Bobot seragam didefinisikan dalam persamaan berikut (Diani dkk 2013):

$$W_{ij} = \frac{1}{n_i}, \quad (2.15)$$

dimana pada $\frac{1}{n_i}, i \neq j$ dengan n_i merupakan jumlah lokasi yang berdekatan dengan lokasi i .

2. Bobot Biner

Bobot biner mempunyai pembobot dengan $w_{ij} = 0$ atau 1. Jika secara geografis jarak lokasi yang dekat bernilai 1, sedangkan terjauh bernilai 0.

3. Bobot Invers Jarak

Pemilihan bobot menggunakan bobot invers merupakan pemilihan bobot yang didasarkan pada jarak sebenarnya antar lokasi. Sehingga pembobot ini mempertimbangkan koordinat bujur dan lintang pada lokasi. Setelah didapatkan jarak asli antar lokasi, maka penentuan nilai bobot didapatkan dari normalisasi nilai invers jarak tersebut. Oleh karena itu, besar nilai bobot bergantung pada jarak, semakin dekat jaraknya maka semakin besar nilai koefisiennya dan begitu pula sebaliknya. Pembobot invers jarak didefinisikan sebagai berikut:

$$w_{ij} = \frac{w_{ij}^*}{\sum_{k=1}^p w_{ij}^*} \quad (2.16)$$

dimana:

$$w_{ij}^* = \begin{cases} \frac{1}{d_{ij}}, & i \neq j \\ 0, & i = j \end{cases} \quad (2.17)$$

dengan d_{ij} dapat dirumuskan mengikuti persamaan garis linier berikut:

$$d_{ij} = \sqrt{(u_i - u_j)^2 + (v_i - v_j)^2} \quad (2.18)$$

Dimana d_{ij} adalah jarak dari lokasi i ke lokasi j , $(u_i - u_j)$ dan $(v_i - v_j)$ berturut-turut adalah garis lintang dan garis bujur. Jika diinterpretasikan dengan matriks akan menghasilkan sebagai berikut:

$$\begin{bmatrix} 0 & \frac{r_1}{r_1 + r_2} & \frac{r_2}{r_1 + r_2} \\ \frac{r_1}{r_1 + r_3} & 0 & \frac{r_3}{r_1 + r_3} \\ \frac{r_3}{r_2 + r_3} & \frac{r_2}{r_2 + r_3} & 0 \end{bmatrix} = \begin{bmatrix} 0 & W_{12} & W_{13} \\ W_{21} & 0 & W_{23} \\ W_{31} & W_{32} & 0 \end{bmatrix} \quad (2.19)$$

dimana:

r_1 = Jarak lokasi 1 ke lokasi 2.

r_2 = Jarak lokasi 1 ke lokasi 3.

r_3 = Jarak lokasi 2 ke lokasi 3.

4. Bobot Normalisasi Korelasi Silang

Pemilihan bobot ini secara garis besar merupakan normalisasi hasil korelasi silang antara lokasi pada *lag* yang sama. Korelasi silang antar lokasi pengamatan ke-*i* dan ke-*j* pada *lag* yang bersesuaian yaitu (*k*) didefinisikan sebagai berikut:

$$\rho_{ij}(k) = \frac{\gamma_{ij}(k)}{\sigma_i \sigma_j}, k = 0, \pm 1, \pm 2, \pm 3, \dots \quad (2.20)$$

$\gamma_{ij}(k)$ adalah korelasi silang antar lokasi pengamatan pada *lag* yang sama.

$\sigma_i \sigma_j$ merupakan standar deviasi pada lokasi pengamatan. Untuk pendugaan atau penaksir parameter nilai korelasi silang didefinisikan sebagai berikut

(Diani dkk 2013):

$$r_{ij}(k) = \frac{\sum_{t=k+1}^n (Z_i(t) - \bar{Z}_i)(Z_j(t-k) - \bar{Z}_j)}{\sqrt{(\sum_{t=1}^n (Z_i(t) - \bar{Z}_i)^2 \sum_{t=1}^n (Z_j(t) - \bar{Z}_j)^2)}} \quad (2.21)$$

Untuk menentukan pembobot lokasi dengan cara korelasi silang antar lokasi pengamatan dengan *lag* yang bersesuaian untuk model GSTAR dapat dirumuskan sebagai berikut:

$$w_{ij} = \frac{r_{ij}(k)}{\sum_{j \neq i} |r_{ij}(k)|} \quad (2.22)$$

dengan $j \neq i$ dan $\sum_{j \neq i} |r_{ij}(k)| = 1$.

2.3.4 Estimasi Parameter pada Model SGSTAR

Model GSTAR termasuk ke dalam model linier, dimana dapat dilakukan dengan metode *Ordinary Least Square* (OLS) untuk mengestimasi parameter pada model. OLS sendiri merupakan salah satu cara estimasi nilai koefisien dalam model regresi dengan cara meminimalkan hasil kuadrat residual pada data ramalan dengan data aktual. Pada metode ini terdapat beberapa asumsi yang harus terpenuhi, yaitu asumsi *error* berdistribusi normal dan sifat penaksir yang didapat adalah penaksir tak bias. Pada asumsi *error* berdistribusi normal nilai rata-rata dan variansinya berturut-turut adalah 0 dan σ^2 .

Misalkan terdapat sebuah model GSTAR(1,1) untuk seluruh lokasi. Berdasarkan persamaan (2.9), maka bentuk model GSTAR dapat dituliskan dalam bentuk linier sebagai berikut:

$$\vec{Y} = X\vec{\beta} + \vec{\varepsilon} \quad (2.23)$$

jika dituliskan dalam bentuk matriks dapat dinyatakan sebagai berikut:

$$\begin{bmatrix} Z_i(1) \\ Z_i(2) \\ \vdots \\ Z_i(T) \end{bmatrix} = \begin{bmatrix} Z_i(1) & V_i(1) \\ Z_i(2) & V_i(2) \\ \vdots & \vdots \\ Z_i(T-1) & V_i(T-1) \end{bmatrix} \begin{bmatrix} \beta_i(1) \\ \beta_i(2) \\ \vdots \\ \beta_i(T) \end{bmatrix} + \varepsilon_i = \begin{bmatrix} \varepsilon_i(1) \\ \varepsilon_i(2) \\ \vdots \\ \varepsilon_i(T) \end{bmatrix}$$

Dimana $Z_i(T)$ adalah banyaknya pengamatan dengan $t = 1, 2, 3, \dots, T$ untuk lokasi $i = 1, 2, 3, \dots, n$ dan $V_i(T) = \sum_{i \neq j}^n w_{ij} Z_j(t)$ dimana $i \neq j$. Untuk mengestimasi parameter β dapat digunakan metode *Ordinary Least Square* (OLS), dimana pada

metode ini dilakukan proses meminimumkan jumlah *square error* yang definisikan sebagai berikut:

$$\vec{\varepsilon} = \vec{Y} - X\vec{\beta} \quad (2.24)$$

sehingga didapatkan nilai *square error* yang dapat dituliskan sebagai berikut:

$$\sum_{i=1}^n \varepsilon_i^2 = \vec{\varepsilon}^T \vec{\varepsilon} \quad (2.25)$$

$$= (\vec{y} - X\vec{\beta})^T (\vec{y} - X\vec{\beta}) \quad (2.26)$$

$$= \vec{y}^T \vec{y} - \vec{y}^T X\vec{\beta} - \vec{\beta}^T X^T \vec{y} + \vec{\beta}^T X^T X\vec{\beta}$$

$$= \vec{y}^T \vec{y} - 2\vec{\beta}^T X^T \vec{y} + \vec{\beta}^T X^T X\vec{\beta}$$

Untuk meminimumkan *square error* ($\vec{\varepsilon}^T \vec{\varepsilon}$) pada persamaan (2.25), maka dilakukan proses turunan pertama atas $\vec{\beta}$ yang harus bernilai 0. Setelah itu didapatkan persamaan normal yang dinamakan sebagai penaksir *Ordinary Least Squares* (OLS) yang diperoleh sebagai berikut (Aziz, 2007):

$$\vec{\beta} = (\vec{X}^T \vec{X})^{-1} \vec{X}^T \vec{y} \quad (2.27)$$

Setelah didapatkan parameter untuk model GSTAR, maka perlu di uji signifikansi pada parameter yang telah diestimasi. Tujuannya adalah untuk mengetahui seberapa besar pengaruh secara signifikan parameter yang telah didapatkan terhadap model. Parameter yang signifikan adalah ketika parameternya tidak sama dengan nol. Adapun hipotesis yang digunakan adalah sebagai berikut:

$$H_0: \hat{\beta} = 0 \text{ (parameter tidak signifikan)}$$

$$H_1: \hat{\beta} \neq 0 \text{ (parameter signifikan)}$$

dan statistik uji sebagai berikut:

$$t_{hitung} = \frac{\hat{\phi}}{SE\hat{\phi}} \quad (2.28)$$

dimana:

$\hat{\phi}$: Estimasi parameter.

$SE\hat{\phi}$: Standar *error* estimasi parameter.

Kriteria uji yang digunakan adalah H_0 ditolak jika nilai $|t_{hitung}| > t - \text{tabel} \left(t_{\frac{\alpha}{2}, (n-k-1)} \right)$ atau nilai $p < \alpha$. Untuk α adalah taraf nyata (*level of significance*) yang bernilai 0,05.

2.3.5 Uji Kesesuaian Model

Pada tahap ini akan dilakukan dua uji yang menjadi acuan atas kelayakan model yang akan digunakan. Sebuah model GSTAR dikatakan layak jika nilai residualnya bersifat *white noise* dan berdistribusi normal multivariat.

2.3.5.1 Uji *White Noise*

Suatu nilai residual bersifat *white noise* jika variabel tidak terdapat korelasi, rata-rata $E(\varepsilon_t) = \mu_t = 0$, varian konstan ($Var(\varepsilon_t) = \sigma^2$), dan $cov(\varepsilon_t, \varepsilon_{t-k}) = \gamma_k = 0$ untuk $k \neq 0$ (Wei, 2006). Salah satu metode untuk mengetahui kesesuaian pada model adalah dengan mencari nilai *Akaike's Information Criterion* (AIC). Jika residual terkecil tepat berada di *lag* ke-0, maka tidak ada korelasi antar variabel. Artinya, residual mengalami *white noise*. Cara lain untuk mengetahui ada tidaknya *white noise* pada residual adalah dengan menggunakan uji *Ljung-Box* yang didefinisikan sebagai berikut (Wei, 2006):

$$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{(n-k)}, n > k \quad (2.29)$$

Dimana n merupakan banyak pengamatan, k adalah banyaknya *lag*, K adalah *lag* optimum dan $\hat{\rho}_k^2$ merupakan autokorelasi residual pada *lag* ke- k . Uji hipotesis yang digunakan adalah $H_0 : \rho_1, \rho_2, \dots, \rho_k = 0$ (tidak terdapat autokorelasi antar residu/residu *white noise*). H_1 : minimal terdapat satu $\rho_k \neq 0$ (terdapat autokorelasi antar residu/residu tidak *white noise*).

2.3.5.2 Uji Residual Berdistribusi Normal *Multivariate*

Tahap kesesuaian model setelah uji *white noise* adalah uji residual berdistribusi normal *multivariate* atau tidak. Jika plot sebaran residual mendekati garis lurus, maka residual berdistribusi normal *multivariate*. Untuk mengetahui residual berdistribusi normal *multivariate* atau tidak, dapat menggunakan uji *Kolmogorov Smirnov*. Uji hipotesis yang digunakan adalah sebagai berikut:

$H_0 : F(x) = F_0(x)$ (residual berdistribui normal multivariat)

$H_0 : F(x) \neq F_0(x)$ (residual tidak berdistribusi normal multivariat)

dengan statistik uji:

$$D = \sup |F(x) - F_0(x)| \quad (2.30)$$

$F(x)$ menandakan fungsi peluang kumulatif yang didapatkan dari data aktual. Sedangkan $F_0(x)$ menunjukkan fungsi distribusi data yang dihipotesis. Jarak kuadrat mahalanobis (d_i^2) disimbolkan dengan x . Residual dikatakan berdistribusi normal atau terima H_0 jika nilai *p-value* $> 0,05$ dan tidak berdistribusi normal multivariat jika *p-value* $< 0,05$.

2.4 Evaluasi Model

Setelah model persamaan dari VAR dan GSTAR diperoleh, maka akan diuji terkait tingkat keakuratan model. Evaluasi model dapat dijadikan sebagai landasan dalam memilih model terbaik yang akan digunakan dalam peramalan. Model yang keakuratannya tinggi memiliki tingkat kepercayaan yang tinggi pula, sehingga model tersebut bisa dipercaya untuk digunakan pada proses peramalan. Model terbaik merupakan model dengan nilai *error* terkecil. Dalam pengertian model peramalan sendiri pada penelitian kuantitatif adalah meramalkan nilai yang akan datang dengan nilai *error* terkecil. Beberapa cara yang dapat dilakukan dalam menentukan model terbaik diantaranya adalah menghitung nilai *Mean Absolute Percentage Error* (MAPE), dan *Root Mean Square Error* (RMSE).

2.4.1 Mean Squared Error (MSE)

Mean Squared Error (MSE) adalah cara yang dipakai untuk mengetahui kekuratan dalam suatu model yang dihitung dalam bentuk rata-rata persentase mutlak residual. Nilai MSE yang semakin kecil menandakan semakin akurat model dalam melakukan peramalan. Persamaan untuk mengetahui besarnya nilai MSE adalah sebagai berikut (Montgomery, dkk., 2015):

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2 \quad (2.31)$$

dengan n adalah banyaknya ramalan yang dilakukan, sedangkan y_t adalah nilai data pengamatan pada waktu ke- t dan $\hat{y}_t$ adalah data peramalan pada waktu ke- t .

2.4.2 Root Mean Square Error (RMSE)

Root Mean Square Error (RMSE) juga termasuk salah satu cara untuk mengetahui keakuratan pada model, sehingga dapat diketahui tingkat kesalahan pada model dalam peramalan. Semakin kecil nilai RMSE atau mendekati nol, maka semakin akurat hasil peramalan, RMSE digunakan untuk mengukur perbedaan nilai antara data ramalan dari model yang terhadap data aktual. Persamaan untuk menghitung nilai RMSE didefinisikan sebagai berikut:

$$RMSE = \sqrt{\left(\frac{\sum_{t=1}^T y_t - \hat{y}_t}{m}\right)^2} \quad (2.32)$$

dengan m menyatakan banyaknya periode ramalan, y_t adalah data pengamatan pada waktu ke- t , dan $\hat{y}_t$ menyatakan data ramalan pada waktu ke- t .

2.5 Curah Hujan

Menurut Badan Meterologi Klimatologi dan Geofisika, curah hujan adalah tingginya air hujan yang berada di dalam penakar hujan pada tempat yang tidak menyerap dan tidak mengalir. Artinya jumlah bulir air yang turun saat hujan pada suatu daerah dalam waktu tertentu disebut curah hujan. Sedangkan menurut (Tjasyono, 2012), curah hujan adalah hasil dari peristiwa kondensasi cair total yang berasal dari atmosfer yang diukur dalam penakar hujan.

Satuan curah hujan yaitu 1 milimeter (mm), artinya dalam suatu tempat seluas 1 meter persegi yang digunakan untuk menampung air hujan dapat menampung air hujan setinggi 1 milimeter (mm). BMKG menjelaskan jika musim penghujan tiba maka banyaknya curah hujan adalah lebih atau sama dengan 50 mm dalam satu dasarian (10 hari) dan diikuti oleh beberapa dasarian berikutnya.

Sedangkan jika musim kemarau tiba maka banyaknya curah hujan adalah kurang dari 50 mm dalam satu dasarian (10 hari) dan diikuti oleh beberapa dasarian berikutnya. Terdapat beberapa alat yang digunakan untuk mengukur curah hujan yang manual, diantaranya yaitu ombrometer, pluviometer. Sedangkan alat pengukur curah hujan otomatis diantaranya ada Hellman dan Tipping-bucket gauge.

2.6 Konsep Curah Hujan dalam Al-Quran

Hujan yang turun merupakan sebuah bentuk kasih sayang dari Allah pada hambanya, sehingga Ia memberikan rahmat dan berkah dalam turunnya hujan kepada manusia. Seperti yang telah dijelaskan dalam Al-Quran pada Surah Asy-Syura ayat 28 yang berbunyi:

وَهُوَ الَّذِي يُنَزِّلُ الْغَيْثَ مِنْ بَعْدِ مَا قَنَطُوا وَيَنْشُرُ رَحْمَتَهُ وَهُوَ الْوَلِيُّ الْحَمِيدُ
“Dan Dialah yang menurunkan hujan setelah mereka berputus asa dan menyebarkan rahmat-Nya. Dan Dialah Maha Pelindung, Maha Terpuji”

Pada fenomena hujan terdapat banyak pelajaran yang dapat diambil. Salah satunya adalah kasih sayang Allah yang begitu luas sehingga menjadikan hujan sebagai turunnya rahmat Allah bagi seluruh makhluk-Nya. Sebagaimana yang telah Allah jelaskan dalam firman-Nya pada surah Az-Zukhruf ayat 11 yang berbunyi:

وَالَّذِي نَزَّلَ مِنَ السَّمَاءِ مَاءً بِقَدَرٍ فَأَنْشَرْنَا بِهِ بَلْدَةً مَيْتًا كَذَلِكَ تُخْرَجُونَ
“Dan Yang menurunkan air dari langit menurut kadar (yang diperlukan) lalu Kami hidupkan dengan air itu negeri yang mati, seperti itulah kamu akan dikeluarkan (dari dalam kubur).”

Pada ayat tersebut dijelaskan bahwa banyak manfaat yang didapat dari fenomena hujan. Negeri yang awalnya mati, tandus dan kering, oleh Allah dijadikan negeri tersebut hidup dengan turunnya hujan. Tanah yang awalnya tandus menjadi tanah yang subur dan dapat tumbuh di atasnya tumbuh-tumbuhan. Hewan-hewan

yang kehausan dapat menghapuskan dahaganya dengan Allah turunkan hujan kepadanya. Itu semua karena rahmat Allah dengan segala kasih sayang-Nya kepada makhluk-Nya menjadikan turunnya hujan sebagai berkah. Meskipun seringkali hamba-Nya masih berbuat maksiat kepada-Nya, tetapi Allah tetap tidak pandang bulu dalam memberikan rasa kasih sayang-Nya. Tentunya masih banyak lagi pelajaran, hikmah, dan manfaat yang diperoleh dari fenomena hujan bagi mereka yang mau bertafakur tentang hujan.

Semua pemberian dari Allah yang diberikan kepada manusia beriman, baik berupa rahmat, nikmat, berkah, dan anugrah merupakan suatu amanah yang diharuskan untuk mengelolanya, karena Allah telah memberikan kepercayaan terhadap manusia untuk memakmurkan dan menjaga amanah tersebut dengan baik dan benar sehingga tidak akan terjadi sebuah kerusakan di muka bumi. Sebagaimana yang telah Allah firman dalam Al-Qur'an surah Hud ayat 61 yang berbunyi:

وَالِى تَمُودَ أَخَاهُمْ صَالِحًا قَالَ يَاقَوْمِ اعْبُدُوا اللَّهَ مَا لَكُمْ مِنْ إِلَهٍ غَيْرُهُ ۖ هُوَ أَنشَأَكُمْ مِنَ الْأَرْضِ وَاسْتَعْمَرَكُمْ فِيهَا فَاسْتَغْفِرُوا لَهُ ثُمَّ تَوْبُوا إِلَيْهِ ۚ إِنَّ رَبِّي قَرِيبٌ مُجِيبٌ

"Dan kepada Tsamud (Kami utus) saudara mereka Shaleh. Shaleh berkata: "Hai kaumku, sembahlah Allah, sekali-kali tidak ada bagimu Tuhan selain Dia. Dia telah menciptakan kamu dari bumi (tanah) dan menjadikan kamu pemakmurnya, karena itu mohonlah ampunan-Nya, kemudian bertobatlah kepada-Nya, Sesungguhnya Tuhanku amat dekat (rahmat-Nya) lagi memperkenankan (doa hamba-Nya)".

Menurut (Abdillah, 2001) ayat tersebut menjelaskan bahwa manusia diperintahkan untuk memakmurkan bumi, karena manusia yang memiliki potensi dalam menjaga amanah atau mandat yang telah diberikan oleh Allah. Memakmurkan bumi dapat dengan cara melakukan pengelolaan, pembangunan, dan pemeliharaan lingkungan secara benar, karena alam harus dilestarikan dan dijaga supaya tidak punah sehingga dapat dimanfaatkan oleh generasi setelahnya.

Jikalau manusia dapat memakmurkan bumi maka Allah akan menghamparkan bumi yang begitu luas beserta isinya untuk dapat dinikmati.

2.7 Kajian Topik dan Teori Pendukung

Penelitian ini dilakukan dengan beberapa teori pendukung terkait model *Generalized Space Time Autoregressive* dalam memodelkan suatu data *time series*. Beberapa penelitian yang dijadikan rujukan dan teori pendukung, diantaranya yaitu penelitian yang dilakukan oleh Irawati & Yasin (2015) yang berjudul “Peramalan Indeks Harga Konsumen 4 Kota di Jawa Tengah Menggunakan Model *Generalized Space Time Autoregressive* (GSTAR)”. Kota yang dipilih diantaranya yaitu Kota Purwokerto, Solo, Semarang, dan Tegal, dimana masing-masing lokasi pengamatan bersifat heterogen. Pada penelitiannya dijelaskan bahwa hanya IHK Kota Purwokerto saja yang dipengaruhi data sebelumnya tetapi tidak mempengaruhi kota-kota lainnya. Model GSTAR terbaik yang diperoleh adalah model GSTAR (1,1)(1) dengan bobot lokasi yang digunakan adalah normalisasi silang. Penelitian serupa tentang pemodelan *Generalized Space Time Autoregressive* (GSTAR) terhadap data curah hujan, yaitu penelitian yang dilakukan Adam, dkk (2017) dengan judul “Penerapan Model GSTAR (1,1) Untuk Data Curah Hujan”. Pada penelitiannya juga menggunakan metode *Ordinary Least Square* (OLS) untuk estimasi parameternya. Data curah hujan yang digunakan berasal dari beberapa stasiun di Kota Sintang, dimana data pada masing-masing stasiun berpengaruh terhadap satu sama lain. Namun pada peramalan yang dilakukan hanya beberapa stasiun saja yang digunakan, dikarenakan nilai *error* yang tinggi sehingga nilai data ramalan tidak mendekati nilai hasil ramalan.

BAB III

METODE PENELITIAN

3.1 Jenis Penelitian

Penelitian yang dilakukan merupakan penelitian yang bersifat deskriptif kuantitatif. Deskriptif kuantitatif merupakan salah satu teknik penelitian yang digunakan untuk hipotesis berdasarkan perhitungan matematika dan statistik. Data yang digunakan berupa data numerik agar sesuai dengan kebutuhan peneliti. Kemudian data tersebut diolah secara terstruktur untuk menghasilkan informasi yang dapat dipahami oleh pembaca.

3.2 Data dan Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder, yaitu data curah hujan di 3 kecamatan Kota Batu pada bulan Januari 2019 sampai September 2023. Data diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika Jawa Timur yang berlokasi di Karangploso, Kabupaten Malang, Jawa Timur. Data dibagi menjadi 2 yaitu *out-sample* dan *in-sample*. Data *out-sample* berisikan data curah hujan periode Januari 2019 hingga Desember 2022, sedangkan data *in-sample* berisikan data curah hujan pada bulan Januari 2023 hingga September 2023.

Variabel yang digunakan dalam penelitian ini didasarkan pada 3 kecamatan di Kota Batu, adapun 3 variabel tersebut adalah sebagai berikut:

$Z_1(t)$: Curah hujan di Kecamatan Batu.

$Z_2(t)$: Curah hujan di Kecamatan Junrejo.

$Z_3(t)$: Curah hujan di Kecamatan Bumiaji.


3.3 Tahapan Penelitian

Adapun langkah-langkah penelitian ini adalah sebagai berikut:

1. Menjelaskan gambaran umum data dengan melihat statistik deksriptif dan grafik data.
2. Membagi data menjadi data *training* dan data *testing* dengan perbandingan 70:30.
3. Menentukan kestasioneran data dengan plot data dan uji ADF dan plot MACF dengan menggunakan persamaan masing-masing 2.5 dan 2.6.
4. Melakukan uji pengaruh spasial yaitu, uji autokorelasi spasial dengan Durbin Watson pada persamaan 2.12 dan uji keheterogenan lokasi dengan indeks gini menggunakan persamaan 2.13.
5. Menentukan orde dari model SGSTAR yang sesuai dari identifikasi model dengan menggunakan plot MPACF berdasarkan nilai AIC terkecil pada persamaan 2.14.
6. Menetapkan matriks bobot lokasi seragam dan invers jarak yang masing-masing sesuai pada persamaan 2.15 dan 2.19.
7. Mengestimasi parameter pada model SGSTAR dengan metode OLS sesuai persamaan 2.24.
8. Melakukan uji kesesuaian model terhadap residual model SGSTAR dengan uji asumsi *white noise* dan residual berdistribusi normal multivariat, masing-masing sesuai pada persamaan 2.29 dan 2.30.
9. Menguji model terbaik dengan nilai MSE dan RMSE terkecil yang masing-masing sesuai pada persamaan 2.31 dan 2.32.

3.4 Flowchart Penelitian

Flowchart pada penelitian ini adalah sebagai berikut:



Gambar 3. 1 Diagram Alir Model GSTAR

BAB IV

HASIL DAN PEMBAHASAN

4.1 Analisis Deskriptif


Analisa deskriptif bertujuan untuk menjelaskan karakteristik dari data yang diperoleh. Pada hal ini dilakukan analisa deskriptif pada data curah hujan di 3 kecamatan Kota Batu periode Januari 2019 – September 2023. Jumlah data pada penelitian berjumlah 57 data pada masing-masing kecamatan dengan tipe data bulanan. Statistika deskriptif data dideskripsikan secara jelas pada tabel 4.1.

Tabel 4.1 Statistika Deskriptif Data Curah Hujan di 3 Kecamatan Kota Batu Periode Januari 2019 - September 2023

Variabel	Junrejo (mm)	Bumiaji (mm)	Batu (mm)
<i>Minimum</i>	0.0	0.0	0.0
1st Quartil	22.0	42.0	23.0
Median	123.0	168.0	103.0
Mean	175.3	193.1	126.2
3rd Quartil	288.0	312.0	211.0
Standar Deviasi	154.9	163.2	110.4
<i>Maximum</i>	494.0	588.0	395.0

Berdasarkan pada tabel 4.1 dapat diketahui bahwa ditiap kecamatan Kota Batu pada periode Januari 2019 - September 2023 terdapat bulan dimana hampir tidak terjadi hujan. Hal ini dapat dilihat dari nilai minimum di ketiga kecamatan yang bernilai 0 mm. Selain itu pada tabel 4.1 juga dapat dilihat bahwa Kecamatan Bumiaji memiliki rata-rata curah hujan tertinggi dibandingkan dengan kecamatan lainnya, yaitu sebesar 193.1 mm. Hal ini disebabkan karena letak Kecamatan Bumiaji yang lebih tinggi dibandingkan dengan kecamatan lainnya. Ketinggian Kecamatan Bumiaji yaitu 1219 mdpl (meter di atas permukaan laut) sedangkan Kecamatan Junrejo dan Kecamatan Batu masing-masing berada pada ketinggian

878 mdpl dan 915 mdpl, karena faktor ketinggian tersebut Kecamatan Bumiaji lebih sering turun hujan dibandingkan dengan kecamatan lainnya. Hal ini didukung dengan nilai maximum Kecamatan Bumiaji yang juga lebih tinggi dibandingkan dengan nilai maximum kecamatan lainnya, yaitu sebesar 588 mm.



Gambar 4.1 Plot Data Curah Hujan di 3 Kecamatan Kota Batu

Pada gambar 4.1 menjelaskan bahwa secara keseluruhan grafik data curah hujan di 3 kecamatan Kota Batu memiliki pola yang hampir sama. Hal ini dikarenakan lokasi masing-masing kecamatan yang cukup berdekatan. Pada grafik tersebut terlihat curah hujan di 3 kecamatan Kota Batu dari tahun 2019 hingga 2021 mengalami tren naik pada bulan Oktober hingga awal tahun bulan Januari. Setelah itu pada bulan April hingga Mei ditiap tahunnya curah hujan di 3 kecamatan Kota Batu mengalami tren turun. Pada periode Agustus hingga Oktober nilai curah hujan di 3 kecamatan Kota Batu selalu lebih sedikit daripada bulan-bulan lainnya. Hal itu menandakan bahwa pada periode tersebut selalu lebih sedikit turun hujan daripada bulan-bulan lainnya. Bahkan pada bulan Agustus hingga September di tahun 2019 tidak ada hujan yang turun karena data bernilai 0 mm. Data curah hujan di 3

kecamatan Kota Batu mengalami fluktuatif dikarenakan curah hujan memiliki pengaruh musiman, sehingga terdapat tren naik dan tren turun dalam datanya. Pada gambar 4.1 juga dapat ditentukan bahwa orde pengaruh musiman yang dimiliki oleh data curah hujan di 3 kecamatan Kota Batu adalah 6.

4.2 Pembagian Data *Training* dan *Testing*

Sebelum melakukan tahap analisis data, data terlebih dahulu dibagi menjadi data *training* dan *testing*. Data *training* digunakan untuk memodelkan data sedangkan data *testing* digunakan untuk mengevaluasi model yang telah diperoleh. Jumlah data yang diperoleh adalah 57 data yang dibagi menjadi data *training* dan *testing* dengan komposisi masing-masing 70% dan 30%. Dari komposisi tersebut diperoleh bahwa data *training* berjumlah 40 data, mulai dari Januari 2019 hingga April 2022. Sedangkan data *testing* berjumlah 17 data, mulai dari Mei 2022 hingga September 2023.

4.3 Uji Kestasioneran Data

Langkah awal sebelum melakukan analisis model GSTAR, dilakukan uji untuk memenuhi asumsi analisis *time series* yaitu kestasioneran data. Asumsi tersebut digunakan untuk mengetahui kondisi lag dari model yang diuji. Jika data tidak stasioner maka akan dilakukan proses *differencing* agar data menjadi stasioner sehingga dapat dilakukan proses analisis selanjutnya. Uji stasioner pada penelitian ini menggunakan Uji ADF (*Augmented Dickey-Fuller*) dengan hipotesis sebagai berikut:

$H_0 : \gamma = 0$ (Data tidak stasioner)

$H_1 : \gamma \neq 0$ (Data stasioner)

Dengan tingkat signifikansi $\alpha = 5\%$ (0.05) dan dikatakan tolak H_0 jika $p - value \leq \alpha$. Berdasarkan tabel 4.2 uji kestasioneran dengan uji ADF dapat dijelaskan sebagai berikut:

Tabel 4.2 Uji ADF Data Curah Hujan di 3 Kecamatan Kota Batu

Kecamatan	p -value	α	Keputusan	Kesimpulan
Junrejo	0.0003	0.05	Tolak H_0	Data Stasioner
Bumiaji	0.0101	0.05	Tolak H_0	Data Stasioner
Batu	0.0025	0.05	Tolak H_0	Data Stasioner

Berdasarkan tabel 4.2 dapat dijelaskan bahwa hasil uji kestasioneran data curah hujan di 3 kecamatan Kota Batu sudah stasioner di tiap lokasinya. Terlihat dari nilai *p-value* pada tiap lokasi bernilai kurang dari tingkat signifikansi sebesar 5% (0.05). Selain ADF dengan cara uji, stasioneritas data dapat dilihat dengan plot MACF. Untuk data sebelum *differencing* plot MACF menunjukkan bahwa plot MACF masih banyak bermunculan simbol (-) dan (+) di semua *lag* bahkan melebihi ± 2 kali *standard error*, oleh karena itu perlu dilakukan *differencing*. Berikut skema plot MACF setelah dilakukan *differencing*:

Tabel 4.3 Plot MACF Data Curah Hujan di 3 Kecamatan Kota Batu

Schematic Representation of Cross Correlations											
Variable/Lag	0	1	2	3	4	5	6	7	8	9	10
Junrejo	+++	...	...	...	...	...	---	...	...	...	+..
Bumiaji	+++	...	...	...	...	...	---	...	...	...	...
Batu	+++	...	...	...	...	...	-.-	...	...	...	+..

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

Terlihat pada tabel 4.3 plot MACF bahwa tanda (+) dan (-) yang muncul signifikan pada *lag-lag* tertentu saja tidak lebih dari ± 2 kali batas *standard error* secara bersamaan, tapi hanya keluar pada *lag-lag* tertentu saja. Hal ini menunjukkan bahwa data telah stasioner.

4.4 Uji Pengaruh Spasial

4.4.1 Uji Autokorelasi Spasial

Salah satu tahap dari analisis model SGSTAR adalah dengan menguji korelasi data antar variabel. Tujuannya adalah dapat menjelaskan pola hubungan atau korelasi antar lokasi pengamatan. Pada hal ini akan dilakukan uji korelasi pada data curah hujan di 3 kecamatan Kota Batu, sehingga dapat diketahui pola hubungan curah hujan antar lokasi kecamatan. Uji autokorelasi spasial dapat menggunakan uji durbin watson, yang dapat dijelaskan sebagai berikut:

Tabel 4.4 Korelasi Data Curah Hujan di 3 Kecamatan Kota Batu

Mean dependent var	1.000000	S.D. dependent var	0.000000
S.E. of regression	0.654530	Akaike info criterion	2.041398
Sum squared resid	23.13413	Schwarz criterion	2.148927
Log likelihood	-55.17984	Hannan-Quinn criter.	2.083187
Durbin-Watson stat	0.371622		

Terlihat bahwa nilai *Durbin-Watson stat* pada tabel 4.4 sebesar 0.371622. Nilai tersebut terletak diantara 0 dan DL (*durbin lower*). Nilai DL sendiri bernilai 1.4637 yang didapatkan dari tabel durbin watson dengan jumlah observasi dan jumlah variabel masing-masing sebesar 57 dan 3. Dikarenakan nilai durbin watson berada diantara 0 dan DL, maka dapat disimpulkan bahwa data curah hujan di 3 kecamatan Kota Batu terdapat autokorelasi yang bernilai positif. Semakin meningkat nilai data curah hujan di salah satu kecamatan, maka akan

meningkat pula nilai data curah hujan di kecamatan lain. Hal tersebut dijelaskan dapat dijelaskan pada tabel berikut:

Tabel 4.5 Korelasi Curah Hujan di 3 Kecamatan Kota Batu

Variabel	Junrejo	Bumiaji	Batu
Junrejo	1		
Bumiaji (p-value)	0.9285 0.000	1	
Batu (p-value)	0.9393 0.000	0.8931 0.000	1

Pada tabel 4.5 menunjukkan bahwa data curah hujan di 3 kecamatan Kota Batu secara keseluruhan memiliki nilai korelasi *p-value* sebesar 0.000. Artinya ketiga variabel memiliki hubungan yang nyata karena nilai korelasi *p-value* kurang dari $\alpha = 0.05$. Masing-masing nilai korelasi data curah hujan di 3 kecamatan Kota Batu bernilai positif yang menandakan hubungan korelasi tersebut searah atau berbanding lurus. Pada tabel 4.5 juga dapat diketahui bahwa korelasi terbesar data curah hujan ada pada Kecamatan Junrejo dengan Kecamatan Batu yang bernilai 0.9393. Sedangkan korelasi paling kecil ada pada Kecamatan Bumiaji dengan Kecamatan Batu yang bernilai 0.8931.

4.4.2 Uji Heterogenitas Lokasi

Uji heterogenitas lokasi merupakan salah satu uji pengaruh spasial setelah uji autokorelasi spasial. Uji ini bertujuan untuk mengetahui apakah lokasi pengamatan terjadi pemerataan secara sempurna (homogen) atau tidak sempurna (heterogen). Uji heterogenitas dapat dilakukan dengan uji indeks gini yang dapat dijelaskan sebagai berikut:

Indeks gini Kecamatan Junrejo =

$$G_{junrejo} = 1 + \frac{1}{n} - \frac{2}{(n^2 \hat{y}_i)} \sum_{i=1}^N Y_i = 1 + \frac{1}{171} - \frac{2}{((171^2)(175.333))} (9994) \\ = 1.001949$$

Indeks gini Kecamatan Bumiaji =

$$G_{bumiaji} = 1 + \frac{1}{n} - \frac{2}{(n^2 \hat{y}_i)} \sum_{i=1}^N Y_i = 1 + \frac{1}{171} - \frac{2}{((171^2)(193.0526))} (11004) \\ = 1.001949$$

Indeks gini Kecamatan Batu =

$$G_{batu} = 1 + \frac{1}{n} - \frac{2}{(n^2 \hat{y}_i)} \sum_{i=1}^N Y_i = 1 + \frac{1}{171} - \frac{2}{((171^2)(126.2105))} (7194) \\ = 1.001949$$

Dengan statistik uji sebagai berikut:

H_0 : lokasi pengamatan bersifat homogen.


H_1 : lokasi pengamatan bersifat heterogen.

H_0 ditolak jika $G_i = 1$

Indeks gini untuk curah hujan di 3 kecamatan Kota Batu di atas menghasilkan nilai yang sama yaitu 1.001949 yang menunjukkan tolak H_0 . Artinya hasil uji heterogenitas lokasi dari ketiga kecamatan tersebut dapat disimpulkan bahwa setiap lokasi pengamatan tidak terjadi pemerataan yang sempurna. Hal ini memenuhi asumsi model SGSTAR dimana setiap lokasi pengamatan bersifat heterogen.

4.5 Perhitungan Bobot Lokasi Model SGSTAR

Pada model SGSTAR yang dalam pengaplikasian modelnya berhubungan dengan data spasial, maka lokasi pengamatan menjadi salah satu pertimbangan dalam melakukan pemodelan. Dalam penelitian ini digunakan parameter dengan bobot lokasi *invers* jarak dan seragam pada 3 tiap-tiap lokasi. Adapun jarak pada tiap lokasi sebagai berikut:



Gambar 4.2 Jarak Tiap Lokasi Pengamatan pada Peta

Dari gambar 4.2 diperoleh jarak antar lokasi pengamatan pada peta yakni pada Kecamatan Batu ke Kecamatan Junrejo adalah 4.49 km, Kecamatan Bumiaji ke Kecamatan Junrejo adalah 10.96 km, dan Kecamatan Batu ke Kecamatan Bumiaji adalah 6.87 km. Dapat disimpulkan pula bahwa jarak terjauh ada pada Kecamatan Bumiaji ke Kecamatan Junrejo yakni 10.96 km, sedangkan jarak terdekat ada pada Kecamatan Batu ke Kecamatan Junrejo dengan jarak 449 km. Adapun tabel jarak antar lokasi pengamatan untuk memudahkan penginterpretasian data curah hujan di 3 kecamatan Kota Batu adalah sebagai berikut:

Tabel 4.6 Jarak Antar Lokasi Pengamatan

Lokasi	Junrejo	Bumiaji	Batu
Junrejo	0	10.96 km	4.49 Km
Bumiaji	10.96 km	0	6.87 km
Batu	4.49 km	6.87 km	0

Parameter pada bobot invers didasarkan pada jarak sebenarnya antar lokasi. Sehingga pembobot ini mempertimbangkan koordinat bujur dan lintang pada lokasi. Setelah didapatkan jarak asli antar lokasi, maka penentuan nilai bobot didapatkan dari normalisasi nilai invers jarak tersebut. Pada bobot invers, jarak yang dekat diperoleh nilai bobot yang kecil, sedangkan jarak yang jauh diperoleh nilai bobot yang besar. Hal ini dikarenakan dugaan pada lokasi yang jauh memiliki keterkaitan yang kecil, begitu pula sebaliknya jika jarak lokasi dekat, maka diduga akan memiliki keterkaitan yang besar.

Jarak lokasi Kecamatan Batu ke Kecamatan Junrejo dilambangkan dengan r_1 . Jarak lokasi Kecamatan Bumiaji ke Kecamatan Junrejo dilambangkan dengan r_2 . Jarak lokasi Kecamatan Batu ke Kecamatan Bumiaji dilambangkan dengan r_3 . Sehingga nilai r_1 , r_2 , r_3 berturut-turut adalah 4.49, 10.96, dan 6.87. Berdasarkan persamaan 2.14 perhitungan matriks bobot invers jarak dapat dituliskan sebagai berikut:

$$\begin{aligned}
 W_{ij} &= \begin{bmatrix} 0 & \frac{4.49}{4.49 + 10.96} & \frac{10.96}{4.49 + 10.96} \\ \frac{4.49}{4.49 + 6.87} & 0 & \frac{6.87}{4.49 + 6.87} \\ \frac{6.87}{10.96 + 6.87} & \frac{10.96}{10.96 + 6.87} & 0 \end{bmatrix} \\
 &= \begin{bmatrix} 0 & 0.2906149 & 0.7093851 \\ 0.3952465 & 0 & 0.6047535 \\ 0.3853057 & 0.6146943 & 0 \end{bmatrix} \quad (4.1)
 \end{aligned}$$

Selanjutnya akan dilakukan penentuan bobot lokasi menggunakan bobot seragam. Matriks bobot seragam memberikan nilai yang sama untuk setiap lokasi. Terdapat 3 lokasi pengamatan pada penelitian. Dengan demikian untuk setiap lokasi, jumlah lokasi yang berdekatan adalah dua. Dengan menggunakan persamaan $W_{ij} = \frac{1}{n_i} \quad i \neq j$, dimana n_i merupakan jumlah lokasi yang berdekatan dengan lokasi i maka hasil perhitungan bobot lokasi seragam dapat dilihat sebagai berikut:

$$W_{ij} = \begin{bmatrix} 0 & \frac{1}{2} & \frac{1}{2} \\ \frac{1}{2} & 0 & \frac{1}{2} \\ \frac{1}{2} & \frac{1}{2} & 0 \end{bmatrix}$$

4.6 Penentuan Orde Model SGSTAR

Pada tahap ini akan dilakukan sebuah uji untuk menentukan orde pada model SGSTAR musiman dengan cara menggunakan orde model *autoregressive*(p). Identifikasi model *autoregressive* sendiri dapat ditentukan dengan cara mencari lag yang optimal pada model dengan menggunakan plot MPACF. Berikut plot MPACF untuk data curah hujan di 3 kecamatan di Kota Batu:

Tabel 4.7 MPACF Data Curah Hujan 3 Kecamatan di Kota Batu.

[illegible]

Tabel 4.7 menunjukkan bahwa beberapa *lag-lag* yang ada pada plot MPACF keluar dari batas *standard error* dan lebih dari satu. Sehingga model yang terbentuk juga akan lebih dari satu. Oleh karena itu perlu dilakukan identifikasi terhadap nilai-nilai *Akaike's Information Criterion* (AIC) terkecil pada beberapa *lag*. *Lag* dengan nilai AIC terkecil dapat dijadikan orde yang nantinya dapat membentuk model SGSTAR.

Pada tabel 4.8 menunjukkan hasil identifikasi nilai AIC terkecil berupa *lag-lag* dengan nilai AIC-nya masing-masing. Pada tabel tersebut juga menunjukkan bahwa nilai AIC terkecil terdapat pada ARMA(8,5) atau AR(8) yakni sebesar -33.73783. Sehingga pada tahap penentuan orde didapatkan model paling sesuai mempunyai orde *autoregressive* sama dengan 8 ($p=8$). Pada penelitian ini digunakan orde spasial satu ($\lambda_p = 1$), dengan artian bahwa ketiga lokasi pengamatan berada dalam 1 wilayah, pada hal ini Kecamatan Junrejo, Bumiaji, dan Batu masih berada dalam satu wilayah yang sama yaitu Kota Batu.

Tabel 4.8 Nilai AIC dari Beberapa Model.

Minimum Information Criterion Based on AICC						
Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	25.591055	24.957967	25.304648	25.459906	25.511831	26.05407
AR 1	25.087209	25.077301	25.397016	25.595162	25.792923	26.406433
AR 2	25.261399	25.367668	25.817017	25.816858	26.207797	27.027505
AR 3	25.308679	25.292424	25.870641	26.38888	26.846277	27.838715
AR 4	25.394932	25.542981	26.342901	27.045064	27.823726	28.863455
AR 5	25.777621	25.763522	26.683825	27.553293	28.901473	30.087885
AR 6	26.258811	26.024505	27.178506	28.637322	30.447653	32.083195

AR 7	27.001066	26.95839	28.588289	29.953715	32.628432	34.995507
AR 8	28.221158	28.098267	30.205742	32.353821	34.987352	-33.73783
AR 9	29.809537	29.837419	32.823202			

Dapat disimpulkan bahwa model yang sesuai dengan data curah hujan di 3 kecamatan Kota Batu yang sudah dilakukan *differencing* orde 1 adalah model SGSTAR(8)-I(1)⁶. Sehingga dari model yang diperoleh menurut menurut persamaan (2.9) masing-masing lokasi adalah sebagai berikut:

$$\begin{aligned}
 Z_{junrejo}(t) = & \Phi_{10}^1 Z_1(t-1) + \Phi_{20}^1 Z_1(t-2) + \Phi_{30}^1 Z_1(t-3) \\
 & + \Phi_{11}^1 w_{12} Z_2(t-1) + \Phi_{11}^1 w_{13} Z_3(t-1) + \Phi_{21}^1 w_{12} Z_2(t-2) \\
 & + \Phi_{21}^1 w_{13} Z_3(t-2) + \dots + \Phi_{81}^1 w_{12} Z_2(t-8) \\
 & + \Phi_{81}^1 w_{13} Z_3(t-8) + e_1(t)
 \end{aligned}$$

$$\begin{aligned}
 Z_{bumiaji}(t) = & \Phi_{10}^2 Z_2(t-1) + \Phi_{20}^2 Z_2(t-2) + \Phi_{30}^2 Z_2(t-3) \\
 & + \Phi_{11}^1 w_{21} Z_1(t-1) + \Phi_{11}^1 w_{23} Z_3(t-1) + \Phi_{21}^1 w_{21} Z_1(t-2) \\
 & + \Phi_{21}^1 w_{23} Z_3(t-2) + \dots + \Phi_{81}^1 w_{21} Z_1(t-8) \\
 & + \Phi_{81}^1 w_{23} Z_3(t-8) + e_2(t)
 \end{aligned}$$

$$\begin{aligned}
 Z_{batu}(t) = & \Phi_{10}^3 Z_3(t-1) + \Phi_{20}^3 Z_3(t-2) + \Phi_{30}^3 Z_3(t-3) \\
 & + \Phi_{11}^1 w_{31} Z_1(t-1) + \Phi_{11}^1 w_{32} Z_2(t-1) + \Phi_{21}^1 w_{31} Z_1(t-2) \\
 & + \Phi_{21}^1 w_{32} Z_2(t-2) + \dots + \Phi_{81}^1 w_{31} Z_1(t-8) \\
 & + \Phi_{81}^1 w_{32} Z_2(t-8) + e_2(t)
 \end{aligned}$$

4.6.1 Estimasi Parameter dengan Metode *Ordinary Least Square*

Estimasi parameter model GSTAR pada penelitian ini dilakukan dengan metode *Ordinary Least Square* (OLS), yaitu dengan meminimumkan jumlah kuadrat *error*. Adapun estimasi parameter model SGSTAR(8)-I(1)⁶ dengan bobot seragam dapat dituliskan dalam bentuk tabel sebagai berikut:

Tabel 4.9 Estimasi Parameter Model SGSTAR(7₁) Bobot lokasi Seragam

Parameter	Estimate	Parameter	Estimate
Φ_{10}^1	-0.277281	Φ_{21}^1	0.87053
Φ_{10}^2	0.447833	Φ_{21}^2	-1.15073
Φ_{10}^3	0.204751	Φ_{21}^3	0.27053
Φ_{20}^1	-0.820637	Φ_{31}^1	0.36404
Φ_{20}^2	0.655323	Φ_{31}^2	-1.06792
Φ_{20}^3	-0.262136	Φ_{31}^3	-0.26445
Φ_{30}^1	-0.575767	Φ_{41}^1	-0.01791
Φ_{30}^2	0.679664	Φ_{41}^2	0.13849
Φ_{30}^3	0.108257	Φ_{41}^3	-0.5428
Φ_{40}^1	0.009317	Φ_{51}^1	0.34974
Φ_{40}^2	0.272695	Φ_{51}^2	0.69523
Φ_{40}^3	0.694929	Φ_{51}^3	0.19462
Φ_{50}^1	0.348941	Φ_{61}^1	-1.02236
Φ_{50}^2	0.013516	Φ_{61}^2	0.77132
Φ_{50}^3	0.556777	Φ_{61}^3	-0.52231
Φ_{60}^1	0.21693	Φ_{71}^1	-0.72484
Φ_{60}^2	-1.392834	Φ_{71}^2	1.0497
Φ_{60}^3	0.183952	Φ_{71}^3	-0.47523
Φ_{70}^1	0.600724	Φ_{81}^1	0.22048
Φ_{70}^2	-0.838347	Φ_{81}^2	0.89488
Φ_{70}^3	0.213031	Φ_{81}^3	0.18346
Φ_{80}^1	0.270412	Φ_{10}^6 (Junrejo)	0.08412
Φ_{80}^2	-0.037592	Φ_{10}^6 (Bumiaji)	-0.40739
Φ_{80}^3	0.373893	Φ_{10}^6 (Batu)	0.06453
Φ_{11}^1	0.829139	Φ_{11}^6 (Junrejo)	0.39805
Φ_{11}^2	-0.05478	Φ_{11}^6 (Bumiaji)	1.01951
Φ_{11}^3	0.273133	Φ_{11}^6 (Batu)	0.10888

Hasil estimasi parameter model SGSTAR(8)-I(1)⁶ pada data curah hujan di 3 kecamatan Kota Batu dengan pembobot seragam dapat dituliskan dalam bentuk matriks terdapat pada lampiran. Adapun estimasi parameter model SGSTAR(8)-I(1)⁶ dengan bobot *invers* jarak dapat dituliskan dalam bentuk tabel sebagai berikut:

Tabel 4.10 Hasil Estimasi Parameter Model SGSTAR Bobot *Invers* Jarak

Parameter	Estimate	Parameter	Estimate
Φ_{10}^1	-0.3413	Φ_{21}^1	0.8343
Φ_{10}^2	0.44099	Φ_{21}^2	-1.54556
Φ_{10}^3	0.19372	Φ_{21}^3	0.32391
Φ_{20}^1	-0.8183	Φ_{31}^1	0.37588
Φ_{20}^2	0.84017	Φ_{31}^2	-1.35608
Φ_{20}^3	-0.3559	Φ_{31}^3	-0.20705
Φ_{30}^1	-0.5964	Φ_{41}^1	0.02308
Φ_{30}^2	0.86146	Φ_{41}^2	0.0147
Φ_{30}^3	0.03272	Φ_{41}^3	-0.52866
Φ_{40}^1	-0.0612	Φ_{51}^1	0.48205
Φ_{40}^2	0.36788	Φ_{51}^2	0.77624
Φ_{40}^3	0.64752	Φ_{51}^3	0.18608
Φ_{50}^1	0.22555	Φ_{61}^1	-0.73392
Φ_{50}^2	-0.0182	Φ_{61}^2	1.16607
Φ_{50}^3	0.57007	Φ_{61}^3	-0.54492
Φ_{60}^1	-0.0291	Φ_{71}^1	-0.54068
Φ_{60}^2	-1.5229	Φ_{71}^2	1.29301
Φ_{60}^3	0.26054	Φ_{71}^3	-0.56029
Φ_{70}^1	0.46512	Φ_{81}^1	0.25111
Φ_{70}^2	-0.9507	Φ_{81}^2	1.05235
Φ_{70}^3	0.35868	Φ_{81}^3	0.09516
Φ_{80}^1	0.17788	Φ_{10}^6 (Junrejo)	0.11596
Φ_{80}^2	-0.2093	Φ_{10}^6 (Bumiaji)	-0.4572
Φ_{80}^3	0.45751	Φ_{10}^6 (Batu)	0.12002
Φ_{11}^1	0.88208	Φ_{11}^6 (Junrejo)	0.40552
Φ_{11}^2	-0.2006	Φ_{11}^6 (Bumiaji)	1.23474
Φ_{11}^3	0.26265	Φ_{11}^6 (Batu)	0.08518

Tabel 4.10 menjelaskan tentang estimasi paramter model SGSTAR(8)-I(1)⁶ dengan bobot lokasi invers jarak, sedangkan tabel 4.9 menjelaskan tentang estimasi parameter model SGSTAR(8)-I(1)⁶ dengan bobot lokasi seragam. Estimasi parameter pada tiap-tiap bobot lokasi dapat diinterpretasikan dalam bentuk persamaan matriks sebagai berikut:

$$\begin{aligned}
 \begin{bmatrix} Z_1(t) \\ Z_2(t) \\ Z_3(t) \end{bmatrix} &= \left(\begin{bmatrix} -0.277281 & 0 & 0 \\ 0 & 0.447833 & 0 \\ 0 & 0 & 0.204751 \end{bmatrix} + \begin{bmatrix} 0.829139 & 0 & 0 \\ 0 & -0.05478 & 0 \\ 0 & 0 & 0.273133 \end{bmatrix} \begin{bmatrix} 0 & 0.5 & 0.5 \\ 0.5 & 0 & 0.5 \\ 0.5 & 0.5 & 0 \end{bmatrix} \right) \begin{bmatrix} Z_1(t-1) \\ Z_2(t-1) \\ Z_3(t-1) \end{bmatrix} \\
 &+ \dots + \left(\begin{bmatrix} 0.270412 & 0 & 0 \\ 0 & -0.037592 & 0 \\ 0 & 0 & 0.373893 \end{bmatrix} + \begin{bmatrix} 0.22048 & 0 & 0 \\ 0 & 0.89488 & 0 \\ 0 & 0 & 0.18346 \end{bmatrix} \begin{bmatrix} 0 & 0.5 & 0.5 \\ 0.5 & 0 & 0.5 \\ 0.5 & 0.5 & 0 \end{bmatrix} \right) \begin{bmatrix} Z_1(t-8) \\ Z_2(t-8) \\ Z_3(t-8) \end{bmatrix} \\
 &+ \left(\begin{bmatrix} 0.08412 & 0 & 0 \\ 0 & -0.40739 & 0 \\ 0 & 0 & 0.06453 \end{bmatrix} + \begin{bmatrix} 0.39805 & 0 & 0 \\ 0 & 1.01951 & 0 \\ 0 & 0 & 0.10888 \end{bmatrix} \begin{bmatrix} 0 & 0.5 & 0.5 \\ 0.5 & 0 & 0.5 \\ 0.5 & 0.5 & 0 \end{bmatrix} \right) \begin{bmatrix} Z_1(t-6) \\ Z_2(t-6) \\ Z_3(t-6) \end{bmatrix} + \begin{bmatrix} e_1(t) \\ e_2(t) \\ e_3(t) \end{bmatrix}
 \end{aligned}$$

Persamaan matriks diatas merupakan contoh sebagian hasil interpretasi estimasi parameter model SGSTAR(8)-I(1)⁶ dengan bobot seragam di Kecamatan Junrejo yang selengkapnya terlampir pada lampiran 7. Dari persamaan matriks tersebut dapat dijabarkan menjadi persamaan yang lebih sederhana yang dijelaskan sebagai berikut:

a. Model SGSTAR(8)-I(1)⁶ dengan bobot seragam di Kecamatan Junrejo:

$$\begin{aligned}
 Z_1(t) &= -0.2773Z_1(t-1) + 0.4146Z_2(t-1) + 0.4146Z_3(t-1) \\
 &\quad -0.8206Z_1(t-2) + 0.4353Z_2(t-2) + 0.4353Z_3(t-2) \\
 &\quad -0.5758Z_1(t-3) + 0.1820Z_2(t-3) + 0.1820Z_3(t-3) \\
 &\quad +0.0093Z_1(t-4) - 0.0090Z_2(t-4) - 0.0090Z_3(t-4)
 \end{aligned}$$

$$\begin{aligned}
& +0.3489Z_1(t-5) + 0.1749Z_2(t-5) + 0.1749Z_3(t-5) \\
& +0.2169Z_1(t-6) - 0.5112Z_2(t-6) - 0.5112Z_3(t-6) \\
& +0.6007Z_1(t-7) - 0.3624Z_2(t-7) - 0.3624Z_3(t-7) \\
& +0.2704Z_1(t-8) + 0.1102Z_2(t-8) + 0.1102Z_3(t-8) \\
& +0.0841Z_1(t-6) + 0.1990Z_2(t-6) + 0.1990Z_3(t-6) + e_1(t)
\end{aligned}$$

b. Model SGSTAR(8)-I(1)⁶ dengan bobot seragam di Kecamatan Bumiaji:

$$\begin{aligned}
Z_2(t) = & 0.4478Z_2(t-1) - 0.0274Z_1(t-1) - 0.0274Z_3(t-1) \\
& +0.6553Z_2(t-2) - 0.5754Z_1(t-2) - 0.5754Z_3(t-2) \\
& +0.4478Z_2(t-3) - 0.5340Z_1(t-3) - 0.5340Z_3(t-3) \\
& +0.2727Z_2(t-4) + 0.0692Z_1(t-4) + 0.0692Z_3(t-4) \\
& +0.0135Z_2(t-5) + 0.3476Z_1(t-5) + 0.3476Z_3(t-5) \\
& +1.3928Z_2(t-6) + 0.3857Z_1(t-6) + 0.3857Z_3(t-6) \\
& -0.8383Z_2(t-7) + 0.5249Z_1(t-7) + 0.5249Z_3(t-7) \\
& -0.0376Z_2(t-8) + 0.4474Z_1(t-8) + 0.4474Z_3(t-8) \\
& -0.4074Z_2(t-6) + 0.5098Z_1(t-6) + 0.5098Z_3(t-6) + e_2(t)
\end{aligned}$$

c. Model SGSTAR(8)-I(1)⁶ dengan bobot seragam di Kecamatan Batu:

$$\begin{aligned}
Z_3(t) = & 0.2048Z_3(t-1) + 0.1336Z_1(t-1) + 0.1336Z_2(t-1) \\
& -0.2621Z_3(t-2) + 0.1353Z_1(t-2) + 0.1353Z_2(t-2) \\
& +0.1083Z_3(t-3) - 0.1332Z_1(t-3) - 0.1332Z_2(t-3) \\
& +0.6949Z_3(t-4) - 0.2714Z_1(t-4) - 0.2714Z_2(t-4) \\
& +0.5568Z_3(t-5) + 0.0973Z_1(t-5) + 0.0973Z_2(t-5) \\
& +0.1840Z_3(t-6) - 0.2612Z_1(t-6) - 0.2612Z_2(t-6) \\
& -0.8383Z_3(t-7) - 0.2376Z_1(t-7) - 0.2376Z_2(t-7) \\
& +0.3738Z_1(t-8) + 0.0917Z_2(t-8) + 0.0917Z_3(t-8)
\end{aligned}$$

$$+0.0645Z_1(t-6) + 0.0544Z_2(t-6) + 0.0544Z_3(t-6) + e_3(t)$$

Adapun hasil estimasi pratameter bobot lokasi invers jarak pada data curah hujan di 3 kecamatan di kota Batu dengan dapat dijabarkan dalam bentuk persamaan sebagai berikut:

a. Model SGSTAR(8)-I(1)⁶ dengan bobot invers jarak di Kecamatan Junrejo:

$$\begin{aligned} Z_1(t) = & 0.341Z_1(t-1) - 0.0583Z_2(t-1) + 0.1863Z_3(t-1) \\ & - 0.818Z_1(t-2) + 0.242Z_2(t-2) + 0.592Z_3(t-2) \\ & - 0.596Z_1(t-3) + 0.109Z_2(t-3) + 0.267Z_3(t-3) \\ & - 0.0612Z_1(t-4) + 0.00671Z_2(t-4) + 0.0164Z_3(t-4) \\ & + 0.226Z_1(t-5) + 0.140Z_2(t-5) + 0.342Z_3(t-5) \\ & - 0.0291Z_1(t-6) - 0.213Z_2(t-6) - 0.521Z_3(t-6) \\ & + 0.465Z_1(t-7) - 0.157Z_2(t-7) - 0.384Z_3(t-7) \\ & + 0.178Z_1(t-8) + 0.0730Z_2(t-8) + 0.178Z_3(t-8) \\ & + 0.116Z_1(t-6) + 0.118Z_2(t-6) + 0.288Z_3(t-6) + e_1(t) \end{aligned}$$

b. Model SGSTAR(8)-I(1)⁶ dengan bobot *invers* jarak di Kecamatan Bumiaji:

$$\begin{aligned} Z_2(t) = & 0.4410Z_2(t-1) + 0.3486Z_1(t-1) + 0.1588Z_3(t-1) \\ & + 0.840Z_2(t-2)0.1588Z_1(t-2) - 0.935Z_3(t-2) \\ & + 0.861Z_2(t-3) - 0.536Z_1(t-3) - 0.820Z_3(t-3) \\ & + 0.368Z_2(t-4) + 0.00581Z_1(t-4) + 0.00889Z_3(t-4) \\ & - 0.0182Z_2(t-5) + 0.307Z_1(t-5) + 0.469Z_3(t-5) \\ & - 1.52Z_2(t-6) + 0.461Z_1(t-6) + 0.705Z_3(t-6) \\ & - 0.951Z_2(t-7) + 0.511Z_1(t-7) + 0.782Z_3(t-7) \\ & - 0.209Z_2(t-8) + 0.416Z_1(t-8) + 0.636Z_3(t-8) \\ & - 0.457Z_2(t-6) + 0.488Z_1(t-6) + 0.747Z_3(t-6) + e_2(t) \end{aligned}$$

c. Model SGSTAR(8)-I(1)⁶ dengan bobot *invers* jarak di Kecamatan Batu:

$$\begin{aligned}
 Z_3(t) = & 0.1937Z_3(t-1) + 0.3399Z_1(t-1) - 0.1233Z_2(t-1) \\
 & -0.356Z_3(t-2) + 0.125Z_1(t-2) + 0.199Z_2(t-2) \\
 & +0.0327Z_3(t-3) + 0.0798Z_1(t-3) - 0.127Z_2(t-3) \\
 & +0.648Z_3(t-4) - 0.2204Z_1(t-4) - 0.2204Z_2(t-4) \\
 & +0.570Z_3(t-5) + 0.0717Z_1(t-5) + 0.114Z_2(t-5) \\
 & +0.261Z_3(t-6) - 0.210Z_1(t-6) - 0.335Z_2(t-6) \\
 & +0.359Z_3(t-7) - 0.216Z_1(t-7) - 0.344Z_2(t-7) \\
 & +0.458Z_3(t-8) + 0.0367Z_1(t-8) + 0.0585Z_2(t-8) \\
 & +0.0328Z_1(t-6) + 0.05245Z_2(t-6) + 0.120Z_3(t-6) + e_3(t)
 \end{aligned}$$

4.7 Uji Kesesuaian Model SGSTAR

Setelah didapatkan parameter bobot lokasi pada model SGSTAR(8)-I(1)⁶, maka langkah selanjutnya adalah pengecekan beberapa asumsi pada model yang harus terpenuhi. Salah satunya adalah asumsi *white noise*, pada hal ini akan dilakukan uji *white noise* pada residual model SGSTAR(8)-I(1)⁶ menggunakan uji *Ljung-Box* dengan uji hipotesis sebagai berikut:

$$H_0 : \rho_1, \rho_2, \dots, \rho_k = 0 \text{ (tidak terdapat autokorelasi antar residu/residu } white \text{ noise)}$$

$$H_1 : \text{minimal terdapat satu } \rho_k \neq 0 \text{ (terdapat autokorelasi antar residu/residu tidak } white \text{ noise.)}$$

Sehingga akan diketahui apakah residual bersifat *white noise* atau tidak, jika residual model mengalami *white noise* maka model dikatakan layak untuk digunakan. Berikut hasil uji *white noise* pada residual model SGSTAR(8)-I(1)⁶:

Tabel 4.11 Hasil Uji *Ljung-Box* dengan *p-value*

Bobot lokasi	<i>p-value</i>	Tanda	α	Keputusan	Kesimpulan
Invers Jarak	0.503	>	0.05	Gagal Tolak H_0	Residual mengalami <i>white noise</i>
Seragam	0.379	>	0.05	Gagal Tolak H_0	Residual mengalami <i>white noise</i>

Tabel 4.11 menjelaskan bahwa hasil uji *white noise* pada residual model SGSTAR(8)-I(1)⁶ menggunakan *Ljung-Box* bersifat *white noise*, dikarenakan nilai *p-value* lebih besar dari pada derajat signifikansi 5% (0,05) sehingga terima H_0 yang artinya asumsi *white noise* pada model terpenuhi. Selain asumsi residual mengalami *white noise*, terdapat asumsi residual berdistribusi normal yang harus terpenuhi. Pada asumsi ini akan dilakukan dengan uji *Kolmogorov-Smirnov* untuk pengujian apakah residual berdistribusi normal atau tidak. Jika residual pada model berdistribusi normal, maka model dikatakan layak untuk digunakan. Uji hipotesis untuk uji residual berdistribusi normal adalah sebagai berikut:

$$H_0 : F(x) = F_0(x) \text{ (residual berdistribui normal multivariat)}$$

$$H_0 : F(x) \neq F_0(x) \text{ (residual tidak berdistribusi normal multivariat)}$$

Berikut hasil uji residual bersitribusi normal menggunakan *Kolmogorov-Smirnov*:

Tabel 4.12 Hasil Uji *Kolmogorov-Smirnov*

Bobot lokasi	<i>p-value</i>	Tanda	α	Keputusan	Kesimpulan
Invers Jarak	0.4843	>	0.05	Terima H_0	Residual Berdistribusi Normal
Seragam	0.3654	>	0.05	Terima H_0	Residual Berdistribusi Normal

Pada tabel 4.12 dapat diketahui bahwa normalitas residual untuk model SGSTAR(8)-I(1)⁶ memiliki nilai *p-value* yang lebih besar dari pada derajat signifikansi 5% (0,05) sehingga terima H_0 . Artinya dapat disimpulkan bahwa

residual pada model berdistribusi normal. Oleh karena itu dapat dikatakan bahwa model SGSTAR(8)-I(1)⁶ layak digunakan karena telah memenuhi uji kelayakan model, yaitu residual bersifat *white noise* dan berdistribusi normal.

4.8 Akurasi Model

Setelah diketahui bahwa residual pada model SGSTAR(8)-I(1)⁶ telah memenuhi asumsi kelayakan model, maka langkah selanjutnya adalah penentuan model terbaik dengan cara membandingkan nilai kesalahan model. Hal ini bertujuan untuk melihat seberapa akurat model yang didapat. Pada hal ini akan ditentukan keakuratan model dengan cara membandingkan nilai *Mean Squared Error* (MSE) dan *Root Mean Square Error* (RMSE). Semakin kecil nilai MSE dan RMSE maka semakin akurat model yang didapat. Berikut hasil pengujian kesalahan model SGSTAR(8)-I(1)⁶ untuk bobot seragam dan *invers* jarak pada tiap lokasi:

Tabel 4.13 Nilai MSE dan RMSE Model pada Masing-Masing Bobot

Bobot lokasi	Nilai MSE	Nilai RMSE
Seragam	6478.669444	78.42302551
Invers Jarak	6505.979445	81.21480656

Pada tabel 4.13 dapat diketahui bahwa model SGSTAR(8)-I(1)⁶ dengan bobot lokasi seragam memiliki nilai MSE dan RMSE yang lebih kecil dibandingkan model SGSTAR(8)-I(1)⁶ dengan bobot *invers* jarak. Oleh karena itu dapat disimpulkan bahwa model SGSTAR(8)-I(1)⁶ dengan bobot lokasi seragam lebih baik daripada model SGSTAR(8)-I(1)⁶ dengan bobot lokasi *invers* jarak. Berikut persamaan model SGSTAR(8)-I(1)⁶ pada tiap-tiap lokasi:

a. Model SGSTAR(8)-I(1)⁶ dengan bobot seragam di Kecamatan Junrejo:

$$\begin{aligned}
 Z_1(t) = & -0.2773Z_1(t-1) + 0.4146Z_2(t-1) + 0.4146Z_3(t-1) \\
 & - 0.8206Z_1(t-2) + 0.4353Z_2(t-2) + 0.4353Z_3(t-2) \\
 & - 0.5758Z_1(t-3) + 0.1820Z_2(t-3) + 0.1820Z_3(t-3) \\
 & + 0.0093Z_1(t-4) - 0.0090Z_2(t-4) - 0.0090Z_3(t-4) \\
 & + 0.3489Z_1(t-5) + 0.1749Z_2(t-5) + 0.1749Z_3(t-5) \\
 & + 0.2169Z_1(t-6) - 0.5112Z_2(t-6) - 0.5112Z_3(t-6) \\
 & + 0.6007Z_1(t-7) - 0.3624Z_2(t-7) - 0.3624Z_3(t-7) \\
 & + 0.2704Z_1(t-8) + 0.1102Z_2(t-8) + 0.1102Z_3(t-8) \\
 & + 0.0841Z_1(t-6) + 0.1990Z_2(t-6) + 0.1990Z_3(t-6) \\
 & + e_1(t)
 \end{aligned}$$

b. Model SGSTAR(8)-I(1)⁶ dengan bobot seragam di Kecamatan Bumiaji:

$$\begin{aligned}
 Z_2(t) = & 0.4478Z_2(t-1) - 0.0274Z_1(t-1) - 0.0274Z_3(t-1) \\
 & + 0.6553Z_2(t-2) - 0.5754Z_1(t-2) - 0.5754Z_3(t-2) \\
 & + 0.4478Z_2(t-3) - 0.5340Z_1(t-3) - 0.5340Z_3(t-3) \\
 & + 0.2727Z_2(t-4) + 0.0692Z_1(t-4) + 0.0692Z_3(t-4) \\
 & + 0.0135Z_2(t-5) + 0.3476Z_1(t-5) + 0.3476Z_3(t-5) \\
 & + 1.3928Z_2(t-6) + 0.3857Z_1(t-6) + 0.3857Z_3(t-6) \\
 & - 0.8383Z_2(t-7) + 0.5249Z_1(t-7) + 0.5249Z_3(t-7) \\
 & - 0.0376Z_2(t-8) + 0.4474Z_1(t-8) + 0.4474Z_3(t-8) \\
 & - 0.4074Z_2(t-6) + 0.5098Z_1(t-6) + 0.5098Z_3(t-6) + e_2(t)
 \end{aligned}$$


c. Model SGSTAR(8)-I(1)⁶ dengan bobot seragam di Kecamatan Batu:

$$\begin{aligned}
 Z_3(t) = & 0.2048Z_3(t-1) + 0.1336Z_1(t-1) + 0.1336Z_2(t-1) \\
 & - 0.2621Z_3(t-2) + 0.1353Z_1(t-2) + 0.1353Z_2(t-2)
 \end{aligned}$$

$$\begin{aligned}
& +0.1083Z_3(t-3) - 0.1332Z_1(t-3) - 0.1332Z_2(t-3) \\
& +0.6949Z_3(t-4) - 0.2714Z_1(t-4) - 0.2714Z_2(t-4) \\
& +0.5568Z_3(t-5) + 0.0973Z_1(t-5) + 0.0973Z_2(t-5) \\
& +0.1840Z_3(t-6) - 0.2612Z_1(t-6) - 0.2612Z_2(t-6) \\
& -0.8383Z_3(t-7) - 0.2376Z_1(t-7) - 0.2376Z_2(t-7) \\
& +0.3738Z_1(t-8) + 0.0917Z_2(t-8) + 0.0917Z_3(t-8) \\
& +0.0645Z_1(t-6) + 0.0544Z_2(t-6) + 0.0544Z_3(t-6) + e_3(t)
\end{aligned}$$

Pada model SGSTAR(8)-I(1)⁶ dengan bobot seragam terlihat pada masing-masing lokasi memuat semua orde *autoregressive* yang artinya curah hujan di masing-masing lokasi dipengaruhi oleh jumlah curah hujan pada hari sebelumnya. Selain itu model SGSTAR(8)-I(1)⁶ dengan bobot seragam menginterpretasikan bahwa curah hujan di masing-masing lokasi juga dipengaruhi oleh curah hujan di lokasi lainnya. Oleh karena itu curah hujan di 3 kecamatan Kota Batu saling mempengaruhi.

Untuk penjelasan lebih lanjut tentang akurasi model dapat dijelaskan oleh plot berikut:



Gambar 4.3 Plot Model SGSTAR(8)-I(1)⁶ dengan Bobot Seragam

Gambar 4.3 menjelaskan bahwa data *fitted values* di plot model SGSTAR(8)-I(1)⁶ bobot seragam mengikuti dan sesuai dengan pola data *actual* curah hujan di 3 kecamatan Kota Batu. Hal ini menandakan bahwa model SGSTAR(8)-I(1)⁶ bobot seragam sudah akurat. Hal tersebut didukung dengan nilai *error* model bobot seragam lebih kecil daripada model *invers* jarak.

4.9 Bertafakur Tentang Hujan dalam Al-Qur'an

Pada fenomena hujan terdapat banyak pelajaran yang dapat diambil. Salah satunya adalah kasih sayang Allah yang begitu luas sehingga menjadikan hujan sebagai turunnya rahmat Allah bagi seluruh makhluk-Nya. Semua pemberian dari Allah yang diberikan kepada manusia beriman, baik berupa rahmat, nikmat, berkah, dan anugrah merupakan suatu amanah yang diharuskan untuk mengelolanya, karena Allah telah memberikan kepercayaan terhadap manusia untuk memakmurkan dan menjaga amanah tersebut dengan baik dan benar sehingga tidak akan terjadi sebuah kerusakan di muka bumi.

Menurut (Abdillah, 2001), ayat yang telah dikutip pada kajian pustaka menjelaskan bahwa manusia diperintahkan untuk memakmurkan bumi, karena manusia yang memiliki potensi dalam menjaga amanah atau mandat yang telah diberikan oleh Allah. Salah satu cara untuk menjaga amanah sekaligus bertafakur tentang ciptaan Allah ialah dengan memahami pola dan karakteristik tentang curah hujan. Sebagaimana yang telah dilakukan oleh peneliti pada 3 kecamatan Kota Batu.

Pola dan karakteristik curah hujan di 3 kecamatan Kota Batu dengan model SGSTAR(8)-I(1)⁶ bobot seragam menjelaskan bahwa hujan di ketiga tempat saling

mempengaruhi satu sama lain. Jika disuatu tempat turun hujan, maka kemungkinan besar ditempat lain juga turun hujan dan berlaku juga sebaliknya jika tidak terjadi hujan atau curah hujan sedikit. Selain itu model SGSTAR(8)-I(1)⁶ bobot seragam juga menjelaskan bahwa curah hujan di 3 Kecamatan Kota Batu dipengaruhi oleh jumlah curah hujan di hari sebelum-sebelumnya. Dari pola dan karakteristik curah hujan tersebut dapat digunakan sebagai informasi guna mencegah dampak buruk yang tidak diinginkan. Selain itu juga dapat diperoleh sebuah informasi tentang momen yang tepat untuk memperoleh keuntungan, seperti cocok tanam dengan melihat curah hujan yang sesuai. Hal itu semua merupakan salah satu cara untuk mengimani dan menjaga amanah yang telah Allah beri.

BAB V

PENUTUP

5.1 Kesimpulan

Berdasarkan hasil analisis dan pembahasan yang telah dilakukan pada tahapan sebelumnya, didapatkan kesimpulan sebagai berikut:

1. Hasil penelitian menunjukkan bahwa secara keseluruhan grafik data curah hujan di 3 kecamatan Kota Batu pada periode Januari 2019 hingga September 2023 mengalami fluktuasi/*tren* pada awal dan akhir tahun, hal ini disebabkan data curah hujan dipengaruhi oleh faktor musiman.
2. Model GSTAR dengan metode *Ordinary Least Square* (OLS) yang sesuai dengan data curah hujan di 3 kecamatan Kota Batu adalah model SGSTAR(8)-I(1)⁶ dengan pembobot lokasi seragam, karena model tersebut memenuhi asumsi kelayakan model dan nilai RMSE dan MSE yang lebih kecil dibandingkan dengan model SGSTAR(8)-I(1)⁶ dengan pembobot *invers* jarak. Adapun model SGSTAR(8)-I(1)⁶ dengan bobot seragam sebagai berikut:
 - a. Model SGSTAR(8)-I(1)⁶ dengan bobot seragam di Kecamatan Junrejo:

$$\begin{aligned}
 Z_1(t) = & -0.2773Z_1(t-1) + 0.4146Z_2(t-1) + 0.4146Z_3(t-1) \\
 & -0.8206Z_1(t-2) + 0.4353Z_2(t-2) + 0.4353Z_3(t-2) \\
 & -0.5758Z_1(t-3) + 0.1820Z_2(t-3) + 0.1820Z_3(t-3) \\
 & +0.0093Z_1(t-4) - 0.0090Z_2(t-4) - 0.0090Z_3(t-4) \\
 & +0.3489Z_1(t-5) + 0.1749Z_2(t-5) + 0.1749Z_3(t-5) \\
 & +0.2169Z_1(t-6) - 0.5112Z_2(t-6) - 0.5112Z_3(t-6) \\
 & +0.6007Z_1(t-7) - 0.3624Z_2(t-7) - 0.3624Z_3(t-7)
 \end{aligned}$$

$$+0.2704Z_1(t-8) + 0.1102Z_2(t-8) + 0.1102Z_3(t-8) \\ +0.0841Z_1(t-6) + 0.1990Z_2(t-6) + 0.1990Z_3(t-6) + e_1(t)$$

b. Model SGSTAR(8)-I(1)⁶ dengan bobot seragam di Kecamatan Bumiaji:

$$Z_2(t) = 0.4478Z_2(t-1) - 0.0274Z_1(t-1) - 0.0274Z_3(t-1) \\ +0.6553Z_2(t-2) - 0.5754Z_1(t-2) - 0.5754Z_3(t-2) \\ +0.4478Z_2(t-3) - 0.5340Z_1(t-3) - 0.5340Z_3(t-3) \\ +0.2727Z_2(t-4) + 0.0692Z_1(t-4) + 0.0692Z_3(t-4) \\ +0.0135Z_2(t-5) + 0.3476Z_1(t-5) + 0.3476Z_3(t-5) \\ +1.3928Z_2(t-6) + 0.3857Z_1(t-6) + 0.3857Z_3(t-6) \\ -0.8383Z_2(t-7) + 0.5249Z_1(t-7) + 0.5249Z_3(t-7) \\ -0.0376Z_2(t-8) + 0.4474Z_1(t-8) + 0.4474Z_3(t-8) \\ -0.4074Z_2(t-6) + 0.5098Z_1(t-6) + 0.5098Z_3(t-6) + e_2(t)$$

c. Model SGSTAR(8)-I(1)⁶ dengan bobot seragam di Kecamatan Batu:

$$Z_3(t) = 0.2048Z_3(t-1) + 0.1336Z_1(t-1) + 0.1336Z_2(t-1) \\ -0.2621Z_3(t-2) + 0.1353Z_1(t-2) + 0.1353Z_2(t-2) \\ +0.1083Z_3(t-3) - 0.1332Z_1(t-3) - 0.1332Z_2(t-3) \\ +0.6949Z_3(t-4) - 0.2714Z_1(t-4) - 0.2714Z_2(t-4) \\ +0.5568Z_3(t-5) + 0.0973Z_1(t-5) + 0.0973Z_2(t-5) \\ +0.1840Z_3(t-6) - 0.2612Z_1(t-6) - 0.2612Z_2(t-6) \\ -0.8383Z_3(t-7) - 0.2376Z_1(t-7) - 0.2376Z_2(t-7) \\ +0.3738Z_1(t-8) + 0.0917Z_2(t-8) + 0.0917Z_3(t-8) \\ +0.0645Z_1(t-6) + 0.0544Z_2(t-6) + 0.0544Z_3(t-6) + e_3(t)$$

5.2 Saran

Perlu penelitian lebih lanjut terhadap curah hujan di 3 kecamatan Kota Batu pada model GSTAR. Selain itu, penelitian ini menggunakan metode *Ordinary Least Square* dalam menentukan estimasi parameter model SGSTAR. Oleh karena itu, penulis berharap kepada pembaca untuk mengembangkan penelitian dengan menggunakan metode lain, sehingga dapat diketahui mana model yang lebih baik.

DAFTAR PUSTAKA

- Abdillah, M. (2001). *Agama Ramah Lingkungan Perspektif Al-Qur'an* (1st ed.). Paramadina.
http://opac.stainponorogo.ac.id/index.php?p=show_detail&id=9501
- Adam, I., D. Kusnandar, & H. Perdana. (2017). Penerapan Model GSTAR(1,1) untuk Data Curah Hujan. *Buletin Ilmiah Math. Stat. Dan Terapannya (Bimaster)*, 6(3), 159–166.
<https://doi.org/http://dx.doi.org/10.26418/bbimst.v6i03.21616>
- Aziz, A. (2007). *Ekonometrika Teori & Praktik Eksperimen dengan MATLAB*. In Universitas UIN Malang. UIN-Maliki Press. <http://repository.uin-malang.ac.id/1207/1/1207.pdf>
- Balqis, V. P., Kurniati, E., & Rohaeni, O. (2020). Model Peramalan Data Inflasi dengan Metode Generalized Space Time Autoregressive (GSTAR) pada Tiga Kota di Jawa Barat. *Prodi Matematika, Fakultas Matematika Dan Ilmu Pengetahuan Alam, Universitas Islam Bandung, Indonesia*, 6(2), 43–50.
<http://dx.doi.org/10.29313/v6i2.23338>
- BMKG. (n.d.). *BMKG Jawa Timur Profil Prakiraan Iklim Analisis Iklim Informasi Iklim E-Buletin Layanan Publik Search ? (Prakiraan 6 Bulanan) Prakiraan Sifat Hujan Musim Hujan Tahun 2022 - 2023 Zona Musim di Provinsi Jawa Timur*.
<https://karangploso.jatim.bmkg.go.id/index.php/prakiraan-iklim/prakiraan-musim/prakiraan-musim-hujan/prakiraan-sifat-hujan-musim-hujan>
- Borovkova, S., & Nurani, B. (2002). *Generalized STAR odels with experimental weights, proceedings of the 17th International Workshop on Statistical Modelling 2002*. 139–147.
- Chang, M. C., & Dickey, D. A. (1994). RECOGNIZING OVERDIFFERENCED TIME SERIES. *JOURNAL OF TIME SERIES ANALYSIS*, 15(1).
<https://doi.org/10.1111/j.1467-9892.1994.tb00173.x>
- Diani, K. A. N., Setiawan, & Suhartono. (2013). Pemodelan VAR-NN dan GSTAR-NN untuk Peramalan Curah Hujan di Kabupaten Malang. *Jurnal Sains Dan Seni Pomits*, 2(1), 19–24. <http://dx.doi.org/10.12962/j23373520.v2i1.3137>
- Fransiska, H., Sunandi, E., & Agustina, D. (2020). Peramalan Curah Hujan Provinsi Bengkulu dengan Generalized Space-Time Autoregressive. *MUST: Journal of Mathematics Education, Science and Technology*, 5(2), 130.
<https://doi.org/10.30651/must.v5i2.5326>
- Irawati, L., & Yasin, H. (2015). Peramalan Indeks Harga Konsumen 4 Kota Di Jawa Tengah Menggunakan Model Generalized Space Time Autoregressive (Gstar). *Universitas Diponegoro*, 4(1980), 553–562. <http://ejournal-s1.undip.ac.id/index.php/gaussian>
- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (1998). *Forecasting Methods and Applications: Index* (3rd ed.). John Wiley & Sons, Inc.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2015). *Introduction Time Series Analysis and Forecasting* (2nd ed.). John Wiley & Sons, Inc.
- Nurchayani, F. (2016). *Pengelompokan Stasiun Hujan untuk Model Generalized Space Time Autoregressive (GSTAR) pada Peramalan Curah Hujan Kabupaten Jember dengan Tiga Pembobotan*. UNIVERSITAS JEMBER.

- Risza, A. A., Nugroho, S., & Faisal, F. (2018). Autokorelasi Dalam Regresi Linier Sederhana. *E-Jurnal Statistika*, 1–12. <https://doi.org/http://sigitnugroho.id/e-Skripsi/0501%20Autokorelasi%20dalam%20Regresi%20Linier%20Sederhana.pdf>
- Ruchjana, B. N. (2019). Pengembangan Model Spatio Temporal. *Prosiding Seminar Nasional Matematika Dan Pendidikan Matematika 2019*, 1–19.
- Shaliha Mansoer, A., & Wilandari, Y. (2016). PEMODELAN SEASONAL GENERALIZED SPACE TIME AUTOREGRESSIVE (SGSTAR) (Studi Kasus: Produksi Padi di Kabupaten Demak, Kabupaten Boyolali, dan Kabupaten Grobogan). *Jurnal Gaussian*, 5(4), 593–602. <http://ejournal-s1.undip.ac.id/index.php/gaussian>
- Tjasyono, B. H. (2012). Meteorologi Indonesia Volume I: Karakteristik dan Sirkulasi Atmosfer. In *Badan Meteorologi Klimatologi dan Geofisika: Vol. I* (4th ed.). Jakarta: Badan Meteorologi Klimatologi dan Geofisika. <https://staklimjogja.files.wordpress.com/2017/02/meteo-indonesia-i.pdf>
- Wei, W. W. S. (2006). Time Series Analysis Univariate and Multivariate Methods. In *Applied Time Series Analysis* (2nd ed.). Greg Tobin. <https://doi.org/10.1201/b11459-9>
- Widarjono, A. (2009). *Ekonometrika Pengantar dan Aplikasinya*. (3rd ed.). Yogyakarta: Ekonisia. <http://balaiyanpus.jogjaprovo.go.id/opac/detail-opac?id=319768>
- Wutsqa, D. U., Suhartono, & Sutijo, B. (2010). Generalized Space-Time Autoregressive Modeling. *Proceedings of the 6th IMT-GT Conference on Mathematics, Statistics and Its Applications (ICMSA2010)*, 752–761.
- Wutsqa, D. U., Suhartono, & Sutijo, B. (2012). Aplikasi Model Generalized Space Time Autoregressive Pada Data Pencemaran Udara Di Kota Surabaya. *Pythagoras: Jurnal Pendidikan Matematika*, 7(2), 17–30. <https://doi.org/https://doi.org/10.21831/pg.v7i2.4782>

LAMPIRAN

Lampiran 1 Data Curah Hujan di 3 Kecamatan Kota Batu Periode Januari 2019 - September 2023

Date	Junrejo	Bumiaji	Batu
Jan-19	264	327	290
Feb-19	340	156	259
Mar-19	362	316	395
Apr-19	272	257	209
Mei-19	56	74	103
Jun-19	0	19	0
Jul-19	14	34	23
Aug-19	0	0	0
Sep-19	0	0	0
Okt-19	0	15	29
Nov-19	54	122	42
Des-19	181	244	165
Jan-20	344	283	223
Feb-20	393	540	270
Mar-20	314	360	241
Apr-20	200	210	209
Mei-20	109	119	132
Jun-20	4	0	0
Jul-20	18	43	20
Agu-20	36	0	25
Sep-20	2	52	23
Oky-20	67	210	90
Nov-20	280	439	211
Des-20	459	516	275
Jan-21	494	588	361
Feb-21	418	464	286
Mar-21	288	365	246
Apr-21	101	177	81
Mei-21	22	9	28
Jun-21	123	82	65
Jul-21	6	33	1
Agu-21	6	0	3
Sep-21	97	168	51
Okt-21	85	130	55
Nov-21	445	466	308
Des-21	240	288	178
Jan-22	252	207	97

Feb-22	261	281	160
Mar-22	214	307	148
Apr-22	319	299	261
Mei-22	49	51	41
Jun-22	181	150	128
Jul-22	20	31	20
Agu-22	40	60	18
Sep-22	119	130	73
Okt-22	433	434	244
Nov-22	436	322	275
Des-22	211	250	144
Jan-23	248	312	143
Feb-23	325	331	164
Mar-23	251	313	126
Apr-23	394	267	203
Mei-23	56	35	8
Jun-23	80	42	37
Jul-23	11	76	7
Agu-23	0	0	0
Sep-23	0	0	0

Lampiran 2 Tabel Uji ADF

Null Hypothesis: JUNREJO has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 5 (Automatic - based on AIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-5.667110	0.0003
Test critical values: 1% level	-4.252879	
5% level	-3.548490	
10% level	-3.207094	

Null Hypothesis: BUMIAJI has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 5 (Automatic - based on AIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.248236	0.0101
Test critical values: 1% level	-4.252879	
5% level	-3.548490	
10% level	-3.207094	

Null Hypothesis: BATU has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 5 (Automatic - based on AIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.801201	0.0025
Test critical values: 1% level	-4.252879	
5% level	-3.548490	
10% level	-3.207094	

Lampiran 3 Tabel MACF sebelum didifferencing

Schematic Representation of Cross Correlations											
Variable/Lag	0	1	2	3	4	5	6	7	8	9	10
Junrejo	+++	+++	+.+	...	---	---	---	---	-.-	...	+++
Bumiaji	+++	+++	+++	...	---	---	---	---	-.-	...	++.
Batu	+++	+++	..+	...	---	---	---	---	-.-	...	+++
+ is $\geq 2 \times \text{std error}$, - is $\leq -2 \times \text{std error}$, . is between											

Lampiran 4 Tabel Durbin Watson

n	k = 2		k = 3		k = 4	
	dL	dU	dL	dU	dL	dU
6						
7	0.4672	1.8964				
8	0.5591	1.7771	0.3674	2.2866		
9	0.6291	1.6993	0.4548	2.1282	0.2957	2.5881
10	0.6972	1.6413	0.5253	2.0163	0.376	2.4137
11	0.758	1.6044	0.5948	1.928	0.4441	2.2833
12	0.8122	1.5794	0.6577	1.864	0.512	2.1766
13	0.8612	1.5621	0.7147	1.8159	0.5745	2.0943
14	0.9054	1.5507	0.7667	1.7788	0.6321	2.0296
15	0.9455	1.5432	0.814	1.7501	0.6852	1.9774
16	0.982	1.5386	0.8572	1.7277	0.734	1.9351
17	1.0154	1.5361	0.8968	1.7101	0.779	1.9005
18	1.0461	1.5353	0.9331	1.6961	0.8204	1.8719
19	1.0743	1.5355	0.9666	1.6851	0.8588	1.8482
20	1.1004	1.5367	0.9976	1.6763	0.8943	1.8283
21	1.1246	1.5385	1.0262	1.6694	0.9272	1.8116
22	1.1471	1.5408	1.0529	1.664	0.9578	1.7974
23	1.1682	1.5435	1.0778	1.6597	0.9864	1.7855
24	1.1878	1.5464	1.101	1.6565	1.0131	1.7753
25	1.2063	1.5495	1.1228	1.654	1.0381	1.7666

26	1.2236	1.5528	1.1432	1.6523	1.0616	1.7591
27	1.2399	1.5562	1.1624	1.651	1.0836	1.7527
28	1.2553	1.5596	1.1805	1.6503	1.1044	1.7473
29	1.2699	1.5631	1.1976	1.6499	1.1241	1.7426
30	1.2837	1.5666	1.2138	1.6498	1.1426	1.7386
31	1.2969	1.5701	1.2292	1.65	1.1602	1.7352
32	1.3093	1.5736	1.2437	1.6505	1.1769	1.7323
33	1.3212	1.577	1.2576	1.6511	1.1927	1.7298
34	1.3325	1.5805	1.2707	1.6519	1.2078	1.7277
35	1.3433	1.5838	1.2833	1.6528	1.2221	1.7259
36	1.3537	1.5872	1.2953	1.6539	1.2358	1.7245
37	1.3635	1.5904	1.3068	1.655	1.2489	1.7233
38	1.373	1.5937	1.3177	1.6563	1.2614	1.7223
39	1.3821	1.5969	1.3283	1.6575	1.2734	1.7215
40	1.3908	1.6	1.3384	1.6589	1.2848	1.7209
41	1.3992	1.6031	1.348	1.6603	1.2958	1.7205
42	1.4073	1.6061	1.3573	1.6617	1.3064	1.7202
43	1.4151	1.6091	1.3663	1.6632	1.3166	1.72
44	1.4226	1.612	1.3749	1.6647	1.3263	1.72
45	1.4298	1.6148	1.3832	1.6662	1.3357	1.72
46	1.4368	1.6176	1.3912	1.6677	1.3448	1.7201
47	1.4435	1.6204	1.3989	1.6692	1.3535	1.7203
48	1.45	1.6231	1.4064	1.6708	1.3619	1.7206
49	1.4564	1.6257	1.4136	1.6723	1.3701	1.721
50	1.4625	1.6283	1.4206	1.6739	1.3779	1.7214
51	1.4684	1.6309	1.4273	1.6754	1.3855	1.7218
52	1.4741	1.6334	1.4339	1.6769	1.3929	1.7223
53	1.4797	1.6359	1.4402	1.6785	1.4	1.7228
54	1.4851	1.6383	1.4464	1.68	1.4069	1.7234
55	1.4903	1.6406	1.4523	1.6815	1.4136	1.724
56	1.4954	1.643	1.4581	1.683	1.4201	1.7246
57	1.5004	1.6452	1.4637	1.6845	1.4264	1.7253
58	1.5052	1.6475	1.4692	1.686	1.4325	1.7259
59	1.5099	1.6497	1.4745	1.6875	1.4385	1.7266
60	1.5144	1.6518	1.4797	1.6889	1.4443	1.7274
61	1.5189	1.654	1.4847	1.6904	1.4499	1.7281
62	1.5232	1.6561	1.4896	1.6918	1.4554	1.7288
63	1.5274	1.6581	1.4943	1.6932	1.4607	1.7296
64	1.5315	1.6601	1.499	1.6946	1.4659	1.7303
65	1.5355	1.6621	1.5035	1.696	1.4709	1.7311
66	1.5395	1.664	1.5079	1.6974	1.4758	1.7319
67	1.5433	1.666	1.5122	1.6988	1.4806	1.7327
68	1.547	1.6678	1.5164	1.7001	1.4853	1.7335

69	1.5507	1.6697	1.5205	1.7015	1.4899	1.7343
70	1.5542	1.6715	1.5245	1.7028	1.4943	1.7351

Lampiran 5 Output Rstudio Uji Autokorelasi *Correlation Pearson*

Pearson's product-moment correlation

```
data: new$skripsi.Junrejo and new$skripsi.Bumiaji
t = 18.554, df = 55, p-value < 2.2e-16
alternative hypothesis: true correlation is not equal to 0
95 percent confidence interval:
0.8812130 0.9574704
sample estimates:
cor
0.9285671
data: new$skripsi.Batu and new$skripsi.Bumiaji
t = 14.729, df = 55, p-value < 2.2e-16
alternative hypothesis: true correlation is not equal to 0
95 percent confidence interval:
0.8244886 0.9359209
sample estimates:
cor
0.8931717
data: new$skripsi.Batu and new$skripsi.Junrejo
t = 20.304, df = 55, p-value < 2.2e-16
alternative hypothesis: true correlation is not equal to 0
95 percent confidence interval:
0.8986899 0.9639428
sample estimates:
cor
0.9393017
```

Lampiran 6 Output Rstudio Hasil Uji *White Noise* dan Residual Berdistribusi Normal

Shapiro-wilk normality test data: Book1\$junrejo W = 0.96783, p-value = 0.4228 Shapiro-wilk normality test data: Book1\$bumiaji W = 0.97554, p-value = 0.6461 Shapiro-wilk normality test data: Book1\$batu W = 0.96851, p-value = 0.4401 Shapiro-wilk normality test data: book2\$junrejo W = 0.96441, p-value = 0.3428 Shapiro-wilk normality test data: book2\$bumiaji W = 0.9696, p-value = 0.4692	Lilliefors (Kolmogorov-Smirnov) normality test data: (Book1\$junrejo) D = 0.12225, p-value = 0.2398 Lilliefors (Kolmogorov-Smirnov) normality test data: (Book1\$bumiaji) D = 0.085278, p-value = 0.785 Lilliefors (Kolmogorov-Smirnov) normality test data: (Book1\$batu) D = 0.10771, p-value = 0.4281 Lilliefors (Kolmogorov-Smirnov) normality test data: (book2\$junrejo) D = 0.12532, p-value = 0.2088
--	---

Shapiro-wilk normality test data: book2\$batu W = 0.96367, p-value = 0.327	Lilliefors (Kolmogorov-Smirnov) normality test data: (book2\$bumiaji) D = 0.095695, p-value = 0.6199 Lilliefors (Kolmogorov-Smirnov) normality test data: (book2\$batu) D = 0.11974, p-value = 0.2675
--	--

Lampiran 7 Matriks Persamaan Model SGSTAR(8)-I(1)⁶ dengan Bobot Seragam

$$\begin{aligned}
 & \begin{bmatrix} Z_1(t) \\ Z_2(t) \\ Z_3(t) \end{bmatrix} \\
 &= \begin{pmatrix} \begin{bmatrix} -0.277281 & 0 & 0 \\ 0 & 0.447833 & 0 \\ 0 & 0 & 0.204751 \end{bmatrix} \\ + \begin{bmatrix} 0.829139 & 0 & 0 \\ 0 & -0.05478 & 0 \\ 0 & 0 & 0.273133 \end{bmatrix} \begin{bmatrix} 0 & 0.5 & 0.5 \\ 0.5 & 0 & 0.5 \\ 0.5 & 0.5 & 0 \end{bmatrix} \end{pmatrix} \begin{bmatrix} Z_1(t-1) \\ Z_2(t-1) \\ Z_3(t-1) \end{bmatrix} \\
 &+ \begin{pmatrix} \begin{bmatrix} -0.820637 & 0 & 0 \\ 0 & 0.655323 & 0 \\ 0 & 0 & -0.262136 \end{bmatrix} \\ + \begin{bmatrix} 0.87053 & 0 & 0 \\ 0 & -1.15073 & 0 \\ 0 & 0 & 0.27053 \end{bmatrix} \begin{bmatrix} 0 & 0.5 & 0.5 \\ 0.5 & 0 & 0.5 \\ 0.5 & 0.5 & 0 \end{bmatrix} \end{pmatrix} \begin{bmatrix} Z_1(t-2) \\ Z_2(t-2) \\ Z_3(t-2) \end{bmatrix} \\
 &+ \begin{pmatrix} \begin{bmatrix} -0.575767 & 0 & 0 \\ 0 & 0.679664 & 0 \\ 0 & 0 & 0.108257 \end{bmatrix} \\ + \begin{bmatrix} 0.36404 & 0 & 0 \\ 0 & -1.06792 & 0 \\ 0 & 0 & -0.26445 \end{bmatrix} \begin{bmatrix} 0 & 0.5 & 0.5 \\ 0.5 & 0 & 0.5 \\ 0.5 & 0.5 & 0 \end{bmatrix} \end{pmatrix} \begin{bmatrix} Z_1(t-3) \\ Z_2(t-3) \\ Z_3(t-3) \end{bmatrix} \\
 &+ \begin{pmatrix} \begin{bmatrix} 0.009317 & 0 & 0 \\ 0 & 0.272695 & 0 \\ 0 & 0 & 0.694929 \end{bmatrix} \\ + \begin{bmatrix} -0.01791 & 0 & 0 \\ 0 & 0.13849 & 0 \\ 0 & 0 & -0.5428 \end{bmatrix} \begin{bmatrix} 0 & 0.5 & 0.5 \\ 0.5 & 0 & 0.5 \\ 0.5 & 0.5 & 0 \end{bmatrix} \end{pmatrix} \begin{bmatrix} Z_1(t-4) \\ Z_2(t-4) \\ Z_3(t-4) \end{bmatrix} \\
 &+ \begin{pmatrix} \begin{bmatrix} 0.348941 & 0 & 0 \\ 0 & 0.013516 & 0 \\ 0 & 0 & 0.556777 \end{bmatrix} \\ + \begin{bmatrix} 0.34974 & 0 & 0 \\ 0 & 0.69523 & 0 \\ 0 & 0 & 0.19462 \end{bmatrix} \begin{bmatrix} 0 & 0.5 & 0.5 \\ 0.5 & 0 & 0.5 \\ 0.5 & 0.5 & 0 \end{bmatrix} \end{pmatrix} \begin{bmatrix} Z_1(t-5) \\ Z_2(t-5) \\ Z_3(t-5) \end{bmatrix}
 \end{aligned}$$

$$\begin{aligned}
& + \left(\begin{bmatrix} 0.21693 & 0 & 0 \\ 0 & 1.392834 & 0 \\ 0 & 0 & 0.183952 \end{bmatrix} \right. \\
& + \left. \begin{bmatrix} -1.02236 & 0 & 0 \\ 0 & 0.77132 & 0 \\ 0 & 0 & -0.52231 \end{bmatrix} \begin{bmatrix} 0 & 0.5 & 0.5 \\ 0.5 & 0 & 0.5 \\ 0.5 & 0.5 & 0 \end{bmatrix} \right) \begin{bmatrix} Z_1(t-6) \\ Z_2(t-6) \\ Z_3(t-6) \end{bmatrix} \\
& + \left(\begin{bmatrix} 0.600724 & 0 & 0 \\ 0 & -0.838347 & 0 \\ 0 & 0 & 0.213031 \end{bmatrix} \right. \\
& + \left. \begin{bmatrix} -0.72484 & 0 & 0 \\ 0 & 1.0497 & 0 \\ 0 & 0 & -0.47523 \end{bmatrix} \begin{bmatrix} 0 & 0.5 & 0.5 \\ 0.5 & 0 & 0.5 \\ 0.5 & 0.5 & 0 \end{bmatrix} \right) \begin{bmatrix} Z_1(t-7) \\ Z_2(t-7) \\ Z_3(t-7) \end{bmatrix} \\
& + \left(\begin{bmatrix} 0.270412 & 0 & 0 \\ 0 & -0.037592 & 0 \\ 0 & 0 & 0.373893 \end{bmatrix} \right. \\
& + \left. \begin{bmatrix} 0.22048 & 0 & 0 \\ 0 & 0.89488 & 0 \\ 0 & 0 & 0.18346 \end{bmatrix} \begin{bmatrix} 0 & 0.5 & 0.5 \\ 0.5 & 0 & 0.5 \\ 0.5 & 0.5 & 0 \end{bmatrix} \right) \begin{bmatrix} Z_1(t-8) \\ Z_2(t-8) \\ Z_3(t-8) \end{bmatrix} \\
& + \begin{bmatrix} 0.08412 & 0 & 0 \\ 0 & -0.40739 & 0 \\ 0 & 0 & 0.06453 \end{bmatrix} \\
& + \begin{bmatrix} 0.39805 & 0 & 0 \\ 0 & 1.01951 & 0 \\ 0 & 0 & 0.10888 \end{bmatrix} \begin{bmatrix} 0 & 0.5 & 0.5 \\ 0.5 & 0 & 0.5 \\ 0.5 & 0.5 & 0 \end{bmatrix} \begin{bmatrix} Z_1(t-6) \\ Z_2(t-6) \\ Z_3(t-6) \end{bmatrix} + \begin{bmatrix} e_1(t) \\ e_2(t) \\ e_3(t) \end{bmatrix}
\end{aligned}$$

Lampiran 8 Matriks Persamaan Model SGSTAR(8)-I(1)⁶ dengan Bobot Invers Jarak

$$\begin{aligned}
& \begin{bmatrix} Z_1(t) \\ Z_2(t) \\ Z_3(t) \end{bmatrix} \\
& = \left(\begin{bmatrix} -0.3413 & 0 & 0 \\ 0 & 0.44099 & 0 \\ 0 & 0 & 0.19372 \end{bmatrix} \right. \\
& + \left. \begin{bmatrix} 0.88208 & 0 & 0 \\ 0 & -0.2006 & 0 \\ 0 & 0 & 0.26265 \end{bmatrix} \begin{bmatrix} 0 & 0.2906149 & 0.7093851 \\ 0.3952465 & 0 & 0.6047535 \\ 0.3853057 & 0.6146943 & 0 \end{bmatrix} \right) \begin{bmatrix} Z_1(t-1) \\ Z_2(t-1) \\ Z_3(t-1) \end{bmatrix} \\
& + \left(\begin{bmatrix} -0.8183 & 0 & 0 \\ 0 & 0.84017 & 0 \\ 0 & 0 & -0.3559 \end{bmatrix} \right. \\
& + \left. \begin{bmatrix} 0.8343 & 0 & 0 \\ 0 & -1.54556 & 0 \\ 0 & 0 & 0.32391 \end{bmatrix} \begin{bmatrix} 0 & 0.2906149 & 0.7093851 \\ 0.3952465 & 0 & 0.6047535 \\ 0.3853057 & 0.6146943 & 0 \end{bmatrix} \right) \begin{bmatrix} Z_1(t-2) \\ Z_2(t-2) \\ Z_3(t-2) \end{bmatrix}
\end{aligned}$$

$$\begin{aligned}
& + \begin{pmatrix} -0.5964 & 0 & 0 \\ 0 & 0.86146 & 0 \\ 0 & 0 & 0.03272 \end{pmatrix} \\
& + \begin{pmatrix} 0.37588 & 0 & 0 \\ 0 & -1.35608 & 0 \\ 0 & 0 & -0.20705 \end{pmatrix} \begin{bmatrix} 0 & 0.2906149 & 0.7093851 \\ 0.3952465 & 0 & 0.6047535 \\ 0.3853057 & 0.6146943 & 0 \end{bmatrix} \begin{bmatrix} z_1(t-3) \\ z_2(t-3) \\ z_3(t-3) \end{bmatrix} \\
& + \begin{pmatrix} -0.0612 & 0 & 0 \\ 0 & 0.36788 & 0 \\ 0 & 0 & 0.64752 \end{pmatrix} \\
& + \begin{pmatrix} 0.02308 & 0 & 0 \\ 0 & 0.0147 & 0 \\ 0 & 0 & -0.52866 \end{pmatrix} \begin{bmatrix} 0 & 0.2906149 & 0.7093851 \\ 0.3952465 & 0 & 0.6047535 \\ 0.3853057 & 0.6146943 & 0 \end{bmatrix} \begin{bmatrix} z_1(t-4) \\ z_2(t-4) \\ z_3(t-4) \end{bmatrix} \\
& + \begin{pmatrix} 0.22555 & 0 & 0 \\ 0 & -0.0182 & 0 \\ 0 & 0 & 0.57007 \end{pmatrix} \\
& + \begin{pmatrix} 0.48205 & 0 & 0 \\ 0 & 0.77624 & 0 \\ 0 & 0 & 0.18608 \end{pmatrix} \begin{bmatrix} 0 & 0.2906149 & 0.7093851 \\ 0.3952465 & 0 & 0.6047535 \\ 0.3853057 & 0.6146943 & 0 \end{bmatrix} \begin{bmatrix} z_1(t-5) \\ z_2(t-5) \\ z_3(t-5) \end{bmatrix} \\
& + \begin{pmatrix} -0.0291 & 0 & 0 \\ 0 & -1.5229 & 0 \\ 0 & 0 & 0.26054 \end{pmatrix} \\
& + \begin{pmatrix} -0.73392 & 0 & 0 \\ 0 & 1.16607 & 0 \\ 0 & 0 & -0.54492 \end{pmatrix} \begin{bmatrix} 0 & 0.2906149 & 0.7093851 \\ 0.3952465 & 0 & 0.6047535 \\ 0.3853057 & 0.6146943 & 0 \end{bmatrix} \begin{bmatrix} z_1(t-6) \\ z_2(t-6) \\ z_3(t-6) \end{bmatrix} \\
& + \begin{pmatrix} 0.46512 & 0 & 0 \\ 0 & -0.9507 & 0 \\ 0 & 0 & 0.35868 \end{pmatrix} \\
& + \begin{pmatrix} -0.54068 & 0 & 0 \\ 0 & 1.29301 & 0 \\ 0 & 0 & -0.56029 \end{pmatrix} \begin{bmatrix} 0 & 0.2906149 & 0.7093851 \\ 0.3952465 & 0 & 0.6047535 \\ 0.3853057 & 0.6146943 & 0 \end{bmatrix} \begin{bmatrix} z_1(t-7) \\ z_2(t-7) \\ z_3(t-7) \end{bmatrix} \\
& + \begin{pmatrix} 0.17788 & 0 & 0 \\ 0 & -0.2093 & 0 \\ 0 & 0 & 0.45751 \end{pmatrix} \\
& + \begin{pmatrix} 0.25111 & 0 & 0 \\ 0 & 1.05235 & 0 \\ 0 & 0 & 0.09516 \end{pmatrix} \begin{bmatrix} 0 & 0.2906149 & 0.7093851 \\ 0.3952465 & 0 & 0.6047535 \\ 0.3853057 & 0.6146943 & 0 \end{bmatrix} \begin{bmatrix} z_1(t-8) \\ z_2(t-8) \\ z_3(t-8) \end{bmatrix} \\
& + \begin{pmatrix} 0.11596 & 0 & 0 \\ 0 & -0.4572 & 0 \\ 0 & 0 & 0.12002 \end{pmatrix} \\
& + \begin{pmatrix} 0.40552 & 0 & 0 \\ 0 & 1.23474 & 0 \\ 0 & 0 & 0.08518 \end{pmatrix} \begin{bmatrix} 0 & 0.2906149 & 0.7093851 \\ 0.3952465 & 0 & 0.6047535 \\ 0.3853057 & 0.6146943 & 0 \end{bmatrix} \begin{bmatrix} z_1(t-6) \\ z_2(t-6) \\ z_3(t-6) \end{bmatrix} \\
& + \begin{bmatrix} e_1(t) \\ e_2(t) \\ e_3(t) \end{bmatrix}
\end{aligned}$$

RIWAYAT HIDUP



Achmad Hilmi Fuady, lahir di Malang, 07 April 2001. Anak pertama dari 3 bersaudara. Putra dari pasangan Bapak Basuki Djamansyah dan Ibu Nur Isnaini Fitriyah. Pendidikan dasar ditempuh di SDIT Permata Kota Probolinggo dan lulus pada tahun 2013, kemudian melanjutkan Pendidikan menengah pertama di MTs Surya Buana Kota Malang dan lulus pada tahun 2016. Setelah itu melanjutkan pendidikan menengah atas di MAN 1 Kota Malanag dan lulus pada tahun 2019. Selanjutnya menempuh Pendidikan tinggi di Universitas Islam Negeri Maulana Malik Ibrahim Malang pada tahun 2019. Selama menempuh Pendidikan tinggi, peneliti juga aktif dalam Himpunan Mahasiswa Jurusan Matematika selama 1 periode. Peneliti dapat dihubungi melalui *e-mail*: afuady789@gmail.com.



BUKTI KONSULTASI SKRIPSI

Nama : Achmad Hilmi Fuady
NIM : 19610097
Fakultas / Program Studi : Sains dan Teknologi
Judul Skripsi : Implementasi Model *Generalized Space Time Autoregressive* Musiman pada Curah Hujan di Kota Batu
Pembimbing I : Prof. Dr. Hj. Sri Harini, M.Si.
Pembimbing II : Dr. H. Imam Sujarwo, M.Pd.

No	Tanggal	Hal	Tanda Tangan
1.	12 Desember 2022	Bimbingan Judul Skripsi	1.
2.	30 Desember 2022	Bimbingan Latar Belakang	2.
3.	2 Januari 2023	Bimbingan Penelitian Terdahulu	3.
4.	10 Januari 2023	Revisi Latar Belakang	4.
5.	17 Januari 2023	Bimbingan Bab I	5.
6.	21 Februari 2023	Bimbingan Bab I (Batasan masalah)	6.
7.	9 Maret 2023	Revisi Bab I	7.
8.	21 Maret 2023	Bimbingan Kajian Pustaka	8.
9.	28 Maret 2023	Bimbingan Daftar Pustaka	9.
10.	31 Maret 2023	Bimbingan Integrasi Ayat tentang Curah Hujan	10.
11.	4 April 2023	Revisi Daftar Pustaka dan Tanda Tangan Proposal	11.
12.	29 Agustus 2023	Pengambilan Data ke BMKG	12.
13.	12 September 2023	Revisi Proposal Skripsi Bab II	13.
14.	13 September 2023	Bimbingan Analisis dan Pengolahan Data	14.



**KEMENTERIAN AGAMA RI
UNIVERSITAS ISLAM NEGERI
MAULANA MALIK IBRAHIM MALANG
FAKULTAS SAINS DAN TEKNOLOGI**

Jl. Gajayana No.50 Dinoyo Malang Telp. / Fax. (0341)558933

15.	10 Oktober 2023	Bimbingan Integrasi Model	15.
16.	18 Oktober 2023	Bimbingan Penentuan Model GSTAR	16.
17.	27 November 2023	Tanda Tangan dan Pengajuan Seminar Hasil	17.
18.	5 Februari 2024	Bimbingan Revisi Semhas	18.
19.	14 Maret 2024	Bimbingan Revisi Pembahasan	19.
20.	3 Mei 2024	ACC Sidang Skripsi	20.
21.	14 Mei 2024	ACC Kajian Agama	21.
22.	28 Juni 2024	ACC Keseluruhan	22.

Malang, 3 Juli 2024

Mengetahui,

Ketua Program Studi Matematika



Dr. Elly Susanti, M.Sc

NIP. 19741129 200012 2 005