



**PENGELOMPOKAN STASIUN HUJAN MELALUI VARIABEL  
GEOGRAFIS PADA PEMODELAN GSTAR MUSIMAN UNTUK  
PERAMALAN CURAH HUJAN DI KABUPATEN JEMBER**

**TESIS**

Oleh

**Ira Yudistira  
NIM 151820101013**

**PROGRAM STUDI PASCA SARJANA MATEMATIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS JEMBER  
2017**



**PENGELOMPOKAN STASIUN HUJAN MELALUI VARIABEL  
GEOGRAFIS PADA PEMODELAN GSTAR MUSIMAN UNTUK  
PERAMALAN CURAH HUJAN DI KABUPATEN JEMBER**

**TESIS**

diajukan guna melengkapi tugas akhir dan memenuhi salah satu syarat  
untuk menyelesaikan Program Pasca Sarjana Matematika (S2)  
dan mencapai gelar Magister Sains

Oleh

**Ira Yudistira  
NIM 151820101013**

**PROGRAM STUDI PASCA SARJANA MATEMATIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS JEMBER  
2017**

## **PERSEMBAHAN**

Tesis ini saya persembahkan untuk:

1. Ibunda Marbiyah dan Ayahanda Iksan tercinta, yang tidak henti-hentinya memberi doa, nasehat dan kasih sayang kepada putri tercintanya;
2. Kakakku tersayang Heri Siswanto dan keluarga kecilnya yang selalu memberi dukungan dan semangat dalam suka dan duka;
3. guru-guru sejak taman kanak-kanak sampai perguruan tinggi, yang telah mendidik, memberikan ilmu dan membimbing dengan penuh kesabaran;
4. sahabat dan teman sealmamater, yang telah memberikan dorongan dan dukungan dalam penulisan tesis ini.

## MOTTO

Demi masa. Sungguh manusia berada dalam kerugian, kecuali orang-orang yang beriman dan mengerjakan kebaikan serta saling menasehati untuk kebenaran dan saling menasehati untuk kesabaran.

(terjemahan Q.S Al-Ashr ayat 1:3) \*)

Man Jaddah Wa jadda, Barang siapa yang bersungguh-sungguh , maka pasti akan berhasil. \*\*)

Apapun yang kita lakukan jangan sampai mengotori tujuan penciptaan kita sebagai manusia. \*\*\*)

---

\*) Departemen Agama Republika Indonesia. 2002. Al-Qur'an dan Terjemahannya. Jakarta : Mekar Surabaya.

\*\*) Zainudin, A. 2010. Man Jadda Wajada *The Art of Excellent Life*. Jakarta : Gramedia Pustaka Utama

\*\*\*)Penulis

## **PERNYATAAN**

Saya yang bertanda tangan di bawah ini:

nama : Ira Yudistira

NIM : 151820101013

menyatakan dengan sesungguhnya bahwa karya ilmiah yang berjudul “Pengelompokan Stasiun Hujan Melalui Variabel Geografis pada Pemodelan GSTAR Musiman untuk Peramalan Curah Hujan di Kabupaten Jember” adalah benar-benar hasil karya sendiri, kecuali kutipan yang sudah saya sebutkan sumbernya, belum pernah diajukan pada institusi mana pun, dan bukan karya jiplakan. Saya bertanggung jawab atas keabsahan dan kebenaran isinya sesuai dengan sikap ilmiah yang harus dijunjung tinggi.

Demikian pernyataan ini saya buat dengan sebenarnya, tanpa ada tekanan dan paksaan dari pihak manapun serta bersedia mendapat sanksi akademik jika ternyata di kemudian hari pernyataan ini tidak benar.

Jember, Juni 2017  
Yang menyatakan,

Ira Yudistira  
NIM. 151820101013

**TESIS**

**PENGELOMPOKAN STASIUN HUJAN MELALUI VARIABEL  
GEOGRAFIS PADA PEMODELAN GSTAR MUSIMAN UNTUK  
PERAMALAN CURAH HUJAN DI KABUPATEN JEMBER**

Oleh

Ira Yudistira  
NIM 151820101013

Pembimbing:

Dosen Pembimbing Utama

: Dr. Alfian Futuhul Hadi, S.Si, M.Si

Dosen Pembimbing Anggota

: Dian Anggraeni, S.Si, M.Si

## PENGESAHAN

Tesis berjudul “Pengelompokan Stasiun Hujan Melalui Variabel Geografis pada Pemodelan GSTAR Musiman untuk Peramalan Curah Hujan di Kabupaten Jember” telah diuji dan disahkan pada:

hari, tanggal : :

tempat : Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas  
Jember.

Tim Pengaji:

Ketua,

Dr. Alfian Futuhul Hadi, S.Si, M.Si.  
NIP. 197407192000121001

Sekretaris,

Dian Anggraeni, S.Si, M.Si.  
NIP. 198202162006042002

Pengaji I,

Pengaji II,

Dr. Mohamad Fatekurohman, S.Si., M.Si.  
NIP. 196906061998031001

Drs. Budi Lestari, PGD.Sc., M.Si.  
NIP. 196310251991031003

Mengesahkan  
Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam  
Universitas Jember

Drs. Sujito, Ph.D.  
NIP 196102041987111001

## RINGKASAN

**Pengelompokan Stasiun Hujan Melalui Variabel Geografis pada Pemodelan GSTAR Musiman untuk Peramalan Curah Hujan di Kabupaten Jember;** Ira Yudistira; 151820101013; 2017; 49 Halaman; Magister Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Jember.

Peramalan (*Forecasting*) merupakan analisis statistik untuk memperoleh gambaran tentang perkembangan suatu kejadian di masa mendatang. *Forecasting* dilakukan pada data deret waktu (*time series*), yaitu suatu deretan observasi yang diambil secara berurutan berdasarkan waktu dengan interval yang sama. Seiring perkembangannya, penelitian dibidang *time series* menunjukkan bahwa data yang dijumpai tidak hanya mengandung keterkaitan dengan kejadian pada waktu sebelumnya, akan tetapi juga mempunyai keterkaitan antar lokasi atau biasa disebut dengan hubungan spasial. *Time series* dengan unsur dependensi waktu dan lokasi dimodelkan dengan model *Space-Time*. Salah satu model *Space-Time* adalah model STAR. Model STAR mengasumsikan bahwa lokasi-lokasi yang diteliti memiliki karakteristik yang homogen sehingga model ini kurang efektif jika dihadapkan pada lokasi-lokasi yang heterogen. Kelemahan ini kemudian diperbaiki oleh model *Generalized Space Time Autoregresif* (GSTAR).

Jember merupakan salah satu Kabupaten di Pulau Jawa dengan topografi wilayah yang beragam. Sebagian wilayah merupakan daerah pantai, dataran dengan ketinggian yang beragam, daerah bukit serta perbatasan pegunungan di daerah barat dan timur. Disamping itu, sebagian besar wilayahnya berupa lahan pertanian dan perkebunan, sehingga sebagian besar perekonomian masyarakat jember terfokus pada pertanian dan perkebunan. Informasi mengenai pola curah hujan sangat berguna bagi petani untuk membantu perencanaan pola tanam. Berdasarkan hal tersebut, peneliti tertarik untuk melakukan analisis peramalan curah hujan di Kabupaten Jember menggunakan model GSTAR Musiman dengan dua macam pengelompokan data.

Pengelompokan pertama dilakukan berdasarkan letak stasiun hujan yang dilakukan oleh Badan Pusat Statistik (BPS) Jember, kemudian pengelompokan kedua dilakukan menggunakan algoritma *K-Means*. Model GSTAR dengan unsur musiman serta pengelompokan *K-Means* ini diharapkan dapat memberikan hasil peramalan yang lebih baik.

Data dalam penelitian ini adalah data curah hujan dari 77 stasiun hujan di Kabupaten Jember periode 2005 sampai dengan 2016. Data tersebut terbagi menjadi dua, yaitu data *in-sample* dan data *out-sample*. Data *in-sample* adalah data yang digunakan untuk membentuk model peramalan, yaitu data bulan Januari 2005 sampai dengan Desember 2015. Sedangkan data *out-sample* adalah data yang digunakan untuk memeriksa daya ramal model, yaitu data curah hujan bulan Januari 2016 sampai dengan Desember 2016. Secara garis besar, tahapan analisis peramalan dalam penelitian ini adalah pengelompokan data, identifikasi data, pemodelan GSTAR, kemudian analisis data dengan melihat RMSE, dimana RMSE yang lebih kecil menunjukkan model yang lebih baik.

Pemodelan GSTAR dilakukan pada kedua pengelompokan, berdasarkan data rata-rata curah hujan setiap bulan pada masing-masing wilayah dari kedua pengelompokan. Pemodelan pada masing-masing pengelompokan dilakukan sebanyak dua kali, yaitu Pemodelan GSTAR Non Musiman dan GSTAR Musiman. Sehingga terbentuk empat macam model GSTAR. Model yang terbentuk adalah  $GSTAR_B(1; 1)$ ,  $GSTAR_B - \text{Musiman}(1; 1)$ ,  $GSTAR_K(1; 1)$ , dan  $GSTAR_K - \text{Musiman}(1; 1)$  dengan nilai RMSE berturut turut adalah 163,293 ; 155,107; 147,505; dan 141,466. Berdasarkan nilai RMSE tersebut, didapat model terbaik adalah model  $GSTAR_K - \text{Musiman}(1; 1)$ , yaitu model GSTAR Musiman pada pengelompokan *K-Means*.

Jika dibandingkan antara model non musiman dengan model musiman, maka model musiman memberikan nilai RMSE yang lebih kecil, baik pada pengelompokan BPS maupun pengelompokan *K-Means*. Sedangkan jika dibandingkan berdasarkan

pengelompokan data, maka model pada pengelompokan K-Means memiliki nilai RMSE yang lebih kecil dibandingkan pada pengelompokan BPS. Sehingga dapat disimpulkan bahwa dengan memasukkan unsur musiman pada model dapat memperkecil nilai RMSE. Selain itu, pengelompokan K-Means dalam penelitian ini juga dapat memperkecil nilai RMSE model, baik pada model non musiman maupun model musiman.

## **KATA PENGANTAR**

Puji dan syukur penulis panjatkan kehadirat Allah SWT yang telah memberikan rahmat, taufik serta hidayah-Nya sehingga tesis yang berjudul “Pengelompokan Stasiun Hujan Melalui Variabel Geografis pada Pemodelan GSTAR Musiman untuk Peramalan Curah Hujan di Kabupaten Jember” dapat terselesaikan. Tugas akhir ini disusun untuk memenuhi syarat dalam menyelesaikan pendidikan strata dua (S2) pada Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Jember.

Penyusunan tesis ini tidak terlepas dari bantuan berbagai pihak, baik secara langsung maupun tidak langsung. Oleh karena itu, penulis menyampaikan terima kasih kepada:

1. Dr. Alfian Futuhul Hadi, S.Si, M.Si. selaku Dosen Pembimbing Utama sekaligus Ketua Program Studi Magister Matematika Fakultas MIPA Universitas Jember dan Dian Anggraeni, S.Si, M.Si. selaku Dosen Pembimbing Anggota yang telah meluangkan waktu, pikiran, dan perhatian dalam penulisan tesis ini;
2. Dr. Mohamad Fatekurohman, S.Si., M.Si. selaku Dosen Penguji I dan Drs. Budi Lestari, PGD.Sc., M.Si. selaku dosen penguji II yang telah memberikan kritik dan saran demi kesempurnaan tesis ini;
3. Bapak Drs. Sujito, Ph.D. Selaku Dekan Fakultas MIPA Universitas Jember;
4. Bapak Kusbudiono, S.Si., M.Si. selaku ketua Jurusan Matematika Fakultas MIPA Universitas Jember;
5. seluruh staf pengajar Jurusan Matematika Fakultas MIPA Universitas Jember yang telah memberikan ilmu serta bimbingannya sehingga penulis dapat menyelesaikan tesis ini;
6. Keluarga Besar Mahasiswa Magister Matematika 2015 yang telah memberikan semangat dan bantuan dalam proses penulisan tesis ini;

7. teman-teman Kos 41A terima kasih atas keceriaan dan canda tawa yang telah diberikan;
8. serta semua pihak yang tidak dapat disebutkan satu-persatu.

Penulis juga menerima segala kritik dan saran dari semua pihak demi kesempurnaan tesis ini. Akhirnya penulis berharap, semoga tesis ini dapat bermanfaat.

Jember,

Juni 2017

Penulis

## DAFTAR ISI

	Halaman
<b>HALAMAN HALAMAN JUDUL .....</b>	ii
<b>HALAMAN PERSEMBAHAN.....</b>	iii
<b>HALAMAN MOTTO .....</b>	iv
<b>HALAMAN PERNYATAAN.....</b>	v
<b>HALAMAN PEMBIMBINGAN.....</b>	vi
<b>HALAMAN PENGESAHAN .....</b>	vii
<b>RINKASAN .....</b>	viii
<b>KATA PENGANTAR.....</b>	xi
<b>DAFTAR ISI.....</b>	xiii
<b>DAFTAR TABEL.....</b>	xvi
<b>DAFTAR GAMBAR.....</b>	xvii
<b>DAFTAR LAMPIRAN .....</b>	xviii
<b>BAB 1. PENDAHULUAN .....</b>	1
<b>1.1 Latar Belakang .....</b>	1
<b>1.2 Rumusan Masalah.....</b>	3
<b>1.3 Tujuan .....</b>	4
<b>1.4 Manfaat .....</b>	4
<b>BAB 2. TINJAUAN PUSTAKA .....</b>	5
<b>2.1 Analisis Kluster .....</b>	5
<b>2.2 Analisis <i>Time Series</i> .....</b>	6
<b>2.3 Kestasioneran Data .....</b>	8
2.3.1 Uji ADF ( <i>Augmented Dickey Fuller</i> ).....	9
2.3.2 Pembedaan Data ( <i>Differencing</i> ).....	10
2.3.3 Transformasi <i>Box Cok</i> .....	10

<b>2.4 Model Space Time.....</b>	<b>11</b>
2.4.1 Model Space Time Autoregressive (STAR) .....	11
2.4.2 Model Generalized Space Time Autoregressive (GSTAR) ..	11
<b>2.5 Orde Model GSTAR .....</b>	<b>13</b>
<b>2.6 Bobot Lokasi Invers Jarak .....</b>	<b>14</b>
<b>2.7 Estimasi Parameter .....</b>	<b>15</b>
2.7.1 OLS ( <i>Ordinary Least Square</i> ) .....	15
2.7.2 GLS ( <i>Generalized Least Square</i> ) .....	16
<b>2.8 Uji Kesesuaian Model .....</b>	<b>17</b>
<b>2.9 Root Mean Square Error (RMSE) .....</b>	<b>18</b>
<b>BAB 3. METODE PENELITIAN.....</b>	<b>19</b>
<b>3.1 Data Penelitian .....</b>	<b>19</b>
<b>3.2 Langkah-Langkah Penelitian.....</b>	<b>19</b>
3.2.1 Pengelompokan Data .....	20
3.2.2 Identifikasi Data.....	20
3.2.3 Pemodelan GSTAR dan Estimasi Parameter .....	21
3.2.4 Metode Analisis Data .....	22
<b>BAB 4. HASIL DAN PEMBAHASAN .....</b>	<b>24</b>
<b>4.1 Diskripsi Data .....</b>	<b>24</b>
4.1.1 Pengelompokan Stasiun Hujan Oleh Badan Pusat Statistika (BPS) Jember .....	25
4.1.2 Pengelompokan Stasiun Hujan Menggunakan Algoritma K-Means .....	27
4.1.3 Uji Kestasioneran Data .....	30
<b>4.2 Pemodelan GSTAR .....</b>	<b>32</b>
4.2.1 Identifikasi Model .....	33
4.2.2 Perhitungan Bobot Invers Jarak .....	34
<b>4.3 Estimasi Parameter .....</b>	<b>35</b>
4.3.1 Estimasi Parameter Model GSTAR Non Musiman .....	35

4.3.2 Estimasi Parameter Model GSTAR Musiman .....	38
<b>4.4 Uji Kesesuaian Model .....</b>	<b>42</b>
<b>4.5 Pemilihan Model Terbaik.....</b>	<b>42</b>
<b>4.6 Peramalan Curah Hujan 2017 .....</b>	<b>44</b>
<b>BAB 5. PENUTUP.....</b>	<b>47</b>
<b>5.1 Kesimpulan .....</b>	<b>47</b>
<b>5.2 Saran .....</b>	<b>47</b>
<b>DAFTAR PUSTAKA .....</b>	<b>48</b>

**LAMPIRAN**

## DAFTAR TABEL

	Halaman
Tabel 2.1 Nilai $\lambda$ dan Transformasinya .....	10
Tabel 4.1 Pengelompokan Stasiun Hujan Oleh BPS Jember .....	25
Tabel 4.2 Matriks Korelasi Antar Wilayah Pengelompokan BPS .....	27
Tabel 4.3 Pengelompokan Stasiun Hujan dengan Algoritma K-Means .....	28
Tabel 4.4 Matriks Korelasi Antar Wilayah Pengelompokan K-Means .....	30
Tabel 4.5 Hasil Uji Kestasioneran Data dengan ADF .....	32
Tabel 4.6 Ringkasan Nilai AIC Model dengan Orde Tentatif .....	33
Tabel 4.7 Jarak Antar Wilayah Kelompok Stasiun Hujan .....	34
Tabel 4.8 Estimasi Parameter Model GSTAR_B (1;1) dan GSTAR_K (1;1)	36
Tabel 4.9 Estimasi Parameter Model GSTAR Musiman .....	38
Tabel 4.10 Hasil Uji Portmanteau Model .....	42
Tabel 4.11 Nilai RMSE Model .....	43
Tabel 4.12 Perbandingan data Testing dengan Hasil Peramalan Curah Hujan Kabupaten Jember Tahun 2016 di Empat Wilayah .....	44
Tabel 4.13 Peramalan Curah Hujan Tahun 2017 .....	45

## DAFTAR GAMBAR

	Halaman
Gambar 2.1 Pola Data Time series (a) Pola Tren, (b) Pola Musiman, (c) Pola Siklis, (d) Pola Acak.....	8
Gambar 3.1 Skema Metode Penelitian.....	23
Gambar 4.1 Plot Hasil Pengelompokan Stasiun Hujan Oleh BPS Jember .....	26
Gambar 4.2 Plot Hasil Pengelompokan Stasiun Hujan Menggunakan Algoritma K-Means .....	29
Gambar 4.3 Plot Data Curah Hujan di Empat Wilayah Kabupaten Jember Tahun 2005-2015 (a) Pengelompokan BPS (b) Pengelompokan <i>K-Means</i> .....	31
Gambar 4.4 Curah Hujan tahun 2005-2016 dan Peramalan Curah Hujan Tahun 2017 .....	46

## DAFTAR LAMPIRAN

	Halaman
A. KETERANGAN STRUKTUR FUNGSI.....	<b>50</b>
A.1 Struktur Fungsi <code>kmeans( )</code> .....	50
A.2 Struktur Fungsi <code>adf.test( )</code> .....	50
A.3 Struktur Fungsi <code>gls( )</code> .....	50
A.4 Struktur Fungsi <code>LjungBox( )</code> .....	51
B. SKRIP PROGRAM R .....	<b>52</b>
B.1 Pemodelan GSTAR pada Data Pengelompokan BPS Jember .....	52
B.3 Pengelompokan <i>K-Means</i> .....	58
B.4 Pemodelan GSTAR pada Data Pengelompokan <i>K-Means</i> .....	58
C. DATA CURAH HUJAN.....	<b>66</b>

## BAB 1. PENDAHULUAN

### 1.1 Latar Belakang

Peramalan (*Forecasting*) merupakan analisis statistik untuk memperoleh gambaran tentang perkembangan suatu kejadian di masa mendatang. *Forecasting* dilakukan pada data deret waktu (*time series*). Data *time series* merupakan suatu deretan observasi yang diambil secara berurutan berdasarkan waktu dengan interval yang sama, yaitu harian, mingguan, bulanan, tahunan atau periode waktu lainnya. Data *time series* mempunyai struktur korelasi antar nilai-nilainya karena dipengaruhi oleh data pada waktu-waktu sebelumnya (Box *et al.*, 1994).

Seiring perkembangannya, penelitian dibidang *time series* menunjukkan bahwa seringkali dalam kehidupan sehari-hari data yang dijumpai tidak hanya mengandung keterkaitan dengan kejadian pada waktu sebelumnya, akan tetapi juga mempunyai keterkaitan dengan lokasi atau tempat lain yang biasanya disebut dengan hubungan spasial. Data *time series* dengan unsur dependensi waktu dan lokasi dimodelkan dengan model *Space-Time*. Pfeifer dan Deutsch pada tahun 1980 mengenalkan model STAR (*Space Time Autoregresif*) sebagai model *Space-Time*. Model STAR mengasumsikan bahwa lokasi-lokasi yang diteliti memiliki karakteristik yang seragam (homogen). Pada perkembangannya, model ini banyak dikaji oleh beberapa peneliti pemodelan *time series*. Model STAR mempunyai kelemahan pada fleksibilitas parameter dengan dependensi waktu dan lokasi yang memiliki karakteristik berbeda (heterogen). Kelemahan ini telah diperbaiki oleh Borovkova *et al* (2002) melalui suatu model yang dikenal dengan *Generalized Space Time Autoregresif* (GSTAR).

Model GSTAR merupakan generalisasi dari model STAR. Berbeda dengan model STAR, model GSTAR tidak mensyaratkan nilai-nilai parameter sama untuk semua lokasi. Oleh karena itu Wutsqa *et al.* (2010) menyatakan bahwa model GSTAR lebih realistik karena pada kenyataannya lebih banyak ditemui model dengan

parameter berbeda untuk lokasi berbeda. Perbedaan antar lokasi ini ditunjukkan dalam bentuk matriks pembobot. Bobot lokasi pada GSTAR secara umum dibagi menjadi tiga yaitu bobot lokasi seragam (*uniform*), invers jarak dan normalisasi korelasi silang. Sama halnya dengan model STAR, model GSTAR juga telah banyak dikaji dalam pemodelan *time series*, diantaranya adalah pemodelan curah hujan.

Curah hujan merupakan fenomena alam yang mempunyai pengaruh penting dalam kehidupan sehari-hari terutama dalam kegiatan perekonomian masyarakat di sektor pertanian dan perkebunan. Informasi mengenai banyaknya curah hujan sangat berguna bagi petani dalam mengantisipasi kemungkinan terjadinya peristiwa-peristiwa ekstrim yang tidak diinginkan seperti kebanjiran dan kekeringan. Sebagian besar wilayah kabupaten Jember merupakan lahan pertanian dan perkebunan, sehingga analisis pola curah hujan perlu dilakukan untuk memudahkan petani menghindari kegagalan produksi.

Peramalan curah hujan di kabupaten Jember telah dilakukan oleh beberapa peneliti diantaranya adalah Retnaningrum (2015) membandingkan hasil ketepatan ramalan curah hujan di Kabupaten Jember menggunakan model ARIMA dan model STAR. Retnaningrum mengelompokkan 77 stasiun hujan yang terdapat di kabupaten Jember ke dalam empat kelompok kemudian dilakukan peramalan berdasarkan rata-rata curah hujan dari masing-masing kelompok tersebut. Hasil penelitian tersebut menunjukkan bahwa Model STAR menghasilkan ketepatan peramalan yang lebih baik dibandingkan Model ARIMA. Hal ini disebabkan oleh adanya hubungan spasial antar lokasi stasiun hujan yang tidak bisa dijelaskan oleh model ARIMA. Pada tahun selanjutnya, Nurcahyani (2016) melakukan penelitian tentang peramalan curah hujan di Kabupaten Jember menggunakan model GSTAR dengan tiga macam bobot lokasi, yaitu bobot seragam, invers jarak, dan normalisasi korelasi silang. Serupa dengan Retnaningrum (2015), Nurcahyani (2016) juga mengelompokkan 77 stasiun hujan yang terdapat di kabupaten Jember ke dalam empat kelompok menggunakan algoritma Hirarki. Hasil yang diperoleh menunjukkan bahwa model yang terbaik adalah model GSTAR (11) dengan bobot lokasi invers jarak.

Sampai saat ini, penelitian tentang peramalan curah hujan di Kabupaten Jember masih terbatas pada pemodelan *time series* dengan data non-musiman. Sedangkan pada kenyataannya, curah hujan merupakan kejadian berkala setiap tahunnya sehingga menimbulkan pola musiman. Selain itu, sebagian besar penelitian yang berkaitan dengan model GSTAR, metode estimasi parameter yang digunakan adalah OLS (*Ordinary Least Square*). Estimasi parameter menggunakan OLS pada model GSTAR dengan residual saling berkorelasi akan menghasilkan estimator yang relatif tidak efisien. Salah satu metode yang sesuai untuk mengestimasi parameter dengan residual saling berkorelasi adalah GLS (*Generalized Least Square*) yang biasanya digunakan dalam model SUR (*Seemingly Unrelated Regression*) (Prastuti *et.al*, 2014).

Jember memiliki topografi wilayah yang beragam. Sebagian wilayah merupakan daerah pantai, dataran dengan ketinggian yang beragam, daerah berbukit serta perbatasan pengunungan di daerah barat dan timur. Berdasarkan hal tersebut, peneliti tertarik untuk melakukan analisis peramalan curah hujan di Kabupaten Jember menggunakan model GSTAR Musiman. Sejalan dengan dua penelitian sebelumnya, penelitian ini akan membagi 77 stasiun hujan di Kabupaten Jember kedalam empat kelompok. Pengelompokan pertama dilakukan berdasarkan letak stasiun hujan yang dilakukan oleh Badan Pusat Statistik (BPS) Jember, kemudian pengelompokan kedua dilakukan menggunakan algoritma Non Hirarki K-Means. Model GSTAR dengan unsur musiman serta pengelompokan K-Means ini diharapkan dapat memberikan hasil peramalan yang lebih baik.. Data curah hujan yang akan digunakan dalam peneltian ini adalah data curah hujan pada periode 2005 sampai dengan 2016.

## 1.2 Rumusan Masalah

Jember merupakan salah satu Kabupaten di Pulau Jawa yang sebagian besar wilayahnya berupa lahan pertanian dan perkebunan, sehingga sebagian besar perekonomian masyarakat jember terfokus pada pertanian dan perkebunan. Informasi

mengenai pola curah hujan sangat berguna bagi petani untuk membantu perencanaan pola tanam. Sebagaimana telah dijelaskan sebelumnya bahwa curah hujan merupakan kejadian berkala setiap tahunnya sehingga menimbulkan pola musiman. Berdasarkan hal tersebut, rumusan masalah yang akan dibahas dalam penelitian ini adalah

- a. Bagaimana mengoptimalkan pengelompokan 77 stasiun hujan pada pemodelan GSTAR melalui variabel-variabel geografis agar didapatkan peramalan yang lebih baik.
- b. Bagaimana memodelkan peramalan curah hujan di Kabupaten Jember menggunakan model GSTAR dengan memasukkan faktor musiman.
- c. Bagaimana peramalan curah hujan di Kabupaten Jember tahun 2017.

### **1.3 Tujuan**

Berdasarkan rumusan masalah, tujuan dari penelitian ini adalah sebagai berikut:

- a. Mendapatkan pengelompokan 77 stasiun hujan yang optimal melalui variabel-variabel geografis sehingga didapatkan peramalan yang lebih baik.
- b. Mendapatkan model peramalan GSTAR curah hujan di Kabupaten Jember dengan unsur musiman.
- c. Mendapatkan peramalan curah hujan di Kabupaten Jember tahun 2017.

### **1.4 Manfaat**

Adapun manfaat yang diharapkan dari penelitian ini adalah sebagai bahan pembanding bagi peneliti selanjutnya dalam mempelajari metode-metode statistika terutama yang berhubungan dengan pemodelan time series. Selain itu, dengan adanya penelitian ini diharapkan dapat menambah wawasan keilmuan dan pengetahuan dalam memodelkan data *time series* yang mengandung unsur musiman, khususnya data curah hujan di kabupaten Jember sehingga dapat membantu perencanaan pola tanam dalam bidang pertanian.

## BAB 2. TINJAUAN PUSTAKA

### 2.1 Analisis Klaster

Analisis klaster merupakan analisis multivariat yang mempunyai tujuan utama untuk mengelompokkan obyek-obyek berdasarkan kemiripan karakteristik yang dimilikinya. Karakteristik antar obyek dalam satu klaster memiliki tingkat kemiripan yang tinggi, sedangkan karakteristik antar obyek pada suatu klaster dengan klaster lainnya memiliki tingkat kemiripan yang rendah. Variabel-variabel yang dilibatkan dalam analisis klaster dipilih sesuai dengan tujuan pengklasteran. Kemiripan antar obyek diukur dengan menggunakan ukuran jarak. Salah satu ukuran jarak yang umum digunakan adalah jarak *Euclidean*.

Secara garis besar, analisis klaster terbagi menjadi dua metode, yaitu metode Hirarki dan Non Hirarki. Perbedaan mendasar dari kedua metode tersebut terletak pada proses penentuan jumlah klaster yang diinginkan. Metode Hirarki memulai pengelompokan dengan dua atau lebih obyek yang mempunyai kesamaan karakteristik paling dekat. Kemudian diteruskan pada obyek yang lain dan seterusnya hingga terbentuk sejumlah klaster dari data tersebut. Sedangkan metode Non Hirarki harus menentukan jumlah klaster yang diinginkan terlebih dahulu. Salah satu metode Non Hirarki yang sering digunakan adalah metode *K-Means* (Sarstedt *et.al.*, 2014).

*K-Means* merupakan salah satu metode analisis klaster Non Hirarki dengan teknik mempartisi obyek yang ada kedalam satu atau lebih klaster berdasarkan kesamaan karakteristiknya. Hal ini menyebabkan obyek dengan karakteristik yang sama terkelompok ke dalam satu klaster, sedangkan obyek dengan karakteristik berbeda akan membentuk klaster lainnya. Agusta (2007) merumuskan algoritma metode *K-Means* sebagai berikut:

- a. Menentukan  $K$  jumlah klaster yang akan dibentuk.

- b. Menetapkan pusat klaster  $C_m$ , yaitu nilai rata-rata dari keseluruhan obyek yang terdapat dalam klaster ke- $m$ .
- c. Menentukan jarak terdekat setiap obyek dengan setiap pusat klaster menggunakan jarak *Euclidian*. Jarak *Euclidian* dihitung menggunakan persamaan berikut.

$$d(x, x_{i+1}) = \sqrt{\sum_{i=1}^{n_m} (x_i - x_{i+1})^2}$$

dimana :

$x_i$  = nilai pengamatan obyek ke- $i$  dengan  $i = 1, 2, \dots, n_m$

$x_{i+1}$  = nilai pengamatan obyek ke- $(i + 1)$

$n_m$  = banyak obyek pada klaster ke- $m$

- d. Menentukan obyek yang mempunyai jarak terdekat dengan pusat klaster. Jika obyek berpindah dari posisi awal (langkah a) maka pusat klaster ( $C_m$ ) harus dihitung kembali menggunakan persamaan berikut.

$$C_m = \frac{1}{n_m} \sum_{i=1}^{n_m} x_i$$

- e. Ulangi kembali langkah kedua (langkah b) hingga tidak ada lagi pemindahan obyek dari satu klaster ke klaster lainnya.

## 2.2 Analisis Time series

Deret waktu (*time series*) adalah serangkaian data observasi yang diambil secara berurutan berdasarkan waktu dengan interval yang sama, yaitu harian, mingguan, bulanan, tahunan atau periode waktu lainnya. Menurut Wei (2006), secara matematis time series didefinisikan oleh nilai-nilai  $Z_1, Z_2, \dots, Z_n$  dari suatu variabel  $Z$  untuk titik-titik waktu  $t_1, t_2, \dots, t_n$ . *Time series* umumnya digunakan untuk memperoleh gambaran keadaan atau sifat variabel pada periode yang akan datang. Analisis *time series* merupakan analisis statistik yang digunakan untuk meramalkan

struktur probabilistik keadaan yang akan terjadi dimasa mendatang. Analisis ini menggunakan pola data untuk meramalkan masa depan, sehingga salah satu aspek penting dari pemilihan teknik peramalan yang sesuai data *time series* adalah dengan memperhatikan jenis pola data tersebut. Menurut Cryer dan Kung-Sik (2008) terdapat empat jenis pola data yaitu :

a. Pola Tren (*Trend*)

Pola *trend* terbentuk ketika data observasi terlihat mengalami peningkatan atau penurunan dalam periode waktu jangka panjang. *Trend* dapat disebabkan oleh misalnya pertumbuhan populasi, inflasi, perubahan teknologi, dan peningkatan produktivitas.

b. Pola Musiman (*Seasonality*)

Pola ini terjadi ketika data observasi dipengaruhi oleh faktor musiman. Pola musiman mengacu pada suatu perubahan yang berulang dengan sendirinya dari waktu ke waktu. Pola musiman merupakan fluktuasi dari data yang terjadi secara periodik dalam kurun waktu tertentu, misalkan tahunan, triwulan, kuartalan, bulanan, mingguan, atau harian.

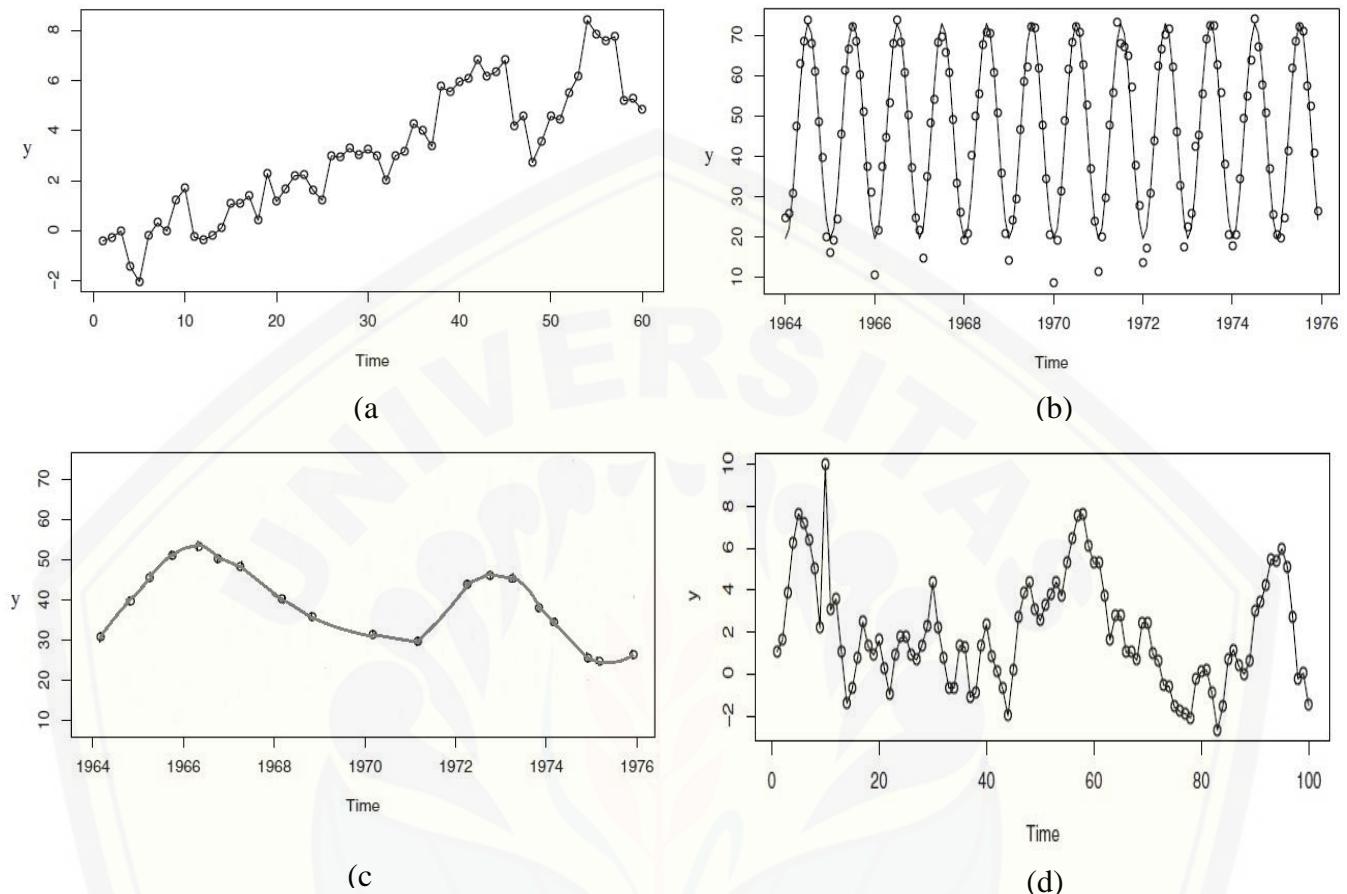
c. Pola Siklis (*Cycle*)

pola siklis terjadi ketika data observasi terlihat naik turun dalam periode waktu yang lebih panjang dari pola musiman. Hal ini menyebabkan pola siklis hampir memiliki karakteristik yang sama dengan pola musiman. Umumnya periode pola siklis berlangsung selama lebih dari setahun dan variasi gelombangnya tidak pernah memperlihatkan pola yang tertentu.

d. Pola Acak (*Random*)

Pola random terjadi ketika data observasi tidak dipengaruhi oleh faktor-faktor khusus sehingga pola menjadi tidak menentu dan tidak dapat diperkirakan secara biasa. Pola random ditimbulkan oleh suatu kejadian yang tak terduga seperti perang, gempa bumi dan sebagainya.

Bentuk pola data *time series* dapat dilihat pada Gambar 2.1 dibawah ini.



Gambar 2.1 Pola Data *Time series* (a) Pola Tren, (b) Pola Musiman, (c) Pola Siklis, (d) Pola Acak

### 2.3 Kestasioneran Data

Pemodelan *time series* mensyaratkan kestasioneran data yang digunakan. Data yang stasioner memiliki pola yang tidak berubah secara signifikan sehingga tidak akan terlalu berpengaruh pada model peramalan yang terbentuk. Thomas (1997) menyebutkan bahwa *time series*  $Z(t)$  dikatakan stasioner jika mean dan variannya konstan, yaitu :

- $E(Z(t)) = \mu$  konstan untuk semua  $t$
- $Var(Z(t)) = \sigma^2$  konstan untuk semua  $t$

begitu pula sebaliknya, *time series* dikatakan tidak stasioner jika tidak memenuhi salah satu kriteria tersebut. Sedangkan berdasarkan plot data pengamatan terhadap waktu, data dikatakan stasioner jika secara stokastik menunjukkan pola yang konstan dari waktu ke waktu dengan kecenderungan fluktuasinya di sekitar nilai tengah dengan amplitudo yang relatif tetap.

### 2.3.1 Uji ADF (*Augmented Dickey Fuller*)

Uji formal kestasioneran dapat dilakukan dengan uji ADF (*Augmented Dickey Fuller*). Uji ADF merupakan pengujian stasioner dengan menentukan apakah *time series* mengandung akar unit (*unit root*). Uji ADF diperkenalkan oleh Dickey dan Fuller pada tahun 1979 dengan model sederhana

$$\Delta Z_t = \beta_0 + \gamma Z(t-1) + e_t$$

dimana  $\gamma = \beta_1 - 1$  dan  $\Delta Z(t) = Z(t) - Z(t-1)$  dengan  $Z(t)$  adalah data pada waktu ke- $t$ . Hipotesis yang digunakan adalah

$$H_0 : \gamma = 0 \text{ (mengandung akar unit atau tidak stasioner)}$$

$$H_1 : \gamma \neq 0 \text{ (tidak mengandung akar unit atau stasioner)}$$

Uji hipotesis dilakukan dengan menggunakan statistik- $\tau$  yang didefinisikan oleh formula berikut.

$$\tau = \frac{\hat{\gamma} - \gamma}{se(\hat{\gamma})}$$

dimana  $\hat{\gamma}$  adalah penaksiran kuadrat terkecil dari  $\gamma$  dan  $se(\hat{\gamma})$  adalah kesalahan standart dari  $\hat{\gamma}$ . Pengambilan keputusan berdasarkan kriteria terima  $H_0$  jika statistik- $\tau$  lebih besar dari nilai kritis ADF dan dapat disimpulkan data tidak stasioner. Sedangkan jika statistik- $\tau$  lebih kecil dari nilai kritis ADF atau  $p-value < 0.05$  maka tolak  $H_0$  dan dapat disimpulkan bahwa *time series* stasioner. Jika data tidak stasioner dalam mean maka dilakukan pembedaan, sedangkan jika data tidak stasioner dalam varian maka dilakukan transformasi.

### 2.3.2 Pembedaan Data (*Differencing*)

*Differencing* merupakan salah satu cara yang umum digunakan untuk mengatasi data yang tidak stasioner. Proses *differencing* dapat dilakukan untuk beberapa periode sampai data stasioner, yaitu dengan cara mengurangkan suatu data dengan data sebelumnya. *Differencing* dilakukan ketika data tidak stasioner dalam mean. Jika  $Z'_t$  adalah data yang telah di *differencing* maka Makridakis (1995) merumuskan proses *differencing* dengan persamaan di bawah ini.

$$Z'(t) = (1 - B)^d Z(t)$$

dimana  $B$  adalah operator shift mundur (*backward shift*), yaitu operator yang menunjukkan pergeseran data satu periode ke belakang. Sedangkan  $d$  adalah variabel yang menunjukkan orde *differencing*, yaitu banyaknya *differencing* yang dilakukan sampai data stasioner.

### 2.3.3 Transformasi *Box–Cox*

Data yang tidak stasioner dalam varian dapat diatasi dengan metode transformasi *Box–Cox*. Transformasi *Box–Cox* adalah transformasi pangkat berparameter tunggal yaitu  $\lambda$ . Variabel  $\lambda$  dipangkatkan pada variabel respon  $Z(t)$  sehingga transformasinya menjadi  $Z_t^\lambda$  dimana  $\lambda$  adalah parameter yang perlu diduga. Tabel (2.1) di bawah ini merangkum beberapa nilai  $\lambda$  dengan transformasinya (Ispriyanti, 2004).

Tabel 2.1 Nilai  $\lambda$  dan Transformasinya

No.	$\lambda$	Transformasi
1.	2	$Z^2(t)$
2.	0.5	$\sqrt{Z(t)}$
3.	0	$\log Z(t) / \ln Z(t)$
4.	-0.5	$1 / \sqrt{Z(t)}$
5.	-1.0	$1/Z(t)$

## 2.4 Model Space Time

Data *time series* yang mengandung dependensi waktu dan lokasi dimodelkan dengan model *space time*. Berikut ini beberapa model *space time* :

### 2.4.1 Model Space Time Autoregressive (STAR)

Model STAR merupakan model peramalan *time series* yang mempunyai karakteristik dependensi linier dalam lokasi dan waktu. Model STAR mengasumsikan bahwa penelitian di waktu sekarang dipengaruhi oleh waktu sebelumnya di lokasi tetentu dimana lokasi-lokasi yang diteliti adalah sama sehingga model ini hanya dapat diterapkan pada lokasi yang bersifat homogen. Model STAR dengan orde *autoregressive*  $p$  dan orde spasial  $\lambda_k$  atau dapat dituliskan  $\text{STAR}(p, \lambda_k)$  dirumuskan oleh persamaan (2.1) di bawah ini (Pfeifer *et.al.*, 1980):

$$\mathbf{Z}(t) = \sum_{k=1}^p \sum_{l=1}^{\lambda_k} \emptyset_{kl} \mathbf{W}^{(l)} \mathbf{Z}(t-k) + \mathbf{e}(t) \quad (2.1)$$

dengan

- $\emptyset_{kl} = \text{diag}(\phi_{k0}^1, \dots, \phi_{k0}^N)$  merupakan matriks parameter waktu
- $\mathbf{e}(t)$  = vektor *noise* berukuran  $(N \times 1)$  yang independen, identik, dan berdistribusi normal multivariat dengan mean =  $\mathbf{0}$  dan matriks varians-kovarians =  $\sigma^2 I_N$
- $\mathbf{W}^{(l)}$  = matriks bobot ukuran  $(N \times N)$  pada lag spasial  $l = 0, 1, 2, \dots, N$
- $N$  = Jumlah lokasi.

### 2.4.2 Model Generalized Space Time Autoregressive (GSTAR)

Model GSTAR merupakan pengembangan dari model STAR serta merupakan spesifikasi dari model *Vector Autoregressive* (VAR) sehingga model ini termasuk dalam kelompok *time series* multivariat. Perbedaan yang mendasar pada model GSTAR dengan model STAR terletak pada pengasumsian parameternya. Model STAR mengasumsikan parameter *autoregressive* adalah sama untuk setiap lokasi sehingga model STAR hanya dapat digunakan pada lokasi yang homogen. Sedangkan

pada model GSTAR terdapat asumsi yang menyatakan parameter diperbolehkan berbeda untuk setiap lokasi sehingga model GSTAR dapat digunakan pada lokasi-lokasi penelitian yang bersifat heterogen.

Jika diketahui sebuah deret  $\{Z(t) : t = 0, \pm 1, \pm 2, \dots, \pm n\}$  merupakan sebuah multivariat *time series* dari  $N$  lokasi, maka Borovkova *et al.* (2008) memodelkan GSTAR  $(p; \lambda_1, \lambda_2, \dots, \lambda_p)$  secara umum dalam notasi matriks seperti dalam persamaan (2.2) berikut ini.

$$\mathbf{Z}(t) = \sum_{k=1}^p \left[ \emptyset_{k0} \mathbf{Z}(t-k) + \sum_{l=1}^{\lambda_k} \emptyset_{kl} \mathbf{W}^{(l)} \mathbf{Z}(t-1) \right] + \mathbf{e}(t) \quad (2.2)$$

dengan :

$p$  = orde *autoregressive*

$\lambda_k$  = orde spasial dengan  $k = 1, 2, \dots, p$

$\emptyset_{k0} = diag(\phi_{k0}^1, \dots, \phi_{k0}^N)$  merupakan matriks parameter waktu

$\emptyset_{kl} = diag(\phi_{kl}^1, \dots, \phi_{kl}^N)$  merupakan matriks parameter spasial

$\mathbf{e}(t)$  = vektor *noise* berukuran  $(N \times 1)$  yang independen, identik, dan berdistribusi

Normal multivariat dengan mean = 0 dan matriks varians-kovarians =  $\sigma^2 I_N$

$\mathbf{W}$  = adalah pembobot dengan  $\mathbf{W}_{ii}^{(k)} = 0$  dan  $\sum_{i \neq j} \mathbf{W}_{ij}^{(k)} = 1$ .

Jika data mengandung pola musiman maka model yang digunakan adalah model GSTAR Musiman. Model GSTAR Musiman memasukkan unsur musiman pada model umum GSTAR. Secara matematis, unsur musiman model GSTAR dengan  $s$  musiman (GSTAR  $(p; \lambda_1, \lambda_2, \dots, \lambda_p)^s$ ) dituliskan dalam notasi matriks berikut:

$$\mathbf{Z}(t) = \sum_{k=1}^p \left[ \emptyset_{k0}^s \mathbf{Z}(t-s) + \sum_{l=1}^{\lambda_k} \emptyset_{kl}^s \mathbf{W}^{(l)} \mathbf{Z}(t-s) \right] + \mathbf{e}(t) \quad (2.3)$$

dengan

$\emptyset_{k0}^s = diag(\phi_{k0}^1, \dots, \phi_{k0}^N)$  merupakan matriks parameter waktu periode musiman  $s$

$\emptyset^s_{kl} = diag(\phi_{kl}^1, \dots, \phi_{kl}^N)$  merupakan matriks parameter spasial periode musiman  $s$ , sehingga berdasarkan persamaan (2.2) dan persamaan (2.3), model GSTAR–Musiman( $p; \lambda_1, \lambda_2, \dots, \lambda_p$ ) diformulasikan sebagaimana persamaan (2.4) berikut ini:

$$\begin{aligned} \mathbf{Z}(t) = \sum_{k=1}^p & \left[ \emptyset_{k0} \mathbf{Z}(t-k) + \sum_{l=1}^{\lambda_k} \emptyset_{kl} \mathbf{W}^{(l)} \mathbf{Z}(t-1) + \emptyset^s_{k0} \mathbf{Z}(t-s) \right. \\ & \left. + \sum_{l=1}^{\lambda_k} \emptyset^s_{kl} \mathbf{W}^{(l)} \mathbf{Z}(t-s) \right] + \mathbf{e}(t) \end{aligned} \quad (2.4)$$

## 2.5 Orde Model GSTAR

Model GSTAR merupakan model peramalan *time series* yang bergantung pada orde *autoregressive* ( $p$ ) dan orde spasial ( $\lambda_p$ ). Wutsqa *et al.* (2010) menyatakan bahwa orde spasial pada model GSTAR dibatasi pada orde 1. Hal ini disebabkan model dengan orde yang lebih tinggi akan sulit untuk diinterpretasikan. Orde *autoregressive* ditentukan berdasarkan nilai *Akaike Information Criterion* (AIC) terkecil.

Tsay (2005) memformulasikan perhitungan AIC dengan persamaan (2.5) berikut ini.

$$AIC(i) = \ln \left( \frac{\sum_{i=1}^T \hat{u}_i^2}{T} \right) + \frac{2k^2 i}{T} \quad (2.5)$$

sehingga orde model adalah  $p$  sedemikian sehingga  $AIC(p) = \min_{0 \leq i \leq p} AIC(i)$ .

dimana :

$T$  = Jumlah pengamatan

$k$  = Jumlah parameter yang diestimasi dalam model regresi

$\hat{u}_i$  = Matriks taksiran kovarian residual dari model *vector autoregressive* ke- $i$

$i = 0, 1, \dots, p$  = Orde *autoregressive* tentatif model

## 2.6 Bobot Lokasi Invers Jarak

Permasalahan yang sering terjadi pada pemodelan GSTAR adalah penentuan bobot lokasi. Bobot lokasi pada model GSTAR dibagi menjadi 3 yaitu bobot lokasi seragam (*uniform*), invers jarak, dan normalisasi korelasi silang. Nurcahyani (2016) dalam penelitiannya tentang peramalan curah hujan di Kabupaten Jember dengan menggunakan model GSTAR menyebutkan bahwa bobot lokasi invers jarak menghasilkan model GSTAR terbaik dibandingkan dengan menggunakan kedua bobot lainnya.

Nilai bobot lokasi invers jarak diperoleh berdasarkan perhitungan jarak antar lokasi yang sebenarnya. Semakin lokasi yang berdekatan maka semakin besar nilai bobot lokasinya. Pembobotan dengan invers jarak mengacu pada jarak antar lokasi, misalkan jarak diantara 4 lokasi didefinisikan:

$r_1$  = Jarak antara lokasi 1 dengan lokasi 2

$r_2$  = Jarak antara lokasi 1 dengan lokasi 3

$r_3$  = Jarak antara lokasi 1 dengan lokasi 4

$r_4$  = Jarak antara lokasi 2 dengan lokasi 3

$r_5$  = Jarak antara lokasi 2 dengan lokasi 4

$r_6$  = Jarak antara lokasi 3 dengan lokasi 4

Maka bobot lokasi invers jarak dalam bentuk matriks di bawah ini (Anggraeni *et al.*, 2013).

$$W_{ij} = \begin{bmatrix} 0 & \frac{r_2 + r_3}{r_1 + r_2 + r_3} & \frac{r_1 + r_3}{r_1 + r_2 + r_3} & \frac{r_1 + r_2}{r_1 + r_2 + r_3} \\ \frac{r_4 + r_5}{r_1 + r_4 + r_5} & 0 & \frac{r_1 + r_5}{r_1 + r_4 + r_4} & \frac{r_1 + r_4}{r_1 + r_4 + r_4} \\ \frac{r_4 + r_6}{r_2 + r_4 + r_6} & \frac{r_2 + r_6}{r_2 + r_4 + r_6} & 0 & \frac{r_2 + r_4}{r_2 + r_4 + r_6} \\ \frac{r_5 + r_6}{r_3 + r_5 + r_6} & \frac{r_3 + r_6}{r_3 + r_5 + r_6} & \frac{r_3 + r_5}{r_3 + r_5 + r_6} & 0 \end{bmatrix}$$

$$= \begin{bmatrix} 0 & W_{12} & W_{13} & W_{14} \\ W_{21} & 0 & W_{23} & W_{24} \\ W_{31} & W_{32} & 0 & W_{34} \\ W_{41} & W_{42} & W_{43} & 0 \end{bmatrix}$$

Matriks  $\mathbf{W}_{ij}$  distandardkan dalam bentuk  $\mathbf{W}_{ij}^*$  untuk mendapatkan  $\sum_{i \neq j} \mathbf{W}_{ij}^{(l)} = 1$ , yaitu:

$$\mathbf{W}_{ij}^* = \begin{bmatrix} 0 & \frac{1}{W_{12}} & \frac{1}{W_{13}} & \frac{1}{W_{14}} \\ \frac{1}{W_{21}} & 0 & \frac{1}{W_{23}} & \frac{1}{W_{24}} \\ \frac{1}{W_{31}} & \frac{1}{W_{32}} & 0 & \frac{1}{W_{34}} \\ \frac{1}{W_{41}} & \frac{1}{W_{42}} & \frac{1}{W_{43}} & 0 \end{bmatrix}$$

## 2.7 Estimasi Parameter

Estimasi Parameter pada model GSTAR dapat dilakukan dengan beberapa metode, diantaranya sebagia berikut:

### 2.7.1 OLS (*Ordinary Least Square*).

Estimasi parameter model GSTAR bisa dilakukan dengan menggunakan metode OLS. Secara matematis, model GSTAR dengan orde  $p = 1$  dan orde  $\lambda_p = 1$  dituliskan dengan GSTAR (11). Persamaan model GSTAR (11) didapat dengan mensubstitusikan orde  $p = 1$  dan orde  $\lambda_p = 1$  ke dalam persamaan (2.2) dimana  $\emptyset_{ki} = \emptyset_{1k}^{(i)}$  untuk  $k = 0, 1$ .

$$\mathbf{Z}_i(t) = \emptyset_{10}^{(i)} \mathbf{Z}_i(t-1) + \emptyset_{11}^{(i)} \sum_{j=1}^N \mathbf{W}_{ij}^* \mathbf{Z}_j(t-1) + \boldsymbol{\epsilon}_i(t)$$

dengan  $Z_i(t)$  menyatakan pengamatan pada  $t = 0, 1, \dots, T$  untuk lokasi  $i = 1, 2, \dots, N$ . Persamaan (2.4) di atas serupa dengan bentuk linier  $\mathbf{Y}_i = \mathbf{X}_i \boldsymbol{\beta}_i + \boldsymbol{\epsilon}_i$  dimana

$$\mathbf{Y}_i = \begin{bmatrix} Z_i(1) \\ Z_i(2) \\ \vdots \\ Z_i(T) \end{bmatrix}, \quad \mathbf{X}_i = \begin{bmatrix} Z_i(0) & V_i(0) \\ Z_i(1) & V_i(1) \\ \vdots & \vdots \\ Z_i(T-1) & V_i(T-1) \end{bmatrix}, \quad \boldsymbol{\varepsilon}_i = \begin{bmatrix} e_i(1) \\ e_i(2) \\ \vdots \\ e_i(T) \end{bmatrix}, \quad \text{dan} \quad \boldsymbol{\beta}_i = \begin{bmatrix} \emptyset_{10}^{(i)} \\ \emptyset_{11}^{(i)} \end{bmatrix}$$

dengan

$$V_i(t) = \sum_{j=1}^N \mathbf{W}_{ij}^* \mathbf{Z}_j(t)$$

Akibatnya, persamaan model untuk semua lokasi secara bersamaan mengikuti struktur model linear  $\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$  dengan

$$\mathbf{Y} = \begin{bmatrix} \mathbf{Y}_1 \\ \mathbf{Y}_2 \\ \vdots \\ \mathbf{Y}_N \end{bmatrix}, \quad \mathbf{X} = \begin{bmatrix} \mathbf{X}_1 & 0 & \cdots & 0 \\ 0 & \mathbf{X}_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \mathbf{X}_N \end{bmatrix}, \quad \boldsymbol{\beta} = \begin{bmatrix} \boldsymbol{\beta}_1 \\ \boldsymbol{\beta}_2 \\ \vdots \\ \boldsymbol{\beta}_N \end{bmatrix}, \quad \text{dan} \quad \boldsymbol{\varepsilon} = \begin{bmatrix} \boldsymbol{\varepsilon}_1 \\ \boldsymbol{\varepsilon}_2 \\ \vdots \\ \boldsymbol{\varepsilon}_N \end{bmatrix} \quad (2.6)$$

Estimasi terhadap parameter  $\boldsymbol{\beta}$  dilakukan dengan meminimumkan fungsi

$$\boldsymbol{\varepsilon}'\boldsymbol{\varepsilon} = (\mathbf{Y} - \hat{\boldsymbol{\beta}}\mathbf{X})'(\mathbf{Y} - \hat{\boldsymbol{\beta}}\mathbf{X})$$

sehingga dihasilkan  $\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}(\mathbf{X}'\mathbf{Y})$  (Borovkova, 2008).

### 2.7.2 GLS (*Generalized Least Square*)

Residual pada model GSTAR adalah berkorelasi antar persamaan atau lokasi sehingga matriks varian-kovariannya adalah

$$\begin{aligned} E(\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}') &= \boldsymbol{\sigma}_{ij}\mathbf{I}_T = \begin{bmatrix} \boldsymbol{\sigma}_{11}\mathbf{I}_T & \boldsymbol{\sigma}_{12}\mathbf{I}_T & \cdots & \boldsymbol{\sigma}_{1N}\mathbf{I}_T \\ \boldsymbol{\sigma}_{21}\mathbf{I}_T & \boldsymbol{\sigma}_{22}\mathbf{I}_T & \cdots & \boldsymbol{\sigma}_{2N}\mathbf{I}_T \\ \vdots & \vdots & \ddots & \vdots \\ \boldsymbol{\sigma}_{N1}\mathbf{I}_T & \boldsymbol{\sigma}_{N2}\mathbf{I}_T & \cdots & \boldsymbol{\sigma}_{NN}\mathbf{I}_T \end{bmatrix} \\ &= \begin{bmatrix} \boldsymbol{\sigma}_{11} & \boldsymbol{\sigma}_{12} & \cdots & \boldsymbol{\sigma}_{1N} \\ \boldsymbol{\sigma}_{21} & \boldsymbol{\sigma}_{22} & \cdots & \boldsymbol{\sigma}_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ \boldsymbol{\sigma}_{N1} & \boldsymbol{\sigma}_{N2} & \cdots & \boldsymbol{\sigma}_{NN} \end{bmatrix} \otimes \mathbf{I}_T \\ &= \boldsymbol{\Omega}. \end{aligned} \quad (2.7)$$

Berdasarkan persamaan (2.6) dan (2.7) maka estimasi parameter GSTAR dengan metode GLS dilakukan dengan meminimumkan *generalized sum of square*  $\boldsymbol{\varepsilon}'\boldsymbol{\Omega}^{-1}\boldsymbol{\varepsilon}$ , yaitu

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}' \boldsymbol{\Omega}^{-1} \mathbf{X})^{-1} \mathbf{X}' \boldsymbol{\Omega}^{-1} \mathbf{Y}$$

(Prastuti *et.al*, 2014).

## 2.8 Uji Kesesuaian Model

Model GSTAR dikatakan layak jika residual memenuhi asumsi *white noise*.

Residual  $r(t)$  dikatakan *white noise* jika  $\{r(t)\}$  adalah barisan yang independen, identik dan berdistribusi Normal dengan mean 0 dan varian  $\sigma^2$ . Uji *white noise* dapat dilakukan dengan dua cara. Pertama adalah dengan melihat plot ACF dari residual. Jika plot ACF residual pada semua lag sama dengan atau mendekati nilai nol maka dapat dikatakan bahwa residual memenuhi asumsi *white noise* (Tsay, 2005).

Cara kedua adalah dengan melakukan uji Portmanteau Multivariat. Uji ini merupakan generalisasi dari uji Ljung–Box untuk kasus multivariat. Uji statistik yang digunakan adalah

$$Q_N(m) = T^2 \sum_{t=1}^m \frac{1}{T-t} \text{tr}(\hat{\Gamma}_t' \hat{\Gamma}_0^{-1} \hat{\Gamma}_t \hat{\Gamma}_0^{-1}) \quad (2.8)$$

dengan

$T$  = Jumlah pengamatan

$\hat{\Gamma}_T(k) = \frac{1}{T-k+1} \sum_{t=0}^{T-k} \mathbf{Z}(t) \mathbf{Z}'(t-k)$  adalah elemen matriks kovarian  $\boldsymbol{\Gamma}^{(p)}$  dan  $\hat{\Gamma}_T(-k) = \hat{\Gamma}_T'(k)$  untuk  $k \geq 0$ .

Tahap pertama uji Portmanteau adalah menghitung nilai  $Q$  statistik seperti pada persamaan (2.8).  $Q$  berdistribusi *Chi-square* dengan derajat bebas  $N^2m$ . Kemudian, tahap selanjutnya adalah membandingkan nilai  $Q$  dengan nilai  $\chi^2_{N^2m}$  pada tingkat kepercayaan  $100(1 - \alpha)\%$ . Hipotesis yang digunakan pada uji ini adalah

$$H_0 : \boldsymbol{\rho}_1 = \boldsymbol{\rho}_2 = \cdots = \boldsymbol{\rho}_m = 0$$

$$H_1 : \text{terdapat minimal satu } \boldsymbol{\rho} \neq 0$$

dimana  $\boldsymbol{\rho}$  adalah matriks korelasi dari vektor error.

Jika  $Q < \chi^2_{N^2m}$  maka terima  $H_0$ . Hasil ini menunjukkan bahwa residual memenuhi asumsi *white noise* dan dapat dikatakan model sesuai dengan data. Begitu pula sebaliknya, jika  $Q > \chi^2_{N^2m}$  maka tolak  $H_0$  dan dapat disimpulkan model tidak sesuai dengan data karena residual tidak memenuhi asumsi *white noise* (Ljung dan Box, 1978).

### 2.9 Root Mean Square Error (RMSE)

*Root Mean Square Error* (RMSE) merupakan suatu ukuran kesalahan yang didasarkan pada selisih antara dua buah nilai yang bersesuaian. RMSE umumnya digunakan untuk menentukan model terbaik dari beberapa model yang ada. Semakin kecil nilai RMSE maka semakin bagus model tersebut, begitu pula sebaliknya. Perhitungan RMSE diformulasikan dengan persamaan berikut ini.

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{M} \sum_{t=1}^M (Z(t) - \hat{Z}(t))^2}$$

dengan  $M$  adalah banyaknya data yang akan diramalkan (Wei, 2006).

### BAB 3. METODELOGI PENELITIAN

#### 3.1 Data Penelitian

Data yang digunakan dalam penelitian ini adalah data curah hujan dari 77 stasiun hujan yang terdapat di Kabupaten Jember periode bulan Januari 2005 sampai dengan Desember 2016 (Data dapat dilihat pada Lampiran A). Data tersebut merupakan data sekunder yang diambil dari penelitian Retnaningrum (2015) dan Dinas Pengairan Kabupaten Jember. Data terbagi menjadi dua macam, yaitu data in-sampel dan data out-sampel. Data in-sampel merupakan data yang digunakan untuk membentuk model peramalan, sedangkan data out-sampel adalah data yang digunakan untuk memeriksa daya ramal model yang terbentuk. Pembagian data dalam penelitian ini adalah sebagai berikut :

- a. Data In-sampel yaitu data curah hujan bulan Januari 2005 Sampai dengan Desember 2015.
- b. Data Out-sampel yaitu data curah hujan bulan Januari 2016 sampai dengan Desember 2016.

Data dalam penelitian ini diambil dari 77 stasiun hujan di Kabupaten Jember. Data akan dikelompokkan ke dalam empat kelompok dan masing-masing kelompok akan mewakili variabel penelitian.

#### 3.2 Langkah-Langkah Penelitian

Secara garis besar langkah-langkah Penelitian dalam tugas akhir ini adalah sebagai berikut:

- a. Pengelompokan data
- b. Identifikasi data
- c. Pemodelan GSTAR dan estimasi parameter
- d. Metode analisis data dan peramalan

### 3.2.1 Pengelompokan Data

Data 77 stasiun hujan di Kabupaten Jember pada penelitian ini akan dikelompokkan menggunakan dua macam pengelompokan, yaitu pengelompokan yang dilakukan oleh Badan Pusat Statistik (BPS) Jember. BPS Jember mengelompokkan stasiun-stasiun hujan ke dalam empat kelompok, yaitu Jember Barat, Jember Selatan, Jember Tengah, dan Jember Timur. Pengelompokan tersebut didasarkan pada letak stasiun hujan sehingga stasiun-stasiun hujan yang berdekatan akan menjadi satu kelompok wilayah. Selanjutnya pengelompokan ini akan disebut dengan pengelompokan BPS untuk mempermudah dalam penyebutannya.

Pengelompokan kedua dilakukan dengan menggunakan algoritma pengelompokan *K-Means*. Pengelompokan ini dilakukan berdasarkan koordinat stasiun hujan, ketinggian wilayah stasiun hujan dari permukaan laut serta intensitas curah hujan tiap bulan pada masing-masing stasiun hujan. Jumlah kelompok dalam pengelompokan ini adalah empat. Penentuan jumlah ini mengacu pada pengelompokan yang dilakukan oleh BPS Jember. Pengelompokan *K-Means* pada penelitian ini menggunakan bantuan *software R 3.2.3* dengan paket *stats*. Fungsi yang digunakan adalah sebagai berikut:

```
kmeans(x, centers)
```

Pemodelan GSTAR dilakukan berdasarkan nilai rata-rata curah hujan di masing-masing wilayah pada kedua pengelompokan yang telah dilakukan.

### 3.2.2 Identifikasi Data

Setelah melakukan pengelompokan data, akan dilakukan uji kestasioneran data pada masing-masing kluster menggunakan uji ADF. Uji ADF dalam penelitian ini menggunakan bantuan paket *tseries* pada *software R 3.2.3* dengan fungsi sebagai berikut:

```
adf.test(x, alternative=c("stationary", "explosive"),
```

```
k = trunc((length(x)-1)^(1/3)))
```

Jika hasil uji tidak stasioner maka akan dilakukan identifikasi data lebih lanjut untuk melihat apakah data tidak stasioner terhadap *mean* atau terhadap *varian*. Identifikasi lanjutan ini dilakukan dengan melihat plot data. Jika fluktuasi data tidak berada disekitar suatu nilai rata-rata yang konstan maka data tidak stasioner dalam *mean* sehingga perlu dilakukan *differencing*. *Differencing* data bisa dilakukan dengan bantuan paket *timeSeries* dengan fungsi sebagai berikut:

```
diff(x, lag, difference)
```

Jika plot data memperlihatkan adanya perubahan variansi yang jelas dari waktu ke waktu maka data tidak stasioner dalam *varian* sehingga perlu dilakukan transformasi. Transformasi bisa dilakukan dengan bantuan paket *car* dengan fungsi sebagai berikut:

```
boxCox(object, lambda = seq(-2, 2, 1/10), plotit =  
TRUE, ...)
```

### 3.2.3 Pemodelan GSTAR dan Estimasi Parameter

Penelitian ini akan melakukan empat macam pemodelan *time series* pada data curah hujan yang telah stasioner dengan metode GSTAR, yaitu:

- a. Pemodelan peramalan curah hujan pada pengelompokan BPS Jember menggunakan model GSTAR Non Musiman dan GSTAR Musiman.
- b. Pemodelan peramalan curah hujan pada pengelompokan K-Means menggunakan metode GSTAR Non Musiman dan GSTAR Musiman.

Orde spasial model GSTAR dibatasi pada orde 1 sehingga bentuk model GSTAR hanya bergantung pada orde *autoregressive* (*p*). Langkah pertama pemodelan GSTAR dalam penelitian ini adalah menentukan beberapa nilai tentatif *p* untuk setiap model. Orde *p* dipilih berdasarkan nilai AIC terkecil dari model-model yang dibentuk berdasarkan orde tentatif tersebut. Kemudian akan dilakukan estimasi parameter model.

Estimasi parameter dilakukan pada masing-masing model GSTAR yang terbentuk. Estimasi parameter model GSTAR Non Musiman dilakukan dengan meregresikan variabel  $Z(t)$  sebagai respon dengan variabel prediktor  $Z(t - k)$  dan  $WZ(t - k)$ , dimana  $k = 1, 2, \dots, p$  merupakan orde *autoregressive* model. Sedangkan pada model GSTAR Musiman, yang berperan sebagai variabel prediktor adalah  $Z(t - k)$ ,  $WZ(t - k)$ ,  $Z(t - s)$  dan  $WZ(t - s)$ , dimana  $s = 12$  menunjukkan musiman. Estimasi parameter model-model GSTAR ini menggunakan bantuan paket *nlme* pada *software R* 3.2.3 dengan fungsi sebagai berikut:

```
gls(model, data, ...)
```

Langkah terakhir dalam pemodelan GSTAR adalah melakukan uji kesesuaian model. Uji kesesuaian model dalam penelitian ini menggunakan bantuan paket *portes* dengan fungsi

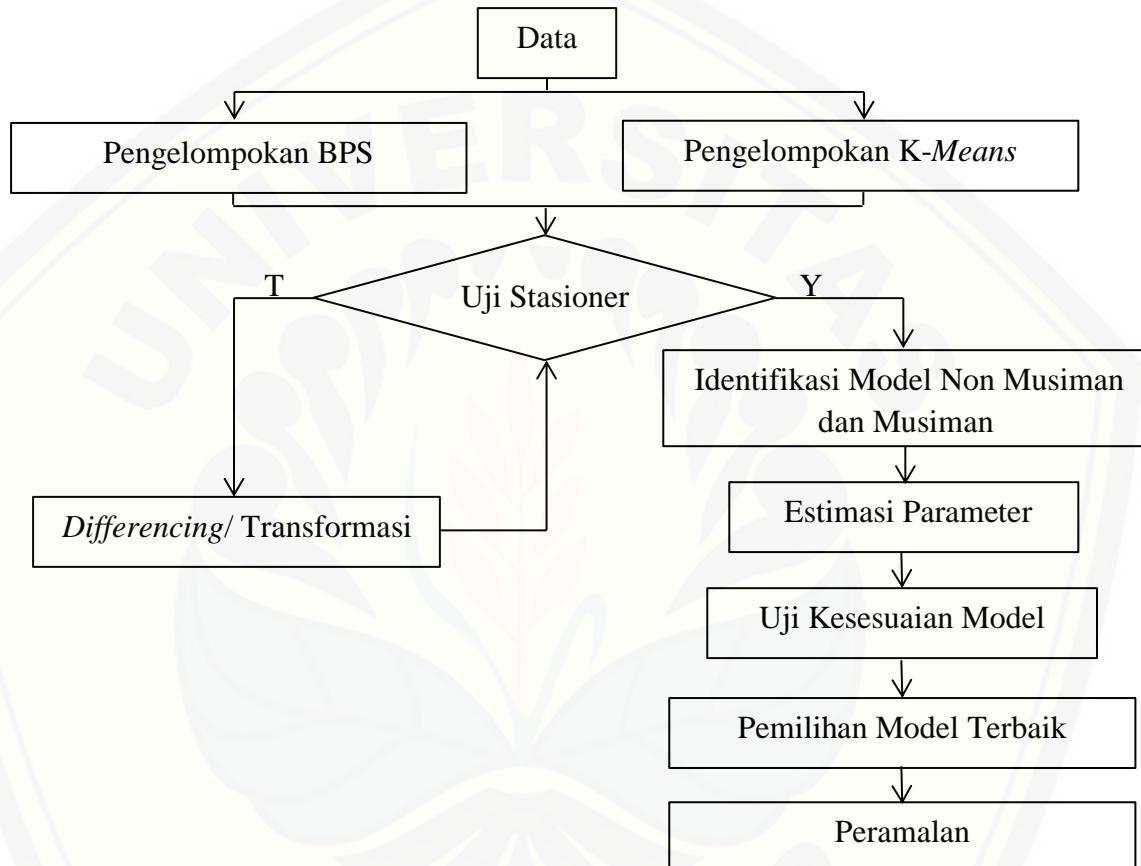
```
LjungBox(obj, lags, order, SquaredQ=FALSE)
```

Jika  $p-value$  yang dihasilkan  $> 0,05$  maka dapat disimpulkan model telah sesuai dengan data, begitu pula sebaliknya. Keterangan fungsi-fungsi paket *software R* 3.2.3 yang digunakan dalam penelitian ini dapat dilihat pada Lampiran A.

### 3.2.4 Metode Analisis Data dan Peramalan

Setelah memperoleh estimasi parameter dan uji kesesuaian model dari keempat model yang terbentuk, yaitu model GSTAR Non Musiman dan Musiman pada pengelompokan BPS maupun pada pengelompokan *K-Means*, akan dilakukan analisis hasil dan penarikan kesimpulan kemudian peramalan curah hujan tahun 2017. Analisis hasil dan penarikan kesimpulan dilakukan dengan melihat RMSE yang dihasilkan dari keempat model, dimana RMSE yang lebih kecil menunjukkan model yang lebih baik. Selanjutnya, model terbaik yang didapat akan digunakan dalam meramalan curah hujan tahun 2017.

Secara sistematik langkah-langkah penelitian dalam tugas akhir ini dapat dilihat pada Gambar 3.1 di bawah ini.



Gambar 3.1 Skema Metode Penelitian

## BAB 5. PENUTUP

### 5.1 Kesimpulan

Berdasarkan hasil analisis data dan pembahasan yang telah diuraikan sebelumnya maka didapatkan kesimpulan sebagai berikut:

- a. Pengelompokan stasiun hujan yang lebih optimal untuk peramalan curah hujan di Kabupaten Jember adalah pengelompokan dengan Algoritma *K-Means*. Pengelompokan ini berdasarkan koordinat letak stasiun hujan, ketinggian wilayah stasiun hujan dari permukaan laut, serta intensitas curah hujan perbulan selama 2015.
- b. Model peramalan curah hujan di Kabupaten Jember adalah  $GSTAR_B - \text{Musiman}(1; 1)$  untuk pengelompokan stasiun hujan yang dilakukan oleh BPS dan  $GSTAR_K - \text{Musiman}(1; 1)$  untuk pengelompokan stasiun hujan menggunakan algoritma *K-Means*. Model yang lebih baik adalah  $GSTAR_K - \text{Musiman}(1; 1)$ .
- c. Berdasarkan model peramalan  $GSTAR_K - \text{Musiman}(1; 1)$  Peramalan curah hujan Kabupaten Jember tahun 2017 di empat wilayah adalah Intensitas curah hujan tertinggi terjadi pada bulan Februari, sedangkan intensitas curah hujan terendah terjadi pada bulan Agustus. Intensitas curah hujan mulai menurun dari bulan Maret hingga Agustus kemudian meningkat kembali pada bulan September sampai Desember (Selengkapnya dapat dilihat pada Tabel 4.13).

### 5.2 Saran

Penelitian ini menggunakan algoritma *K-Means* dalam pengelompokan data, dimana jumlah kelompok yang ditentukan adalah empat. Penelitian selanjutnya disarankan untuk mencoba beberapa jumlah kelompok yang lebih besar untuk meningkatkan daya ramal model. Selain itu, masih terdapat peluang bagi peneliti untuk mengembangkan model GSTAR dengan memasukkan orde *moving average* (MA) pada model.

## DAFTAR PUSTAKA

- Agusta, Y. 2007. K-Means-Penerapan, Permasalahan dan Metode Terkait. Denpasar, Bali: *Jurnal Sistem dan Informatika*. Vol. 3: 47-60.
- Anggraeni, D., Prahatama, A., dan Danari, S. 2013. Aplikasi Generalized Space Time Autoregressive (GSTAR) pada Pemodelan Volume Kendaraan Masuk Tol Semarang. *Media Statistika*. Vol. 6(2): 71-80.
- Borovkova, S.A., Lopuhaa, H.P., dan Ruchjana, B.N. 2002. Generalized S-TAR with Rdanom Weight. *Proceeding of the 17<sup>th</sup> International Workshop on Statistical Modeling*. Chania-Greece.139-147.
- Borovkova, S.A., Lopuhaa, H.P., dan Ruchjana, B.N. 2008. Consistency dan Asymptotic Normality of Least Squares Estimators in Generalized STAR Models. *Journal compilation Statistica Nederldanica*. 487-489.
- Box, G.E.P., Jenkins, G.M., dan REINSEL, G.J. 1994. *Time Series Analysis: Forecasting dan Control: 3<sup>rd</sup> Edition*. Englewood Cliffs: Prentice Hall.
- Box, G. E. P., Ljung, G. M. 1978. On a Measure of a Lack of Fit in Time Series Models. *Biometrika*. 65 (2): 297–303.
- Dicky, D.A., dan Wayne, A.F. 1979. Distribusi of Estimators for Autoregressive Time Series With a Unit Root. *Journal of the American Statistical Association*. Vol.74, No. 336.
- Ispriyanti, D. 2004. Pemodelan Statistika dengan Transformasi Box Cox. *Jurnal Matematika dan Komputer*. Vol.7(3): 8-17.
- Makridakis. 1995. *Metode dan Aplikasi Peramalan*. Jakarta: Erlangga.
- Mattjik, A.A., dan Sumertajaya, I.M. 2011. *Sidik Peubah Gdana dengan menggunakan SAS*. Bogor. IPB PRESS.
- Nurcahyani, F. 2016. “Pengelompokan Stasiun Hujan untuk Model *Generalized Space Time Autoregressive* (GSTAR) pada Peramalan Curah Hujan Kabupaten Jember dengan Tiga Pembobotan”. Tidak Diterbitkan. Skripsi. Jember: Jurusan Matematika FMIPA Universitas Jember.

- Pfeifer, P.E., dan Deutsch, S.J. (1980). A Three Stage Iterative Procedure for Space-Time Modeling. *Technometrics*, Vol. 22, No. 1, Hal. 397-408.
- Prastuti, M., dan Suhartono. 2014. "Model GSTAR-SUR Musiman untuk Peramalan Jumlah Wisatawan Mancanegara di Empat Lokasi Wisata di Indonesia". Tidak Diterbitkan. Tesis. Surabaya: Program Magister Jurusan Statistika FMIPA Institut Teknologi Sepuluh Nopember.
- Retnaningrum. 2015. "Penerapan Model STAR (*Space Time Autoregressive*) dan ARIMA (*Autoregressive Integrated Moving Average*) untuk Peramalan Data Curah Hujan di Kabupaten Jember". Tidak Diterbitkan. Skripsi. Jember: Jurusan Matematika FMIPA Universitas Jember.
- Thomas, R.L. 1997. *Modern Econometrics an Introduction*. Engldan: Addison Wesley.
- Tsay, R.S. 2005. *Analysis of Financial Time Series*. New Jersey: John Wiley & Sons.
- Sarstedt, M., dan Mooi, E. 2014. A Concise Guide to Market Research. *Springer Texts in Business dan Economics*. Berlin.
- Susanti, D. dan Susiswo. 2013. *Aplikasi Model GSTAR pada Peramalan Jumlah Kunjungan Wisatawan Empat Lokasi Wisata di Batu*. Malang : Universitas Negeri Malang.
- Wei, W.W.S. 2006. *Time series Analysis : Univariat dan Multivariate Methods*. Canada: Addison Wesley Publishing Company.
- Wutsqa, D.W., Suhartono, dan Sujito, B. 2010. Generalized Space-Time Autoregressive Modeling. *Proceedings of the 6<sup>th</sup> IMT-GT Conference on Mathematics, Statistics dan its Applications (ICMSA2010)*. Universitas Tunku Abdul Rahman, Kuala Lumpur, Malaysia.

## LAMPIRAN A : KETERANGAN STRUKTUR FUNGSI

### 1. Struktur Fungsi **kmeans( )**

Fungsi **kmeans( )** terdapat dalam paket **stats**, digunakan untuk mengelompokkan data. Struktur fungsi **kmeans( )** yang digunakan dalam penelitian ini yaitu:

```
kmeans(x, centers)
```

Keterangan :

- x : Data frame atau data dalam bentuk matrik  
centers : Jumlah kluster yang diinginkan

### 2. Struktur Fungsi **adf.test( )**

Fungsi **adf.test( )** terdapat dalam paket **tseries**, digunakan untuk menguji kestasioneran data. Struktur fungsi **adf.test( )** yang digunakan dalam penelitian ini yaitu:

```
adf.test(x, alternative = c("stationary", "explosive"),  
         k = trunc((length(x)-1)^(1/3)))
```

Keterangan :

- x : Data frame atau data dalam bentuk matrik.  
alternative : Argumen yang menunjukkan hipotesis alternatif.  
k : Urutan lag untuk menghitung statistik uji.

### 3. Struktur Fungsi **gls( )**

Fungsi **gls( )** terdapat dalam paket **nlme**, digunakan untuk mengestimasi parameter dari model yang telah terbentuk. Struktur fungsi **gls()** yang digunakan dalam penelitian ini yaitu:

```
gls(model, data, ...)
```

Keterangan :

- model : Formula atau model dari data.

data : Data dalam bentuk data frame atau matrik.

#### 4. Struktur Fungsi LjungBox ( )

Fungsi LjungBox( ) terdapat dalam paket portes, digunakan untuk menguji residual model yang terbentuk. Struktur fungsi LjungBox( ) yang digunakan dalam penelitian ini yaitu:

```
LjungBox(obj, lags, order, SquaredQ=FALSE)
```

Keterangan :

obj : Matrik residual model yang terbentuk.

lags : Vektor nilai lag yang akan diuji.

order : Nilai yang diperlukan untuk derajat bebas asimtotik distribusi Chi-Kuadrat.

SquaredQ : Jika TRUE maka test dilakukan pada nilai kuadrat untuk mengecek *Autoregressive Conditional Heteroscedastic*. Jika FALSE maka test hanya untuk menguji residual.

## LAMPIRAN B: SKRIP PROGRAM R

### 1. Pemodelan GSTAR pada Data Pengelompokan BPS Jember

```
### Plot Rata-Rata Curah Hujan
> data(hujanNoclus)
> attach(hujanNoclus)
> library(ggplot2)
> library(reshape2)
>df<- data.frame(Bulan = seq(as.Date("2005/1/1"), by =
  "month", length.out =length (Z1)),Z1,Z2,Z3,Z4)
>df2<- melt(dat=df, id.vars="Bulan")
>head(df2)
>ggplot(dat=df2, aes(x=Bulan, y= value, colour=variable) )
  +geom_line() +ylab("Curah Hujan (mm)") +xlab("Waktu")

### Test Kestasioneran Data
> adf.test(Z1)
  Augmented Dickey-Fuller Test
data: Z1
Dickey-Fuller = -8.4917, Lag order = 5, p-value = 0.01
alternative hypothesis: stationary

> adf.test(Z2)
  Augmented Dickey-Fuller Test
data: Z2
Dickey-Fuller = -8.5329, Lag order = 5, p-value = 0.01
alternative hypothesis: stationary

> adf.test(Z3)
  Augmented Dickey-Fuller Test
data: Z3
Dickey-Fuller = -8.4946, Lag order = 5, p-value = 0.01
alternative hypothesis: stationary

> adf.test(Z4)
  Augmented Dickey-Fuller Test
data: Z4
Dickey-Fuller = -8.8481, Lag order = 5, p-value = 0.01
alternative hypothesis: stationary
```

```

####Pemodelan GSTAR Non Musiman
#Z(t-1)
> Z<-matrix(c(Z1[1:132],Z2[1:132],Z3[1:132],Z4[1:132]),
  132,4)
> Zt.min1<-Z[-132,]
#Z(t-1) dikali bobot
> data(bobotNoclus3)
> attach(bobotNoclus3)
> W<-matrix(c(Bobot),4,4)
> Zt.min1.W<-t(W%*%t(Z[-132,]))
#Data untuk model Non Musiman
> Zt1<-c(Z[-1,1],Z[-1,2],Z[-1,3],Z[-1,4])
> Z1t.min1<-c(Zt.min1[,1],rep(0,393))
> Z1t.min1.W<-c(Zt.min1.W[,1],rep(0,393))
> Z2t.min1<-c(rep(0,131),Zt.min1[,2],rep(0,262))
> Z2t.min1.W<-c(rep(0,131),Zt.min1.W[,2],rep(0,262))
> Z3t.min1<-c(rep(0,262),Zt.min1[,3],rep(0,131))
> Z3t.min1.W<-c(rep(0,262),Zt.min1.W[,3],rep(0,131))
> Z4t.min1<-c(rep(0,393),Zt.min1[,4])
> Z4t.min1.W<-c(rep(0,393),Zt.min1.W[,4])
> dat.nonmusiman<-data.frame(Zt1=Zt1, Z1t.min1=Z1t.min1,
  Z1t.min1.W=Z1t.min1.W,Z2t.min1=Z2t.min1,
  Z2t.min1.W=Z2.min1.W,Z3t.min1=Z3t.min1,
  Z3t.min1.W=Z3t.min1.W, Z4t.min1=Z4t.min1,
  Z4t.min1.W=Z4t.min1.W)
#Estimasi parameter
> library(nlme)
> estimasinonmusiman<-gls(Zt1~Z1t.min1+Z1t.min1.W+
  Z2t.min1+Z2t.min1.W+Z3t.min1+Z3t.min1.W+Z4t.min1+Z4t.m
  in1.W-1, data=dat.nonmusiman)
> summary(estimasinonmusiman)
Generalized least squares fit by REML
  Model: Zt1 ~ Z1t.min1 + Z1t.min1.W + Z2t.min1 +
  Z2t.min1.W + Z3t.min1 +      Z3t.min1.W + Z4t.min1 +
  Z4t.min1.W - 1
  Data: dat.nonmusiman
        AIC      BIC      logLik
  6485.957 6524.172 -3233.978

Coefficients:
              Value   Std.Error   t-value p-value
Z1t.min1    0.3849812 0.21315351  1.806122  0.0715
Z1t.min1.W  0.0590882 0.02716974  2.174780  0.0301

```

```

Z2t.min1   -0.7583653 0.25676186 -2.953574  0.0033
Z2t.min1.W  0.3138131 0.05070979  6.188412  0.0000
Z3t.min1    1.1881820 0.25765198  4.611577  0.0000
Z3t.min1.W -0.1097164 0.08656788 -1.267403  0.2056
Z4t.min1    0.3779117 0.16457096  2.296345  0.0221
Z4t.min1.W  0.0692705 0.02272152  3.048673  0.0024

```

Correlation:

```

          Z1t.m1 Z1.1.W Z2t.m1 Z2.1.W Z3t.m1 Z3.1.W
Z4t.m1
Z1t.min1.W -0.973
Z2t.min1    0.000  0.000
Z2t.min1.W  0.000  0.000 -0.976
Z3t.min1    0.000  0.000  0.000  0.000
Z3t.min1.W  0.000  0.000  0.000  0.000 -0.987
Z4t.min1    0.000  0.000  0.000  0.000  0.000  0.000
Z4t.min1.W  0.000  0.000  0.000  0.000  0.000  0.000 -
0.971

```

Standardized residuals:

Min	Q1	Med	Q3	Max
-2.8941652	-0.3572660	0.0000000	0.6435648	3.9366476

Residual standard error: 112.8927

Degrees of freedom: 524 total; 516 residual

```

### Unsur Musiman Model
#Z(t-12)
> Zt.min12<-Z[-c(121:132),]
#Z(t-12) dikali bobot
> Zt.min12.W<-t(W%*%t(Zt.min12))
#Data untuk model unsur Musiman
> Zt2<-c(Z[-c(1:12),1],Z[-c(1:12),2],Z[-c(1:12),3],Z[-c(1:12),4])
> Z1t.min12<-c(Zt.min12[,1],rep(0,360))
> Z1t.min12.W<-c(Zt.min12.W[,1],rep(0,360))
> Z2t.min12<-c(rep(0,120),Zt.min12[,2],rep(0,240))
> Z2t.min12.W<-c(rep(0,120),Zt.min12.W[,2],rep(0,240))
> Z3t.min12<-c(rep(0,240),Zt.min12[,3],rep(0,120))
> Z3t.min12.W<-c(rep(0,240),Zt.min12.W[,3],rep(0,120))
> Z4t.min12<-c(rep(0,360),Zt.min12[,4])
> Z4t.min12.W<-c(rep(0,360),Zt.min12.W[,4])

```

```
> dat.musiman<-data.frame(Zt2=Zt2, Z1t.min12=Z1t.min12,
  Z1t.min12.W=Z1t.min12.W, Z2t.min12=Z2t.min12,
  Z2t.min12.W=Z2t.min12.W, Z3t.min12=Z3t.min12,
  Z3t.min12.W=Z3t.min12.W, Z4t.min12=Z4t.min12,
  Z4t.min12.W=Z4t.min12.W)

### Pemodelan GSTAR Musiman
#Data Untuk Model Musiman
> Ztm<-c(Z[-c(1:12),1],Z[-c(1:12),2],Z[-c(1:12),3],Z[-c(1:12),4])
> Z1t.min1m<-c(Zt.min1[-c(1:11),1],rep(0,360))
> Z1t.min1m.W<-c(Zt.min1.W[-c(1:11),1],rep(0,360))
> Z2t.min1m<-c(rep(0,120),Zt.min1[-c(1:11),2],rep(0,240))
> Z2t.min1m.W<-c(rep(0,120),Zt.min1.W[-c(1:11),2],rep(0,240))
> Z3t.min1m<-c(rep(0,240),Zt.min1[-c(1:11),3],rep(0,120))
> Z3t.min1m.W<-c(rep(0,240),Zt.min1.W[-c(1:11),3],rep(0,120))
> Z4t.min1m<-c(rep(0,360),Zt.min1[-c(1:11),4])
> Z4t.min1m.W<-c(rep(0,360),Zt.min1.W[-c(1:11),4])
> dat<-data.frame(Ztm=Ztm, Z1t.min1m=Z1t.min1m,
  Z1t.min1m.W=Z1t.min1m.W, Z1t.min12=Z1t.min12,
  Z1t.min12.W=Z1t.min12.W,Z2t.min1m=Z2t.min1m,
  Z2t.min1m.W=Z2t.min1m.W,Z2t.min12=Z2t.min12,
  Z2t.min12.W=Z2t.min12.W, Z3t.min1m=Z3t.min1m,
  Z3t.min1m.W=Z3t.min1m.W, Z3t.min12=Z3t.min12,
  Z3t.min12.W=Z3t.min12.W, Z4t.min1m=Z4t.min1m,
  Z4t.min1m.W=Z4t.min1m.W, Z4t.min12=Z4t.min12,
  Z4t.min12.W=Z4t.min12.W)

#Estimasi Parameter Model Musiman
> estimasi.musiman<-gls(Ztm~
  Z1t.min1m+Z1t.min1m.W+Z1t.min12+Z1t.min12.W+Z2t.min1m+
  Z2t.min1m.W+Z2t.min12+Z2t.min12.W+Z3t.min1m+Z3t.min1m.W+
  Z3t.min12+Z3t.min12.W+Z4t.min1m+Z4t.min1m.W+Z4t.min12+
  Z4t.min12.W-1, data=dat)
> summary(estimasi.musiman)
Generalized least squares fit by REML
  Model: Ztm ~ Z1t.min1m + Z1t.min1m.W + Z1t.min12 +
  Z1t.min12.W + Z2t.min1m + Z2t.min1m.W + Z2t.min12 +
  Z2t.min12.W + Z3t.min1m + Z3t.min1m.W + Z3t.min12 +
  Z3t.min12.W + Z4t.min1m + Z4t.min1m.W + Z4t.min12 +
  Z4t.min12.W - 1
  Data: dat
```

AIC	BIC	logLik
5772.014	5842.392	-2869.007

**Coefficients:**

	Value	Std.Error	t-value	p-value
Z1t.min1m	0.4277001	0.17891571	2.390511	0.0172
Z1t.min1m.W	-0.0046895	0.02403462	-0.195113	0.8454
Z1t.min12	0.3116722	0.17835495	1.747483	0.0812
Z1t.min12.W	0.0309768	0.02311458	1.340143	0.1809
Z2t.min1m	-0.3709667	0.21301965	-1.741467	0.0823
Z2t.min1m.W	0.1593227	0.04638956	3.434451	0.0006
Z2t.min12	-0.1790411	0.20973899	-0.853638	0.3937
Z2t.min12.W	0.1308232	0.04429339	2.953560	0.0033
Z3t.min1m	0.7577373	0.21266943	3.562982	0.0004
Z3t.min1m.W	-0.0912063	0.07048976	-1.293894	0.1963
Z3t.min12	0.2215785	0.22055398	1.004645	0.3156
Z3t.min12.W	0.0795741	0.07842714	1.014624	0.3108
Z4t.min1m	0.0199079	0.14314908	0.139071	0.8895
Z4t.min1m.W	0.0638847	0.01890772	3.378763	0.0008
Z4t.min12	0.1322020	0.13823303	0.956371	0.3394
Z4t.min12.W	0.0488879	0.01851485	2.640468	0.0086

**Correlation:**

	Z1t.m1	Z1.1.W	Z1t.12	Z1.12.	Z2t.m1	Z2.1.W	
Z2t.12	Z2.12.	Z3t.m1					
Z1t.min1m.W	-0.930						
Z1t.min12	-0.025	-0.022					
Z1t.min12.W	0.038	-0.107	-0.924				
Z2t.min1m	0.000	0.000	0.000	0.000			
Z2t.min1m.W	0.000	0.000	0.000	0.000	-0.944		
Z2t.min12	0.000	0.000	0.000	0.000	-0.076	0.089	
Z2t.min12.W	0.000	0.000	0.000	0.000	0.144	-0.245	-
Z3t.min1m	0.000	0.000	0.000	0.000	0.000	0.000	
0.000	0.000						
Z3t.min1m.W	0.000	0.000	0.000	0.000	0.000	0.000	
0.000	0.000	-0.963					
Z3t.min12	0.000	0.000	0.000	0.000	0.000	0.000	
0.000	0.000	0.032					
Z3t.min12.W	0.000	0.000	0.000	0.000	0.000	0.000	
0.000	0.000	-0.073					
Z4t.min1m	0.000	0.000	0.000	0.000	0.000	0.000	
0.000	0.000	0.000					

```

Z4t.min1m.W  0.000  0.000  0.000  0.000  0.000  0.000  0.000
0.000  0.000  0.000
Z4t.min12    0.000  0.000  0.000  0.000  0.000  0.000  0.000
0.000  0.000  0.000
Z4t.min12.W  0.000  0.000  0.000  0.000  0.000  0.000  0.000
0.000  0.000  0.000
          Z3.1.W Z3t.12 Z3.12. Z4t.m1 Z4.1.W Z4t.12
Z1t.min1m.W
Z1t.min12
Z1t.min12.W
Z2t.min1m
Z2t.min1m.W
Z2t.min12
Z2t.min12.W
Z3t.min1m
Z3t.min1m.W
Z3t.min12  0.016
Z3t.min12.W -0.026 -0.970
Z4t.min1m   0.000  0.000  0.000
Z4t.min1m.W 0.000  0.000  0.000 -0.921
Z4t.min12   0.000  0.000  0.000 -0.073 -0.022
Z4t.min12.W 0.000  0.000  0.000 -0.052  0.014 -0.914

```

Standardized residuals:

Min	Q1	Med	Q3	Max
-2.83546748	-0.52345928	-0.04761469	0.48314484	
3.92612554				

Residual standard error: 89.89531

Degrees of freedom: 480 total; 464 residual

```

### Uji Kesesuaian Model
> library(portes)
> data(res_bps)
> attach(res_bps)
#Model Non Musiman
> LjungBox(res_bps_non, lag =1,order=0,SquaredQ=FALSE)
  Lags Statistic df pvalue
  1 1.439146  1 0.2302776
#Model Musiman
> LjungBox(res_bps_mus, lag =1,order=0,SquaredQ=FALSE)
  Lags Statistic df pvalue
  1 0.002958879 1 0.95662

```

## 2. Pengelompokan K-Means

```
###Menentukan Jumlah Kluster
> data(kluster)
> m=4;
> mydata <-kluster
> rownames(mydata) = kluster[,1]
> mydata = mydata[,-1]
> wss <-(nrow(mydata)-1)*sum(apply(mydata,2,var))
> for(i in 2:m) {
  set.seed(40709)
  wss[i]<- sum(kmeans(mydata, centers=i)$withinss)
}
> plot(1:m, wss, type="b", xlab="Number of Clusters",
  ylab="Within groups sum of squares")

###Pengelompokan K-Means
> set.seed(40709)
> fit <- kmeans(mydata, m)
> aggregate(mydata,by=list(fit$cluster),FUN=mean)
> mydata <- data.frame(mydata, fit$cluster)
#Plot Hasil Kluster
> Koordinat_x<-mydata$Koor.X
> Koordinat_y<-mydata$Koor.Y
> plot(Koordinat_x,Koordinat_y, col =rainbow(4)
  [mydata$fit.cluster],pch=16, main="Hasil Pengelompokan
  K-Means")
```

## 3. Pemodelan GSTAR pada Data Pengelompokan K-Means

```
###Mecari Jarak
> data(matriks_jarak)
> n=4
> matriks_jarak = matriks_jarak[,-1]
> jarak=matrix(0,n,n)
> for (i in 1:n){
  indeks_i=which(mydata$fit.cluster==i)
  kluster=matriks_jarak[indeks_i,]
  for (k in 1: n){
    if(i!=k){
      indeks_k=which(mydata$fit.cluster==k)
      jarak_min=min(kluster[,indeks_k])
      jarak[i,k]=jarak_min
    } else {
```

```
        jarak[i,k]=0
    }
}
>jarak

##Mencari Bobot Invers Jarak
> bobot = matrix(0, n, n)
> for (i in 1 : n) {
  for (j in 1:n) {
    if (i != j) {
      bobot[i,j] = sum(jarak[i,])/sum(jarak[i,-j])
    }
  }
}
>bobot

### Pemodelan GSTAR Non MUsiman
#Data Curah Hujan
> data(hujan)
> data_1<-hujan[which(mydata$fit.cluster==1),]
> data_2<-hujan[which(mydata$fit.cluster==2),]
> data_3<-hujan[which(mydata$fit.cluster==3),]
> data_4<-hujan[which(mydata$fit.cluster==4),]
#Rata-Rata Curah Hujan
> rataan_1<-apply(data_1[,-1],2,mean)
> rataan_2<-apply(data_2[,-1],2,mean)
> rataan_3<-apply(data_3[,-1],2,mean)
> rataan_4<-apply(data_4[,-1],2,mean)
> data_rataan<-data.frame(Z1=rataan_1[-c(133:144)],Z2=rataan_2[-c(133:144)],Z3=rataan_3[-c(133:144)],Z4=rataan_4[-c(133:144)])
> attach(data_rataan)

###Plot Rata-Rata Curah Hujan
> library(ggplot2)
> library(reshape2)
>df<- data.frame(Bulan = seq(as.Date("2005/1/1"), by =
  "month", length.out =length(rataan_1)) ,rataan_1,
  rataan_2,rataan_3,rataan_4)
>df2<- melt(dat=df, id.vars="Bulan")
>head(df2)
```

```
>ggplot(dat=df2, aes(x=Bulan, y= value, colour=variable))  
+geom_line() +ylab("Curah Hujan (mm)") +xlab("Waktu")  
  
###Test Kestasioneran Data  
> Z<-matrix(c(Z1,Z2,Z3,Z4),132,4)  
> library(tseries)  
> adf.test(Z1)  
    Augmented Dickey-Fuller Test  
data: Z1  
Dickey-Fuller = -8.2658, Lag order = 5, p-value = 0.01  
alternative hypothesis: stationary  
  
> adf.test(Z2)  
    Augmented Dickey-Fuller Test  
data: Z2  
Dickey-Fuller = -8.8197, Lag order = 5, p-value = 0.01  
alternative hypothesis: stationary  
  
> adf.test(Z3)  
    Augmented Dickey-Fuller Test  
data: Z3  
Dickey-Fuller = -8.6455, Lag order = 5, p-value = 0.01  
alternative hypothesis: stationary  
  
> adf.test(Z4)  
    Augmented Dickey-Fuller Test  
data: Z4  
Dickey-Fuller = -8.708, Lag order = 5, p-value = 0.01  
alternative hypothesis: stationary  
  
###Pemodelan GSTAR Non Musiman  
#Z(t-1)  
> Zt.min1<-Z[-132,]  
#Z(t-1) dikali bobot  
> Zt.min1.W<-t(bobot%*%t(Z[-132,]))  
#Data untuk Model Non Musiman  
> Zt1<-c(Z[-1,1],Z[-1,2],Z[-1,3],Z[-1,4])  
> Z1t.min1<-c(Zt.min1[,1],rep(0,393))  
> Z1t.min1.W<-c(Zt.min1.W[,1],rep(0,393))  
> Z2t.min1<-c(rep(0,131),Zt.min1[,2],rep(0,262))  
> Z2t.min1.W<-c(rep(0,131),Zt.min1.W[,2],rep(0,262))  
> Z3t.min1<-c(rep(0,262),Zt.min1[,3],rep(0,131))  
> Z3t.min1.W<-c(rep(0,262),Zt.min1.W[,3],rep(0,131))
```

```

> Z4t.min1<-c(rep(0,393),Zt.min1[,4])
> Z4t.min1.W<-c(rep(0,393),Zt.min1.W[,4])
> dat.nonmusiman<-data.frame(Zt1=Zt1, Z1t.min1=Z1t.min1,
+ Z1t.min1.W=Z1t.min1.W,Z2t.min1=Z2t.min1,
+ Z2t.min1.W=Z2t.min1.W, Z3t.min1=Z3t.min1,
+ Z3t.min1.W=Z3t.min1.W, Z4t.min1=Z4t.min1,
+ Z4t.min1.W=Z4t.min1.W)
#Estimasi Parameter
> library(nlme)
> estimasinonmusiman<-gls(Zt1~
+ Z1t.min1+Z1t.min1.W+Z2t.min1+Z2t.min1.W+Z3t.min1+Z3t.m
+ in1.W+Z4t.min1+Z4t.min1.W-1, data=dat.nonmusiman)
> summary(estimasinonmusiman)
Generalized least squares fit by REML
Model: Zt1 ~ Z1t.min1 + Z1t.min1.W + Z2t.min1 +
Z2t.min1.W + Z3t.min1 + Z3t.min1.W + Z4t.min1 +
Z4t.min1.W - 1
Data: dat.nonmusiman
      AIC      BIC      logLik
 6474.266 6512.481 -3228.133

Coefficients:
            Value Std.Error t-value p-value
Z1t.min1    0.1556482 0.26180129  0.594528  0.5524
Z1t.min1.W  0.1052385 0.04011059  2.623709  0.0090
Z2t.min1    0.9897052 0.21187215  4.671238  0.0000
Z2t.min1.W -0.0319917 0.05560287 -0.575361  0.5653
Z3t.min1    0.6669063 0.19660068  3.392187  0.0007
Z3t.min1.W  0.0525136 0.05063880  1.037022  0.3002
Z4t.min1    -0.5067519 0.28500915 -1.778020  0.0760
Z4t.min1.W  0.2829323 0.05979614  4.731615  0.0000

Correlation:
          Z1t.m1 Z1.1.W Z2t.m1 Z2.1.W Z3t.m1 Z3.1.W
Z4t.m1
Z1t.min1.W -0.975
Z2t.min1    0.000  0.000
Z2t.min1.W  0.000  0.000 -0.984
Z3t.min1    0.000  0.000  0.000  0.000
Z3t.min1.W  0.000  0.000  0.000  0.000 -0.978
Z4t.min1    0.000  0.000  0.000  0.000  0.000  0.000
Z4t.min1.W  0.000  0.000  0.000  0.000  0.000  0.000 -
0.983

```

```
Standardized residuals:  
Min Q1 Med Q3 Max  
-2.8307028 -0.3398888 0.0000000 0.6433070 4.3513378  
  
Residual standard error: 111.8497  
Degrees of freedom: 524 total; 516 residual  
  
###Unsur Musiman Model  
#Z(t-12)  
> Zt.min12<-Z[-c(121:132),]  
#Z(t-12) dikali bobot  
> Zt.min12.W<-t(bobot%*%t(Zt.min12))  
#data untuk model unsur Musiman 4 Kluster  
> Zt2<-c(Z[-c(1:12),1],Z[-c(1:12),2],Z[-c(1:12),3],Z[-c(1:12),4])  
> Z1t.min12<-c(Zt.min12[,1],rep(0,360))  
> Z1t.min12.W<-c(Zt.min12.W[,1],rep(0,360))  
> Z2t.min12<-c(rep(0,120),Zt.min12[,2],rep(0,240))  
> Z2t.min12.W<-c(rep(0,120),Zt.min12.W[,2],rep(0,240))  
> Z3t.min12<-c(rep(0,240),Zt.min12[,3],rep(0,120))  
> Z3t.min12.W<-c(rep(0,240),Zt.min12.W[,3],rep(0,120))  
> Z4t.min12<-c(rep(0,360),Zt.min12[,4])  
> Z4t.min12.W<-c(rep(0,360),Zt.min12.W[,4])  
> dat.musiman<-data.frame(Zt2=Zt2, Z1t.min12=Z1t.min12,  
    Z1t.min12.W=Z1t.min12.W, Z2t.min12=Z2t.min12,  
    Z2t.min12.W=Z2t.min12.W, Z3t.min12=Z3t.min12,  
    Z3t.min12.W=Z3t.min12.W, Z4t.min12=Z4t.min12,  
    Z4t.min12.W=Z4t.min12.W)  
  
###Model GSTAR Musiman  
> Ztm<-c(Z[-c(1:12),1],Z[-c(1:12),2],Z[-c(1:12),3],Z[-c(1:12),4])  
> Z1t.min1m<-c(Zt.min1[-c(1:11),1],rep(0,360))  
> Z1t.min1m.W<-c(Zt.min1.W[-c(1:11),1],rep(0,360))  
> Z2t.min1m<-c(rep(0,120),Zt.min1[-c(1:11),2],rep(0,240))  
> Z2t.min1m.W<-c(rep(0,120),Zt.min1.W[-c(1:11),2],rep(0,240))  
> Z3t.min1m<-c(rep(0,240),Zt.min1[-c(1:11),3],rep(0,120))  
> Z3t.min1m.W<-c(rep(0,240),Zt.min1.W[-c(1:11),3],rep(0,120))  
> Z4t.min1m<-c(rep(0,360),Zt.min1[-c(1:11),4])  
> Z4t.min1m.W<-c(rep(0,360),Zt.min1.W[-c(1:11),4])
```

```

> dat<-data.frame(Ztm=Ztm, Z1t.min1m=Z1t.min1m,
  Z1t.min1m.W=Z1t.min1m.W, Z1t.min12=Z1t.min12,
  Z1t.min12.W=Z1t.min12.W,
  Z2t.min1m=Z2t.min1m, Z2t.min1m.W=Z2t.min1m.W,
  Z2t.min12=Z2t.min12, Z2t.min12.W=Z2t.min12.W,
  Z3t.min1m=Z3t.min1m, Z3t.min1m.W=Z3t.min1m.W,
  Z3t.min12=Z3t.min12, Z3t.min12.W=Z3t.min12.W,
  Z4t.min1m=Z4t.min1m, Z4t.min1m.W=Z4t.min1m.W,
  Z4t.min12=Z4t.min12, Z4t.min12.W=Z4t.min12.W)
#Estimasi Parameter
> estimasi.musiman<-gls(Ztm~
  Z1t.min1m+Z1t.min1m.W+Z1t.min12+Z1t.min12.W+Z2t.min1m+
  Z2t.min1m.W+Z2t.min12+Z2t.min12.W+Z3t.min1m+Z3t.min1m.
  W+Z3t.min12+Z3t.min12.W+Z4t.min1m+Z4t.min1m.W+Z4t.min1
  2+Z4t.min12.W-1, data=dat)
> summary(estimasi.musiman)
Generalized least squares fit by REML
  Model: Ztm ~ Z1t.min1m + Z1t.min1m.W + Z1t.min12 +
  Z1t.min12.W + Z2t.min1m + Z2t.min1m.W + Z2t.min12 +
  Z2t.min12.W + Z3t.min1m + Z3t.min1m.W + Z3t.min12 +
  Z3t.min12.W + Z4t.min1m + Z4t.min1m.W + Z4t.min12 +
  Z4t.min12.W - 1
  Data: dat
      AIC      BIC      logLik
  5758.595  5828.973 -2862.298

```

Coefficients:

	Value	Std.Error	t-value	p-value
Z1t.min1m	0.2336798	0.21809997	1.071434	0.2845
Z1t.min1m.W	0.0268590	0.03521278	0.762763	0.4460
Z1t.min12	0.1292225	0.23963130	0.539255	0.5900
Z1t.min12.W	0.0603660	0.03761077	1.605019	0.1092
Z2t.min1m	0.5785217	0.18254484	3.169203	0.0016
Z2t.min1m.W	-0.0270641	0.04733964	-0.571701	0.5678
Z2t.min12	0.2746260	0.20449079	1.342975	0.1799
Z2t.min12.W	0.0545226	0.05344984	1.020070	0.3082
Z3t.min1m	0.3110570	0.16624807	1.871041	0.0620
Z3t.min1m.W	0.0474575	0.04128085	1.149625	0.2509
Z3t.min12	0.2034493	0.16327733	1.246035	0.2134
Z3t.min12.W	0.0651802	0.04261245	1.529605	0.1268
Z4t.min1m	-0.1186854	0.23925412	-0.496064	0.6201
Z4t.min1m.W	0.1135523	0.05397002	2.103988	0.0359
Z4t.min12	-0.0565730	0.23493635	-0.240801	0.8098

Z4t.min12.W 0.1190695 0.05049904 2.357856 0.0188

Correlation:

	Z1t.m1	Z1.1.W	Z1t.12	Z1.12.	Z2t.m1	Z2.1.W
Z2t.12						
Z2t.12.						
Z3t.m1						
Z1t.min1m.W	-0.937					
Z1t.min12	-0.142	0.088				
Z1t.min12.W	0.162	-0.202	-0.944			
Z2t.min1m	0.000	0.000	0.000	0.000		
Z2t.min1m.W	0.000	0.000	0.000	0.000	-0.959	
Z2t.min12	0.000	0.000	0.000	0.000	-0.262	0.262
Z2t.min12.W	0.000	0.000	0.000	0.000	0.207	-0.266
	0.967					
Z3t.min1m	0.000	0.000	0.000	0.000	0.000	0.000
0.000	0.000					
Z3t.min1m.W	0.000	0.000	0.000	0.000	0.000	0.000
0.000	0.000	-0.939				
Z3t.min12	0.000	0.000	0.000	0.000	0.000	0.000
0.000	0.000	-0.009				
Z3t.min12.W	0.000	0.000	0.000	0.000	0.000	0.000
0.000	0.000	-0.085				
Z4t.min1m	0.000	0.000	0.000	0.000	0.000	0.000
0.000	0.000	0.000				
Z4t.min1m.W	0.000	0.000	0.000	0.000	0.000	0.000
0.000	0.000	0.000				
Z4t.min12	0.000	0.000	0.000	0.000	0.000	0.000
0.000	0.000	0.000				
Z4t.min12.W	0.000	0.000	0.000	0.000	0.000	0.000
0.000	0.000	0.000				
	Z3.1.W	Z3t.12	Z3.12.	Z4t.m1	Z4.1.W	Z4t.12
Z1t.min1m.W						
Z1t.min12						
Z1t.min12.W						
Z2t.min1m						
Z2t.min1m.W						
Z2t.min12						
Z2t.min12.W						
Z3t.min1m						
Z3t.min1m.W						
Z3t.min12	-0.030					
Z3t.min12.W	0.026	-0.938				
Z4t.min1m	0.000	0.000	0.000			
Z4t.min1m.W	0.000	0.000	0.000	-0.959		

```
Z4t.min12      0.000  0.000  0.000  0.003 -0.011  
Z4t.min12.W   0.000  0.000  0.000  0.058 -0.117 -0.950
```

Standardized residuals:

Min	Q1	Med	Q3	Max
-3.08510411	-0.48018028	-0.06902216	0.55233706	
3.19844669				

Residual standard error: 89.04151

Degrees of freedom: 480 total; 464 residual

```
###Uji Kesesuaian Model  
> library(portes)  
> data(res_kmeans)  
> attach(res_kmeans)  
#Non Musiman  
> LjungBox(res_k_non, lag =1,order=0,SquaredQ=FALSE)  
  Lags Statistic df      pvalue  
 1  2.850352  1 0.09135391  
> #Musiman  
> LjungBox(res_k_mus, lag =1,order=0,SquaredQ=FALSE)  
  Lags Statistic df      pvalue  
 1 0.4173573  1 0.5182587
```

**LAMPIRAN C: DATA CURAH HUJAN KABUPATEN EMBER**

Data Curah Hujan Kabupaten Jember Tahun 2005

No	Nama Stasiun Hujan	Bulan											
		Jan	Feb	Mar	Apr	Mei	Juni	Juli	Agust	Sep	Okt	Nov	Des
1	Watuurip	209	389	388	379	0	71	56	11	31	248	300	855
2	Tanggul	157	386	239	264	0	50	79	0	0	156	267	514
3	Darungan	226	355	222	325	0	108	134	0	29	216	370	603
4	Sukorejo	146	358	0	393	0	10	56	0	0	0	247	395
5	Dam Langkap	226	156	123	258	5	37	96	5	7	67	83	480
6	Dam Kijingan	0	0	0	0	0	0	0	0	0	36	84	506
7	Dam Tugusari	398	436	154	220	0	14	54	0	0	37	42	813
8	Wringin Agung	96	228	259	206	4	25	29	0	4	88	134	569
9	Pladingan	243	208	150	270	0	20	10	0	0	41	131	488
10	Pondokwaluh	182	217	276	266	0	7	13	0	0	64	159	476
11	Kencong	134	136	199	171	0	1	17	0	0	96	204	472
12	Kencong	200	104	239	230	0	18	0	0	0	77	65	346
13	Wonorejo	123	92	253	241	0	0	6	0	0	49	92	409
14	Bagorejo	113	148	155	319	0	0	0	0	0	68	98	514
15	Gumukmas(BT)	124	104	252	278	0	0	7	0	0	32	98	354
16	Bedodo	136	111	181	252	0	0	0	0	0	55	75	357
17	Gumukmas(KT)	186	152	242	322	0	0	10	0	0	91	99	508
18	Menampu	127	146	306	192	0	0	8	0	0	106	89	457
19	Pondokjoyo	259	366	233	278	5	22	51	0	31	193	317	646
20	Pondokjoyo	259	360	234	283	5	21	53	0	31	152	394	828
21	Semboro	137	315	219	177	0	36	14	0	0	98	110	406
22	Paleran	223	351	149	238	11	43	26	0	0	50	177	409
23	Puger	132	82	144	197	0	0	27	0	0	83	30	312
24	Grenden	186	180	165	271	0	0	63	0	0	70	65	505
25	Jambearum	162	118	150	163	16	12	97	0	0	59	60	400
26	Balung	153	188	252	118	17	46	84	0	0	69	63	430
27	Karangduren	159	163	162	188	0	8	69	0	0	86	84	327
28	Gumelar Timur	81	164	202	272	13	15	49	12	9	50	92	421

29	Tamansari	90	150	181	163	41	21	61	6	11	47	96	381
30	Glundengan	72	170	201	144	0	23	96	11	17	49	72	353
31	Lojejer	60	141	148	104	0	10	48	0	0	34	64	400
32	Ampel	100	155	195	156	0	16	27	0	0	76	50	349
33	Tanjungrejo	85	142	261	234	0	33	85	0	0	80	65	397
34	Kesilir	90	143	201	206	0	43	26	0	0	96	72	392
35	Dam Talang	357	276	292	175	0	113	190	26	28	230	144	625
36	Jenggawah	132	164	199	138	0	61	65	13	24	128	83	299
37	Kemuningsari	157	147	225	234	12	104	109	0	15	114	152	427
38	Jatisari	135	100	293	183	0	128	45	0	0	55	106	465
39	Karang Anyar	64	134	316	267	11	0	55	0	0	67	83	600
40	Sabrang DM. 4	89	136	205	199	0	44	23	0	0	91	39	422
41	Sabrang SB. 1	116	169	172	185	0	80	14	0	0	105	50	482
42	Sumberejo	62	161	180	195	0	84	16	0	0	103	82	521
43	Tempurejo	112	268	219	160	0	54	41	0	11	101	143	482
44	Sanenrejo	118	171	148	174	0	19	24	19	6	103	29	739
45	Kr. Kedawung	79	223	290	58	0	78	139	0	31	94	67	497
46	Renes(Ajung)	200	204	230	86	11	86	50	0	7	88	187	435
47	Dam Makam	262	326	386	294	51	100	120	43	105	174	174	475
48	Dam Pecoro	151	285	343	220	38	82	88	19	27	136	155	596
49	Rambipuji	277	291	353	260	46	92	108	38	94	153	113	647
50	Rawatamtu	110	216	260	237	4	58	44	0	13	99	87	526
51	Curahmalang	133	191	215	309	58	33	85	12	0	46	107	487
52	Dam Klatakan	0	0	0	0	0	0	0	0	0	0	765	1088
53	Dam Karanganom	184	320	311	241	27	76	53	30	12	120	138	467
54	Dam Pono	191	333	302	241	32	10	109	30	16	118	125	529
55	Dam Manggis	0	0	0	0	0	0	0	0	0	0	249	741
56	Dam Semangir	215	348	369	174	43	96	50	27	32	132	205	544
57	Bintoro	233	384	567	285	0	102	37	62	35	195	152	775
58	Dam Sembah	224	156	198	217	72	61	69	46	15	163	280	578
59	Kopang	121	169	441	127	12	94	107	75	50	235	157	699
60	Wirolegi	140	277	285	74	12	65	46	57	92	91	128	609

61	Jember	105	139	267	133	0	193	115	0	0	88	226	1009
62	Dam Tegal Batu	0	0	0	0	0	0	0	0	0	0	190	745
63	Sukowono	127	209	441	183	53	174	33	28	1	97	118	478
64	Sukorejo	116	252	309	114	16	83	10	69	10	121	113	586
65	Sbr. Jambe	125	235	447	203	15	123	18	17	0	253	158	465
66	Cumedak	42	333	418	206	0	141	9	0	0	290	413	615
67	Sbr. Kalong	124	263	354	148	15	73	32	92	0	150	148	633
68	Ajung	266	321	260	86	9	64	54	38	22	185	189	620
69	Ledokombo	124	248	241	139	0	85	20	4	0	141	130	429
70	Suren	220	235	276	65	0	43	50	27	0	248	216	614
71	Sumberjati	152	227	389	111	0	84	2	0	5	204	113	632
72	Silo	134	201	305	77	0	76	1	0	10	174	103	626
73	Seputih	364	567	354	26	11	102	65	0	0	282	41	564
74	Jatian	325	376	323	91	0	88	15	35	0	51	33	672
75	Kottok	200	412	375	238	15	150	45	69	0	253	79	540
76	Pakusari	248	442	280	104	0	135	38	26	0	99	66	425
77	Dam Arjasa	45	159	381	108	5	67	103	80	55	210	147	554

Data Curah Hujan Kabupaten Jember Tahun 2006

.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.

Data Curah Hujan Kabupaten Jember Tahun 2015

No	Nama Stasiun Hujan	Bulan											
		Jan	Feb	Mar	Apr	Mei	Juni	Juli	Agust	Sep	Okt	Nov	Des
1	Watuurip	154	264	284	445	73	20	7	0	0	0	95	300
2	Tanggul	127	322	191	362	187	64	4	0	0	0	85	279
3	Darungan	143	460	285	432	294	78	21	0	0	0	216	228
4	Sukorejo	206	272	89	320	70	19	0	0	0	0	110	282
5	Dam Langkap	180	332	165	268	173	0	0	0	0	0	27	117
6	Dam Kijingan	366	596	551	473	191	97	20	0	0	0	170	412
7	Dam Tugusari	445	759	518	474	157	0	0	0	0	0	170	449
8	Wringin Agung	48	162	114	157	58	2	5	0	0	0	23	154
9	Pladingan	77	230	260	246	98	0	12	0	0	0	27	187

10	Pondokwaluh	112	291	222	199	122	0	0	0	0	0	39	228
11	Kencong	133	374	209	149	52	0	0	0	0	0	64	170
12	Kencong	109	374	150	56	66	0	1	0	0	0	52	140
13	Wonorejo	127	380	126	191	66	0	0	0	0	0	70	271
14	Bagorejo	125	282	71	109	60	0	0	0	0	0	34	258
15	Gumukmas(BT)	143	362	125	148	54	3	0	0	0	0	101	296
16	Bedodo	188	277	130	184	120	0	3	0	0	0	30	187
17	Gumukmas(KT)	123	389	154	152	55	0	0	0	0	0	88	236
18	Menampu	143	376	145	97	24	0	4	0	0	0	44	210
19	Pondokjoyo	67	240	96	189	111	28	2	0	0	0	67	112
20	Pondokjoyo	58	211	75	176	93	24	1	0	0	0	68	94
21	Semboro	39	363	262	201	91	34	27	0	0	0	72	269
22	Paleran	291	135	258	235	89	0	0	0	0	0	8	181
23	Puger	106	221	82	130	47	0	0	0	0	0	47	239
24	Grenden	86	163	38	73	28	0	0	0	0	0	13	167
25	Jambearum	231	281	109	162	107	0	0	0	0	0	45	248
26	Balung	260	474	170	234	20	8	0	0	0	0	79	171
27	Karangduren	159	288	112	238	69	9	0	0	0	0	54	290
28	Gumelar Timur	257	403	193	280	11	26	0	0	0	0	80	194
29	Tamansari	201	308	171	249	16	10	0	0	0	0	57	221
30	Glundengan	222	252	162	316	20	11	0	0	0	0	56	200
31	Lojejer	169	124	64	141	15	0	0	0	0	0	19	157
32	Ampel	218	136	105	196	71	0	0	0	0	0	26	197
33	Tanjungrejo	256	224	148	329	22	13	0	0	0	0	21	164
34	Kesilir	218	221	143	345	38	12	0	0	0	0	78	239
35	Dam Talang	246	144	308	356	35	44	0	0	0	0	188	248
36	Jenggawah	28	68	37	32	7	5	5	0	0	0	150	185
37	Kemuningsari	199	242	295	366	33	15	1	0	0	0	55	150
38	Jatisari	226	273	262	257	34	0	0	0	0	0	21	202
39	Karang Anyar	274	235	158	362	73	0	0	0	0	0	86	67
40	Sabrang DM. 4	227	217	122	278	48	0	0	0	0	0	72	275
41	Sabrang SB. 1	260	240	151	323	91	7	0	0	0	0	45	198

42	Sumberejo	264	212	163	389	109	10	0	0	0	0	0	14	216
43	Tempurejo	241	181	239	296	43	22	0	0	0	0	0	99	233
44	Sanenrejo	278	381	243	133	22	0	0	0	0	0	0	121	370
45	Kr. Kedawung	255	359	381	308	60	64	7	0	0	0	0	152	280
46	Renes(Ajung)	359	251	162	288	8	5	0	0	0	0	0	127	210
47	Dam Makam	355	349	373	364	47	27	12	0	0	0	7	143	364
48	Dam Pecoro	380	352	471	328	59	30	14	0	0	0	0	136	365
49	Rambipuji	359	337	438	343	61	31	16	0	0	0	0	147	356
50	Rawatamtu	396	285	302	125	12	7	0	0	0	0	0	80	284
51	Curahmalang	260	229	206	175	4	4	0	0	0	0	0	98	152
52	Dam Klatakan	322	308	410	298	114	27	14	0	0	0	0	103	275
53	Dam Karanganom	324	405	452	389	138	19	13	0	0	0	0	122	303
54	Dam Pono	285	399	468	177	112	18	14	0	0	0	0	101	273
55	Dam Manggis	358	354	427	300	122	22	13	0	0	0	0	111	306
56	Dam Semangir	305	317	486	285	143	25	11	0	0	0	0	98	286
57	Bintoro	237	250	280	165	0	0	0	0	0	0	0	147	198
58	Dam Sembah	520	162	219	254	0	61	3	0	0	0	0	158	305
59	Kopang	332	133	176	153	84	0	0	0	0	0	0	101	123
60	Wirolegi	98	128	215	89	31	23	0	0	0	0	0	100	178
61	Jember	489	235	544	334	155	104	0	0	0	0	4	186	282
62	Dam Tegal Batu	416	265	417	193	0	0	2	0	0	0	0	127	117
63	Sukowono	264	404	553	278	25	1	22	0	0	0	0	132	150
64	Sukorejo	282	289	402	242	89	0	18	0	0	0	0	67	151
65	Sbr. Jambe	304	554	537	443	157	32	42	0	0	0	0	164	255
66	Cumedak	346	466	398	409	88	0	0	0	0	0	0	214	473
67	Sbr. Kalong	247	266	478	305	101	0	16	0	0	0	0	130	147
68	Ajung	258	388	254	266	40	39	10	0	0	0	0	269	260
69	Ledokombo	223	367	195	235	46	54	5	0	0	0	0	325	570
70	Suren	266	375	269	287	0	80	9	0	0	0	0	270	373
71	Sumberjati	243	258	153	337	17	63	0	0	0	0	0	189	407
72	Silo	534	600	312	474	31	92	0	0	0	0	0	359	498
73	Seputih	245	396	350	325	17	69	0	0	0	0	0	168	305

74	Jatian	311	208	276	252	85	30	0	0	0	0	153	314
75	Kottok	419	475	564	252	127	70	7	0	0	5	102	302
76	Pakusari	214	401	448	459	93	0	0	0	0	0	135	305
77	Dam Arjasa	356	172	214	172	0	0	0	0	0	0	129	92