



TUGAS AKHIR - KS184822

***STATISTICAL DOWNSCALING OUTPUT GCM
DENGAN METODE SUPPORT VECTOR
REGRESSION*** UNTUK PREDIKSI CURAH HUJAN
SEBAGAI DASAR PREDIKSI BANJIR GENANGAN
DI KOTA SURABAYA

HENIDAR ISLAMI WINARNINGTYAS
NRP 062115 4000 0011

Dosen Pembimbing
Dr.rer.pol. Dedy Dwi Prastyo, S.Si., M.Si.

PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2019



TUGAS AKHIR - KS184822

***STATISTICAL DOWNSCALING OUTPUT GCM
DENGAN METODE SUPPORT VECTOR
REGRESSION* UNTUK PREDIKSI CURAH HUJAN
SEBAGAI DASAR PREDIKSI BANJIR GENANGAN
DI KOTA SURABAYA**

**HENIDAR ISLAMI WINARNINGTYAS
NRP 062115 4000 0011**

**Dosen Pembimbing
Dr.rer.pol. Dedy Dwi Prastyo, S.Si., M.Si.**

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2019**



FINAL PROJECT - KS184822

**STATISTICAL DOWNSCALING OF GCM OUTPUT
USING SUPPORT VECTOR REGRESSION METHOD
FOR FORECASTING RAINFALL TO PREDICT
FLOOD IN SURABAYA**

**HENIDAR ISLAMI WINARNINGTYAS
SN 062115 4000 0011**

**Supervisor
Dr.rer.pol. Dedy Dwi Prastyo, S.Si., M.Si.**

**UNDERGRADUATE PROGRAMME
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS, COMPUTING, AND DATA SCIENCE
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2019**

LEMBAR PENGESAHAN

STATISTICAL DOWNSCALING OUTPUT GCM DENGAN METODE SUPPORT VECTOR REGRESSION UNTUK PREDIKSI CURAH HUJAN SEBAGAI DASAR PREDIKSI BANJIR GENANGAN DI KOTA SURABAYA

TUGAS AKHIR

Diajukan untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Statistika
pada
Program Studi Sarjana Departemen Statistika
Fakultas Matematika, Komputasi, dan Sains Data
Institut Teknologi Sepuluh Nopember

Oleh :

Henidar Islami Winarningtyas
NRP. 062115 4000 0011

Disetujui oleh Pembimbing :

Dr.rer.pol. Dedy Dwi Prastyo, S.Si., M.Si.
NIP. 19831204 200812 1 002



SURABAYA, JULI 2019

(Halaman ini sengaja dikosongkan)

**STATISTICAL DOWNSCALING OUTPUT GCM DENGAN
METODE SUPPORT VECTOR REGRESSION UNTUK
PREDIKSI CURAH HUJAN SEBAGAI DASAR PREDIKSI
BANJIR GENANGAN DI KOTA SURABAYA**

Nama Mahasiswa : Henidar Islami Winarningtyas
NRP : 062115 4000 0011
Departemen : Statistika
Dosen Pembimbing: Dr.rer.pol. Dedy Dwi Prastyo, S.Si., M.Si.

Abstrak

Indonesia merupakan negara kepulauan terbesar di dunia yang dilalui oleh angin monsun, yaitu angin monsun barat dan monsun timur yang menyebabkan Indonesia memiliki dua musim, yaitu musim kemarau dan musim penghujan. Pada musim penghujan, curah hujan yang sangat tinggi dapat menimbulkan banjir di daerah dataran rendah dan kota-kota besar seperti kota Surabaya. Prediksi curah hujan dapat dilakukan dengan melakukan statistical downscaling output General Circulation Models (GCM) (model CSIRO Mk3.6.0) pada grid 1x1, grid 3x3 dan grid 3x3 dengan perlakuan PCA. Metode yang digunakan dalam penelitian ini adalah Support Vector Regression (SVR). Prediktor data GCM pada grid 3x3 merupakan grid terbaik untuk memprediksi curah hujan sekaligus dengan penambahan variabel dummy serta lag curah hujan dari hasil model ARIMA(1,0,0)(5,1,0)³⁶⁵ sebagai input pada pemodelan SVR. Hasil RMSE dan RMSE pada data testing untuk pos hujan Keputih yaitu sebesar 5.6648. Selanjutnya, dilakukan prediksi curah hujan bulan Desember 2018 untuk setiap pos hujan. Setelah itu dilakukan perhitungan matematis hidrologi dengan metode rasional dan dibandingkan dengan perhitungan matematis hidrolika saluran – saluran air dan sungai dan didapatkan hasil prediksi bahwa $Q_{hidrologi} < Q_{hidrolika}$. Kesimpulan yang diperoleh adalah pada wilayah Keputih, Kedung Cowek, Gubeng, Wonorejo, Wonokromo, dan Gunung Sari tidak berpotensi terjadinya banjir genangan di bulan Desember 2018.*

Kata Kunci : Banjir, Curah Hujan, GCM, Statistical Downscaling, SVR.

(Halaman ini sengaja dikosongkan)

STATISTICAL DOWNSCALING OF GCM OUTPUT USING SUPPORT VECTOR REGRESSION METHOD FOR FORECASTING RAINFALL TO PREDICT FLOOD IN SURABAYA

Name : Henidar Islami Winarningtyas
Student Number : 062115 4000 0011
Department : Statistics
Supervisor : Dr.rer.pol. Dedy Dwi Prastyo, S.Si., M.Si.

Abstract

Indonesia is the largest archipelagic country in the world which is passed by Monsoon Wind, which is the West and East Monsoon Wind which causes Indonesia have two seasons, i.e dry season and rainy season. In rainy season, extreme rainfall can cause flooding in low-lying areas and big cities such as Surabaya. Rainfall prediction can be done by statistical downscaling of General Circulation Models (GCM) output (CSIRO Mk3.6.0 model) on a 1x1 grid, 3x3 grid, and 3x3 grid with PCA treatment. The method used in this research is Support Vector Regression (SVR). The predictor from GCM data on a 3x3 grid is the best grid for forecasting rainfall with addition of dummy variables and lag of rainfall from the (resulted from ARIMA(1,0,0)(5,1,0)³⁶⁵) as input of SVR modeling. The results of RMSE and RMSE in testing dataset for the Keputih rainfall post are 5.6648. Furthermore, rainfall prediction is carried out in December 2018 for each rainfall post. Next, the mathematical hydrological calculations were carried out using the rational method and compared with the mathematical calculations of the hydraulics of the waterways and rivers. It obtained that the $Q_{hidrologi} < Q_{hidrolika}$. The conclusions obtained were that Keputih, Kedung Cowek, Gubeng, Wonorejo, Wonokromo, and Gunung Sari areas had no potential for flood inundation in December 2018.*

Keywords : Flood, GCM, Rainfall, Statistical Downscaling, SVR.

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Puji syukur kehadirat Tuhan Yang Maha Esa, atas segala berkat dan karunia-Nya, sehingga penulis dapat menyelesaikan laporan Tugas Akhir yang berjudul “***Statistical Downscaling Output GCM dengan Metode Support Vector Regression untuk Prediksi Curah Hujan Sebagai Dasar Prediksi Banjir Genangan di Kota Surabaya***” dengan lancar.

Oleh karena, penulis menyampaikan terima kasih kepada

1. Dr.rer.pol. Dedy Dwi Prastyo, S.Si., M.Si. selaku dosen pembimbing Tugas Akhir yang senantiasa sabar dalam memberikan arahan dalam bimbingan selama menyelesaikan Tugas Akhir.
2. Dr. Drs. Agus Suharsono, M.S. selaku dosen wali selama masa perkuliahan yang telah memberikan arahan selama menjalani proses perkuliahan.
3. M. Sjahid Akbar, S.Si., M.Si. dan Santi Puteri Rahayu, S.Si., M.Si., Ph.D. selaku dosen penguji Tugas Akhir yang telah banyak memberi masukan kepada penulis dalam penyelesaian Tugas Akhir.
4. Dr. Suhartono selaku Kepala Departemen Statistika dan Ibu Dr. Santi Wulan Purnami, S. Si., M.Si. selaku Ketua Program Studi Sarjana Departemen Statistika FMKSD ITS.
5. Seluruh dosen dan staf Program Studi Sarjana Departemen Statistika FMKSD ITS yang telah membantu penulis selama proses perkuliahan.
6. Ibu, Bapak, Mas, Adik yang selalu siap sedia mendengarkan curahan hati penulis dan memberikan motivasi serta doa sehingga penulis dapat menyelesaikan Tugas Akhir ini.
7. Teman-teman seperjuangan Tugas Akhir prediksi curah hujan dan banjir, yaitu Afifah Nur Iswari, Icha Tirhiss Febriana, Devita Prima Vernanda, Risda Ikfina Putri, dan Angga Mahendra yang selalu sedia diajak berdiskusi, berproses bersama, dan saling memberi *support* selama menyelesaikan Tugas Akhir ini.

8. Teman-teman Statistika ITS angkatan 2015, VIVACIOUS, yang selalu memberikan dukungan kepada penulis selama ini, khususnya Triajeng Nuraisyah, Nur Indah Asrori, Imas Ayu Lestari, Fitria Nurul Alfariz, Ulfa Siti Nuraini, Shindi Shella May Wara, Rahayu Prihatini Saputri, Ika Nur Laily Fitriana, Waode Melvy Agrina Jalil Silea.
9. Semua pihak yang telah membantu dalam penyelesaian Tugas Akhir ini yang tidak bisa penulis sebutkan satu persatu

Surabaya, Juli 2019

Penulis

DAFTAR ISI

	Hal
LEMBAR PENGESAHAN	iii
ABSTRAK	v
ABSTRACT	vii
KATA PENGANTAR	ix
DAFTAR ISI	xi
DAFTAR GAMBAR	xiv
DAFTAR TABEL	xix
DAFTAR LAMPIRAN	xxiii
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 TINJAUAN PUSTAKA	7
2.1 <i>Statistical Downscaling</i>	7
2.2 Korelasi <i>Pearson</i>	9
2.3 <i>Principal Component Analysis</i>	10
2.4 <i>Support Vector Regression</i>	11
2.5 Evaluasi Kebaikan Model.....	16
2.6 Model Matematis Perhitungan Banjir.....	17
2.7 Curah Hujan & Banjir.....	21

BAB III METODOLOGI PENELITIAN	23
3.1 Sumber Data	23
3.2 Variabel Penelitian	24
3.3 Langkah Analisis	28
BAB IV ANALISIS DAN PEMBAHASAN	33
4.1 Karakteristik Data.....	33
4.1.1 Pola Hubungan Antar Variabel di Pos Hujan Keputih	42
4.1.2 Pola Hubungan Antar Variabel di Pos Hujan Kedung Cowek	46
4.1.3 Pola Hubungan Antar Variabel di Pos Hujan Gubeng.....	47
4.1.4 Pola Hubungan Antar Variabel di Pos Hujan Wonorejo	47
4.1.5 Pola Hubungan Antar Variabel di Pos Hujan Wonokromo	47
4.1.6 Pola Hubungan Antar Variabel di Pos Hujan Gunung Sari	48
4.2 Pemodelan dan Prediksi Curah Hujan di Kota Surabaya	48
4.2.1 Pemodelan Curah Hujan Sederhana.....	49
4.2.2 Pemodelan Curah Hujan dengan Penambahan Lag	61
4.2.3 Pemodelan Curah Hujan dengan tidak melibatkan Observasi Nol pada Data Training ..	63
4.2.4 Penentuan Model Terbaik untuk Setiap Grid dan Secara Keseluruhan.....	64
4.2.5 Prediksi Curah Hujan di Kota Surabaya	72

4.3	Prediksi Banjir Genangan.....	85
BAB V KESIMPULAN DAN SARAN		90
5.1	Kesimpulan.....	90
5.2	Saran.....	90
DAFTAR PUSTAKA		92
LAMPIRAN.....		96
BIODATA PENULIS.....		190

(Halaman ini sengaja dikosongkan)

DAFTAR GAMBAR

Gambar 2. 1 Struktur Konseptual Sebuah GCM	7
Gambar 2. 2 Ilustrasi <i>Statistical Downscaling</i>	8
Gambar 2. 3 Fungsi Regresi pada SVR	11
Gambar 2. 4 Ilustrasi Proses SVR	12
Gambar 3.1 Visualisasi Pengambilan Ukuran Grid	24
Gambar 3.2 Peta Lokasi Pos Hujan terhadap Peta Saluran Air Sungai berdasarkan Rayon di Kota Surabaya	26
Gambar 3.3 Diagram Alir	29
Gambar 3.4 Penjelasan Pemodelan SVR	32
Gambar 4. 1 <i>Missing Value</i> pada Variabel Respon.....	33
Gambar 4. 2 <i>Missing Value</i> pada Variabel Prediktor	34
Gambar 4. 3 <i>Time Series Plot</i> Variabel Respon	37
Gambar 4. 4 <i>Boxplot</i> Bulanan Variabel Respon	38
Gambar 4. 5 <i>Boxplot</i> Bulanan Variabel Presipitasi	39
Gambar 4. 6 <i>Boxplot</i> Bulanan Variabel Temperatur	39
Gambar 4. 7 <i>Boxplot</i> Bulanan Variabel Kelembapan Udara	40
Gambar 4. 8 <i>Boxplot</i> Bulanan Variabel Kecepatan Angin	41
Gambar 4. 9 <i>Scatterplot</i> Presipitasi (Horisontal) terhadap Curah Hujan (Vertikal) di Pos Hujan Keputih	42
Gambar 4. 10 <i>Scatterplot</i> Temperatur (Horisontal) terhadap Curah Hujan (Vertikal) di Pos Hujan Keputih	43
Gambar 4. 11 <i>Scatterplot</i> Kelembapan Udara (Horisontal) terhadap Curah Hujan (Vertikal) di Pos Hujan Keputih ...	44
Gambar 4. 12 <i>Scatterplot</i> Kecepatan Angin (Horisontal) terhadap Curah Hujan (Vertikal) di Pos Hujan Keputih ...	45
Gambar 4. 13 Plot ACF dan PACF Data Curah Hujan di Pos Hujan Keputih	61
Gambar 4. 14 Plot ACF dan PACF Data Curah Hujan di Pos Hujan Keputih setelah <i>Differencing Seasonal</i> terhadap lag 365.....	62

Gambar 4. 15	<i>Time Series Plot</i> Hasil Pemodelan SVR Curah Hujan Keputih terhadap Data GCM Grid 1x1 ($Y_{1,t} = f(X_{15,t}, X_{25,t}, X_{35,t}, X_{45,t}, dummy_t)$)	65
Gambar 4. 16	<i>Time Series Plot</i> Hasil Pemodelan SVR Curah Hujan Keputih terhadap Data GCM pada Grid 1x1 ($Y_{1,t} = f(X_{15,t}, X_{25,t}, X_{35,t}, X_{45,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$) .	66
Gambar 4. 17	<i>Time Series Plot</i> Hasil Pemodelan SVR Curah Hujan Keputih terhadap Data GCM dengan NA pada Grid 1x1 ($Y_{1,t} = f(X_{15,t}, X_{25,t}, X_{35,t}, X_{45,t})$)	66
Gambar 4. 18	<i>Time Series Plot</i> Hasil Pemodelan SVR Curah Hujan Keputih terhadap Data GCM pada Grid 3x3 ($Y_{1,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t)$)	67
Gambar 4. 19	<i>Time Series Plot</i> Hasil Pemodelan SVR Curah Hujan Keputih terhadap Data GCM pada Grid 3x3 ($Y_{1,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$)	68
Gambar 4. 20	<i>Time Series Plot</i> Hasil Pemodelan SVR Curah Hujan dengan NA Keputih terhadap Data GCM pada Grid 3x3 ($Y_{1,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t})$)	68
Gambar 4. 21	<i>Time Series Plot</i> Hasil Pemodelan SVR Curah Hujan Keputih terhadap Data GCM pada Grid 3x3 PCA ($Y_1 = f(PC_{11,t}, PC_{21,t}, PC_{12,t}, PC_{22,t}, PC_{13,t}, PC_{23,t}, PC_{24,t}, PC_{24,t})$)	69
Gambar 4. 22	<i>Time Series Plot</i> Hasil Pemodelan SVR Curah Hujan Keputih terhadap Data GCM pada Grid 3x3 PCA ($Y_1 = f(PC_{11,t}, PC_{21,t}, PC_{12,t}, PC_{22,t}, PC_{13,t}, PC_{23,t}, PC_{24,t}, PC_{24,t}, lagARIMA(1,0,0)(5,1,0)^{365})$)	70
Gambar 4. 23	<i>Time Series Plot</i> Hasil Pemodelan SVR Curah Hujan Keputih dengan NA terhadap Data GCM pada Grid 3x3 PCA ($Y_1 = f(PC_{11,t}, PC_{21,t}, PC_{12,t}, PC_{22,t}, PC_{13,t}, PC_{23,t}, PC_{24,t}, PC_{24,t})$)	70

Gambar 4. 24 *Time Series Plot* Hasil Pemodelan SVR
Keputih pada Data GCM grid 3x3 ($Y_{1,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$) 73

Gambar 4. 25 *Time Series Plot* Hasil Pemodelan SVR
Kedung Cowek pada Data GCM grid 3x3 ($Y_{2,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$) 75

Gambar 4. 26 *Time Series Plot* Hasil Pemodelan SVR
Gubeng pada Data GCM grid 3x3 ($Y_{3,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$) 77

Gambar 4. 27 *Time Series Plot* Hasil Pemodelan SVR
Wonorejo pada Data GCM grid 3x3 ($Y_{4,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$) 79

Gambar 4. 28 *Time Series Plot* Hasil Pemodelan SVR
Wonokromo pada Data GCM grid 3x3 ($Y_{5,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$) 81

Gambar 4. 29 *Time Series Plot* Hasil Pemodelan SVR pada
Data GCM grid 3x3 ($Y_{6,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$) 84

Gambar 4. 30 Sikronisasi 5 Rayon terhadap 6 Pos Hujan di
Kota Surabaya 86

(Halaman ini sengaja dikosongkan)

DAFTAR TABEL

Tabel 2. 1 Tabel Kekasaran Manning untuk Saluran.....	20
Tabel 3. 1 Penentuan Lokasi di Kota Surabaya pada Data Output GCM CSIRO Mk3.6.0	23
Tabel 3.2 Variabel Penelitian	24
Tabel 3.3 Pos Hujan di Kota Surabaya	25
Tabel 3.4 Struktur Data Curah Hujan pada Setiap dengan Data Output GCM pada Grid 3x3	27
Tabel 4. 1 Karakteristik Data Curah Hujan	35
Tabel 4. 2 Hasil Keputusan Korelasi Pearson Variabel Presipitasi terhadap Curah Hujan Keputih	42
Tabel 4. 3 Hasil Keputusan Korelasi Pearson Variabel Temperatur terhadap Curah Hujan Keputih	44
Tabel 4. 4 Hasil Keputusan Korelasi Pearson Variabel Kelembapan Udara terhadap Curah Hujan Keputih.....	45
Tabel 4. 5 Hasil Keputusan Korelasi Pearson Variabel Kecepatan Angin terhadap Curah Hujan Keputih.....	46
Tabel 4. 6 Pemodelan SVR Curah Hujan Keputih dengan Data <i>Testing</i> Bulan Desember 2018 pada Data GCM Grid 1x1	50
Tabel 4. 7 Pemodelan SVR Curah Hujan Keputih dengan Data <i>Testing</i> Tahun 2018 pada Data GCM Grid 1x1	51
Tabel 4. 8 Pemodelan SVR Curah Hujan Keputih dengan Data <i>Testing</i> Bulan Desember 2018 pada Data GCM Grid 3x3	53
Tabel 4. 9 Pemodelan SVR Curah Hujan Keputih dengan Data <i>Testing</i> Tahun 2018 pada Data GCM Grid 3x3.....	55
Tabel 4. 10 <i>Cumulative Proportion</i> untuk PCA Variabel Prediktor.....	56
Tabel 4. 11 Pemodelan SVR Curah Hujan Keputih dengan Data <i>Testing</i> Bulan Desember 2018 pada Data GCM Grid 3x3 PCA.....	58

Tabel 4. 12 Pemodelan SVR Curah Hujan Keputih dengan Data <i>Testing</i> Tahun 2018 pada Data GCM Grid 3x3 PCA	59
Tabel 4. 13 Pemodelan SVR Curah Hujan Keputih Terbaik dengan Penambahan Lag dari ARIMA (1,0,0)(5,1,0) ³⁶⁵ ...	62
Tabel 4. 14 Pemodelan SVR Curah Hujan Keputih dengan Tidak Melibatkan Observasi Nol	64
Tabel 4. 15 Rangkuman Hasil Pemodelan SVR Curah Hujan Keputih dengan Variabel Prediktor Data GCM	71
Tabel 4. 16 Hasil Prediksi Curah Hujan Keputih pada Data GCM grid 3x3 ($Y_{1,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$)	73
Tabel 4. 17 Hasil Prediksi Curah Hujan Kedung Cowek pada Data GCM grid 3x3 ($Y_{2,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$)	75
Tabel 4. 18 Hasil Prediksi Curah Hujan Gubeng pada Data GCM grid 3x3 ($Y_{3,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$)	77
Tabel 4. 19 Hasil Prediksi Curah Hujan Wonorejo pada Data GCM grid 3x3 ($Y_{4,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$)	80
Tabel 4. 20 Hasil Prediksi Curah Hujan Wonokromo pada Data GCM grid 3x3 ($Y_{5,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$)	82
Tabel 4. 21 Hasil Prediksi Curah Hujan Gunung Sari pada Data GCM grid 3x3 ($Y_{6,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$)	84
Tabel 4. 22 Hasil Prediksi Curah Hujan Maksimum di Setiap Pos Hujan	85

Tabel 4. 23 Sikronisasi 5 Rayon terhadap 6 Pos Hujan di Kota
Surabaya.....87

(Halaman ini sengaja dikosongkan)

DAFTAR LAMPIRAN

Lampiran 1 Data Curah Hujan di Kota Surabaya	96
Lampiran 2 Data General Circulation Model (GCM)	97
Lampiran 3 <i>Source Code</i> R untuk Menggabungkan Data Curah Hujan Setiap Pos Hujan.....	101
Lampiran 4 <i>Source Code</i> R untuk Cropping Data GCM.....	105
Lampiran 5 <i>Source Code</i> R untuk Menggabungkan Data Curah Hujan dan GCM	107
Lampiran 6 <i>Source Code</i> R untuk Identifikasi <i>Missing</i> <i>Value</i>	108
Lampiran 7 <i>Source Code</i> R untuk Imputasi <i>Missing Value</i>	111
Lampiran 8 <i>Source Code</i> R untuk Eksplorasi Variabel Curah Hujan	112
Lampiran 9 <i>Source Code</i> R untuk Eksplorasi Variabel GCM	115
Lampiran 10 <i>Source Code</i> R untuk Eksplorasi Pola Hubungan Data GCM terhadap Curah Hujan	121
Lampiran 11 <i>Source Code</i> R untuk <i>Tuning</i> Parameter SVR ...	128
Lampiran 12 Hasil Pemodelan setelah <i>Tuning</i> Parameter	131
Lampiran 13 Eksplorasi Pola Hubungan di Pos Hujan Kedung Cowek.....	135
Lampiran 14 Eksplorasi Pola Hubungan di Pos Hujan Gubeng.....	136
Lampiran 15 Eksplorasi Pola Hubungan di Pos Hujan Wonorejo.....	137
Lampiran 16 Eksplorasi Pola Hubungan di Pos Hujan Wonokromo	138
Lampiran 17 Eksplorasi Pola Hubungan di Pos Hujan Gunung Sari	139
Lampiran 18 Hasil Keputusan Korelasi Antar Variabel Prediktor terhadap Curah Hujan di Pos Hujan Kedung Cowek	140

Lampiran 19 Hasil Keputusan Korelasi Antar Variabel Prediktor terhadap Curah Hujan di Pos Hujan Gubeng ..	141
Lampiran 20 Hasil Keputusan Korelasi Antar Variabel Prediktor terhadap Curah Hujan di Pos Hujan Wonorejo.....	142
Lampiran 21 Hasil Keputusan Korelasi Antar Variabel Prediktor terhadap Curah Hujan di Pos Hujan Wonokromo.....	143
Lampiran 22 Hasil Keputusan Korelasi Antar Variabel Prediktor terhadap Curah Hujan di Pos Hujan Gunung Sari	144
Lampiran 23 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Bulan Desember 2018 pada Grid 1x1	145
Lampiran 24 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Bulan Desember 2018 pada Grid 3x3	150
Lampiran 25 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Bulan Desember 2018 pada Grid 3x3 PCA	155
Lampiran 26 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Tahun 2018 pada Grid 1x1.....	160
Lampiran 27 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Tahun 2018 pada Grid 3x3.....	165
Lampiran 28 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Tahun 2018 pada Grid 3x3 PCA.....	170
Lampiran 29 Persamaan ARIMA untuk menentukan Lag dalam Pemodelan SVR.....	175
Lampiran 30 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Penambahan Lag pada Grid 1x1	176

Lampiran 31 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Penambahan Lag pada Grid 3x3	177
Lampiran 32 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Penambahan Lag pada Grid 3x3 PCA ..	178
Lampiran 33 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Penggunaan NA pada Grid 1x1	179
Lampiran 34 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Penggunaan NA pada Grid 3x3	180
Lampiran 35 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Penggunaan NA pada Grid 3x3 PCA ...	181
Lampiran 36 <i>Support Vector</i> yang terbentuk dari Pemodelan SVR	182
Lampiran 37 Surat Keterangan Data Curah Hujan dan Saluran Air	185
Lampiran 38 Surat Pernyataan Data <i>General Circulation</i> <i>Model</i> (GCM).....	187

(Halaman ini sengaja dikosongkan)

BAB I

PENDAHULUAN

1.1 Latar Belakang

Indonesia merupakan negara kepulauan terbesar di dunia yang memiliki letak astronomis pada 6° LU – 11° LS dan 95° BT – 141° BT dan letak geografis berada diantara benua Asia dan benua Australia, serta Samudera Hindia dan Samudera Pasifik. Hal tersebut menyebabkan Indonesia dilalui oleh angin monsun yang berganti arah sebanyak dua kali setahun, yaitu angin monsun barat dan monsun timur. Keberadaan angin monsun ini berdampak pada besarnya curah hujan. Angin monsun timur yang terjadi pada kurun waktu bulan April hingga Oktober menyebabkan Indonesia mengalami musim kemarau. Hal ini dikarenakan, angin bertiup dari kawasan benua Australia menuju ke kawasan benua Asia dengan melewati daerah gurun pasir yang terletak di bagian utara benua Australia yang bersifat kering dan angin tersebut hanya melalui lautan yang sempit yang mengakibatkan angin tidak mengandung uap air yang banyak dan mengakibatkan rendahnya curah hujan. Selain angin monsun timur juga terdapat angin monsun barat yang bertiup dari kawasan benua Asia ke kawasan benua Australia terjadi pada kurun waktu bulan Oktober hingga April. Angin tersebut melalui samudera Hindia sehingga mengandung uap air yang banyak. Hal ini mengakibatkan Indonesia mengalami musim penghujan yang mengakibatkan curah hujan yang tinggi.

Curah hujan yang sangat tinggi pada musim penghujan, banyaknya sampah di selokan dan sedikitnya pohon yang menyerap air di daerah hulu aliran sungai akan menimbulkan banjir di daerah dataran rendah dan kota-kota besar yang padat penduduk yang umumnya terletak di daerah dataran rendah (Kemdikbud RI, 2010). Salah satu kota besar di Indonesia adalah kota Surabaya. Surabaya merupakan ibu kota Propinsi Jawa Timur yang dikenal sebagai Kota Pahlawan yang memiliki letak astronomis pada $7^{\circ} 9' - 7^{\circ} 21' LS$ dan $112^{\circ} 36' - 112^{\circ} 54' BT$. Ketinggian kota Surabaya

tersebut berada pada 3 – 6 meter di atas permukaan air laut sehingga dapat dikatakan bahwa kota Surabaya merupakan wilayah dengan dataran rendah, kecuali di bagian selatan terdapat dua bukit landai di daerah Lidah & Gayungan dengan ketinggian 25-50 meter di atas permukaan air laut (Pemkot Surabaya, 2019). Kondisi geografi yang merupakan dataran rendah tersebut mengakibatkan air pada saat curah hujan tinggi tidak bisa terbuang mengikuti gravitasi, sehingga harus bergantung pada operasional pompa air (Gol, 2017). Selain itu juga, perkembangan perkotaan yang tidak diiringi dengan pengelolaan yang baik akan menyebabkan sistem drainase perkotaan akan memburuk, air tidak dapat mengalir dengan semestinya sehingga menyebabkan genangan banjir (Billiocta, 2017). Kejadian banjir berupa genangan air yang berlebihan tersebut muncul karena adanya peningkatan volume air yang mengalir diatas permukaan tanah, baik akibat curah hujan yang tinggi atau luapan air sungai. Oleh sebab itu diperlukan prediksi curah hujan untuk memperkirakan kapan banjir genangan akan terjadi sehingga dapat dilakukan antisipasi dini terkait operasional pompa air dan sistem drainase di kota Surabaya.

Curah hujan merupakan salah satu bentuk endapan (presipitasi) yang didefinisikan sebagai bentuk air cair dan padat (es) yang jatuh ke permukaan bumi (Tjasjono, 1999). Pengamatan curah hujan di Indonesia secara langsung dilakukan oleh Badan Meteorologi, Klimatologi dan Geofisika (BMKG). Fluktuasi curah hujan dipengaruhi berbagai faktor lokal hingga faktor global (Rahmadini, Azani, & Rejeki, 2019). Di Indonesia, iklim lokal erat hubungannya dipengaruhi oleh iklim global seperti halnya yang diketahui bahwa Indonesia merupakan negara kepulauan dengan bentuk topografi yang sangat beragam dan terdapat berbagai faktor yang mempengaruhi keragaman iklim, baik lokal, regional maupun global, maka upaya regionalisasi (*downscaling*) perlu dilakukan dalam kajian keragaman iklim, studi perubahan iklim, dan pemanfaatan kajian iklim lainnya dengan *General Circulation Models* (GCM) (Sutikno, 2008).

Statistical downscaling merupakan proses *downscaling* yang bersifat statistik yang digunakan dimana data pada grid-grid berskala global digunakan sebagai dasar untuk menentukan data pada grid berskala lokal. Dalam *statistical downscaling*, variabel permukaan skala global digunakan sebagai variabel prediktor, yaitu data *output* GCM sedangkan variabel respon merupakan variabel iklim yang diinginkan dalam skala lokal, yaitu data curah hujan. Pengamatan banjir genangan di kota Surabaya hanya terletak pada lima kecamatan, sehingga pada penelitian ini akan dilakukan *statistical downscaling output* GCM terhadap curah hujan di kelima kecamatan tersebut. Dalam penelitian ini, data *output* GCM yang digunakan yaitu model CSIRO Mk3.6.0 dikarenakan model CSIRO-9 dan GFDL mempunyai kinerja yang baik untuk digunakan sebagai penilai dampak di Indonesia (Kaimuddin, 2000).

Penelitian sebelumnya terkait prediksi curah hujan telah dilakukan oleh Mukid & Sugito (2013) yaitu prediksi curah hujan di Kabupaten Grobogan dengan pendekatan regresi proses gaussian menggunakan variabel suhu dan kelembaban udara sebagai variabel prediktornya dan didapatkan RMSEP sebesar 123.63. Sedangkan untuk studi kasus Kota Surabaya, prediksi curah hujan pernah dilakukan oleh (Dhawangkhara & Riksakomara (2017) dengan curah hujan sebagai variabel respon dan variabel prediktor nya merupakan rekam data cuaca yang dicatat oleh NCDC (*National Climatic Data Center*) dengan metode yang digunakan adalah metode CART dan *Random Forest* diperoleh akurasi sebesar 77-78%.

Selanjutnya untuk penelitian *statistical downscaling output* GCM telah dilakukan oleh Ghosh & Mujumdar (2006), Sutikno (2008), Agmalaro (2011), Lembang (2013), dan Sanusi, Buono, Sitanggang, & Faqih (2014) yang mana sebelum melakukan pengolahan terlebih dahulu variabel prediktor yang merupakan data *output* GCM dilakukan reduksi dimensi secara serentak dengan *Principal Component Analysis* (PCA) guna untuk mengatasi adanya korelasi antar variabel yang akan mengakibatkan

kasus multikolinieritas pada proses pemodelan. Begitu juga pada penelitian yang pernah dilakukan oleh Mandasari (2010) menyatakan bahwa reduksi dimensi variabel prediktor *output* GCM dengan metode transformasi *wavelet* Daubechies tidak dapat mengatasi multikolinieritas sehingga perlu direduksi kembali dengan PCA.

Selanjutnya penelitian *statistical downscaling output* GCM lainnya telah dilakukan oleh Chen, Yu, & Tang (2010) menghasilkan bahwa SVM-*Classification* maupun SVM-*Regression* mengungguli kebaikan model dari analisis multivariat. Selain itu Sanusi, Buono, Sitanggang, & Faqih (2014) juga melakukan penelitian *statistical downscaling output* GCM dengan metode SVM-*Regression* fungsi kernel linear dan menghasilkan model prediksi yang baik. Penelitian selanjutnya oleh Sahoo & Sen (2017) menyatakan bahwa dibandingkan dengan model regresi linear sederhana dan *Artificial Neural Networks* (ANN), SVM-*Regression* selain menghasilkan model yang dapat memprediksi dengan baik kemudian penelitian pada tahun berikutnya oleh Sachindra, Rashid, Ahmed, & Shahid (2018) dengan kesimpulan bahwa metode dengan performa terbaik adalah SVM-*Regression* dan RVM dengan kernel polinomial dibandingkan *Artificial Neural Networks* (ANN) dan *Genetic Programming* (GP). Sehingga metode SVR memiliki kelebihan yaitu dapat mengatasi masalah ketidaklinieran data dalam pembentukan model digunakan fungsi kernel. Selain itu metode SVR merupakan salah satu metode nonparametrik yang dapat digunakan untuk mengatasi masalah pelanggaran asumsi multikolinieritas khususnya pada data *output* GCM yang akan diolah.

Berdasarkan uraian yang telah dijelaskan, pada penelitian ini akan dilakukan *statistical downscaling output* GCM dengan metode *Support Vector Regression* (SVR). Selanjutnya dilakukan evaluasi kinerja model dengan menghitung *Root Mean Squared Error* (RMSE). Setelah didapatkan model prediksi curah hujan paling optimal, selanjutnya dilakukan prediksi terhadap banjir genangan di Kota Surabaya dengan model matematis hidrologi

perhitungan banjir dengan metode rasional sehingga diharapkan dapat digunakan Pemerintah Kota Surabaya dalamantisipasi banjir.

1.2 Rumusan Masalah

Berdasarkan latar belakang dijelaskan bahwa Indonesia khususnya Kota Surabaya merupakan daerah dataran rendah yang rawan akan adanya banjir, sehingga dapat digarisbawahi bahwa permasalahan yang akan dibahas dalam penelitian ini adalah bagaimana memprediksi banjir genangan berdasarkan prediksi curah hujan hasil *statistical downscaling output General Circulation Model* (GCM) dengan metode *Principal Component Regression* (PCR) dan *Support Vector Regression* (SVR)?.

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah yang telah diuraikan, maka terdapat beberapa tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut.

1. Memperoleh karakteristik curah hujan harian di Kota Surabaya.
2. Mendapatkan model optimum *statistical downscaling* data *output* GCM untuk prediksi curah hujan di Kota Surabaya dengan metode SVR.
3. Mendapatkan hasil prediksi banjir genangan di Kota Surabaya berdasarkan prediksi curah hujan.

1.4 Manfaat Penelitian

Hasil dari penelitian ini diharapkan dapat dijadikan Pemerintah Kota Surabaya sebagai peringatan dini dan sebagai upaya pencegahan banjir genangan yang diakibatkan oleh curah hujan di Kota Surabaya. Selain itu, penelitian ini juga bermanfaat bagi pembaca sebagai wawasan keilmuan statistika khususnya dalam penggunaan metode *Principal Component Regression* dan *Support Vector Regression* dalam *statistical downscaling* data *output General Circulation Model* (GCM) untuk prediksi curah hujan di Kota Surabaya.

1.5 Batasan Masalah

Dalam penelitian ini memiliki batasan masalah yaitu menggunakan data curah hujan harian pada 6 dari 7 Pos Hujan di Kota Surabaya yang selama periode tahun 2009 – 2018 alat pencatat curah hujan yang digunakan tidak rusak. Hal ini bertujuan agar diperoleh hasil analisis yang akurat karena tidak banyak data yang *missing* karena alat pencatat curah hujan rusak. Selain itu, juga dalam penelitian ini tidak mempertimbangkan efek spasial yang ditimbulkan oleh antar wilayah pengamatan di Kota Surabaya.


BAB II

TINJAUAN PUSTAKA

Tinjauan pustaka yang digunakan dalam penelitian ini terdapat beberapa macam, yaitu *statistical downscaling*, korelasi *pearson*, *Principal Component Analysis (PCA)*, *Support Vector Regression (SVR)*, model matematis perhitungan banjir, dan curah hujan & banjir.

2.1 *Statistical Downscaling*


Downscaling merupakan suatu proses yang memungkinkan untuk memodelkan interaksi dan membangun hubungan antara iklim lokal saat ini dengan kondisi atmosfer yang terjadi (Trzaska & Schnarr, 2014). Tujuan dari *downscaling* adalah untuk menyediakan data iklim dalam skala lokal. *General Circulation Models (GCM)* merupakan model yang mensimulasikan iklim bumi melalui persamaan matematika yang menggambarkan proses atmosfer, lautan, dan biotik, interaksi, dan umpan balik. GCM merupakan alat utama yang menyediakan informasi iklim berskala global yang cukup akurat dan digunakan untuk memahami skenario iklim saat ini dan masa depan (Trzaska & Schnarr, 2014). GCM terdiri dari banyak sel *grid* yang mewakili area horizontal dan vertikal pada permukaan bumi yang disajikan pada Gambar 2.1.



Gambar 2. 1 Struktur Konseptual Sebuah GCM

Dalam setiap sel, GCM menghitung hal-hal berikut, seperti interaksi uap air dan atmosfer awan, efek langsung dan tidak langsung dari aerosol pada radiasi dan presipitasi, perubahan lapisan salju dan laut es, penyimpanan panas di tanah dan lautan, fluks permukaan panas dan kelembaban, dan transportasi skala besar panas dan air oleh atmosfer dan lautan Wilby, et al. (2009) dalam Trzaska & Schnarr (2014). Berbagai model GCM telah dikembangkan dengan berbagai resolusi spasial. Hasil kajian perbandingan GCM untuk menilai dampak menunjukkan bahwa setiap model GCM mempunyai tingkat akurasi yang berbeda-beda pada suatu wilayah.

Metode *downscaling* untuk data *output* GCM dapat dibedakan menjadi tiga, yaitu metode resolusi tinggi/grid yang diregangkan, *regional models/dynamic downscaling* dan *statistical downscaling*. Dari ketiga metode tersebut, metode *statistical downscaling* memiliki keuntungan utama yaitu komputasinya lebih murah dan dapat dengan mudah diaplikasikan pada *output* berbagai simulasi dan eksperimen berbasis GCM (Sutikno, 2008). Dalam *statistical downscaling*, variabel permukaan skala global digunakan sebagai variabel prediktor sedangkan variabel respon merupakan variabel iklim yang diinginkan yang mana memerlukan sumber data *time series* skala lokal. Berikut ini merupakan ilustrasi *statistical downscaling* (Halik, Anwar, & Santosa, 2014).



Gambar 2. 2 Ilustrasi *Statistical Downscaling*

Meskipun penurunan skala statistik efisien, komputasi murah, dan terdiri dari beragam kelompok metode. Menurut Hewitson & Crane (1996) dalam Halik (2014), ada tiga asumsi yang digunakan dalam metode *statistical downscaling*, yaitu sebagai berikut.

1. Prediktor adalah variabel *output* GCM yang relevan dan realistik.
2. Hubungan empiris yang berlaku juga pada kondisi iklim yang berubah.
3. Prediktor yang digunakan sepenuhnya mewakili signal iklim.

2.2 Korelasi *Pearson*

Korelasi dapat menyatakan adanya hubungan antar variabel. Salah satu macam korelasi adalah korelasi *pearson* yang mana dapat menyatakan korelasi untuk data interval/rasio. Hubungan yang dikaji pada korelasi *pearson* ini merupakan hubungan linier antar variabel prediktor dan variabel respon yang nilainya bisa dihitung dengan rumus pada Persamaan (2.1) berikut (Walpole, Myers, Myers, & Ye, 2012).

$$r_{xy} = \frac{S_{xy}}{\sqrt{S_{xx}S_{yy}}}$$

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (2.1)$$

Hipotesis untuk pengujian korelasi *pearson* yang digunakan dalam penelitian ini adalah sebagai berikut.

H_0 : Tidak ada hubungan yang signifikan antara Variabel Prediktor terhadap Variabel Respon Curah Hujan Harian.

H_1 : Adanya hubungan yang signifikan antara Variabel Prediktor terhadap Variabel Respon Curah Hujan Harian.

Statistik Uji yang digunakan adalah sebagai berikut.

$$t_{hit} = \frac{r\sqrt{n-2}}{\sqrt{1-r^2}}, \quad t_{tabel(\alpha, n-2)} \quad (2.2)$$

dengan kriteria pengujian yaitu tolak H_0 jika $t_{hit} > t_{tabel}$ atau nilai $p\text{-value} < \alpha$ (0.05).

2.3 Principal Component Analysis

Principal Component Analysis (PCA) merupakan teknik analisis yang secara luas digunakan untuk mereduksi dimensi dataset tanpa kehilangan informasi yang signifikan. Tujuan PCA adalah memproyeksikan variabel prediktor dengan dimensi tinggi ke dalam subset yang lebih kecil untuk mengurangi biaya komputasi. PCA menghitung variabel-variabel prediktor baru, yang disebut *Principal Components* (PCs), yang merupakan kombinasi linear tidak berkorelasi dari variabel prediktor yang diproyeksikan ke arah variabilitas yang lebih besar (Awad & Khanna, 2015). *Principal Components* (PCs) dapat dijelaskan sesuai Persamaan (2.3) berikut (Yu, Chen, & Zhang, 2014).

$$\begin{cases} PC_1 = \vec{\alpha}_1^T \cdot \vec{X} = \alpha_{11}X_1 + \alpha_{12}X_2 + \dots + \alpha_{1n}X_n \\ PC_2 = \vec{\alpha}_2^T \cdot \vec{X} = \alpha_{21}X_1 + \alpha_{22}X_2 + \dots + \alpha_{2n}X_n \\ \vdots \\ PC_n = \vec{\alpha}_n^T \cdot \vec{X} = \alpha_{n1}X_1 + \alpha_{n2}X_2 + \dots + \alpha_{nn}X_n \end{cases} \quad (2.3)$$


dimana X_i adalah variabel prediktor *output* GCM, PC_i adalah *Principal Component*, dan $\vec{\alpha}_i$ adalah koefisien vektor masing-masing. $\vec{\alpha}_i$ dapat di estimasi dengan memaksimumkan $Var(Y_i)$ dengan kondisi konstrain $Cov(Y_i, Y_j) = \vec{\alpha}_i^T \cdot \Sigma \cdot \vec{\alpha}_j = 0, j = 1, 2, \dots, i-1$, dimana $\Sigma = (\sigma_{ij})_{n \times n}$ adalah kovarian matriks dari \vec{X} . Keuntungan PCA adalah mengurangi dimensi variabel prediktor dan pada saat yang sama tidak ada informasi dan korelasi yang

berlebihan di antara prediktor, yang mungkin mengarah pada multikolinieritas. Kriteria pemilihan banyaknya n *Principal Component* yaitu dengan melihat proporsi kumulatif keragaman data asal yang dijelaskan oleh n *Principal Component* minimal 80% dan proporsi total variansi populasi bernilai cukup besar (Johnson & Winchern, 2002).

2.4 Support Vector Regression

Support Vector Regression (SVR) adalah penerapan metode regresi dari *Support Vector Machine* (SVM). SVR menggunakan prinsip yang sama seperti SVM untuk klasifikasi, dengan tujuan untuk menemukan suatu fungsi $f(\mathbf{x})$ sebagai hyperplane. Sementara itu, SVR dapat menghasilkan bilangan real sebagai output dari variabel input independen. Penggunaan SVR untuk downscaling bertujuan untuk menangkap efek non linear pada data (Vandal, Kodra, & Gangul, 2017).

Misalkan diberikan set data *training*, $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ dengan *input* $x \in X \subset \mathbb{R}$ dan data *output* $y \in Y \subset \mathbb{R}$. Berdasarkan dari data, fungsi regresi $f(x)$ dari *support vector regression* dengan asumsi fungsi nonlinear dapat diilustrasikan pada Gambar 2.3 dan dapat dinyatakan dengan formula pada Persamaan (2.4) (Ojemakinde, 2006).



Gambar 2. 3 Fungsi Regresi pada SVR

$$f(\mathbf{x}) = \mathbf{w}^T \varphi(\mathbf{x}) + b \quad (2.4)$$

Dimana \mathbf{w} adalah vektor pembobot, b adalah bias, dan $\varphi(x_i)$ menunjukkan suatu titik didalam ruang fitur berdimensi lebih

tinggi, yang secara linear dipetakan dari input x didalam ruang input yang berdimensi lebih rendah. Tujuan dari *support vector regression* adalah untuk menentukan nilai parameter \mathbf{w} dan b yang di estimasi dengan cara meminimalkan risiko empiris $R_{\text{empirical}}$ yang didefinisikan dalam Persamaan (2.5) berikut (Sachindra, Rashid, Ahmed, & Shahid, 2018).

$$R_{\text{empirical}} = \frac{C}{n} \sum_{i=1}^n L_{\varepsilon}(f(\mathbf{x}_i), \mathbf{y}_i) + \frac{1}{2} \|\mathbf{w}\|^2 \quad (2.5)$$

dalam persamaan risiko empiris diatas, $|y_i - f(x_i)| \leq \varepsilon$ didefinisikan sebagai Vapnik's ε insensitive loss function seperti yang disajikan pada Persamaan (2.6) berikut.

$$L_{\varepsilon}(f(\mathbf{x}_i), \mathbf{y}_i) = |y_i - f(\mathbf{x}_i)|_{\varepsilon} = \begin{cases} 0 & , \text{jika } |y_i - f(\mathbf{x}_i)| \leq \varepsilon \\ |y_i - f(\mathbf{x}_i)| - \varepsilon & , \text{ untuk yang lain} \end{cases} \quad (2.6)$$

Parameter \mathbf{w} dan b diestimasi dengan meminimalkan *cost function* Ψ_{ε} yang ditunjukkan pada Persamaan (2.7), dimana ξ_i dan ξ_i^* adalah variabel *slack* dan C adalah konstanta real positif yang telah ditentukan.


$$\Psi_{\varepsilon} = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (2.7)$$

dengan batasan Persamaan (2.7) harus mengikuti syarat yang diberikan adalah sebagai berikut.

$$(w\varphi(\mathbf{x}_i) + b) - \mathbf{y}_i \leq \varepsilon + \xi_i^*$$

$$\mathbf{y}_i - (w\varphi(\mathbf{x}_i) + b) \leq \varepsilon + \xi_i^*$$

$$\xi_i, \xi_i^* \geq 0, \quad i = 1, 2, \dots, nSV$$



Gambar 2.4 Ilustrasi Proses SVR

Selanjutnya, optimasi Persamaan (2.7) dengan batasan yang telah disebutkan tersebut dapat diselesaikan dengan menggunakan primal lagrangian dalam bentuk sebagai berikut.

$$\begin{aligned}
 L = & \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) - \sum_{i=1}^n (\beta_i \xi_i + \beta_i^* \xi_i^*) \\
 & - \sum_{i=1}^n \alpha_i (\varepsilon + \xi_i + y_i - \mathbf{w}^T \varphi(\mathbf{x}_i) - b) \quad (2.8) \\
 & - \sum_{i=1}^n \alpha_i^* (\varepsilon + \xi_i^* + y_i + \mathbf{w}^T \varphi(\mathbf{x}_i) - b)
 \end{aligned}$$

Persamaan (2.8) diminimalkan pada variabel primal w, b, ξ, ξ^* dan dimaksimalkan dalam bentuk *lagrangian multiplier non negative* $\alpha_i, \alpha_i^*, \beta_i, \beta_i^*$ seperti ditampilkan pada persamaan berikut.

$$\frac{\partial L}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^n (\alpha_i^* - \alpha_i) \varphi(\mathbf{x}_i) = 0 \quad (2.9)$$

$$\mathbf{w} = \sum_{i=1}^n (\alpha_i^* - \alpha_i) \varphi(\mathbf{x}_i)$$

$$\frac{\partial L}{\partial b} = \sum_{i=1}^n (\alpha_i^* - \alpha_i) = 0 \quad (2.10)$$

$$\frac{\partial L}{\partial \xi} = C - \beta_i - \alpha_i = 0 \quad (2.11)$$

$$\frac{\partial L}{\partial \xi^*} = C - \beta_i^* - \alpha_i^* = 0 \quad (2.12)$$


Sehingga berdasarkan hasil penurunan tersebut, didapatkan Persamaan (2.9) yang kemudian disubstitusikan terhadap Persamaan (2.4) maka didapatkan model *Support Vector Regression* (SVR) sesuai dengan persamaan berikut.

$$f(\mathbf{x}) = \mathbf{w}^T \varphi(\mathbf{x}) + b = \sum_{i=1}^{nSV} (\alpha_i^* - \alpha_i) \varphi(\mathbf{x}_i)^T \varphi(\mathbf{x}) + b \quad (2.13)$$

Dalam Persamaan (2.13), koefisien Langrange Multiplier α_i dan α_i^* yang merupakan konstanta real positif dapat didapatkan dengan menyelesaikan permasalahan *quadratic programming* (Lahiri & Ghanta, 2006).

Fungsi pemetaan yang memetakan ruang awal kedalam ruang berdimensi tinggi dinyatakan dengan *dot product* dalam Persamaan (2.12) dapat diganti dengan fungsi $K(\mathbf{x}, \mathbf{x}_i)$ sehingga $\varphi(\mathbf{x}_i)^T \varphi(\mathbf{x}) = K(\mathbf{x}, \mathbf{x}_i)$ yang dikenal sebagai fungsi kernel yang dinyatakan dalam Persamaan (2.14) sebagai berikut.

$$f(x) = \sum_{i=1}^{nSV} (\alpha_i - \alpha_i^*) K(\mathbf{x}, \mathbf{x}_i) + b \quad (2.14)$$



Gambar 2.5 Ilustrasi Penggunaan Kernel dalam SVR

Penggunaan kernel dalam model SVR dapat diilustrasikan dalam Gambar 2.5. Selanjutnya, pada penelitian ini digunakan fungsi kernel yang umum digunakan dalam metode SVR adalah *Radial Basis Function* dengan fungsi kernel seperti yang disajikan pada Persamaan (2.15) berikut.

$$K(\mathbf{x}, \mathbf{x}_i) = \exp(-\gamma \|\mathbf{x} - \mathbf{x}_i\|^2), \gamma > 0 \quad (2.15)$$

Penerapan algoritma SVR memerlukan parameter *set up* atau dikenal juga dengan istilah hyperparameter (parameter yang tidak muncul pada Persamaan (2.13)). Dalam kernel RBF, terdapat *hyperparameter* gamma (γ) yang merupakan parameter positif yang mengontrol radius. Adapun matriks kernel RBF dapat dihitung dengan perhitungan sebagai berikut.

- i. Misalkan terdapat data dengan variabel respon (Y) dan variabel prediktor sebanyak p ($X_1, X_2, X_3, \dots, X_p$) sebanyak n observasi.

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ \vdots \\ y_n \end{bmatrix} \text{ dan } X = \begin{bmatrix} x_{1,1} & x_{2,1} & x_{3,1} & \cdots & x_{p,1} \\ x_{1,2} & x_{2,2} & x_{3,2} & \cdots & x_{p,2} \\ x_{1,3} & x_{2,3} & x_{3,3} & \cdots & x_{p,3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_{1,n} & x_{2,n} & x_{3,n} & \cdots & x_{p,n} \end{bmatrix}$$

- ii. Berdasarkan Persamaan (2.14), maka diperlukan vektor \mathbf{x}_i yang merupakan variabel prediktor observasi ke- i . Sedangkan vektor \mathbf{x} merupakan variabel prediktor selain observasi ke- i .

$$\mathbf{x}_i = \begin{bmatrix} x_{1,i} \\ x_{2,i} \\ x_{3,i} \\ \vdots \\ x_{p,i} \end{bmatrix}$$

- iii. Setelah ditentukan parameter γ yang digunakan dan telah diketahui vektor \mathbf{x}_i dan vektor \mathbf{x} , maka fungsi kernel RBF dapat dihitung. Misalkan vektor \mathbf{x}_i merupakan data pada observasi ke-1 dan vektor \mathbf{x} merupakan data pengamatan ke-2. $\|\mathbf{x} - \mathbf{x}_i\|^2$ pada Persamaan (2.14) merupakan normalisasi

yang dapat dihitung dengan kuadrat jarak Euclidean. Berikut merupakan penjabaran perhitungan dari fungsi kernel RBF.

$$K(\mathbf{x}_2, \mathbf{x}_1) = \exp \left(-\gamma \left\| \begin{bmatrix} x_{1,2} \\ x_{2,2} \\ x_{3,2} \\ \vdots \\ x_{p,2} \end{bmatrix} - \begin{bmatrix} x_{1,1} \\ x_{2,1} \\ x_{3,1} \\ \vdots \\ x_{p,1} \end{bmatrix} \right\|^2 \right)$$

$$K(\mathbf{x}_2, \mathbf{x}_1) = \exp \left(-\gamma \times \left\{ (x_{1,2} - x_{1,1})^2 + (x_{2,2} - x_{2,1})^2 + \dots + (x_{p,2} - x_{p,1})^2 \right\} \right)$$

- iv. Setelah dilakukan kombinasi perhitungan fungsi kernel RBF untuk setiap antar observasi, maka matrik kernel atau yang disebut juga *Gram Matrix* bisa didapatkan sebagai berikut.

$$K = \begin{bmatrix} K(\mathbf{x}_1, \mathbf{x}_1) & K(\mathbf{x}_1, \mathbf{x}_2) & K(\mathbf{x}_1, \mathbf{x}_3) & \dots & K(\mathbf{x}_1, \mathbf{x}_n) \\ K(\mathbf{x}_2, \mathbf{x}_1) & K(\mathbf{x}_2, \mathbf{x}_2) & K(\mathbf{x}_2, \mathbf{x}_3) & \dots & K(\mathbf{x}_2, \mathbf{x}_n) \\ K(\mathbf{x}_3, \mathbf{x}_1) & K(\mathbf{x}_3, \mathbf{x}_2) & K(\mathbf{x}_3, \mathbf{x}_3) & \dots & K(\mathbf{x}_3, \mathbf{x}_n) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ K(\mathbf{x}_n, \mathbf{x}_1) & K(\mathbf{x}_n, \mathbf{x}_2) & K(\mathbf{x}_n, \mathbf{x}_3) & \dots & K(\mathbf{x}_n, \mathbf{x}_n) \end{bmatrix}$$

2.5 Evaluasi Kbaikan Model

Penentuan model terbaik pada penelitian ini digunakan *Root Mean Squared Error* (RMSE). RMSE biasanya digunakan untuk regresi dan dalam sejumlah penelitian tentang *statistical downscaling* banyak yang menggunakan RMSE. RMSE digunakan untuk menghitung tingkat *error* sebuah model, atau jika diimplementasikan dalam data mining maka digunakan untuk mengukur tingkat *error* data *testing* berdasarkan hasil pemodelan data *training*. Berikut ini merupakan perhitungan RMSE yang disajikan pada Persamaan (2.16) (Singh & Sihag, 2014).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_{obs.i} - \hat{Y}_{obs.i})^2}{n}} \quad (2.16)$$

dengan melakukan perhitungan sesuai dengan Persamaan 2.16 yaitu dengan menghitung akar kuadrat jumlah selisih curah hujan prediksi model terhadap observasi dibagi sejumlah n periode waktu maka akan didapatkan nilai RMSE dimana semakin kecil nilai tersebut maka model akan semakin baik. Selanjutnya dikarenakan hasil prediksi curah hujan dengan menggunakan metode SVR dapat menghasilkan prediksi yang negatif. Maka diperlukan perhitungan RMSE*. RMSE* dapat dihitung dengan terlebih dahulu melakukan transformasi terhadap hasil prediksi curah hujan yang didapatkan dengan $\widehat{Y}_{obs.i}^* = \max(0, \widehat{Y}_{obs.i})$. Sehingga didapatkan Persamaan (2.17) untuk menghitung nilai RMSE*.

$$RMSE^* = \sqrt{\frac{\sum_{i=1}^n (Y_{obs.i} - \widehat{Y}_{obs.i}^*)^2}{n}} \quad (2.17)$$

Selain menggunakan RMSE, juga bisa digunakan MAPE. MAPE merupakan perhitungan untuk mengetahui akurasi dalam bentuk persentase dengan semakin kecil nilainya maka model semakin baik. Namun perhitungan MAPE tidak dapat digunakan dalam penelitian ini dikarenakan mengandung penyebut curah hujan aktual dimana pada curah hujan di Kota Surabaya terdapat nilai nol.

2.6 Model Matematis Perhitungan Banjir

Penentuan banjir rencana memiliki banyak metode perhitungan, salah satunya adalah dengan melihat hubungan empiris curah hujan-limpasan dengan metode rasional. Metode ini sudah dipakai sejak pertengahan abad 19 dan merupakan metode yang sering dipakai untuk perencanaan banjir daerah perkotaan. Persamaan yang digunakan dalam penentuan banjir dengan metode rasional disajikan pada Persamaan (2.18) sebagai berikut (Kodoatie & Sugiyanto, 2002).

$$Q = 0.278 \times C \times I \times A \quad (2.18)$$

Keterangan:

C = koefisien *run-off*

I = intensitas maksimum selama waktu konsentrasi
(mm/jam)

A = luas daerah aliran (km²)

Q = debit maksimum (m³/detik)

Nilai intensitas curah hujan (*I*) didapat melalui rumus sebagai berikut :

$$I = \left[\frac{R_{24}}{24} \left[\frac{24}{T_c} \right]^{\frac{2}{3}} \right] \quad (2.19)$$

dimana :

R = hujan maksimum (mm)

T_c = waktu konsentrasi (jam)

Untuk memperoleh nilai *t_c* dapat dirumuskan sebagai berikut.

$$t_c = t_0 + t_f \quad (2.20)$$

Keterangan

t₀ : waktu yang dibutuhkan untuk mengalir di permukaan untuk mencapai inlet (*overland flow time, inlet time*)

t_f : waktu yang diperlukan untuk mengalir di sepanjang saluran

Untuk menentukan harga *t₀*, diasumsikan permukaan dengan penutup homogen sehingga untuk perhitungan dapat menggunakan perumusan Kerby.

$$t_0 = 1,44 \left(n_d \cdot \frac{l}{\sqrt{s}} \right)^{0,467} \quad (2.21)$$

Keterangan

l : jarak dari titik terjauh ke inlet (m)

n_d : koefisien setara koefisien kekasaran

s : kemiringan saluran

Selanjutnya banjir genangan dapat dilihat saat $Q_{hidrologi} > Q_{hidrolika}$ maka akan didapatkan air hujan tidak dapat ditampung baik oleh saluran air atau sungai sehingga menyebabkan adanya luapan air. Agar mendapat desain yang ekonomis maka seharusnya $Q_{hidrologi} \approx Q_{hidrolika}$. $Q_{hidrolika}$ dapat dirumuskan sesuai dengan Persamaan (2.22) sebagai berikut.

$$Q_{hidrolika} = V_{(m/detik)} \times A_{(m^2)} = \frac{1}{n} \times R^{2/3} \times S^{1/2} \times A \quad (2.22)$$

dimana A merupakan luas penampang sungai yang diperoleh dari

$$A_{(m^2)} = b_{(m)} \times h_{(m)} \quad (2.23)$$

Keterangan

$b_{(m)}$: lebar sungai

$h_{(m)}$: tinggi sungai

$b_{(m)}$ diperoleh dari rata-rata lebar sungai minimum & maksimum yang diperoleh data Dinas Pekerjaan Umum, Bina Marga & Pematuan. Sedangkan untuk $h_{(m)}$ dari tabel u-ditch tergantung nilai $b_{(m)}$ -nya. Untuk memudahkan dalam analisis, maka dapat diketahui $h_{(m)}$ suatu saluran adalah sama dengan $b_{(m)}$ jika $b_{(m)}$

lebih besar sama dengan 12. Jika $b_{(m)} < 12$ maka $h_{(m)} = b_{(m)} \times \frac{10}{6}$.

Hal ini dikarenakan, keseluruhan saluran di Kota Surabaya menggunakan *u-ditch* atau saluran *rectangle*. Berikut beberapa bentuk saluran yang sering digunakan. Kecepatan saluran dapat dihitung dengan menggunakan Rumus Manning pada Persamaan (2.24) berikut.

$$V_{(m/detik)} = \frac{1}{n} R^{2/3} S^{1/2} \quad (2.24)$$

Keterangan

n : koefisien kekerasan saluran

R : jari-jari hidrolis

S : kemiringan salur

Selanjutnya untuk jari-jari hidrolis dapat dirumuskan sesuai dengan Persamaan (2.25) berikut.

$$R_{(m)} = \frac{A_{(m^2)}}{P_{(m)}} \quad (2.25)$$

dimana $P_{(m)}$ atau penampang yang terkena air dapat dirumuskan sesuai dengan Persamaan (2.26) berikut.

$$P_{(m)} = b_{(m)} + 2.h_{(m)} \quad (2.26)$$

Untuk menentukan kecepatan aliran di saluran tergantung material saluran yang digunakan. Semakin halus permukaan saluran maka kecepatan semakin besar. Saluran juga harus dapat menahan kecepatan agar tidak tergerus aliran. Kekasaran juga merupakan hambatan pada aliran, berikut tabel koefisien kekasaran saluran yang sering digunakan.

Tabel 2. 1 Tabel Kekasaran Manning untuk Saluran

Saluran	Keterangan	n Manning
Tanah	Lurus, baru, seragam, landai & bersih	0,016-0,033
	Berkelok, landai & berumput	0,023-0,040
	Tidak terawat & kotor	0,050-0,140
	Tanah berbatu, kasar & tidak teratur	0,035-0,045
Pasangan	Batu kosong	0,023-0,035
	Pasangan batu belah	0,017-0,030
Beton	Halus, sambungan baik dan rata	0,014-0,018
	Kurang halus dan sambungan kurang rata	0,018-0,030

Asumsi-asumsi metode rasional diantaranya adalah, sebagai berikut :

- Curah hujan mempunyai intensitas yang merata di seluruh daerah aliran untuk durasi tertentu
- Debit yang terjadi (debit puncak) bukan hasil dari intensitas hujan yang lebih tinggi dengan durasi yang lebih pendek dimana hal ini berlangsung hanya pada sebagian DPS yang berkontribusi debit puncak tersebut

- c. Lama curah hujan sama dengan waktu konsentrasi dari daerah aliran, dengan kata lain waktu konsentrasi merupakan waktu terjadinya *runoff* dan mengalir dari jarak antara titik terjauh dari DPS ke titik *inflow* yang ditinjau
- d. Puncak banjir dan intensitas curah hujan mempunyai tahun berulang yang sama.

2.7 Curah Hujan & Banjir

Curah hujan merupakan salah satu bentuk endapan (presipitasi) yang didefinisikan sebagai bentuk air cair dan padat (es) yang jatuh ke permukaan bumi. Jumlah curah hujan dicatat dalam inci atau millimeter (1 inci = 25.4 mm). Jumlah curah hujan 1 mm, menunjukkan tinggi air hujan yang menutupi permukaan 1 mm, jika air tersebut tidak meresap ke dalam tanah atau menguap ke atmosfer (Tjasjono, 1999). Menurut Sosrodarsono & Takeda (2003), curah hujan yang diperlukan untuk pembuatan rancangan dan rencana yang berdasarkan volume debit (yang disebabkan oleh curah hujan) dari daerah pengaliran yang kecil seperti perhitungan debit banjir adalah curah hujan jangka waktu yang pendek dan bukan curah hujan jangka waktu yang panjang seperti curah hujan tahunan atau bulanan.

Banjir merupakan suatu peristiwa meluapnya air dari batas tebing sungai dalam jangka waktu relatif pendek atau suatu peristiwa menggenangnya air di permukaan tanah sampai melebihi batas waktu tertentu yang mengakibatkan kerugian (Sandhyavitri, et al., 2015). Menurut Suripin (2004) dalam Sandhyavitri, et al. (2015), penyebab banjir dapat dibedakan menjadi 3 (tiga) macam, yaitu:

1. Banjir kiriman

Aliran banjir yang datang dari daerah hulu di luar kawasan yang tergenang. Hal ini terjadi jika hujan yang terjadi di daerah hulu menimbulkan aliran banjir yang melebihi kapasitas sungainya atau banjir kanal yang ada, sehingga mengakibatkan terjadinya limpasan.

2. Banjir lokal (banjir genangan)

Genangan air yang timbul akibat hujan yang jatuh di daerah itu sendiri. Hal ini dapat terjadi kalau hujan yang terjadi melebihi kapasitas sistem drainase yang ada. Pada banjir lokal, ketinggian genangan air antara 0.2 – 0.7 m dan lama genangan 1 – 8 jam. Banjir ini terdapat pada daerah yang rendah.

3. Banjir rob (banjir air pasang)

Banjir yang terjadi baik akibat aliran langsung air pasang dan/ atau air balik dari saluran drainase akibat terhambat oleh air pasang.

Peramalan banjir memiliki dua fase utama, yaitu yang berkaitan dengan peramalan jumlah curah hujan atau pencairan salju yang akan tersedia untuk mengalir dan yang lain berusaha untuk memprediksi laju aliran dalam kaitannya dengan kapasitas aliran (Critchfield, 1990). Kejadian banjir yang akan dibahas dalam penelitian ini merupakan banjir lokal/banjir genangan di Kota Surabaya sehingga akan dilakukan peramalan banjir tersebut berdasarkan curah hujan dan kapasitas sistem drainase yang ada.

BAB III

METODOLOGI PENELITIAN

3.1 Sumber Data


Data yang digunakan dalam penelitian ini merupakan data sekunder yang merupakan data curah hujan harian di 6 pos hujan dan data saluran air di Kota Surabaya. Data tersebut diperoleh dari Dinas Pekerjaan Umum, Bina Marga, dan Pematuan Kota Surabaya. Selain itu, juga digunakan data *output General Circulation Model* (GCM) dimana menurut Kaimuddin (2000) dalam Sutikno (2008) menyimpulkan bahwa model CSIRO-9 dan GFDL mempunyai kinerja yang baik untuk digunakan sebagai penilai dampak di Indonesia. Sehingga dalam penelitian ini akan digunakan data *output* GCM yaitu model CSIRO-Mk3.6.0 yang dapat diunduh di *website* <https://cera-www.dkrz.de/WDCC/ui/ceraresearch/>.

Model CSIRO-Mk3.6.0 dikelola oleh *Commonwealth Scientific and Industrial Research Organisation in collaboration with Queensland Climate Change Centre of Excellence* (CSIRO-QCCCE) dengan resolusi grid $1.865^0 \times 1.875^0$ (1^0 setara dengan 111.322 km) dan skenario yang digunakan RCP4.5. Data *output* GCM yang digunakan merupakan data yang mewakili Kota Surabaya dengan koordinat *latitude* dan *longitude* yaitu -7.24917, 112.75083. Luasan (jumlah grid) yang digunakan dalam penelitian ini merupakan 1 grid dan 9 grid (3x3 *latitude-longitude*) di sekitar lokasi curah hujan yang dapat dilihat pada Tabel 3.1.

Tabel 3. 1 Penentuan Lokasi di Kota Surabaya pada Data *Output* GCM CSIRO Mk3.6.0

<i>Latitude</i>	<i>Longitude</i>	3x3	1x1	3x3
		110.625	112.5	114.375
3x3	-8.3936			
1x1	-6.5284		SURABAYA	
3x3	-4.6631			

Berdasarkan Tabel 3.1, maka dapat diperoleh visualisasi pengambilan ukuran grid data *output* GCM pada peta sebagai berikut.



Gambar 3.1 Visualisasi Pengambilan Ukuran Grid

Gambar 3.1 menjelaskan bahwa lokasi curah hujan di Kota Surabaya terletak pada grid ke-5 dan dikelilingi oleh 8 grid lainnya.

3.2 Variabel Penelitian

Variabel penelitian yang digunakan dalam penelitian ini sejumlah 5 variabel yaitu variabel curah hujan dan 4 variabel prediktor yang diambil dari data *output* GCM yang secara lengkap disajikan pada Tabel 3.2 sebagai berikut.

Tabel 3.2 Variabel Penelitian

Variabel	Simbol	Kode	Keterangan	Satuan
Curah Hujan	Y_b	CH	Curah Hujan Harian	mm
	X_1	PR	Presipitasi (<i>Precipitation</i>)	Kg/m ² s
Data <i>Output</i> GCM	X_2	TAS	Temperatur (<i>Near Surface Air Temperature</i>)	K
	X_3	HUSS	Kelembapan Udara (<i>Near Surface Specific Humidity</i>)	Kg/kg
	X_4	SFC WIND	Kecepatan Angin (<i>Daily-Mean Near Surface Wind Speed</i>)	m/s

Pada penelitian ini terdapat 4 variabel prediktor pada data GCM yang diduga mempengaruhi curah hujan seperti yang

dijelaskan pada Tabel 3.2. Berikut ini merupakan penjelasan variabel-variabel tersebut dalam data GCM CSIRO Mk3.6.0.


- a. Presipitasi (X_1) diberi kode PR merupakan turunnya air dari atmosfer ke permukaan bumi dan laut bisa dalam bentuk curah hujan atau salju.
- b. Temperatur (X_2) diberi kode TAS yang secara lengkap dituliskan *Near Surface Air Temperature* pada data GCM merupakan temperatur udara diukur didekat permukaan bumi dan laut.
- c. Kelembapan Udara (X_3) diberi kode HUSS yang secara lengkap dituliskan *Near Surface Specific Humidity* pada data GCM merupakan kelembapan spesifik, yaitu banyaknya uap air yang terkandung dalam 1 kilogram udara dan diukur didekat permukaan bumi dan laut.
- d. Kecepatan Angin (X_4) diberi kode SFCWIND yang secara lengkap dituliskan *Daily Mean Near Surface Wind Speed* pada data GCM merupakan rata-rata kecepatan angin yang diukur didekat permukaan bumi dan laut.

Selanjutnya, dalam penelitian ini variabel respon data curah hujan yang digunakan berada pada 6 pos hujan yang tersebar di Kota Surabaya, dengan keterangan sebagai berikut.

Tabel 3.3 Pos Hujan di Kota Surabaya

Variabel	Simbol	Kode	Keterangan
Curah Hujan	Y_1	CH_Keputih	Curah Hujan Harian di Pos Hujan Keputih
	Y_2	CH_KdCowek	Curah Hujan Harian di Pos Hujan Kedung Cowek
	Y_3	CH_Gubeng	Curah Hujan Harian di Pos Hujan Gubeng
	Y_4	CH_Wonorejo	Curah Hujan Harian di Pos Hujan Wonorejo
	Y_5	CH_Wonokromo	Curah Hujan Harian di Pos Hujan Wonokromo
	Y_6	CH_GnSari	Curah Hujan Harian di Pos Hujan Gunung Sari

Berikut merupakan peta lokasi setiap pos hujan di Kota Surabaya yang disesuaikan dengan peta saluran air sungai berdasarkan rayon dari Dinas Pekerjaan Umum, Bina Marga, dan Pematusan Kota Surabaya.



Gambar 3.2 Peta Lokasi Pos Hujan terhadap Peta Saluran Air Sungai berdasarkan Rayon di Kota Surabaya

Sehingga struktur data yang digunakan untuk analisis setiap pos hujan dalam penelitian ini disajikan pada Tabel 3.4 dan Tabel 3.5 sebagai berikut.

Tabel 3.4 Struktur Data Curah Hujan pada Setiap dengan Data Output GCM pada Grid 1x1

Tanggal	Curah Hujan		Output GCM		
	$Y_{b,t}$	$X_{1t,5}$	$X_{25,t}$	$X_{35,t}$	$X_{45,t}$
<i>Data Training</i>					
01/01/2009	$Y_{b,1}$	$X_{15,1}$	$X_{25,1}$	$X_{35,1}$	$X_{45,1}$
⋮	⋮	⋮	⋮	⋮	⋮
11/30/2018	$Y_{b,3621}$	$X_{15,3621}$	$X_{25,3620}$	$X_{35,3621}$	$X_{45,3621}$
<i>Data Testing</i>					
12/01/2018	$Y_{b,3622}$	$X_{15,3622}$	$X_{25,3622}$	$X_{35,3622}$	$X_{45,3622}$
⋮	⋮	⋮	⋮	⋮	⋮
12/31/2018	$Y_{b,3652}$	$X_{15,3652}$	$X_{25,3652}$	$X_{35,3652}$	$X_{45,3652}$

Tabel 3.4 Struktur Data Curah Hujan pada Setiap dengan
Data *Output* GCM pada Grid 3x3

Tanggal	Curah Hujan Y_{bt}	<i>Output</i> GCM											
		PR			TAS			HUSS			SFCWIND		
		$X_{11,t}$...	$X_{19,t}$	$X_{21,t}$...	$X_{29,t}$	$X_{31,t}$...	$X_{39,t}$	$X_{41,t}$...	$X_{49,t}$
<i>Data Training</i>													
01/01/2009	$Y_{b,1}$	$X_{11,1}$...	$X_{19,1}$	$X_{21,1}$...	$X_{29,1}$	$X_{31,1}$...	$X_{39,1}$	$X_{41,1}$...	$X_{49,1}$
01/02/2009	$Y_{b,2}$	$X_{11,2}$...	$X_{19,2}$	$X_{21,2}$...	$X_{29,2}$	$X_{31,2}$...	$X_{39,2}$	$X_{41,2}$...	$X_{49,2}$
⋮	⋮	⋮	...	⋮	⋮	...	⋮	⋮	...	⋮	⋮	...	⋮
11/29/2018	$Y_{b,3620}$	$X_{11,3620}$...	$X_{19,3620}$	$X_{21,3620}$...	$X_{29,3620}$	$X_{31,3620}$...	$X_{39,3620}$	$X_{41,3620}$...	$X_{49,3620}$
11/30/2018	$Y_{b,3621}$	$X_{11,3621}$...	$X_{19,3621}$	$X_{21,3621}$...	$X_{29,3621}$	$X_{31,3621}$...	$X_{39,3621}$	$X_{41,3621}$...	$X_{49,3621}$
<i>Data Testing</i>													
12/01/2018	$Y_{b,3622}$	$X_{11,3622}$...	$X_{19,3622}$	$X_{21,3622}$...	$X_{29,3622}$	$X_{31,3622}$...	$X_{39,3622}$	$X_{41,3622}$...	$X_{49,3622}$
12/02/2018	$Y_{b,3623}$	$X_{11,3623}$...	$X_{19,3623}$	$X_{21,3623}$...	$X_{29,3623}$	$X_{31,3623}$...	$X_{39,3623}$	$X_{41,3623}$...	$X_{49,3623}$
⋮	⋮	⋮	...	⋮	⋮	...	⋮	⋮	...	⋮	⋮	...	⋮
12/30/2018	$Y_{b,3651}$	$X_{11,3651}$...	$X_{19,3651}$	$X_{21,3651}$...	$X_{29,3651}$	$X_{31,3651}$...	$X_{39,3651}$	$X_{41,3651}$...	$X_{49,3651}$
12/31/2018	$Y_{b,3652}$	$X_{11,3652}$...	$X_{19,3652}$	$X_{21,3652}$...	$X_{29,3652}$	$X_{31,3652}$...	$X_{39,3652}$	$X_{41,3652}$...	$X_{49,3652}$

3.3 Langkah Analisis


Langkah-langkah analisis yang digunakan untuk mencapai tujuan dari penelitian ini adalah sebagai berikut.

1. Mengidentifikasi karakteristik data curah hujan harian pada setiap pos hujan di Kota Surabaya.
2. Melakukan *statistical downscaling output General Circulation Model* (GCM) terhadap curah hujan harian pada setiap pos hujan di Kota Surabaya dengan langkah-langkah sebagai berikut.
 - a. *Pre-processing data* curah hujan harian pada setiap pos hujan di Kota Surabaya yaitu dengan mendeteksi adanya *missing value*. Apabila terdapat *missing value* maka diatasi dengan melakukan imputasi.
 - b. *Pre-processing data output* GCM.
 - i. Mengkonversikan format data *output* GCM dari netCDF ke format CSV yang bertujuan untuk menguraikan data agar mudah dalam pengolahan data dengan menggunakan software Panoply.
 - ii. Melakukan *cropping* grid variabel prediktor pada data GCM yang digunakan yang disesuaikan dengan lokasi pengamatan curah hujan harian yang di Kota Surabaya. Luasan grid yang digunakan adalah bujursangkar berukuran 1x1 dan 3x3 sekaligus pengambilan data dari tanggal 1 Januari 2009 s.d 31 Desember 2018.
 - iii. Mendeteksi adanya *missing value* pada data *output* GCM. Apabila terdapat *missing value* maka diatasi dengan melakukan imputasi.
 - c. Membagi data *output* GCM dan curah hujan harian di Kota Surabaya ke dalam data *training* dan *testing* untuk validasi model.
 - d. Melakukan pemodelan regresi dengan menggunakan *Support Vector Regression* dan melakukan optimasi parameter pada model yang terbentuk, yaitu

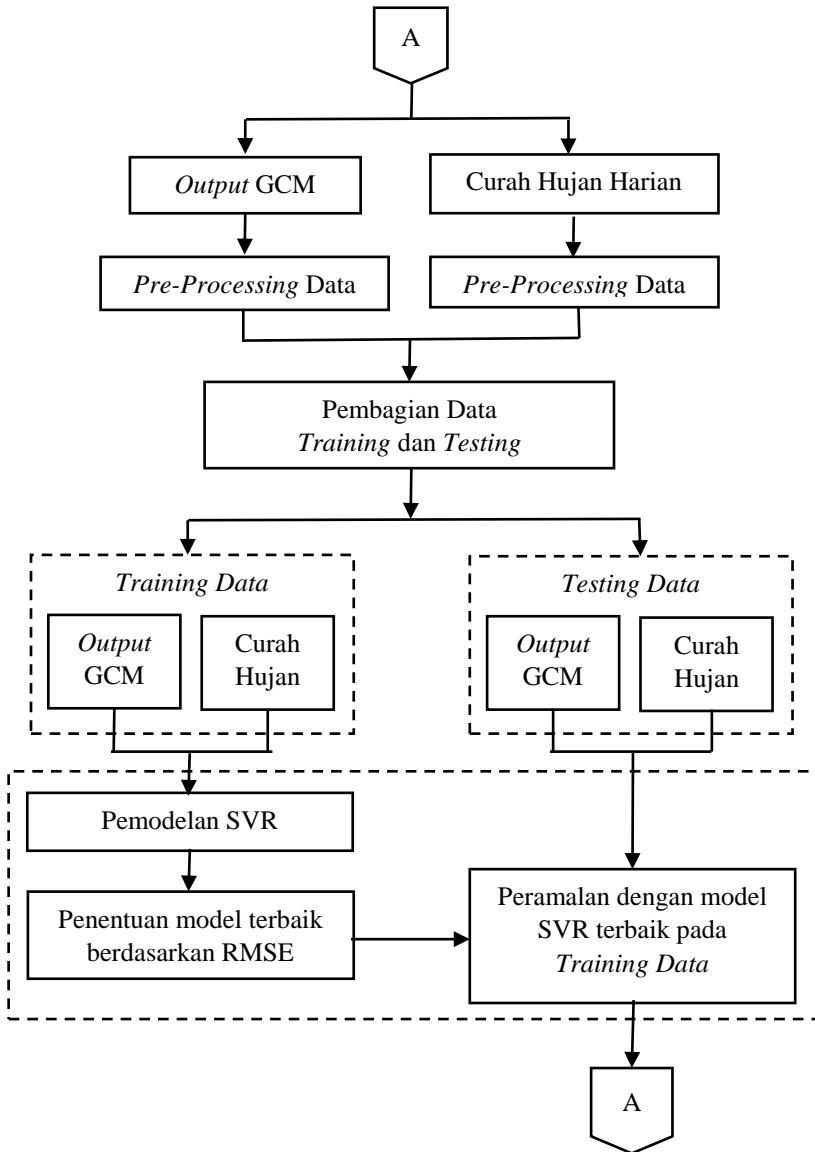
parameter *epsilon* dan *cost* serta parameter *gamma* pada kernel *Radial Basis Function* (RBF) yang digunakan. Model yang akan dicobakan pada setiap pos hujan dengan metode SVR antara lain, sebagai berikut.

- i. Pemodelan curah hujan harian sederhana dan penambahan variabel *dummy* terhadap variabel prediktor *output* GCM pada grid berukuran 1x1, 3x3, dan 3x3 dengan PCA.
 - ii. Pemodelan curah hujan harian dengan penambahan lag yang diduga terhadap variabel prediktor *output* GCM pada grid berukuran 1x1, 3x3, dan 3x3 dengan PCA.
 - iii. Pemodelan curah hujan harian tanpa mempertimbangkan observasi bernilai nol terhadap variabel prediktor *output* GCM pada grid berukuran 1x1, 3x3, dan 3x3 dengan PCA.
- e. Menganalisis kebaikan antar model yang telah terbentuk pada langkah sebelumnya dengan membandingkan nilai RMSE dan RMSE* data *testing* dan juga pola hasil prediksi yang terbentuk tidak konstan.
3. Melakukan prediksi banjir berdasarkan prediksi curah hujan harian sesuai dengan Persamaan (2.18) dan Persamaan (2.22).


Berdasarkan langkah analisis yang telah dijelaskan maka secara umum dapat digambarkan dalam diagram alir pada Gambar 3.1 sebagai berikut.



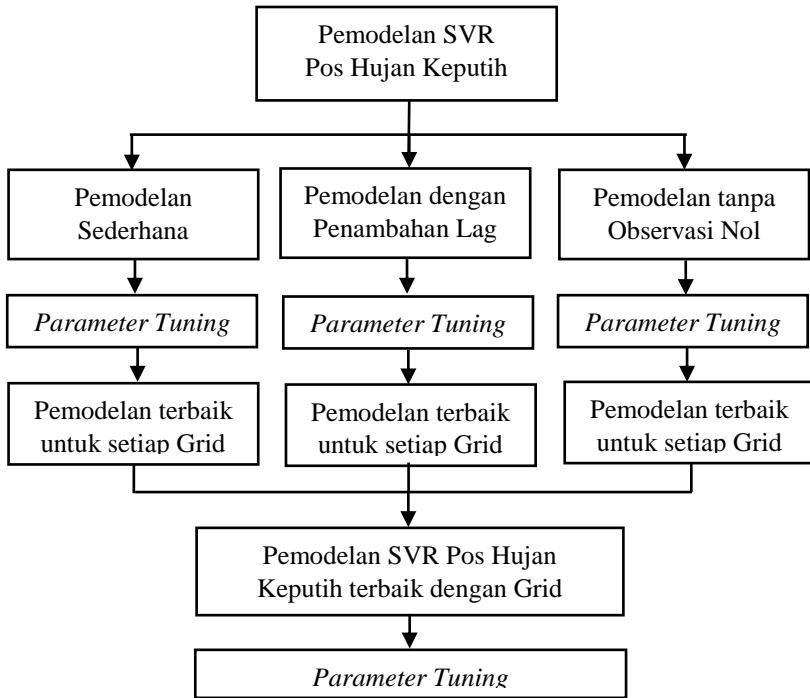
Gambar 3.3 Diagram Alir



Gambar 3.3 Diagram Alir (Lanjutan)



Gambar 3.3 Diagram Alir (Lanjutan)



Gambar 3.4 Penjelasan Pemodelan SVR

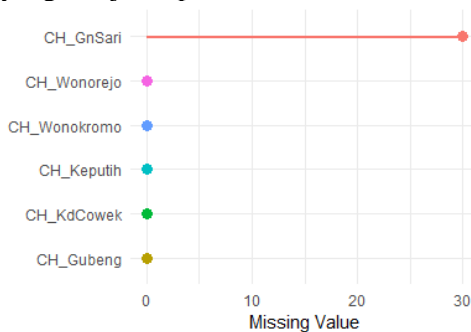
BAB IV

ANALISIS DAN PEMBAHASAN

Sesuai dengan tujuan yang ingin dicapai pada penelitian ini, maka terdapat beberapa tahapan analisis yang akan dilakukan, yaitu sebanyak 3 pokok bahasan. Pokok bahasan pertama yaitu menganalisis karakteristik data dengan sebelumnya melakukan tahapan *pre-processing*, lalu melakukan prediksi curah hujan harian, dan yang terakhir melakukan prediksi banjir genangan di Kota Surabaya.

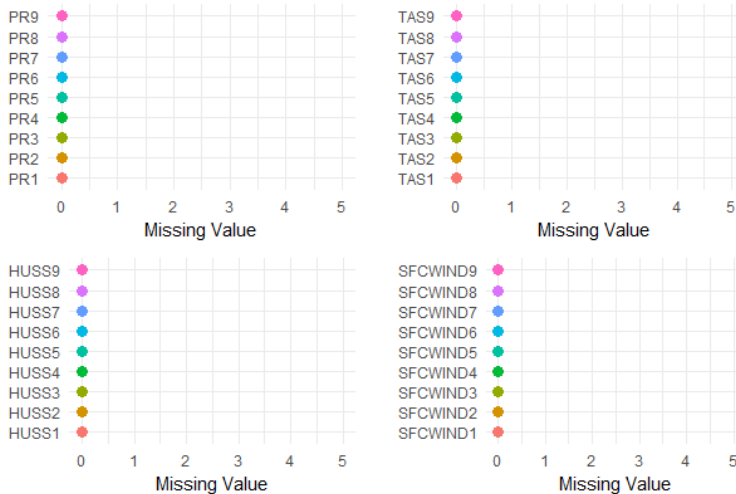
4.1 Karakteristik Data

Curah hujan yang lebat atau yang bisa disebut tinggi berpotensi dapat mengakibatkan banjir khususnya pada daerah perkotaan dengan kemampuan perembesan tanah yang buruk, seperti halnya di Kota Surabaya. Oleh sebab itu, maka perlu adanya prediksi curah hujan harian di Kota Surabaya sebagai antisipasi terjadinya banjir. Sebelum melakukan prediksi curah hujan, maka dilakukan terlebih dahulu analisis karakteristik data. Tahapan pertama yang dilakukan setelah didapatkan penggabungan data curah hujan dan data hasil *cropping output General Circulation Model (GCM)* yang telah disesuaikan yaitu pada rentang waktu 1 Januari 2009 s.d 31 Desember 2018, maka terlebih dahulu dilakukan tahapan *pre-processing data* yaitu identifikasi *missing value* seperti yang disajikan pada Gambar 4.1 berikut.



Gambar 4. 1 *Missing Value* pada Variabel Respon

Gambar 4.1 menunjukkan bahwa terdapat *missing value* pada variabel respon data curah hujan di Gunung Sari sebanyak 30 data dan 0 data pada 5 curah hujan yang lain. Berdasarkan identifikasi lebih lanjut, diperoleh informasi bahwa 30 data *missing value* tersebut merupakan data curah hujan pada 30 hari selama bulan November 2015. Sehingga perlu dilakukan imputasi pada data tersebut. Terdapat beberapa macam pendekatan untuk imputasi, salah satunya adalah *mean imputation*, yaitu *missing value* diganti dengan rata-rata (*mean*) dari kelompok sampel unit terkait. Dalam penelitian ini, 30 data *missing value* curah hujan di Gunung Sari pada bulan November 2015 diganti dengan rata-rata (*mean*) curah hujan bulan November pada hari yang sama pada setiap *missing value*.



Gambar 4. 2 *Missing Value* pada Variabel Prediktor

Berbeda halnya dengan variabel respon data curah hujan, pada variabel prediktor data *output* GCM tidak terdapat data *missing value*. Sehingga setelah keseluruhan data sudah tidak ditemukan adanya *missing value*, maka dapat dilakukan analisis lebih lanjut.

Selanjutnya, dilakukan analisis karakteristik curah hujan yang ada di Kota Surabaya yang diwakili oleh 6 pos hujan, yaitu di wilayah Keputih, Kedung Cowek, Gubeng, Wonorejo, Wonokromo, dan Gunung Sari dengan karakteristik seperti yang disajikan pada Tabel 4.1 berikut.

Tabel 4. 1 Karakteristik Data Curah Hujan

	Min	Max	Median	Mean	Var	Std.Dev
Y_1	0	164	0	5.513	174.097	13.195
Y_2	0	123	0	5.132	129.972	11.401
Y_3	0	116	0	6.487	196.247	14.009
Y_4	0	122	0	5.860	189.957	13.782
Y_5	0	114	0	6.419	198.935	14.104
Y_6	0	120	0	6.361	197.468	14.052

Berdasarkan Tabel 4.1 dapat diperoleh informasi bahwa curah hujan minimum di Kota Surabaya adalah nol di setiap pos hujan, yang artinya dalam setiap harinya pernah tidak ada curah hujan sama sekali. Sedangkan untuk curah hujan maksimum di Kota Surabaya yaitu sebesar 164 mm/hari yang terletak di Pos Hujan Keputih (Y_1) tepatnya pada tanggal 30 Mei 2016. Hal ini diikuti dengan curah hujan yang tinggi juga di wilayah lain selain di Gunung Sari (Y_6) yaitu di Kedung Cowek (Y_2) sebesar 103 mm/hari, Gubeng (Y_3) sebesar 98 mm/hari, Wonorejo (Y_4) sebesar 120 mm/hari, dan Wonokromo (Y_5) sebesar 108 mm/hari. Curah hujan yang terjadi pada bulan Mei 2016 tersebut menyebabkan Kepala Bidang Pengendalian Banjir Dinas PU Surabaya salah prediksi akan adanya potensi banjir dikarenakan bulan Mei berada di musim kemarau (suarasurabaya.net). Curah hujan yang tinggi tersebut menyebabkan Kota Surabaya mengalami banjir genangan yang cukup lama dan menggenangi beberapa jalan, kampus, mall, bahkan genangan air masuk ke ruang rawat inap RSUD dr. Soetomo Surabaya. Selain itu, seperti dilansir oleh SURYA.co.id bahwa curah hujan yang tinggi tersebut masih menyebabkan adanya banjir genangan di Kampus ITS bahkan sampai betis peserta SBMPTN pada tanggal 31 Mei 2016 yang bertepatan dengan diadakannya tes SBMPTN. Hal ini diduga karena terkena

limpasan air dari daerah barat yang menuju ke laut, mengingat bahwa lokasi ITS yang berada di daerah timur dan dekat dengan laut. Selanjutnya curah hujan maksimum terjadi di Pos Hujan Kedung Cowek (Y_2), yaitu sebesar 123 mm/hari terjadi pada tanggal 3 Desember 2010 diikuti dengan curah hujan yang tinggi juga di wilayah Keputih sebesar 90 mm/hari, dan wilayah Gubeng, Wonorejo, Wonokromo, dan Gunung sari berturut sebesar 106, 98, 110, 92 mm/hari menyebabkan banjir genangan, dikutip dari news.okezone.com ratusan rumah di Kota Surabaya terendam banjir bahkan sampai masuk ke dalam sekolah. Sedangkan untuk curah hujan maksimum di keempat pos hujan lainnya terjadi pada tanggal 24 November 2017 yang juga menyebabkan banjir di beberapa wilayah dan menyebabkan kemacetan dan banyak kendaraan roda dua yang mogok karena genangan air mencapai lutut orang dewasa.

Tabel 4.1 juga menunjukkan rata-rata curah hujan pada setiap pos hujan yang mana memiliki rata-rata yang hampir sama berkisar 5-7 mm/hari. dengan rata-rata curah hujan terendah yaitu Pos Hujan Kedung Cowek sebesar 5.132 mm/hari dan rata-rata curah hujan tertinggi sebesar 6.487 mm/hari yang berada di Pos Hujan Gubeng. Sedangkan untuk keragaman curah hujan harian pada setiap pos hujan di Kota Surabaya memiliki varians yang cukup besar dan hampir sama, yang artinya bahwa setiap pos hujan memiliki keragaman curah hujan harian yang cukup tinggi dan sama antar pos hujan. Hal ini juga dapat dilihat dari standar deviasi cukup besar pada setiap pos hujan yang menunjukkan bahwa curah hujan di 6 wilayah mengalami kenaikan dan penurunan yang signifikan.

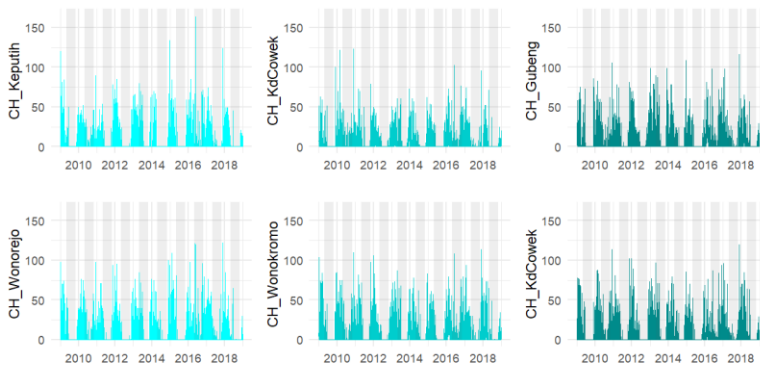
Selanjutnya, akan dilihat plot curah hujan harian pada setiap pos hujan di Kota Surabaya berdasarkan waktu yang disajikan pada Gambar 4.3 berikut.



Gambar 4.3 Time Series Plot Variabel Respon

Indonesia memiliki iklim monsun, hal ini dikarenakan wilayah Indonesia dilalui angin monsun yang umumnya berganti setiap setengah tahun sehingga menimbulkan adanya musim hujan dan kemarau. Berdasarkan Gambar 4.3 dapat diperoleh informasi bahwa secara keseluruhan curah hujan di 6 pos hujan di Kota Surabaya memiliki pola curah hujan yang fluktuatif naik turun dalam setiap harinya, terlebih jika diidentifikasi lebih lanjut pada hari di bulan-bulan terdapat pola musiman, yaitu curah hujan harian cenderung tinggi pada bulan November s.d April begitu juga sebaliknya curah hujan harian pada bulan Mei s.d Oktober cenderung rendah bahkan banyak yang nol mm. Hal ini sesuai dengan yang diutarakan oleh Caraka & Tahmid (2019) menyatakan bahwa cir-ciri pola monsun yaitu curah hujan mempunyai perbedaan antara periode musim hujan dan periode musim kemarau. Sehingga dapat dikatakan bahwa pada periode musim hujan, curah hujan cenderung tinggi sedangkan pada periode musim kemarau, curah hujan cenderung rendah atau bahkan berada disekitar angka nol.

Secara lebih jelas, curah hujan harian yang memiliki pola musiman dan berulang dalam setiap tahunnya tersebut dapat dijelaskan dengan menggunakan *boxplot* curah hujan harian dalam bulanan yang disajikan pada Gambar 4.4 berikut.



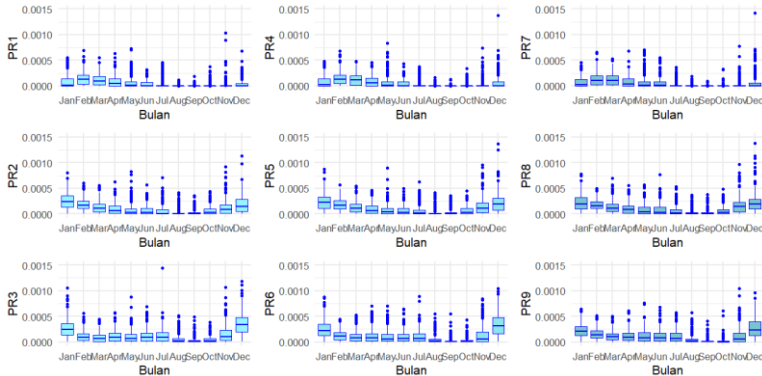
Gambar 4.4 *Boxplot* Bulanan Variabel Respon

Berdasarkan Gambar 4.4 diperoleh informasi bahwa, rata-rata curah hujan tinggi berada pada bulan Februari dan Desember. Hal tersebut sesuai dengan *time series plot* curah hujan pada Gambar 4.3, Gambar 4.4 menunjukkan secara jelas bahwa curah hujan pada bulan Mei, Juni, Juli, Agustus, September, dan Oktober cenderung lebih rendah dibandingkan bulan-bulan lainnya. Namun jika dilihat lebih detail, terdapat data *outlier* pada bulan-bulan tersebut yang menunjukkan masih terjadi hujan di bulan tersebut.

Setelah mengetahui karakteristik curah hujan harian di Kota Surabaya yang merupakan variabel respon, juga perlu mengetahui karakteristik variabel prediktornya yang merupakan *output* data *General Circulation Model* (GCM) yang mana dalam penelitian ini digunakan CSIRO Mk3.6.0. Dalam penelitian ini digunakan 4 variabel prediktor yang diduga dapat memprediksi curah hujan, yaitu Presipitasi (X_1), Temperatur (X_2), Kelembapan Udara (X_3), dan Kecepatan Angin (X_4).


Presipitasi pada *output* GCM menunjukkan dua hal, yaitu curah hujan dan turunnya salju. Sehingga di Indonesia bisa disebut juga curah hujan karena turun menuju ke permukaan bumi dalam bentuk cair. Berdasarkan Gambar 4.5 dapat diperoleh informasi bahwa presipitasi memiliki pola yang hampir sama dengan pola curah hujan di Kota Surabaya, khususnya pada grid 5 yang terletak di area Kota Surabaya dan pada grid 1, 2, 4, 7, dan 8. Hal ini

berbeda dengan yang ada pada grid 3, 6, dan 9 yang hampir mengalami curah hujan yang merata pada setiap bulannya dikarenakan berada di dekat laut.



Gambar 4. 5 Boxplot Bulanan Variabel Presipitasi


Selanjutnya, variabel prediktor lain yang juga diduga dapat digunakan untuk memprediksi curah hujan adalah temperatur. Temperatur pada data *output* GCM ini merupakan temperatur udara di permukaan. Apabila temperatur di daratan lebih rendah dibandingkan di perairan maka hujan akan lebih sering turun di daratan begitu juga sebaliknya.



Gambar 4. 6 Boxplot Bulanan Variabel Temperatur

Pada Gambar 4.6 ditunjukkan bahwa temperatur memiliki pola naik turun yang fluktuatif dalam setiap bulannya. Hal tersebut sesuai dengan pola curah hujan yang juga fluktuatif, namun apabila diidentifikasi lebih lanjut temperatur dengan rata-rata paling tinggi berada pada awal musim kemarau yaitu pada bulan Mei kemudian berangsur turun hingga naik lagi di akhir musim kemarau pada bulan Oktober sampai awal musim penghujan pada bulan November. Selain itu, juga terlihat bahwa pada grid 1, 4, dan 7 memiliki keragaman yang lebih besar dibandingkan pada grid lainnya. Hal ini diduga dikarenakan lokasi pada grid 1, 4, dan 7 yang terletak di perairan Indonesia.

Variabel prediktor berikutnya yang diduga mempengaruhi kejadian curah hujan adalah variabel kelembapan udara. Variabel tersebut memuat jumlah uap air yang terkandung di udara tergantung pada temperatur udara.

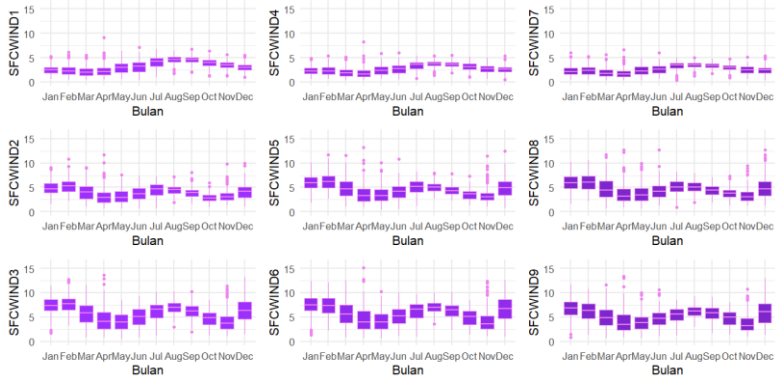


Gambar 4. 7 Boxplot Bulanan Variabel Kelembapan Udara

Berdasarkan Gambar 4.7, dapat diperoleh informasi bahwa rata-rata kelembapan udara pada setiap grid adalah sama berada pada 0.02 dan yang berbeda adalah pada grid 1, 2, 4, 5, 7, dan 8 yang memiliki pola kelembapan udara yang sedikit fluktuatif dan memiliki keragaman yang lebih besar dibandingkan pada grid 3, 6, dan 9. Jika dilihat lebih lanjut, terlebih pada grid 5 tepatnya dimana Kota Surabaya berada, kelembapan udara dengan rata-rata paling tinggi berada pada bulan November yang merupakan musim hujan,

namun pada bulan sebelumnya juga memiliki rata-rata kelembapan udara yang cukup tinggi.

Selain tiga variabel prediktor yang telah disebutkan diatas, juga terdapat variabel kecepatan angin yang diduga dapat memprediksi curah hujan. Pola bulanan kecepatan angin dapat disajikan pada Gambar 4.8 berikut.



Gambar 4. 8 *Boxplot* Bulanan Variabel Kecepatan Angin

Pada Gambar 4.8 dapat ditunjukkan bahwa pola kecepatan angin yang fluktuatif naik turun. Rata-rata kecepatan angin tertinggi dapat ditunjukkan pada grid 3, 6, dan 9 dengan keragaman yang tinggi juga lalu disusul oleh grid 2, 5, dan 8 kemudian yang terakhir yaitu grid 1, 4, dan 7 yang memiliki rata-rata kecepatan angin paling rendah serta keragaman yang paling kecil.

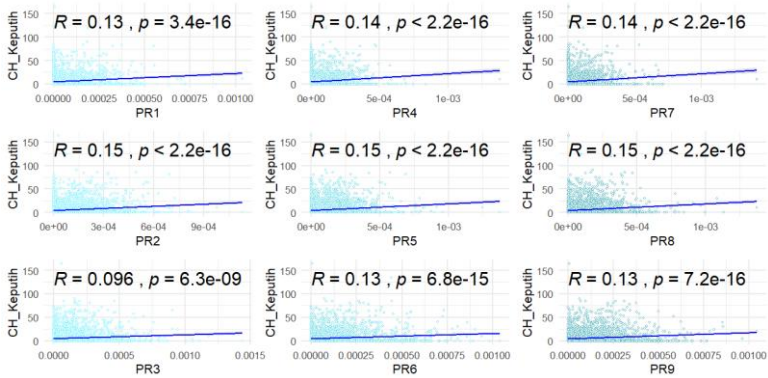
Sebelum dilakukan pemodelan, terlebih dahulu ingin dilihat korelasi antara variabel respon dengan variabel prediktor. Korelasi tersebut menunjukkan besar keeratan hubungan antara kedua data yang mana memiliki rentang antara -1 sampai dengan 1. Korelasi positif menandakan antar variabel memiliki hubungan yang berbanding lurus dan begitu juga sebaliknya. Pada penelitian ini digunakan analisis korelasi *pearson* untuk mengukur hubungan antar variabel secara linier pada setiap pos hujan di Kota Surabaya. Hipotesis yang digunakan adalah sebagai berikut.

H_0 : Tidak ada hubungan yang signifikan antara Variabel Prediktor terhadap Variabel Respon Curah Hujan Harian.

H_1 : Adanya hubungan yang signifikan antara Variabel Prediktor terhadap Variabel Respon Curah Hujan Harian. dengan kriteria pengujian yaitu tolak H_0 jika $p\text{-value} < \alpha$ (0.05).

4.1.1 Pola Hubungan Antar Variabel di Pos Hujan Keputih

Pos Hujan Keputih berada pada sisi paling timur Kota Surabaya yang artinya berada di paling pinggir pada grid 5 pada *output* GCM. Berikut ini disajikan pola hubungan antar variabel prediktor *output* GCM terhadap curah hujan harian di pos hujan Keputih.



Gambar 4. 9 Scatterplot Presipitasi (Horisontal) terhadap Curah Hujan (Vertikal) di Pos Hujan Keputih

Pada Gambar 4.9 ditunjukkan bahwa hubungan variabel presipitasi terhadap curah hujan di pos hujan Keputih yang mana apabila dilihat dari korelasi *pearson* nya memiliki hubungan yang kecil, yaitu rata-rata sebesar 0.13. Namun, nilai korelasi tersebut signifikan karena keseluruhan memiliki nilai kurang dari 0.05 seperti yang dijelaskan pada Tabel 4.2.


Tabel 4. 2 Hasil Keputusan Korelasi *Pearson* Variabel Presipitasi terhadap Curah Hujan Keputih

Variabel Prediktor	<i>r-pearson</i>	<i>p-value</i>	Keputusan
X ₁₁	0.13	3.4×10^{-16}	Tolak H_0
X ₁₂	0.15	$< 2.2 \times 10^{-16}$	Tolak H_0

Tabel 4. 2 Hasil Keputusan Korelasi *Pearson* Variabel Presipitasi terhadap Curah Hujan Keputih (Lanjutan)

Variabel Prediktor	<i>r-pearson</i>	<i>p-value</i>	Keputusan
X ₁₃	0.096	6.3×10^{-9}	Tolak H ₀
X ₁₄	0.14	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₁₅	0.15	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₁₆	0.13	6.8×10^{-15}	Tolak H ₀
X ₁₇	0.14	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₁₈	0.15	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₁₉	0.13	7.2×10^{-16}	Tolak H ₀

Sehingga dapat disimpulkan bahwa variabel presipitasi memiliki hubungan yang signifikan terhadap curah hujan namun tidak secara linier. Hal ini dapat dilihat dari pola hubungan yang terbentuk antar kedua variabel tersebut yang menunjukkan pola acak.



Gambar 4. 10 Scatterplot Temperatur (Horisontal) terhadap Curah Hujan (Vertikal) di Pos Hujan Keputih


Tidak jauh berbeda dengan pola hubungan pada variabel presipitasi dan curah hujan, pada variabel temperatur juga menunjukkan pola hubungan yang sama yaitu pola acak seperti yang ditunjukkan pada Gambar 4.10. Hal ini menunjukkan bahwa tidak adanya hubungan linier yang terbentuk satu sama lain. Namun, apabila dilakukan analisis korelasi secara linier didapatkan bahwa temperatur memiliki korelasi yang negatif terhadap curah

hujan walaupun nilai tersebut kecil akan tetapi sebagian besar signifikan terhadap curah hujan.

Tabel 4. 3 Hasil Keputusan Korelasi *Pearson* Variabel Temperatur terhadap Curah Hujan Keputih

Variabel Prediktor	<i>r-pearson</i>	<i>p-value</i>	Keputusan
X ₂₁	-0.041	1.4×10^{-2}	Tolak H ₀
X ₂₂	-0.15	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₂₃	-0.12	6.0×10^{-13}	Tolak H ₀
X ₂₄	-0.044	8.3×10^{-3}	Tolak H ₀
X ₂₅	-0.12	5.6×10^{-13}	Tolak H ₀
X ₂₆	-0.026	1.1×10^{-1}	Gagal Tolak H ₀
X ₂₇	-0.011	5.1×10^{-1}	Gagal Tolak H ₀
X ₂₈	-0.091	3.6×10^{-8}	Tolak H ₀
X ₂₉	0.013	4.5×10^{-1}	Gagal Tolak H ₀

Berdasarkan Tabel 4.3 tersebut dapat dilihat bahwa variabel temperatur signifikan di seluruh grid kecuali pada grid 6, 7, dan 9. Hal ini ditunjukkan dengan hasil keputusan gagal tolak H₀.



Gambar 4. 11 Scatterplot Kelembapan Udara (Horisontal) terhadap Curah Hujan (Vertikal) di Pos Hujan Keputih

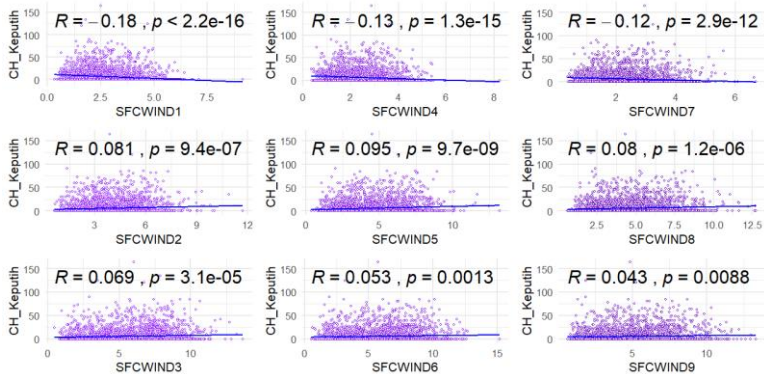
Pola hubungan variabel kelembapan udara dan curah hujan di pos hujan Keputih pada Gambar 4.11 menunjukkan pola yang hampir sama pada grid 2, 3, 5, 6, 8, dan 9, yaitu acak pada nilai kelembapan tertentu. Hal tersebut berbeda dengan pola acak pada grid 1, 4, dan 7 yang merata secara keseluruhan memiliki korelasi yang paling besar dibandingkan pada grid lainnya.

Tabel 4. 4 Hasil Keputusan Korelasi *Pearson* Variabel Kelembapan Udara terhadap Curah Hujan Keputih

Variabel Prediktor	<i>r-pearson</i>	<i>p-value</i>	Keputusan
X ₃₁	0.18	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₃₂	-0.068	4.4×10^{-5}	Tolak H ₀
X ₃₃	-0.036	3.0×10^{-2}	Tolak H ₀
X ₃₄	0.19	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₃₅	-0.04	1.6×10^{-2}	Tolak H ₀
X ₃₆	0.021	2.0×10^{-1}	Gagal Tolak H ₀
X ₃₇	0.18	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₃₈	-0.028	9.3×10^{-2}	Gagal Tolak H ₀
X ₃₉	0.074	7.4×10^{-6}	Tolak H ₀

Berdasarkan Tabel 4.4, didapatkan analisis bahwa pada grid 6 dan 8, variabel kelembapan udara menghasilkan keputusan Gagal Tolak H₀ yang artinya tidak berpengaruh signifikan. Akan tetapi dalam penelitian ini akan tetap dilakukan analisis karena pada grid lainnya, kelembapan udara berpengaruh signifikan secara linier dan pada grid 6 dan 8 masih merupakan bagian dari domain grid 3x3. Selain itu, juga diduga bahwa hubungan yang terbentuk antar variabel merupakan hubungan non linier.

Selanjutnya, yang terakhir adalah pola hubungan variabel kecepatan angin terhadap curah hujan di pos hujan Keputih yang disajikan pada Gambar 4.8 sebagai berikut.



Gambar 4. 12 Scatterplot Kecepatan Angin (Horisontal) terhadap Curah Hujan (Vertikal) di Pos Hujan Keputih

Berdasarkan Gambar 4.12, didapat informasi bahwa variabel kecepatan angin mempengaruhi curah hujan di pos hujan Keputih. Hal tersebut dapat dilihat dari nilai korelasi *pearson* yang dihasilkan seperti yang dijelaskan pada Tabel 4.5 berikut.

Tabel 4. 5 Hasil Keputusan Korelasi *Pearson* Variabel Kecepatan Angin terhadap Curah Hujan Keputih

Variabel Prediktor	<i>r-pearson</i>	<i>p-value</i>	Keputusan
X ₄₁	-0.18	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₄₂	0.081	9.4×10^{-7}	Tolak H ₀
X ₄₃	0.069	3.1×10^{-5}	Tolak H ₀
X ₄₄	-0.13	1.3×10^{-15}	Tolak H ₀
X ₄₅	0.095	9.7×10^{-9}	Tolak H ₀
X ₄₆	0.053	1.3×10^{-3}	Tolak H ₀
X ₄₇	-0.12	2.9×10^{-12}	Tolak H ₀
X ₄₈	0.08	1.2×10^{-6}	Tolak H ₀
X ₄₉	0.043	8.8×10^{-3}	Tolak H ₀

Namun demikian, nilai korelasi *pearson* yang didapatkan kecil. Apabila dilihat dari pola hubungan antar kedua variabel yang acak maka diduga variabel kecepatan angin tersebut memiliki pola hubungan yang non linier terhadap curah hujan di pos hujan Keputih. Sehingga, untuk analisis selanjutnya disarankan untuk dilakukan penyelesaian secara non linier.

4.1.2 Pola Hubungan Antar Variabel di Pos Hujan Kedung Cowek

Tidak jauh berbeda dengan analisis pada pos hujan Keputih, pola hubungan antar variabel prediktor GCM dan variabel curah hujan di pos hujan Kedung Cowek. Hal ini dapat dilihat pada Lampiran 13 dimana secara keseluruhan memiliki pola acak dan nilai korelasi *pearson* yang didapatkan cenderung kecil. Selanjutnya, dilakukan pengujian hipotesis (Lampiran 18) didapatkan bahwa hampir keseluruhan menghasilkan keputusan Tolak H₀, yang artinya bahwa variabel-variabel tersebut berpengaruh signifikan secara linier terhadap curah hujan. Kesimpulan yang berbeda terjadi pada variabel temperatur pada grid 6, 7 dan 9 lalu pada variabel kelembapan udara pada grid 3 karena menghasilkan keputusan Gagal Tolak H₀. Namun demikian,

dengan pola hubungan dan hasil tersebut diduga bahwa hubungan yang terbentuk antar variabel tersebut adalah pola non linier.

4.1.3 Pola Hubungan Antar Variabel di Pos Hujan Gubeng

Pada pos hujan Gubeng, pola hubungan antar variabel yang terbentuk yaitu memiliki pola acak. Hal ini dapat ditunjukkan pada Lampiran 14 dimana baik pada variabel presipitasi, temperatur, kelembapan udara, dan kecepatan angin memiliki pola acak yang berbeda-beda. Kemudian, apabila dilihat nilai korelasi *pearson* yang dihasilkan (Lampiran 19) menunjukkan nilai yang cenderung rendah dan yang paling tinggi terdapat pada variabel kelembapan udara pada grid 1 yaitu sebesar 0.2. Walaupun nilai korelasi yang dihasilkan rendah, hampir keseluruhan keputusan yang didapatkan adalah Tolak H_0 yang artinya bahwa terdapat hubungan yang signifikan antara variabel prediktor data GCM terhadap variabel respon curah hujan di pos hujan Gubeng. Sama halnya dengan yang sebelumnya, hasil tersebut diduga karena hubungan yang terbentuk merupakan hubungan non linier.

4.1.4 Pola Hubungan Antar Variabel di Pos Hujan Wonorejo

Sama halnya dengan pos hujan lainnya, pada pos hujan Wonorejo diperoleh hasil bahwa hubungan yang terbentuk antar variabel prediktor data GCM dan variabel respon data curah hujan diindikasikan memiliki hubungan yang non linier. Hal ini dapat dilihat pada Lampiran 15, dimana hampir keseluruhan pola hubungan yang terbentuk adalah acak dan tidak linier terhadap garis regresi linier terlebih setelah dilihat nilai korelasi yang dihasilkan juga rendah untuk masing-masing variabel. Namun, apabila dilakukan pengujian hipotesis (Lampiran 20) didapatkan hasil yaitu hampir keseluruhan menunjukkan bahwa hubungan antar variabel prediktor pada data GCM berpengaruh signifikan terhadap variabel respon curah hujan di pos hujan Wonorejo.

4.1.5 Pola Hubungan Antar Variabel di Pos Hujan Wonokromo

Tidak jauh berbeda dengan analisis korelasi pada pos - pos hujan lainnya, pada pos hujan Wonokromo juga menghasilkan pola

hubungan yang acak yang dapat dilihat pada Lampiran 16. Selanjutnya, setelah dihitung nilai korelasi *pearson* nya didapatkan bahwa hampir keseluruhan variabel memiliki hubungan linier yang rendah terhadap curah hujan. Namun, setelah dilakukan pengujian hipotesis seperti yang ditunjukkan pada Lampiran 21 didapatkan hasil Tolak H_0 . Hal ini diduga hubungan yang terbentuk antar variabel adalah non linier.

4.1.6 Pola Hubungan Antar Variabel di Pos Hujan Gunung Sari

Pola hubungan yang terbentuk antar variabel prediktor data GCM dan variabel curah hujan di pos hujan Gunung Sari dapat ditunjukkan pada Lampiran 16 dimana dihasilkan bahwa keseluruhan plot memiliki pola acak yang berbeda-beda antar variabel. Lalu, hampir keseluruhan korelasi *pearson* yang dihasilkan rendah, yang artinya bahwa variabel prediktor data GCM tidak memiliki hubungan yang kuat terhadap variabel respon curah hujan seperti yang ditunjukkan pada Lampiran 21. Selain itu, juga dilakukan pengujian hipotesis terhadap nilai korelasi *pearson* yang dihasilkan. Maka diperoleh bahwa hampir keseluruhan variabel berpengaruh signifikan namun memiliki kekuatan hubungan yang rendah. Hal ini diduga karena hubungan yang terbentuk bersifat non linier.

4.2 Pemodelan dan Prediksi Curah Hujan di Kota Surabaya

Peramalan atau yang sering disebut juga dengan prediksi adalah proses memperkirakan suatu kejadian berdasarkan data pendukung dan data historis yang berpengaruh signifikan terhadap hasil prediksi. Prediksi curah hujan akan dilakukan pada setiap pos hujan di Kota Surabaya dengan melakukan *statistical downscaling* data *output General Circulation Model* (GCM) dengan pemodelan regresi curah hujan dengan variabel prediktor *output* GCM dengan domain grid berukuran 1x1, 3x3, dan 3x3 dengan perlakuan *Principal Component Analysis* (PCA). Pada penelitian ini dilakukan pembagian data *training* dan data *testing* dengan pemodelan pada data *training* (1 Januari 2009 s.d 30 November

2018) dan data *testing* (1 s.d 31 Desember 2018). Metode regresi yang digunakan adalah metode *Support Vector Regression* (SVR) dengan kernel non linier yaitu *Radial Basis Function* dengan mengoptimalkan parameter berikut.

- a. *Epsilon* (ε), pada nilai 0.1 dan 0.01.
- b. *Cost* (C), pada nilai 5, 10, ..., 100.
- c. *Gamma* (γ), pada nilai 0.5, 1.0, ..., 5.0.

Dalam penelitian ini, penentuan input dalam pemodelan curah hujan seluruh pos hujan hanya didasarkan pada satu pos hujan yaitu pos hujan Keputih. Selanjutnya kebaikan model dinilai dari nilai RMSE dan RMSE* yang dihasilkan, dimana perhitungan RMSE sesuai dengan Persamaan (2.12) dan perhitungan RMSE* sesuai dengan Persamaan (2.13).

4.2.1 Pemodelan Curah Hujan Sederhana

Pada pemodelan curah hujan sederhana ini akan dilakukan pemodelan curah hujan terhadap variabel prediktor *output* GCM secara univariabel dan multivariabel. Selain itu, juga dilakukan penambahan variabel *dummy*, dengan 0 yang artinya musim kemarau (1 Mei s.d 31 Oktober) dan 1 berarti musim hujan (1 November s.d 30 April).

a. Pemodelan Curah Hujan Keputih dengan Variabel Prediktor *Output* GCM pada Grid 1x1

Pada data GCM grid 1x1, hanya digunakan 1 data untuk setiap variabel prediktor, yaitu presipitasi (X_{15}), temperatur (X_{25}), kelembapan udara (X_{35}), dan kecepatan angin (X_{45}). Sebelumnya, terlebih dahulu dilakukan *tuning* parameter pada setiap model SVR dengan menggunakan data *training*. Parameter model SVR optimum diperoleh dengan kriteria RMSE terkecil. Setelah itu dilakukan pemodelan SVR dengan parameter optimum pada data *training* dan dilanjutkan dengan prediksi curah hujan Keputih di Kota Surabaya dengan data *testing*. Berikut ini merupakan beberapa model SVR dengan variabel prediktor data GCM pada grid 1x1 yang dirangkum dalam Tabel 4.6 dan Lampiran 23.

Tabel 4. 6 Pemodelan SVR Curah Hujan Keputih dengan Data *Testing* Bulan Desember 2018 pada Data GCM Grid 1x1

Model	Epsilon Cost Gamma			Training		Testing	
				RMSE	RMSE*	RMSE	RMSE*
$Y_{1,t} = f(X_{15,t})$	0.1	65	3	13.8596	13.8586	4.7251	4.7251
	0.01	80	3.5	14.2530	14.2523	5.1622	5.1622
$Y_{1,t} = f(X_{15,t}, dummy_t)$	0.1	85	4	13.8460	13.8458	4.5099	4.5099
	0.01	100	5	14.1429	14.1418	4.6268	4.6268
$Y_{1,t} = f(X_{25,t})$	0.1	100	5	13.8106	13.8106	4.4954	4.4954
	0.01	90	5	14.1549	14.1549	4.9628	4.9628
$Y_{1,t} = f(X_{25,t}, dummy_t)$	0.1	60	4	13.4779	13.4780	4.4855	4.4855
	0.01	40	3.5	13.7256	13.7256	4.9595	4.9595
$Y_{1,t} = f(X_{35,t})$	0.1	15	0.5	13.8935	13.8935	4.4941	4.4941
	0.01	5	0.5	14.2998	14.2999	4.9616	4.9616
$Y_{1,t} = f(X_{35,t}, dummy_t)$	0.1	40	5	13.6693	13.6692	4.5237	4.5237
	0.01	85	5	13.9023	13.9023	4.9768	4.8677
$Y_{1,t} = f(X_{45,t})$	0.1	90	5	13.8588	13.8588	4.5896	4.5896
	0.01	75	5	14.2554	14.2552	5.0284	5.0284
$Y_{1,t} = f(X_{45,t}, dummy_t)$	0.1	100	5	13.7152	13.7152	4.6591	4.6591
	0.01	75	5	13.9713	13.9712	4.9447	4.9447
$Y_{1,t} = f(X_{15,t}, X_{25,t}, X_{35,t}, X_{45,t})$	0.1	100	5	8.2954	8.2586	11.9639	9.6671
	0.01	100	5	8.6010	8.5643	13.2713	10.9060
$Y_{1,t} = f(X_{15,t}, X_{25,t}, X_{35,t}, X_{45,t}, dummy_t)$	0.1	100	5	6.7569	6.7239	13.4038	8.4207
	0.01	100	5	6.9578	6.9380	14.8016	9.1871

Selain pemodelan dengan hanya melibatkan variabel prediktor data GCM, pada Tabel 4.6 juga menunjukkan pemodelan dengan melibatkan variabel *dummy*. Dalam hal ini, variabel *dummy* yang digunakan merupakan identifikasi musim yang terjadi, yaitu 0 jika musim kemarau (bulan Mei – Oktober) dan 1 jika musim

penghujan (bulan November – April). Berdasarkan tabel tersebut, dapat diperoleh informasi bahwa RMSE dan RMSE* pemodelan dengan input variabel 1 cenderung lebih tinggi dibandingkan dengan pemodelan dengan input keseluruhan variabel. Selain itu juga didapatkan kesimpulan bahwa penggunaan variabel *dummy* berpengaruh signifikan dalam menurunkan RMSE dan RMSE*. Selanjutnya pada model terakhir pada pemodelan curah hujan dengan seluruh variabel prediktor diolah dalam 2 model SVR, yaitu dengan epsilon 0.1 dan 0.01. Pada model SVR dengan epsilon 0.1 didapatkan RMSE dan RMSE* pada data *testing* lebih rendah daripada model SVR dengan epsilon 0.01. Sehingga diperoleh kesimpulan bahwa pada grid 1x1 dengan data testing bulan Desember 2018 model SVR terbaik terdapat pada pemodelan curah hujan dengan keseluruhan variabel prediktor dan *dummy* dengan parameter optimum $\varepsilon = 0.1$, $C = 100$, dan $\gamma = 5$.

Selain pemodelan SVR dengan pembagian data testing 1 bulan, juga dilakukan pemodelan SVR dengan data testing 1 tahun. Hal ini dilakukan untuk mengetahui apakah pemodelan dengan data *training* dapat memprediksi dengan baik data *testing* 1 tahun dan mengetahui efek pola data *testing* berpengaruh signifikan terhadap prediksi pada grid 1x1. Pada Tabel 4.7 berikut disajikan beberapa olahan model SVR dengan parameter yang telah dioptimumkan kembali untuk data *testing* 1 tahun dan visualisasi dijelaskan pada Lampiran 26.

Tabel 4. 7 Pemodelan SVR Curah Hujan Keputih dengan Data *Testing* Tahun 2018 pada Data GCM Grid 1x1

Model	Epsilon Cost Gamma			Training		Testing	
				RMSE	RMSE*	RMSE	RMSE*
$Y_{1,t} = f(X_{15,t})$	0.1	85	3	14.2552	14.2542	8.6318	8.6224
	0.01	70	4	14.6695	14.6674	8.9567	8.9447
$Y_{1,t} = f(X_{15,t}, dummy_t)$	0.1	100	5	14.1990	14.1989	8.6526	8.6519
	0.01	85	5	14.5232	14.5232	8.8789	8.8786

Tabel 4. 7 Pemodelan SVR Curah Hujan Keputih dengan Data *Testing* Tahun 2018 pada Data GCM Grid 1x1

Model	Epsilon Cost Gamma			Training		Testing	
				RMSE	RMSE*	RMSE	RMSE*
$Y_{1,t} = f(X_{25,t})$	0.1	100	5	14.1668	14.1668	8.6404	8.6404
	0.01	100	5	14.5252	14.5252	8.9677	8.9677
$Y_{1,t} = f(X_{25,t}, dummy_t)$	0.1	50	3.5	13.8713	13.8713	8.3400	8.3400
	0.01	100	3.5	14.1527	14.1527	8.4974	8.4974
$Y_{1,t} = f(X_{35,t})$	0.1	85	0.5	14.2925	14.2925	8.6118	8.6118
	0.01	10	0.5	14.7176	14.7176	8.9324	8.9324
$Y_{1,t} = f(X_{35,t}, dummy_t)$	0.1	70	5	14.0406	14.0405	8.4754	8.4754
	0.01	85	4.5	14.2787	14.2787	8.6033	8.6033
$Y_{1,t} = f(X_{45,t})$	0.1	100	5	14.2576	14.2576	8.6158	8.6147
	0.01	35	4	14.6765	14.6765	8.9275	8.9275
$Y_{1,t} = f(X_{45,t}, dummy_t)$	0.1	100	5	14.0426	14.0426	8.6157	8.6157
	0.01	100	5	14.2818	14.2815	8.8165	8.8165
$Y_{1,t} = f(X_{15,t}, X_{25,t}, X_{35,t}, X_{45,t})$	0.1	100	5	8.1594	8.8184	12.2350	11.0717
	0.01	100	5	8.4058	8.3859	13.8681	11.8200
$Y_{1,t} = f(X_{15,t}, X_{25,t}, X_{35,t}, X_{45,t}, dummy_t)$	0.1	100	5	6.6697	6.6328	14.9607	13.6214
	0.01	100	5	6.8640	6.8420	15.5587	14.0477

Berdasarkan hasil pada Tabel 4.7 diperoleh hasil bahwa pemodelan dengan pola data *training* yang sama menghasilkan nilai RMSE dan RMSE* yang hampir sama. Selanjutnya pada data testing didapatkan bahwa, baik dengan data *testing* 1 bulan maupun 1 tahun tidak memberikan hasil perbedaan RMSE dan RMSE* yang signifikan. Bahkan justru pemodelan SVR menghasilkan RMSE dan RMSE* yang cenderung semakin besar apabila digunakan untuk memprediksi data curah hujan Keputih dalam rentang waktu yang panjang.

b. Pemodelan Curah Hujan dengan Variabel Prediktor *Output* GCM pada Grid 3x3

Pemodelan curah hujan yang dilakukan adalah dengan menggunakan variabel prediktor data GCM pada grid 3x3. Sehingga untuk setiap variabel prediktor memiliki 9 data masing-masing. Pada pemodelan kedua ini 9 data tersebut digunakan secara langsung tanpa diolah terlebih dahulu. Berikut ini merupakan beberapa model SVR dengan variabel prediktor data GCM pada grid 3x3 yang telah dicobakan pada data *training* dan digunakan untuk memprediksi data *testing* pada bulan Desember 2018 yang disajikan pada Tabel 4.8 dan Lampiran 24

Tabel 4. 8 Pemodelan SVR Curah Hujan Keputih dengan Data *Testing* Bulan Desember 2018 pada Data GCM Grid 3x3

Model	Epsilon Cost Gamma			<i>Training</i>		<i>Testing</i>	
				RMSE	RMSE*	RMSE	RMSE*
$Y_{1,t} = f(X_{1,t})$	0.1	100	5	5.2480	5.2357	9.8415	9.8408
	0.01	100	5	5.3327	5.3313	9.6588	9.6541
$Y_{1,t} = f(X_{1,t}, dummy_t)$	0.1	100	5	4.6480	4.6339	9.7799	9.7799
	0.01	100	5	4.6548	4.6509	9.5817	9.5817
$Y_{1,t} = f(X_{2,t})$	0.1	85	4.5	1.2560	1.1855	5.6435	5.6207
	0.01	70	5	0.1324	0.1226	5.3859	5.3698
$Y_{1,t} = f(X_{2,t}, dummy_t)$	0.1	100	4	1.2513	1.1843	6.3934	6.3917
	0.01	100	4.5	0.1321	0.1223	6.1332	6.1329
$Y_{1,t} = f(X_{3,t})$	0.1	100	5	3.4378	3.4069	15.7301	14.5396
	0.01	100	5	3.3024	3.3017	16.7907	15.5561
$Y_{1,t} = f(X_{3,t}, dummy_t)$	0.1	100	5	3.3189	3.2913	12.3863	11.5862
	0.01	100	5	3.1815	3.1776	12.7211	11.8226
$Y_{1,t} = f(X_{4,t})$	0.1	25	3.5	1.2576	0.1411	10.6931	10.6924
	0.01	15	5	0.1320	0.1269	7.6917	7.6917

Tabel 4. 8 Pemodelan SVR Curah Hujan Keputih dengan Data *Testing*
Bulan Desember 2018 pada Data GCM Grid 3x3

Model	Epsilon Cost Gamma			Training		Testing	
				RMSE	RMSE*	RMSE	RMSE*
$Y_{1,t} = f(X_{4,t}, dummy_t)$	0.1	70	2	1.2477	1.1360	17.7867	17.4576
	0.01	15	5	0.1320	0.1282	7.8400	7.8400
$Y_{1,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t})$	0.1	25	0.5	1.2818	1.2724	6.1482	6.1482
	0.01	25	0.5	0.1320	0.1288	5.7111	5.7111
$Y_{1,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t)$	0.1	25	0.5	1.2817	1.2729	6.1256	6.1256
	0.01	25	0.5	0.1321	0.1290	5.6872	5.6872

Pada Tabel 4.8 telah dibentuk pemodelan SVR curah hujan Keputih baik secara individual maupun serentak dengan parameter optimum yang merupakan hasil *tuning*. Berdasarkan tabel tersebut, dapat diperoleh informasi bahwa dengan parameter epsilon 0.01 menghasilkan RMSE dan RMSE* yang lebih kecil dibandingkan pada epsilon 0.1. Semakin kecil epsilon, maka semakin sedikit besar model SVR dalam memberikan toleransi kesalahan. Pemodelan SVR pada grid 3x3 cenderung menghasilkan RMSE dan RMSE* yang lebih kecil dibandingkan pada grid 1x1. Namun, setelah model SVR diujikan pada data *testing* diperoleh hasil RMSE dan RMSE* yang lebih besar dibandingkan dengan data *training*. Hal ini diduga disebabkan karena banyaknya variabel prediktor yang digunakan dalam prediksi. Sehingga model pada data *training* bisa menghasilkan nilai RMSE dan RMSE* yang sangat kecil bahkan mendekati nol. Selanjutnya, jika dianalisis lebih dalam model dengan mengakomodasi seluruh variabel prediktor beserta variabel *dummy* menghasilkan RMSE dan RMSE* pada data *testing* lebih kecil dibandingkan dengan yang tidak diberi variabel *dummy*, yaitu dengan parameter optimum $\epsilon = 0.01$, $C = 25$, dan $\gamma = 0.5$.

Sama halnya pada pemodelan SVR curah hujan Keputih dengan data GCM pada grid 1x1, pada grid 3x3 juga dilakukan pemodelan SVR dengan data *training* 9 tahun dan data *testing* 1

tahun. Berikut merupakan rangkuman hasil pemodelan yang disajikan pada Tabel 4.9 dan Lampiran 27.

Tabel 4. 9 Pemodelan SVR Curah Hujan Keputih dengan Data *Testing* Tahun 2018 pada Data GCM Grid 3x3

Model	Epsilon Cost Gamma			Training		Testing	
				RMSE	RMSE*	RMSE	RMSE*
$Y_{1,t} = f(X_{1,t})$	0.1	100	5	5.4144	5.4031	10.8601	10.6030
	0.01	100	5	5.4996	5.4967	10.8776	10.6164
$Y_{1,t} = f(X_{1,t}, dummy_t)$	0.1	100	5	4.7596	4.7468	10.3963	9.9641
	0.01	100	5	4.7677	4.7645	10.3194	9.9889
$Y_{1,t} = f(X_{2,t})$	0.1	100	4	1.2891	1.2067	10.8956	10.3598
	0.01	65	5	0.1359	0.1268	10.0710	9.7832
$Y_{1,t} = f(X_{2,t}, dummy_t)$	0.1	100	4	1.2817	1.2204	10.8440	10.2645
	0.01	65	5	0.1356	0.1279	10.0347	9.7132
$Y_{1,t} = f(X_{3,t})$	0.1	100	5	3.3875	3.3545	14.3626	12.8915
	0.01	100	5	3.2428	3.2413	14.8738	13.1696
$Y_{1,t} = f(X_{3,t}, dummy_t)$	0.1	100	5	3.2710	3.2430	13.4669	12.1489
	0.01	100	5	3.1256	3.1177	13.7982	12.2842
$Y_{1,t} = f(X_{4,t})$	0.1	35	3	1.2895	1.2082	11.2103	11.0971
	0.01	20	4	0.1357	0.1357	10.3173	10.2651
$Y_{1,t} = f(X_{4,t}, dummy_t)$	0.1	25	2.5	1.2804	1.2061	11.4559	11.2718
	0.01	15	4.5	0.1355	0.1309	9.6753	9.6525
$Y_{1,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t})$	0.1	25	0.5	1.3194	1.3120	8.8232	8.8187
	0.01	25	0.5	0.1355	0.1327	8.6242	8.6168
$Y_{1,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t)$	0.1	25	0.5	1.3190	1.3120	8.7700	8.7654
	0.01	25	0.5	0.1357	0.1329	8.5704	8.5635

Berdasarkan Tabel 4.9 dapat dijelaskan bahwa pemodelan curah hujan Keputih dengan variabel prediktor data GCM pada grid 3x3 menghasilkan nilai RMSE dan RMSE* pada data *training*

baik dengan data 9 tahun 11 bulan atau data 9 tahun dengan nilai yang hampir sama. Namun nilai RMSE dan RMSE* tersebut terlihat berbeda setelah hasil pemodelan SVR data *training* tersebut dicobakan ke data *testing*. Hal tersebut ditunjukkan dengan nilai RMSE dan RMSE* pada data *testing* 1 bulan memiliki nilai yang lebih kecil dibandingkan pada data *testing* 1 tahun.

c. Pemodelan Curah Hujan Keputih dengan Variabel Prediktor *Output* GCM pada Grid 3x3 dengan PCA

Selain dilakukan pemodelan curah hujan Keputih dengan menggunakan keseluruhan data GCM pada grid 3x3, juga dilakukan pemodelan curah hujan dimana variabel prediktor data GCM pada grid 3x3 dilakukan reduksi dimensi dengan menggunakan metode PCA. Hal ini dilakukan karena diduga kedekatan antar lokasi pada setiap grid tersebut dapat diindikasikan terjadi adanya multikolinieritas yang dapat berpengaruh terhadap pemodelan. Walaupun metode SVR tidak memerlukan syarat dan asumsi yang harus dipenuhi, pada penelitian ini juga ingin diketahui besar pengaruh PCA terhadap hasil pemodelan SVR. Selanjutnya, terlebih dulu dilakukan analisis PCA terlebih dahulu pada semua variabel prediktor data GCM pada grid 3x3 dan didapatkan hasil pembentukan *Principal Component* (PC) seperti pada Tabel 4.10 berikut.

Tabel 4. 10 *Cumulative Proportion* untuk PCA Variabel Prediktor

	<i>Cumulative Proportion</i>			
	X_1	X_2	X_3	X_4
PC ₁	0.6482	0.7810	0.6589	0.7964
PC ₂	0.8337	0.9346	0.8502	0.8980
PC ₃	0.8996	0.9704	0.9505	0.9474
PC ₄	0.9492	0.9879	0.9761	0.9800
PC ₅	0.9736	0.9935	0.9892	0.9888
PC ₆	0.9850	0.9969	0.9959	0.9942
PC ₇	0.9931	0.9988	0.9977	0.9979
PC ₈	0.9973	0.9998	0.9992	0.9993
PC ₉	1.0000	1.0000	1.0000	1.0000

Berdasarkan Tabel 4.10, dijelaskan *cumulative proportion* yang dihasilkan oleh setiap variabel prediktor pada analisis PCA. Dalam penelitian ini, *threshol* 80% untuk *cumulative proportion* digunakan untuk dasar pemilihan PC yang akan dijadikan variabel prediktor baru. Sehingga didapatkan bahwa setiap variabel data GCM pada grid 3x3 dapat diwakili dengan 2 PC untuk masing-masing variabel. Selanjutnya, variabel – variabel baru dapat diperoleh setelah dilakukan dimasukkan ke dalam persamaan yang terbentuk sebagai berikut.

$$PC_{11} = 0.1508X_{11} + 0.3497X_{12} + 0.4232X_{13} + 0.1817X_{14} + 0.4019X_{15} \\ - 0.4886X_{26} + 0.2719X_{27} - 0.2311X_{28} - 0.4603X_{29}$$

$$PC_{21} = -0.4115X_{11} - 0.2120X_{12} + 0.3681X_{13} - 0.4551X_{14} - 0.1873X_{15} \\ + 0.3778X_{16} - 0.3979X_{17} - 0.1534X_{18} + 0.2888X_{19}$$

$$PC_{12} = -0.4121X_{21} - 0.3043X_{22} - 0.1483X_{23} - 0.5156X_{24} - 0.3099X_{25} \\ - 0.1149X_{26} - 0.4953X_{27} - 0.2858X_{28} - 0.1166X_{29}$$

$$PC_{22} = 0.2116X_{21} - 0.1981X_{22} - 0.4584X_{23} + 0.2873X_{24} - 0.2129X_{25} \\ - 0.4886X_{26} + 0.2719X_{27} - 0.2311X_{28} - 0.4603X_{29}$$

$$PC_{13} = -0.1639X_{31} + 0.6179X_{32} + 0.0414X_{33} - 0.1885X_{34} + 0.5822X_{35} \\ + 0.0317X_{36} - 0.1722X_{37} + 0.4292X_{38} + 0.0174X_{39}$$

$$PC_{23} = -0.4973X_{31} + 0.0466X_{32} - 0.0846X_{33} - 0.5389X_{34} - 0.2786X_{35} \\ - 0.1189X_{36} - 0.5025X_{37} - 0.2946X_{38} - 0.1476X_{39}$$

$$PC_{14} = 0.0886X_{41} + 0.2791X_{42} + 0.4521X_{43} + 0.1149X_{44} + 0.3623X_{45} \\ + 0.4879X_{46} + 0.1187X_{47} + 0.3634X_{48} + 0.4255X_{49}$$

$$PC_{24} = 0.6989X_{41} + 0.0503X_{42} - 0.0711X_{43} + 0.5243X_{44} - 0.1002X_{45} \\ - 0.0742X_{46} + 0.4349X_{47} - 0.1323X_{48} - 0.0826X_{49}$$

Berdasarkan persamaan PC diatas maka didapatkan data untuk setiap variabel prediktor yaitu 2 variabel baru sesuai dengan persamaan PC yang terbentuk. Setelah itu variabel – variabel baru

tersebut dilakukan pemodelan terhadap curah hujan Keputih. Berikut ini merupakan rangkuman hasil pemodelan yang dibentuk yang disajikan pada Tabel 4.11 dan secara visual dapat dilihat pada Lampiran 25.

Tabel 4. 11 Pemodelan SVR Curah Hujan Keputih dengan Data *Testing* Bulan Desember 2018 pada Data GCM Grid 3x3 PCA

Model	Epsilon Cost Gamma			Training		Testing	
				RMSE	RMSE*	RMSE	RMSE*
$Y_{1,t} = f(PC_{11,t}, PC_{21,t})$	0.1	100	5	12.9877	12.9776	12.4370	11.6325
	0.01	100	5	13.3217	13.3153	12.4884	11.7937
$Y_{1,t} = f(PC_{11,t}, PC_{21,t}, dummy_t)$	0.1	100	5	12.4119	12.4001	12.7888	11.4364
	0.01	100	5	12.6586	12.6419	12.7962	11.7124
$Y_{1,t} = f(PC_{12,t}, PC_{22,t})$	0.1	100	5	13.4476	13.4468	4.5142	4.5142
	0.01	100	5	13.8188	13.8175	4.9639	4.9632
$Y_{1,t} = f(PC_{12,t}, PC_{22,t}, dummy_t)$	0.1	100	5	12.6676	12.6613	5.6698	5.6616
	0.01	100	5	12.9018	12.8928	5.9650	5.9648
$Y_{1,t} = f(PC_{13,t}, PC_{23,t})$	0.1	100	5	13.5117	13.5104	6.9856	6.8824
	0.01	100	5	13.8668	13.8645	6.2389	6.0413
$Y_{1,t} = f(PC_{13,t}, PC_{23,t}, dummy_t)$	0.1	100	5	12.9447	12.9423	9.5256	9.2323
	0.01	100	5	13.1220	13.1194	9.9366	9.5058
$Y_{1,t} = f(PC_{14,t}, PC_{24,t})$	0.1	100	5	13.3025	13.3006	6.2660	6.2660
	0.01	100	5	13.5799	13.5713	6.4927	6.4927
$Y_{1,t} = f(PC_{14,t}, PC_{24,t}, dummy_t)$	0.1	100	5	12.8657	12.8619	6.7325	6.7325
	0.01	100	5	13.0824	13.0710	6.3885	6.3885
$Y_{1,t} = f(PC_{11,t}, PC_{21,t}, PC_{12,t}, PC_{22,t}, PC_{13,t}, PC_{23,t}, PC_{24,t}, PC_{24,t})$	0.1	55	2	1.2419	1.1648	12.1930	12.1923
	0.01	20	4	0.1319	0.1283	7.6725	7.6725
$Y_{1,t} = f(PC_{11,t}, PC_{21,t}, PC_{12,t}, PC_{22,t}, PC_{13,t}, PC_{23,t}, PC_{24,t}, PC_{24,t}, dummy_t)$	0.1	55	2	1.2460	1.1809	12.1383	12.1383
	0.01	30	3	0.1316	0.1260	9.3051	9.3051

Pada Tabel 4.12, diperoleh nilai RMSE dan RMSE* untuk pemodelan curah hujan Keputih pada data *training* yaitu cukup besar untuk pemodelan dengan variabel baru *principal component* dari setiap variabel prediktor secara individu. Hal ini didukung dengan Lampiran 24 yang menunjukkan hasil prediksi pada data *training* tidak dapat menangkap kejadian-kejadian curah hujan yang ekstrim. Berbeda halnya dengan pemodelan curah hujan Keputih dengan variabel prediktor seluruh *principal component* pada setiap variabel, nilai RMSE dan RMSE* nya cenderung sangat kecil bahkan mendekati nol. Hal ini diakibatkan oleh kemampuan hasil pemodelan tersebut dalam menangkap kejadian curah hujan yang ekstrim. Selanjutnya, penambahan variabel *dummy* musim pada pemodelan SVR ini tidak memberikan efek yang signifikan dalam menurunkan RMSE dan RMSE*. Jadi, dapat disimpulkan bahwa pemodelan curah hujan dengan variabel prediktor data GCM pada grid 3x3 PCA yang terbaik adalah pemodelan dengan keseluruhan *principal component* yang dihasilkan setiap variabel prediktor dan parameter optimum $\varepsilon = 0.01$, $C = 20$, dan $\gamma = 4$.

Sama halnya dengan pemodelan SVR sebelumnya, pada pemodelan curah hujan dengan variabel prediktor data GCM pada grid 3x3 PCA juga dilakukan pemodelan dengan data *training* 9 tahun dan data *testing* 1 tahun. Berikut ini merupakan hasil rangkuman dari pemodelan yang telah dibentuk disajikan pada Tabel 4.12 dan visualisasinya dapat dilihat di Lampiran 28.

Tabel 4. 12 Pemodelan SVR Curah Hujan Keputih dengan Data *Testing* Tahun 2018 pada Data GCM Grid 3x3 PCA

Model	Epsilon Cost Gamma			Training		Testing	
				RMSE	RMSE*	RMSE	RMSE*
$Y_{i,t} = f(PC_{11,t}, PC_{21,t})$	0.1	100	5	13.4191	13.4105	10.8780	10.6254
	0.01	100	5	13.7661	13.7565	11.0409	10.8156
$Y_{i,t} = f(PC_{11,t}, PC_{21,t}, dummy_t)$	0.1	100	5	12.7563	12.7379	10.9713	10.7261
	0.01	100	5	12.9513	12.9240	11.1667	10.9685


Tabel 4. 12 Pemodelan SVR Curah Hujan Keputih dengan Data *Testing* Tahun 2018 pada Data GCM Grid 3x3 PCA (Lanjutan)

Model	Epsilon Cost Gamma			Training		Testing	
				RMSE	RMSE*	RMSE	RMSE*
$Y_{1,t} = f(PC_{12,t}, PC_{22,t})$	0.1	100	5	13.7474	13.7461	9.2938	9.0554
	0.01	100	5	14.1302	14.1291	9.4180	9.2611
$Y_{1,t} = f(PC_{12,t}, PC_{22,t}, dummy_t)$	0.1	100	5	12.8904	12.8843	9.3186	8.9130
	0.01	100	5	13.0971	13.0908	9.1418	8.7807
$Y_{1,t} = f(PC_{13,t}, PC_{23,t})$	0.1	100	5	13.8747	13.8734	10.2240	10.1749
	0.01	100	5	14.2506	14.2491	10.6019	10.5568
$Y_{1,t} = f(PC_{13,t}, PC_{23,t}, dummy_t)$	0.1	100	5	13.2829	13.2798	9.9788	9.8286
	0.01	100	5	13.4788	13.4745	10.0949	9.9562
$Y_{1,t} = f(PC_{14,t}, PC_{24,t})$	0.1	100	5	13.6358	13.6303	8.3874	8.3625
	0.01	100	5	13.9256	13.9171	8.4983	8.4795
$Y_{1,t} = f(PC_{14,t}, PC_{24,t}, dummy_t)$	0.1	100	5	13.0983	13.0882	8.4888	8.4432
	0.01	100	5	13.3210	13.3081	8.4620	8.4348
$Y_{1,t} = f(PC_{11,t}, PC_{21,t}, PC_{12,t}, PC_{22,t}, PC_{13,t}, PC_{23,t}, PC_{24,t}, PC_{24,t})$	0.1	50	2	1.2772	1.2061	11.9577	11.6990
	0.01	15	5	0.1355	0.1341	8.9289	8.9277
$Y_{1,t} = f(PC_{11,t}, PC_{21,t}, PC_{12,t}, PC_{22,t}, PC_{13,t}, PC_{23,t}, PC_{24,t}, PC_{24,t}, dummy_t)$	0.1	50	2	1.2800	1.2195	11.4641	11.2237
	0.01	25	3	0.1355	0.1301	9.8470	9.8157

Berdasarkan Tabel 4.13, dapat diperoleh informasi bahwa nilai RMSE dan RMSE* di dalam pemodelan SVR pada data *training* cenderung sama dengan pemodelan sebelumnya. Hal itu juga terjadi pada hasil RMSE dan RMSE* pada data *testing* pada 1 bulan maupun 1 tahun. Namun, pada kedua pemodelan tersebut dapat disimpulkan bahwa melakukan prediksi curah hujan harian selama 1 bulan memiliki nilai RMSE dan RMSE* yang lebih kecil dibandingkan dengan prediksi curah hujan harian dalam satu tahun.


4.2.2 Pemodelan Curah Hujan dengan Penambahan Lag

Setelah dilakukan pemodelan SVR secara sederhana hanya dengan penggunaan variabel – variabel prediktor data GCM dan penggunaan variabel *dummy*, didapatkan hasil prediksi yang belum bagus dan belum mengikuti titik pengamatan curah hujan asli. Sehingga pada bagian ini akan dilakukan pemodelan seluruh variabel prediktor data GCM dan *dummy* pada grid 1x1 dan grid 3x3, namun tidak pada grid 3x3 PCA beserta penambahan lag – lag curah hujan Keputih yang diduga signifikan mempengaruhi hasil prediksi. Berikut ini merupakan plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (ACF) yang disajikan pada Gambar 4.13.



Gambar 4. 13 Plot ACF dan PACF Data Curah Hujan di Pos Hujan Keputih

Berdasarkan Gambar 4.13 dapat dilihat bahwa data membentuk pola musiman dan belum stasioner. Sehingga, perlu dilakukan *differencing* musiman, yaitu terhadap lag 365 agar diperoleh lag-lag yang signifikan untuk pemodelan ARIMA. Berikut ini merupakan plot ACF dan PACF curah hujan Keputih hasil *differencing* terhadap lag 365 yang disajikan pada Gambar 4.14.



Gambar 4. 14 Plot ACF dan PACF Data Curah Hujan di Pos Hujan Keputih setelah *Differencing* Seasonal terhadap lag 365

Plot ACF dan PACF pada Gambar 4.14 menunjukkan bahwa lag-lag yang signifikan telah terbentuk dan selanjutnya dapat dilakukan identifikasi model ARIMA. Namun, dalam penelitian ini lag-lag yang signifikan yang dilihat hanya pada model AR atau pada ordo p dan P. Sehingga model ARIMA yang terbentuk jika dilihat dari plot ACF PACF dengan melihat model AR adalah $ARIMA(p,d,q)(P,D,Q)^S = ARIMA(1,0,0)(5,1,0)^{365}$. Selanjutnya model ARIMA tersebut dihitung secara matematis dan dapat dilihat pada Lampiran 29. Berdasarkan perhitungan tersebut didapatkan bahwa lag-lag curah hujan yang diduga berpengaruh signifikan terhadap curah hujan Keputih adalah pada $Y_{(t-1)}$, $Y_{(t-365)}$, $Y_{(t-366)}$, $Y_{(t-730)}$, $Y_{(t-731)}$, $Y_{(t-1095)}$, $Y_{(t-1096)}$, $Y_{(t-1460)}$, $Y_{(t-1461)}$, $Y_{(t-1825)}$, $Y_{(t-1826)}$, $Y_{(t-2190)}$, $Y_{(t-2191)}$.

Tabel 4. 13 Pemodelan SVR Curah Hujan Keputih Terbaik dengan Penambahan Lag dari ARIMA (1,0,0)(5,1,0)³⁶⁵

Data GCM	Model	Epsilon Cost Gamma			Training		Testing	
					RMSE	RMSE*	RMSE	RMSE*
Grid	$Y_{t,r} = f(X_t, dummy_t, lag)$	0.1	100	5	2.5725	2.551	6.3245	6.3245
1x1	ARIMA(1,0,0)(5,1,0) ³⁶⁵	0.01	100	5	2.6735	2.6731	5.8462	5.8462

Tabel 4. 13 Pemodelan SVR Curah Hujan Keputih Terbaik dengan Penambahan Lag dari ARIMA (1,0,0)(5,1,0)³⁶⁵

Data GCM	Model	Epsilon Cost Gamma			Training		Testing	
					RMSE	RMSE*	RMSE	RMSE*
Grid 3x3	$Y_{i,t} = f(X_{i,t}, dummy_{i,t}, lag)$	0.1	15	0.5	1.3231	1.321	6.1464	6.1464
	ARIMA(1,0,0)(5,1,0) ³⁶⁵	0.01	15	0.5	0.1353	0.1338	5.6648	5.6648
Grid 3x3 PCA	$Y_{i,t} = f(X_{i,t}, lag)$	0.1	30	1	1.2906	1.2516	6.6607	6.6607
	ARIMA(1,0,0)(5,1,0) ³⁶⁵	0.01	50	1	0.1344	0.1277	6.1714	6.1714

Berdasarkan Tabel 4.14, diperoleh informasi bahwa pemodelan curah hujan Keputih dengan penambahan lag, cenderung menurun dibandingkan pemodelan sebelumnya tanpa menggunakan lag. Namun, apabila dilihat dari hasil plot yang di visualisasikan pada Lampiran 30, Lampiran 31, dan Lampiran 32 menunjukkan bahwa hasil prediksi yang didapatkan cenderung konstan dan tidak mengikuti pola data aktual curah hujan pada bulan Desember 2018.

4.2.3 Pemodelan Curah Hujan dengan tidak melibatkan Observasi Nol pada Data Training

Pada pemodelan curah hujan yang telah dilakukan sebelumnya, didapatkan hasil prediksi pada bulan Desember yang cenderung konstan. Hal ini diduga karena pemodelan SVR dibentuk dari banyaknya observasi curah hujan harian Keputih yang bernilai nol. Oleh sebab itu, pada penelitian ini juga dicobakan pemodelan SVR dengan tidak melibatkan observasi curah hujan harian Keputih bernilai nol. Sehingga, akan diperoleh hasil pemodelan seperti yang disajikan pada Tabel 4.15 sebagai berikut dan juga secara visual dapat dilihat pada Lampiran 33, Lampiran 34, dan Lampiran 35.

Tabel 4. 14 Pemodelan SVR Curah Hujan Keputih dengan Tidak Melibatkan Observasi Nol

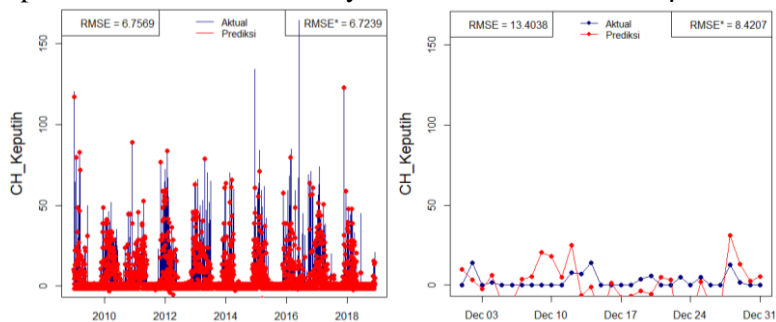
Data GCM	Model	Epsilon Cost Gamma			Training		Testing	
					RMSE	RMSE*	RMSE	RMSE*
Grid 1x1	$Y_{1,t} = f(X_{15,t}, X_{25,t}, X_{35,t}, X_{45,t})$	0.1	20	1.5	7.8261	7.8261	15.9498	15.9498
		0.01	60	1	8.0961	8.0961	15.9182	15.9182
Grid 3x3	$Y_{1,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t})$	0.1	45	0.5	0.9223	0.9223	14.1801	14.1801
		0.01	40	0.5	0.0952	0.0952	13.8685	13.8685
Grid 3x3 PCA	$Y_{1,t} = f(PC_{11,t}, PC_{21,t}, PC_{12,t}, PC_{22,t}, PC_{13,t}, PC_{23,t}, PC_{24,t}, PC_{24,t})$	0.1	15	0.5	4.7152	4.7152	20.9202	20.9202
		0.01	85	0.5	2.1576	2.1576	26.7786	26.7786

Pengujian pada data *testing* bulan Desember 2018 dengan pemodelan SVR tanpa melibatkan observasi nol perlu dilakukan identifikasi apakah pada tanggal tersebut diperkirakan hujan atau tidak. Sehingga pada penelitian ini, peneliti mengamsusikan apabila pada tahun 2009 – 2017 pada tanggal tertentu di Bulan Desember tidak mengalami hujan minimal 50% maka dianggap pada tanggal tersebut tidak terjadi hujan atau curah hujan sama dengan nol. Berdasarkan Tabel 4.15 dapat diperoleh informasi bahwa RMSE dan RMSE* baik pada data *training* dan data *testing* bernilai cukup besar dan didapatkan bahwa pemodelan SVR terbaik terjadi pada saat epsilon bernilai 0.01.

4.2.4 Penentuan Model Terbaik untuk Setiap Grid dan Secara Keseluruhan

Pemodelan SVR curah hujan Keputih telah dicobakan dengan berbagai macam model untuk masing-masing grid dan perlakuan. Selanjutnya perlu untuk ditentukan model terbaik dan data GCM dengan grid yang paling cocok digunakan untuk memprediksi curah hujan di Kota Surabaya. Berikut ini disajikan perbandingan secara visual beserta nilai RMSE dan RMSE* untuk menentukan model terbaik.

- a. Pemodelan Curah Hujan dengan Data GCM Grid 1x1
Setelah dilakukan 3 jenis pemodelan yang berbeda, didapatkan 3 model terbaik. Pemodelan pertama merupakan pemodelan curah hujan dengan seluruh variabel prediktor dan variabel *dummy*. Pada pemodelan ini didapatkan parameter optimum untuk model SVR, yaitu $\varepsilon = 0.1$, $C = 100$, dan $\gamma = 5$.




Gambar 4. 15 Time Series Plot Hasil Pemodelan SVR Curah Hujan Keputih terhadap Data GCM Grid 1x1 ($Y_{1,t} = f(X_{15,t}, X_{25,t}, X_{35,t}, X_{45,t}, dummy_t)$)

Berdasarkan Gambar 4.15, dapat diperoleh informasi bahwa pemodelan SVR tersebut menghasilkan nilai RMSE dan RMSE* pada data *testing* lebih besar dibandingkan pada data *training*. Hal ini diduga disebabkan karena data curah hujan aktual Keputih yang cenderung rendah dan tidak terdapat curah hujan ekstrim. Lalu, didapatkan bahwa pemodelan dengan keseluruhan data curah hujan bisa menghasilkan curah hujan negatif atau dibawah nol. Prediksi curah hujan yang dihasilkan pada pemodelan tersebut dapat baik karena telah sedikit mengikuti pola curah hujan aktual dan menghasilkan RMSE* sebesar 8.4207.

Selanjutnya, guna menurunkan nilai RMSE dan menghasilkan prediksi curah hujan aktual maka didapatkan model terbaik kedua yaitu merupakan pemodelan curah hujan pada pemodelan pertama dan dilakukan penambahan lag-lag curah hujan model ARIMA(1,0,0)(5,1,0)³⁶⁵. Pada pemodelan ini didapatkan parameter optimum untuk model SVR, yaitu $\varepsilon = 0.01$, $C = 100$, dan $\gamma = 5$. Selanjutnya, RMSE dan RMSE* pada data


training dan *testing* yang dihasilkan lebih rendah dibandingkan pada model SVR sebelumnya dan adapun visualisasi dari hasil pemodelan tersebut disajikan pada Gambar 4.16 berikut.



Gambar 4. 16 Time Series Plot Hasil Pemodelan SVR Curah Hujan Keputih terhadap Data GCM pada Grid 1x1

$$(Y_{1,t} = f(X_{15,t}, X_{25,t}, X_{35,t}, X_{45,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365}))$$

Pemodelan terbaik ketiga yang dilakukan adalah pemodelan SVR curah hujan Keputih terhadap variabel prediktor data GCM tanpa melibatkan data aktual curah hujan yang bernilai nol. Pada pemodelan ini didapatkan parameter optimum untuk model SVR, yaitu $\varepsilon = 0.01$, $C = 60$, dan $\gamma = 1$. Sehingga dalam pemodelan tidak dilakukan prediksi pada data curah hujan nol. Berikut ini merupakan hasil plot prediksi yang didapatkan dengan pemodelan tersebut.




Gambar 4. 17 Time Series Plot Hasil Pemodelan SVR Curah Hujan Keputih terhadap Data GCM dengan NA pada Grid 1x1 ($Y_{1,t} = f(X_{15,t}, X_{25,t}, X_{35,t}, X_{45,t})$)

Pada Gambar 4.17 dapat dilihat bahwa pada prediksi data *training*, model sudah dapat menangkap beberapa kejadian curah hujan ekstrim. Selanjutnya pada prediksi untuk data *testing* dengan mempertimbangkan data lampau didapatkan nilai RMSE dan RMSE* sebesar 15.9182. Sedangkan, untuk pola yang dihasilkan pada data *testing* didapatkan prediksi yang cenderung memiliki kesamaan pola dengan data aktual.


b. Pemodelan Curah Hujan dengan Data GCM Grid 3x3

Pada hasil pemodelan SVR terbaik yang dihasilkan untuk memprediksi curah hujan dengan data GCM grid 3x3 didapatkan hasil sebagai berikut.



Gambar 4. 18 Time Series Plot Hasil Pemodelan SVR Curah Hujan Keputih terhadap Data GCM pada Grid 3x3 ($Y_{1,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t)$)


Pemodelan terbaik pertama yang dihasilkan merupakan pemodelan curah hujan dengan seluruh variabel prediktor dan variabel *dummy*. Pada pemodelan ini didapatkan parameter optimum untuk model SVR, yaitu $\varepsilon = 0.01$, $C = 25$, dan $\gamma = 0.5$. Berdasarkan Gambar 4.18 dapat dilihat bahwa hasil prediksi pada data *training* dapat menangkap kejadian-kejadian curah hujan ekstrim, sedangkan pada data *testing* didapatkan hasil prediksi yang cenderung konstan. Nilai RMSE dan RMSE* pada data *training* maupun *testing* menghasilkan nilai yang kecil. Selanjutnya, dilakukan penambahan lag-lag curah hujan yang diduga berpengaruh terhadap curah hujan Keputih guna didapatkan hasil prediksi yang lebih baik.



Gambar 4. 19 Time Series Plot Hasil Pemodelan SVR Curah Hujan Keputih terhadap Data GCM pada Grid 3x3

$$(Y_{1,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365}))$$

Pada pemodelan ini didapatkan parameter optimum untuk model SVR, yaitu $\varepsilon = 0.01$, $C = 15$, dan $\gamma = 0.5$. Berdasarkan Gambar 4.19, hasil prediksi yang didapatkan tidak jauh berbeda dengan pemodelan tanpa penambahan lag-lag curah hujan. Hal tersebut dapat dilihat dari prediksi yang dihasilkan sama-sama cenderung konstan dalam setiap tanggalnya, sedangkan nilai RMSE dan RMSE* yang dihasilkan pada pemodelan ini lebih kecil yaitu sebesar 5.6648. Selanjutnya, dilakukan pemodelan ketiga untuk prediksi curah hujan tanpa melibatkan data curah hujan bernilai nol dengan variabel prediktor data GCM grid 3x3.




Gambar 4. 20 Time Series Plot Hasil Pemodelan SVR Curah Hujan dengan NA Keputih terhadap Data GCM pada Grid 3x3 ($Y_{1,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t})$)

Pada pemodelan ini didapatkan parameter optimum untuk model SVR, yaitu $\varepsilon = 0.01$, $C = 40$, dan $\gamma = 0.5$. Tidak jauh berbeda

dengan hasil prediksi curah hujan pada dua pemodelan sebelumnya, dapat dilihat hasil prediksi pada Gambar 4.20 juga menghasilkan prediksi yang cenderung konstan pada tanggal yang diduga akan terjadi hujan dengan nilai RMSE dan RMSE* yang dihasilkan kecil, yaitu sebesar 13.8685.

c. Pemodelan Curah Hujan dengan Data GCM Grid 3x3 PCA


Pemodelan SVR terbaik pertama merupakan pemodelan SVR curah hujan dengan seluruh data GCM grid 3x3 yang telah dilakukan PCA. Berikut ini merupakan hasil prediksi yang didapatkan dan dapat dilihat pada Gambar 4.21 berikut ini.



Gambar 4. 21 Time Series Plot Hasil Pemodelan SVR Curah Hujan Keputih terhadap Data GCM pada Grid 3x3 PCA

$$(Y_1 = f(PC_{11,t}, PC_{21,t}, PC_{12,t}, PC_{22,t}, PC_{13,t}, PC_{23,t}, PC_{24,t}, PC_{24,t}))$$


Berdasarkan Gambar tersebut dapat dilihat bahwa hasil prediksi pada testing sudah tidak konstan Pada pemodelan ini didapatkan parameter optimum untuk model SVR, yaitu $\varepsilon = 0.01$, $C = 20$, dan $\gamma = 4$. Nilai RMSE dan RMSE* yang didapatkan cenderung kecil, yaitu sebesar 7.6725. Dikarenakan pemodelan SVR prediksi curah hujan tersebut masih belum baik, sehingga dilakukan pemodelan SVR dengan penambahan lag curah hujan. Namun, dapat dilihat pada Gambar 4.22 bahwa nilai RMSE dan RMSE* yang dihasilkan cukup kecil pada prediksi data *testing* dan didapatkan hasil prediksi yang konstan dalam setiap tanggalnya.



Gambar 4. 22 Time Series Plot Hasil Pemodelan SVR Curah Hujan Keputih terhadap Data GCM pada Grid 3x3 PCA

$$(Y_1 = f(PC_{11,t}, PC_{21,t}, PC_{12,t}, PC_{22,t}, PC_{13,t}, PC_{23,t}, PC_{24,t}, PC_{24,t}, \text{lagARIMA}(1,0,0)(5,1,0)^{365}))$$

Sehingga dapat dikatakan bahwa pemodelan terbaik kedua justru menghasilkan pola prediksi yang tidak lebih baik dari model pertama. Pada pemodelan tersebut didapatkan parameter optimum untuk model SVR, yaitu $\varepsilon = 0.01$, $C = 50$, dan $\gamma = 1$. Selanjutnya, didapatkan model terbaik ketiga yaitu dengan tidak melibatkan data aktual curah hujan yang bernilai nol. Berikut merupakan hasil prediksi yang didapatkan yang disajikan pada Gambar 4.23.



Gambar 4. 23 Time Series Plot Hasil Pemodelan SVR Curah Hujan Keputih dengan NA terhadap Data GCM pada Grid 3x3 PCA

$$(Y_1 = f(PC_{11,t}, PC_{21,t}, PC_{12,t}, PC_{22,t}, PC_{13,t}, PC_{23,t}, PC_{24,t}, PC_{24,t}))$$

Pada pemodelan tersebut didapatkan parameter optimum untuk model SVR, yaitu $\varepsilon = 0.1$, $C = 15$, dan $\gamma = 0.5$. Pada Gambar

4.23 dapat ditarik kesimpulan bahwa pemodelan curah hujan dengan data GCM pada grid 3x3 PCA menghasilkan prediksi yang dengan nilai RMSE dan RMSE* yang besar, yaitu sebesar 20.9202 dan 20.6516 pada data *testing*. Hasil dari pemodelan tersebut memiliki tingkat kebaikan model yang tidak lebih baik dari dua pemodelan sebelumnya.

Tabel 4. 15 Rangkuman Hasil Pemodelan SVR Curah Hujan Keputih dengan Variabel Prediktor Data GCM

Model	Epsilon	Cost	Gamma	Training		Testing	
				RMSE	RMSE*	RMSE	RMSE*
Pemodelan Curah Hujan Keputih pada Data GCM grid 1x1							
$Y_{1,t} = f(X_{15,t}, X_{25,t}, X_{35,t}, X_{45,t}, dummy_{1t})$	0.1	100	5	6.7569	6.7239	13.4038	8.4207
$Y_{1,t} = f(X_t, dummy_t, lag)$ ARIMA(1,0,0)(5,1,0) ³⁶⁵	0.01	100	5	2.6735	2.6731	5.8462	5.8462
$Y_{1,t} = f(X_{15,t}, X_{25,t}, X_{35,t}, X_{45,t})$	0.01	60	1	8.0961	8.0961	15.9182	15.9182
Pemodelan Curah Hujan Keputih pada Data GCM grid 3x3							
$Y_{1,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_{1t})$	0.01	25	0.5	0.1321	0.1290	5.6872	5.6872
$Y_{1,t} = f(X_t, dummy_t, lag)$ ARIMA(1,0,0)(5,1,0) ³⁶⁵	0.01	15	0.5	0.1353	0.1338	5.6648	5.6648
$Y_{1,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t})$	0.01	40	0.5	0.0952	0.0952	13.8685	13.8685
Pemodelan Curah Hujan Keputih pada Data GCM grid 3x3 PCA							
$Y_{1,t} = f(PC_{11,t}, PC_{21,t}, PC_{12,t}, PC_{22,t}, PC_{13,t}, PC_{23,t}, PC_{24,t}, PC_{24,t})$	0.01	20	4	0.1319	0.1283	7.6725	7.6725
$Y_{1,t} = f(X_t, lag)$ ARIMA(1,0,0)(5,1,0) ³⁶⁵	0.01	50	1	0.1344	0.1277	6.1714	6.1714
$Y_{1,t} = f(PC_{11,t}, PC_{21,t}, PC_{12,t}, PC_{22,t}, PC_{13,t}, PC_{23,t}, PC_{24,t}, PC_{24,t})$	0.1	15	0.5	4.7152	4.7152	20.9202	20.9202

Kesimpulan yang diperoleh dari hasil pemodelan SVR curah hujan Keputih dengan menggunakan 3 jenis data variabel prediktor yang berbeda, yaitu data GCM pada grid 1x1, data GCM pada grid 3x3, dan data GCM pada grid 3x3 dengan perlakuan PCA yang telah dirangkum dalam Tabel 4.15 didapatkan hasil bahwa pemodelan SVR curah hujan Keputih dengan seluruh variabel prediktor data GCM grid 3x3 dengan penambahan variabel *dummy* dan lag curah hujan ARIMA(1,0,0)(5,1,0)³⁶⁵ didapatkan hasil prediksi dengan nilai RMSE dan RMSE* pada data *testing* terkecil, yaitu sebesar 5.6648. Namun, hasil prediksi yang didapatkan cenderung konstan dan tidak mengikuti pola data curah hujan aktual.

4.2.5 Prediksi Curah Hujan di Kota Surabaya

Setelah didapatkan model untuk prediksi curah hujan di pos hujan Keputih yang terbaik, kemudian input model terbaik tersebut diimplementasikan untuk prediksi curah hujan pada pos hujan di Kota Surabaya lainnya. Namun, pada setiap pos hujan masih dilakukan *tuning parameter* model SVR. Berikut ini merupakan hasil prediksi curah hujan untuk setiap pos hujan di Kota Surabaya.


4.2.5.1 Prediksi Curah Hujan di Pos Hujan Keputih

Prediksi curah hujan Keputih pada bulan Desember 2018 didasarkan pada pemodelan curah hujan dengan variabel prediktor seluruh data GCM pada grid 1x1 dan tidak melibatkannya observasi curah hujan yang nol. Dengan melakukan tuning parameter, didapatkan model SVR kernel RBF dengan parameter optimum $\varepsilon = 0.01$, $C = 15$, dan $\gamma = 0.5$. Model *Support Vector Regression* prediksi curah hujan di pos hujan Keputih dapat dituliskan dalam persamaan sebagai berikut.

$$f(x) = \sum_{i=1}^{1422} (\alpha_i - \alpha_i^*) \exp(-0.5 \|x - x_i\|^2) - 0.0737$$

Penggunaan parameter optimum pada pemodelan SVR curah hujan di pos hujan Keputih, didapatkan jumlah *support vector* yang terbentuk adalah sebanyak 1422 data sebagaimana

yang dituliskan pada nilai α_i (Lampiran 36a). Selanjutnya, juga didapatkan nilai bias sebesar -0.0737. Berikut merupakan hasil prediksi yang didapatkan dari model SVR yang telah didapatkan.



Gambar 4. 24 Time Series Plot Hasil Pemodelan SVR Keputih pada Data GCM grid 3x3 ($Y_{1,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$)

Berdasarkan Gambar 4.24 didapatkan hasil RMSE dan RMSE* untuk prediksi bulan Desember 2018 sebesar 5.6648. Hasil prediksi curah hujan Keputih disajikan pada Tabel 4.16 berikut.

Tabel 4. 16 Hasil Prediksi Curah Hujan Keputih pada Data GCM grid 3x3 ($Y_{1,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$)

No	Tanggal	Hasil Prediksi
1	12/1/2018	6.25148
2	12/2/2018	6.25127
3	12/3/2018	6.25098
4	12/4/2018	6.25136
5	12/5/2018	6.25148
6	12/6/2018	6.25149
7	12/7/2018	6.25151
8	12/8/2018	6.25148
9	12/9/2018	6.25148
10	12/10/2018	6.25130
11	12/11/2018	6.25148
12	12/12/2018	6.25148
13	12/13/2018	6.25149
14	12/14/2018	6.25148

Tabel 4. 16 Hasil Prediksi Curah Hujan Keputih pada Data GCM grid 3x3 ($Y_{1,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$) (Lanjutan)

No	Tanggal	Hasil Prediksi
15	12/15/2018	6.25148
16	12/16/2018	6.25148
17	12/17/2018	6.25164
18	12/18/2018	6.25148
19	12/19/2018	6.25148
20	12/20/2018	6.25061
21	12/21/2018	6.25043
22	12/22/2018	6.25109
23	12/23/2018	6.25062
24	12/24/2018	6.21551
25	12/25/2018	6.25140
26	12/26/2018	6.25148
27	12/27/2018	6.25148
28	12/28/2018	6.25148
29	12/29/2018	6.25148
30	12/30/2018	6.25148
31	12/31/2018	6.25148


Berdasarkan Tabel 4.16 didapatkan hasil prediksi curah hujan tertinggi terjadi pada tanggal 17 Desember 2018 yaitu sebesar 6.25164. Sehingga data tersebut nantinya akan digunakan sebagai dasar dalam memprediksi banjir genangan di Keputih pada bulan Desember 2018 dengan perhitungan matematis hidrologi.

4.2.5.2 Prediksi Curah Hujan di Pos Hujan Kedung Cowek

Prediksi curah hujan juga dilakukan di pos hujan Kedung Cowek untuk bulan Desember 2018 didasarkan pada pemodelan SVR yang terbentuk pada data *training*. Dengan melakukan tuning parameter. didapatkan model SVR kernel RBF dengan parameter optimum $\varepsilon = 0.1$, $C = 10$, dan $\gamma = 0.5$. Model *Support Vector Regression* prediksi curah hujan di pos hujan Kedung Cowek dapat dituliskan dalam persamaan sebagai berikut.

$$f(x) = \sum_{i=1}^{1351} (\alpha_i - \alpha_i^*) \exp(-0.5 \|x - x_i\|^2) - 0.1265$$

Penggunaan parameter optimum pada pemodelan SVR curah hujan di pos hujan Kedung Cowek, didapatkan jumlah *support vector* yang terbentuk adalah sebanyak 1351 data sebagaimana yang dituliskan pada nilai α_i (Lampiran 36b). Selanjutnya, juga didapatkan nilai bias sebesar -0.1265. Berikut merupakan hasil prediksi yang didapatkan dari model SVR yang telah didapatkan.



Gambar 4. 25 Time Series Plot Hasil Pemodelan SVR Kedung Cowek pada Data GCM grid 3x3

$$(Y_{2,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365}))$$

Berdasarkan Gambar 4.25 didapatkan hasil RMSE dan RMSE* untuk prediksi bulan Desember 2018 sebesar 6.1988. Hasil prediksi curah hujan Kedung Cowek disajikan pada Tabel 4.17 berikut.

Tabel 4. 17 Hasil Prediksi Curah Hujan Kedung Cowek pada Data GCM grid 3x3 ($Y_{2,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$)

No	Tanggal	Hasil Prediksi
1	12/1/2018	6.45629
2	12/2/2018	6.45626
3	12/3/2018	6.45626
4	12/4/2018	6.45629
5	12/5/2018	6.45629
6	12/6/2018	6.45629
7	12/7/2018	6.45629
8	12/8/2018	6.45629
9	12/9/2018	6.45629

Tabel 4. 17 Hasil Prediksi Curah Hujan Kedung Cowek pada Data GCM grid 3x3 ($Y_{2,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$)

(Lanjutan)

No	Tanggal	Hasil Prediksi
10	12/10/2018	6.45626
11	12/11/2018	6.45629
12	12/12/2018	6.45629
13	12/13/2018	6.45629
14	12/14/2018	6.45629
15	12/15/2018	6.45629
16	12/16/2018	6.45629
17	12/17/2018	6.45628
18	12/18/2018	6.45629
19	12/19/2018	6.45629
20	12/20/2018	6.45623
21	12/21/2018	6.45615
22	12/22/2018	6.45623
23	12/23/2018	6.45623
24	12/24/2018	6.45527
25	12/25/2018	6.45628
26	12/26/2018	6.45629
27	12/27/2018	6.45629
28	12/28/2018	6.45629
29	12/29/2018	6.45629
30	12/30/2018	6.45629
31	12/31/2018	6.45629

Berdasarkan Tabel 4.17 didapatkan hasil prediksi curah hujan tertinggi terjadi pada beberapa hari di bulan Desember 2018 yaitu sebesar 6.45629. Sehingga data tersebut nantinya akan digunakan sebagai dasar dalam memprediksi banjir genangan di Kedung Cowek pada bulan Desember 2018 dengan perhitungan matematis hidrologi.


4.2.5.3 Prediksi Curah Hujan di Pos Hujan Gubeng

Prediksi curah hujan Gubeng pada bulan Desember 2018 didasarkan pada pemodelan curah hujan dengan variabel prediktor seluruh data GCM pada grid 1x1 dan tidak melibatkannya observasi curah hujan yang nol. Dengan melakukan tuning

parameter didapatkan model SVR kernel RBF dengan parameter optimum $\varepsilon = 0.01$, $C = 10$, dan $\gamma = 1$. Model *Support Vector Regression* prediksi curah hujan di pos hujan Gubeng dapat dituliskan dalam persamaan sebagai berikut.

$$f(x) = \sum_{i=1}^{1397} (\alpha_i - \alpha_i^*) \exp(-1 \|x - x_i\|^2) + 0.0886$$

Penggunaan parameter optimum pada pemodelan SVR curah hujan di pos hujan Gubeng didapatkan jumlah support vector yang terbentuk adalah sebanyak 1397 data sebagaimana yang dituliskan pada nilai α_i (Lampiran 36c). Selanjutnya, juga didapatkan nilai bias sebesar 0.0886. Berikut merupakan hasil prediksi yang didapatkan dari model SVR yang telah didapatkan.



Gambar 4. 26 Time Series Plot Hasil Pemodelan SVR Gubeng pada Data GCM grid 3x3 ($Y_{3,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$)

Berdasarkan Gambar 4.26 didapatkan hasil RMSE dan RMSE* untuk prediksi bulan Desember 2018 sebesar 6.9735. Hasil prediksi curah hujan Gubeng disajikan pada Tabel 4.18 berikut.

Tabel 4. 18 Hasil Prediksi Curah Hujan Gubeng pada Data GCM grid 3x3 ($Y_{3,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365})$)

No	Tanggal	Hasil Prediksi
1	12/1/2018	6.88954
2	12/2/2018	6.88954
3	12/3/2018	6.88954
4	12/4/2018	6.88954

Tabel 4. 18 Hasil Prediksi Curah Hujan Gubeng pada Data GCM grid 3x3
 $(Y_{3,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365}))$

(Lanjutan)

No	Tanggal	Hasil Prediksi
5	12/5/2018	6.88954
6	12/6/2018	6.88954
7	12/7/2018	6.88954
8	12/8/2018	6.88954
9	12/9/2018	6.88954
10	12/10/2018	6.88954
11	12/11/2018	6.88954
12	12/12/2018	6.88954
13	12/13/2018	6.88954
14	12/14/2018	6.88954
15	12/15/2018	6.88954
16	12/16/2018	6.88954
17	12/17/2018	6.88954
18	12/18/2018	6.88954
19	12/19/2018	6.88954
20	12/20/2018	6.88954
21	12/21/2018	6.88954
22	12/22/2018	6.88954
23	12/23/2018	6.88954
24	12/24/2018	6.88951
25	12/25/2018	6.88954
26	12/26/2018	6.88954
27	12/27/2018	6.88954
28	12/28/2018	6.88954
29	12/29/2018	6.88954
30	12/30/2018	6.88954
31	12/31/2018	6.88954


Berdasarkan Tabel 4.18 didapatkan hasil prediksi curah hujan tertinggi terjadi hampir pada setiap tanggal di bulan Desember 2018 yaitu sebesar 6.88954. Sehingga data tersebut nantinya akan digunakan sebagai dasar dalam memprediksi banjir genangan di Gubeng pada bulan Desember 2018 dengan perhitungan matematis hidrologi.

4.2.5.4 Prediksi Curah Hujan di Pos Hujan Wonorejo

Prediksi curah hujan Wonorejo pada bulan Desember 2018 didasarkan pada pemodelan curah hujan dengan variabel prediktor seluruh data GCM pada grid 1x1 dan tidak melibatkannya observasi curah hujan yang nol. Dengan melakukan tuning parameter didapatkan model SVR kernel RBF dengan parameter optimum $\varepsilon = 0.01$, $C = 10$, dan $\gamma = 2.5$, serta jumlah support vector yang digunakan adalah sebanyak 989 data. Model *Support Vector Regression* prediksi curah hujan di pos hujan Wonorejo dapat dituliskan dalam persamaan sebagai berikut.

$$f(x) = \sum_{i=1}^{1417} (\alpha_i - \alpha_i^*) \exp(-2.5 \|x - x_i\|^2) - 0.0076$$

Penggunaan parameter optimum pada pemodelan SVR curah hujan di pos hujan Wonorejo, didapatkan jumlah support vector yang terbentuk adalah sebanyak 1417 data sebagaimana yang dituliskan pada nilai α_i (Lampiran 36d). Selanjutnya, juga didapatkan nilai bias sebesar -0.0076. Berikut merupakan hasil prediksi yang didapatkan dari model SVR yang telah didapatkan.



Gambar 4. 27 Time Series Plot Hasil Pemodelan SVR Wonorejo pada Data GCM grid 3x3

$$(Y_{4,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365}))$$

Berdasarkan Gambar 4.27 didapatkan hasil RMSE dan RMSE* untuk prediksi bulan Desember 2018 sebesar 6.6846.

Hasil prediksi curah hujan Wonorejo disajikan pada Tabel 4.18 berikut.

Tabel 4. 19 Hasil Prediksi Curah Hujan Wonorejo pada Data GCM grid 3x3

$$(Y_{4,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365}))$$

No	Tanggal	Hasil Prediksi
1	12/1/2018	5.95019
2	12/2/2018	5.95019
3	12/3/2018	5.95019
4	12/4/2018	5.95019
5	12/5/2018	5.95019
6	12/6/2018	5.95019
7	12/7/2018	5.95019
8	12/8/2018	5.95019
9	12/9/2018	5.95019
10	12/10/2018	5.95019
11	12/11/2018	5.95019
12	12/12/2018	5.95019
13	12/13/2018	5.95019
14	12/14/2018	5.95019
15	12/15/2018	5.95019
16	12/16/2018	5.95019
17	12/17/2018	5.95019
18	12/18/2018	5.95019
19	12/19/2018	5.95019
20	12/20/2018	5.95019
21	12/21/2018	5.95019
22	12/22/2018	5.95019
23	12/23/2018	5.95019
24	12/24/2018	5.95019
25	12/25/2018	5.95019
26	12/26/2018	5.95019
27	12/27/2018	5.95019
28	12/28/2018	5.95019
29	12/29/2018	5.95019
30	12/30/2018	5.95019
31	12/31/2018	5.95019

Berdasarkan Tabel 4.19 didapatkan hasil prediksi curah hujan tertinggi terjadi pada setiap hari di bulan Desember 2018


yaitu sebesar 5.95019. Sehingga data tersebut nantinya akan digunakan sebagai dasar dalam memprediksi banjir genangan di Wonorejo pada bulan Desember 2018 dengan perhitungan matematis hidrologi.

4.2.5.5 Prediksi Curah Hujan di Pos Hujan Wonokromo

Prediksi curah hujan Wonokromo pada bulan Desember 2018 didasarkan pada pemodelan curah hujan dengan variabel prediktor seluruh data GCM pada grid 1x1 dan tidak melibatkannya observasi curah hujan yang nol. Dengan melakukan tuning parameter didapatkan model SVR kernel RBF dengan parameter optimum $\varepsilon = 0.01$, $C = 10$, dan $\gamma = 1$. Model *Support Vector Regression* prediksi curah hujan di pos hujan Wonokromo dapat dituliskan dalam persamaan sebagai berikut.

$$f(x) = \sum_{i=1}^{1408} (\alpha_i - \alpha_i^*) \exp(-1 \|x - x_i\|^2) - 0.0316$$

Penggunaan parameter optimum pada pemodelan SVR curah hujan di pos hujan Wonokromo, didapatkan jumlah support vector yang terbentuk adalah sebanyak 1408 data sebagaimana yang dituliskan pada nilai α_i (Lampiran 36e). Selanjutnya, juga didapatkan nilai bias sebesar -0.0316. Berikut merupakan hasil prediksi yang didapatkan dari model SVR yang telah didapatkan.



Gambar 4. 28 Time Series Plot Hasil Pemodelan SVR Wonokromo pada Data GCM grid 3x3

$$(Y_{5,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365}))$$

Berdasarkan Gambar 4.28 didapatkan hasil RMSE dan RMSE* untuk prediksi bulan Desember 2018 sebesar 6.9238. Hasil prediksi curah hujan Wonokromo disajikan pada Tabel 4.20 berikut.

Tabel 4. 20 Hasil Prediksi Curah Hujan Wonokromo pada Data GCM grid 3x3
 $(Y_{5,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365}))$

No	Tanggal	Hasil Prediksi
1	12/1/2018	6.90232
2	12/2/2018	6.90232
3	12/3/2018	6.90232
4	12/4/2018	6.90232
5	12/5/2018	6.90232
6	12/6/2018	6.90232
7	12/7/2018	6.90232
8	12/8/2018	6.90232
9	12/9/2018	6.90232
10	12/10/2018	6.90232
11	12/11/2018	6.90232
12	12/12/2018	6.90232
13	12/13/2018	6.90232
14	12/14/2018	6.90232
15	12/15/2018	6.90232
16	12/16/2018	6.90232
17	12/17/2018	6.90232
18	12/18/2018	6.90232
19	12/19/2018	6.90232
20	12/20/2018	6.90232
21	12/21/2018	6.90232
22	12/22/2018	6.90232
23	12/23/2018	6.90232
24	12/24/2018	6.90232
25	12/25/2018	6.90232
26	12/26/2018	6.90232
27	12/27/2018	6.90232
28	12/28/2018	6.90232
29	12/29/2018	6.90232
30	12/30/2018	6.90232
31	12/31/2018	6.90232


Berdasarkan Tabel 4.20 didapatkan hasil prediksi curah hujan tertinggi terjadi pada setiap hari di bulan Desember 2018 yaitu sebesar 6.90232. Sehingga data tersebut nantinya akan digunakan sebagai dasar dalam memprediksi banjir genangan di Wonokromo pada bulan Desember 2018 dengan perhitungan matematis hidrologi.

4.2.5.6 Prediksi Curah Hujan di Pos Hujan Gunung Sari

Prediksi curah hujan Gunung Sari pada bulan Desember 2018 didasarkan pada pemodelan curah hujan dengan variabel prediktor seluruh data GCM pada grid 1x1 dan tidak melibatkannya observasi curah hujan yang nol. Dengan melakukan tuning parameter didapatkan model SVR kernel RBF dengan parameter optimum $\varepsilon = 0.01$, $C = 10$, dan $\gamma = 0.5$. Model *Support Vector Regression* prediksi curah hujan di pos hujan Gunung Sari dapat dituliskan dalam persamaan sebagai berikut.

$$f(x) = \sum_{i=1}^{1404} (\alpha_i - \alpha_i^*) \exp(-1 \|x - x_i\|^2) - 0.0850$$

Penggunaan parameter optimum pada pemodelan SVR curah hujan di pos hujan Gunung Sari, didapatkan jumlah *support vector* yang terbentuk adalah sebanyak 1404 data sebagaimana yang dituliskan pada nilai α_i (Lampiran 36f). Selanjutnya, juga didapatkan nilai bias sebesar -0.0850. Berikut merupakan hasil prediksi yang didapatkan dari model SVR yang telah didapatkan.



Gambar 4. 29 *Time Series Plot* Hasil Pemodelan SVR Gunung Sari pada Data GCM grid 3x3

$$(Y_{6,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365}))$$

Berdasarkan Gambar 4.29 didapatkan hasil RMSE dan RMSE* untuk prediksi bulan Desember 2018 sebesar 15.9182. Hasil prediksi curah hujan Gunung Sari disajikan pada Tabel 4.21 berikut.

Tabel 4. 21 Hasil Prediksi Curah Hujan Gunung Sari pada Data GCM grid 3x3

$$(Y_{6,t} = f(X_{1,t}, X_{2,t}, X_{3,t}, X_{4,t}, dummy_t, lagARIMA(1,0,0)(5,1,0)^{365}))$$

No	Tanggal	Hasil Prediksi
1	12/1/2018	6.97912
2	12/2/2018	6.97908
3	12/3/2018	6.97912
4	12/4/2018	6.97911
5	12/5/2018	6.97912
6	12/6/2018	6.97912
7	12/7/2018	6.97912
8	12/8/2018	6.97912
9	12/9/2018	6.97912
10	12/10/2018	6.97912
11	12/11/2018	6.97912
12	12/12/2018	6.97912
13	12/13/2018	6.98028
14	12/14/2018	6.97912
15	12/15/2018	6.97912
16	12/16/2018	6.97901
17	12/17/2018	6.97912
18	12/18/2018	6.97912
19	12/19/2018	6.97912
20	12/20/2018	6.97912
21	12/21/2018	6.97912
22	12/22/2018	6.97909
23	12/23/2018	6.97906
24	12/24/2018	6.97795
25	12/25/2018	6.97912
26	12/26/2018	6.97912
27	12/27/2018	6.97912
28	12/28/2018	6.97912

29	12/29/2018	6.97911
30	12/30/2018	6.97924
31	12/31/2018	6.97912

Berdasarkan Tabel 4.21 didapatkan hasil prediksi curah hujan tertinggi terjadi pada tanggal 13 Desember 2018 yaitu sebesar 6.98028. Sehingga data tersebut nantinya akan digunakan sebagai dasar dalam memprediksi banjir genangan di Gunung Sari pada bulan Desember 2018 dengan perhitungan matematis hidrologi.

4.3 Prediksi Banjir Genangan

Pada keadaan $Q_{hidrologi} > Q_{hidrolika}$, maka diprediksi bahwa suatu wilayah dapat berpotensi banjir khususnya banjir genangan. Keadaan tersebut dapat diprediksi dengan melakukan perhitungan matematis rasional pada $Q_{hidrologi}$ untuk setiap pos hujan dan $Q_{hidrolika}$ untuk setiap saluran – saluran air dan sungai yang berada disekitar pos hujan.

Sesuai dengan Persamaan (2.18), dalam perhitungan $Q_{hidrologi}$ memerlukan 3 komponen penting yaitu koefisien *run off* (C), intensitas curah hujan (I), dan luas daerah aliran (A). Dalam penelitian ini komponen yang telah ditentukan adalah koefisien *run off* (C) sebesar 0.800 dan luas daerah aliran (A) sebesar 0.25876 km². Sedangkan untuk komponen intensitas curah hujan (I) didapatkan dari data hasil prediksi curah hujan maksimum di bulan Desember 2018 yang telah disesuaikan. Berikut hasil prediksi curah hujan maksimum yang telah diperoleh dari setiap pos hujan di Kota Surabaya.

Tabel 4. 22 Hasil Prediksi Curah Hujan Maksimum di Setiap Pos Hujan


Pos Hujan	Prediksi Curah Hujan Maksimum
Pos Hujan Keputih	6.25164
Pos Hujan Kedung Cowek	6.45629
Pos Hujan Gubeng	6.88954
Pos Hujan Wonorejo	5.95019
Pos Hujan Wonokromo	6.90232

 Pos Hujan Gunung Sari

6.98028

Berdasarkan Tabel 4.22, maka dapat diketahui curah hujan tertinggi berada di wilayah Gubeng. Selanjutnya dilakukan perhitungan $Q_{hidrologi}$ untuk setiap pos hujan sesuai dengan Persamaan (2.18). Setelah didapatkan hasil $Q_{hidrologi}$ tersebut, selanjutnya dilakukan prediksi banjir genangan dengan membandingkan nilai tersebut dengan $Q_{hidrolika}$ pada setiap saluran.

Dinas Pekerjaan Umum, Bina Marga, & Pematuan Kota Surabaya telah membagi saluran air dan sungai wilayah Kota Surabaya menjadi lima rayon. Setiap rayon memiliki saluran air dan sungai (primer maupun sekunder) yang memiliki $Q_{hidrolika}$ masing-masing. Dikarenakan pos hujan tidak terletak sesuai dengan setiap rayon, maka perlu dilakukan penyesuaian atau sinkronisasi antara saluran di setiap rayon tersebut terhadap letak pos hujan di Kota Surabaya. Hal tersebut bertujuan agar didapatkan hasil prediksi banjir genangan yang sesuai untuk setiap wilayah. Berikut merupakan gambaran sinkronisasi letak enam pos hujan terhadap lima rayon dari saluran air dan sungai di Kota Surabaya yang disajikan pada Gambar 4.30 berikut.



Gambar 4. 30 Sikronisasi 5 Rayon terhadap 6 Pos Hujan di Kota Surabaya

Berdasarkan Gambar 4.30, dapat diketahui bahwa pos hujan di Surabaya terletak di empat rayon saluran air dan sungai. Berikut merupakan rincian hasil sinkronisasi antara letak pos hujan terhadap jumlah saluran air dan sungai di lima rayon Kota Surabaya yang disajikan pada Tabel 4.23.

Tabel 4. 23 Sikronisasi 5 Rayon terhadap 6 Pos Hujan di Kota Surabaya

Rayon	Pos Hujan	Jumlah Saluran
Gubeng	Keputih	47
	Kedung Cowek	
	Gubeng	
Genteng	Wonorejo	37
Jambangan	Wonokromo	31
Wiyung	Gunung Sari	18
Tandes	-	37

Tabel 4.23 menunjukkan bahwa letak pos hujan hanya terdapat pada 4 dari 5 rayon di Kota Surabaya. Sehingga pada analisis selanjutnya, saluran air dan sungai di rayon Tandes dapat diabaikan. Jadi, prediksi banjir genangan di Kota Surabaya hanya dihitung berdasarkan 133 saluran air dan sungai yang telah disesuaikan dengan pos hujan masing-masing di Kota Surabaya.

Setiap saluran akan memiliki $Q_{hidrolika}$ masing-masing. $Q_{hidrolika}$ atau debit saluran sangat dipengaruhi oleh luas penampang basah dan kecepatan aliran. Pada penelitian ini diasumsikan keseluruhan koefisien kekerasan Manning disetiap saluran adalah 0.03. Sedangkan untuk kemiringan saluran di asumsikan konstan, 0.02. Dalam praktik lapangan, nilai S pada umumnya diperoleh dari hasil pengukuran *long-section* dan *cross-section*. Selanjutnya, dilakukan perhitungan rasional $Q_{hidrolika}$ sesuai dengan Persamaan (2.22).

Pada pembahasan sebelumnya telah didapatkan $Q_{hidrologi}$ untuk setiap pos hujan dan $Q_{hidrolika}$ untuk setiap saluran air dan sungai. Selanjutnya, untuk prediksi banjir genangan dilakukan perbandingan antar kedua nilai tersebut. Jika $Q_{hidrologi} > Q_{hidrolika}$ saluran, maka dapat dikatakan saluran tersebut

berpotensi menyebabkan banjir genangan di suatu wilayah. Sehingga setelah dilakukan perhitungan secara lengkap didapatkan bahwa untuk setiap wilayah di Kota Surabaya menghasilkan nilai $Q_{hidrologi} < Q_{hidrolika}$ saluran air nya masing-masing. Hal ini dikarenakan hasil prediksi curah hujan dengan menggunakan metode SVR untuk bulan Desember 2018 pada setiap wilayah di Kota Surabaya yang dihasilkan cenderung konstan dan curah hujan maksimal yang didapatkan berkisar pada 6 mm/hari atau bisa dikatakan rendah. Selain itu, kecepatan aliran dari saluran air juga berpengaruh terhadap terjadinya banjir genangan di Kota Surabaya. Oleh sebab itu, dapat diperoleh kesimpulan bahwa pada penelitian ini tidak terdapat satupun saluran air untuk setiap wilayah di Kota Surabaya yang berpotensi terjadinya banjir genangan untuk bulan Desember 2018.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan analisis yang telah dilakukan, maka diperoleh beberapa kesimpulan sebagai berikut.

1. Karakteristik curah hujan harian di Kota Surabaya cenderung sama antar pos hujan yang ada. Selain itu dapat diketahui bahwa kejadian curah hujan fluktuatif naik turun pada rentang periode tertentu. Hal ini diduga karena pengaruh efek musim, yaitu pada bulan Mei s.d Oktober cenderung rendah sedangkan pada bulan November s.d April cenderung tinggi.
2. Model optimum *statistical downscaling* data *output* GCM untuk prediksi curah hujan di Kota Surabaya dengan metode SVR yaitu pada pemodelan curah hujan dengan menggunakan variabel prediktor data GCM pada grid 3x3 dan penambahan variabel *dummy* serta lag curah hujan dari hasil model ARIMA(1,0,0)(5,1,0)³⁶⁵ dengan didapatkan RMSE dan RMSE* terkccil di pos hujan Keputih sebesar 5.6648.
3. Hasil prediksi banjir genangan di Kota Surabaya berdasarkan prediksi curah hujan didapatkan pada bulan Desember 2018 menghasilkan curah hujan yang rendah dan tidak berpotensi adanya banjir genangan pada sejumlah 133 saluran air di Kota Surabaya.

5.2 Saran

Berdasarkan kesimpulan yang telah disebutkan, saran untuk penelitian selanjutnya adalah mengkaji lebih dalam terkait metode yang akan digunakan dalam *statistical downscaling* data *output* GCM. Selain itu, perlu dilakukan kajian mendalam lagi terkait mendapatkan prediksi curah hujan harian. Hal ini dikarenakan curah hujan harian yang terjadi tidak menentu serta banyaknya observasi data curah hujan bernilai nol.

(Halaman ini sengaja dikosongkan)

DAFTAR PUSTAKA

- Agmalaro, M. A. (2011). *Pemodelan Statistical Downscaling Data GCM menggunakan Support Vector Regression Untuk Memprediksi Curah Hujan Bulanan Indramayu*. Bogor: Institut Pertanian Bogor.
- Awad, M., & Khanna, R. (2015). *Efficient Machine Learning*. New York: Apress Media.
- Billiocta, Y. (2017). *Risma Sebut Penyebab Banjir Surabaya karena Banyak Tumpukan Sampah*. Dipetik Februari 23, 2019, dari merdeka.com: <https://www.merdeka.com/peristiwa/risma-sebut-penyebab-banjir-surabaya-karena-banyak-tumpukan-sampah.html>
- Caraka, R. E., & Tahmid, M. (2019). *Statistika Klimatologi*. Yogyakarta: Mobius.
- Chen, S.-T., Yu, P.-S., & Tang, Y.-H. (2010). Statistical Downscaling of Daily Precipitation Using Support Vector Machines and Multivariate Analysis. *Journal of Hidrology*, 385(1-4), 13-22.
- Critchfield, H. J. (1990). *General Climatology*. United State of America: Prentice-Hall, Inc.
- Dhawangkharo, M., & Riksakomara, E. (2017). Prediksi Intensitas Hujan Kota Surabaya dengan Matlab menggunakan Teknik Random Forest dan CART (Studi Kasus Kota Surabaya). *Jurnal Teknik ITS*, 6, A-94 - A-99.
- Ghosh, S., & Mujumdar, P. P. (2006). *Future Rainfall Scenario Over Orissa with GCM Projections by Statistical Downscaling*. Bangalore, India: Department of Civil Engineering, Indian Institute of Science.
- Gol. (2017). *Intensitas Curah Hujan Penyebab Surabaya Dikepung Banjir*. Dipetik Februari 23, 2019, dari ITS

- News: <https://www.its.ac.id/news/2017/11/26/intensitas-curah-hujan-penyebab-surabaya-dikepung-banjir/>
- Halik, G., Anwar, N., & Santosa, B. (2014). *Downscaling Model Iklim (NCEP/NCAR Reanalysis) Sebagai Alat Bantu dalam Memprediksi Curah Hujan Akibat Perubahan Iklim*. Surabaya: Institut Teknologi Sepuluh Nopember.
- Hewitson, B. C., & Crane, R. G. (1996). Climate Downscaling: Techniques and Application. *Climate Research*, 7, 85-95.
- Johnson, R., & Winchern, D. (2002). *Applied Multivariate Statistical Analysis* (5th ed.). New Jersey: Pearson Education International.
- Kaimuddin. (2000). *Kajian Dampak Perubahan Iklim dan Tataguna Lahan Terhadap Keseimbangan Air Wilayah Sulawesi Selatan. Studi Kasus DAS Walanae Hulu dan DAS Saddang* . Bogor: Institut Pertanian Bogor.
- Kemdikbud RI. (2010). *Keadaan Iklim Indonesia*. Dipetik Februari 19, 2019, dari Rumah Belajar: <https://my.belajar.kemdikbud.go.id/sumberbelajar/tampil/Keadaan-Iklim-Indonesia-2010/konten4.html>
- Kodoatie, R. J., & Sugiyanto. (2002). *Banjir : Beberapa Penyebab dan Metode Pengendaliannya dalam Perspektif Lingkungan*. Yogyakarta: Pustaka Pelajar.
- Lahiri, S., & Ghanta, K. (2006). The Support Vector Regression with the Parameter Tuning assisted by A Differential Evolution Techniqueurry Flow in A Pipeline. *Scientific Paper*, 14, 191-203.
- Lembang, F. K. (2013). *Pemodelan Statistical Consulting dengan Pendekatan Markov Chain Monte Carlo PCA (Studi Kasus : Data GCM Stasiun Ambon)*. Ambon: Universitas Pattimura .

- Mandasari, V. (2010). *Pra-pemrosesan Data Luaran GCM CSIRO-Mk3 dengan Metode Transformasi Wavelet Daubechies untuk Pemodelan Statistical Downscaling*. Surabaya: Statistika ITS.
- Mukid, M., & Sugito. (2013). Model Prediksi Curah Hujan dengan Pendekatan Regresi Proses Gaussian (Studi Kasus di Kabupaten Grobogan). *Media Statistika*, 6, 113-122.
- Ojemakinde, B. T. (2006). *Support Vector Regression for Non-Stationary Time Series*. Knoxville: University of Tennessee.
- Pemkot Surabaya. (2019). *Geografi*. Dipetik Februari 23, 2019, dari Web Resmi Surabaya: <https://www.surabaya.go.id/id/page/0/8227/geografi>
- Rahmadini, H. N., Azani, A. A., & Rejeki, H. A. (2019). *Distribusi Temporal Curah Hujan dan Ketersediaan Air Tanah Periode 2000-2010*. Banten: Sekolah Tinggi Meteorologi Klimatologi dan Geofisika.
- Sachindra, D., Rashid, M., Ahmed, K., & Shahid, S. (2018, Mei). Statistical Downscaling of Precipitation Using Machine Learning Techniques Downscaling with Machine Learning Techniques. *Atmospheric*, hal. 240-258.
- Sahoo, A., & Sen, D. (2017). Assessing Climate Changes in California, Using Support Vector Machine in Statistical Downscaling. *IUP Journal of Computer Sciences*, 11(4), 7-25.
- Sandhyavitri, A., Fauzi, M., Gunawan, H., Sutikno, S., Restuhadi, F., Amri, R., . . . Riza, S. (2015). *Mitigasi Bencana Banjir dan Kebakaran*. Pekanbaru, Riau: UR Press.
- Sanusi, Bueno, A., Sitanggang, I. S., & Faqih, A. (2014). Downscaling Modeling Using Support Vector

- Regression for Rainfall Prediction. *TELKOMNIKA Indonesian Journal of Electrical Engineering*, 12(8), 6423-6430.
- Singh, K., & Sihag, P. (2014). Downscaling Monthly Rainfall Using Support Vector Regression and M5P Model Tree. *Journal of Civil Engineering and Environmental Technology*, 1(5), 42-50.
- Sosrodarsono, S., & Takeda, K. (2003). *Hidrologi untuk Pengairan*. Jakarta: PT Pradnya Paramita.
- Sutikno. (2008). *Statistical Downscaling Luaran GCM dan Pemanfaatannya Untuk Peramalan Produksi Padi*. Bogor: Sekolah Pascasarjana Institut Pertanian Bogor.
- Tjasjono, B. (1999). *Klimatologi Umum*. Bandung: Institut Teknologi Bandung.
- Trzaska, S., & Schnarr, E. (2014). *A Review of Downscaling Methods for Climate Change Projections*. United States: United States Agency for International Development by Tetra Tech ARD.
- Vandal, T., Kodra, E., & Gangul, A. R. (2017). Intercomparison of Machine Learning Methods for Statistical Downscaling: The Case of Daily and Extreme Precipitation. *Theoretical and Applied Climatology*, 137(1-2), 557–570.
- Walpole, R. E., Myers, R. H., Myers, S. L., & Ye, K. (2012). *Probability and Statistics for Engineers and Scientists*. United State of America: Pearson Education, Inc.
- Wilby, R., Troni, J., Biot, Y., Tedd, L., Hewitson, B., Smith, D., & Sutton, R. (2009). A Review of Climate Risk Information for Adaptation and Development Planning. *International Journal of Climatology*, 29, 1993-1215.
- Yu, H., Chen, R., & Zhang, G. (2014). A SVM Stock Selection Model within PCA. *Procedia Computer Science*, 31, 401-412.

LAMPIRAN

Lampiran 1 Data Curah Hujan di Kota Surabaya

Tanggal	Y_1	Y_2	Y_3	Y_4	Y_5	Y_6
1/1/2009	9	6.6999	5	7	8	12
1/2/2009	0	8.3839	2	4	0	0
1/3/2009	6	7.8959	13	0	15	16
1/4/2009	0	10.2460	4	0	2	5
1/5/2009	10	21.9592	30	16	21	27
1/6/2009	0	7.9626	14	0	10	7
1/7/2009	0	0.0000	0	0	3	12
1/8/2009	0	17.7536	0	0	0	0
1/9/2009	120	51.4144	58	98	104	78
1/10/2009	9	4.4203	0	0	0	0
1/11/2009	0	6.1594	0	1	4	7
1/12/2009	12	33.9328	36	49	31	36
1/13/2009	60	37.2584	23	52	31	1
1/14/2009	0	0.3623	0	0	0	0
1/15/2009	0	0	0	0	0	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮
12/16/2018	0	0	12	0	9	4
12/17/2018	0	0	8	3	4	6
12/18/2018	0	0	4	0	2	0
12/19/2018	4	0	8	3	6	2
12/20/2018	6	0	0	0	2	0
12/21/2018	0	0	6	0	4	2
12/22/2018	0	0	0	2	0	0
12/23/2018	5	7	12	7	9	2
12/24/2018	0	0	9	6	11	7
12/25/2018	5	8	6	7	8	3
12/26/2018	0	0	4	0	2	0
12/27/2018	0	0	15	3	7	4
12/28/2018	13	20	17	7	15	12
12/29/2018	2	9	4	7	8	5
12/30/2018	0	0	0	0	0	0
12/31/2018	0	0	0	0	0	0

Lampiran 2 Data General Circulation Model (GCM)**Lampiran 2 a Data GCM : Presipitasi (*Precipitation*)**

Tanggal	PR1	PR2	PR3	PR4	PR5	PR6	PR7	PR8	PR9
1/1/2009	1.46E-05	0.00018	0.000177	7.01E-05	0.000163	0.000121	1.34E-06	4.13E-05	4.97E-05
1/2/2009	4.73E-06	0.000137	0.000101	1.38E-08	2.47E-05	8.95E-06	1.38E-08	4.8E-06	2.66E-06
1/3/2009	1.38E-08	1.95E-05	1.12E-05	1.38E-08	3.31E-05	7.66E-08	1.38E-08	2E-05	1.38E-08
1/4/2009	1.38E-08	1.29E-05	7.94E-06	1.38E-08	1.25E-05	2.66E-07	1.38E-08	2.68E-05	3.28E-07
1/5/2009	1.38E-08	8.78E-05	1.64E-05	1.38E-08	0.000114	1.38E-08	1.38E-08	9.88E-05	7.69E-07
1/6/2009	1.38E-08	0.000215	0.000121	2.26E-05	0.000254	4.76E-05	4.99E-06	0.000208	4.01E-05
1/7/2009	1.38E-08	0.000279	0.000219	1.38E-08	0.000311	0.000212	2.66E-07	0.000214	0.000186
1/8/2009	3.32E-05	0.00035	0.000343	7.63E-06	0.000357	0.00031	1.91E-05	0.000336	0.000207
1/9/2009	0.000187	0.00036	0.000492	0.000111	0.000396	0.000432	0.000112	0.000308	0.000334
1/10/2009	0.000155	0.00057	0.000807	9.06E-05	0.000615	0.000856	4.73E-05	0.000481	0.000643
1/11/2009	0.00017	0.000402	0.000266	0.000181	0.00045	0.000253	0.000115	0.000413	0.000239
1/12/2009	0.000156	0.000352	0.000455	0.000156	0.000271	0.000255	0.000123	0.000186	0.000222
1/13/2009	0.000246	0.000379	0.000306	0.000143	0.000324	0.000231	9.27E-05	0.000263	0.000241
1/14/2009	0.000295	0.000476	0.000317	0.000172	0.000372	0.000214	8.27E-05	0.000319	0.000259
1/15/2009	0.00047	0.000464	0.000124	0.000231	0.000245	5.09E-05	0.000146	0.000124	3.65E-05
:	:	:	:	:	:	:	:	:	:
12/16/2018	3.65E-05	0.000175	0.00054	9.58E-06	0.000259	0.000574	1.46E-06	0.000244	0.0004
12/17/2018	2.13E-05	0.000108	0.00044	1.23E-05	0.000295	0.000561	5.29E-05	0.000242	0.000427
12/18/2018	2.03E-05	0.000155	0.000509	0.000119	0.000321	0.000472	8.85E-05	0.000166	0.000341
12/19/2018	0.000128	0.000195	0.000494	9.71E-05	0.000196	0.0005	2.34E-05	0.000144	0.000325
12/20/2018	5.08E-05	0.000275	0.000589	3.77E-05	0.000203	0.000405	2.71E-05	0.000125	0.000205
12/21/2018	9.71E-06	0.000371	0.000697	1.18E-05	0.000349	0.000553	8.39E-06	0.000204	0.0003
12/22/2018	7.06E-07	0.000384	0.000699	1.38E-08	0.000402	0.000576	8.95E-07	0.000244	0.000426
12/23/2018	1.38E-08	0.000324	0.00075	7.32E-06	0.000363	0.000551	2.78E-06	0.000335	0.000513
12/24/2018	1.49E-05	0.000355	0.000577	1.44E-05	0.000541	0.000635	1.78E-05	0.00045	0.0005
12/25/2018	5.3E-06	6.96E-05	0.000395	2.42E-05	0.000374	0.000529	3.84E-05	0.000592	0.000651
12/26/2018	1.38E-08	5.18E-06	0.000339	1.38E-08	1.63E-05	0.000443	4.92E-06	0.000114	0.00053
12/27/2018	1.38E-08	1.88E-05	0.000412	1.38E-08	5.92E-05	0.000375	7.66E-08	7.55E-05	0.000302
12/28/2018	1.38E-08	0.000144	0.000551	1.38E-08	0.000128	0.000347	1.38E-08	8.96E-05	0.000237
12/29/2018	1.38E-08	0.000287	0.00039	1.38E-08	0.000256	0.000275	1.38E-08	0.000236	0.000234
12/30/2018	4.52E-05	0.000377	0.000249	5.37E-05	0.000273	0.000104	7.29E-05	0.000162	0.000117
12/31/2018	0.000249	0.000525	0.000551	0.0003	0.000449	0.000296	0.000241	0.000253	9.97E-05

Lampiran 2 b Data GCM : Temperatur (*Temperature Air Surface*)

Tanggal	TAS1	TAS2	TAS3	TAS4	TAS5	TAS6	TAS7	TAS8	TAS9
1/1/2009	303.3993	302.4126	301.6745	302.2961	302.3077	301.7988	302.3621	302.3272	301.8921
1/2/2009	303.5236	302.8399	302.0242	303.0147	303.0342	302.5097	302.6807	302.9370	302.7001
1/3/2009	304.1180	303.3605	302.4476	303.2944	303.2789	302.7700	302.8360	303.0885	302.8943
1/4/2009	304.1102	303.5275	302.8438	303.7334	303.4304	302.9642	303.6285	303.2595	302.9642
1/5/2009	304.6268	303.5586	302.5913	304.8910	303.6829	302.8438	304.3472	303.3954	302.7739
1/6/2009	304.0714	302.8244	302.0902	304.0674	303.0031	302.3815	303.7489	302.8050	302.4282
1/7/2009	304.1063	302.7311	301.8649	304.7628	303.0419	302.0125	304.3938	302.8671	301.9970
1/8/2009	303.5042	302.3543	301.7639	304.2695	302.6185	301.9154	303.9470	302.5369	301.8688
1/9/2009	301.3482	301.7056	301.7406	301.9892	301.9892	302.0125	302.8205	302.2417	301.8027
1/10/2009	300.8044	301.4298	301.4959	301.4337	301.7367	301.7833	302.4476	302.0475	301.7056
1/11/2009	300.7694	301.3521	301.6745	301.5541	301.6940	301.9387	302.6185	301.9348	301.7017
1/12/2009	300.7655	301.3016	301.6707	301.1385	301.6202	302.2184	301.4453	301.7717	302.2029
1/13/2009	300.7112	301.3910	301.8105	301.1501	301.5696	302.2145	302.0747	301.8727	302.1368
1/14/2009	300.6956	301.3948	302.0086	301.3133	301.7833	302.4243	302.2029	301.9542	302.1368
1/15/2009	300.4043	301.3599	302.1485	300.8898	302.0047	302.8943	301.6240	302.2417	303.0109
:	:	:	:	:	:	:	:	:	:
12/16/2018	301.0763	302.5175	302.4592	302.1096	302.8904	302.4903	303.2595	303.1934	302.4631
12/17/2018	301.2200	302.6068	302.5680	302.4825	302.9215	302.5602	303.1080	303.1390	302.4786
12/18/2018	301.2045	302.1990	302.3000	301.9270	302.5991	302.4592	302.9448	302.9370	302.4126
12/19/2018	301.5153	302.2261	302.2572	302.3932	302.7739	302.4748	303.6363	303.3100	302.3971
12/20/2018	301.8299	302.3388	302.1795	302.4748	302.8283	302.4437	303.3410	303.2905	302.4981
12/21/2018	301.7134	302.1990	302.1096	302.5175	302.6574	302.3077	303.6246	303.2517	302.4592
12/22/2018	301.7484	302.1951	302.0902	302.7739	302.7506	302.3543	303.7101	303.2128	302.4243
12/23/2018	300.9365	301.6940	301.9115	302.3000	302.4437	302.3077	303.4421	303.0109	302.4204
12/24/2018	300.5286	301.4803	301.8765	301.5386	302.0164	302.1329	302.6845	302.5175	302.1562
12/25/2018	300.5635	301.9737	302.2650	300.5286	301.9504	302.3038	301.1657	301.9620	302.0708
12/26/2018	301.5075	302.4825	302.4398	301.8144	302.7040	302.6068	301.9504	302.6418	302.1912
12/27/2018	301.7950	302.2767	302.1640	302.3466	302.6807	302.4631	302.5291	302.7234	302.4320
12/28/2018	301.9814	302.1329	302.0552	302.0397	302.3155	302.3893	302.4243	302.4126	302.3971
12/29/2018	302.7545	302.1640	302.1018	303.4382	302.4282	302.2339	303.3954	302.3000	302.2184
12/30/2018	302.1912	302.3077	302.4359	302.8283	302.4204	302.5952	303.2789	302.4670	302.5719
12/31/2018	301.1151	302.1096	302.1252	301.2434	302.2223	302.7117	301.5347	302.3038	303.0769

Lampiran 2 c Data GCM : Kelembapan Udara (*Humidity Surface*)

Tanggal	HUSS1	HUSS2	HUSS3	HUSS4	HUSS5	HUSS6	HUSS7	HUSS8	HUSS9
1/1/2009	0.01710	0.02139	0.02083	0.02029	0.02119	0.02083	0.01741	0.02140	0.02083
1/2/2009	0.01622	0.02143	0.02061	0.01818	0.02413	0.02029	0.01618	0.02965	0.02029
1/3/2009	0.01466	0.02953	0.02025	0.01686	0.02351	0.01974	0.01558	0.02261	0.01997
1/4/2009	0.01326	0.03525	0.02027	0.01564	0.02588	0.01966	0.01528	0.02290	0.01975
1/5/2009	0.01273	0.02660	0.02049	0.01498	0.02461	0.02029	0.01606	0.02191	0.02008
1/6/2009	0.01442	0.02138	0.02084	0.01769	0.02119	0.02083	0.01728	0.02141	0.02092
1/7/2009	0.01583	0.02118	0.02073	0.01541	0.02110	0.02105	0.01626	0.02155	0.02136
1/8/2009	0.01744	0.02148	0.02065	0.01525	0.02123	0.02097	0.01811	0.02160	0.02131
1/9/2009	0.01944	0.02137	0.02070	0.01846	0.02111	0.02083	0.01961	0.02107	0.02094
1/10/2009	0.01946	0.02166	0.02075	0.01983	0.02187	0.02115	0.01954	0.02167	0.02153
1/11/2009	0.01957	0.02094	0.02013	0.01963	0.02104	0.02037	0.01886	0.02138	0.02086
1/12/2009	0.01989	0.02129	0.02080	0.01997	0.02136	0.02113	0.01967	0.02106	0.02129
1/13/2009	0.01993	0.02096	0.02040	0.01992	0.02101	0.02075	0.01904	0.02114	0.02108
1/14/2009	0.01995	0.02080	0.02020	0.01984	0.02099	0.02088	0.01917	0.02134	0.02151
1/15/2009	0.01990	0.02043	0.02009	0.01988	0.02062	0.02068	0.01928	0.02094	0.02170
:	:	:	:	:	:	:	:	:	:
12/16/2018	0.01976	0.02203	0.02212	0.02013	0.02220	0.02253	0.01830	0.02359	0.02227
12/17/2018	0.01941	0.02159	0.02168	0.02018	0.02179	0.02208	0.01934	0.02157	0.02239
12/18/2018	0.02016	0.02186	0.02189	0.02089	0.02214	0.02199	0.02028	0.02215	0.02223
12/19/2018	0.02119	0.02205	0.02151	0.02151	0.02203	0.02186	0.02048	0.02235	0.02227
12/20/2018	0.02089	0.02237	0.02173	0.02143	0.02237	0.02202	0.02068	0.02241	0.02234
12/21/2018	0.01962	0.02219	0.02152	0.02054	0.02230	0.02179	0.01986	0.02240	0.02209
12/22/2018	0.01783	0.02164	0.02165	0.01897	0.02190	0.02183	0.01803	0.02241	0.02211
12/23/2018	0.01775	0.02137	0.02142	0.01860	0.02176	0.02154	0.01783	0.02210	0.02195
12/24/2018	0.01777	0.02092	0.02097	0.01865	0.02142	0.02127	0.01864	0.02181	0.02165
12/25/2018	0.01705	0.02021	0.02059	0.01843	0.02082	0.02092	0.01862	0.02139	0.02138
12/26/2018	0.01654	0.01993	0.02083	0.01688	0.02012	0.02089	0.01666	0.02079	0.02113
12/27/2018	0.01533	0.02017	0.02105	0.01577	0.02043	0.02101	0.01544	0.02083	0.02114
12/28/2018	0.01390	0.02101	0.02110	0.01406	0.02106	0.02113	0.01429	0.02114	0.02123
12/29/2018	0.01606	0.02156	0.02088	0.01618	0.02141	0.02094	0.01606	0.02147	0.02130
12/30/2018	0.01767	0.02167	0.02102	0.01890	0.02160	0.02121	0.01872	0.02181	0.02153
12/31/2018	0.01988	0.02130	0.02092	0.02002	0.02116	0.02106	0.02021	0.02153	0.02159

Lampiran 2 d Data GCM : Kecepatan Angin (*Surface Wind Speed*)

Tanggal	SFCWIND1	SFCWIND2	SFCWIND3	SFCWIND4	SFCWIND5	SFCWIND6	SFCWIND7	SFCWIND8	SFCWIND9
1/1/2009	2.40103	2.67451	3.54155	1.99703	2.26895	2.78172	1.73598	2.31246	2.83766
1/2/2009	2.02345	2.38549	2.39171	1.66606	1.72821	1.75307	1.48271	1.59769	1.50135
1/3/2009	2.54087	1.75618	1.65052	1.65985	2.10114	1.83388	1.18592	2.31868	1.47494
1/4/2009	2.91225	2.23011	2.02655	1.30402	2.86097	2.18971	0.88914	3.01946	2.37928
1/5/2009	2.08405	3.19038	3.78862	0.94974	3.82125	3.81348	0.85806	3.60992	3.44521
1/6/2009	1.82611	3.90515	5.19795	0.87360	4.74112	5.15755	0.68248	4.62303	4.57486
1/7/2009	2.22078	4.12114	5.99508	1.42366	4.84057	6.30740	0.84874	4.78463	5.53203
1/8/2009	2.21302	4.63857	6.34780	1.19835	5.61749	6.48764	0.70734	5.72937	5.71539
1/9/2009	1.58681	5.19795	6.75646	1.35529	6.27011	6.39131	0.70734	6.19552	5.26632
1/10/2009	1.55108	6.13803	8.30565	2.05141	7.35469	7.37178	1.74375	6.91651	5.76511
1/11/2009	1.83388	5.64857	6.64303	2.47406	7.33294	6.84814	2.52689	7.60020	5.89097
1/12/2009	1.55885	4.40239	6.41617	2.11668	5.10628	5.75423	2.12445	5.19795	4.90272
1/13/2009	0.64674	4.38840	7.27855	1.96440	5.81328	7.06102	2.67606	6.47366	6.62283
1/14/2009	0.80212	6.61195	10.09568	2.48028	8.04615	8.91941	3.40792	8.06635	7.32828
1/15/2009	2.27517	8.64283	10.78869	3.54311	9.19755	9.36226	3.79949	8.35071	7.39043
:	:	:	:	:	:	:	:	:	:
12/16/2018	2.48960	4.42258	5.79308	1.90069	3.58351	5.58175	1.35840	2.25652	4.51892
12/17/2018	2.16640	3.81659	5.17620	1.81367	3.54466	4.88563	1.47649	2.22234	3.51358
12/18/2018	1.69248	3.50737	4.86543	1.59925	3.44987	5.10938	1.79348	2.45541	4.19262
12/19/2018	2.01412	2.65897	6.19086	1.47494	3.09404	6.46434	1.44852	2.88738	5.51028
12/20/2018	2.52068	2.59992	7.86591	1.28226	3.70626	7.77578	0.94508	4.06831	6.77045
12/21/2018	3.35509	3.06452	8.40509	2.04209	4.24545	8.36469	1.65519	4.77686	7.50386
12/22/2018	3.38461	4.38063	8.81220	2.09958	5.03169	9.43529	1.82145	4.99129	8.20465
12/23/2018	2.62323	4.83435	8.47968	2.39171	6.16289	9.73518	2.41035	6.26078	9.03751
12/24/2018	3.07695	5.26011	8.63195	2.59215	6.33848	9.83774	2.50514	6.63371	9.37625
12/25/2018	3.70315	5.87387	9.48191	3.40326	7.39975	10.87571	3.55865	7.49143	10.06615
12/26/2018	4.21592	6.33692	9.67458	3.75599	8.13783	11.23620	4.11492	8.24349	10.13142
12/27/2018	3.81037	5.86921	9.54717	4.04034	8.38023	11.43198	3.63478	8.28856	10.91766
12/28/2018	3.49339	5.24612	9.22397	3.36752	7.22728	10.19202	3.69383	8.70498	10.16405
12/29/2018	2.79571	4.69296	8.52629	2.54243	6.00440	8.11142	2.32023	6.40374	7.66080
12/30/2018	1.17505	5.62682	9.83463	1.92400	6.38043	8.13628	1.83077	6.16134	6.58243
12/31/2018	3.98129	9.92942	11.33875	4.21126	9.81443	9.78957	3.14377	7.15735	6.70829

Lampiran 3 *Source Code* R untuk Menggabungkan Data Curah Hujan Setiap Pos Hujan

```

library(xlsx)
library(openxlsx)
library(readxl)

# Mengambil file excel keseluruhan dari 1 folder 1 file
setwd('D:/CH')
CH <- list.files()

# CH_Keputih
# Membaca seluruh data CH_Keputih dari file yang berbeda
CH_Keputih = NA
for(x in CH){
  PSAWS1 = read_excel(x, sheet = 1)
  CH_Keputih = rbind(CH_Keputih, stack(PSAWS1[2:33,2:13]))
}
CH_Keputih = CH_Keputih[complete.cases(CH_Keputih), ]
# Menghapus missing satu baris
CH_Keputih = cbind((seq(as.Date("2009/1/1"), as.Date("2018/12/31"),
"day")), CH_Keputih)
colnames(CH_Keputih) = c("Tanggal", "CH")
CH_Keputih = CH_Keputih[,1:2]
CH_Keputih = transform(CH_Keputih, CH=as.numeric(CH))
# Meng-export data hasil gabungan ke dalam xlsx
write.xlsx(CH_Keputih, file="D:/1. CH_Keputih.xlsx")
# CH_KdCowek
# Membaca seluruh data CH_KdCowek dari file yang berbeda
CH_KdCowek = NA
for(x in CH){
  PSAWS2 = read_excel(x, sheet = 2)
  CH_KdCowek = rbind(CH_KdCowek, stack(PSAWS2[2:33,2:13]))
}
CH_KdCowek = CH_KdCowek[complete.cases(CH_KdCowek), ]
# Menghapus missing satu baris
CH_KdCowek = cbind((seq(as.Date("2009/1/1"), as.Date("2018/12/31"),
"day")), CH_KdCowek)
colnames(CH_KdCowek) = c("Tanggal", "CH")
CH_KdCowek = CH_KdCowek[,1:2]
CH_KdCowek = transform(CH_KdCowek, CH=as.numeric(CH))

```

Lampiran 3 *Source Code* R untuk Menggabungkan Data Curah Hujan Setiap Pos Hujan (Lanjutan)

```
# Meng-export data hasil gabungan ke dalam xlsx
write.xlsx(CH_KdCowek, file="D:/2. CH_KdCowek.xlsx")

# CH_Simo
# Membaca seluruh data CH_Simo dari file yang berbeda
CH_Simo = NA
for(x in CH){
  PSAWS3 = read_excel(x, sheet = 3)
  CH_Simo = rbind(CH_Simo, stack(PSAWS3[2:33,2:13]))
}
CH_Simo = CH_Simo[complete.cases(CH_Simo), ]
# Menghapus missing satu baris
CH_Simo = cbind((seq(as.Date("2009/1/1"), as.Date("2018/12/31"),
"day")), CH_Simo)
colnames(CH_Simo) = c("Tanggal", "CH")
CH_Simo = CH_Simo[,1:2]
CH_Simo = transform(CH_Simo, CH=as.numeric(CH))
# Meng-export data hasil gabungan ke dalam xlsx
write.xlsx(CH_Simo, file="D:/3. CH_Simo.xlsx")

# CH_Gubeng
# Membaca seluruh data CH_Gubeng dari file yang berbeda
CH_Gubeng = NA
for(x in CH){
  PSAWS4 = read_excel(x, sheet = 4)
  CH_Gubeng = rbind(CH_Gubeng, stack(PSAWS4[2:33,2:13]))
}
CH_Gubeng = CH_Gubeng[complete.cases(CH_Gubeng), ]
# Menghapus missing satu baris
CH_Gubeng = cbind((seq(as.Date("2009/1/1"), as.Date("2018/12/31"),
"day")), CH_Gubeng)
colnames(CH_Gubeng) = c("Tanggal", "CH")
CH_Gubeng = CH_Gubeng[,1:2]
CH_Gubeng = transform(CH_Gubeng, CH=as.numeric(CH))

# Meng-export data hasil gabungan ke dalam xlsx
?write.table
write.xlsx(CH_Gubeng, file="D:/4. CH_Gubeng.xlsx")
```

Lampiran 3 *Source Code* R untuk Menggabungkan Data Curah Hujan Setiap Pos Hujan (Lanjutan)

```
# CH_Wonorejo
# Membaca seluruh data CH_Wonorejo dari file yang berbeda
CH_Wonorejo = NA
for(x in CH){
  PSAWS5 = read_excel(x, sheet = 5)
  CH_Wonorejo = rbind(CH_Wonorejo, stack(PSAWS5[2:33,2:13]))
}
CH_Wonorejo = CH_Wonorejo[complete.cases(CH_Wonorejo), ]
# Menghapus missing satu baris
CH_Wonorejo = cbind((seq(as.Date("2009/1/1"), as.Date("2018/12/31"),
"day")), CH_Wonorejo)
colnames(CH_Wonorejo) = c("Tanggal", "CH")
CH_Wonorejo = CH_Wonorejo[,1:2]
CH_Wonorejo = transform(CH_Wonorejo, CH=as.numeric(CH))
# Meng-export data hasil gabungan ke dalam xlsx
write.xlsx(CH_Wonorejo, file="D:/5. CH_Wonorejo.xlsx")

# CH_Wonokromo
# Membaca seluruh data CH_Wonokromo dari file yang berbeda
CH_Wonokromo = NA
for(x in CH){
  PSAWS6 = read_excel(x, sheet = 6)
  CH_Wonokromo = rbind(CH_Wonokromo, stack(PSAWS6[2:33,2:13]))
}
CH_Wonokromo = CH_Wonokromo[complete.cases(CH_Wonokromo), ]
# Menghapus missing satu baris
CH_Wonokromo = cbind((seq(as.Date("2009/1/1"), as.Date("2018/12/31"),
"day")), CH_Wonokromo)
colnames(CH_Wonokromo) = c("Tanggal", "CH")
CH_Wonokromo = CH_Wonokromo[,1:2]
CH_Wonokromo = transform(CH_Wonokromo, CH=as.numeric(CH))
# Meng-export data hasil gabungan ke dalam xlsx
write.xlsx(CH_Wonokromo, file="D:/6. CH_Wonokromo.xlsx")
# CH_GnSari
# Membaca seluruh data CH_GnSari dari file yang berbeda
CH_GnSari = NA
for(x in CH){
  PSAWS7 = read_excel(x, sheet = 7)
  CH_GnSari = rbind(CH_GnSari, stack(PSAWS7[2:33,2:13]))
}
```

Lampiran 3 *Source Code* R untuk Menggabungkan Data Curah Hujan Setiap Pos Hujan (Lanjutan)

```
CH_GnSari = CH_GnSari[complete.cases(CH_GnSari), ]  
# Menghapus missing satu baris  
CH_GnSari = cbind((seq(as.Date("2009/1/1"), as.Date("2018/12/31"),  
"day")), CH_GnSari)  
colnames(CH_GnSari) = c("Tanggal", "CH")  
CH_GnSari = CH_GnSari[,1:2]  
CH_GnSari = transform(CH_GnSari, CH=as.numeric(CH))  
# Meng-export data hasil gabungan ke dalam xlsx  
write.xlsx(CH_GnSari, file="D:/7. CH_GnSari.xlsx")
```

Lampiran 4 *Source Code R untuk Cropping Data GCM*

```

library(xlsx)
library(openxlsx)
library(readxl)
setwd('D:/GCM')

# PR
datapr<-read.csv("pr.csv",header = FALSE)
datapr_1<-datapr[,-1:-50]
datapr_2<-datapr_1[,-1:-9]
datapr_3<-datapr_2[,-4:-100]
datapr_4<-datapr_3[,-4:-36]
data_pr<-datapr_4[105217:455808,]
dataPR=matrix(nrow=3652,ncol=9)
for(i in 1:3652){
  dataPR[i,]=as.matrix(data_pr[(96*i-52):(96*i-50),])
}
colnames(dataPR) =
c("PR1", "PR2", "PR3", "PR4", "PR5", "PR6", "PR7", "PR8", "PR9")
# Meng-export data ke dalam xlsx
write.xlsx(dataPR, file="dataPR.xlsx")

# TAS
datatas<-read.csv("tas.csv",header = FALSE)
datatas_1<-datatas[,-1:-50]
datatas_2<-datatas_1[,-1:-9]
datatas_3<-datatas_2[,-4:-100]
datatas_4<-datatas_3[,-4:-36]
data_tas<-datatas_4[105217:455808,]
dataTAS=matrix(nrow=3652,ncol=9)
for(i in 1:3652){
  dataTAS[i,]=as.matrix(data_tas[(96*i-52):(96*i-50),])
}
colnames(dataTAS) =
c("TAS1", "TAS2", "TAS3", "TAS4", "TAS5", "TAS6", "TAS7", "TAS8", "TAS9")
# Meng-export data ke dalam xlsx
write.xlsx(dataTAS, file="dataTAS.xlsx")
# HUSS
datahuss<-read.csv("huss.csv",header = FALSE)
datahuss_1<-datahuss[,-1:-50]
datahuss_2<-datahuss_1[,-1:-9]

```

Lampiran 4 *Source Code R untuk Cropping Data GCM (Lanjutan)*

```

datahuss_3<-datahuss_2[,-4:-100]
datahuss_4<-datahuss_3[,-4:-36]
data_huss<-datahuss_4[105217:455808,]
dataHUSS=matrix(nrow=3652,ncol=9)
for(i in 1:3652){
  dataHUSS[i,]=as.matrix(data_huss[(96*i-52):(96*i-50),])
}
colnames(dataHUSS) =
c("HUSS1","HUSS2","HUSS3","HUSS4","HUSS5","HUSS6","HUSS7","
HUSS8","HUSS9")
# Meng-export data ke dalam xlsx
write.xlsx(dataHUSS, file="dataHUSS.xlsx")

# SFCWIND
datasfcWind<-read.csv("sfcWind.csv",header = FALSE)
datasfcWind_1<-datasfcWind[,-1:-50]
datasfcWind_2<-datasfcWind_1[,-1:-9]
datasfcWind_3<-datasfcWind_2[,-4:-100]
datasfcWind_4<-datasfcWind_3[,-4:-36]
data_sfcWind<-datasfcWind_4[105217:455808,]
dataSFCWIND=matrix(nrow=3652,ncol=9)
for(i in 1:3652){
  dataSFCWIND[i,]=as.matrix(data_sfcWind[(96*i-52):(96*i-50),])
}
colnames(dataSFCWIND) =
c("SFCWIND1","SFCWIND2","SFCWIND3","SFCWIND4","SFCWIND5
","SFCWIND6","SFCWIND7","SFCWIND8","SFCWIND9")
# Meng-export data ke dalam xlsx
write.xlsx(dataSFCWIND, file="dataSFCWIND.xlsx")

```


Lampiran 5 *Source Code* R untuk Menggabungkan Data Curah Hujan dan GCM

```

library(xlsx)
library(openxlsx)
library(readxl)
# Memanggil Data Cropping GCM
setwd("D:/GCM")
dataPR<-read.xlsx("dataPR.xlsx")
dataTAS<-read.xlsx("dataTAS.xlsx")
dataHUSS<-read.xlsx("dataHUSS.xlsx")
dataSFCWIND<-read.xlsx("dataSFCWIND.xlsx")

# Memanggil Data CH
setwd("D:/")
CH_Keputih<-read.xlsx("1. CH_Keputih.xlsx")
CH_KdCowek<-read.xlsx("2. CH_KdCowek.xlsx")
CH_Simo<-read.xlsx("3. CH_Simo.xlsx")
CH_Gubeng<-read.xlsx("4. CH_Gubeng.xlsx")
CH_Wonorejo<-read.xlsx("5. CH_Wonorejo.xlsx")
CH_Wonokromo<-read.xlsx("6. CH_Wonokromo.xlsx")
CH_GnSari<-read.xlsx("7. CH_GnSari.xlsx")

DAT <- cbind((seq(as.Date("2009/1/1"), as.Date("2018/12/31"), "day")),
             dataPR, dataTAS, dataHUSS,dataSFCWIND,
             CH_Keputih[2], CH_KdCowek[2], CH_Gubeng[2],
             CH_Wonorejo[2], CH_Wonokromo[2], CH_GnSari[2])

colnames(DAT) <- c("Tanggal",
                 "PR1","PR2","PR3","PR4","PR5","PR6","PR7","PR8","PR9",
                 "TAS1","TAS2","TAS3","TAS4","TAS5","TAS6","TAS7",
                 "TAS8","TAS9","HUSS1","HUSS2","HUSS3","HUSS4",
                 "HUSS5","HUSS6","HUSS7","HUSS8","HUSS9",
                 "SFCWIND1","SFCWIND2","SFCWIND3","SFCWIND4",
                 "SFCWIND5","SFCWIND6","SFCWIND7","SFCWIND8",
                 "SFCWIND9","CH_Keputih", "CH_KdCowek",
                 "CH_Gubeng", "CH_Wonorejo", CH_Wonokromo",
                 "CH_GnSari")

# Meng-export Big Data ke dalam xlsx
write.xlsx(DAT, file="D:/DAT.xlsx")

```

Lampiran 6 *Source Code R* untuk Identifikasi Missing Value

```

library(xlsx)
library(openxlsx)
library(readxl)
library(ggplot2)
library(ggthemes)
library(cowplot)
library(dplyr)
library(naniar)

setwd('D:/')
DAT<-read.xlsx("DAT.xlsx")

DAT$Tanggal<-seq(as.Date("2009/1/1"), as.Date("2018/12/31"), "day")

summary(DAT)

# Deteksi Missing Value
# Respon
DAT[,38:43] %>%
  miss_var_summary() %>%
  dplyr::mutate(missing = n_miss > 0) %>%
  ggplot(aes(x = stats::reorder(variable, n_miss),
             y = n_miss,
             colour = variable,
             fill = variable)) +
  geom_bar(stat = "identity",
           position = "dodge",
           width = 0.03) +
  geom_point(size = 3) +
  coord_flip() +
  labs(x="",
       y="Missing Value") +
  theme_minimal() +
  theme(legend.position = "none")

#Prediktor

plot_grid(
  DAT[,2:10] %>%
    miss_var_summary() %>%
    dplyr::mutate(missing = n_miss > 0) %>%

```

Lampiran 6 *Source Code R* untuk Identifikasi Missing Value (Lanjutan)

```

ggplot(aes(x = stats::reorder(variable, n_miss),
           y = n_miss,
           colour = variable,
           fill = variable)) +
ylim(0,5)+
geom_bar(stat = "identity",
         position = "dodge",
         width = 0.03) +
geom_point(size = 3) +
coord_flip() +
labs(x="",
     y="Missing Value") +
theme_minimal() +
theme(legend.position = "none"),
DAT[,11:19] %>%
miss_var_summary() %>%
dplyr::mutate(missing = n_miss > 0) %>%
ggplot(aes(x = stats::reorder(variable, n_miss),
           y = n_miss,
           colour = variable,
           fill = variable)) +
ylim(0,5)+
geom_bar(stat = "identity",
         position = "dodge",
         width = 0.03) +
geom_point(size = 3) +
coord_flip() +
labs(x="",
     y="Missing Value") +
theme_minimal() +
theme(legend.position = "none"),
DAT[,20:28] %>%
miss_var_summary() %>%
dplyr::mutate(missing = n_miss > 0) %>%
ggplot(aes(x = stats::reorder(variable, n_miss),
           y = n_miss,
           colour = variable,
           fill = variable)) +
ylim(0,5)+
geom_bar(stat = "identity",
         position = "dodge",

```

Lampiran 6 *Source Code R* untuk Identifikasi Missing Value (Lanjutan)

```
width = 0.03) +  
geom_point(size = 3) +  
coord_flip() +  
labs(x="",  
      y="Missing Value") +  
theme_minimal() +  
theme(legend.position = "none"),  
DAT[,29:37] %>%  
miss_var_summary() %>%  
dplyr::mutate(missing = n_miss > 0) %>%  
ggplot(aes(x = stats::reorder(variable, n_miss),  
           y = n_miss,  
           colour = variable,  
           fill = variable)) +  
ylim(0,5)+  
geom_bar(stat = "identity",  
         position = "dodge",  
         width = 0.03) +  
geom_point(size = 3) +  
coord_flip() +  
labs(x="",  
      y="Missing Value") +  
theme_minimal() +  
theme(legend.position = "none")  
)
```

Lampiran 7 *Source Code R* untuk Imputasi Missing Value

```
library(xlsx)
library(openxlsx)
library(readxl)
library(cowplot)
library(dplyr)
library(naniar)
library(lubridate)

setwd("D:/")
DAT<-read.xlsx("DAT.xlsx")
DAT$Tanggal<-seq(as.Date("2009/1/1"), as.Date("2018/12/31"), "day")

Im_GnSari = DAT %>%
  group_by(Bulan = month(Tanggal), Hari = day(Tanggal)) %>%
  mutate(CH_GnSari = replace(CH_GnSari, is.na(CH_GnSari),
  mean(CH_GnSari, na.rm = TRUE)))

DATA = cbind(Im_GnSari[,1:43])
summary(DATA)

# Meng-export Big Data ke dalam xlsx
write.xlsx(DATA, file="D:/DATA.xlsx")
```

Lampiran 8 *Source Code R* untuk Eksplorasi Variabel Curah Hujan

```

library(xlsx)
library(openxlsx)
library(readxl)
library(ggplot2)
library(ggthemes)
library(cowplot)
library(dplyr)
library(naniar)
library(lubridate)

setwd("D:/")
DATA<-read.xlsx("DATA.xlsx")
summary(DATA)
dummy<-read.xlsx("dummy.xlsx")
DATA<-cbind(DATA,dummy[2])
DATA$Tanggal<-seq(as.Date("2009/1/1"), as.Date("2018/12/31"), "day")

describe(DATA[-1])
a=stat.desc(DATA[-1])

write.xlsx(a, file="D:/has.xlsx")
# Time Series Plot
Kemarau = data.frame(
  from = as.Date(c("2009-05-01", "2010-05-01", "2011-05-01", "2012-05-
01", "2013-05-01","2014-05-01", "2015-05-01", "2016-05-01", "2017-05-
01", "2018-05-01")),
  to = as.Date(c("2009-10-31", "2010-10-31", "2011-10-31", "2012-10-31",
"2013-10-31","2014-10-31", "2015-10-31", "2016-10-31", "2017-10-31",
"2018-10-31"))
)
win.graph()
plot_grid(
  ggplot() +
    geom_line(data=DATA, aes(x = Tanggal, y = CH_Keputih),
    color = "cyan1") + labs(x = "") + ylim(0, 165) +
    geom_rect(data=Kemarau, aes(xmin = from, xmax = to, ymin = 0,
ymax = Inf), alpha = 0.1) + theme_minimal(base_size = 18),

```

Lampiran 8 *Source Code* R untuk Eksplorasi Variabel Curah Hujan (Lanjutan)

```

ggplot() +
  geom_line(data=DATA, aes(x = Tanggal, y = CH_KdCowek),
    color = "cyan3") + labs(x = "") + ylim(0, 165) +
  geom_rect(data=Kemarau, aes(xmin = from, xmax = to, ymin = 0,
    ymax = Inf), alpha = 0.1) + theme_minimal(base_size = 18),
ggplot() +
  geom_line(data=DATA, aes(x = Tanggal, y = CH_Gubeng),
    color = "darkcyan") + labs(x = "") + ylim(0, 165) +
  geom_rect(data=Kemarau, aes(xmin = from, xmax = to, ymin = 0,
    ymax = Inf), alpha = 0.1) + theme_minimal(base_size = 18),
ggplot() +
  geom_line(data=DATA, aes(x = Tanggal, y = CH_Wonorejo),
    color = "cyan1") + labs(x = "") + ylim(0, 165) +
  geom_rect(data=Kemarau, aes(xmin = from, xmax = to, ymin = 0,
    ymax = Inf), alpha = 0.1) + theme_minimal(base_size = 18),
ggplot() +
  geom_line(data=DATA, aes(x = Tanggal, y = CH_Wonokromo),
    color = "cyan3") + labs(x = "") + ylim(0, 165) +
  geom_rect(data=Kemarau, aes(xmin = from, xmax = to, ymin = 0,
    ymax = Inf), alpha = 0.1) + theme_minimal(base_size = 18),
ggplot() +
  geom_line(data=DATA, aes(x = Tanggal, y = CH_GnSari),
    color = "darkcyan") + labs(x = "") + ylim(0, 165) +
  geom_rect(data=Kemarau, aes(xmin = from, xmax = to, ymin = 0,
    ymax = Inf), alpha = 0.1) + theme_minimal(base_size = 18),
labels = NULL, nrow = 2, ncol = 3)

# Boxplot
Hari = strftime(DATA$Tanggal,"%d")
Bulan = strftime(DATA$Tanggal,"%b")
Tahun = strftime(DATA$Tanggal,"%Y")
month.abb =
c("Jan","Feb","Mar","Apr","May","Jun","Jul","Aug","Sep","Oct","Nov","D
ec")
win.graph()

```

Lampiran 8 *Source Code* R untuk Eksplorasi Variabel Curah Hujan (Lanjutan)

```

plot_grid(
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$CH_Keputih) +
    labs(x = "Bulan", y = "CH_Keputih") + ylim(0.00000,165) +
    geom_boxplot(color = "cyan2", fill = "cyan1") +
    theme_minimal(base_size = 17),
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$CH_KdCowek) +
    labs(x = "Bulan", y = "CH_KdCowek") + ylim(0.00000,165)+
    geom_boxplot(color = "cyan4", fill = "cyan3") +
    theme_minimal(base_size = 17),
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$CH_Gubeng) +
    labs(x = "Bulan", y = "CH_Gubeng") + ylim(0.00000,165) +
    geom_boxplot(color = "black", fill = "darkcyan") +
    theme_minimal(base_size = 17),
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$CH_Wonorejo) +
    labs(x = "Bulan", y = "CH_Wonorejo") + ylim(0.00000,165)+
    geom_boxplot(color = "cyan2", fill = "cyan1") +
    theme_minimal(base_size = 17),
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$CH_Wonokromo)
  + labs(x = "Bulan", y = "CH_Wonokromo") + ylim(0.00000,165)+
    geom_boxplot(color = "cyan4", fill = "cyan3") +
    theme_minimal(base_size = 17),
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$CH_GnSari) +
    labs(x = "Bulan", y = "CH_Gnsari") + ylim(0.00000,165)+
    geom_boxplot(color = "black", fill = "darkcyan") +
    theme_minimal(base_size = 17),
  labels = NULL, nrow = 2, ncol = 3)

```


Lampiran 9 *Source Code R* untuk Eksplorasi Variabel GCM

```
#####
# Boxplot
#####
Hari <- strptime(DATA$Tanggal,"%d")
Bulan <- strptime(DATA$Tanggal,"%b")
Tahun <- strptime(DATA$Tanggal,"%Y")
month.abb <- c("Jan", "Feb", "Mar", "Apr", "May", "Jun", "Jul", "Aug",
"Sep", "Oct", "Nov", "Dec")

#BOXPLOT GCM
# Presipitasi
win.graph()
plot_grid(
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$PR1) +
    labs(x = "Bulan", y = "PR1") + ylim(0.00000,0.00150)+
    geom_boxplot(color = "blue", fill = "cadetblue1") +
    theme_minimal(base_size = 16),
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$PR4) +
    labs(x = "Bulan", y = "PR4") + ylim(0.00000,0.00150)+
    geom_boxplot(color = "blue", fill = "cadetblue2") +
    theme_minimal(base_size = 16),
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$PR7) +
    labs(x = "Bulan", y = "PR7") + ylim(0.00000,0.00150)+
    geom_boxplot(color = "blue", fill = "cadetblue3") +
    theme_minimal(base_size = 16),
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$PR2) +
    labs(x = "Bulan", y = "PR2") + ylim(0.00000,0.00150)+
    geom_boxplot(color = "blue", fill = "cadetblue1") +
    theme_minimal(base_size = 16),
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$PR5) +
    labs(x = "Bulan", y = "PR5") + ylim(0.00000,0.00150)+
    geom_boxplot(color = "blue", fill = "cadetblue2") +
    theme_minimal(base_size = 16),
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$PR8) +
    labs(x = "Bulan", y = "PR8") + ylim(0.00000,0.00150)+
```

Lampiran 9 *Source Code R* untuk Eksplorasi Variabel GCM (Lanjutan)

```

geom_boxplot(color = "blue", fill = "cadetblue3") +
theme_minimal(base_size = 16),
ggplot(data = DATA) +
aes(x = factor(Bulan ,levels = month.abb), y = DATA$PR3) +
labs(x = "Bulan", y = "PR3") + ylim(0.00000,0.00150)+
geom_boxplot(color = "blue", fill = "cadetblue1") +
theme_minimal(base_size = 16),
ggplot(data = DATA) +
aes(x = factor(Bulan ,levels = month.abb), y = DATA$PR6) +
labs(x = "Bulan", y = "PR6") + ylim(0.00000,0.00150)+
geom_boxplot(color = "blue", fill = "cadetblue2") +
theme_minimal(base_size = 16),
ggplot(data = DATA) +
aes(x = factor(Bulan ,levels = month.abb), y = DATA$PR9) +
labs(x = "Bulan", y = "PR9") + ylim(0.00000,0.00150)+
geom_boxplot(color = "blue", fill = "cadetblue3") +
theme_minimal(base_size = 16),
labels = NULL, nrow = 3, ncol = 3)
# Temperature
win.graph()
plot_grid(
ggplot(data = DATA) +
aes(x = factor(Bulan ,levels = month.abb), y = DATA$TAS1) +
labs(x = "Bulan", y = "TAS1") + ylim(297,307)+
geom_boxplot(fill = "orange", color = "brown1") +
theme_minimal(base_size = 16),
ggplot(data = DATA) +
aes(x = factor(Bulan ,levels = month.abb), y = DATA$TAS4) +
labs(x = "Bulan", y = "TAS4") + ylim(297,307)+
geom_boxplot(fill = "orange", color = "brown2") +
theme_minimal(base_size = 16),
ggplot(data = DATA) +
aes(x = factor(Bulan ,levels = month.abb), y = DATA$TAS7) +
labs(x = "Bulan", y = "TAS7") + ylim(297,307)+
geom_boxplot(fill = "orange", color = "brown3") +
theme_minimal(base_size = 16),

```

Lampiran 9 *Source Code R* untuk Eksplorasi Variabel GCM (Lanjutan)

```

ggplot(data = DATA) +
  aes(x = factor(Bulan ,levels = month.abb), y = DATA$TAS2) +
  labs(x = "Bulan", y = "TAS2") + ylim(297,307)+
  geom_boxplot(fill = "orange", color = "brown1") +
  theme_minimal(base_size = 16),
ggplot(data = DATA) +
  aes(x = factor(Bulan ,levels = month.abb), y = DATA$TAS5) +
  labs(x = "Bulan", y = "TAS5") + ylim(297,307)+
  geom_boxplot(fill = "orange", color = "brown2") +
  theme_minimal(base_size = 16),
ggplot(data = DATA) +
  aes(x = factor(Bulan ,levels = month.abb), y = DATA$TAS8) +
  labs(x = "Bulan", y = "TAS8") + ylim(297,307)+
  geom_boxplot(fill = "orange", color = "brown3") +
  theme_minimal(base_size = 16),
ggplot(data = DATA) +
  aes(x = factor(Bulan ,levels = month.abb), y = DATA$TAS3) +
  labs(x = "Bulan", y = "TAS3") + ylim(297,307)+
  geom_boxplot(fill = "orange", color = "brown1") +
  theme_minimal(base_size = 16),
ggplot(data = DATA) +
  aes(x = factor(Bulan ,levels = month.abb), y = DATA$TAS6) +
  labs(x = "Bulan", y = "TAS6") + ylim(297,307)+
  geom_boxplot(fill = "orange", color = "brown2") +
  theme_minimal(base_size = 16),
ggplot(data = DATA) +
  aes(x = factor(Bulan ,levels = month.abb), y = DATA$TAS9) +
  labs(x = "Bulan", y = "TAS9") + ylim(297,307)+
  geom_boxplot(fill = "orange", color = "brown3") +
  theme_minimal(base_size = 16),
labels = NULL, nrow = 3, ncol = 3)

# HUSS
win.graph()
plot_grid(
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$HUSS1) +
    labs(x = "Bulan", y = "HUSS1") + ylim(0,0.06)+
    geom_boxplot(color = "orange", fill = "red1") +
    theme_minimal(base_size = 16),

```

Lampiran 9 *Source Code R* untuk Eksplorasi Variabel GCM (Lanjutan)

```

ggplot(data = DATA) +
  aes(x = factor(Bulan ,levels = month.abb), y = DATA$HUSS4) +
  labs(x = "Bulan", y = "HUSS4") + ylim(0,0.06)+
  geom_boxplot(color = "orange", fill = "red2") +
  theme_minimal(base_size = 16),
ggplot(data = DATA) +
  aes(x = factor(Bulan ,levels = month.abb), y = DATA$HUSS7) +
  labs(x = "Bulan", y = "HUSS7") + ylim(0,0.06)+
  geom_boxplot(color = "orange", fill = "red3") +
  theme_minimal(base_size = 16),
ggplot(data = DATA) +
  aes(x = factor(Bulan ,levels = month.abb), y = DATA$HUSS2) +
  labs(x = "Bulan", y = "HUSS2") + ylim(0,0.06)+
  geom_boxplot(color = "orange", fill = "red1") +
  theme_minimal(base_size = 16),
ggplot(data = DATA) +
  aes(x = factor(Bulan ,levels = month.abb), y = DATA$HUSS5) +
  labs(x = "Bulan", y = "HUSS5") + ylim(0,0.06)+
  geom_boxplot(color = "orange", fill = "red2") +
  theme_minimal(base_size = 16),
ggplot(data = DATA) +
  aes(x = factor(Bulan ,levels = month.abb), y = DATA$HUSS8) +
  labs(x = "Bulan", y = "HUSS8") + ylim(0,0.06)+
  geom_boxplot(color = "orange", fill = "red3") +
  theme_minimal(base_size = 16),
ggplot(data = DATA) +
  aes(x = factor(Bulan ,levels = month.abb), y = DATA$HUSS3) +
  labs(x = "Bulan", y = "HUSS3") + ylim(0,0.06)+
  geom_boxplot(color = "orange", fill = "red1") +
  theme_minimal(base_size = 16),
ggplot(data = DATA) +
  aes(x = factor(Bulan ,levels = month.abb), y = DATA$HUSS6) +
  labs(x = "Bulan", y = "HUSS6") + ylim(0,0.06)+
  geom_boxplot(color = "orange", fill = "red2") +
  theme_minimal(base_size = 16),
ggplot(data = DATA) +
  aes(x = factor(Bulan ,levels = month.abb), y = DATA$HUSS9) +
  labs(x = "Bulan", y = "HUSS9") + ylim(0,0.06)+
  geom_boxplot(color = "orange", fill = "red3") +
  theme_minimal(base_size = 16),
labels = NULL, nrow = 3, ncol = 3)

```

Lampiran 9 *Source Code R* untuk Eksplorasi Variabel GCM (Lanjutan)

```

#SFCWIND
win.graph()
plot_grid(
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$SFCWIND1) +
    labs(x = "Bulan", y = "SFCWIND1") + ylim(0,16)+
    geom_boxplot(color = "violet", fill = "purple1") +
    theme_minimal(base_size = 16),
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$SFCWIND4) +
    labs(x = "Bulan", y = "SFCWIND4") + ylim(0,16)+
    geom_boxplot(color = "violet", fill = "purple2") +
    theme_minimal(base_size = 16),
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$SFCWIND7) +
    labs(x = "Bulan", y = "SFCWIND7") + ylim(0,16)+
    geom_boxplot(color = "violet", fill = "purple3") +
    theme_minimal(base_size = 16),
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$SFCWIND2) +
    labs(x = "Bulan", y = "SFCWIND2") + ylim(0,16)+
    geom_boxplot(color = "violet", fill = "purple1") +
    theme_minimal(base_size = 16),
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$SFCWIND5) +
    labs(x = "Bulan", y = "SFCWIND5") + ylim(0,16)+
    geom_boxplot(color = "violet", fill = "purple2") +
    theme_minimal(base_size = 16),
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$SFCWIND8) +
    labs(x = "Bulan", y = "SFCWIND8") + ylim(0,16)+
    geom_boxplot(color = "violet", fill = "purple3") +
    theme_minimal(base_size = 16),
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$SFCWIND3) +
    labs(x = "Bulan", y = "SFCWIND3") + ylim(0,16)+
    geom_boxplot(color = "violet", fill = "purple1") +
    theme_minimal(base_size = 16),
  ggplot(data = DATA) +
    aes(x = factor(Bulan ,levels = month.abb), y = DATA$SFCWIND6) +
    labs(x = "Bulan", y = "SFCWIND6") + ylim(0,16)+

```

Lampiran 9 *Source Code R* untuk Eksplorasi Variabel GCM (Lanjutan)

```
geom_boxplot(color = "violet", fill = "purple2") +  
theme_minimal(base_size = 16),  
ggplot(data = DATA) +  
aes(x = factor(Bulan ,levels = month.abb), y = DATA$SFCWIND9) +  
labs(x = "Bulan", y = "SFCWIND9") + ylim(0,16)+  
geom_boxplot(color = "violet", fill = "purple3") +  
theme_minimal(base_size = 16),  
labels = NULL, nrow = 3, ncol = 3)
```

Lampiran 10 *Source Code* R untuk Eksplorasi Pola Hubungan Data GCM terhadap Curah Hujan

```
#scatterplot
library(ggpubr)
# Pos Hujan Hujan : CH_Keputih, Jika pos hujan yang lain, maka
CH_Keputih diganti dengan CH_KdCowek, CH_Gubeng, CH_Wonorejo,
CH_Wonokromo, CH_GnSari

# Pola Hubungan Presipitasi terhadap Curah Hujan
a=ggscatter(DATA, y = "CH_Keputih", x = "PR1",
            color = "cadetblue1", palette = c("#00AFBB"),shape = 21, size = 1,
            add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"), conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE,
cor.coeff.args = list(method = "pearson", label.sep = "\n"))
b=ggscatter(DATA, y = "CH_Keputih", x = "PR2",
            color = "cadetblue1", palette = c("#00AFBB"),shape = 21, size = 1,
            add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
            conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
c=ggscatter(DATA, y = "CH_Keputih", x = "PR3",
            color = "cadetblue1", palette = c("#00AFBB"),shape = 21, size = 1,
            add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
            conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
d=ggscatter(DATA, y = "CH_Keputih", x = "PR4",
            color = "cadetblue2", palette = c("#00AFBB"),shape = 21, size = 1,
            add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
            conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
e=ggscatter(DATA, y = "CH_Keputih", x = "PR5",
            color = "cadetblue2", palette = c("#00AFBB"),shape = 21, size = 1,
            add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
            conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
```

Lampiran 10 *Source Code* R untuk Eksplorasi Pola Hubungan Data GCM terhadap Curah Hujan (Lanjutan)

```
f=ggscatter(DATA, y = "CH_Keputih", x = "PR6",
  color = "cadetblue2", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
g=ggscatter(DATA, y = "CH_Keputih", x = "PR7",
  color = "cadetblue3", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
h=ggscatter(DATA, y = "CH_Keputih", x = "PR8",
  color = "cadetblue3", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
i=ggscatter(DATA, y = "CH_Keputih", x = "PR9",
  color = "cadetblue3", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
win.graph()
plot_grid(a,b,c,d,e,f,g,h,i,nrow=3)

# Pola Hubungan Temperatur terhadap Curah Hujan
a=ggscatter(DATA, y = "CH_Keputih", x = "TAS1",
  color = "red1", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"red", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
```


Lampiran 10 *Source Code* R untuk Eksplorasi Pola Hubungan Data GCM terhadap Curah Hujan (Lanjutan)

```

b=ggscatter(DATA, y = "CH_Keputih", x = "TAS2",
  color = "red1", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"red", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
c=ggscatter(DATA, y = "CH_Keputih", x = "TAS3",
  color = "red1", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"red", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
d=ggscatter(DATA, y = "CH_Keputih", x = "TAS4",
  color = "red2", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"red", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
e=ggscatter(DATA, y = "CH_Keputih", x = "TAS5",
  color = "red2", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"red", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
f=ggscatter(DATA, y = "CH_Keputih", x = "TAS6",
  color = "red2", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"red", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
g=ggscatter(DATA, y = "CH_Keputih", x = "TAS7",
  color = "red3", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"red", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))

```

Lampiran 10 *Source Code* R untuk Eksplorasi Pola Hubungan Data GCM terhadap Curah Hujan (Lanjutan)

```

h=ggscatter(DATA, y = "CH_Keputih", x = "TAS8",
            color = "red3", palette = c("#00AFBB"),shape = 21, size = 1,
            add = "reg.line", cor.method = "pearson",add.params = list(color =
"red", fill = "grey"),
            conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
i=ggscatter(DATA, y = "CH_Keputih", x = "TAS9",
            color = "red3", palette = c("#00AFBB"),shape = 21, size = 1,
            add = "reg.line", cor.method = "pearson",add.params = list(color =
"red", fill = "grey"),
            conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
win.graph()
plot_grid(a,b,c,d,e,f,g,h,i,nrow=3)

# Pola Hubungan Kelembapan Udara terhadap Curah Hujan
a=ggscatter(DATA, y = "CH_Keputih", x = "HUSS1",
            color = "orange1", palette = c("#00AFBB"),shape = 21, size = 1,
            add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
            conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
b=ggscatter(DATA, y = "CH_Keputih", x = "HUSS2",
            color = "orange1", palette = c("#00AFBB"),shape = 21, size = 1,
            add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
            conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
c=ggscatter(DATA, y = "CH_Keputih", x = "HUSS3",
            color = "orange1", palette = c("#00AFBB"),shape = 21, size = 1,
            add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
            conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))

```

Lampiran 10 *Source Code* R untuk Eksplorasi Pola Hubungan Data GCM terhadap Curah Hujan (Lanjutan)

```

d=ggscatter(DATA, y = "CH_Keputih", x = "HUSS4",
  color = "orange2", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
e=ggscatter(DATA, y = "CH_Keputih", x = "HUSS5",
  color = "orange2", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
f=ggscatter(DATA, y = "CH_Keputih", x = "HUSS6",
  color = "orange2", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
g=ggscatter(DATA, y = "CH_Keputih", x = "HUSS7",
  color = "orange3", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
h=ggscatter(DATA, y = "CH_Keputih", x = "HUSS8",
  color = "orange3", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
i=ggscatter(DATA, y = "CH_Keputih", x = "HUSS9",
  color = "orange3", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
win.graph()

plot_grid(a,b,c,d,e,f,g,h,i,nrow=3)

```

Lampiran 10 *Source Code* R untuk Eksplorasi Pola Hubungan Data GCM terhadap Curah Hujan (Lanjutan)

```
# Pola Hubungan Kecepatan Udara terhadap Curah Hujan
a=ggscatter(DATA, y = "CH_Keputih", x = "SFCWIND1",
  color = "purple1", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
b=ggscatter(DATA, y = "CH_Keputih", x = "SFCWIND2",
  color = "purple1", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
c=ggscatter(DATA, y = "CH_Keputih", x = "SFCWIND3",
  color = "purple1", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
d=ggscatter(DATA, y = "CH_Keputih", x = "SFCWIND4",
  color = "purple2", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
e=ggscatter(DATA, y = "CH_Keputih", x = "SFCWIND5",
  color = "purple2", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
f=ggscatter(DATA, y = "CH_Keputih", x = "SFCWIND6",
  color = "purple2", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
```

Lampiran 10 *Source Code* R untuk Eksplorasi Pola Hubungan Data GCM terhadap Curah Hujan (Lanjutan)

```

g=ggscatter(DATA, y = "CH_Keputih", x = "SFCWIND7",
  color = "purple3", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
h=ggscatter(DATA, y = "CH_Keputih", x = "SFCWIND8",
  color = "purple3", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
i=ggscatter(DATA, y = "CH_Keputih", x = "SFCWIND9",
  color = "purple3", palette = c("#00AFBB"),shape = 21, size = 1,
  add = "reg.line", cor.method = "pearson",add.params = list(color =
"blue", fill = "grey"),
  conf.int = TRUE, cor.coef.size = 8,cor.coef = TRUE, cor.coeff.args
= list(method = "pearson", label.sep = "\n"))
win.graph()
plot_grid(a,b,c,d,e,f,g,h,i,nrow=3)

```

Lampiran 11 *Source Code R* untuk Tuning Parameter SVR

```

library(xlsx)
library(openxlsx)
library(readxl)
library(e1071)

setwd("D:/")
DATA<-read.xlsx("DATA.xlsx")
DATA$Tanggal<-seq(as.Date("2009/1/1"), as.Date("2018/12/31"), "day")
dummy<-read.xlsx("dummy.xlsx")
# n_train = jumlah data training
DATA_TRAIN<-cbind(DATA[1: n_train,],dummy[1: n_train,2])
dimnames(DATA_TRAIN)

#####
Y1=DATA_TRAIN$CH_Keputih
Y2=DATA_TRAIN$CH_KdCowek
Y3=DATA_TRAIN$CH_Gubeng
Y4=DATA_TRAIN$CH_Wonorejo
Y5=DATA_TRAIN$CH_Wonokromo
Y6=DATA_TRAIN$CH_GnSari

X1=DATA_TRAIN[,2:10]
X2=DATA_TRAIN[,11:19]
X3=DATA_TRAIN[,20:28]
X4=DATA_TRAIN[,29:37]

X15=DATA_TRAIN[,6]
X25=DATA_TRAIN[,15]
X35=DATA_TRAIN[,24]
X45=DATA_TRAIN[,33]

DUMMY=DATA_TRAIN$dummy[1: n_train, 2]

data.pca <- prcomp(X1)
summary(data.pca)
data.pca
PCAX1=as.data.frame(data.pca$x)
X1PC1=PCAX1$PC1
X1PC2=PCAX1$PC2

```

Lampiran 11 *Source Code R* untuk Tuning Parameter SVR (Lanjutan)

```

data.pca <- prcomp(X2)
summary(data.pca)
data.pca
PCAX2=as.data.frame(data.pca$x)
X2PC1=PCAX2$PC1
X2PC2=PCAX2$PC2

data.pca <- prcomp(X3)
summary(data.pca)
data.pca
PCAX3=as.data.frame(data.pca$x)
X3PC1=PCAX3$PC1
X3PC2=PCAX3$PC2

data.pca <- prcomp(X4)
summary(data.pca)
data.pca
PCAX4=as.data.frame(data.pca$x)
X4PC1=PCAX4$PC1
X4PC2=PCAX4$PC2

# Prediktor = variabel prediktor yang digunakan
#####
Model = cbind.data.frame(Y1, Prediktor)
DATAREG = Model

# Epsilon = 0.1, 0.01
kombinasi=matrix(ncol=3,nrow=200)
mse=matrix(ncol=1,nrow=200)
rmse=matrix(ncol=1,nrow=200)

for(i in 1:20){
  for(j in 1:10){
    regmm=svm(Y1~.,data=DATAREG,type="eps",kernel="radial",epsilon
= Epsilon,cost=i*5,gamma=j*0.5)
    a=predict(regmm,DATAREG)
    kombinasi[10*(i-1)+j,1]=Epsilon
    kombinasi[10*(i-1)+j,2]=i*5
  }
}

```

Lampiran 11 Source Code R untuk Tuning Parameter SVR (Lanjutan)

```
kombinasi[10*(i-1)+j,3]=j*0.5
mse[10*(i-1)+j,]=mean((DATAREG$Y1 - a)^2)
rmse[10*(i-1)+j,]=sqrt(mean((DATAREG$Y1 - a)^2))
}
}
Tune.Epsilon.Model= cbind(kombinasi,mse,rmse)

# Meng-export data ke dalam xlsx
write.xlsx(Tune.Epsilon.Model, file="D:/Tune.Epsilon.Model.xlsx")
```


Lampiran 12 Hasil Pemodelan setelah Tuning Parameter

```

library(xlsx)
library(openxlsx)
library(readxl)
library(ggplot2)
library(ggthemes)
library(cowplot)
library(e1071)

setwd("D:/")
DATA<-read.xlsx("DATA.xlsx")
DATA$Tanggal<-seq(as.Date("2009/1/1"), as.Date("2018/12/31"), "day")
dummy<-read.xlsx("dummy.xlsx")
dummy = dummy[1:3652,2]

Y1=DATA$CH_Keputih
Y2=DATA$CH_KdCowek
Y3=DATA$CH_Gubeng
Y4=DATA$CH_Wonorejo
Y5=DATA$CH_Wonokromo
Y6=DATA$CH_GnSari

X1=DATA[,2:10]
X2=DATA[,11:19]
X3=DATA[,20:28]
X4=DATA[,29:37]

X15=DATA[,6]
X25=DATA[,15]
X35=DATA[,24]
X45=DATA[,33]

DATAFULL1GRID = cbind.data.frame(Y1,X15,X25,X35,X45)
DATAFULL9GRID = cbind.data.frame(Y1,X1,X2,X3,X4)

DATA_TRAIN1GRID = DATAFULL1GRID[1: n_train,]
DATA_TRAIN9GRID = DATAFULL9GRID[1: n_train,]

DATA_TEST1GRID = DATAFULL1GRID[n_train+1:3652,]
DATA_TEST9GRID = DATAFULL9GRID[n_train+1:3652,]

```

Lampiran 12 Hasil Pemodelan setelah Tuning Parameter (Lanjutan)

```
Y1=DATA$CH_Keputih
Y2=DATA$CH_KdCowek
Y3=DATA$CH_Gubeng
Y4=DATA$CH_Wonorejo
Y5=DATA$CH_Wonokromo
Y6=DATA$CH_GnSari

X1=DATA[,2:10]
X2=DATA[,11:19]
X3=DATA[,20:28]
X4=DATA[,29:37]

data.pca <- prcomp(X1)
summary(data.pca)
data.pca
PCAX1=as.data.frame(data.pca$x)
X1PC1=PCAX1$PC1
X1PC2=PCAX1$PC2

data.pca <- prcomp(X2)
summary(data.pca)
data.pca
PCAX2=as.data.frame(data.pca$x)
X2PC1=PCAX2$PC1
X2PC2=PCAX2$PC2

data.pca <- prcomp(X3)
summary(data.pca)
data.pca
PCAX3=as.data.frame(data.pca$x)
X3PC1=PCAX3$PC1
X3PC2=PCAX3$PC2

data.pca <- prcomp(X4)
summary(data.pca)
data.pca
PCAX4=as.data.frame(data.pca$x)
X4PC1=PCAX4$PC1
X4PC2=PCAX4$PC2
```

Lampiran 12 Hasil Pemodelan setelah Tuning Parameter (Lanjutan)

```

# Y diganti sesuai dengan pos curah hujan yang diprediksi
DATAPCYX1X2X3X4=cbind.data.frame(Y,X1PC1,X1PC2,
                                   X2PC1,X2PC2,
                                   X3PC1,X3PC2,
                                   X4PC1,X4PC2)

DATA_TRAIN9GRIDPCA = DATAPCYX1X2X3X4[1:3287,]
DATA_TEST9GRIDPCA = DATAPCYX1X2X3X4[3288:3652,]
GRIDtr = DATA_TRAIN1GRID
GRIDte = DATA_TEST1GRID

DATAREG = cbind.data.frame(GRIDtr[,c(1,2)])
DATATEST = cbind.data.frame(GRIDte[,c(1,2)])

## Model Training

# Epsilon = 0.1, 0.01
# Cost = cost optimum hasil tuning parameter
# Gamma = gamma optimum hasil tuning parameter
modelsvm = svm(Y1~.,DATAREG,type="eps-regression",kernel="radial",
               cost=Cost,epsilon = Epsilon,gamma= Gamma)

predYsvm = predict(modelsvm, DATAREG)

mse=mean((predYsvm - DATAREG$Y)^2)
rmse=sqrt(mse)
rmse

nol = matrix(ncol=1,nrow=length(predYsvm))
nol[] = 0
df = cbind.data.frame(nol,predYsvm)
predYsvmbaru = do.call(pmax,df)
msebaru=mean((predYsvmbaru - DATAREG$Y1)^2)
rmsebaru=sqrt(msebaru)
rmsebaru

win.graph()
plot(y=DATA_TRAIN$CH_Keputih,x=DATA_TRAIN$Tanggal,
     xlab="", ylab="CH_Keputih",
     col="navy",type="l")

```

Lampiran 12 Hasil Pemodelan setelah Tuning Parameter (Lanjutan)

```

points(y=predYsvm,x=DATA_TRAIN$Tanggal,col="red")
legend("topleft",paste("RMSE =",round(rmse,4)))
legend("topright",paste("RMSE* =",round(rmsebaru,4)))

## Model Testing

predYsvm = predict(modelsvm, DATATEST)

mse=mean((predYsvm - DATATEST$Y1)^2)
rmse=sqrt(mse)
rmse


nol = matrix(ncol=1,nrow=length(predYsvm))
nol[] = 0
df = cbind.data.frame(nol,predYsvm)
predYsvmbaru = do.call(pmax,df)
msebaru=mean((predYsvmbaru - DATATEST$Y1)^2)
rmsebaru=sqrt(msebaru)
rmsebaru

win.graph()
plot(y=DATA_TEST$CH_Keputih,x=DATA_TEST$Tanggal,
     xlab="", ylab="CH_Keputih",
     col="navy",type="l")
points(y=predYsvm,x=DATA_TEST$Tanggal,col="red")
legend("topleft",paste("RMSE =",round(rmse,4)))
legend("topright",paste("RMSE* =",round(rmsebaru,4)))


```

Lampiran 13 Eksplorasi Pola Hubungan di Pos Hujan Kedung Cowek


Lampiran 13 a Pola Hubungan Presipitasi terhadap Curah Hujan




Lampiran 13 b Pola Hubungan Temperatur terhadap Curah Hujan




Lampiran 13 c Pola Hubungan Kelembapan Udara terhadap Curah Hujan




Lampiran 13 d Pola Hubungan Kecepatan Angin terhadap Curah Hujan




Lampiran 14 Eksplorasi Pola Hubungan di Pos Hujan Gubeng
Lampiran 14 a Pola Hubungan Presipitasi terhadap Curah Hujan




Lampiran 14 b Pola Hubungan Temperatur terhadap Curah Hujan




Lampiran 14 c Pola Hubungan Kelembapan Udara terhadap Curah Hujan




Lampiran 14 d Pola Hubungan Kecepatan Angin terhadap Curah Hujan




Lampiran 15 Eksplorasi Pola Hubungan di Pos Hujan Wonorejo
Lampiran 15 a Pola Hubungan Presipitasi terhadap Curah Hujan




Lampiran 15 b Pola Hubungan Temperatur terhadap Curah Hujan



Lampiran 15 c Pola Hubungan Kelembapan Udara terhadap Curah Hujan




Lampiran 15 d Pola Hubungan Kecepatan Angin terhadap Curah Hujan




Lampiran 16 Eksplorasi Pola Hubungan di Pos Hujan Wonokromo


Lampiran 16 a Pola Hubungan Presipitasi terhadap Curah Hujan




Lampiran 16 b Pola Hubungan Temperatur terhadap Curah Hujan



Lampiran 16 c Pola Hubungan Kelembapan Udara terhadap Curah Hujan




Lampiran 16 d Pola Hubungan Kecepatan Angin terhadap Curah Hujan




Lampiran 17 Eksplorasi Pola Hubungan di Pos Hujan Gunung Sari


Lampiran 17 a Pola Hubungan Presipitasi terhadap Curah Hujan




Lampiran 17 b Pola Hubungan Temperatur terhadap Curah Hujan



Lampiran 17 c Pola Hubungan Kelembapan Udara terhadap Curah Hujan



Lampiran 17 d Pola Hubungan Kecepatan Angin terhadap Curah Hujan



Lampiran 18 Hasil Keputusan Korelasi Antar Variabel Prediktor terhadap Curah Hujan di Pos Hujan Kedung Cowek

Variabel Prediktor	<i>r-pearson</i>	<i>p-value</i>	Keputusan
X ₁₁	0.14	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₁₂	0.15	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₁₃	0.11	1.8×10^{-10}	Tolak H ₀
X ₁₄	0.14	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₁₅	0.15	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₁₆	0.13	3.2×10^{-16}	Tolak H ₀
X ₁₇	0.14	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₁₈	0.16	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₁₉	0.15	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₂₁	-0.036	3.1×10^{-2}	Tolak H ₀
X ₂₂	-0.14	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₂₃	-0.1	9.2×10^{-10}	Tolak H ₀
X ₂₄	-0.041	1.4×10^{-2}	Tolak H ₀
X ₂₅	-0.1	3.7×10^{-10}	Tolak H ₀
X ₂₆	-0.00058	9.7×10^{-1}	Gagal Tolak H ₀
X ₂₇	-0.011	5×10^{-1}	Gagal Tolak H ₀
X ₂₈	-0.076	4.9×10^{-6}	Tolak H ₀
X ₂₉	0.0094	5.7×10^{-1}	Gagal Tolak H ₀
X ₃₁	0.19	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₃₂	-0.068	4.4×10^{-5}	Tolak H ₀
X ₃₃	-0.016	3.2×10^{-1}	Gagal Tolak H ₀
X ₃₄	0.2	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₃₅	-0.037	3.6×10^{-2}	Tolak H ₀
X ₃₆	0.041	4.1×10^{-2}	Tolak H ₀
X ₃₇	0.2	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₃₈	-0.037	2.7×10^{-2}	Tolak H ₀
X ₃₉	0.1	6.2×10^{-10}	Tolak H ₀
X ₄₁	-0.19	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₄₂	0.073	1.1×10^{-5}	Tolak H ₀
X ₄₃	0.057	6.1×10^{-4}	Tolak H ₀
X ₄₄	-0.14	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₄₅	0.094	1.1×10^{-8}	Tolak H ₀
X ₄₆	0.052	1.7×10^{-3}	Tolak H ₀
X ₄₇	-0.12	1.2×10^{-12}	Tolak H ₀
X ₄₈	0.085	2.7×10^{-7}	Tolak H ₀
X ₄₉	0.05	2.6×10^{-3}	Tolak H ₀

Lampiran 19 Hasil Keputusan Korelasi Antar Variabel Prediktor terhadap Curah Hujan di Pos Hujan Gubeng

Variabel Prediktor	<i>r-pearson</i>	<i>p-value</i>	Keputusan
X ₁₁	0.16	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₁₂	0.17	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₁₃	0.12	4.0×10^{-13}	Tolak H ₀
X ₁₄	0.16	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₁₅	0.17	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₁₆	0.16	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₁₇	0.15	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₁₈	0.17	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₁₉	0.16	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₂₁	-0.039	1.7×10^{-2}	Tolak H ₀
X ₂₂	-0.13	5.0×10^{-15}	Tolak H ₀
X ₂₃	-0.085	2.6×10^{-7}	Tolak H ₀
X ₂₄	-0.034	3.8×10^{-2}	Tolak H ₀
X ₂₅	-0.092	2.9×10^{-8}	Tolak H ₀
X ₂₆	0.013	4.3×10^{-1}	Gagal Tolak H ₀
X ₂₇	0.0027	8.7×10^{-1}	Gagal Tolak H ₀
X ₂₈	-0.057	6.0×10^{-4}	Tolak H ₀
X ₂₉	0.026	1.2×10^{-1}	Gagal Tolak H ₀
X ₃₁	0.2	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₃₂	-0.063	1.4×10^{-4}	Tolak H ₀
X ₃₃	0.0057	7.3×10^{-1}	Gagal Tolak H ₀
X ₃₄	0.2	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₃₅	0.032	5.3×10^{-2}	Gagal Tolak H ₀
X ₃₆	0.053	1.3×10^{-3}	Tolak H ₀
X ₃₇	0.19	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₃₈	-0.016	3.5×10^{-1}	Gagal Tolak H ₀
X ₃₉	0.12	5.5×10^{-13}	Tolak H ₀
X ₄₁	-0.19	$< 2.2 \times 10^{-16}$	Tolak H ₀
X ₄₂	0.094	1.2×10^{-8}	Tolak H ₀
X ₄₃	0.069	2.9×10^{-5}	Tolak H ₀
X ₄₄	-0.13	3.9×10^{-16}	Tolak H ₀
X ₄₅	0.11	8.0×10^{-11}	Tolak H ₀
X ₄₆	0.058	4.1×10^{-4}	Tolak H ₀
X ₄₇	-0.11	7.7×10^{-12}	Tolak H ₀
X ₄₈	0.095	7.7×10^{-9}	Tolak H ₀
X ₄₉	0.048	3.4×10^{-3}	Tolak H ₀

Lampiran 20 Hasil Keputusan Korelasi Antar Variabel Prediktor terhadap Curah Hujan di Pos Hujan Wonorejo

Variabel Prediktor	<i>r-pearson</i>	<i>p-value</i>	Keputusan
X ₁₁	0.13	4.3 x10 ⁻¹⁵	Tolak H ₀
X ₁₂	0.17	<2.2 x10 ⁻¹⁶	Tolak H ₀
X ₁₃	0.092	2.4 x10 ⁻⁸	Tolak H ₀
X ₁₄	0.14	<2.2 x10 ⁻¹⁶	Tolak H ₀
X ₁₅	0.16	<2.2 x10 ⁻¹⁶	Tolak H ₀
X ₁₆	0.11	3.9 x10 ⁻¹²	Tolak H ₀
X ₁₇	0.13	1.1 x10 ⁻¹⁵	Tolak H ₀
X ₁₈	0.15	<2.2 x10 ⁻¹⁶	Tolak H ₀
X ₁₉	0.12	4.8 x10 ⁻¹⁴	Tolak H ₀
X ₂₁	-0.033	4.4 x10 ⁻²	Tolak H ₀
X ₂₂	-0.13	6.6 x10 ⁻¹⁵	Tolak H ₀
X ₂₃	-0.086	2.2 x10 ⁻⁷	Tolak H ₀
X ₂₄	-0.035	3.4 x10 ⁻²	Tolak H ₀
X ₂₅	-0.098	2.6 x10 ⁻⁹	Tolak H ₀
X ₂₆	0.0011	9.5 x10 ⁻¹	Gagal Tolak H ₀
X ₂₇	-0.0032	8.5 x10 ⁻¹	Gagal Tolak H ₀
X ₂₈	-0.068	3.5 x10 ⁻⁵	Tolak H ₀
X ₂₉	0.016	3.4 x10 ⁻¹	Gagal Tolak H ₀
X ₃₁	0.19	<2.2 x10 ⁻¹⁶	Tolak H ₀
X ₃₂	-0.061	2.2 x10 ⁻⁴	Tolak H ₀
X ₃₃	-0.016	3.2 x10 ⁻¹	Gagal Tolak H ₀
X ₃₄	0.19	<2.2 x10 ⁻¹⁶	Tolak H ₀
X ₃₅	-0.041	1.4 x10 ⁻²	Tolak H ₀
X ₃₆	0.042	1.1 x10 ⁻²	Tolak H ₀
X ₃₇	0.18	<2.2 x10 ⁻¹⁶	Tolak H ₀
X ₃₈	-0.033	4.4 x10 ⁻²	Tolak H ₀
X ₃₉	0.094	1.5 x10 ⁻⁸	Tolak H ₀
X ₄₁	-0.18	<2.2 x10 ⁻¹⁶	Tolak H ₀
X ₄₂	0.068	3.5 x10 ⁻⁵	Tolak H ₀
X ₄₃	0.055	9.1 x10 ⁻⁴	Tolak H ₀
X ₄₄	-0.13	3.5 x10 ⁻¹⁵	Tolak H ₀
X ₄₅	0.082	7.5 x10 ⁻⁷	Tolak H ₀
X ₄₆	0.036	2.9 x10 ⁻²	Tolak H ₀
X ₄₇	-0.11	6.1 x10 ⁻¹²	Tolak H ₀
X ₄₈	0.068	3.7 x10 ⁻⁵	Tolak H ₀
X ₄₉	0.027	9.8 x10 ⁻²	Gagal Tolak H ₀

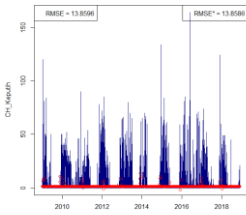
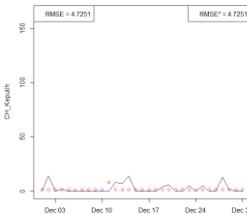
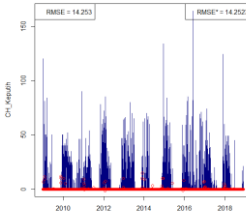
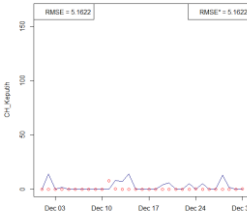
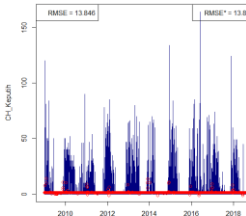
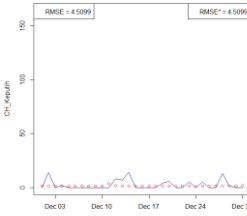
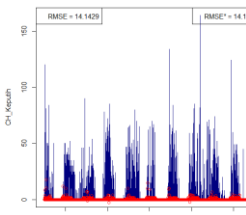
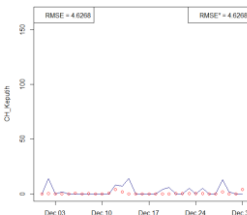
Lampiran 21 Hasil Keputusan Korelasi Antar Variabel Prediktor terhadap Curah Hujan di Pos Hujan Wonokromo

Variabel Prediktor	<i>r-pearson</i>	<i>p-value</i>	Keputusan
X ₁₁	0.16	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₁₂	0.17	2.2×10^{-16}	Tolak H ₀
X ₁₃	0.11	1.3×10^{-11}	Tolak H ₀
X ₁₄	0.17	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₁₅	0.17	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₁₆	0.14	2.4×10^{-16}	Tolak H ₀
X ₁₇	0.16	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₁₈	0.17	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₁₉	0.14	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₂₁	-0.035	3.4×10^{-2}	Tolak H ₀
X ₂₂	-0.15	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₂₃	-0.11	3.8×10^{-12}	Tolak H ₀
X ₂₄	-0.033	4.9×10^{-2}	Tolak H ₀
X ₂₅	-0.11	3.5×10^{-11}	Tolak H ₀
X ₂₆	-0.014	4.1×10^{-1}	Gagal Tolak H ₀
X ₂₇	-0.0011	9.5×10^{-1}	Gagal Tolak H ₀
X ₂₈	-0.079	1.9×10^{-6}	Tolak H ₀
X ₂₉	0.0047	7.8×10^{-1}	Gagal Tolak H ₀
X ₃₁	0.19	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₃₂	-0.061	2.0×10^{-4}	Tolak H ₀
X ₃₃	-0.021	2.1×10^{-1}	Gagal Tolak H ₀
X ₃₄	0.2	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₃₅	-0.041	1.4×10^{-2}	Tolak H ₀
X ₃₆	0.043	8.7×10^{-3}	Tolak H ₀
X ₃₇	0.19	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₃₈	-0.026	1.2×10^{-1}	Gagal Tolak H ₀
X ₃₉	0.099	2.0×10^{-9}	Tolak H ₀
X ₄₁	-0.18	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₄₂	0.094	1.4×10^{-8}	Tolak H ₀
X ₄₃	0.074	7.5×10^{-6}	Tolak H ₀
X ₄₄	-0.14	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₄₅	0.098	2.5×10^{-9}	Tolak H ₀
X ₄₆	0.057	5.4×10^{-4}	Tolak H ₀
X ₄₇	-0.13	6.9×10^{-15}	Tolak H ₀
X ₄₈	0.08	1.4×10^{-6}	Tolak H ₀
X ₄₉	0.043	9.9×10^{-3}	Tolak H ₀

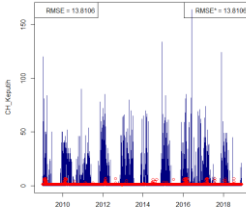
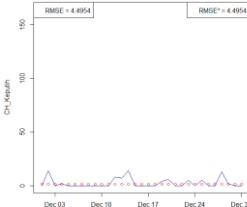
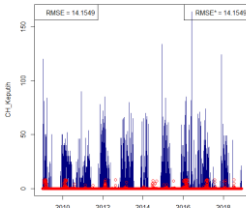
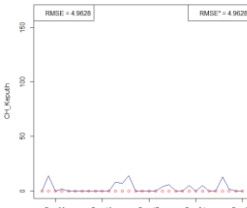
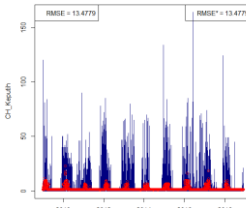
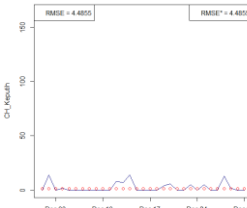
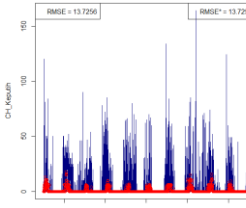
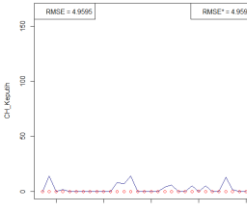
Lampiran 22 Hasil Keputusan Korelasi Antar Variabel Prediktor terhadap Curah Hujan di Pos Hujan Gunung Sari

Variabel Prediktor	r-pearson	p-value	Keputusan
X ₁₁	0.14	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₁₂	0.18	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₁₃	0.13	1.7×10^{-15}	Tolak H ₀
X ₁₄	0.15	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₁₅	0.18	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₁₆	0.14	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₁₇	0.14	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₁₈	0.18	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₁₉	0.14	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₂₁	-0.031	6.4×10^{-2}	Gagal Tolak H ₀
X ₂₂	-0.14	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₂₃	-0.094	1.1×10^{-8}	Tolak H ₀
X ₂₄	-0.027	1×10^{-1}	Gagal Tolak H ₀
X ₂₅	-0.098	2.5×10^{-9}	Tolak H ₀
X ₂₆	0.003	8.6×10^{-1}	Gagal Tolak H ₀
X ₂₇	0.0066	6.9×10^{-1}	Gagal Tolak H ₀
X ₂₈	-0.064	9.6×10^{-5}	Tolak H ₀
X ₂₉	0.02	2.2×10^{-1}	Gagal Tolak H ₀
X ₃₁	0.2	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₃₂	-0.07	2.2×10^{-5}	Tolak H ₀
X ₃₃	-0.0096	5.6×10^{-1}	Gagal Tolak H ₀
X ₃₄	0.21	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₃₅	-0.032	5.3×10^{-2}	Gagal Tolak H ₀
X ₃₆	0.05	2.5×10^{-3}	Tolak H ₀
X ₃₇	0.2	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₃₈	-0.016	3.4×10^{-1}	Gagal Tolak H ₀
X ₃₉	0.11	4.2×10^{-12}	Tolak H ₀
X ₄₁	-0.19	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₄₂	0.06	2.6×10^{-4}	Tolak H ₀
X ₄₃	0.042	1.1×10^{-2}	Tolak H ₀
X ₄₄	-0.16	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₄₅	0.065	7.6×10^{-5}	Tolak H ₀
X ₄₆	0.023	1.6×10^{-1}	Gagal Tolak H ₀
X ₄₇	-0.15	$<2.2 \times 10^{-16}$	Tolak H ₀
X ₄₈	0.054	1.2×10^{-3}	Tolak H ₀
X ₄₉	0.017	3.1×10^{-1}	Gagal Tolak H ₀

Lampiran 23 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Bulan Desember 2018 pada Grid 1x1

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_{15})$	0.1		
	0.01		
$Y_1 = f(X_{15}, \text{dummy})$	0.1		
	0.01		

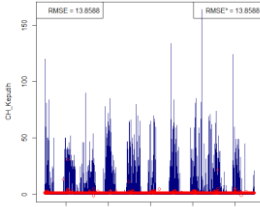
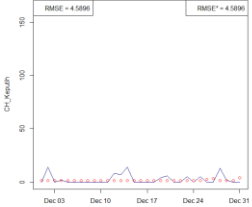
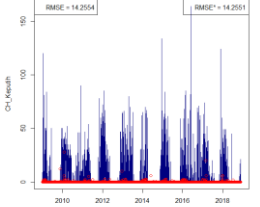
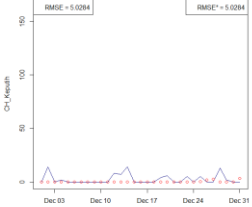
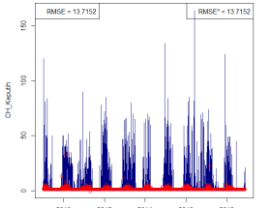
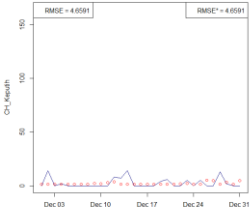
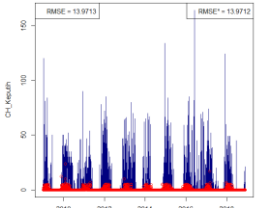
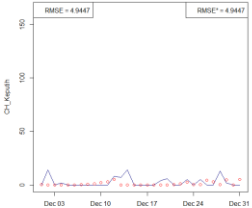
Lampiran 23 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Bulan Desember 2018 pada Grid 1x1 (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_{25})$	0.1		
	0.01		
$Y_1 = f(X_{25}, dummy)$	0.1		
	0.01		

Lampiran 23 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Bulan Desember 2018 pada Grid 1x1 (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_{35})$	0.1		
	0.01		
$Y_1 = f(X_{35}, \text{dummy})$	0.1		
	0.01		

Lampiran 23 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Bulan Desember 2018 pada Grid 1x1 (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_{45})$	0.1		
	0.01		
$Y_1 = f(X_{45}, \text{dummy})$	0.1		
	0.01		

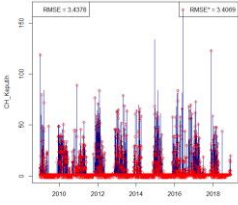
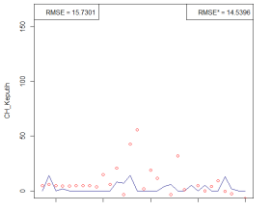
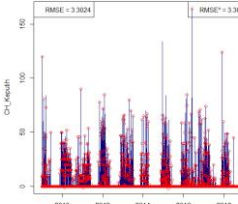
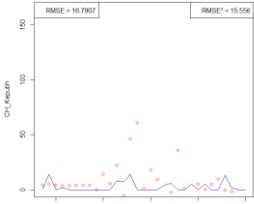
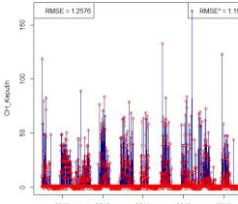
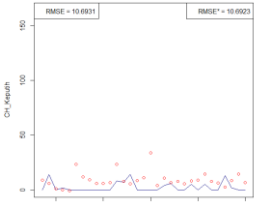
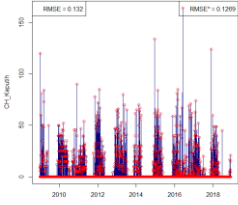
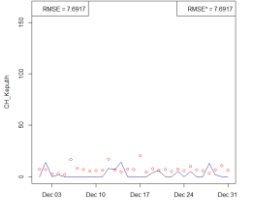
Lampiran 23 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Bulan Desember 2018 pada Grid 1x1 (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_{15}, X_{25}, X_{35}, X_{45})$	0.1		
	0.01		
$Y_1 = f(X_{15}, X_{25}, X_{35}, X_{45}, dummy)$	0.1		
	0.01		

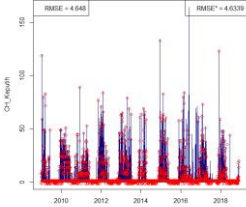
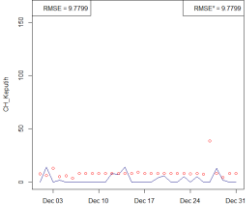
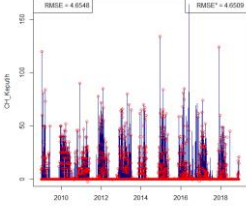
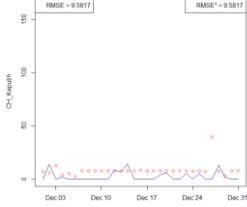
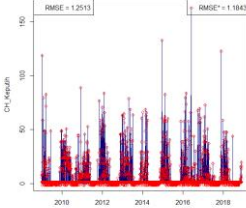
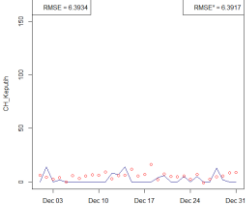
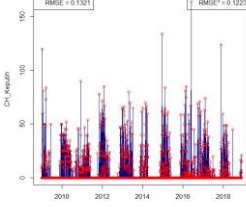
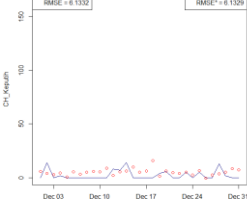
Lampiran 24 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Bulan Desember 2018 pada Grid 3x3

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_1)$	0.1		
	0.01		
$Y_1 = f(X_2)$	0.1		
	0.01		

Lampiran 24 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Bulan Desember 2018 pada Grid 3x3 (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_3)$	0.1		
	0.01		
$Y_1 = f(X_4)$	0.1		
	0.01		

Lampiran 24 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Bulan Desember 2018 pada Grid 3x3 (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_1, dummy)$	0.1		
	0.01		
$Y_1 = f(X_2, dummy)$	0.1		
	0.01		

Lampiran 24 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Bulan Desember 2018 pada Grid 3x3 (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_3,$ <i>dummy</i>)	0.1		
	0.01		
$Y_1 = f(X_4,$ <i>dummy</i>)	0.1		
	0.01		

Lampiran 24 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Bulan Desember 2018 pada Grid 3x3 (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_1, X_2, X_3, X_4)$	0.1		
	0.01		
$Y_1 = f(X_1, X_2, X_3, X_4, dummy)$	0.1		
	0.01		

Lampiran 25 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Bulan Desember 2018 pada Grid 3x3 PCA

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_{1,t} = f(PC_{11,t}, PC_{21,t})$	0.1		
	0.01		
$Y_{1,t} = f(PC_{12,t}, PC_{22,t})$	0.1		
	0.01		

Lampiran 25 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Bulan Desember 2018 pada Grid 3x3 PCA (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_{1,t} = f(PC_{13,t}, PC_{23,t})$	0.1		
	0.01		
$Y_{1,t} = f(PC_{14,t}, PC_{24,t})$	0.1		
	0.01		

Lampiran 25 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Bulan Desember 2018 pada Grid 3x3 PCA (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_{1,t} = f(PC_{11,t}, PC_{21,t}, dummy_t)$	0.1		
	0.01		
$Y_{1,t} = f(PC_{12,t}, PC_{22,t}, dummy_t)$	0.1		
	0.01		

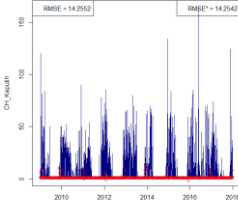
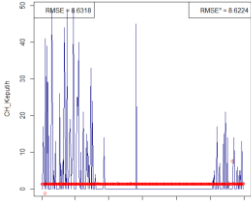
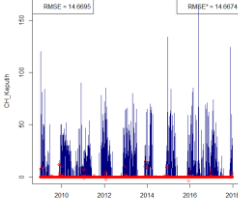
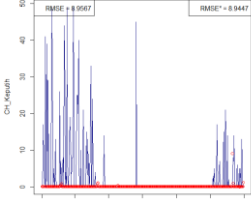
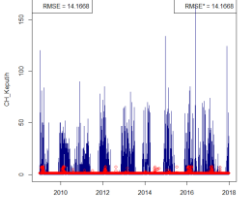
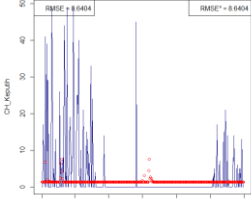
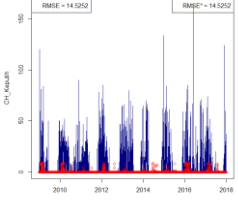
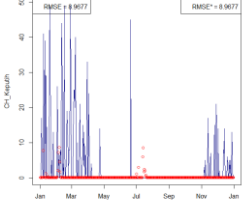
Lampiran 25 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Bulan Desember 2018 pada Grid 3x3 PCA (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_{1,t} = f(PC_{13,t}, PC_{23,t}, dummy_t)$	0.1		
	0.01		
$Y_{1,t} = f(PC_{14,t}, PC_{24,t}, dummy_t)$	0.1		
	0.01		

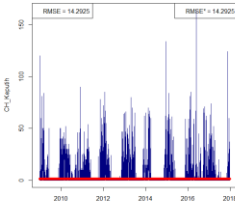
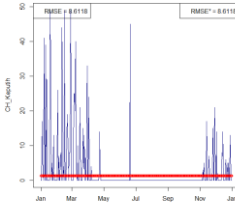
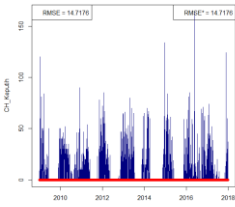
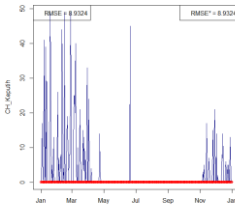
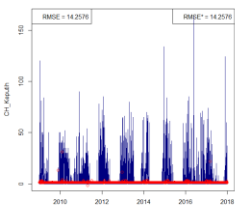
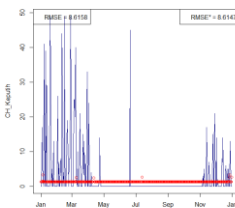
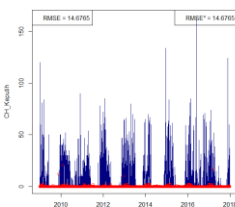
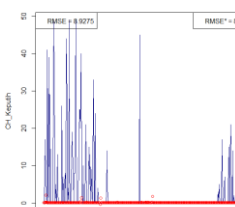
Lampiran 25 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Bulan Desember 2018 pada Grid 3x3 PCA (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_{1,t} = f(PC_{11,t}, PC_{21,t}, PC_{12,t}, PC_{22,t}, PC_{13,t}, PC_{23,t}, PC_{24,t}, PC_{24,t})$	0.1		
	0.01		
$Y_{1,t} = f(PC_{11,t}, PC_{21,t}, PC_{12,t}, PC_{22,t}, PC_{13,t}, PC_{23,t}, PC_{24,t}, PC_{24,t}, dummy_t)$	0.1		
	0.01		

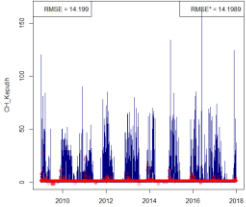
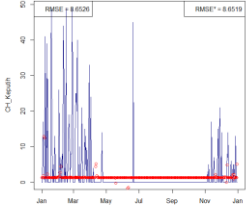
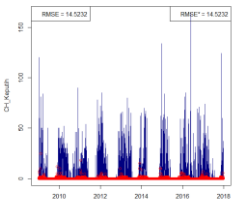
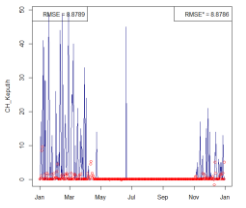
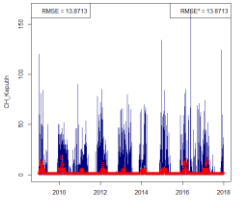
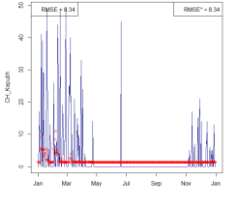
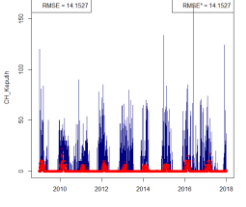
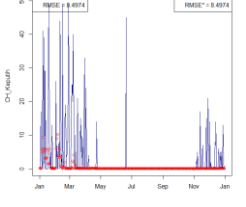
Lampiran 26 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Tahun 2018 pada Grid 1x1

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_{15})$	0.1		
	0.01		
$Y_1 = f(X_{25})$	0.1		
	0.01		


Lampiran 26 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Tahun 2018 pada Grid 1x1 (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_{35})$	0.1		
	0.01		
$Y_1 = f(X_{45})$	0.1		
	0.01		

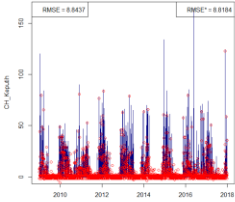
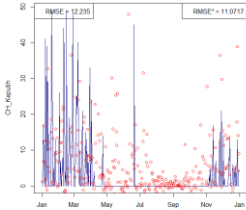
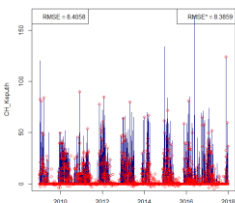
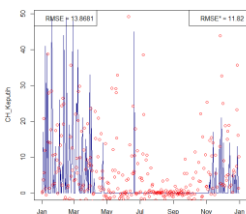
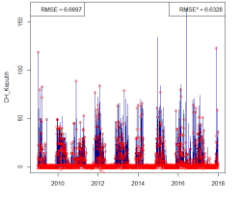
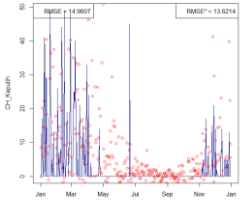
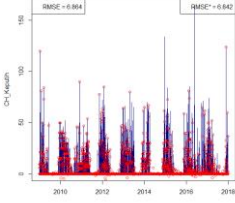
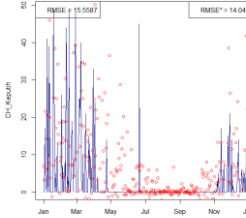
Lampiran 26 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Tahun 2018 pada Grid 1x1 (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_{15}, \text{dummy})$	0.1		
	0.01		
$Y_1 = f(X_{25}, \text{dummy})$	0.1		
	0.01		

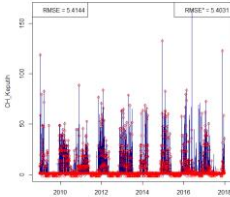
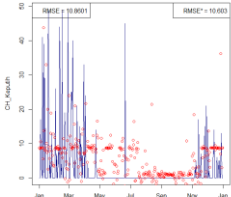
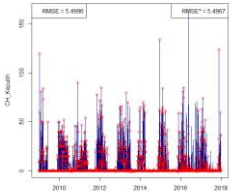
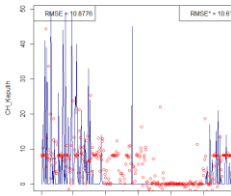
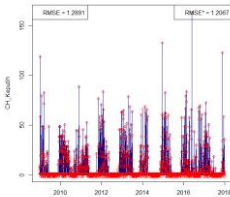
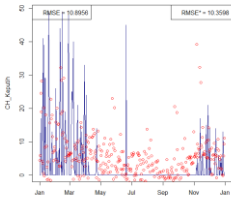
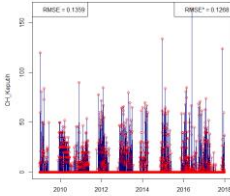
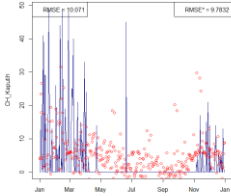
Lampiran 26 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Tahun 2018 pada Grid 1x1 (Lanjutan)



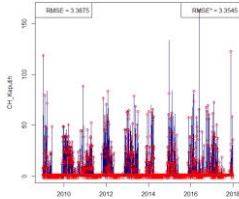
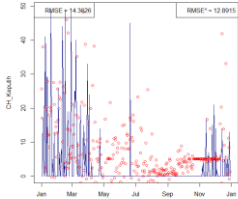
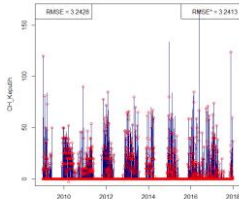
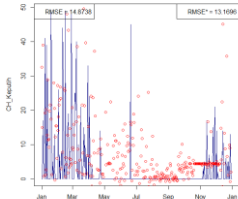
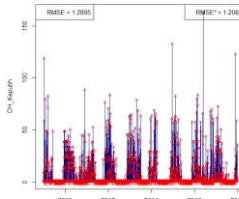
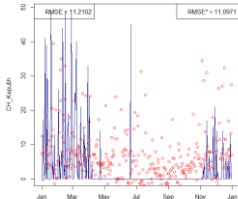
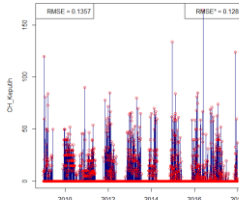
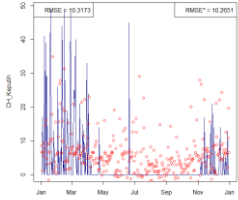
Lampiran 26 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Tahun 2018 pada Grid 1x1 (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_{15}, X_{25}, X_{35}, X_{45})$	0.1		
	0.01		
$Y_1 = f(X_{15}, X_{25}, X_{35}, X_{45}, dummy)$	0.1		
	0.01		

Lampiran 27 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Tahun 2018 pada Grid 3x3

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_1)$	0.1		
	0.01		
$Y_1 = f(X_2)$	0.1		
	0.01		

Lampiran 27 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Tahun 2018 pada Grid 3x3 (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_3)$	0.1		
	0.01		
$Y_1 = f(X_4)$	0.1		
	0.01		

Lampiran 27 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Tahun 2018 pada Grid 3x3 (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_1, \text{dummy})$	0.1		
	0.01		
$Y_1 = f(X_2, \text{dummy})$	0.1		
	0.01		

Lampiran 26 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Tahun 2018 pada Grid 3x3 (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_3, \text{dummy})$	0.1		
	0.01		
$Y_1 = f(X_4, \text{dummy})$	0.1		
	0.01		

Lampiran 26 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Tahun 2018 pada Grid 3x3 (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_1, X_2, X_3, X_4)$	0.1		
	0.01		
$Y_1 = f(X_1, X_2, X_3, X_4, dummy)$	0.1		
	0.01		

Lampiran 28 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Tahun 2018 pada Grid 3x3 PCA

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_{1,t} = f(PC_{11,t}, PC_{21,t})$	0.1		
	0.01		
$Y_{1,t} = f(PC_{12,t}, PC_{22,t})$	0.1		
	0.01		

Lampiran 27 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Tahun 2018 pada Grid 3x3 PCA (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_{1,t} = f(PC_{13,t}, PC_{23,t})$	0.1		
	0.01		
$Y_{1,t} = f(PC_{14,t}, PC_{24,t})$	0.1		
	0.01		

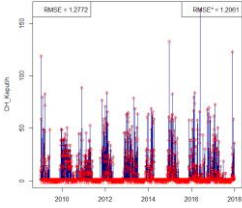
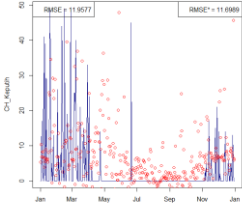
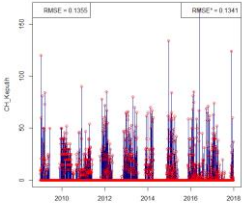
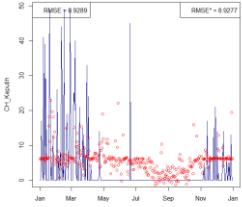
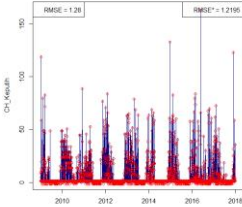
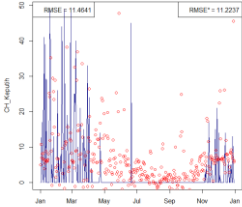
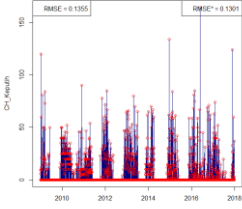
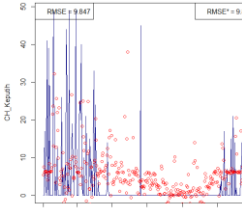
Lampiran 27 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Tahun 2018 pada Grid 3x3 PCA (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_{1,t} = f(PC_{11,t}, PC_{21,t}, dummy_t)$	0.1		
	0.01		
$Y_{1t} = f(PC_{12,t}, PC_{22,t}, dummy_t)$	0.1		
	0.01		

Lampiran 27 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Tahun 2018 pada Grid 3x3 PCA (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_{1,t} = f(PC_{13,t}, PC_{23,t}, dummy_t)$	0.1		
	0.01		
$Y_{1,t} = f(PC_{14,t}, PC_{24,t}, dummy_t)$	0.1		
	0.01		

Lampiran 27 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Data Testing Tahun 2018 pada Grid 3x3 PCA (Lanjutan)

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_{1,t} = f(PC_{11,t}, PC_{21,t}, PC_{12,t}, PC_{22,t}, PC_{13,t}, PC_{23,t}, PC_{24,t}, PC_{24,t})$	0.1		
	0.01		
$Y_{1,t} = f(PC_{11,t}, PC_{21,t}, PC_{12,t}, PC_{22,t}, PC_{13,t}, PC_{23,t}, PC_{24,t}, dummy_t)$	0.1		
	0.01		

Lampiran 29 Persamaan ARIMA untuk menentukan Lag dalam Pemodelan SVR

$$\begin{aligned}
 Y_t &= ARIMA(p, d, q)(P, D, Q)^s \\
 Y_t &= ARIMA(1, 0, 0)(5, 1, 0)^{365} \\
 \phi_p(B)\Phi_p(B^s)(1-B)^d(1-B^s)^D Y_t &= \theta_0 + \theta_q(B)\Theta_q(B^s)a_t \\
 (1-\phi_1 B)(1-\Phi_1 B^{365} - \Phi_2 B^{2(365)} - \Phi_3 B^{3(365)} - \Phi_4 B^{4(365)} - \Phi_5 B^{5(365)})(1-B^{365})^1 Y_t &= a_t \\
 (1-\phi_1 B)(1-\Phi_1 B^{365} - \Phi_2 B^{2(365)} - \Phi_3 B^{3(365)} - \Phi_4 B^{4(365)} - \Phi_5 B^{5(365)})(Y_t - Y_{t-365}) &= a_t \\
 ((1-\Phi_1 B^{365} - \Phi_2 B^{730} - \Phi_3 B^{1095} - \Phi_4 B^{1460} - \Phi_5 B^{1825}) - (\phi_1 B - \phi_1 \Phi_1 B B^{365} \\
 - \phi_1 \Phi_2 B B^{730} - \phi_1 \Phi_3 B B^{1095} - \phi_1 \Phi_4 B B^{1460} - \phi_1 \Phi_5 B B^{1825}))(Y_t - Y_{t-365}) &= a_t \\
 (1-\phi_1 B - \Phi_1 B^{365} + \Psi_1 B^{366} - \Phi_2 B^{730} + \Psi_2 B^{731} - \Phi_3 B^{1095} + \Psi_3 B^{1096} \\
 - \Phi_4 B^{1460} + \Psi_4 B^{1461} - \Phi_5 B^{1825} + \Psi_5 B^{1826})(Y_t - Y_{t-365}) &= a_t \\
 W_t - \phi_1 W_{t-1} - \Phi_1 W_{t-365} + \Psi_1 W_{t-366} - \Phi_2 W_{t-730} + \Psi_2 W_{t-731} - \Phi_3 W_{t-1095} \\
 + \Psi_3 W_{t-1096} - \Phi_4 W_{t-1460} + \Psi_4 W_{t-1461} - \Phi_5 W_{t-1825} + \Psi_5 W_{t-1826} &= a_t \\
 W_t = \phi_1 (Y_{t-1} - Y_{t-1-365}) + \Phi_1 (Y_{t-365} - Y_{t-365-365}) - \Psi_1 (Y_{t-366} - Y_{t-366-365}) \\
 + \Phi_2 (Y_{t-730} - Y_{t-730-365}) - \Psi_2 (Y_{t-731} - Y_{t-731-365}) + \Phi_3 (Y_{t-1095} - Y_{t-1095-365}) \\
 - \Psi_3 (Y_{t-1096} - Y_{t-1096-365}) + \Phi_4 (Y_{t-1460} - Y_{t-1460-365}) - \Psi_4 (Y_{t-1461} - Y_{t-1461-365}) \\
 + \Phi_5 (Y_{t-1825} - Y_{t-1825-365}) - \Psi_5 (Y_{t-1826} - Y_{t-1826-365}) + a_t \\
 W_t = \phi_1 (Y_{t-1} - Y_{t-366}) + \Phi_1 (Y_{t-365} - Y_{t-730}) - \Psi_1 (Y_{t-366} - Y_{t-731}) \\
 + \Phi_2 (Y_{t-730} - Y_{t-1095}) - \Psi_2 (Y_{t-731} - Y_{t-1096}) + \Phi_3 (Y_{t-1095} - Y_{t-1460}) \\
 - \Psi_3 (Y_{t-1096} - Y_{t-1461}) + \Phi_4 (Y_{t-1460} - Y_{t-1825}) - \Psi_4 (Y_{t-1461} - Y_{t-1826}) \\
 + \Phi_5 (Y_{t-1825} - Y_{t-2190}) - \Psi_5 (Y_{t-1826} - Y_{t-2191}) + a_t \\
 Y_t = f(Y_{t-1}, Y_{t-365}, Y_{t-366}, Y_{t-730}, Y_{t-731}, Y_{t-1095}, Y_{t-1096}, Y_{t-1460}, Y_{t-1461}, \\
 Y_{t-1825}, Y_{t-1826}, Y_{t-2190}, Y_{t-2191})
 \end{aligned}$$

Lampiran 30 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Penambahan Lag pada Grid 1x1

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_{1,t} = f(X_t,$ <i>dummy_t,</i> <i>lagARIMA</i> $(1,0,0)(5,1,0)^{365}$)	0.1		
	0.01		

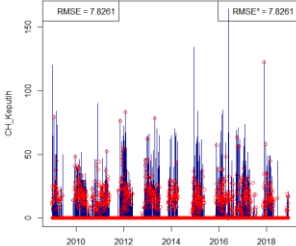
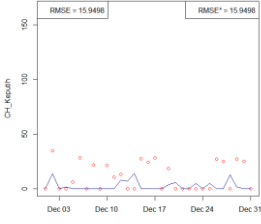
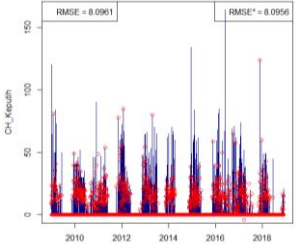
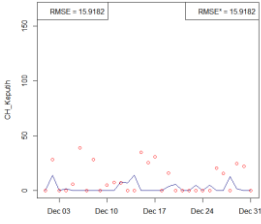
Lampiran 31 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Penambahan Lag pada Grid 3x3

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_{i,t} = f(X_t,$ <i>dummy</i> _{<i>t</i>} , <i>lagARIMA</i> $(1,0,0)(5,1,0)^{365}$)	0.1		
	0.01		

Lampiran 32 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Penambahan Lag pada Grid 3x3 PCA

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_{i,t} = f(X_t,$ <i>lag</i> ARIMA $(1,0,0)(5,1,0)^{365})$	0.1		
	0.01		

Lampiran 33 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Penggunaan NA pada Grid 1x1

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_{15}, X_{25}, X_{35}, X_{45})$	0.1		
	0.01		

Lampiran 34 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Penggunaan NA pada Grid 3x3

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_1 = f(X_1, X_2, X_3, X_4)$	0.1		
	0.01		

Lampiran 35 Hasil Pemodelan Curah Hujan di Pos Hujan Keputih dengan Penggunaan NA pada Grid 3x3 PCA

Model	Epsilon	Plot Data Training	Plot Data Testing
$Y_{1,t} = f(PC_{11,t}, PC_{21,t}, PC_{12,t}, PC_{22,t}, PC_{13,t}, PC_{23,t}, PC_{24,t}, PC_{24,t})$	0.1		
	0.01		

Lampiran 36 *Support Vector* yang terbentuk dari Pemodelan SVR**Lampiran 36 a** *Support Vector* yang terbentuk dari Pemodelan SVR Curah Hujan di Pos Hujan Keputih

No	Data ke-	Alpha
1	1	0.41448
2	2	1.00462
3	3	1.37431
4	4	-0.45150
5	5	0.00811
⋮	⋮	⋮
1418	1426	-0.45146
1419	1427	-0.45145
1420	1428	1.07900
1421	1429	0.63566
1422	1430	-0.45145

Lampiran 36 b *Support Vector* yang terbentuk dari Pemodelan SVR Curah Hujan di Pos Hujan Kedung Cowek

No	Data ke-	Alpha
1	1	0.03574
2	2	1.18194
3	3	2.41524
4	5	-0.02838
5	6	-0.11648
⋮	⋮	⋮
1347	1426	-0.46920
1348	1427	-0.46918
1349	1428	1.53413
1350	1429	0.56492
1351	1430	-0.46913

Lampiran 36 c *Support Vector* yang terbentuk dari Pemodelan SVR Curah Hujan di Pos Hujan Gubeng

No	Data ke-	Alpha
1	1	-0.51311
2	3	0.68138
3	4	-0.51301
4	5	-0.51239
5	6	-0.51254
⋮	⋮	⋮
1393	1426	-0.51306
1394	1427	-0.51304
1395	1428	0.37801
1396	1429	0.98473
1397	1430	-0.51254

Lampiran 36 d *Support Vector* yang terbentuk dari Pemodelan SVR Curah Hujan di Pos Hujan Wonorejo

No	Data ke-	Alpha
1	1	0.06214
2	2	0.33790
3	3	0.95719
4	4	-0.39949
5	5	-0.26159
⋮	⋮	⋮
1413	1426	-0.39951
1414	1427	-0.39948
1415	1428	-0.39949
1416	1429	-0.39948
1417	1430	-0.39986

Lampiran 36 e *Support Vector* yang terbentuk dari Pemodelan SVR Curah Hujan di Pos Hujan Wonokromo

No	Data ke-	Alpha
1	1	-0.49635
2	2	0.07103
3	3	0.51017
4	4	-0.49611
5	5	-0.49553
⋮	⋮	⋮
1404	1426	-0.49597
1405	1427	-0.49560
1406	1428	0.51028
1407	1429	1.46306
1408	1430	-0.49550

Lampiran 36 f *Support Vector* yang terbentuk dari Pemodelan SVR Curah Hujan di Pos Hujan Gunung Sari

No	Data ke-	Alpha
1	1	1.70860
2	2	-0.51054
3	3	-0.51011
4	5	-0.51082
5	6	-0.51084
⋮	⋮	⋮
1400	1426	-0.51072
1401	1427	-0.51089
1402	1428	0.73823
1403	1429	1.03655
1404	1430	-0.51128

(Halaman ini sengaja dikosongkan)

Lampiran 37 Surat Keterangan Data Curah Hujan dan Saluran Air

SURAT KETERANGAN

Saya yang bertanda tangan di bawah ini menerangkan bahwa :

1. Mahasiswa Statistika FMKSD-ITS dengan identitas berikut :

Nama : Henidar Islami Winarningtyas

NRP : 0621154000011

Telah mengambil data di instansi/perusahaan kami :

Nama Instansi: Dinas Pekerjaan Umum, Bina Marga, dan Pematusan Kota Surabaya

Divisi/ bagian: ~~Sub Bagian Penyusunan Program dan Pelaporan~~

sejak tanggal 1 Maret 2019 sampai dengan 30 April 2019 untuk keperluan Tugas Akhir/~~Thesis~~ Semester ~~Gasal~~/Genap* 2018/2019.

2. Tidak Keberatan/~~Keberatan~~* nama instansi dicantumkan dalam Tugas Akhir/ Thesis mahasiswa Statistika yang akan di simpan di Perpustakaan ITS dan dibaca di lingkungan ITS.
3. Tidak Keberatan/~~Keberatan~~* bahwa hasil analisis data dari instansi dipublikasikan dalam E journal ITS yaitu Jurnal Sains dan Seni ITS.

Surabaya, 2 Juli 2019

Pimpinan Instansi

~~Kepala Sub Bagian Penyusunan Program dan Pelaporan~~



*(coret yang tidak perlu)

(Halaman ini sengaja dikosongkan)

Lampiran 38 Surat Pernyataan Data *General Circulation Model* (GCM)**SURAT PERNYATAAN**

Saya yang bertanda tangan di bawah ini, mahasiswa Departemen Statistika FMKSD ITS:

Nama : Henidar Islami Winarningtyas

NRP : 0621154000011

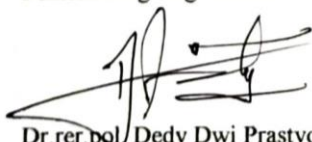
menyatakan bahwa data yang digunakan dalam Tugas Akhir/ Thesis ini merupakan data sekunder yang diambil dari penelitian / buku/ Tugas Akhir/ Thesis/ publikasi lainnya yaitu:

Sumber : *Website* WDC Climate
<https://cera-www.dkrz.de/WDCC/ui/cersearch/>

Keterangan : Data *General Circulation Model* (GCM) yang digunakan adalah model CSIRO-Mk3.6.0

Surat Pernyataan ini dibuat dengan sebenarnya. Apabila terdapat pemalsuan data maka saya siap menerima sanksi sesuai aturan yang berlaku.

Mengetahui
Pembimbing Tugas Akhir



Dr. rer. pol. Dedy Dwi Prastyo, S.Si., M.Si.
NIP. 19831204 200812 1 002

Surabaya, 13 Juni 2019



Henidar Islami W
NRP. 0621154000011

(Halaman ini sengaja dikosongkan)

BIODATA PENULIS



Nama lengkap penulis adalah Henidar Islami Winarningtyas. Penulis merupakan anak kedua dari pasangan Supatno dan Lindaryati yang terlahir di Banjarmasin pada tanggal 19 Agustus 1997. Pendidikan formal penulis telah ditempuh di TK Mardhatillah, SDN Kemasan 1, SMPN 1 Sukoharjo, dan SMA Negeri 1 Sukoharjo. Selanjutnya, penulis melanjutkan pendidikan formal di Program Studi Sarjana Departemen Statistika ITS dan diterima pada tahun 2015 melalui jalur SNMPTN. Selama perkuliahan, penulis aktif dalam organisasi dan kepanitiaan. Penulis aktif di *Statistics Computer Course* (SCC) Himpunan Mahasiswa Departemen Statistika ITS (HIMASTA-ITS) sebagai bendahara pada periode 2016-2017. Selain aktif dalam organisasi dan kepanitiaan, penulis juga mengikuti berbagai perlombaan di bidang statistika dan karya tulis ilmiah. Capaian prestasi penulis antara lain tercatat sebagai Juara II *Indonesia Research Olympiad* yang diadakan oleh 4th *Indonesia Statistics Conference and Olympiad* (ISCO) pada tahun 2018 yang diadakan di Semarang. Apabila pembaca ingin memberikan kritik dan saran serta diskusi lebih lanjut mengenai Tugas Akhir ini, dapat menghubungi penulis melalui email henidar.islami@gmail.com atau pada nomor telepon 087836373551.

(Halaman ini sengaja dikosongkan)