



TUGAS AKHIR - KS184822

**PREDIKSI CURAH HUJAN DI KOTA SURABAYA
BERBASIS PEMODELAN UNSUR IKLIM DATA BMKG
DENGAN PENDEKATAN COPULA UNTUK PREDIKSI
BANJIR**

**AFIFAH NUR ISWARI
NRP 062115 4000 0109**

**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**



TUGAS AKHIR - KS184822

**PREDIKSI CURAH HUJAN DI KOTA SURABAYA
BERBASIS PEMODELAN UNSUR IKLIM DATA BMKG
DENGAN PENDEKATAN COPULA UNTUK PREDIKSI
BANJIR**

**AFIFAH NUR ISWARI
NRP 062115 4000 0109**

**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

**RAINFALL PREDICTION IN SURABAYA BASED ON
CLIMATE DATA FROM BMKG USING COPULA
APPROACH FOR FLOOD PREDICTION**

**AFIFAH NUR ISWARI
SN 062115 4000 0109**

**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

PREDIKSI CURAH HUJAN DI KOTA SURABAYABERBASIS PEMODELAN UNSUR IKLIM DATA BMKG DENGAN PENDEKATAN COPULA UNTUK PREDIKSI BANJIR

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 :

Afifah Nur Iswari
NRP. 062115 4000 0109

Disetujui oleh Pembimbing:

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



Mengetahui,
Kepala Departemen Statistika

Dr. Suhartono
NIP. 19710929 199512 1 001

SURABAYA, JULI 2019

(Halaman ini sengaja dikosongkan)

**PREDIKSI CURAH HUJAN DI KOTA SURABAYA
BERBASIS PEMODELAN UNSUR IKLIM DATA BMKG
DENGAN PENDEKATAN COPULA UNTUK PREDIKSI
BANJIR**

Nama Mahasiswa : Afifah Nur Iswari
NRP : 062115 4000 0109
Departemen : Statistika-FMKSD-ITS
Dosen Pembimbing : Dr.rer.pol.Dedy Dwi Prastyo.S.Si.,M.Si.

Abstrak

Indonesia merupakan negara beriklim tropis, yang hanya memiliki dua musim. Dikarenakan perubahan iklim yang terus terjadi, menjadikan peningkatan curah hujan selama musim hujan, dapat menyebabkan risiko banjir yang tinggi. Salah satu kota besar di Indonesia yang masih dihadapkan dengan permasalahan banjir adalah Kota Surabaya. Copula merupakan salah satu metode yang tidak ketat terhadap suatu asumsi terutama asumsi berdistribusi normal serta dapat mengatasi kasus dependensi pada data, seperti data klimatologi. Penelitian kali ini akan melakukan prediksi banjir berdasarkan prediksi curah hujan di Kota Surabaya. Prediksi curah hujan (respon) di enam balai curah hujan diperoleh berdasarkan model terbaik menggunakan metode Gaussian Copula Marginal Regression (GCMR) terhadap unsur iklim (prediktor) di tiga stasiun BMKG dan PC unsur iklim hasil PCA. Menggunakan GCMR pada penelitian ini, mayoritas model terbaik diperoleh pada saat prediktor merupakan data PCA dan ditambahkan lag differencing seasonal curah hujan, tanpa melibatkan data respon yang sama dengan nol (menjadikan data curah hujan bernilai nol menjadi NA). Berdasarkan prediksi curah hujan maksimum, di duga terdapat beberapa saluran di Kota Surabaya tidak mampu menampung curah hujan maksimum hasil prediksi. Harapannya, penelitian ini dapat menjadi bahan evaluasi kepada pemerintah dalam mengantisipasi banjir di Kota Surabaya.

Kata Kunci: Banjir, Copula, Curah Hujan, GCMR, Iklim

(Halaman ini sengaja di kosongkan)

RAINFALL PREDICTION IN SURABAYA BASED ON CLIMATE DATA FROM BMKG USING COPULA APPROACH FOR FLOOD PREDICTION

Name : Afifah Nur Iswari
Student Number : 062115 4000 0109
Department : Statistics
Supervisor : Dr.rer.pol.Dedy Dwi Prastyo.S.Si.,M.Si.

Abstract

Indonesia is a tropical country, which only has two seasons. Due to the climate change, increasing rainfall during the rainy season can cause a high risk of flooding. Surabaya is one of the big cities in Indonesia that still facing flood problems. This research predicts rainfall to predict flood in Surabaya. Rainfall prediction in all six “Balai PSAWS” was obtained based on Gaussian Copula Marginal Regression (GCMR), with the predictor are the climate elements at three BMKG and PC resulted from PCA. Using GCMR, the majority of climate elements the best models when predictors were PC and seasonally-differenced lag, without involving zero response data (making zero rainfall data to be NA). Once obtained rainfall predictions in all six “Balai PSAWS”, flood prediction is carried out based on maximum rainfall predictor using mathematical hydrological calculations. Based on the maximum rainfall prediction, it is predicted that there are several sub-district in Surabaya that are unable to accommodate the maximum rainfall predicted. The result of this work can be used as an evaluation for the government in anticipating flooding in Surabaya.

Keywords: Flood, Copula, Rainfall, GCMR, Climate

(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 **“Prediksi Curah Hujan di Kota Surabaya Berbasis Pemodelan Usur Iklim Data BMKG dengan Pendekatan Copula untuk Prediksi Banjir”** dengan lancar.

Penulis menyadari bahwa Tugas Akhir ini dapat terselesaikan tidak terlepas dari bantuan dan dukungan berbagai pihak. Oleh karena itu, penulis menyampaikan terima kasih kepada :

1. Dr. rer. pol. Dedy Dwi Prastyo S.Si., M.Si. selaku dosen pembimbing Tugas Akhir yang telah meluangkan waktu dan senantiasa sangat sabar dalam memberikan bimbingan, saran, dukungan serta motivasi selama penyusunan Tugas Akhir.
2. Imam Safawi Ahmad S.Si., M.Si. selaku dosen wali dan dosen penguji yang senantiasa memberikan saran dan arahan dalam proses belajar di Departemen Statistika ITS.
3. Dr. Sutikno S.Si., M.Si. selaku dosen penguji yang telah banyak memberi masukan kepada penulis dalam penyelesaian Tugas Akhir.
4. Dr. Suhartono selaku Kepala Departemen Statistika FMKSD ITS dan Ibu Dr. Santi Wulan Purnami, M.Si selaku Ketua Program Studi Sarjana Departemen Statistika FMKSD ITS.
5. Kedua orang tua, adik (Aldian Dwi Iswara & Aliyah Tri Iswari) beserta keluarga atas segala do'a, nasihat, kasih sayang dan dukungan yang diberikan kepada penulis demi kesuksesan dan kebahagiaan penulis
6. Seluruh dosen dan *staff* Program Studi Sarjana Departemen Statistika FMKSD ITS yang telah membantu penulis selama proses perkuliahan.
7. Sahabat-sahabat penulis terutama Ukhti Hereafter dan Devastra cabang Surabaya yang selama ini telah membantu, mendukung dan mendengarkan keluh kesah penulis selama masa perkuliahan berlangsung.

8. Teman-teman seperjuangan Tugas Akhir, khususnya Devita, Henidar, Icha, Risda dan Angga yang selama ini telah berjuang bersama dan saling memberikan semangat.
9. Teman-teman Statistika ITS angkatan 2015 (VIVACIOUS), yang selalu memberikan dukungan kepada penulis selama ini, khususnya.
10. Teman-teman CLICK-ITS khususnya CLICK 2015 dan HIMASTA-ITS 2017/2018, yang selama perkuliahan memberikan banyak pembelajaran dan mendukung penulis untuk meningkatkan *softskill* penulis.
11. Semua pihak yang telah membantu dalam penyelesaian Tugas Akhir ini yang tidak bisa penulis sebutkan satu persatu.

Terlepas dari semua itu, penulis menyadari sepenuhnya bahwa masih banyak kekurangan baik dari segi susunan kalimat maupun bahasa. Oleh karena itu, dengan terbuka kami menerima segala kritik dan saran dari pembaca sebagai bahan perbaikan bagi penulisan selanjutnya. Akhir kata, Besar harapan penulis untuk mendapatkan kritik dan saran yang membangun sehingga Tugas Akhir ini dapat memberikan manfaat bagi semua pihak yang terkait.

Surabaya, Juli 2019

Penulis

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
TITTLE PAGE	ii
LEMBAR PENGESAHAN	iii
ABSTRAK	v
ABSTRACT	vii
KATA PENGANTAR	xvii
DAFTAR ISI	xix
DAFTAR GAMBAR	xxi
DAFTAR TABEL	xxvii
DAFTAR LAMPIRAN	xxxi
BAB I PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	6
1.3 Tujuan.....	6
1.4 Manfaat.....	6
2.5 Batasan Masalah.....	7
BAB II TINJAUAN PUSTAKA	9
2.1 Pre-Processing Data.....	9
2.2 Time Series.....	9
2.3 Principal Component Analysis (PCA).....	12
2.4 Copula.....	15
2.4.1. Copula Elips (<i>Elliptical Copula</i>).....	16
2.4.2. Copula Archimedean.....	19
2.5 Gaussian Copula Marginal Regression.....	21
2.6 Estimasi Parameter.....	25
2.7 Kriteria Keabakan Model.....	28
2.8 Perhitungan Matematis Banjir Rencana.....	28
2.9 Banjir.....	33
2.10 Curah Hujan (CH).....	34
2.11 BMKG.....	35
2.12 Dinas Pekerjaan Umum.....	36
BAB III METODOLOGI PENELITIAN	40
3.1 Sumber Data.....	40
3.2 Variabel Penelitian.....	42

3.3	Struktur Data	43
3.4	Langkah Analisis	44
BAB IV ANALISIS DAN PEMBAHASAN.....		51
4.1	<i>Pre-Processing</i> Data.....	51
4.2	Karakteristik Data.....	54
	4.2.1 Variabel Respon (Curah Hujan)	54
	4.2.2 Variabel Prediktor (Unsur Iklim).....	56
	4.2.3 Variabel Respon dan Prediktor	60
4.3	PCA	64
4.4	Pemodelan Curah Hujan di Kota Surabaya	67
	4.4.1 Keputih	69
	4.4.2 Kedung Cowek	105
	4.4.3 Gubeng.....	106
	4.4.4 Wonorejo	107
	4.4.5 Wonokromo	108
	4.4.6 Gunung Sari.....	109
4.5	Prediksi Unsur Iklim (Prediktor)	109
4.6	Prediksi Curah Hujan di Kota Surabaya.....	111
	4.6.1 Keputih	112
	4.6.2 Kedung Cowek	115
	4.6.3 Gubeng.....	117
	4.6.4 Wonorejo	120
	4.6.5 Wonokromo	120
	4.6.6 Gunung Sari.....	120
4.7	Prediksi Banjir di Kota Surabaya	127
BAB V KESIMPULAN DAN SARAN.....		133
5.1	Kesimpulan.....	133
5.2	Saran.....	134
DAFTAR PUSTAKA		135
LAMPIRAN		139
BIODATA PENULIS		207

DAFTAR GAMBAR

	Halaman
Gambar 2.1	<i>Contour Plots</i> pada Copula Elliptical 19
Gambar 2.2	<i>Contour Plots</i> pada Copula Archimedean 20
Gambar 2.3	Ilustrasi <i>Link-Function</i> pada Regresi Gamma.... 25
Gambar 2.4	Lima Rayon Pengamatan Banjir 37
Gambar 3.1	Peta Kota Surabaya & Wilayah Pengamatan 42
Gambar 3.2	Kerangka Variabel Penelitian 42
Gambar 3.3	Diagram Alir 48
Gambar 4.1	Visualisasi <i>Missing Value</i> Variabel Respon 52
Gambar 4.2	Visualisasi <i>Missing Value</i> Variabel Prediktor.... 53
Gambar 4.3	<i>Time Series Plot</i> Curah Hujan 6 Balai PSAWS. 54
Gambar 4.4	<i>Box-Plot</i> Curah Hujan Enam Balai PSAWS..... 55
Gambar 4.5	<i>Time-Series Plot & Box-Plot</i> Rata-Rata Temperatur Udara Stasiun BMKG 57
Gambar 4.6	<i>Time-Series Plot & Box-Plot</i> Rata-Rata Kelembaban Udara Stasiun BMKG..... 58
Gambar 4.7	<i>Time-Series Plot & Box-Plot</i> Rata-Rata Kecepatan Angin Stasiun BMKG..... 59
Gambar 4.8	<i>Scatter-Plot</i> Temperatur & Curah Hujan 60
Gambar 4.9	<i>Scatter-Plot</i> Kelembaban & Curah Hujan 61
Gambar 4.10	<i>Scatter-Plot</i> Kecepatan Angin & Curah Hujan.. 62
Gambar 4.11	Ilustrasi Terjadinya Hujan..... 64
Gambar 4.12	<i>Scree-Plot</i> PCA Temperatur Udara..... 65
Gambar 4.13	<i>Scree-Plot</i> PCA Kelembaban Udara 66
Gambar 4.14	<i>Scree-Plot</i> PCA Kecepatan Angin 66
Gambar 4.15	Plot Prediksi $CH_{1,t}$ dengan Prediktor (a) $CH_{1,t-1}$ + (b) $CH_{1,t-2}$ + (c) $CH_{1,t-3}$ + (d) $CH_{1,t-4}$ + (e) $CH_{1,t-5}$ + (f) $CH_{1,t-6}$ + (g) $CH_{1,t-7}$ & (h) $CH_{1,t-14}$, Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)..... 70

- Gambar 4.16** Plot Prediksi $CH_{1,t}$ dengan Prediktor (*Univariable*) Stasiun Juanda (a1)T, (b1)RH, (c1)ff dan Prediktor Tambahan Variabel *Dummy* (a2,b2,c2), Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)74
- Gambar 4.17** Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (*Multivariable*) Stasiun Juanda dan (b) Prediktor Tambahan Variabel *Dummy* , Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)75
- Gambar 4.18** Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (*Multivariable*) Stasiun Juanda + $CH_{1,t-1}$ dan (b) Prediktor Tambahan Variabel *Dummy* , Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)77
- Gambar 4.19** Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (*Multivariable*) Stasiun Juanda + (a) $CH_{1,t-2}$ + (b) $CH_{1,t-3}$ + (c) $CH_{1,t-4}$ + (d) $CH_{1,t-5}$ + (e) $CH_{1,t-6}$ +(f) $CH_{1,t-7}$, Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)78
- Gambar 4.20** Plot Prediksi $CH_{1,t}$ dengan Prediktor (*Univariable*) Stasiun Perak2 (a1)T, (b1)RH, (c1)ff dan Prediktor Tambahan Variabel *Dummy* (a2,b2,c2), Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)80
- Gambar 4.21** Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (*Multivariable*) Stasiun Perak 2 dan (b) Prediktor Tambahan Variabel *Dummy* , Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)82
- Gambar 4.22** Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (*Multivariable*) Stasiun Perak 2 + $CH_{1,t-1}$ dan

	(b)Prediktor Tambahan Variabel <i>Dummy</i> , Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	84
Gambar 4.23	Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (<i>Multivariable</i>) Stasiun Perak 2 + (a) $CH_{1,t-2}$ + (b) $CH_{1,t-3}$ + (c) $CH_{1,t-4}$ + (d) $CH_{1,t-5}$ + (e) $CH_{1,t-6}$ +(f) $CH_{1,t-7}$, Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	84
Gambar 4.24	Plot Prediksi $CH_{1,t}$ dengan Prediktor (<i>Univariable</i>) Stasiun Perak1 (a1)T, (b1)RH, (c1)ff dan Prediktor Tambahan Variabel <i>Dummy</i> (a2,b2,c2), Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	87
Gambar 4.25	Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (<i>Multivariable</i>) Stasiun Perak 1 dan (b) Prediktor Tambahan Variabel <i>Dummy</i> , Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	89
Gambar 4.26	Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (<i>Multivariable</i>) Stasiun Perak 1 + $CH_{1,t-1}$ dan (b) Prediktor Tambahan Variabel <i>Dummy</i> , Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	90
Gambar 4.27	Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (<i>Multivariable</i>) Stasiun Perak 1 + (a) $CH_{1,t-2}$ + (b) $CH_{1,t-3}$ + (c) $CH_{1,t-4}$ + (d) $CH_{1,t-5}$ + (e) $CH_{1,t-6}$ +(f) $CH_{1,t-7}$, Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	91
Gambar 4.28	Plot Prediksi $CH_{1,t}$ dengan Prediktor (<i>Univariable</i>) PC (a1)T, (b1)RH, (c1)ff dan Prediktor Tambahan Variabel <i>Dummy</i>	

	(a ₂ ,b ₂ ,c ₂), Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	94
Gambar 4.29	Plot Prediksi CH _{1,t} dengan (a) Prediktor (<i>Multivariable</i>) PC dan (b) Prediktor Tambahan Variabel <i>Dummy</i> , Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	95
Gambar 4.30	Plot Prediksi CH _{1,t} dengan (a) Prediktor (<i>Multivariable</i>) PC + CH _{1,t-1} dan (b) Prediktor Tambahan Variabel <i>Dummy</i> , Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	97
Gambar 4.31	Plot Prediksi CH _{1,t} dengan (a) Prediktor (<i>Multivariable</i>) PC + (a)CH _{1,t-2} + (b) CH _{1,t-3} + (c)CH _{1,t-4} + (d)CH _{1,t-5} + (e)CH _{1,t-6} +(f)CH _{1,t-7} , Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	97
Gambar 4.32	Plot (a) ACF dan (b) PACF Data CH _{1,t}	99
Gambar 4.33	Plot (a) ACF dan (b) PACF Data CH _{1,t} hasil <i>Differencing Seasonal</i> 365	99
Gambar 4.34	Plot (a) Prediksi & (b) ACF & PACF Residual Model CH _{1,t} dengan Prediktor Lag dari Model ARIMA(1,0,0)(5,1,0) ³⁶⁵ , Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	101
Gambar 4.35	Plot (a) Prediksi & (b) ACF & PACF Residual Model CH _{1,t} dengan Prediktor Lag dari Model ARIMA(1,0,0)(5,1,0) ³⁶⁵ , Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	103
Gambar 4.36	Plot Prediksi Variabel Prediktor (Holt Winter's) di (a) Juanda, (b) Perak 2 & (c) Perak 1	110
Gambar 4.37	Plot Prediksi CH _{1,t} Data (a) <i>Traning</i> dan (b) <i>Testing</i> , dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	113

Gambar 4.38	ACF & PACF Error pada Pemodelan $CH_{1,t}$, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	114
Gambar 4.39	Plot Prediksi $CH_{2,t}$ Data (a) <i>Traning</i> dan (b) <i>Testing</i> , dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	115
Gambar 4.40	ACF & PACF Error pada Pemodelan $CH_{2,t}$, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	116
Gambar 4.41	Plot Prediksi $CH_{2,t}$ Data (a) <i>Traning</i> dan (b) <i>Testing</i> , dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	118
Gambar 4.42	ACF & PACF Error pada Pemodelan $CH_{3,t}$, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	119
Gambar 4.43	Plot Prediksi $CH_{4,t}$ Data (a) <i>Traning</i> dan (b) <i>Testing</i> , dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	121
Gambar 4.44	ACF & PACF Error pada Pemodelan $CH_{4,t}$, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	122
Gambar 4.45	Plot Prediksi $CH_{5,t}$ Data (a) <i>Traning</i> dan (b) <i>Testing</i> , dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	123
Gambar 4.46	ACF & PACF Error pada Pemodelan $CH_{5,t}$, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	124
Gambar 4.47	Plot Prediksi $CH_{6,t}$ Data (a) <i>Traning</i> dan (b) <i>Testing</i> , dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	126

Gambar 4.48	ACF & PACF Error pada Pemodelan $CH_{6,t}$, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)	126
Gambar 4.49	Peta Prediksi Banjir di Kota Surabaya	130

DAFTAR TABEL

	Halaman
Tabel 2.1	Subfamilies Copula Archimedean 11
Tabel 2.2	Subfamilies Copula Archimedean 19
Tabel 2.3	<i>Link-Function</i> 25
Tabel 2.4	Estimasi Parameter Copula Archimedean 27
Tabel 2.5	Tabel Koefisien <i>Runoff</i> 29
Tabel 2.6	Kekasaran Manning untuk Saluran..... 32
Tabel 2.7	Derajat Curah Hujan..... 35
Tabel 3.1	Koordinat Stasiun BMKG 40
Tabel 3.2	Koordinat Balai PSAWS 41
Tabel 3.3	Variabel Penelitian 43
Tabel 3.4	Struktur Data Penelitian 1..... 43
Tabel 3.5	Struktur Data Penelitian 2..... 44
Tabel 4.1	Persentase <i>Missing Value</i> Variabel Respon..... 52
Tabel 4.2	Persentase <i>Missing Value</i> Variabel Prediktor 53
Tabel 4.3	PCA Temperatur di 3 Stasiun BMKG 65
Tabel 4.4	PCA Kelembaban di 3 Stasiun BMKG 65
Tabel 4.5	PCA Kecepatan Angin di 3 Stasiun BMKG..... 66
Tabel 4.6	Estimasi Parameter & Signifikansi $CH_{1,t-1}$ terhadap $CH_{1,t}$ 69
Tabel 4.7	Estimasi Parameter & Signifikansi Prediktor <i>Univariable</i> Stasiun Juanda terhadap $CH_{1,t}$ 72
Tabel 4.8	Estimasi Parameter & Signifikansi Prediktor <i>Univariable</i> Stasiun Juanda + Variabel <i>Dummy</i> terhadap CH_1 73
Tabel 4.9	Estimasi Parameter & Signifikansi Prediktor <i>Multivariable</i> Stasiun Juanda terhadap $CH_{1,t}$ 75
Tabel 4.10	Estimasi Parameter & Signifikansi <i>Multivariable</i> Stasiun Juanda + <i>Dummy</i> + $CH_{1,t-1}$ terhadap $CH_{1,t}$. 76
Tabel 4.11	Estimasi Parameter & Signifikansi Prediktor <i>Univariable</i> Stasiun Perak 2 terhadap $CH_{1,t}$ 79

Tabel 4.12	Estimasi Parameter & Signifikansi Prediktor <i>Univariable</i> Stasiun Perak 2 + Variabel <i>Dummy</i> terhadap $CH_{1,t}$	80
Tabel 4.13	Estimasi Parameter & Signifikansi Prediktor <i>Multivariable</i> Stasiun Perak 2 terhadap $CH_{1,t}$	82
Tabel 4.14	Estimasi Parameter & Signifikansi <i>Multivariable</i> Stasiun Perak 2 + <i>Dummy</i> + $CH_{1,t-1}$ terhadap $CH_{1,t}$	83
Tabel 4.15	Estimasi Parameter & Signifikansi <i>Univariable</i> Stasiun Perak 1 terhadap $CH_{1,t}$	86
Tabel 4.16	Estimasi Parameter & Signifikansi Prediktor <i>Univariable</i> Stasiun Perak 1 + Variabel <i>Dummy</i> terhadap $CH_{1,t}$	86
Tabel 4.17	Estimasi Parameter & Signifikansi Prediktor <i>Multivariable</i> Stasiun Perak 1 terhadap $CH_{1,t}$	88
Tabel 4.18	Estimasi Parameter & Signifikansi Prediktor <i>Multivariable</i> Stasiun Perak 1 + <i>Dummy</i> + $CH_{1,t-1}$ terhadap $CH_{1,t}$	90
Tabel 4.19	Estimasi Parameter & Signifikansi Prediktor <i>Univariable</i> PC terhadap $CH_{1,t}$	92
Tabel 4.20	Estimasi Parameter & Signifikansi Prediktor <i>Univariable</i> PC + Variabel <i>Dummy</i> terhadap $CH_{1,t}$	93
Tabel 4.21	Estimasi Parameter & Signifikansi Prediktor <i>Multivariable</i> PC terhadap $CH_{1,t}$	95
Tabel 4.22	Estimasi Parameter & Signifikansi Prediktor <i>Multivariable</i> PC+ <i>Dummy</i> + $CH_{1,t-1}$ terhadap $CH_{1,t}$.	96
Tabel 4.23	RMSE Terkecil pada Pemodelan $CH_{1,t}$	104
Tabel 4.24	RMSE Terkecil pada Pemodelan $CH_{2,t}$	105
Tabel 4.25	RMSE Terkecil pada Pemodelan $CH_{3,t}$	106
Tabel 4.26	RMSE Terkecil pada Pemodelan $CH_{4,t}$	107
Tabel 4.27	RMSE Terkecil pada Pemodelan $CH_{5,t}$	108
Tabel 4.28	RMSE Terkecil pada Pemodelan $CH_{6,t}$	109
Tabel 4.29	RMSE Data Testing $CH_{1,t}$	112

Tabel 4.30	Hasil Prediksi $CH_{1,t}$	114
Tabel 4.31	RMSE Data Testing $CH_{2,t}$	115
Tabel 4.32	Hasil Prediksi $CH_{2,t}$	117
Tabel 4.33	RMSE Data <i>Testing</i> $CH_{3,t}$	117
Tabel 4.34	Hasil Prediksi $CH_{3,t}$	119
Tabel 4.35	RMSE Data <i>Testing</i> $CH_{4,t}$	120
Tabel 4.36	Hasil Prediksi $CH_{4,t}$	122
Tabel 4.37	RMSE Data <i>Testing</i> $CH_{5,t}$	123
Tabel 4.38	Hasil Prediksi $CH_{5,t}$	125
Tabel 4.39	RMSE Data <i>Testing</i> $CH_{6,t}$	125
Tabel 4.40	Hasil Prediksi $CH_{6,t}$	127
Tabel 4.41	Singkronisasi 6 Balai CH terhadap 5 Rayon.....	128
Tabel 4.42	Hasil Prediksi Curah Hujan Maksimum 6 Balai...	129

(Halaman ini sengaja di kosongkan)

DAFTAR LAMPIRAN

	Halaman
Lampiran 1. Surat Keterangan Pengambilan Data	139
Lampiran 2. <i>Syntax</i> R untuk Menggabungkan Data BMKG	143
Lampiran 3. <i>Syntax</i> R Menggabungkan Data Curah Hujan..	144
Lampiran 4. <i>Syntax</i> R Imputasi Data <i>Missing</i>	145
Lampiran 5. <i>Output</i> R <i>Time-Series</i> Plot Imputasi Data <i>Missing</i>	146
Lampiran 6. <i>Syntax</i> R <i>Pre-Processing</i> Data.....	147
Lampiran 7. <i>Syntax</i> R Visualisasi Data	147
Lampiran 8. Data Variabel Prediktor & Respon	150
Lampiran 9. <i>Scatter-Plot</i> Curah Hujan & Lag Curah Hujan di 6 Balai ($CH_{1,t-1}$ s.d $CH_{1,t-7}$)	151
Lampiran 10. <i>Scatter-Plot</i> Temperatur di 3 Stasiun BMKG & $CH_{b,t-1}$ di 6 Balai PSAWS	152
Lampiran 11. <i>Scatter-Plot</i> Temperatur di 3 Stasiun BMKG & $CH_{b,t-2}$ di 6 Balai PSAWS	153
Lampiran 12. <i>Scatter-Plot</i> Temperatur di 3 Stasiun BMKG & $CH_{b,t-3}$ di 6 Balai PSAWS	154
Lampiran 13. <i>Scatter-Plot</i> Temperatur di 3 Stasiun BMKG & $CH_{b,t-4}$ di 6 Balai PSAWS	155
Lampiran 14. <i>Scatter-Plot</i> Temperatur di 3 Stasiun BMKG & $CH_{b,t-5}$ di 6 Balai PSAWS	156
Lampiran 15. <i>Scatter-Plot</i> Kelembaban di 3 Stasiun BMKG & $CH_{b,t-1}$ di 6 Balai PSAWS	157
Lampiran 16. <i>Scatter-Plot</i> Kelembaban di 3 Stasiun BMKG & $CH_{b,t-2}$ di 6 Balai PSAWS	158
Lampiran 17. <i>Scatter-Plot</i> Kelembaban di 3 Stasiun BMKG & $CH_{b,t-3}$ di 6 Balai PSAWS	159
Lampiran 18. <i>Scatter-Plot</i> Kelembaban di 3 Stasiun BMKG & $CH_{b,t-4}$ di 6 Balai PSAWS	160

Lampiran 19.	<i>Scatter-Plot</i> Kelembaban di 3 Stasiun BMKG & $CH_{b,t-5}$ di 6 Balai PSAWS	161
Lampiran 20.	<i>Scatter-Plot</i> Kec. Angin di 3 Stasiun BMKG & $CH_{b,t-1}$ di 6 Balai PSAWS	162
Lampiran 21.	<i>Scatter-Plot</i> Kec. Angin di 3 Stasiun BMKG & $CH_{b,t-2}$ di 6 Balai PSAWS	163
Lampiran 22.	<i>Scatter-Plot</i> Kec. Angin di 3 Stasiun BMKG & $CH_{b,t-3}$ di 6 Balai PSAWS	164
Lampiran 23.	<i>Scatter-Plot</i> Kec. Angin di 3 Stasiun BMKG & $CH_{b,t-4}$ di 6 Balai PSAWS	165
Lampiran 24.	<i>Scatter-Plot</i> Kec. Angin di 3 Stasiun BMKG & $CH_{b,t-5}$ di 6 Balai PSAWS	166
Lampiran 25.	<i>Syntax R</i> PCA dan Output	167
Lampiran 26.	Hasil Prediksi Variabel Prediktor.....	168
Lampiran 27.	Skema Variabel Input untuk ke-6 Balai CH.....	169
Lampiran 28.	<i>Output R</i> Korelasi & Signifikansi antar Unsur Iklim.....	170
Lampiran 29.	Plot Prediksi $CH_{1,t}$ (NA) & Prediktor Juanda...	173
Lampiran 30.	Plot Prediksi $CH_{1,t}$ (NA) & Prediktor Perak2...	174
Lampiran 31.	Plot Prediksi $CH_{1,t}$ (NA) & Prediktor Perak1 ...	175
Lampiran 32.	Plot Prediksi $CH_{1,t}$ (NA) & Prediktor PCA	176
Lampiran 33.	Plot Prediksi $CH_{2,t}$ (NA) & Prediktor Juanda...	177
Lampiran 34.	Plot Prediksi $CH_{2,t}$ (NA) & Prediktor Perak2...	178
Lampiran 35.	Plot Prediksi $CH_{2,t}$ (NA) & Prediktor Perak1 ...	179
Lampiran 36.	Plot Prediksi $CH_{2,t}$ (NA) & Prediktor PCA	180
Lampiran 37.	Plot Prediksi $CH_{3,t}$ (NA) & Prediktor Juanda...	181
Lampiran 38.	Plot Prediksi $CH_{3,t}$ (NA) & Prediktor Perak2...	182
Lampiran 39.	Plot Prediksi $CH_{3,t}$ (NA) & Prediktor Perak1 ...	183
Lampiran 40.	Plot Prediksi $CH_{3,t}$ (NA) & Prediktor PCA	184
Lampiran 41.	Plot Prediksi $CH_{4,t}$ (NA) & Prediktor Juanda...	185
Lampiran 42.	Plot Prediksi $CH_{4,t}$ (NA) & Prediktor Perak2...	186
Lampiran 43.	Plot Prediksi $CH_{4,t}$ (NA) & Prediktor Perak1 ...	187

Lampiran 44.	Plot Prediksi CH _{4,t} (NA) & Prediktor PCA.....	188
Lampiran 45.	Plot Prediksi CH _{5,t} (NA) & Prediktor Juanda...	189
Lampiran 46.	Plot Prediksi CH _{5,t} (NA) & Prediktor Perak2...	190
Lampiran 47.	Plot Prediksi CH _{5,t} (NA) & Prediktor Perak1...	191
Lampiran 48.	Plot Prediksi CH _{5,t} (NA) & Prediktor PCA.....	192
Lampiran 49.	Plot Prediksi CH _{6,t} (NA) & Prediktor Juanda...	193
Lampiran 50.	Plot Prediksi CH _{6,t} (NA) & Prediktor Perak2...	194
Lampiran 51.	Plot Prediksi CH _{6,t} (NA) & Prediktor Perak1...	195
Lampiran 52.	Plot Prediksi CH _{6,t} (NA) & Prediktor PCA.....	196
Lampiran 53.	Plot & Boxplot Harian CH 6 Balai PSAWS (Bulan Desember Selama 10 Tahun).....	197
Lampiran 54.	Estimasi & Signifikansi Parameter pada Model Terbaik.....	198
Lampiran 55.	<i>Syntax</i> R GCMR.....	202
Lampiran 56.	Banjir Prediksi di 5 Rayon	203

(Halaman ini sengaja di kosongkan)

BAB I

PENDAHULUAN

1.1 Latar Belakang

Indonesia merupakan salah satu negara yang berpotensi memiliki tingkat rawan bencana alam yang tinggi. Hal tersebut disebabkan oleh letak geografis Indonesia yang terdiri dari kepulauan, serta diapit oleh empat lempeng tektonik di setiap perbatasannya. Empat lempeng tektonik tersebut diantaranya adalah dua lempeng benua, Benua Asia dan Australia serta dua lempeng samudera, Samudera Hindia dan Pasifik. Tidak hanya berdasarkan letak geografisnya, letak astronomisnya yang terletak berdasarkan pada garis lintang 6° LU (Lintang Utara) - 11° LS (Lintang Selatan), menjadikan Indonesia berada di wilayah beriklim tropis. Akibatnya, Indonesia hanya memiliki dua musim yaitu musim panas dan musim hujan. Dikarenakan Indonesia termasuk negara tropis, Indonesia menjadi salah satu negara yang memiliki hutan hujan tropis yang luas, disinari oleh matahari sepanjang tahun serta memiliki kelembaban dan curah hujan yang tinggi (Geost, 2018).

Curah hujan yang tinggi menjadikan Indonesia selalu dihadapkan dengan permasalahan banjir. Terbukti banjir merupakan salah satu bencana alam yang paling sering terjadi di Indonesia. Berdasarkan Badan Nasional Penanggulangan Bencana (BNPB), bencana alam banjir dari tahun 1815 memiliki tingkat kejadian paling tinggi atau paling sering terjadi jika dibandingkan dengan tingkat bencana alam lainnya. Banjir merupakan salah satu bagian dari bencana hidrometeorologi yang selalu mendominasi setiap tahunnya. Saat ini bencana hidrometeorologi sendiri selalu menunjukkan trend yang terus meningkat. Itu berarti, bencana banjir juga ikut terus meningkat setiap tahunnya di Indonesia.

Secara umum, banjir merupakan suatu peristiwa dimana kondisi air meningkat serta melampaui kapasitas daya tampungnya. Menurut kementerian kesehatan, terdapat berbagai tipe banjir, diantaranya adalah banjir bandang, banjir lumpur, banjir rob, banjir cileungang dan banjir air atau banjir lokal.

Salah satu kota di Indonesia yang masih dihadapkan dengan adanya bencana banjir diantaranya adalah Kota Surabaya. Kota Surabaya merupakan salah satu kota terbesar dan tertua di Indonesia. Kota Surabaya merupakan Ibu Kota Provinsi Jawa Timur yang memiliki luas 330,45 km² dengan jumlah penduduk lebih dari tiga juta orang. Terletak diantara 07°12' – 07°21' Lintang Selatan dan 112° 36' -112° 54' Bujur Timur. Menjadikan Kota Surabaya berbatasan dengan Selat Madura di sebelah utara dan timur, Kabupaten Sidoarjo di sebelah selatan serta Kabupaten Gresik di sebelah barat (PTSP, 2017). Tidak hanya itu, Kota Surabaya juga merupakan salah satu kota yang mengalami perkembangan yang cukup pesat, baik dari segi fisik maupun non fisik. Kota Surabaya merupakan pusat perumbuhan ekonomi di Jawa Timur. Secara geografis letak Kota Surabaya berada di jalur perdagangan kawasan timur dan barat Indonesia. Potensi perdagangan di Kota Surabaya tidak hanya dari arus perdagangan domestik (antar kabupaten, kota, pulau) melainkan juga dari arus perdagangan internasional. Hal ini di dukung dengan infrastruktur pendukung berskala internasional yang cukup lengkap, seperti pelabuhan, bandara, kebutuhan energi dan yang lainnya (Istifadah dkk, 2017).

Terdapat berbagai macam penghargaan lingkungan hidup yang diperoleh oleh Kota Surabaya, yang baru saja diperoleh yaitu pada tanggal 14 Januari 2019. Kota Surabaya mendapatkan tiga penghargaan sekaligus dari Kementerian Lingkungan Hidup dan Kehutanan (KLHK), diantaranya dalah Adipura Kencana, Kinerja

Pengurangan Sampah dan Nirwsita Tantra (Humas Surabaya, 2019). Walaupun Kota Surabaya merupakan salah satu kota terbesar ke-dua di Indonesia dengan berbagai pengharganya khususnya dibidang lingkungan, Surabaya masih dihadapkan dengan adanya permasalahan bencana banjir. Bencana banjir dapat sering terjadi di Surabaya juga di sebabkan oleh kondisi wilayah Surabaya itu sendiri yang sebagian besar merupakan dataran rendah. 80,72% atau lebih dari 50% letak wilayah Surabaya berada pada ketinggian -0,5 s.d 5m SHVP atau berada pada 3 s.d 6 m di atas permukaan laut. Sedangkan sisa wilayah lainnya di Surabaya yaitu sekitar 19,28% nya merupakan daerah perbukitan. 12,77% wilayah perbukitan berada di wilayah Surabaya Barat sedangkan 6,52%-nya berada di wilayah Surabaya Selatan (Bahri & Madlazim, 2012).

Beberapa bulan terakhir ini, terdapat kejadian banjir yang menimpa beberapa daerah di Surabaya. Salah satunya banjir yang terjadi yaitu kejadian banjir yang diungkapkan oleh Sutopo Purwo (2019) sebagai kepala pusat data dan humas BNPB. Banjir terjadi pada 31 Januari 2019 yang merendamkan beberapa perumahan elite di Surabaya Barat seperti Perumahan Citraland, Taman Puspa, Pakuwon dan Bukit Palma yang juga mengakibatkan satu orang pelajar (13 tahun) meninggal dunia akibat hanyut di sungai. Tidak hanya perumahan yang terendam tentu hal ini juga mengakibatkan terendamnya kendaraan pribadi yang dimiliki.

Walaupun sudah banyak upaya yang telah dilakukan oleh pemerintah Kota Surabaya dalam mengurangi tingkat bencana banjir khususnya banjir genangan setiap tahunnya, namun bencana banjir masih belum dapat dihindari. Hal ini sangat dipengaruhi oleh faktor perubahan iklim secara global. Dampak perubahan iklim telah diamati dan diproyeksikan akan meningkat di masa mendatang. Secara umum model perubahan iklim global

memproyeksikan Indonesia akan mengalami kenaikan permukaan laut dan perubahan intensitas pola curah hujan yang akan meningkatkan risiko banjir (Case dkk, 2007). Kenaikan permukaan laut global saat ini meningkat sekitar 2 milimeter per-tahun (IPCC, 2017) dan diperkirakan akan meningkat 3 s.d 5 milimeter per-tahun di wilayah pesisir Indonesia akibat pemanasan global (Soesilo, 2014). Sedangkan pada kenyataannya di Indoneisa khususnya di Surabaya, 60 persen penduduk tinggal di daerah pesisir. Sehingga naiknya permukaan air laut mengakibatkan banjir di daerah pesisir setiap tahunnya meningkat (Case dkk, 2007). Tidak hanya itu, dampak dari perubahan iklim global adalah perubahan intensitas dan pola curah hujan yang merupakan hasil peningkatan suhu permukaan. Penurunan curah hujan selama masa-masa kritis tahun ini dapat meningkatkan risiko kekeringan yang tinggi, sementara peningkatan curah hujan selama musim hujan tahun ini dapat menyebabkan risiko banjir yang tinggi (Soesilo 2014).

Perubahan iklim di Indonesia mulai mendapat perhatian global ketika pemerintah Indonesia menjadi tuan rumah *United Nations Climate Change Conference* di Bali pada tahun 2007. Hal tersebut dikarenakan Indonesia merupakan salah satu negara penghasil emisi gas rumah kaca (*greenhouse*) terbesar. Perubahan iklim global menyebabkan berbagai dampak negatif diantaranya yaitu pada lingkungan, populasi makhluk hidup serta perkembangan sosial dan ekonomi negara (Measey, 2010). Cuaca ataupun iklim yang terus berubah menjadikan sulitnya memprediksi suatu kejadian yang tidak diinginkan seperti banjir. Menjadikan setiap masyarakat perlu melakukan antisipasi dalam menghadapi banjir.

Penelitian Masarotto dan Varin (2012) melakukan penelitian mengenai penggunaan model *Copula Gaussian* untuk analisis regresi marginal pada data yang berkorelasi dan tidak normal.

Spesifikasi model yang tepat menghasilkan interpretasi sederhana dari parameter-parameter marginal dan fleksibilitas yang baik dalam struktur dependen dan telah dibuktikan penerapannya dalam data *time-series*, studi longitudinal, data spasial dan analisis survival. Analisis regresi biasa digunakan untuk menjelaskan hubungan antara variabel prediktor dan respon. Untuk metode copula itu sendiri, tidak membutuhkan asumsi untuk setiap variabel yang akan digunakan. Copula merupakan metode yang dapat memformulasikan struktur dependensi pada variabel random, metode copula dapat menjadi metode alternatif dalam memodelkan struktur dependensi. Selain itu, metode ini dapat menggambarkan ketergantungan pada titik ekstrim dengan jelas. Pada umumnya setiap variabel pada data klimatologi merupakan saling dependen dan tidak berdistribusi normal (Schölzel & Friederich, 2008).

Tidak hanya itu Masarotto & Varin (2017) juga kembali mengaplikasikannya pada data *time series* yang dapat terbukti bahwa residual pada data dengan menggunakan *Gaussian Copula Regression* dapat memenuhi asumsi deret waktu. Sedangkan untuk memprediksi banjir disini akan dilakukan perhitungan matematis hidrologi dikarenakan untuk data pengamatan harian pada karakteristik banjir tidak dilakukan sehingga data tidak tersedia. Sehingga pada penelitian kali ini akan melakukan prediksi curah hujan berbasis pemodelan menggunakan pendekatan *Gaussian Copula Marginal Regression* (GCMR) berdasarkan unsur iklim di tiga stasiun meteorologi BMKG di Kota Surabaya. Unsur iklim yang digunakan untuk prediksi curah hujan diantaranya adalah rata-rata dari temperatur udara, kelembaban udara, dan kecepatan angin. Serta untuk melakukan prediksi banjir di Kota Surabaya yaitu menggunakan perhitungan matematis hidrologi menggunakan metode rasional untuk menemukan periode ulang banjir di Kota Surabaya.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, maka rumusan permasalahan pada penelitian kali ini adalah bagaimana memprediksi banjir berdasarkan prediksi curah hujan berdasarkan unsur klimatologi di tiga stasiun BMKG Kota Surabaya, menggunakan pemodelan dengan pendekatan regresi berbasis Copula khususnya menggunakan *Gaussian Copula Marginal Regression* (GCMR).

1.3 Tujuan

Berdasarkan rumusan masalah yang telah diuraikan di atas, tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut.

1. Mendeskripsikan karakteristik data penelitian yang akan digunakan, meliputi unsur klimatologi dan banjir di Kota Surabaya
2. Memodelkan dan memprediksi curah hujan di enam wilayah pengamatan berdasarkan unsur klimatologi di tiga stasiun BMKG menggunakan pemodelan dengan pendekatan *copula-based regression* (GCMR) di Kota Surabaya.
3. Memprediksi banjir di Kota Surabaya berdasarkan prediksi curah hujan di setiap balai pengamatan curah hujan menggunakan perhitungan matematis hidrologi (Metode Rasional).

1.4 Manfaat

Hasil yang diharapkan dari penelitian ini dapat memberikan informasi mengenai prediksi curah hujan untuk dapat mengetahui prediksi banjir di Kota Surabaya. Sehingga hasil penelitian ini diharapkan dapat bermanfaat bagi berbagai pihak, diantaranya adalah :

1. Bagi pemerintah, dapat memberikan informasi dan rekomendasi terkait risiko ekstrim banjir sehingga dapat menjadi *early warning system* serta upaya pencegahan banjir di Kota Surabaya.
2. Bagi BMKG, khususnya BMKG di Stasiun Juanda, Stasiun Perak 2 dan Stasiun Perak 1. Yaitu dapat memberikan rekomendasi serta evaluasi dalam memprediksi curah hujan menggunakan metode statistika.
3. Memberikan wawasan keilmuan statistika mengenai pemodelan menggunakan *copula-based regression* (BMKG) yang dapat diterapkan pada data klimatologi. Serta dapat menjadi referensi dalam memodelkan ataupun memprediksi curah hujan dan banjir di Kota Surabaya.

1.5 Batasan Masalah

Batasan penelitian yang digunakan dalam penelitian ini adalah jumlah data harian yang akan digunakan (10 tahun) serta adanya data yang *missing* di beberapa variabel prediktor dan juga variabel respon. Dikarenakan tidak tersedianya data curah hujan di Simo selama satu tahun lebih dikarenakan rusaknya alat ukur curah hujan, maka variabel tersebut tidak digunakan dalam penelitian ini. Pada penelitian ini, prediksi banjir hanya dipengaruhi oleh prediksi curah hujan tanpa meninjau penyebab banjir lainnya. Untuk wilayah pengamatan banjir disesuaikan dengan wilayah pengamatan curah hujan (enam balai) dengan sistem saluran dan drainase yang sama sehingga dianggap dapat mewakili keseluruhan Kota Surabaya. Serta dalam melakukan analisis PCA di asumsikan setiap unsur iklim di lokasi yang berbeda diduga berkorelasi, tidak memperhatikan hubungan antar unsur iklim.

(Halaman ini sengaja dikosongkan)

BAB II

TINJAUAN PUSTAKA

2.1 Pre-Processing Data

Pre-processing data perlu untuk dilakukan. Hal ini dikarenakan data memiliki kualitas yang sesuai dengan persyaratan penggunaan data. Terdapat banyak faktor yang mencakup kualitas data antara lain akurasi, kelengkapan, konsistensi, *timeliness*, *believability*, dan *interpretability*. Proses *pre-processing* data meliputi pembersihan data, integrasi data, reduksi data, dan transformasi data (Han, Kamber, & Pei, 2012).

2.2 Time Series

Time series atau deret waktu merupakan serangkaian nilai atau observasi dari suatu variabel tertentu yang berurutan tiap periodenya. Adanya data *time series* ini dapat dijadikan sebagai dasar dalam melakukan perencanaan kegiatan di masa depan (peramalan) (Wei, 2006). Tipe dan pola data merupakan salah satu hal penting yang perlu diperhatikan dalam peramalan *time series*. Secara umum terdapat empat macam pola data *time series*, yaitu horizontal, *trend*, musiman, dan siklis (Syntetos, 2006). Tujuan dari dilakukannya analisis deret waktu ini secara umum dibedakan menjadi dua, yaitu untuk mengetahui atau memodelkan mekanisme proses stokastik yang dapat menghasilkan observasi yang runtun dan untuk memprediksi atau meramalkan nilai yang akan datang dari sebuah data yang runtun berdasarkan pola histori data runtun tersebut dan memungkinkan data runtun yang lainnya maupun faktor-faktor yang lainnya (Cryer & Chan, 2008).

Ada beberapa hal yang harus diperhatikan dalam melakukan analisis data *time series*, diantaranya adalah : stasioneritas data,

Autocorrelation Function (ACF) dan *Partial Autocorrelation Function* (PACF).

- Stasioneritas

Stasioneritas berarti bahwa tidak terdapat perubahan drastis pada data. Fluktuasi data berada disekitar suatu nilai rata-rata yang konstan, tidak bergantung pada waktu dan variansi dari fluktuasi tersebut.

- ACF

Autocorrelation Function (ACF) merupakan suatu fungsi yang digunakan untuk menjelaskan korelasi antara Y_t dan Y_{t+k} dari suatu proses yang sama dan hanya terpisah oleh lag waktu ke- k . Perhitungan ACF untuk sampel Y_1, Y_2, \dots, Y_n dapat diperoleh melalui persamaan berikut (Wei, 2006).

$$\hat{\rho}_k = \frac{\sum_{i=1}^{n-k} (Y_i - \bar{Y})(Y_{i+k} - \bar{Y})}{\sum_{i=1}^n (Y_i - \bar{Y})^2}, k = 0, 1, 2, \dots, n \quad (2.1)$$

- PACF

Partial Autocorrelation Function (PACF) digunakan untuk mengukur korelasi antara Y_t dan Y_{t+k} setelah pengaruh variabel $Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}$ dihilangkan (Wei, 2006). Perhitungan PACF untuk sampel dapat diperoleh melalui persamaan berikut.

$$\hat{\phi}_{k+1, k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j} \quad (2.2)$$

dan

$$\hat{\phi}_{k+1, j} = \hat{\phi}_{k, j} - \hat{\phi}_{k+1, k+1} \hat{\phi}_{k, k+1-j}, j = 1, 2, \dots, k \quad (2.3)$$

Untuk menduga orde p dan q dari model ARIMA dilakukan dengan melihat bentuk dari plot ACF dan PACF. Tabel 2.1 merupakan bentuk-bentuk plot ACF dan PACF dari model ARIMA secara teoritis. Berdasarkan plot ACF dan PACF terdapat beberapa dugaan model ARIMA (Wei, 2006).

Tabel 2.1 Subfamilies Copula Archimedean

Model	Plot ACF	Plot PACF
AR (p)	Turun cepat secara eksponensial	Terpotong setelah lag ke- p
MA (q)	Terpotong setelah lag- q	Turun cepat secara eksponensial
ARMA (p, q)	Turun cepat setelah lag (p, q)	Turun cepat setelah lag (p, q)

Differencing merupakan salah satu cara yang dapat digunakan untuk mengatasi data yang tidak stasioner dalam rata-rata. *Differencing* merupakan suatu proses membuat data baru dengan rata-rata konstan, yang artinya menghitung perubahan pada data secara berturut – turut. Secara garis besar *differencing* dibagi dua, yaitu *differencing series* dan *differencing seasonal*. Untuk *differencing series* dengan $d = 1$ dapat dirumuskan $W_t = X_t - X_{t-1}$. Jika $d = 1$ belum dapat menjadikan data *time series* mempunyai rata-rata yang konstan, maka dapat dilakukan $d = 2$ dan seterusnya. Sedangkan untuk *differencing seasonal*, berarti menghitung pergeseran data secara musiman berdasarkan periode waktu tertentu, biasanya dinotasikan s untuk menstimulasi rata-rata dalam series menjadi konstan. Untuk data kuartal, $s = 4$; untuk data bulanan, $s = 12$; untuk data tahunan, $s = 365$ dan seterusnya. Jika $d = 0$ dan *differencing seasonal* ($D = 1$) maka dapat dirumuskan $W_t = X_t - X_{t-s}$.

Salah satu metode sederhana dalam memprediksi data *time-series* adalah dengan menggunakan metode musiman Holt-

Winters. Metode ini terdiri dari persamaan perkiraan dan tiga persamaan pemulusan - satu untuk tingkat l_t satu untuk tren b_t , dan satu untuk komponen musiman s_t dengan parameter penghalusan yang sesuai α , β^* dan γ . Ada dua variasi metode ini yang berbeda dalam sifat komponen musiman. Metode aditif lebih disukai ketika variasi musiman kira-kira konstan melalui seri, sedangkan metode multiplikasi lebih disukai ketika variasi musiman berubah sebanding dengan tingkat seri. Dengan menggunakan R, hasil prediksi optimum menggunakan metode Holt-Winters dapat menggunakan *function* ‘holtwinters’.

2.3 Principal Component Analysis (PCA)

PCA merupakan suatu prosedur untuk mereduksi dimensi data melalui transformasi variabel-variabel asal yang berkorelasi menjadi sekumpulan variabel baru yang tidak berkorelasi. Variabel-variabel baru tersebut disebut dengan komponen utama atau *Principal Component* (PC). PCA sering digunakan pada permasalahan yang melibatkan banyak variabel dan terdapat korelasi yang tinggi antar variabel.

Misalkan vektor random $x = [x_1, x_2, \dots, x_p]$ yang terdiri atas sejumlah observasi sebanyak p variabel, maka PC adalah kombinasi linear dari p variabel tersebut yang merupakan sistim koordinat baru yang diperoleh dari hasil rotasi sistem asal x_1, x_2, \dots, x_p sebagai sumbu koordinat. Sumbu baru z_1, z_2, \dots, z_p adalah PC yang tidak berkorelasi. PC dapat diperoleh dari pasangan eigen value dan eigen vektor matriks kovarian maupun matriks korelasi (pada penelitian kali ini menggunakan matriks korelasi). Apabila satuan data tiap variabel tidak sama, maka data distandarisasikan terlebih dahulu. Hal ini bertujuan untuk menghindari dominansi satu atau dua variabel dalam PC.

Selanjutnya, bila Σ adalah matriks varian-kovarian dari vektor random $\mathbf{x}=[x_1, x_2, \dots, x_p]$, maka Σ dapat diperoleh berdasarkan rumus berikut.

$$\Sigma = \frac{1}{n-1} \sum_{i=1}^n (x_i - \mu)(x_i - \mu)^T \quad (2.4)$$

Keterangan

- μ : rata-rata observasi
- x_i : observasi ke- i
- n : jumlah observasi

Σ memiliki pasangan *eigen-value* dan *eigen-vector* $(\lambda_1, e_1), (\lambda_2, e_2), \dots, (\lambda_p, e_p)$ dengan $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$. Maka model PC dapat ditulis sebagai berikut.

$$\begin{aligned} Z_p &= e_p' \mathbf{X} = e_{1p}X_1 + e_{2p}X_2 + \dots + e_{pp}X_p \\ Z_p &= e_p' \mathbf{X} = e_{12}X_1 + e_{22}X_2 + \dots + e_{p2}X_p \\ &\quad \vdots \\ Z_p &= e_p' \mathbf{X} = e_{1p}X_1 + e_{2p}X_2 + \dots + e_{pp}X_p \end{aligned} \quad (2.5)$$

Keterangan

- Z_1 : PC pertama, mempunyai varians terbesar
- Z_p : PC ke- p , mempunyai varians terbesar ke- p
- X_1 : variabel asal pertama
- X_p : variabel asal ke- p

maka diperoleh :

$$\begin{aligned} \text{var}(Z_i) &= e_i' \Sigma e_i & i = 1, 2, \dots, p \\ \text{cov}(Z_i, Z_k) &= e_i' \Sigma e_k & i \neq k \end{aligned} \quad (2.6)$$

PC tidak berkorelasi dan mempunyai varians yang sama dengan eigen value dari Σ , sehingga dapat dilihat sebagai berikut.

$$\sigma_{11} + \sigma_{22} + \dots + \sigma_{11} = \sum_{i=1}^p \text{var}(x_i) = \Sigma^T = \lambda_1 + \lambda_2 + \dots + \lambda_p \quad (2.7)$$

Apabila total variansi populasi adalah $\sigma_{11} + \sigma_{22} + \dots + \sigma_{11} = \lambda_1 + \lambda_2 + \dots + \lambda_p$, maka proporsi varian ke- $i = \lambda_i / \lambda_1 + \lambda_2 + \dots + \lambda_p$.

Apabila PC yang diambil sebanyak k dengan ($k < p$), maka proporsi varian k PC adalah sebagai berikut.

$$\frac{\lambda_1 + \lambda_2 + \dots + \lambda_k}{\lambda_1 + \lambda_2 + \dots + \lambda_p} \quad (2.8)$$

Apabila yang digunakan di awal adalah matriks kovarians dari data yang distandarkan, karena diagonal utama matriks berisi nilai satu, maka total variansi populasi untuk variabel distandarkan adalah p , yang merupakan jumlah elemen diagonal matriks \mathcal{D} . Sehingga,

$$\text{Proporsi varian ke-}i = \frac{\lambda_i}{p} \quad (2.9)$$

Salah satu tujuan dari PCA yaitu mereduksi dimensi data asal yang semula terdapat p variabel bebas menjadi k PC dengan $k < p$. Kriteria dalam pemilihan k antra lain (Johnson & Wichern, 2002) :

1. Proporsi kumulatif keragaman data asal yang dijelaskan oleh k PC minimal 80% dan proporsi total variansi populasi bernilai cukup besar.
2. Melihat *scree plot*, dapat menggambarkan besarnya eigen value dengan jumlahnya. Untuk menentukan jumlah PC yang sesuai, maka bisa dilihat pada potongan atau patahan pada garis.

2.4 Copula

Copula pertama kali diperkenalkan oleh Abe Sklar pada tahun 1959 melalui Teorema Sklar. Menurut teorema Sklar, copula merupakan suatu fungsi yang menghubungkan fungsi distribusi multivariat dengan distribusi marginalnya (Nelsen, 2005). Tidak hanya itu, Copula juga dapat mengeksplorasi dan mengkarakterisasi struktur dependensi antar variabel random melalui fungsi distribusi marginal (Genest & Segers, 2010).

Copula merupakan distribusi bersama dari variabel random, jika terdapat (u_1, u_2, \dots, u_p) yang merupakan variabel random kontinu yang masing-masing memiliki distribusi *marginally uniformly* $U(0,1)$. Istilah Copula juga digunakan sebagai fungsi distribusi kumulatif bersama dari distribusi tersebut.

$$C(u_1, u_2, \dots, u_p) = P(U_1 \leq u_1, U_2 \leq u_2, \dots, U_p \leq u_p) \quad (2.10)$$

dimana $C_U : [0,1] \times \dots \times [0,1] \rightarrow [0,1]$. Jika terdapat variabel random yang saling independen maka $C(u_1, u_2, \dots, u_p) = u_1 \times u_2 \times \dots \times u_p$. Serta sebaliknya, jika saling dependen dengan probabilitas satu maka $C(u_1, u_2, \dots, u_p) = \min(u_1 \times u_2 \times \dots \times u_p)$.

Berdasarkan Teorema Sklar's, untuk variabel random X_1, X_2, \dots, X_p dengan joint CDF

$$F(x_1, x_2, \dots, x_p) = P(X_1 \leq x_1, X_2 \leq x_2, \dots, X_p \leq x_p) \quad (2.11)$$

dan dengan marginal CDF

$$F_j(x) = P(X_j \leq x), j = 1, 2, \dots, p \quad (2.12)$$

$$F(x_1, x_2, \dots, x_p) = C[F_1(x_1), F_2(x_2), \dots, F_p(x_p)] \quad (2.13)$$

Saat $F(\cdot)$ dan $C(\cdot)$ di diferensiasi, maka PDF dari Copula,

$$\frac{f(x_1, x_2, \dots, x_p)}{f_1(x_1)f_2(x_2)\dots f_p(x_p)} = c[F_1(x_1), F_2(x_2), \dots, F_p(x_p)] \quad (2.14)$$

dengan dimana $c(\cdot)$ merupakan PDF dari distribusi Copula,

$$c(u_1, u_2, \dots, u_p) = \frac{\partial^p}{\partial u_1 \partial u_2 \dots \partial u_p} C(u_1, u_2, \dots, u_p) \quad (2.15)$$

Sehingga Copula juga dapat diartikan sebagai penyesuaian yang perlu dilakukan guna mengubah PDF yang saling independen menjadi joint PDF.

Copula yang sering sekali digunakan terbagi menjadi dua macam families (keluarga Copula), yaitu Copula Elips dan Copula Archimedean. Berikut penjelasan untuk setiap Keluarga Copula tersebut.

2.4.1 Copula Elips (*Elliptical Copula*)

Copula Elips merupakan Copula yang distribusinya berbentuk elips. Jika terdapat p dimensi Copula Elips, maka akan terdapat paling sedikit $p(p-1)/2$ parameter. Untuk kasus *Spatial Extreme Model* Copula yang dapat digunakan adalah Copula Elips. Copula yang penting dalam Copula Elips adalah Copula Gaussian atau Normal dan Copula *Student's t* (Mung'atu, 2015).

Copula Normal atau Copula Gaussian diperoleh dari distribusi normal melalui teori Sklar's (1959). Jika Φ_p adalah fungsi distribusi kumulatif bivariat standar normal dengan korelasi ρ , maka fungsi Copula Normal adalah sebagai berikut.

$$C_p(u_1, u_2) = \Phi_p[\Phi^{-1}(u_1), \Phi^{-1}(u_2)] \quad (2.16)$$

dimana $u_1, u_2 \in [0,1]$ sehingga hasil diferensial C merupakan fungsi densitas Copula yaitu :

$$C_p(u_1, u_2) = \frac{\varphi_{x_1, x_2, \rho}(\Phi^{-1}(u_1), \Phi^{-1}(u_2))}{\varphi(\Phi^{-1}(u_1))\varphi(\Phi^{-1}(u_2))} \quad (2.17)$$

dengan,

$$\varphi_{x_1, x_2, \rho}(x_1, x_2) = \frac{1}{2\pi\sqrt{1-\rho^2}} \exp\left(-\frac{1}{2(1-\rho^2)}[x_1^2, x_2^2 - 2\rho x_1 x_2]\right) \quad (2.18)$$

φ merupakan fungsi densitas untuk *bivariate* normal standar dengan koefisien korelasi *pearson's product moment* p . Copula Gaussian memiliki batasan-batasan, jika dianalogikan pada distribusi normal multivariat maka diasumsikan mempunyai hubungan linier diantara transformasi variabel random.

Sedangkan untuk Copula *Students-t*, Menurut (Schölzel & Friederich, 2008), Copula-t merupakan analogi untuk Gaussian Copula menggunakan gabungan multivariat distribusi t , fungsi Copula- t . Copula- t menunjukkan fleksibilitas dalam struktur covarians dan tail dependensi. Suatu p -dimensi vektor random $\mathbf{X} = (X_1, X_2, \dots, X_p)$ dikatakan memiliki distribusi t multivariat dengan derajat bebas ν , vektor *mean* $\boldsymbol{\mu}$ dan dispersi definit positif atau matrik korelasi $\boldsymbol{\Sigma}$. Jika ditentukan $X \sim t_p(\nu, \boldsymbol{\mu}, \boldsymbol{\Sigma})$ dengan densitas sebagai berikut.

$$f(x) = \frac{\Gamma\left(\frac{\nu+p}{2}\right)}{\Gamma\left(\frac{\nu}{2}\right)\sqrt{(\pi\nu)^p |\boldsymbol{\Sigma}|}} \left(1 + \frac{(x-\boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (x-\boldsymbol{\mu})}{\nu}\right)^{\frac{\nu+p}{2}} \quad (2.19)$$

Parameter standar cov, $\text{cov}(\mathbf{X}) = \frac{v}{v-2} \Sigma$ dengan matrik korelasi

$\Sigma = \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix}$. Dalam kasus bivariat Copula- t dapat dituliskan sebagai

berikut.

$$C_v^t(u_1, u_2, v, \rho) = \int_{-\infty}^{t_v^{-1}(u_1)} \int_{-\infty}^{t_v^{-1}(u_2)} \frac{\Gamma\left(\frac{v+2}{2}\right)}{\Gamma\left(\frac{v}{2}\right) \pi v \sqrt{(1-\rho^2)}} \left(1 + \frac{x_1^2 - 2\rho x_1 x_2 + x_2^2}{(1-\rho^2)v}\right)^{v+2/2} dx_1 dx_2 \quad (2.20)$$

ρ merupakan koefisien korelasi, v adalah jumlah derajat bebas, sedangkan untuk densitas Copula- t dapat dilihat pada persamaan berikut.

$$c_t(u_1, u_2, v, \rho) = \frac{f_{vp}(t_v^{-1}(u_1), t_v^{-1}(u_2))}{f_v\left(\left\{t_v^{-1}(u_1), t_v^{-1}(u_2)\right\}\right)}, ; u_1, u_2, \rho \in (0,1) \quad (2.21)$$

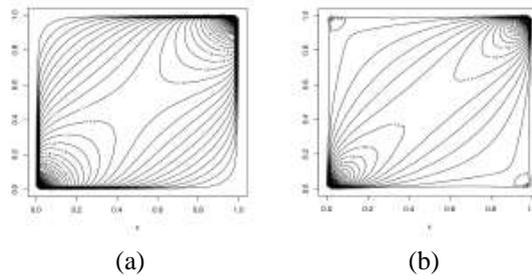
Keterangan

f_{vp} : distribusi gabungan

f_v : distribusi marginal t

t_v^{-1} : fungsi quantil dan distribusi t_v

Tail dependensi tersebut dapat dianggap sebagai probabilitas kondisional dari observasi ekstrim dalam satu komponen lain yang diberikan dalam keadaan yang ekstrim. Berikut *contour plots* untuk Copula Gaussian dan *Student's t* dengan 5000 variabel random dengan parameter = 0,5 dan v pada Copula $t = 15$.



Gambar 2.1 Contour Plots pada Copula (a) Gaussian dan (b) Student's t
(Sumber : Mung'atu, 2015)

Copula- t memiliki kelebihan pada struktur kovarian dan *tail dependence*, yang dapat dianggap sebagai kondisi probabilitas dan observasi ekstrim (Schölzel & Friederich, 2008).

2.4.2 Copula Archimedean

Copula Archimedean terdiri dari tiga subfamilies, yaitu Copula Clayton/Cook Johnson, Gumbel Copula and Frank Copula (Genest dan Rivest, 1993). Sebelum mengetahui lebih lanjut dari ke-tiga subfamilies tersebut, maka dapat diketahui terlebih dahulu bahwa $U_1 = F(x_1)$ dan $U_2 = G(x_2)$ dengan $U_1 \in [0,1]$ dan $U_2 \in [0,1]$. Untuk u_1 dan u_2 , masing-masing merupakan nilai atau realisasi dari U_1 dan U_2 . Notasi ϕ di definisikan sebagai fungsi kontinu, konstan menurun dan $\phi(1) = 0$. Formulasi dari Copula Archimedean secara umum adalah sebagai berikut.

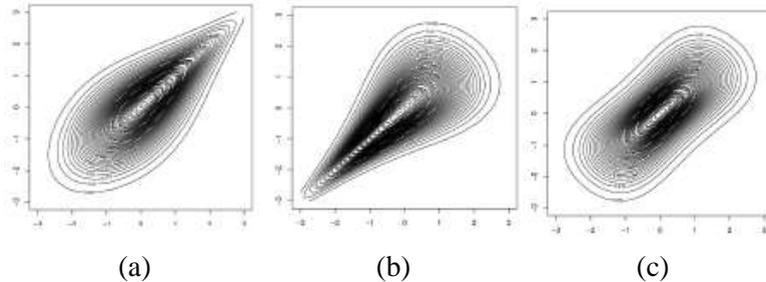
$$C_{\theta}(u_1, u_2, \dots, u_p) = \phi^{-1}[\phi(u_1) + \phi(u_2) + \dots + \phi(u_p)] \quad (2.22)$$

$\phi(t) = (-\ln t)^{\theta}$ merupakan generator atau fungsi pembangkit dari Copula Archimedean, dengan θ disetiap Copula Archimedean mengandung parameter θ (Zhang dkk, 2012). Berikut perbedaan dari ketiga *subfamilies* Copula Archimedean beserta generatornya.

Tabel 2.2 Subfamilies Copula Archimedean		
Copula	Generator	Copula Bivariate

C	$\phi(t)$	$C_\theta(u_1, u_2)$
Gumbel (1960)	$(-\ln t)^\theta$	$\exp\left\{-\left[(-\ln u_1)^\theta + (-\ln u_2)^\theta\right]^{1/\theta}\right\}, \theta \in [1, \infty)$
Clayton (1978)	$\frac{t^{-\theta} - 1}{\theta}$	$\left(u_1^{-\theta} + u_2^{-\theta} - 1\right)^{-\frac{1}{\theta}}, \theta \in [0, \infty)$
Frank (1979)	$-\ln\left(\frac{\exp(-\theta) - 1}{\exp(-\theta) - 1}\right)$	$-\frac{1}{\theta} \ln\left(1 + \frac{[\exp(-\theta u_1) - 1][\exp(-\theta u_2) - 1]}{\exp(-\theta) - 1}\right), \theta \neq 0$

Setiap keluarga Copula Archimedean memiliki *tail* dependensi yang berbeda (Mung'atu, 2015). Pada saat data simulasi 5000 variabel random dengan *standard normal marginal* dan Tau-Kendal's adalah 0,5, maka dapat dilihat *contour plots* dari ke-tiga Copula sebagai berikut.



Gambar 2.2 Contour Plots pada Copula (a) Gumbel, (b) Clayton dan (c) Frank (Sumber : Mung'atu, 2015)

Berdasarkan Gambar 4.2 maka dapat terlihat perbedaan *tail* dependensi dari ke-tiga Copula tersebut. Copula Clayton memiliki *tail* dependensi di bagian bawah, Copula Frank tidak memiliki *tail* dependensi dan Copula Gumbel memiliki *tail* di bagian atas.

Terdapat beberapa kelebihan Copula Archimedean yang menjadikan Copula ini lebih menarik, diantaranya adalah (Zhou dkk, 2018).

1. hasil lebih mudah diperoleh

2. mampu menangkap varietas besar struktur dependensi dengan berbagai model stokastik Copula dapat digunakan untuk variabel acak berkorelasi positif dan negatif.

2.5 Gaussian Copula Marginal Regression (GCMR)

Dapat diketahui $\mathbf{y}=(y_1, y_2, \dots, y_n)^T$ merupakan suatu vektor dari variabel random, $\mathbf{y}=(y_1, y_2, \dots, y_n)^T$ yang saling dependen, dapat berupa variabel kontinu, diskrit ataupun kategorik. Dapat diketahui $P_i(y_i; \lambda) = P(y_i | x_i; \lambda)$ merupakan fungsi densitas dari $y_i | x_i$. Sehingga kovariat dapat memberikan efek tidak hanya untuk rata-rata Y_i melainkan juga terhadap keseluruhan distribusi marginal univariat. Fungsi densitas $P_i(y_i; \lambda)$ dapat diindikasikan sebagai model regresi. Dalam kasus tersebut, nantinya akan dapat mengidentifikasi model regresi tanpa membutuhkan asumsi terhadap respon yang dependen. Maka asumsi independen dapat membangkitkan marginal parameter λ menggunakan fungsi *pseudolikelihood* sebagai berikut.

$$L_{\text{ind}}(\lambda; y) = \prod_{i=1}^n P_i(y_i; \lambda) \quad (2.23)$$

Pada saat $P_i(y_i; \lambda)$ sudah benar-benar sesuai, maka maksimum estimator independen $\lambda_{\text{ind}} = \arg \max_{\lambda} L_{\text{ind}}(\lambda; y)$ akan konsisten dapat mengestimasi λ tanpa memerlukan spesifikasi *joint distribution* (distribusi bersama) dengan mempertimbangkan model matrix $\mathbf{X}=(x_1, \dots, x_n)^T$. Model yang ideal akan mengandung keseluruhan *joint distribution* \mathbf{Y} dengan marginal univariat $P_i(y_i; \lambda)$. Namun model semiparametrik tersebut sangatlah

umum, dan hanya dapat digunakan pada kasus sederhana. Berikut identifikasi dan pengembangan model parametrik yang cukup fleksibel digunakan dalam berbagai kasus. Bentuk umum dari model *Gaussian Copula Marginal Regression* adalah sebagai berikut.

$$Y_i = g(x_i, e_i; \lambda), i = 1, 2, \dots, n \quad (2.24)$$

Keterangan

- $g(\cdot)$: fungsi regresi yang sesuai (*link function*)
- e_i : error dari model
- λ : parameter

Diantara banyak kemungkinan $g(\cdot)$, pemilihan model adalah sebagai berikut.

$$Y_i = F_i^{-1} \{ \Phi(e_i; \lambda) \}, i = 1, 2, \dots, n \quad (2.25)$$

Dimana $\Phi(\cdot)$ adalah fungsi distribusi kumulatif dari error, atau dapat dituliskan dengan $F_i(\cdot; \lambda) = F(\cdot | x_i; \lambda)$, dengan F adalah fungsi distribusi kumulatif dari Y_i bersyarat x_i atau $(Y_i | x_i)$. Berdasarkan teorema transformasi integral, model regresi pada persamaan (2.25) memastikan distribusi marginal dari Y_i . Spesifikasi model didapatkan dengan mengasumsikan vektor error $\mathbf{e} = (e_1, \dots, e_n)^T$ merupakan normal multivariat,

$$\mathbf{e} \sim MVN(0, \Omega) \quad (2.26)$$

dimana Ω merupakan matriks korelasi. Kasus pada observasi independen akan sesuai dengan $\Omega = \mathbf{I}_n$ dengan $n \times n$ identitas matrik. Sebagai contoh untuk *gaussian linear regression model*

$Y_i = x_i^T \beta + \varepsilon_i$, sesuai dengan $Y_i = F_i(Y_i; \lambda) = \Phi\left(Y_i - \frac{x_i^T \beta}{\sigma}\right)$ dengan $\lambda = (\beta^T \sigma)^T$.

Sebagai contoh, ketika model menggunakan model Poisson log-linear, maka.

$$F_i(Y_i; \lambda) = \sum_{j=0}^{Y_i} \frac{e^{-\mu_i} \mu_i^j}{j!} \quad (2.27)$$

dengan $\mu_i = \exp(x_i^T \beta)$, dengan $\lambda = \beta$.

Pada penelitian kali ini menggunakan marginal Gamma & Weibull dengan *link-function* “*sqr*t”. Hal ini dikarenakan respon yang akan digunakan memiliki nilai lebih besar sama dengan nol. Berikut penjelasan untuk kedua distribusi tersebut.

a) Distribusi Gamma

Distribusi Gamma merupakan salah satu keluarga eksponensial. Distrusi Gamma juga merupakan peubah kontinu non negatif. Fungsi densitas untuk distribusi Gamma adalah sebagai berikut.

$$f(y; \alpha, \lambda) = \frac{\lambda^\alpha}{\Gamma(\alpha)} y^{\alpha-1} \exp^{-\lambda y} I_{(0, \infty)}(y) \quad (2.28)$$

Dengan parameter α , $\lambda > 0$, $\Gamma(\cdot)$ fungsi Gamma dan $I(\cdot)$ adalah fungsi indikator. Berdasarkan PDF dapat diketahui bahwa $\mu = \exp(\mathbf{x}_i \beta) = \alpha / \lambda$ dan $\sigma^2 = \alpha / \lambda^2 = \mu^2 / \alpha$, dimana $\lambda = \alpha / \mu$. Parameter dari PDF dapat berupa *mean* (μ) dan *shape* (α). Pada model regresi Gamma dengan parameter *shape* konstan, maka struktur *mean regression* didefinisikan $g(\boldsymbol{\mu}_i) = \eta_i = \mathbf{x}_i \boldsymbol{\beta}$, dengan $g(\cdot)$ merupakan *link-function*, $\boldsymbol{\beta} = (\beta_0, \dots, \beta_p)'$ merupakan parameter *mean regression*. Untuk (η_i) merupakan prediktor

linear. Pada saat parameter *mean* dan *shape* mengikuti struktur regresi maka dapat dirumuskan sebagai berikut (Bassio & Cuervo, 2015).

$$g(\mu_i) = \mu_{1i} = \mathbf{x}'_i \boldsymbol{\beta} \quad (2.29)$$

$$g(\alpha_i) = \mu_{2i} = \mathbf{z}'_i \boldsymbol{\gamma} \quad (2.30)$$

b) Distribusi Weibull

Merupakan generalisasi dari Distribusi Eksponensial. Fungsi densitas dari distribusi Weibull dapat dituliskan sebagai berikut.

$$f(y; \alpha, \lambda) = \begin{cases} \frac{\lambda}{\alpha} \left(\frac{y}{\alpha}\right)^{\lambda-1} \exp^{-(y/\alpha)^\lambda} & , y \geq 0 \\ 0 & , y < 0 \end{cases} \quad (2.31)$$

Dengan parameter *shape* $\alpha > 0$ dan parameter *scale* $\lambda > 0$. Serta berdasarkan PDF dapat diketahui bahwa $\mu = \alpha \Gamma\left(1 + \frac{1}{\lambda}\right)$ dan $\sigma^2 = \alpha^2 \left[\Gamma\left(1 + \frac{2}{\lambda}\right) - \Gamma^2\left(1 + \frac{1}{\lambda}\right) \right]$

Model regresi digunakan untuk mengetahui pengaruh suatu variabel independen. Pengaruh variabel independen, dalam model regresi Weibull diekspresikan melalui parameter *shape* $\alpha = f_\alpha(X; \beta)$ ataupun parameter *scale* $\lambda = f_\lambda(X; \beta)$ dengan bentuk eksponensial $\exp(\beta X)$. Model regresi Weibull yang sering digunakan yaitu $\lambda = f_\lambda(X; \beta) = \exp(\beta X)$, sehingga fungsi untuk regresi Weibull adalah sebagai berikut.

$$f(y_i) = \exp\left(-\left(f_\lambda(X; \beta) y\right)^\alpha\right) \quad (2.32)$$

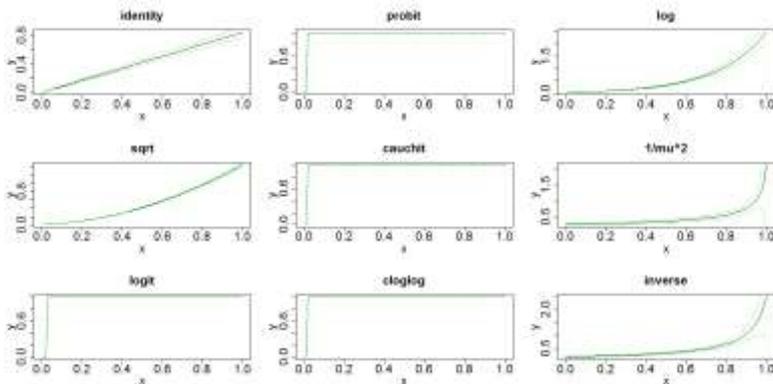
$$f(y_i) = \exp\left(-\left(\exp(\beta X) y\right)^\alpha\right) \quad (2.33)$$

Terdapat beberapa *link-function* yang biasa dapat digunakan, hal tersebut dapat dilihat pada Tabel. 2.3.

Tabel 2.3 *Link-Function*

<i>Link-Function</i>	μ	η
<i>Identity</i>	μ	η
<i>Square Root</i>	$\sqrt{\mu}$	η^2
<i>Inverse</i>	$\frac{1}{\mu}$	$\frac{1}{\eta}$
<i>1/mu Kuadrat</i>	$\frac{1}{\mu^2}$	$\frac{1}{\sqrt{\eta}}$

Untuk mengetahui perbedaan untuk setiap *link-function* dapat diaplikasikan pada salah satu data simulasi (contoh : Regresi Gamma). Sehingga dapat dilihat visualisasi *empirical inverse link* pada regresi Gamma dengan *link-function* yang berbeda.



Gambar 2.3 Ilustrasi *Link-Function* pada Regresi Gamma

2.6 Estimasi Parameter

Terdapat beberapa metode estimasi parameter Copula yang dapat digunakan, metode estimasi parameter copula dapat didekati pada model parametrik, semiparametrik dan non parametrik.

Menurut Choroś dkk, 2010 estimasi parameter copula dapat diperoleh dengan metode *Maximum Likelihood Estimation* (MLE). Sedangkan (Charpentier dkk, 2006). memperkenalkan macam-macam prosedur estimasi densitas fungsi Copula.

MLE untuk Copula diperoleh dengan memaksimalkan fungsi *log-likelihood*. Menurut teori Sklar (1959), fungsi densitas f dari p -dimensi F dengan marginal univariat F_1, F_2, \dots, F_p dan densitas univariat f_1, f_2, \dots, f_p dapat ditulis sebagai berikut.

$$f(x_1, x_2, \dots, x_p) = c(F_1(x_1), F_2(x_2), \dots, F_p(x_p)) \prod_{i=1}^p f_i(x_i) \quad (2.34)$$

Untuk kasus bivariat dengan $p = 2$, maka fungsi densitas marginal f_1 dan f_2 merupakan fungsi dari vektor parameter yang tidak diketahui $\theta \in \mathfrak{R}^p$, C adalah densitas Copula dan f adalah fungsi densitas bersama dengan vektor parameter tambahan $\rho \in \mathfrak{R}$, sehingga model fungsi likelihood dapat ditulis sebagai berikut.

$$\begin{aligned} \ln f(x_1, x_2; \theta, \rho) = & \ln c(F_1(x_1; \theta), F_2(x_2; \theta); \rho) \\ & + \ln f_1(x_1; \theta) + \ln f_2(x_2; \theta) \end{aligned} \quad (2.35)$$

Atau dapat ditulis sebagai berikut.

$$L = \sum_{i=1}^2 C_{u_1 u_2}(F_1(x_1), F_2(x_2)) f_1(x_1) f_2(x_2) \quad (2.36)$$

dimana parameter ρ menunjukkan dependensi keseluruhan antara dua variabel random.

Parameter Copula yang tidak diketahui pada Copula Archimedean dapat diestimasi berdasarkan koefisien korelasi Kendall, karena MLE tidak dapat menghasilkan bentuk *closed-form*.

$$\hat{\tau}_C = 1 + 4 \int_0^1 \frac{\phi(u)}{\phi^r(u)} du \quad (2.37)$$

berdasarkan persamaan (2.14) maka untuk masing-masing subfamilies Copula Archimedean dapat disajikan sebagai berikut (Zhang dkk, 2012).

Tabel 2.4 Estimasi Parameter Subfamilies Copula Archimedean	
Copula	Estimasi Parameter θ
Gumbel (1960)	$\tau = 1 - \theta_G^{-1}$ maka $\theta_G = \frac{1}{1 - \tau}$
Clayton (1978)	$\tau = \frac{\theta_C}{\theta_C + 2}$ maka $\theta_C = \frac{2\tau}{1 - \tau}$

Tabel 2.4 Estimasi Parameter Subfamilies Copula Archimedean (lanjutan)	
Copula	Estimasi Parameter θ
Frank (1979)	$1 - \frac{4}{\theta_F} [D_1(-\theta_F) - 1]$

dimana D_1 adalah fungsi Debye D_k pada saat $k=1$

$$D_k(\theta) = \frac{k}{x^k} \int_0^x \frac{t^k}{\exp(t) - 1} dt, \theta > 0$$

Pemodelan *Gaussian Copula Regression* menggunakan MLE dalam mengestimasi model. Notasi θ menunjukkan vektor parameter model yang terdiri dari parameter marginal univariat dan parameter matriks korelasi Copula gaussian. Fungsi log-likelihood untuk θ dalam kasus kontinu akan memiliki bentuk *closed-form*.

$$L(\theta) = \phi_n(\varepsilon_1, \dots, \varepsilon_n; \mathbf{R}) \prod_{i=1}^n \frac{f(y_i | x_i)}{\phi(\varepsilon_i)} \quad (2.38)$$

Dimana $\phi(\cdot)$ menunjukkan densitas univariat normal standar, $\phi_n(\cdot; \mathbf{R})$ merupakan n -dimensi densitas normal standar dengan matriks korelasi \mathbf{R} , $f(\cdot | x_i)$ merupakan densitas Y_i diberikan x_i dan dependensi fungsi densitas pada θ merupakan penyederhanaan dalam notasi.

2.7 Kriteria Keباikan Model

Pemilihan model terbaik dilakukan jika terdapat lebih dari satu model yang dapat digunakan. Dalam pendekatan *out of sample* pemilihan model terbaik dilakukan berdasarkan *error* dari hasil ramalan. Kriteria yang digunakan adalah *Root Mean Square Error* (RMSE). RMSE dapat dihitung dengan rumus sebagai berikut (Wei, 2006).

$$RMSE = \sqrt{\frac{1}{2} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (2.39)$$

Semakin kecil kedua nilai tersebut, maka dapat dikatakan model akan semakin baik.

2.8 Perhitungan Matematis Banjir Rencana

Terdapat beberapa metode perhitungan untuk menentukan banjir rencana, salah satunya yaitu dengan menghubungkan curah hujan dan limpasan secara empirik dengan menggunakan rumus rasional. Metode ini sudah digunakan sejak pertengahan abad 19 dan merupakan metode yang sering digunakan untuk perencanaan banjir daerah perkotaan. Walaupun banyak yang melakukan kritikan pada akurasinya, namun metode ini tetap dapat digunakan karena metode ini merupakan metode yang paling sederhana. Metode ini digunakan untuk DPS yang kecil dan untuk perencanaan banjir daerah perkotaan dan bangunan fasilitas seperti gorong-

gorong, drainase saluran terbuka dan lainnya. Parameter-parameter pada saat menggunakan metode rasional diantaranya adalah koefisien *runoff*, intensitas hujan dan luas DPS. Metode rasional digunakan untuk daerah perkotaan dengan luas DPS kurang dari 200 acres atau lebih kurang 81 ha, sehingga sesuai dengan kondisi Kota Surabaya. Dengan persamaan metode rasional sebagai berikut (Kodoatie & Sugiyanto, 2002).

$$Q = 0,278 C I A \quad (2.40)$$

Keterangan

- C* : koefisien *runoff*
I : intensitas maksimum selama waktu kensentrasi (mm/jam)
A : luas daerah aliran (km²)
Q : debit maksimum (m³/detik)

Koefisien *runoff* dapat dilihat pada Tabel 2.5, dan dikarenakan Kota Surabaya merupakan perkotaan, maka di asumsikan $C = 0,8$.

Tabel 2.5 Tabel Koefisien *Runoff*

Tata Guna Lahan		<i>C</i>
Daerah Perdagangan	Perkotaan	0,70-0,90
	Pinggiran	0,50-0,70
Pemukiman	Perumahan 1 Keluarga	0,30-0,50
	Perumahan Berkelompok (Terpisah)	0,40-0,60
	Perumahan Berkelompok (Sambung)	0,60-0,75
	Sub-urban	0,25-0,40
	Daerah Apartemen	0,50-0,70
Industri	Industri Ringan	0,50-0,80
	Industri Berat	0,60-0,90
Jalan	Jalan, Hampanan	0,10-0,25
	Atap	0,20-0,35

Taman, Perkuburan	0,20-0,35
Tempat Bermain	0,10-0,30
Daerah Stasiun Kereta Api	0,75-0,85
Daerah Belum Diperbaiki	0,75-0,95

Untuk I atau intensitas curah hujan merupakan jumlah curah hujan dalam satuan waktu tertentu yang biasanya dinyatakan dalam mm/jam, mm/hari, mm/tahun. Untuk perumusan I dapat menggunakan rumus Dr. Manonobe berikut.

$$I = \left[\frac{R_{24}}{24} \right] \left[\frac{24}{t_c} \right]^{2/3} \quad (2.41)$$

Keterangan

- R : hujan maksimum (mm)
 t_c : waktu konsentrasi (jam)

Dapat diketahui untuk memperoleh nilai t_c dapat dirumuskan sebagai berikut.

$$t_c = t_0 + t_f \quad (2.42)$$

Keterangan

- t_0 : 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 t_0 , diasumsikan permukaan dengan penutup homogen sehingga untuk perhitungan dapat menggunakan perumusan *Kerby* sebagai berikut.

$$t_0 = 1,44 \left(n_d \times \frac{l}{\sqrt{s}} \right)^{0,467} \quad (2.43)$$

Keterangan

- l : jarak dari titik terjauh ke inlet (m)
 n_d : koefisien setara koefisien kekasaran
 s : kemiringan saluran

Pada saat $Q_{\text{Hidrolika}} < Q_{\text{Hidrologi}}$ maka dapat dikatakan saluran air atau sungai tidak dapat menampung air hujan dengan baik yang nantinya dapat menjikan air meluap dan terjadinya banjir. Agar mendapat desain yang ekonomis maka seharusnya $Q_{\text{Hidrolika}} \approx Q_{\text{Hidrologi}}$, dimana $Q_{\text{hidrolika}}$ dapat dirumuskan sebagai berikut.

$$Q_{\text{hidrolika}} = V_{(\text{m/detik})} \times A_{(\text{m}^2)} = \frac{1}{n} \times R^{\frac{2}{3}} \times S^{\frac{1}{2}} \times A \quad (2.44)$$

Dimana A merupakan luas penampang sungai yang diperoleh dari

$$A_{(\text{m}^2)} = b_{(\text{m})} \times h_{(\text{m})} \quad (2.45)$$

Keterangan

- $b_{(\text{m})}$: lebar sungai
 $h_{(\text{m})}$: tinggi sungai

$b_{(\text{m})}$ diperoleh dari rata-rata lebar sungai minimum dan maksimum yang diperoleh data PU Binamarga & Pematusan. Sedangkan untuk $h_{(\text{m})}$ dari tabel *u-ditch* tergantung nilai $b_{(\text{m})}$ -nya. Untuk memudahkan dalam analisis, maka dapat diketahui $h_{(\text{m})}$ suatu saluran adalah sama dengan $b_{(\text{m})}$ jika $b_{(\text{m})}$ lebih besar sama dengan 12. Jika $b_{(\text{m})} < 12$ maka $h_{(\text{m})} = b_{(\text{m})} \times \frac{10}{6}$. Hal ini dikarenakan, keseluruhan saluran di Kota Surabaya menggunakan *u-ditch* atau

saluran *rectangle*. Sedangkan untuk kecepatan saluran dalam menggunakan Rumus Manning sebagai berikut.

$$V_{(\text{m/detik})} = \frac{1}{n} R^{2/3} S^{1/2} \quad (2.46)$$

Keterangan

- n : koefisien kekerasan saluran
 R : jari-jari hidrolis
 S : kemiringan salur

Untuk jari-jari hidrolis dapat dirumuskan sebagai berikut.

$$R_{(m)} = \frac{A_{(m^2)}}{P_{(m)}} \quad (2.47)$$

Dimana $P_{(m)}$ atau penampang yang terkena air dapat dirumuskan sebagai berikut.

$$P_{(m)} = b_{(m)} + 2 h_{(m)} \quad (2.48)$$

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 2.6 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

2.9 Banjir

Banjir merupakan kondisi pada saat daratan yang biasanya kering (bukan daerah rawa) menjadi tergenang oleh air yang disebabkan oleh curah hujan yang tinggi atau di atas normal dan kondisi topografi wilayah berupa dataran rendah hingga cekung. Selain itu, terjadinya banjir juga dapat disebabkan oleh limpasan air permukaan (*runoff*) yang meluap dan volumenya melebihi kapasitas pengaliran sistem drainase atau sistem aliran sungai. Tidak hanya itu, bencana banjir juga dapat disebabkan oleh rendahnya kemampuan infiltrasi tanah, sehingga menyebabkan tanah tidak mampu lagi menyerap air (Sebastian, 2008).

Menurut Kodoatie & Sugiyanto (2002), faktor penyebab terjadinya banjir dapat diklasifikasikan dalam dua kategori, yaitu banjir alami dan banjir yang tidak alami atau yang disebabkan oleh tindakan manusia. Sebab-sebab banjir alami diantaranya adalah curah hujan, pengaruh fisiologi, erosi sedimentasi, kapasitas sungai, kapasitas drainase yang tidak memadai dan pengaruh air pasang. Sedangkan untuk penyebab banjir dikarenakan oleh manusia (non-alam) dapat dipengaruhi oleh beberapa faktor, diantaranya adalah perubahan kondisi DAS, kawasan kumuh & sampah, drainase lahan, kerusakan bangunan pengendali air, perencanaan sistem pengendalian banjir tidak tepat dan rusaknya hutan.

Menurut Dinas PU & Pematusan Kota Surabaya keadaan yang sering terjadi di Surabaya merupakan banjir lokal atau genangan. Dan menurut kepala pusat data informasi dan humas BNPB istilah banjir maupun genangan dalam hidrologi adalah

sama, dikarenakan sama-sama merugikan masyarakat. Jika merujuk pada kamus KBBI banjir memiliki arti “berair banyak dan deras, kadang-kadang meluap; air yang banyak dan mengalir”. Sedangkan untuk pengertian genangan sendiri adalah “tempat atau daerah yang berair” (detiknews, 2007). Case dkk (2007) juga membuktikan bahwa curah hujan sangat berpengaruh terhadap terjadinya banjir. Pada saat musim hujan, curah hujan yang tinggi berakibat banjir di sungai dan bila melebihi tebing sungai maka akan timbul banjir atau genangan.

2.10 Curah Hujan (CH)

Endapan atau presipitasi didefinisikan sebagai bentuk air cair dan padat (es) yang jatuh di permukaan bumi. Hujan merupakan gejala meteorologi dan unsur-unsur klimatologi. Hujan merupakan hidrometeor yang jatuh berupa partikel-partikel air yang mempunyai diameter 0,5 mm atau lebih. Hidrometeor yang jatuh ke tanah dapat dikatakan hujan sedangkan jika tidak maka dikatakan *virga* (Tjasyono, 2006). Hujan yang sampai ke permukaan tanah dapat diukur dengan cara mengukur tinggi air hujan berdasarkan volume air hujan persatuan luas. Hujan dari pengukuran tersebut dinamakan dengan curah hujan.

Curah hujan merupakan salah satu unsur cuaca yang datanya diperoleh dengan cara mengukurnya menggunakan alat penakar hujan, sehingga data diketahui jumlahnya dalam satuan milimeter (mm). Curah hujan 1 mm menunjukkan jumlah air hujan yang jatuh dipermukaan per-satuan luas (m^2) dengan catatan tidak ada yang menguap, meresap atau mengalir. Jadi curah hujan sebesar 1 mm sama dengan 1 liter/ m^2 (Aldrian dkk, 2011).

Menurut Sosrodarsono & Takeda (2003), hujan dapat digolongkan menjadi beberapa golongan berdasarkan intensitas curah hujannya, dapat dilihat pada Tabel 2.7 berikut.

Tabel 2.7 Derajat Curah Hujan

Derajat Hujan	Intensitas CH (mm/menit)
Hujan Sangat Lemah	$< 0,02$
Hujan Lemah	$0,02 < CH \leq 0,05$
Hujan Normal	$0,05 < CH \leq 0,25$
Hujan Deras	$0,25 < CH \leq 1,00$
Hujan Sangat Deras	$> 1,00$

2.11 BMKG

Badan Meteorologi, Klimatologi dan Geofisika (BMKG) merupakan Lembaga Pemerintah Non Departemen (LPND) yang memiliki tugas pemerintahan di bidang Meteorologi, Klimatologi, Kualitas Udara dan Geofisika sesuai dengan ketentuan perundang undangan yang berlaku. Di setiap stasiun BMKG memiliki alat untuk mengukur unsur iklim. Iklim maupun klimatologi dapat diartikan sebagai peluang statistik kejadian berbagai keadaan atmosfer di suatu tempat atau daerah selama kurun waktu kalender. Hal ini berbeda jika dibandingkan dengan cuaca. Cuaca merupakan keadaan atmosfer di suatu tempat atau daerah selama waktu tertentu. Namun, untuk unsur iklim maupun cuaca adalah sama.

Terdapat berbagai macam unsur iklim yang dilakukan pengukuran oleh stasiun BMKG. Diantaranya adalah, temperatur udara, kelembaban udara, curah hujan, lama penyinaran matahari, kecepatan angin dan arah angin. Penelitian ini hanya menggunakan tiga unsur iklim sebagai variabel prediktor. Ketiga unsur iklim tersebut diantaranya adalah rata-rata temperatur udara, kelembababn udara dan kecepatan angin.

Untuk penjelasan lebih lanjut untuk ketiga variabel tersebut adalah sebagai berikut.

a. Temperatur atau Suhu Udara

Temperatur atau suhu merupakan keadaan panas atau dinginnya udara yang mempunyai sifat menyebar dan berbeda-beda pada suatu daerah tertentu. Alat ukur yang dapat digunakan yaitu dengan menggunakan termometer.

b. Kelembaban Udara

Kelembaban udara merupakan banyak sedikitnya uap air yang ada di udara. Kelembaban udara akan mempengaruhi pengendapan air di udara dan juga dapat berupa awan, kabut, embun serta hujan. Alat pengukurnya disebut dengan hidrografi.

c. Kecepatan Angin

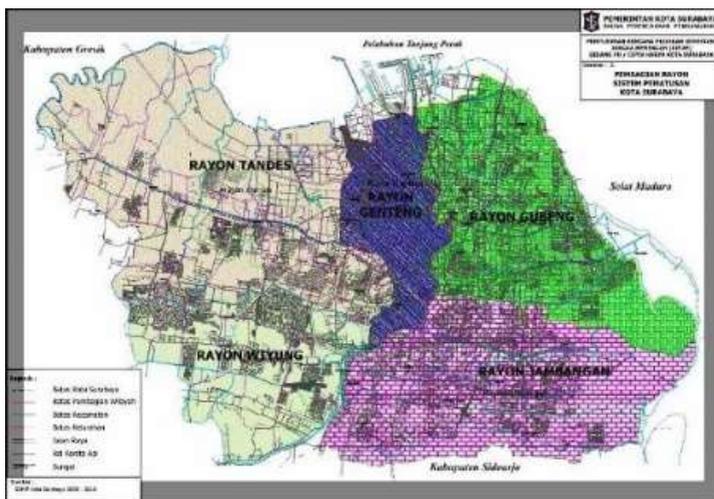
Angin merupakan udara yang bergerak, yang disebabkan karena adanya perubahan udara hingga terjadinya angin. Tekanan udara akan naik apabila suhunya rendah, dan sebaliknya tekanan udara akan turun apabila suhunya tinggi. Angin akan bergerak dari daerah yang bertekanan tinggi ke daerah yang bertekanan rendah. Anemometer merupakan alat yang dapat mengukur kecepatan angin.

2.12 Dinas Pekerjaan Umum

Dinas Pekerjaan Umum (PU) Pengairan serta Dinas Pekerjaan Umum (PU) Binamarga & Pematuan merupakan dua lembaga pemerintah yang berbeda. Dinas PU Pengairan merupakan unsur pelaksanaan otonomi daerah, dipimpin oleh seorang kepala dinas, yang berada di bawah tanggung jawab gubernur melalui sekretaris daerah. Dinas PU Sumber Daya Air Prov. Jatim terletak di Jl. Gayung Kebonsari No.169, Ketintang, Gayungan, Kota Surabaya (60235). Dengan sistem penataan yang ada di Surabaya menggunakan prinsip *provenance* yaitu dikelompokkan berdasarkan Unit Pelaksanaan Teknis Dinas (UPTD) yaitu sembilan (yang saat ini tujuh, setelah adanya

rasionalisasi) Balai Pengelolaan Sumberdaya Air Wilayah Sungai (PSAWS).

Sedangkan untuk Dinas PU Binamarga & Pematuan di bawah tanggung jawab pemerintah Kota Surabaya. Tugas nya yaitu berurusan di bidang pemerintahan khususnya di bidang pekerjaan umum, perhubungan, pemberdayaan masyarakat, otonomi daerah, pemerintahan umum, perhubungan dan administrasi keuangan daerah. Dasar hukum terkait Dinas Dinas Pekerjaan Umum Binamarga dan Pematuan Kota Surabaya yaitu berdasarkan Undang-Undang (UU), Peraturan Daerah, Peraturan Walikota dan Surat Keputusan (SK). Dimana di PU & Pematuan sendiri melakukan evaluasi banjir berdasarkan tata guna lahan berdasarkan 5 sub-rayon, diantaranya adalah Rayon Gubeng, Rayon Genteng, Rayon Tandes, Rayon Wiyung dan Rayon Jambangan. Lima rayon yang digunakan sebagai evaluasi bagi pihak Dinas Pekerjaan Umum Binamarga dan Pematuan Kota Surabaya dapat dilihat pada Gambar 2.4.



Gambar 2.4 5 Rayon Pengamatan Banjir di Kota Surabaya

(Sumber : PU Pematusan & Binamarga Kota Surabaya)

(Halaman ini sengaja di kosongkan)

BAB III METODOLOGI PENELITIAN

3.1 Sumber Data

Data yang digunakan merupakan data skunder yang diperoleh dari Badan Meteorologi, Klimatologi dan Geofisika (BMKG) dan Dinas Pekerjaan Umum Bina Marga dan Pematuan Kota Surabaya. Data yang diperoleh dari BMKG merupakan data unsur iklim di tiga stasiun meteorologi. Untuk setiap data yang digunakan pada penelitian merupakan data harian selama sepuluh tahun, yaitu dari tanggal 01 Januari 2009 sampai dengan 31 Desember 2018. Sehingga total pengamatan yang digunakan pada penelitian ini adalah 3.652 yang nantinya akan dibagi menjadi data *training* sebanyak 3.621 dan data *testing* sebanyak 31.

Ketiga stasiun meteorologi BMKG tersebut diantaranya adalah Stasiun Meteorologi Perak I dan Stasiun Meteorologi Maritim Perak II yang terletak di Kota Surabaya dan Stasiun Meteorologi Juanda yang terletak di Sidoarjo (sangat dekat dengan Kota Surabaya). Untuk garis lintang dan bujur di ke-tiga stasiun tersebut dapat dilihat pada tabel berikut.

Tabel 3.1 Koordinat Stasiun BMKG

X_s	Stasiun	Garis Lintang	Garis Bujur
1.	Juanda	07°23'03.70''S	112°47'02.68''T
2.	Perak 2	07°12'19.00''S	112°44'07.50''T
3.	Perak 1	07°13'25.40''S	112°43'26.20''T

Sedangkan untuk data yang diperoleh dari Dinas PU Bina Marga dan Pematuan pada dasarnya diperoleh dari Dinas Pekerjaan Umum (DPU) Pengairan (Balai PSAWS Buntung Pekingan). Balai PSAWS Buntung Pekingan melakukan pencatatan curah hujan di setiap balai yang memiliki alat ukur curah hujan di Kota Surabaya. Terdapat tujuh balai yang memiliki

alat ukur curah hujan di Kota Surabaya. Tujuh balai tersebut diantaranya adalah Balai Keputih, Kedung Cowek, Gubeng Wonorejo, Wonokromo, Gunung Sari dan Simo. Untuk garis lintang dan bujur di tujuh balai pengamatan curah hujan dapat dilihat pada tabel berikut.

Tabel 3.2 Koordinat Balai PSAWS

CH _b	Balai	Garis Lintang	Garis Bujur
1.	Keputih	07°17'13.09''S	112°49'07.33''T
2.	Kd. Cowek	07°13'02.21''S	112°46'58.20''T
3.	Gubeng	07°16'45.21''S	112°45'13.81''T
4.	Wonorejo	07°16'14.02''S	112°43'56.21''T
5.	Wonokromo	07°18'12.81''S	112°44'02.21''T
6.	Gn. Sari	07°18'01.53''S	112°42'48.61''T
7.	Simo	07°14'12.58''S	112°45'19.18''T

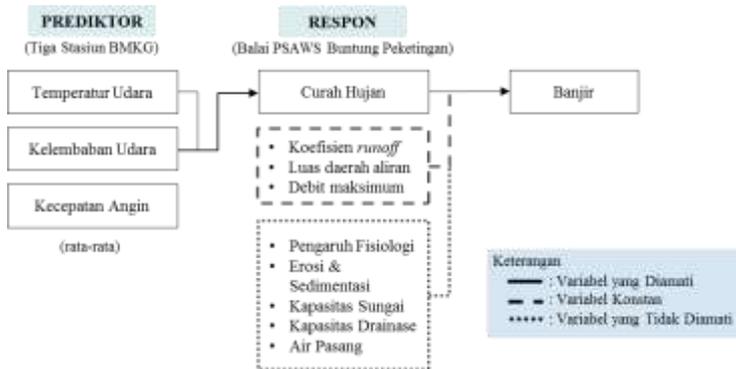
Dapat diketahui bahwa untuk setiap wilayah pengamatan baik itu di tiga stasiun BMKG dan di tujuh wilayah pengamatan curah hujan memiliki koordinat lokasi yang berbeda-beda. Untuk lebih jelasnya, berikut merupakan peta untuk mengetahui letak setiap wilayah pengamatan unsur iklim dan curah hujan di Kota Surabaya.



Gambar 3.1 Peta Kota Surabaya & Wilayah Pengamatan

3.2 Variabel Penelitian

Variabel penelitian yang akan digunakan yaitu variabel prediktor ($X_{i,s,t}$) dan variabel respon ($Y_{b,t}$). Variabel prediktor yang digunakan adalah unsur-unsur iklim yang diperoleh dari tiga stasiun BMKG dan untuk variabel respon merupakan curah hujan di enam balai curah hujan yang akan dianalisis secara univariat. Untuk memudahkan dalam pemahaman terhadap variabel penelitian yang akan digunakan, maka dapat dilihat kerangka variabel penelitian berdasarkan Gambar 3.2.



Gambar 3.2 Kerangka Variabel Penelitian

Berdasarkan Gambar 3.2, dapat diketahui untuk variabel yang tidak diamati tersebut merupakan variabel yang berpengaruh terhadap banjir (seperti yang telah dijelaskan pada sub-BAB 2.9). Variabel tersebut diasumsikan tidak berpengaruh karena sangat sulit untuk diperoleh dan dapat dikatakan tidak tersedia sehingga tidak diamati pada penelitian ini. Pada penelitian kali ini prediksi banjir diperoleh menggunakan perhitungan rasional hidrologi atau

perhitungan banjir rasional. Untuk lebih detailnya, variabel penelitian yang akan digunakan dapat dilihat pada Tabel 3.3.

Tabel 3.3 Variabel Penelitian

No.	Variabel	Deskripsi	Satuan	Jenis Data	Keterangan
1.	$X_{1,s,t}$	Temperatur Udara	°c	Interval	Data
2.	$X_{2,s,t}$	Kelembaban Udara	%	Rasio	Pengamatan di 3 Stasiun
3.	$X_{3,s,t}$	Kecepatan Angin	m/s	Rasio	BMKG
4.	$Y_{b,t}$	Curah Hujan (CH)	mm	Rasio	6 Balai PSAWS

3.3 Struktur Data

Berdasarkan variabel penelitian serta analisis yang akan dilakukan, maka terdapat dua struktur data yang akan digunakan dalam penelitian ini. Struktur data yang pertama merupakan struktur data yang digunakan pada saat curah hujan di 6 balai pengamatan diprediksi berdasarkan tiga unsur iklim di tiga stasiun BMKG secara bergantian. Itu berarti akan diperoleh tiga pemodelan di ke-enam balai yang nantinya akan dipilih model yang terbaik. Struktur data yang pertama yaitu pada Tabel 3.4.

Tabel 3.4 Struktur Data Penelitian 1

Waktu (H/B/T)	T	$X_{1,s}$	$X_{2,s}$	$X_{3,s}$	Y_b
01/01/2010	1	$X_{1,s,1}$	$X_{2,s,1}$	$X_{3,s,1}$	$Y_{b,1}$
02/01/2010	2	$X_{1,s,2}$	$X_{2,s,2}$	$X_{3,s,2}$	$Y_{b,2}$
⋮	⋮	⋮	⋮	⋮	⋮
hh / bb / tttt	t	$X_{1,s,t}$	$X_{2,s,t}$	$X_{3,s,t}$	$Y_{b,t}$
⋮	⋮	⋮	⋮	⋮	⋮
30/12/2018	$n-1$	$X_{1,s,(n-1)}$	$X_{2,s,(n-1)}$	$X_{3,s,(n-1)}$	$Y_{b,(n-1)}$
31/12/2018	$n=3.652$	$X_{1,s,n}$	$X_{2,s,n}$	$X_{3,s,n}$	$Y_{b,n}$

*Keterangan : s = stasiun (1,2,3) & b = balai (1 s.d 6)

Untuk variabel prediktor merupakan data harian yang diperoleh dari tiga stasiun BMKG : Stasiun Meteorologi Juanda, Stasiun Meteorologi Perak 2 dan Stasiun Meteorologi Perak 1. Untuk variabel respon atau curah hujan harian diperoleh dari data pengamatan menggunakan alat ukur curah hujan (Ombrometer) yang dilakukan oleh Balai PSAWS Buntung Peketingan.

Untuk struktur data berikutnya yaitu dapat dilihat pada tabel 3.5. Tabel tersebut menunjukkan struktur data pada saat keseluruhan unsur iklim di 3 Stasiun BMKG melalui tahap PCA terlebih dahulu, untuk mendapatkan PC terbaik di setiap variabel.

Tabel 3.5 Struktur Data Penelitian 2

Waktu (H/B/T)	<i>t</i>	BMKG									CH
		Temperatur			Kelembaban Udara			Kecepatan Angin			
		X_{1t}	X_{2t}	X_{3t}	X_{4t}	X_{5t}	X_{6t}	X_{7t}	X_{8t}	X_{9t}	Y_t
01/01/2010	1	X_{11}	X_{21}	X_{31}	X_{41}	X_{51}	X_{61}	X_{71}	X_{81}	X_{91}	Y_{11}
02/01/2010	2	X_{12}	X_{22}	X_{32}	X_{42}	X_{52}	X_{62}	X_{72}	X_{82}	X_{92}	Y_{21}
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
hh/bb/tttt	<i>r</i>	X_{1r}	X_{2r}	X_{3r}	X_{4r}	X_{5r}	X_{6r}	X_{7r}	X_{8r}	X_{9r}	Y_{r1}
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
30/12/2018	<i>n-1</i>	$X_{1(n-1)}$	$X_{2(n-1)}$	$X_{3(n-1)}$	$X_{4(n-1)}$	$X_{5(n-1)}$	$X_{6(n-1)}$	$X_{7(n-1)}$	$X_{8(n-1)}$	$X_{9(n-1)}$	$Y_{(n-1)1}$
31/12/2018	<i>n</i>	X_{1n}	X_{2n}	X_{3n}	X_{4n}	X_{5n}	X_{6n}	X_{7n}	X_{8n}	X_{9n}	Y_{n1}

*Keterangan : *b* = balai (1 s.d 6)

3.4 Langkah Analisis

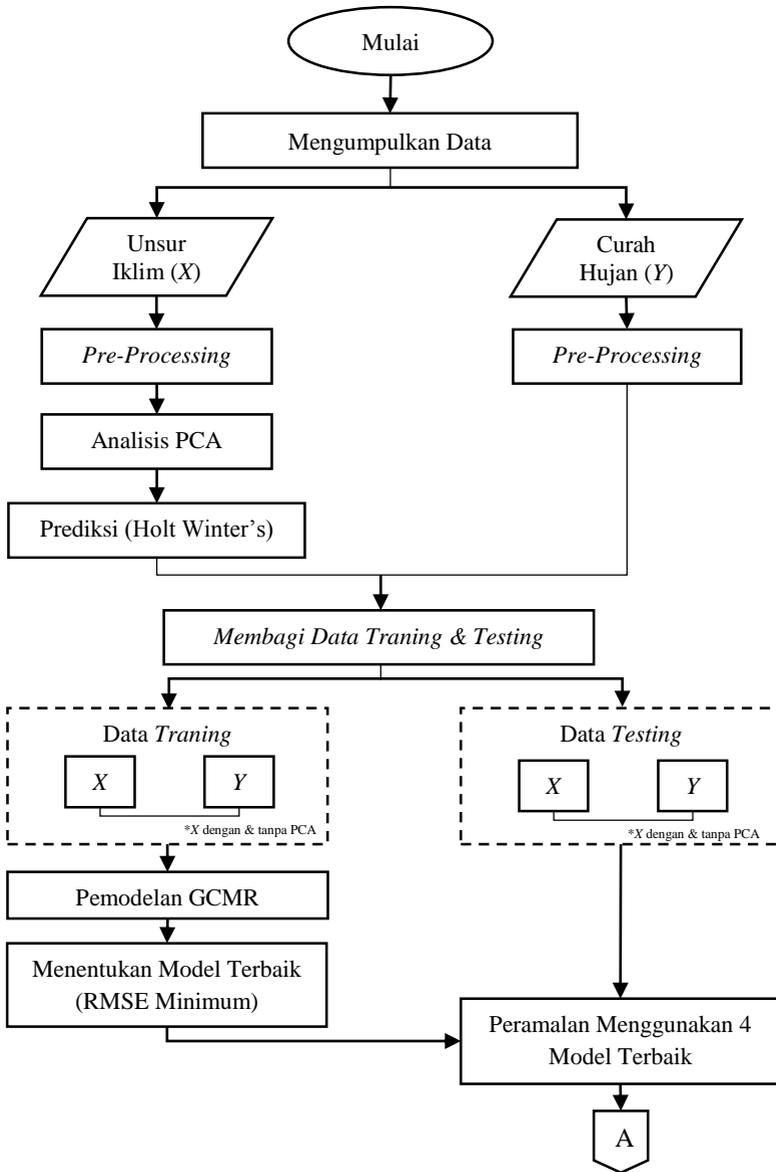
Langkah-langkah analisis yang akan dilakukan untuk mencapai tujuan penelitian ini adalah sebagai berikut.

1. *Pre-processing* data, guna mengintegrasikan keseluruhan data yang diperoleh dari dua sumber yang berbeda dan mengatasi *missing value*.
2. Melakukan eksplorasi data menggunakan statistik deskriptif untuk mengetahui karakteristik data yang akan dianalisis lebih lanjut. Beberapa bentuk eksplorasi data yang akan dilakukan diantaranya adalah sebagai berikut.

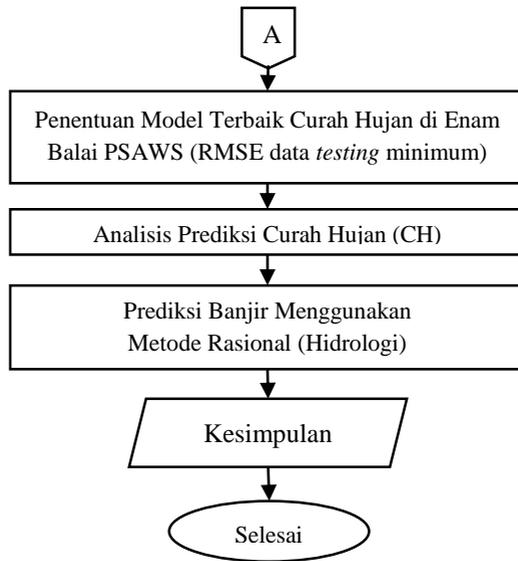
- a. Membuat *time series plot* untuk mengetahui pola dari setiap variabel
 - b. Membuat *box-plot* bulanan untuk mengidentifikasi adanya data *outlier* serta mengetahui interval untuk masing-masing variabel yang akan digunakan. Serta dapat melihat pola data berdasarkan bulan.
 - c. Membuat *scatterplot* untuk mengetahui pola hubungan antar variabel prediktor dan respon.
3. Melakukan pembagian data menjadi data *training (in-sample)* dan *testing (out-sample)*.
4. Melakukan prediksi curah hujan (respon) di balai pengamatan berdasarkan unsur iklim (prediktor) di tiga stasiun BMKG Kota Surabaya menggunakan pemodelan dengan pendekatan *Gaussian Copula Marginal Regression (GCMR)*. Secara garis besar, terdapat dua tahap dalam melakukan pemodelan.
 - a. Tahap pemodelan yang pertama yaitu, melakukan pemodelan setiap satu stasiun BMKG terhadap enam balai. Sehingga akan terdapat analisis terpisah untuk masing-masing stasiun BMKG yang nantinya akan diperoleh tiga model prediksi curah hujan di setiap enam wilayah pengamatan. Struktur data yang digunakan pada tahap pemodelan pertama dapat dilihat pada tabel 3.4.
 - b. Tahap pemodelan yang kedua yaitu, melakukan PCA terlebih dahulu untuk seluruh variabel prediktor di tiga stasiun BMKG. PC yang terpilih akan digunakan sebagai prediktor di 6 wilayah pengamatan. Struktur data yang digunakan pada tahap ini dapat dilihat pada tabel 3.5.
5. Pemodelan dengan pendekatan GCMR dapat diuraikan sebagai berikut.

- a. Melakukan analisis *generalized marginal regression* pada variabel prediktor univariat terhadap variabel respon secara *univariable* dan *multivariable*.
 - b. Dikarenakan variabel respon merupakan nilai yang selalu positif maka *link-function* dapat disesuaikan dengan distribusi dari variabel respon.
 - c. Setelah melakukan *generalized marginal regression* menggunakan *link-function* yang berbeda. Setiap pemodelan akan menghasilkan *error* yang cenderung dependen antar waktu. Harapannya dengan menggunakan GCMR dapat menjadikan pemodelan yang diperoleh, memenuhi asumsi *error* yang saling independen.
6. Melakukan pemilihan model curah hujan terbaik dari keseluruhan model yang diperoleh di setiap wilayah pengamatan menggunakan uji kebaikan model RMSE data *train* terkecil. Sehingga akan diperoleh empat pemodelan prediksi curah hujan di setiap balai.
 7. Melakukan prediksi terhadap variabel prediktor di ke-tiga stasiun menggunakan Holt Winter's.
 8. Melakukan prediksi curah hujan berdasarkan model terbaik dan prediktor hasil prediksi menggunakan Holt Winter's yang didapatkan untuk beberapa periode ke depan. Akan diperoleh hasil prediksi berdasarkan empat pemodelan terbaik pada data *train*, dari ke-empat model tersebut akan dipilih satu model terbaik pada saat hasil prediksi memiliki nilai RMSE data *testing* terkecil.
 9. Prediksi banjir berdasarkan prediksi curah hujan yang telah diperoleh, menggunakan perhitungan matematis hidrologi (Metode Rasional) yang dapat menghubungkan curah hujan dan limpasan secara empiris.

Berdasarkan langka-langkah penelitian yang telah dijelaskan, maka dapat divisualisasikan berdasarkan diagram alir berikut.

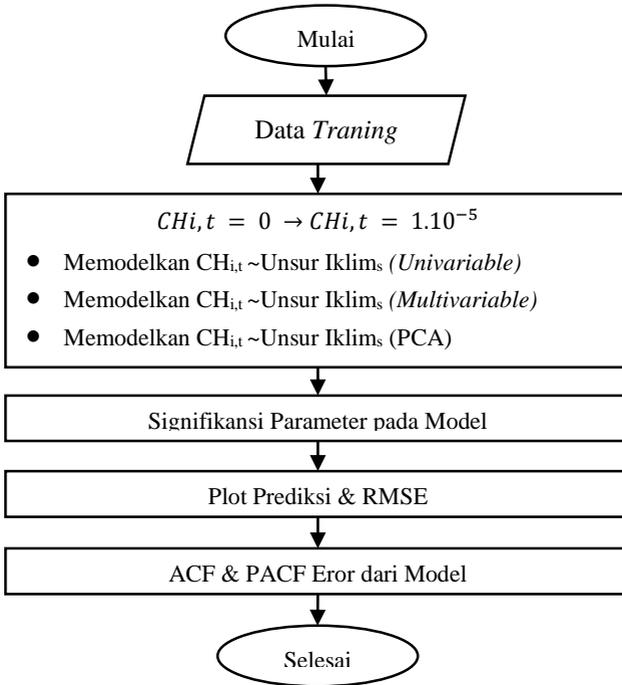


Gambar 3.3 Diagram Alir



Gambar 3.3 Diagram Alir (lanjutan)

Adapun langkah-langkah dalam pemodelan *Gaussian Copula Marginal Regression* (GCMR) dapat dilihat diagram alir pada Gambar 3.4.



Gambar 3.4 Diagram Alir Pemodelan GCMR

BAB IV

ANALISIS DAN PEMBAHASAN

Terdapat beberapa tahap analisis yang dilakukan dalam penelitian ini. Pada bab ini akan mengenai hasil dari tahapan-tahapan analisis yang dilakukan. Sebelum dilakukan pemodelan GCMR variable prediktor (unsur iklim) terhadap variabel respon (Curah Hujan / CH) di enam balai PSAWS, terlebih dahulu dilakukan *pre-processing* data dan mengidentifikasi karakteristik data. Berikut, merupakan hasil analisis prediksi banjir berdasarkan prediksi CH di Kota Surabaya.

4.1 *Pre-Processing Data*

Terdapat dua sumber data yang berbeda yang akan digunakan untuk analisis pada penelitian ini. Faktanya, observasi untuk setiap variabel yang diberikan belum sesuai dengan struktur data yang dibutuhkan dalam analisis. Perlu adanya penggabungan data guna menjadikan data lebih terintegrasi sehingga data memiliki struktur data sesuai dengan yang dibutuhkan. Untuk penggabungan data dapat dilakukan secara manual ataupun menggunakan *syntax* R guna efisiensi waktu yang dapat dilihat pada Lampiran 2 & 3.

Risiko penggunaan data klimatologi harian dengan pengamatan yang cukup besar dalam melakukan analisis adalah terdapat data yang hilang (*missing value*). Data unsur iklim yang akan digunakan baik itu data dari stasiun BMKG maupun balai perairan PSAWS masih terdapat data *missing*. Hal ini dapat disebabkan oleh adanya alat yang rusak ataupun tidak dilakukannya pengamatan pada hari-hari tertentu. Maka perlu adanya *pre-processing* data.

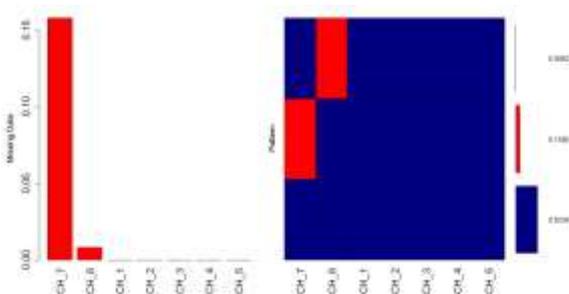
Dikarenakan data yang akan digunakan merupakan data deret waktu atau data *time series*, maka jika terdapat data yang

missing dapat menghambat dalam melakukan analisis lebih lanjut. Perlu dilakukan deteksi *missing value* untuk setiap variabel yang akan digunakan. Berikut persentase *missing value* yang terdapat pada variabel respon (CH).

Tabel 4. 1 Persentase *Missing Value* Variabel Respon

CH _{1,t}	CH _{2,t}	CH _{3,t}	CH _{4,t}	CH _{5,t}	CH _{6,t}	CH _{7,t}
0.000	0.000	0.000	0.000	0.000	0.008	0.158

Dari tabel 4.1 maka dapat dilihat visualisasi berupa histogram dan *pattern missing value* pada variabel respon sebagai berikut.



Gambar 4.1 Visualisasi *Missing Value* Variabel Respon

Dapat diketahui dari Tabel 4.1 dan Gambar 4.1 bahwa hanya curah hujan di Balai Simo dan Balai Gunung Sari yang terdeteksi adanya data yang *missing*. Dapat diketahui dari *missing value* pada curah hujan di Balai Simo lebih 10%, dikarenakan data tidak tersedia lebih dari satu tahun, yaitu dari tanggal 01 Januari 2013 sampai dengan 31 Juli 2014. Hal tersebut terjadi dikarenakan rusaknya alat ukur curah hujan di balai PSAWS tersebut, sehingga untuk variabel curah hujan di Balai Simo tidak dilakukan analisis lebih lanjut. Sedangkan untuk curah hujan di Balai Gunung Sari tetap dilakukan analisis lebih lanjut dikarenakan *missing value* curah hujan di Balai Gunung Sari tidak melebihi 10%. Data curah hujan di Balai Gunung Sari yang tidak tersedia terjadi pada tanggal 1-30

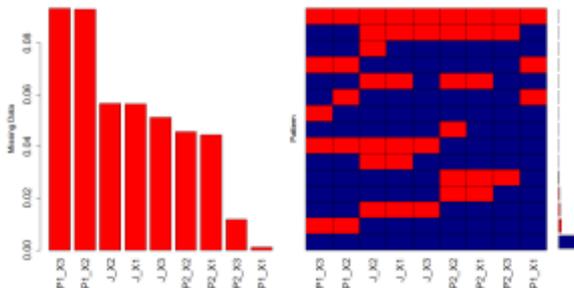
November 2015 (satu bulan). Untuk mengatasi *missing value* curah hujan di Balai Gunung Sari menggunakan nilai rata-rata harian, dibulan yang sama dalam 10 tahun. Sehingga prediksi curah hujan hanya dilakukan untuk ke-enam balai curah hujan, dengan menghapus variabel curah hujan di Balai Simo.

Sedangkan untuk persentase *missing* pada variabel prediktor dapat dilihat pada Tabel 4.2.

Tabel 4. 2 Persentase *Missing Value* Variabel Prediktor

Unsur Iklim \ Stasiun	Juanda (J)	Perak 2 (P2)	Perak 1 (P1)
Temperatur (T)	0.056	0.045	0.001
Kelembaban (RH)	0.057	0.046	0.093
Kecepatan Angin (ff)	0.051	0.012	0.093

Dapat diketahui bahwa persentase *missing value* pada variabel prediktor tidak ada yang melebihi 10%. Untuk lebih jelasnya, berikut merupakan histogram data *missing* di setiap variabel prediktor.



Gambar 4.2 Visualisasi *Missing Value* Variabel Prediktor

Berdasarkan Gambar 4.2 dapat diketahui bahwa persentase *missing value* rata-rata kelembaban udara dan kecepatan angin di Stasiun Perak 1 merupakan yang tertinggi, namun tidak melebihi 10%. Jika dilakukan penghapusan data, maka dapat menyebabkan informasi yang hilang dan dapat menjadikan *forecasting* data yang tidak sesuai. Maka dari itu, imputasi data yang dilakukan untuk

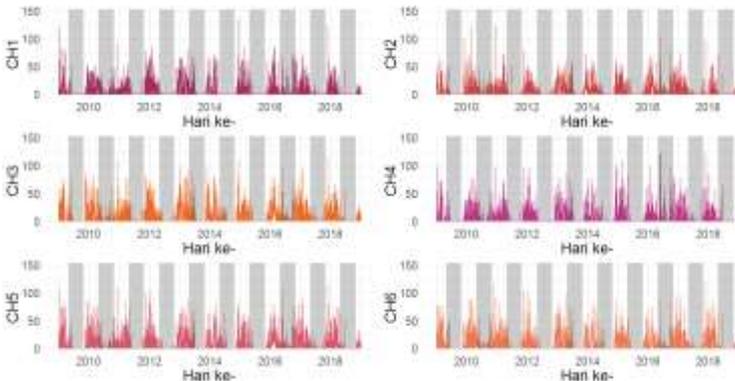
setiap variabel yang mengandung *missing* yaitu dengan penginputan rata-rata harian dalam 10 tahun sama halnya pada saat menginputasi *missing value* pada curah hujan di Balai Gunung Sari. Untuk *time series* dari rata-rata-harian di bulan yang sama dalam 10 tahun dapat dilihat pada Lampiran 5.

4.2 Karakteristik Data

Setelah melakukan imputasi *missing value* pada data yang tidak tersedia, maka perlu mengetahui karakteristik data yang akan dianalisis. Untuk mengetahui karakteristik data yang akan digunakan, dapat menggunakan statistika deskriptif yang dapat di visualisasi menggunakan beberapa grafik, diantaranya adalah plot *time series*, *box-plot* dan *scatter plot*. Berikut penjelasan karakteristik data dari setiap variabel yang digunakan

4.2.1 Variabel Respon (Curah Hujan)

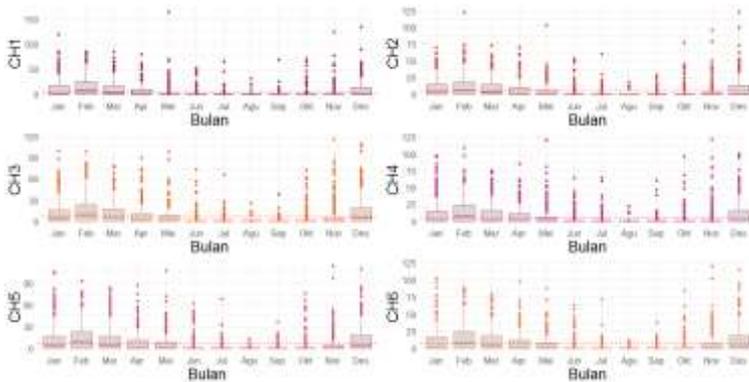
Terdapat enam curah hujan sebagai variabel respon secara univariat pada penelitian kali ini. Untuk mengetahui pola curah hujan harian di 6 balai PSAWS dapat dilihat pada Gambar 4.3.



Gambar 4.3 *Time Series Plot* Curah Hujan Enam Balai PSAWS

Dapat diketahui berdasarkan Gambar 4.3 bahwa curah hujan di 6 balai memiliki pola seasonal yang tidak jauh berbeda. Tidak hanya

itu, curah hujan tertinggi berada di Balai Keputih, dengan nilai maksimum mencapai 164 mm/hari. Walaupun terdapat perbedaan curah hujan setiap harinya di enam balai, namun rata-rata curah hujan nya relatif sama (5 s.d 6 mm/hari). Untuk mengetahui pola CH setiap bulannya dapat dilihat berdasarkan Gambar 4.4.



Gambar 4.4 Box-Plot Curah Hujan Enam Balai PSAWS

Gambar 4.3 dan 4.4 menunjukkan bahwa, curah hujan di seluruh wilayah Kota Surabaya tidak sama, namun memiliki pola yang relatif sama. Gambar menunjukkan bahwa curah hujan di enam balai relatif tinggi pada saat empat bulan pertama dan dua bulan terakhir. Sehingga dapat dikelompokkan bahwa setiap 01 Mei s.d 31 Oktober, curah hujan relatif rendah (musim kemarau). Sedangkan untuk tanggal 01 November s.d 30 April, curah hujan relatif tinggi (musim hujan). Maka dari itu, dapat dinotasikan sebagai *dummy*, yang dapat dituliskan sebagai berikut.

$$Dummy \begin{cases} 0 & : 01 \text{ Mei} - 31 \text{ Okt (Kemarau)} \\ 1 & : 01 \text{ Nov} - 30 \text{ Apr (Hujan)} \end{cases}$$

Kedua kategorik tersebut (musim hujan & kemarau) dapat menjadi variabel *dummy* pada saat pemodelan curah hujan. Setelah itu

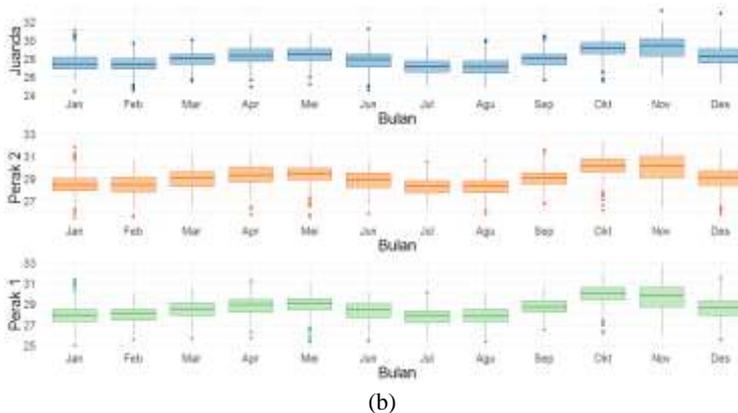
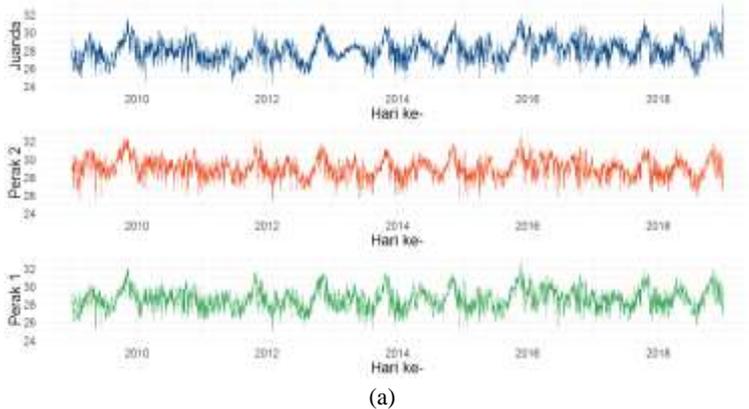
melakukan percobaan dengan cara melakukan visualisasi *scatter-plot* curah hujan di enam balai terhadap lag-nya. Hal ini dapat dilihat Lampiran. 10. Berdasarkan gambar tersebut, menunjukkan bahwa curah hujan di setiap balai memiliki korelasi yang positif terhadap nilai lag-1 s.d lag-5 nya. Sehingga dapat diketahui bahwa curah hujan pada hari tertentu dipengaruhi oleh curah hujan sebelumnya. Jika dilihat pada nilai korelasinya, curah hujan terhadap curah hujan lag-1, memiliki korelasi yang lebih tinggi jika dibandingkan dengan korelasi curah hujan terhadap curah hujan lag-2. Dapat diketahui bahwa enam balai PSAWS memiliki nilai korelasi semakin kecil pada saat curah hujan dikorelasikan dengan curah hujan lag-3, dan meningkat kembali jika dikorelasikan dengan curah hujan lag-4. Tidak hanya itu, keseluruhan korelasi curah hujan dengan lag-nya (hingga lag-5) di enam balai PSAWS signifikan berpengaruh. Hal tersebut dikarenakan nilai *p-value* kurang dari 0,05.

4.2.2 Variabel Prediktor (Unsur Iklim)

Untuk variabel prediktor yang akan digunakan untuk melakukan prediksi curah hujan di enam balai PSAWS Kota Surabaya diantaranya adalah rata-rata temperatur udara, rata-rata kelembaban udara dan rata-rata kecepatan angin. Untuk visualisasi data rata-rata setiap variabel prediktor di 3 stasiun BMKG dapat dilihat pada *time-series* dan *box-plot* berikut.

Gambar 4.5 menunjukkan *time series* dan *box plot* rata-rata temperatur tiga Stasiun BMKG. Dapat diketahui bahwa rata-rata temperatur udara di 3 Stasiun BMKG yang berbeda memiliki nilai yang relatif sama setiap harinya. Jika dilihat berdasarkan *box-plot*, dapat diketahui bahwa setiap bulannya rata-rata temperatur di tiga stasiun BMKG setiap bulannya relatif sama. Gambar 4.5 juga

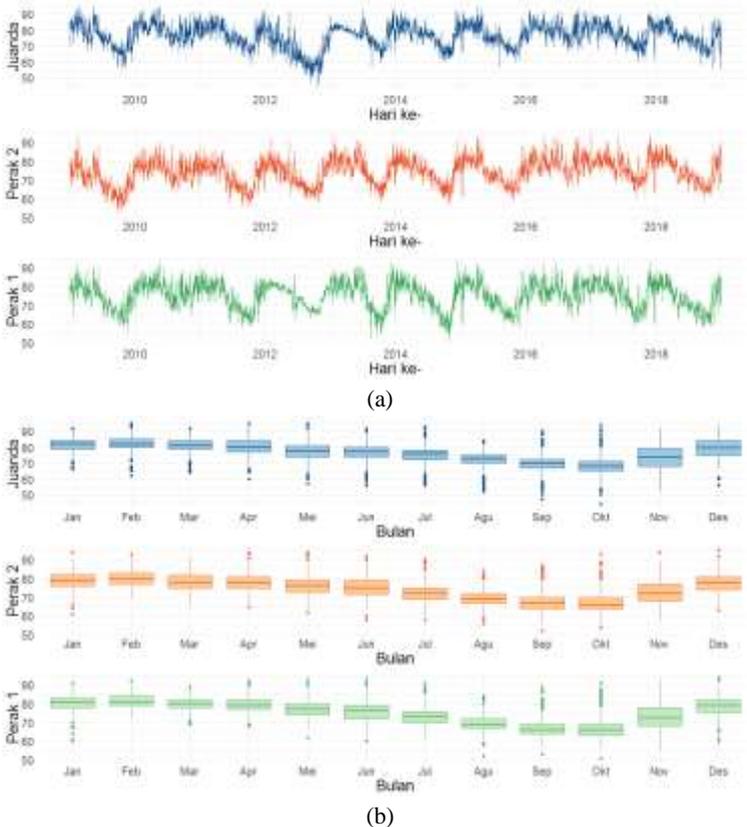
menunjukkan bahwa, selama 10 tahun temperatur udara rata-rata Kota Surabaya berada diantara nilai 25 °c – 33 °c.



Gambar 4.5 (a) *Time-Series Plot* & (b) *Box-Plot* Rata-Rata Temperatur Udara Stasiun BMKG

Tidak hanya pada rata-rata temperatur udara, pada Gambar 4.6 menunjukkan rata-rata kelembaban udara di tiga Stasiun BMKG. Serta dapat diketahui bahwa rata-rata kelembaban udara di tiga stasiun BMKG relatif sama dan tidak memiliki pola yang cenderung

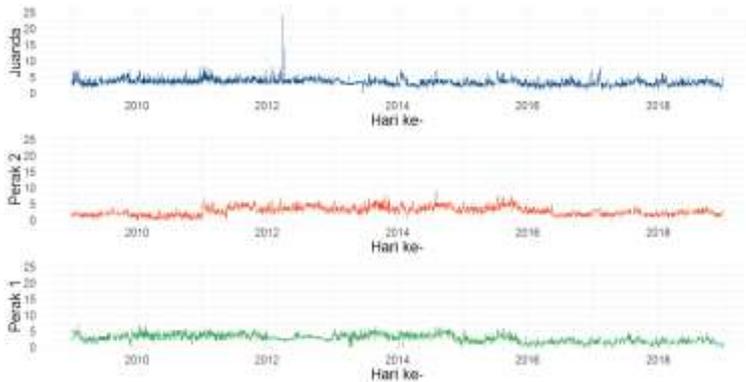
berbeda setiap bulannya. Rentang nilai untuk rata-rata kelembaban udara di tiga Stasiun BMKG yaitu diantara 50 – 95 %.



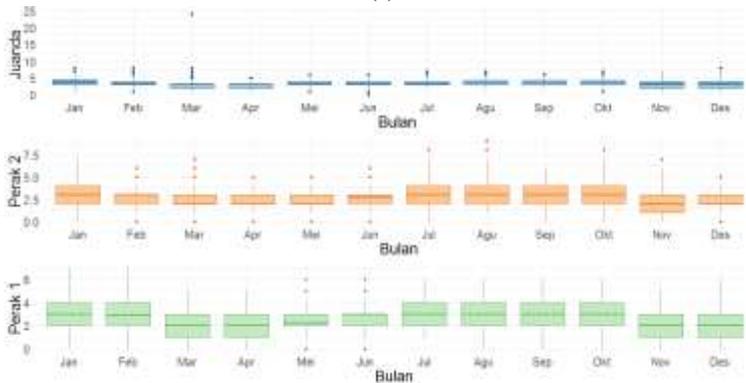
Gambar 4.6 (a) *Time-Series Plot* & (b) *Box-Plot* Rata-Rata Kelembaban Udara Stasiun BMKG

Gambar 4.7 menunjukkan rata-rata kecepatan angin di tiga stasiun BMKG memiliki pola yang relatif sama. Hanya saja, terdapat data *outlier* pada kecepatan angin di stasiun BMKG Juanda. Tanpa adanya *outlier*, maka rata-rata kecepatan angin 0 – 8 m/s. Data *outlier* pada kecepatan angin di Juanda, terjadi pada tanggal 31

Maret 2012 dengan nilai kecepatan angin sebesar 24 m/s. Hal ini diduga karena adanya kesalahan input ataupun jika dikaitkan dengan 10 hari sebelum dari tanggal tersebut, berdasarkan salah satu media (Tempo.co) diinfokan bahwa adanya cuaca buruk dengan kecepatan angin di Laut Jawa mencapai 8 hingga 28 knot.



(a)



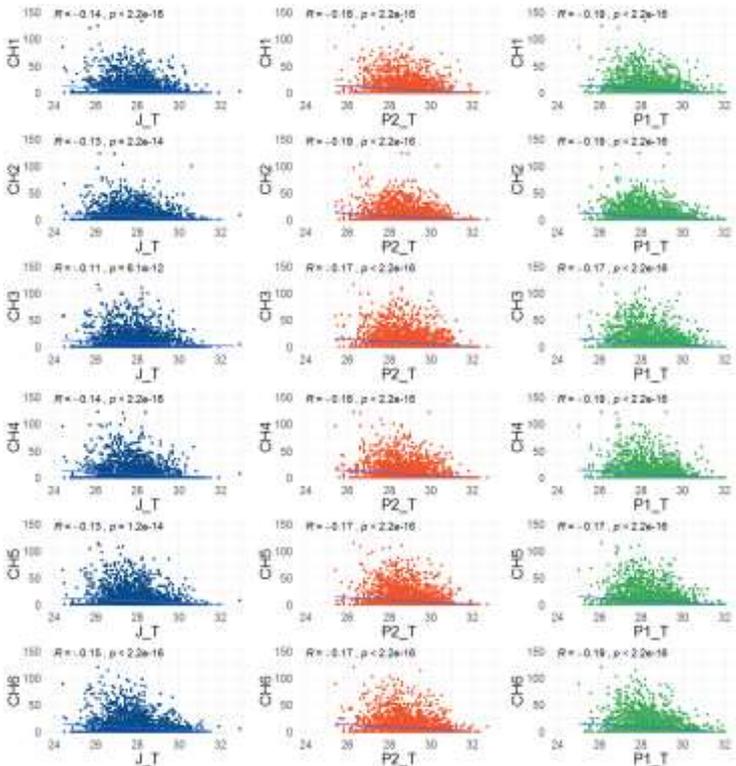
(b)

Gambar 4.7 (a) *Time-Series Plot* & (b) *Box-Plot* Rata-Rata Kec. Angin Stasiun BMKG

Time series dan *box plot* tiga unsur iklim di tiga stasiun BMKG menunjukkan pola yang relatif sama jika dilihat berdasarkan setiap unsur di tiga stasiun BMKG yang berbeda.

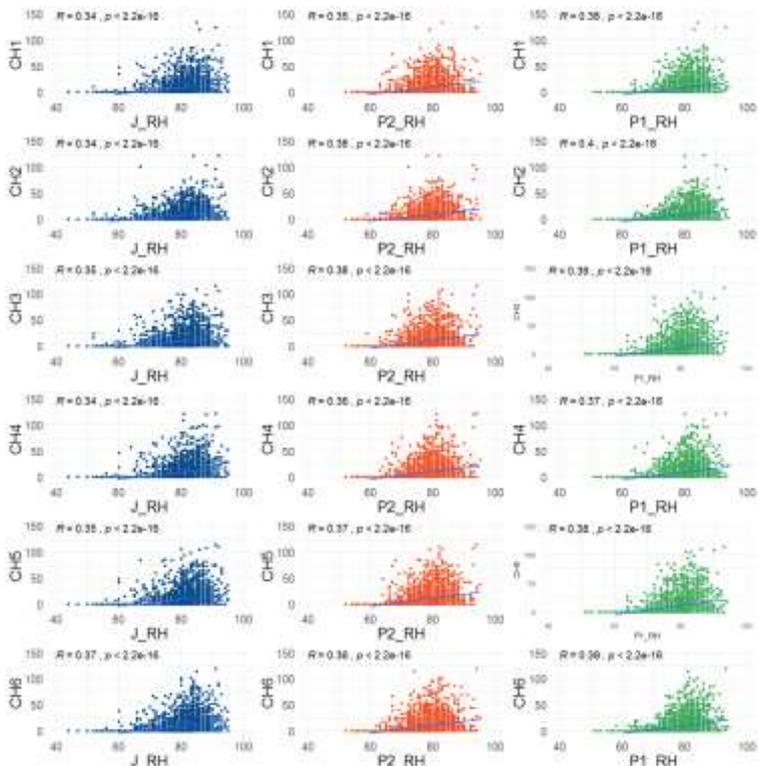
4.2.3 Variabel Respon dan Prediktor

Untuk melihat hubungan antara variabel prediktor terhadap variabel responnya, maka dapat menggunakan visualisasi data menggunakan *scatter-plot*. Berikut merupakan penjelasan berdasarkan *scatter-plot* untuk setiap variabel di tiga stasiun BMKG terhadap curah hujan di enam balai PSAWS.



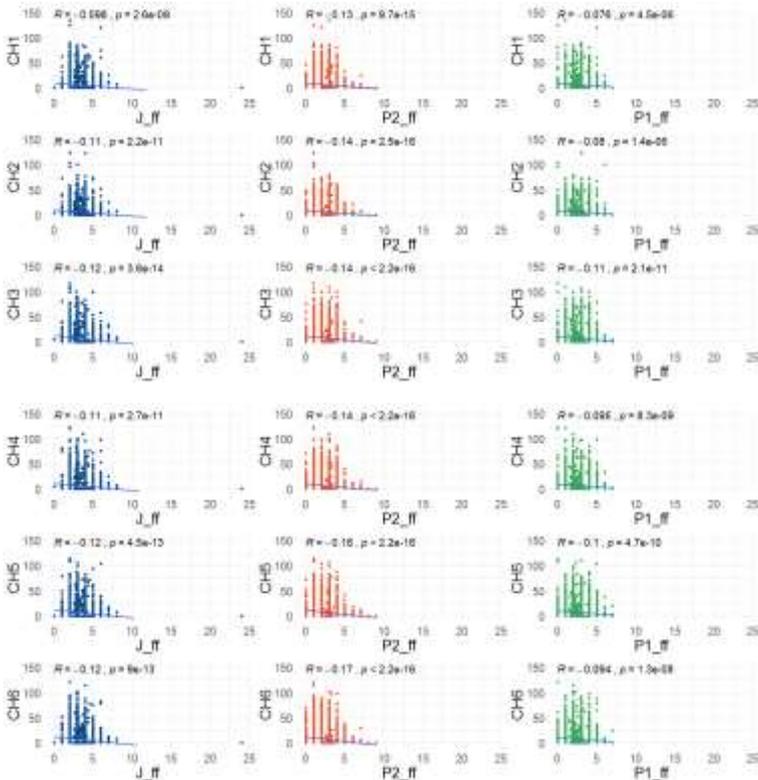
Gambar 4.8 *Scatter-Plot* Temperatur Udara & Curah Hujan

Berdasarkan Gambar 4.8, dapat diketahui bahwa rata-rata temperatur udara di tiga stasiun BMKG memiliki hubungan yang negatif terhadap curah hujan di enam balai PSAWS. Hal tersebut menunjukkan bahwa pada saat temperatur udara rendah, maka curah hujan di enam balai cenderung tinggi. Serta sebaliknya, jika temperatur udara tinggi maka curah hujan relatif rendah. Berdasarkan nilai *p-value* untuk setiap korelasi rata-rata temperatur udara terhadap curah hujan di enam balai menunjukkan nilai kurang dari 0,05, dapat diketahui bahwa temperatur signifikan berpengaruh terhadap curah hujan.



Gambar 4.9 Scatter-Plot Kelembaban Udara & Curah Hujan

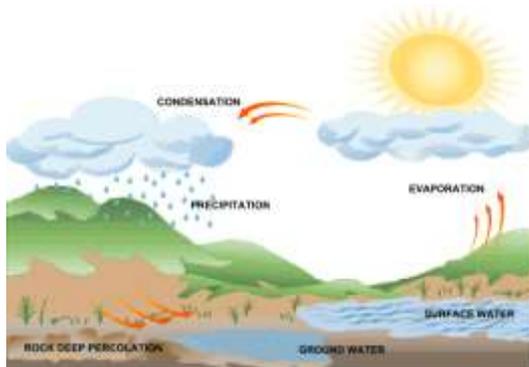
Berbeda dengan temperatur udara, jika dilihat berdasarkan Gambar 4.9, maka dapat diketahui bahwa rata-rata kelembaban udara di tiga stasiun BMKG memiliki hubungan positif terhadap curah hujan di enam balai PSAWS. Sehingga dapat diketahui bahwa pada saat kelembaban udara rendah, curah hujan juga cenderung rendah dan juga sebaliknya. Hal tersebut dikarenakan kelembaban maksimum terjadi pada saat udara jenuh terhadap uap air. Serta, dapat diketahui bahwa kelembaban udara signifikan berpengaruh terhadap curah hujan di enam balai PSAWS.



Gambar 4.10 Scatter-Plot Kecepatan Angin & Curah Hujan

Gambar 4.10 menunjukkan variabel kecepatan angin di tiga Stasiun BMKG memiliki korelasi negatif terhadap curah hujan di enam balai PSAWS, sama halannya dengan hubungan temperatur udara dan curah hujan. Maka, dapat diketahui pada saat kecepatan angin tinggi maka curah hujan rendah. Berdasarkan nilai *p-value* untuk setiap korelasi rata-rata kecepatan angin terhadap curah hujan di enam balai menunjukkan nilai kurang dari 0,05, maka dari itu dapat diketahui bahwa kecepatan angin juga signifikan berpengaruh terhadap curah hujan di enam balai PSAWS. Sehingga dapat diketahui bahwa ketiga unsur iklim di tiga stasiun BMKG berpengaruh signifikan terhadap curah hujan di enam balai PSAWS Kota Surabaya.

Visualisasi menggunakan *scatter-plot* pada Gambar 4.8, 4.9 dan 4.10 menunjukkan hubungan yang sesuai terhadap teori terbentuknya hujan. Dimana panas matahari membuat air laut atau danau menguap. Lalu uap air terkumpul di udara dalam bentuk awan, pada saat awan yang terbentuk menjadi semakin besar, maka kelembaban menjadi sangat maksimum (kelembaban udara tinggi). Awan kecil menjadi besar dikarenakan adanya angin, pada saat kecepatan angin tinggi maka awan kecil akan lebih cepat bergabung menjadi lebih besar. Adanya angin muson barat, dimana tekanan udara di Asia lebih tinggi, menjadikan udara berembus dari Asia ke Australia. Dikarenakan melewati Samudera Hindia, angin bergerak dengan membawa uap air yang tinggi. Pada saat suhu rendah dan awan telah terkumpul (menjadikan kelembaban dalam posisi maksimum), dengan kecepatan udara dalam keadaan rendah, lalu butiran-butiran air pun akan jatuh yang akan mengakibatkan hujan. Untuk proses hujan secara singkat dapat dilihat pada ilustrasi pada Gambar 4.11.



Gambar 4.11 Ilustrasi Terjadinya Hujan
(Sumber : IlmuGeografi.com)

4.3 PCA

Setelah melakukan pembagian data *training* dan *testing*, dimana data *training* sebanyak 3.621 data yang di mulai dari tanggal 01 Januari 2009 sampai dengan 30 November 2018. Sedangkan untuk data *testing* nya yaitu sebanyak 31 hari yang terdiri dari tanggal 1-31 Desember 2018. *Principal Component Analysis* (PCA) dilakukan guna menghindari adanya indikasi setiap unsur iklim saling berkorelasi atau saling mempengaruhi di tiga stasiun BMKG yang berbeda. Sehingga harapannya dapat menghilangkan permasalahan multikolinearitas setiap unsur iklim di lokasi yang berbeda pada saat memodelkan curah hujan terhadap tiga unsur iklim di stasiun yang berbeda secara bersamaan.

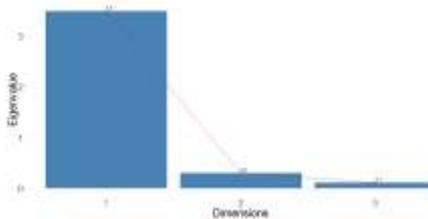
Terdapat beberapa cara dalam menentukan banyaknya PC, beberapa diantaranya yaitu dengan cara matematis dan juga visualisasi. Secara matematis dapat diketahui dengan mencari total *eigen value* atau pada *output* sama saja dengan *cumulative proportion*. Berikut merupakan hasil PCA untuk setiap variabel prediktor di 3 Stasiun BMKG yang telah melalui tahap PCA.

Untuk variabel yang pertama yaitu rata-rata temperatur udara, berikut hasil perhitungannya.

Tabel 4. 3 PCA Temperatur di 3 Stasiun BMKG

	PC1	PC2	PC3
St. Deviasi	1.8685	0.5460	0.3320
Proportion of variance	0.8953	0.0765	0.0283
Cumulative Proportion	0.8953	0.9717	1.0000

Berdasarkan Tabel 4.8 menunjukkan bahwa *cumulative proportion* pada PC 1 telah menjelaskan variabel rata-rata temperatur udara di 3 Stasiun BMKG yang berbeda sebesar 89%. Nilai tersebut sudah lebih dari 80%, sehingga dapat dikatakan X_1 sudah cukup baik dijelaskan jika menggunakan PC1 saja. Hal ini juga dapat dilihat dengan cara visualisasi menggunakan *scree-plot* sebagai berikut.

**Gambar 4.12** *Scree-Plot* PCA Temperatur Udara

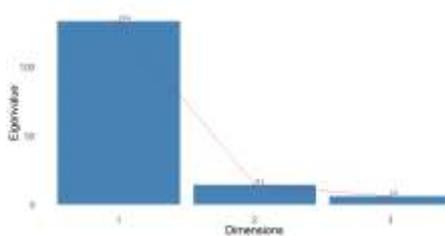
Berdasarkan Gambar. 4.12, dapat dilihat bahwa perubahan nilai secara signifikan terjadi dari komponen satu ke dua. Maka dapat dikatakan, dari data temperatur udara di 3 Stasiun sudah dapat dijelaskan cukup dengan menggunakan PC1. Untuk variabel selanjutnya yaitu rata-rata kelembaban udara.

Tabel 4. 4 PCA Kelembaban di 3 Stasiun BMKG

	PC1	PC2	PC3
St. Deviasi	11.551	3.7645	2.4259
<i>Proportion of variance</i>	0.8693	0.0923	0.0383
<i>Cumulative Proportion</i>	0.8693	0.9617	1.0000

Sama halnya dengan temperatur udara, PCA pada kelembaban udara pada PC 1 sudah mencapai 86%. Dikarenakan sudah melebihi nilai *cumulative proportion* lebih dari 80%. Variabel kelembaban udara

di 3 Stasiun BMKG sudah dapat dijelaskan menggunakan PC1. Hal tersebut juga dapat dilihat berdasarkan *scree*-plot berikut.



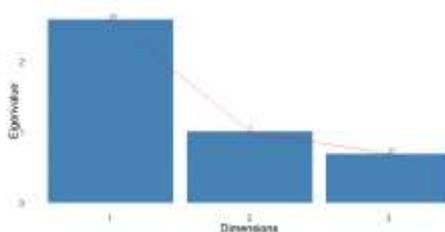
Gambar 4.13 *Scree-Plot* PCA Kelembaban Udara

Berdasarkan Gambar 4.13, perubahan nilai sangat signifikan pada PC1. Sedangkan untuk hasil PCA pada kecepatan angin dapat dilihat pada hasil perhitungan berikut.

Tabel 4. 5 PCA Kecepatan Angin di 3 Stasiun BMKG

	PC1	PC2	PC3
St. Deviasi	1.6106	1.0040	0.8316
<i>Proportion of variance</i>	0.6041	0.2348	0.1610
<i>Cumulative Proportion</i>	0.6041	0.8389	1.0000

Pada variabel kecepatan angin di Stasiun BMKG berdasarkan Tabel 4.10, menunjukkan bahwa pada PC1 belum dapat menjelaskan dengan baik karena nilai *cumulative proportion* belum melebihi 80%. Sehingga dapat dikatakan PC yang dibutuhkan untuk variabel kecepatan angin yaitu PC1 dan PC2. Hal tersebut juga dapat dilihat pada *scree*-plot berikut.



Gambar 4.14 *Scree-Plot* PCA Kecepatan Angin

Scree-Plot pada Gambar 4.14, menunjukkan bahwa PC1 tidak terlalu terlihat memiliki perubahan nilai yang signifikan, maka dari itu perlu menambahkan PC2 agar dapat menjelaskan variabel kecepatan angin dari 3 Stasiun BMKG yang berbeda dengan lebih baik. Maka data yang melalui tahap PCA akan menggunakan data PC1 pada ke-3 variabel dan PC2 pada variabel kecepatan angin. Untuk empat data PC dapat dilihat pada Lampiran 25.

Analisis PCA yang dilakukan pada penelitian tidak memperthatikan korelasi antar keseluruhan unsur iklim ataupun korelasi antar PC. Walaupun korelasi yang dihasilkan signifikan, nilai korelasi yang dihasilkan lebih kecil jika dibandingkan dengan nilai korelasi antar unsur iklim yang sama di tiga lokasi stasiun BMKG yang berbeda. Nilai korelasi tertinggi pada saat melakukan korelasi antar PC yaitu korelasi antar PC1 kecepatan angin dan PC1 kelembaban udara sebesar 39%. Sedangkan pada saat melakukan korelasi unsur iklim yang sama di tiga stasiun BMKG yang berbeda, nilai korelasi melebihi angka 50%.

4.4 Pemodelan Curah Hujan di Kota Surabaya

Terdapat beberapa model yang diperoleh dalam melakukan analisis menggunakan *Gaussian Copula Marginal Regression* (GCMR). Setiap balai akan memperoleh beberapa model prediksi curah hujan, yang nantinya akan dipilih model terbaik untuk setiap balai PSAWS di Kota Surabaya. Secara umum akan terdapat empat pemodelan untuk setiap curah hujan di enam balai, tiga model diperoleh dari tiga variabel prediktor di tiga stasiun BMKG dan satu model lainnya diperoleh dari prediktor yang telah melalui tahap PCA (variabel prediktor Stasiun Juanda, Stasiun Perak 2, Stasiun Perak 1 & variabel yang melalui tahap PCA terhadap tiga Stasiun BMKG). Untuk mendapatkan pemodelan empat pemodelan terhadap setiap balai curah hujan akan dimodelkan

dengan berbagai cara. Diantaranya yaitu dengan memodelkan secara *univariable*, *multivariable* serta di tambahkan variabel *dummy* dan lag yang diduga berpengaruh. Sehingga pada pembahasan kali ini akan di bahas berdasarkan enam balai di Kota Surabaya. Untuk setiap model GCMR akan di cobakan menggunakan dua marginal yang berbeda, diantara-nya adalah dengan menggunakan marginal Gamma (*link-function* = “sqrt”) dan Weibull (*link-function* = “sqrt”).

Dikarenakan *link-function* yang digunakan pada kedua marginal yang akan dilakukan analisis merupakan *link-function* “square root” atau “sqrt”, berdasarkan Tabel 2.3 jika $\eta = g(\mu)$ maka $\mu = g^{-1}(\eta)$. Untuk $\mu = \sqrt{\mu}$ maka $\mu = \eta^2$. Pada saat pemodelan model GCMR dengan prediktor *univariable*, maka model GCMR sebagai berikut.

$$CH_{b,t} = (\hat{\beta}_0 + \hat{\beta}_1 x_i)^2; i = 1,2,3 \text{ \& } b = 1,2, \dots, 6$$

Pada saat pemodelan model GCMR dengan prediktor *multivariable*, maka model GCMR sebagai berikut.

$$CH_{b,t} = (\hat{\beta}_0 + \hat{\beta}_1 x_{1,s} + \hat{\beta}_2 x_{2,s} + \hat{\beta}_3 x_{3,s})^2; s = 1,2,3 \text{ \& } b = 1,2, \dots, 6$$

Serta, pada saat prediktor merupakan PC dari hasil PCA, maka model GCMR.

$$CH_{b,t} = (\hat{\beta}_0 + \hat{\beta}_1 \text{PC1}_{x_{1,t}} + \hat{\beta}_2 \text{PC1}_{x_{2,t}} + \hat{\beta}_3 \text{PC1}_{x_{3,t}} + \hat{\beta}_1 \text{PC2}_{x_{3,t}})^2$$

Untuk skema variabel input yang akan digunakan pada setiap model dapat dilihat pada Lampiran 27. Dari skema tersebut, maka dapat diketahui untuk setiap balai akan memperoleh beberapa model untuk ke-empat kelompok variabel input yang berbeda. Menggunakan metode GCMR tidak dapat mengolah data jika terdapat data respon sama dengan nol, maka dari itu dilakukan

convert data sama dengan nol menjadi 0,00001 agar dapat dilakukan pengolahan data. Sehingga jika terdapat dua RMSE pada satu plot, maka RMSE* merupakan RMSE dari hasil prediksi dengan data respon asli (0 tidak di convert 0,00001). Untuk penjelasan model prediksi curah hujan terbaik berdasarkan empat input yang berbeda, di enam balai dapat dijelaskan sebagai berikut.

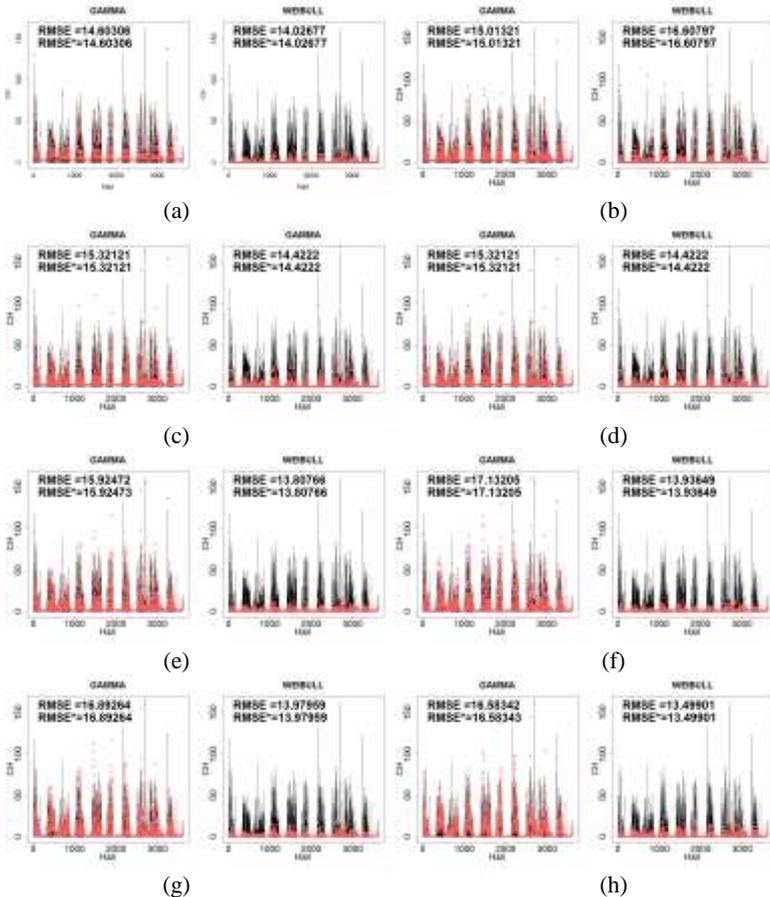
4.4.1 Keputih

Berdasarkan penjelasan pada *scatter-plot* curah hujan terhadap lag-nya (curah hujan pada beberapa hari sebelumnya), dapat diketahui bahwa antar variabel memiliki korelasi yang cukup tinggi. Maka dari itu, sebelum melakukan prediksi berdasarkan variabel prediktornya, curah hujan di Balai Keputih dimodelkan terlebih dahulu dengan curah hujan lag-nya.

Tabel 4. 6 Estimasi Parameter & Signifikansi $CH_{1,t-1}$ terhadap $CH_{1,t}$

Parameter	Gamma			Weibull		
	Est.	<i>z-value</i>	<i>p-value</i>	Est.	<i>z-value</i>	<i>p-value</i>
β_0	1,836	30,80	2.10^{-16}	-0,047	-15,10	2.10^{-16}
β_1	0,079	7,04	$1,9.10^{-12}$	-0,049	-8,49	2.10^{-16}
α	0,088	57,78	2.10^{-16}	0,155	84,18	2.10^{-16}

Tabel 4.6 menunjukkan *output* pemodelan curah hujan di Balai Keputih dengan curah hujan di Balai Keputih pada hari sebelumnya (lag-1). Dapat diketahui estimasi untuk setiap parameter adalah signifikan, hal ini dikarenakan nilai *p-value* lebih kecil dari 0,05. Sehingga terbukti bahwa curah hujan pada saat hari dimana hujan itu terjadi dipengaruhi curah hujan satu hari sebelumnya (lag-1). Pada saat melakukan percobaan dengan cara memodelkan curah hujan di Balai Keputih dengan curah hujan beberapa hari sebelumnya (lag), sampai dengan lag-7 dan lag-14. Gambar 4.16, menunjukkan hasil prediksi pada saat memodelkan curah hujan dengan curah hujan beberapa hari sebelumnya.



Gambar 4.15 Plot Prediksi $CH_{1,t}$ dengan Prediktor (a) $CH_{1,t-1}$ + (b) $CH_{1,t-2}$ + (c) $CH_{1,t-3}$ + (d) $CH_{1,t-4}$ + (e) $CH_{1,t-5}$ + (f) $CH_{1,t-6}$ + (g) $CH_{1,t-7}$ & (h) $CH_{1,t-14}$, Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Terdapat *time series* plot berwarna hitam dan *points* berwarna lain pada Gambar 4.15. Hal ini menunjukkan bahwa untuk plot *time series* merupakan plot data aktual sedangkan *points* merupakan hasil prediksi atau *fitted value* yang dihasilkan oleh model. Hal

tersebut berlaku untuk keseluruhan plot prediksi yang dihasilkan pada model lainnya.

Gambar 4.15, menunjukkan bahwa RMSE data *training* pada saat memodelkan dengan lag-1 nya selalu lebih kecil jika dibandingkan dengan pemodelan yang dilakukan hingga lag-7 dan lag-14. RMSE konsisten menjadi lebih besar secara perlahan sampai dengan lag-6, dan kembali turun pada saat lag-7. Namun nilai RMSE pada saat memodelkan sampai dengan lag-7, lebih tinggi dibandingkan dengan pemodelan yang hanya dilakukan sampai dengan lag-1. Saat melakukan pemodelan sampai dengan curah hujan lag-14, RMSE pada marginal Gamma semakin tinggi jika dibandingkan dengan pemodelan yang hanya menggunakan curah hujan lag-1.

Namun sebaliknya, pada marginal Weibull menunjukkan nilai RMSE yang lebih kecil. Maka besar kemungkinan curah hujan satu hari sebelumnya benar-benar sangat mempengaruhi curah hujan yang terjadi. Jika membandingkan ACF dan PACF dengan menggunakan marginal dan input lag yang berbeda, ACF dan PACF memberikan *output* yang relatif sama, yaitu *long-memory*. Setelah melakukan percobaan dengan menjadikan curah hujan lag-nya sebagai input. Maka selanjutnya yaitu memodelkan curah hujan di Balai Keputih menggunakan tiga unsur iklim dari tiga stasiun BMKG yang berbeda dengan berbagai percobaan guna memperoleh hasil prediksi curah hujan yang lebih baik. Berikut hasil analisis prediksi curah hujan di Balai Keputih berdasarkan empat kelompok input yang berbeda.

4.4.1.1 Stasiun Juanda

Sebelum melakukan pemodelan menggunakan keseluruhan variabel prediktor di Stasiun Juanda, perlu dicobakan untuk memodelkan satu persatu variabel prediktor terhadap variabel

respon, guna mengetahui apakah dengan menggunakan salah satu variabel prediktor di Stasiun Juanda sudah dapat memprediksi curah hujan di Balai Keputih dengan baik. Berikut hasil estimasi dan signifikansi model GCMR pada saat memodelkan curah hujan di Balai Keputih dengan variabel prediktor tiga unsur iklim di Stasiun Juanda secara *univariable* .

Tabel 4.7 Estimasi Parameter & Signifikansi Prediktor *Univariable* Stasiun Juanda terhadap $CH_{1,t}$

Parameter	Gamma			Weibull		
	Est.	<i>z-value</i>	<i>p-value</i>	Est.	<i>z-value</i>	<i>p-value</i>
$X_{1,1,t} = T_{1,t} = \text{Temperatur Udara}$						
β_0	14,69	114,12	2.10^{-16}	14,69	11,48	2.10^{-16}
β_1	-0,44	-85,17	2.10^{-16}	-0,50	11,48	2.10^{-16}
α	0,08	51,61	2.10^{-16}	0,14	73,33	2.10^{-16}
$X_{2,1,t} = RH_{1,t} = \text{Kelembaban Udara}$						
β_0	-4,99	-27,15	2.10^{-16}	0,21	3,89	$9,9. 10^{-5}$
β_1	0,09	26,43	2.10^{-16}	-1,10⁻³	-1,13	0,25
α	0,09	47,54	2.10^{-16}	0,15	80,46	2.10^{-16}
$X_{3,1,t} = ff_{1,t} = \text{Kecepatan Angin}$						
β_0	3,05	16,11	2.10^{-16}	-0,44	-16,76	2.10^{-16}
β_1	-0,21	-4,31	$1,6.10^{-5}$	0,09	16,48	2.10^{-16}
α	0,09	57,83	2.10^{-16}	0,15	82,45	2.10^{-16}

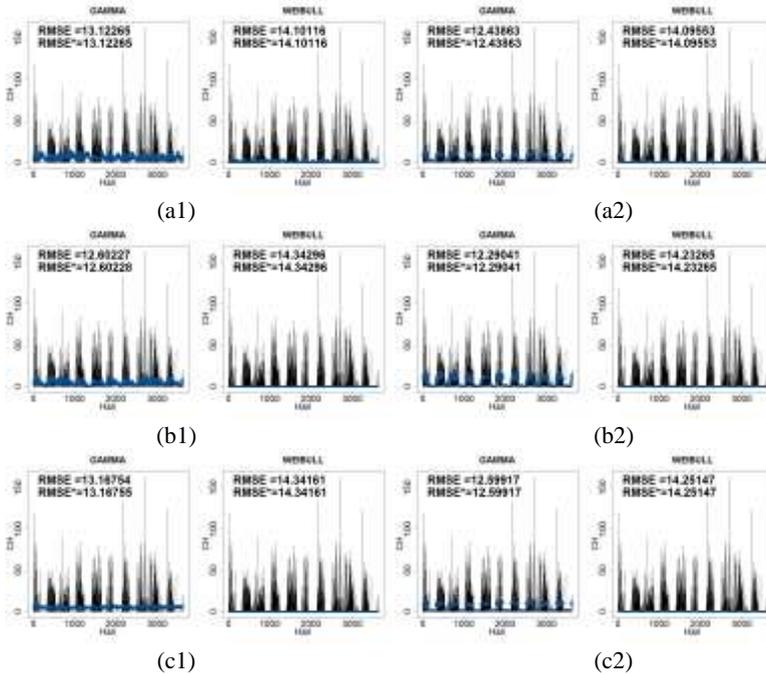
Tabel 4.7 menunjukkan bahwa dengan memodelkan masing-masing variabel prediktor Stasiun Juanda secara satu persatu atau *univariable* menggunakan dua marginal yang berbeda. Dapat diketahui terdapat variabel yang tidak signifikan pada saat variabel prediktor yang digunakan pada model yaitu variabel rata-rata kelembaban udara Stasiun Juanda, dengan marginal distribusi Weibull. Lalu dapat dicobakan pemodelan dengan menambahkan *dummy* untuk setiap model yang telah di hasilkan. Saat menambahkan variabel *dummy* sebagai variabel prediktor, maka *output* estimasi dan signifikansinya dapat dilihat pada Tabel 4.8.

Tabel 4.8 Estimasi Parameter & Signifikansi Prediktor *Univariable* Stasiun Juanda + *Dummy* terhadap $CH_{1,t}$

Parameter	Gamma			Weibull		
	Est.	<i>z-value</i>	<i>p-value</i>	Est.	<i>z-value</i>	<i>p-value</i>
$X_{1,t} = T_{1,t} = \text{Temperatur Udara}$						
β_0	7,12	5,01	$5,1 \cdot 10^{-7}$	7,57	6676,00	$2 \cdot 10^{-16}$
β_1	-0,21	-4,18	$2,8 \cdot 10^{-5}$	-0,28	-4687,66	$2 \cdot 10^{-16}$
d	1,69	12,70	$2 \cdot 10^{-16}$	0,87	151,53	$2 \cdot 10^{-16}$
α	0,09	57,75	$2 \cdot 10^{-16}$	0,16	75,83	$2 \cdot 10^{-16}$
$X_{2,t} = RH_{1,t} = \text{Kelembaban Udara}$						
β_0	-4,37	-34,88	$2 \cdot 10^{-16}$	-1,41	-23,88	$2 \cdot 10^{-16}$
β_1	0,07	34,40	$2 \cdot 10^{-16}$	0,02	23,46	$2 \cdot 10^{-16}$
d	2,14	16,15	$2 \cdot 10^{-16}$	0,27	5,39	$2 \cdot 10^{-16}$
α	0,11	57,01	$2 \cdot 10^{-16}$	0,17	69,33	$2 \cdot 10^{-16}$
$X_{3,t} = ff_{1,t} = \text{Kecepatan Angin}$						
β_0	1,73	92,53	$2 \cdot 10^{-16}$	1,94	13,02	$2 \cdot 10^{-16}$
β_1	-0,20	-23,86	$2 \cdot 10^{-16}$	-0,49	-13,09	$2 \cdot 10^{-16}$
d	1,99	15,04	$2 \cdot 10^{-16}$	0,59	15,50	$2 \cdot 10^{-16}$
α	0,09	57,52	$2 \cdot 10^{-16}$	0,16	73,84	$2 \cdot 10^{-16}$

Berdasarkan Tabel 4.8, dapat diketahui bahwa estimasi untuk setiap variabel yang pada awalnya terdapat variabel yang tidak signifikan, pada saat variabel input ditambahkan dengan *dummy*-menjadikan keseluruhan input signifikan. Plot prediksi dan RMSE pemodelan pada Tabel 4.7 & 4.8 dapat dilihat pada Gambar 4.16.

Gambar 4.16 menunjukkan bahwa, dengan menggunakan satu prediktor yang dimodelkan secara bergantian terhadap curah hujan di Balai Keputih menghasilkan prediksi yang tidak cukup akurat. Hal tersebut dapat dilihat dari *points* berwarna biru (hasil prediksi curah hujan) belum mengikuti pola data aslinya. Namun dengan menambahkan *dummy*, secara signifikan menurunkan nilai RMSE. Untuk lebih jelasnya berikut merupakan plot prediksi beserta RMSE antara data aktual dan prediksi pada pemodelan pada Tabel 4.7 dan 4.8.



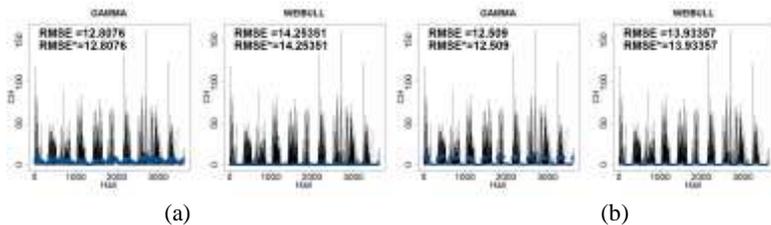
Gambar 4.16 Plot Prediksi $CH_{1,t}$ dengan Prediktor (*Univariable*) Stasiun Juanda (a1)T, (b1)RH, (c1)ff dan Prediktor Tambahan Variabel *Dummy* (a2,b2,c2), Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Untuk langkah selanjutnya yaitu memodelkan curah hujan di Balai Keputih dengan variabel prediktor Stasiun Juanda secara *multivariable* atau secara bersamaan serta di tambahkan variabel *dummy*. Sehingga ingin mengetahui model curah hujan pada saat dimodelkan dengan ketiga unsur iklim secara bersamaan dan pada saat curah hujan di modelkan secara bersamaan ditambahkan variabel prediktor *dummy*. Saat curah hujan di Balai Keputih dimodelkan secara *univariable* menunjukkan estimasi yang signifikan untuk ke-tiga unsur iklim di Stasiun Juanda. Estimasi dan signifikansi pada saat curah hujan di Balai Keputih dimodelkan dengan prediktor *multivariable* dapat dilihat pada Tabel 4.9.

Tabel 4.9 Estimasi Parameter & Signifikansi Prediktor *Multivariable* Stasiun Juanda terhadap $CH_{1,t}$

Parameter	Gamma			Weibull		
	Est.	<i>z</i> -value	<i>p</i> -value	Est.	<i>z</i> -value	<i>p</i> -value
<i>Multivariable</i>						
β_0	-8,30	-21118,50	2.10^{-16}	-8,42	-1350,70	2.10^{-16}
$\beta_1.T_{1,t}$	0,15	1438,50	2.10^{-16}	0,34	1220,20	2.10^{-16}
$\beta_2.RH_{1,t}$	0,08	2047,50	2.10^{-16}	5.10^{-3}	103,80	2.10^{-16}
$\beta_3.ff_{1,t}$	-0,16	-173,40	2.10^{-16}	-0,31	-129,90	2.10^{-16}
α	0,09	1160,30	2.10^{-16}	0,15	75,80	2.10^{-16}
<i>Multivariable + Dummy</i>						
β_0	-4,42	-16,8	2.10^{-16}	-4,41	-4231,40	2.10^{-16}
$\beta_1.T_{1,t}$	0,09	7,4	$6,9.10^{-14}$	1,17	2916,50	2.10^{-16}
$\beta_2.RH_{1,t}$	0,04	15,5	2.10^{-16}	1,98	1163,20	2.10^{-16}
$\beta_3.ff_{1,t}$	-0,06	-4,0	$6,1.10^{-16}$	-6,72	-246,50	2.10^{-16}
ν	1,82	14,6	2.10^{-16}	9,29	16519,60	2.10^{-16}
α	0,09	57,7	2.10^{-16}	1,76	111,60	2.10^{-16}

Tabel di 4.9 menunjukkan bahwa semua estimasi signifikan pada saat keseluruhan variabel unsur iklim di Stasiun Juanda menjadi variabel input pada model. Pada saat model ditambahkan *dummy*, maka dapat diketahui tidak terdapat hasil yang jauh berbeda dengan pemodelan tanpa variabel *dummy* Berikut plot prediksi beserta RMSE-nya.



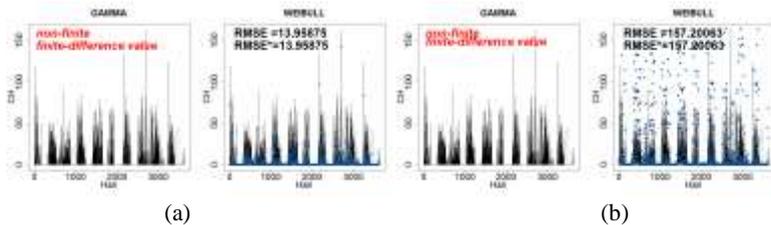
Gambar 4.17 Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (*Multivariable*) Stasiun Juanda dan (b) Prediktor Tambahan Variabel *Dummy*, Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Walapun keseluruhan variabel telah signifikan, baik itu pada saat ditambahkan variabel *dummy* atau tidak. Maka berdasarkan Gambar 4.17 menunjukkan kembali bahwa RMSE semakin kecil jika *dummy* juga merupakan variabel inputnya. Namun nilai prediksi belum mengikuti pola data aktual curah hujan di Balai Keputih. Sehingga mengindikasikan bahwa curah hujan pada hari-hari sebelumnya juga perlu diinputkan ke dalam model, guna memberikan hasil prediksi yang lebih baik. Pada saat variabel input secara keseluruhan dengan dan tanpa adanya variabel input *dummy* ditambahkan variabel curah hujan satu hari sebelumnya (lag-1) pada model, maka estimasi dan signifikansinya dapat dilihat pada Tabel 4.10.

Tabel 4.10 Estimasi Parameter & Signifikansi *Multivariable* Stasiun Juanda + *Dummy* + $CH_{1,t-1}$ terhadap $CH_{1,t}$

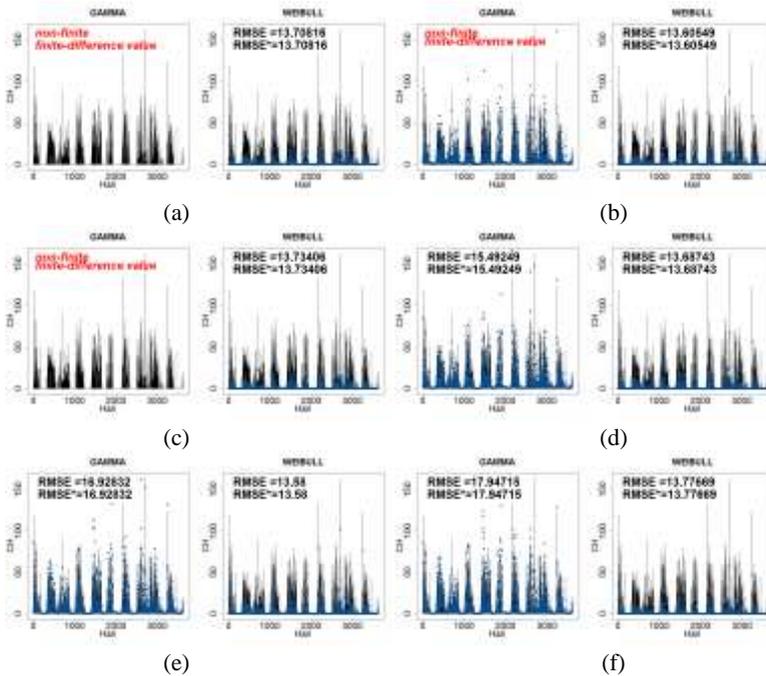
Parameter	Gamma			Weibull		
	Est.	<i>z-value</i>	<i>p-value</i>	Est.	<i>z-value</i>	<i>p-value</i>
<i>Multivariable</i> + $CH_{1,t-1}$						
β_0	-6,30	-4517,55	2.10^{-16}	-6,21	-382,17	2.10^{-16}
$\beta_1.T_{1,t}$	0,15	2174,66	2.10^{-16}	0,13	541,14	2.10^{-16}
$\beta_2.RH_{1,t}$	0,05	131,62	2.10^{-16}	0,04	223,39	2.10^{-16}
$\beta_3.ff_{1,t}$	-0,09	-15,29	2.10^{-16}	-0,09	-133,46	2.10^{-16}
$\beta_4.CH_{1,t-1}$	0,09	8,83	2.10^{-16}	0,07	5,28	$1,2.10^{-7}$
α	0,09	57,72	2.10^{-16}	0,16	67,88	2.10^{-16}
<i>Multivariable</i> + $CH_{1,t-1}$ + <i>Dummy</i>						
β_0				-3,70	-2800,89	2.10^{-16}
$\beta_1.T_{1,t}$				0,03	4831,42	2.10^{-16}
$\beta_2.RH_{1,t}$				0,02	2180,88	2.10^{-16}
$\beta_3.ff_{1,t}$	<i>Tidak Konvergen</i>			0,01	69,28	2.10^{-16}
$\beta_4.CH_{1,t-1}$				0,03	2,82	0,004
ν				0,42	82,10	2.10^{-16}
α				0,18	46,15	2.10^{-16}

Tabel 4.10 menunjukkan hasil yang signifikan untuk keseluruhan variabel, namun pada saat pemodelan menambahkan variabel *dummy* dan curah hujan di hari sebelumnya ($CH_{1,t-1}$) sebagai input dengan menggunakan marginal Gamma memberikan hasil yang tidak konvergen dan jika dilihat pada plot prediksi dan RMSE nya, dapat dilihat pada gambar 4.18



Gambar 4.18 Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (*Multivariable*) Stasiun Juanda + $CH_{1,t-1}$ dan (b) Prediktor Tambahan Variabel *Dummy*, Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Gambar 4.18 (a) menunjukkan bahwa plot prediksi (points berwarna biru) pada marginal Weibull terlihat mengikuti pola curah hujan aktual di Balai Keputih, namun nilai RMSE masih menunjukkan nilai yang cukup tinggi walupun plot peramalan menunjukkan nilai prediksi terlihat mengikuti pola data aslinya. Namun pada saat model tersebut ditambahkan dengan variabel *dummy*-nya maka dapat terlihat pada Gambar 4.18 (b), menunjukkan nilai RMSE semakin tinggi atau terlihat adanya *over fitting* dengan nilai prediksi terlihat tidak mengikuti pola. Serta hanya pada marginal Weibull pemodelan GCMR memberikan hasil yang konvergen jika menggunakan prediktor tersebut. Langkah selanjutnya, melakukan percobaan dengan memodelkan curah hujan di Balai Keputih dengan menambahkan variabel curah hujan beberapa hari sebelumnya sampai dengan curah hujan pada tujuh hari sebelumnya atau sampai dengan variabel lag-7 ($CH_{1,t-7}$).



Gambar 4.19 Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (*Multivariable*) Stasiun Juanda + (a) $CH_{1,t-2}$ + (b) $CH_{1,t-3}$ + (c) $CH_{1,t-4}$ + (d) $CH_{1,t-5}$ + (e) $CH_{1,t-6}$ + (f) $CH_{1,t-7}$, Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Sampai dengan memasukkan variabel sampai dengan tujuh hari sebelumnya pada model, nilai RMSE tidak semakin baik (RMSE tidak semakin kecil), dapat disimpulkan bahwa dengan memodelkan curah hujan di Balai Keputih dengan variabel prediktor di Stasiun Juanda memiliki model terbaik pada saat variabel input yang digunakan yaitu keseluruhan variabel unsur iklim yang ditambahkan variabel *dummy* tanpa melibatkan variabel lag atau variabel curah hujan beberapa hari sebelum kejadian curah hujan. Maka dari itu perlu dilakukan pemodelan dengan variabel input unsur iklim di stasiun yang berbeda dan variabel PC unsur iklim hasil analisis PCA.

4.4.1.2 Stasiun Perak 2

Langkah-langkah yang akan dilakukan dengan menggunakan variabel input di Stasiun Perak 2 akan sama dengan langkah sebelumnya yang telah dilakukan di Stasiun Juanda. Pemodelan pertama yaitu dengan memasukkan variabel input secara *univariable* ataupun satu persatu berdasarkan tiga variabel unsur iklim di Stasiun Perak 2. Estimasi parameter beserta signifikansinya dapat dilihat pada Tabel 4.11.

Tabel 4. 11 Estimasi Parameter & Signifikansi Prediktor *Univariable* Stasiun Perak 2 terhadap $CH_{1,t}$

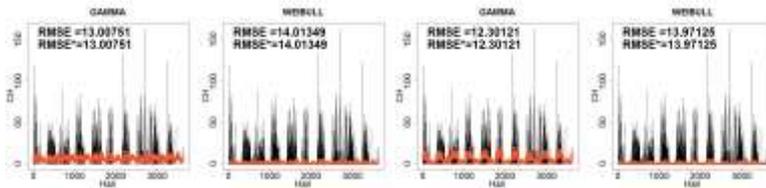
Para- meter	Gamma			Weibull		
	Est.	<i>z-value</i>	<i>p-value</i>	Est.	<i>z-value</i>	<i>p-value</i>
$X_{1,2,t} = T_{2,t} = \text{Temperatur Udara}$						
β_0	15,44	10,35	2.10^{-16}	0,16	3809858,79	2.10^{-16}
β_1	-0,45	-8,99	2.10^{-16}	-0,52	-4364,19	2.10^{-16}
α	0,09	57,88	2.10^{-16}	0,15	76,18	2.10^{-16}
$X_{2,2,t} = RH_{2,t} = \text{Kelembaban Udara}$						
β_0	-6,51	-1671,78	2.10^{-16}	-3,71	-989,88	2.10^{-16}
β_1	0,11	1167,35	2.10^{-16}	0,05	875,28	2.10^{-16}
α	0,09	40,15	2.10^{-16}	0,17	58,56	2.10^{-16}
$X_{3,2,t} = ff_{2,t} = \text{Kecepatan Angin}$						
β_0	3.45	322,67	2.10^{-16}	0.31	16,85	2.10^{-16}
β_1	-0.38	-401,15	2.10^{-16}	-0.06	-16,92	2.10^{-16}
α	0.09	81,54	2.10^{-16}	0.15	81,84	2.10^{-16}

Menggunakan kedua marginal distribusi curah hujan Gamma dan Weibull, memberikan hasil bahwa estimasi parameter tiga variabel unsur iklim di Stasiun Perak 2 signifikan berpengaruh terhadap curah hujan di Balai Keputih, beda halnya pada saat memodelkan curah hujan secara *univariable* di Stasiun Juanda. Menambahkan variabel *dummy* terhadap masing-masing model *univariable*, maka diperoleh hasil estimasi dan signifikansinya sebagai berikut.

Tabel 4.12 Estimasi Parameter & Signifikansi Prediktor *Univariable* Stasiun Perak 2 + Variabel *Dummy* terhadap $CH_{1,t}$

Parameter	Gamma			Weibull		
	Est.	<i>z-value</i>	<i>p-value</i>	Est.	<i>z-value</i>	<i>p-value</i>
$X_{1,2,t} = T_{2,t} = \text{Temperatur Udara}$						
β_0	13,565	3514,20	2.10^{-16}	12,263	51,77	2.10^{-16}
β_1	-0,425	-809,53	2.10^{-16}	-0,427	-51,86	2.10^{-16}
D	1,732	15,65	2.10^{-16}	1,115	48,89	2.10^{-16}
α	0,091	57,68	2.10^{-16}	0,158	75,00	2.10^{-16}
$X_{2,2,t} = RH_{2,t} = \text{Kelembaban Udara}$						
β_0	-2,310	-96,43	2.10^{-16}	-2,213	-127,37	2.10^{-16}
β_1	0,042	17,48	2.10^{-16}	0,031	137,17	2.10^{-16}
D	2,007	16,81	2.10^{-16}	0,284	58,98	2.10^{-16}
α	0,094	57,63	2.10^{-16}	0,172	75,83	2.10^{-16}
$X_{3,2,t} = ff_{2,t} = \text{Kecepatan Angin}$						
β_0	1,597	270,80	2.10^{-16}	0,661	9,90	2.10^{-16}
β_1	-0,200	-351,80	2.10^{-16}	-0,164	-9,82	2.10^{-16}
D	1,995	341,50	2.10^{-16}	0,477	9,55	2.10^{-16}
α	0,092	387,90	2.10^{-16}	0,158	72,15	2.10^{-16}

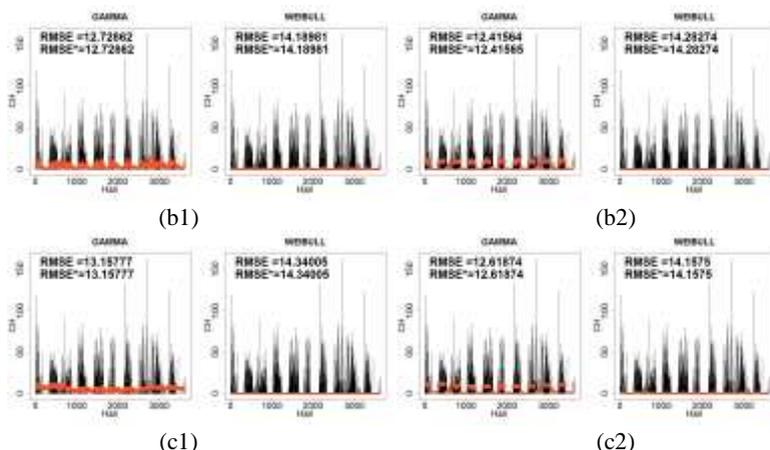
Tabel 4.12 menunjukkan bahwa keseluruhan variabel signifikan pada saat menambahkan variabel *dummy* sebagai variabel input pada model. Plot hasil prediksi dapat dilihat pada Gambar 4.20. Gambar 4.20 menunjukkan pola yang tidak jauh berbeda dengan pemodelan yang telah dilakukan sebelumnya.



(a1)

(a2)

Gambar 4.20 Plot Prediksi $CH_{1,t}$ dengan Prediktor (*Univariable*) Stasiun Perak2 (a1)T, (b1)RH, (c1)ff dan Prediktor Tambahan Variabel *Dummy* (a2,b2,c2), Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)



Gambar 4.20 Plot Prediksi $CH_{1,t}$ dengan Prediktor (*Univariable*) Stasiun Perak2 (a1)T, (b1)RH, (c1)ff dan Prediktor Tambahan Variabel *Dummy* (a2,b2,c2), Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan) [lanjutan]

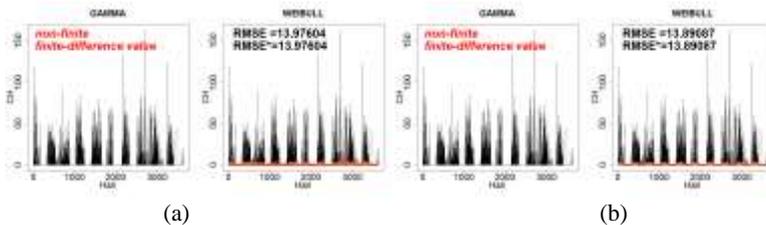
Jika membandingkan pemodelan yang menambahkan variabel prediktor *dummy* sebagai variabel input, sama halnya dengan variabel usur iklim di Stasiun Juanda sebagai prediktor maka diperoleh nilai RMSE semakin kecil dibandingkan model tanpa menginputkan variabel *dummy* pada model.

Langkah selanjutnya yaitu mencoba menginputkan ke seluruh variabel prediktor Stasiun Perak 2 (*multivariable*) terhadap model prediksi curah hujan di Balai Keputih. Hasil estimasi dan signifikansinya dapat dilihat pada Tabel 4.13. Pada saat ke-tiga variabel prediktor di Perak 2 menjadi input dalam model, maka dapat diketahui berdasarkan Tabel 4.13 bahwa variabel temperatur tidak signifikan dikarenakan nilai *p-value* lebih besar dari 0,05. Serta hanya dengan menggunakan marginal Weibull yang dapat memberikan hasil yang konvergen. Pada saat model secara *multivariable* ditambahkan dengan variabel *dummy*, maka berikut hasil estimasi dan signifikansinya. Menambahkan *dummy* memberikan hasil keseluruhan variabel signifikan.

Tabel 4.13 Estimasi Parameter & Signifikansi Prediktor *Multivariable* Stasiun Perak 2 terhadap $CH_{1,t}$

Parameter	Gamma			Weibull		
	Est.	<i>z-value</i>	<i>p-value</i>	Est.	<i>z-value</i>	<i>p-value</i>
<i>Multivariable</i>						
β_0				-5,11	-206,78	2.10^{-16}
$\beta_1.T_{2,t}$				-0,00	-0,46	0,644
$\beta_2.RH_{2,t}$	<i>Tidak Konvergen</i>			0,08	347,11	2.10^{-16}
$\beta_3.ff_{2,t}$				-0,08	-68,88	2.10^{-16}
α				0,16	75,08	2.10^{-16}
<i>Multivariable + Dummy</i>						
β_0				-2,56	-723,81	2.10^{-16}
$\beta_1.T_{2,t}$				0,01	33,44	2.10^{-16}
$\beta_2.RH_{2,t}$	<i>Tidak Konvergen</i>			0,04	484,33	2.10^{-16}
$\beta_3.ff_{2,t}$				-0,19	-108,39	2.10^{-16}
D				0,91	13,03	2.10^{-16}
α				0,17	73,18	2.10^{-16}

Untuk plot prediksi beserta RMSE dari model pada Tabel 4.13 dapat dilihat pada Gambar 4.21.



Gambar 4.21 Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (*Multivariable*) Stasiun Perak 2 dan (b) Prediktor Tambahan Variabel *Dummy*, Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

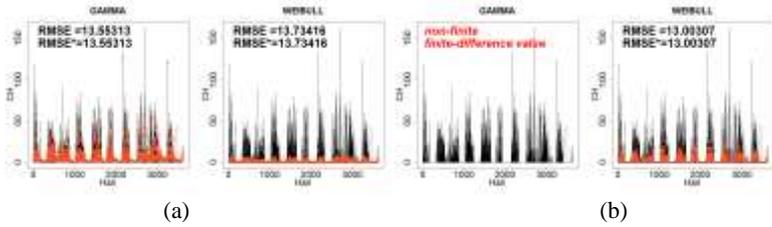
Berdasarkan Gambar 4.21 menunjukkan bahwa dengan menambahkan variabel *dummy*, maka sedikit menurunkan nilai RMSE-nya. Namun nilai prediksi juga belum mengikuti pola data aslinya. Oleh karena itu, langkah selanjutnya yaitu menginputkan

variabel curah hujan satu hari sebelumnya ke dalam model sehingga didapatkan estimasi parameter beserta signifikansinya pada Tabel 4.14 berikut.

Tabel 4.14 Estimasi Parameter & Signifikansi *Multivariable* Stasiun Perak 2 + *Dummy* + $CH_{1,t-1}$ terhadap $CH_{1,t}$

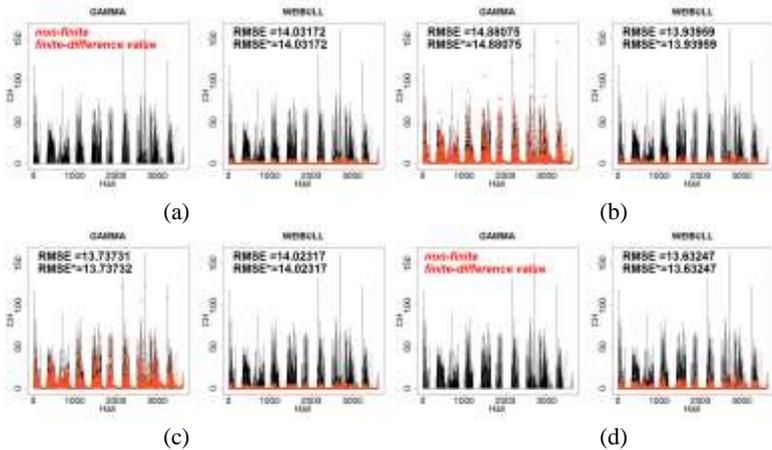
Parameter	Gamma			Weibull		
	Est.	<i>z-value</i>	<i>p-value</i>	Est.	<i>z-value</i>	<i>p-value</i>
<i>Multivariable</i> + $CH_{1,t-1}$						
β_0	-4,05	-2,82	$4 \cdot 10^{-3}$	-4,05	-982,69	$2 \cdot 10^{-16}$
$\beta_1 \cdot T_{2,t}$	0,00	0,00	0,993	-0,03	-364,83	$2 \cdot 10^{-16}$
$\beta_2 \cdot RH_{2,t}$	0,08	27,53	$2 \cdot 10^{-16}$	0,07	1266,25	$2 \cdot 10^{-16}$
$\beta_3 \cdot ff_{2,t}$	-0,14	-9,20	$2 \cdot 10^{-16}$	-0,15	-149,43	$2 \cdot 10^{-16}$
β_{lag1}	0,07	6,46	$9,8 \cdot 10^{-11}$	0,06	19,49	$1,2 \cdot 10^{-7}$
α	0,09	57,26	$2 \cdot 10^{-16}$	0,16	81,22	$2 \cdot 10^{-16}$
<i>Multivariable</i> + $CH_{1,t-1}$ + <i>Dummy</i>						
β_0				-1,92	-580,16	$2 \cdot 10^{-16}$
$\beta_1 \cdot T_{2,t}$				0,02	115,32	$2 \cdot 10^{-16}$
$\beta_2 \cdot RH_{2,t}$				0,02	1063,13	$2 \cdot 10^{-16}$
$\beta_3 \cdot ff_{2,t}$		<i>Tidak Konvergen</i>		-0,06	-365,36	$2 \cdot 10^{-16}$
$\beta_4 \cdot CH_{1,t-1}$				$-3 \cdot 10^{-3}$	-33,30	$2 \cdot 10^{-16}$
D				0,67	149,13	$2 \cdot 10^{-16}$
α				0,18	78,17	$2 \cdot 10^{-16}$

Tidak adanya variabel *dummy* pada model dan hanya menambahkan curah hujan pada hari sebelumnya (*lag1*) di Balai Keputih memberikan hasil estimasi yang tidak signifikan pada variabel temperatur jika menggunakan marginal Gamma. Jika terdapat variabel *dummy* dan variabel curah hujan di hari sebelumnya pada model memberikan hasil estimasi parameter yang signifikan secara keseluruhan, namun memberikan hasil yang tidak konvergen pada marginal Gamma. Gambar 4.22 menunjukkan hasil prediksi dan RMSE dari model.

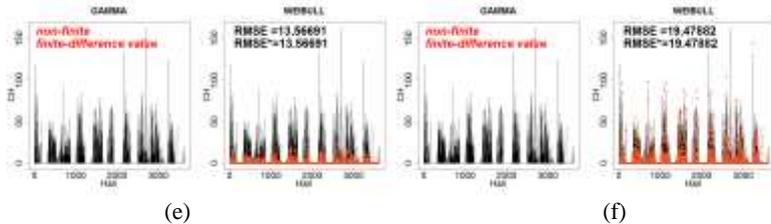


Gambar 4.22 Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (*Multivariable*) Stasiun Perak 2 + $CH_{1,t-1}$ dan (b) Prediktor Tambahan Variabel *Dummy* , Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Gambar 4.22 menunjukkan hasil prediksi sudah terlihat lebih baik dikarenakan sudah terlihat mengikuti pola data aslinya, namun nilai RMSE masih tinggi dan tidak jauh berbeda dengan model-model sebelumnya yang telah di cobakan di Stasiun Juanda. Pada langkah selanjutnya dicobakan dalam memodelkan curah hujan di Balai Keputih dengan menambahkan variabel curah hujan beberapa hari sebelumnya sampai dengan curah hujan pada tujuh hari sebelumnya atau sampai dengan variabel lag-7 ($CH_{1,t-7}$).



Gambar 4.23 Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (*Multivariable*) Stasiun Perak 2 + (a) $CH_{1,t-2}$ + (b) $CH_{1,t-3}$ + (c) $CH_{1,t-4}$ + (d) $CH_{1,t-5}$ + (e) $CH_{1,t-6}$ + (f) $CH_{1,t-7}$, Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)



Gambar 4.23 Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (*Multivariable*) Stasiun Perak 2 + (a) $CH_{1,t-2}$ + (b) $CH_{1,t-3}$ + (c) $CH_{1,t-4}$ + (d) $CH_{1,t-5}$ + (e) $CH_{1,t-6}$ + (f) $CH_{1,t-7}$, Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan) [lanjutan]

Dapat diketahui bahwa pada pemodelan dengan menggunakan variabel input secara *multivariable* di Stasiun Perak 2 memberikan nilai RMSE terkecil pada saat menggunakan marginal Weibull dengan variabel input yang digunakan yaitu variabel unsur iklim secara keseluruhan atau *multivariable* ditambahkan variabel *dummy*.

Memasukkan variabel lag atau variabel curah hujan beberapa hari sebelumnya tidak menjadikan nilai RMSE semakin baik, sama halnya pada saat prediktor yang digunakan merupakan unsur iklim di Stasiun Juanda. Namun jika dilihat berdasarkan plot prediksi, menunjukkan bahwa dengan memasukkan variabel lag sebagai variabel prediktor dalam model, dapat menjadikan prediksi terlihat mengikuti data aktualnya.

4.4.1.3 Stasiun Perak 1

Langkah selanjutnya yaitu memodelkan curah hujan di Balai Keputih dengan variabel prediktor unsur iklim pada Stasiun Perak 1. Langkah yang digunakan sama halnya ketika memodelkan curah hujan dengan berbagai variabel input pada kelompok variabel input unsur iklim di Stasiun Juanda & Stasiun Perak 2. Langkah pertama yaitu memodelkan curah hujan di Balai Keputih terhadap prediktor

univariable unsur iklim di Stasiun Perak 1. Dapat diketahui estimasi dan signifikansi model dapat ditunjukkan pada Tabel 4.15.

Tabel 4.15 Estimasi Parameter & Signifikansi *Univariable* Stasiun Perak 1 terhadap $CH_{1,t}$

Para- meter	Gamma			Weibull		
	Est.	<i>z-value</i>	<i>p-value</i>	Est.	<i>z-value</i>	<i>p-value</i>
$X_{1,3,t} = T_{3,t} = \text{Temperatur Udara}$						
β_0	15,941	12.82	2.10^{-16}	0,162	3332442.93	2.10^{-16}
β_1	-0,478	-11.29	$1,9.10^{-12}$	-0,552	-3943.05	2.10^{-16}
α	0,0885	57.84	2.10^{-16}	0,146	77.72	2.10^{-16}
$X_{2,3,t} = RH_{3,t} = \text{Kelembaban Udara}$						
β_0	-5.221	-52.79	2.10^{-16}	-3.951	-52.79	2.10^{-16}
β_1	0.090	50.33	2.10^{-16}	0,057	50.33	2.10^{-16}
α	0.093	57.53	2.10^{-16}	0,166	57.53	2.10^{-16}
$X_{3,3,t} = ff_{3,t} = \text{Kecepatan Angin}$						
β_0	2.832	17.508	2.10^{-16}	0.197	13.913	2.10^{-16}
β_1	-0.187	-3.626	$2,9.10^{-14}$	-0.029	-9.581	2.10^{-16}
α	0.087	57.831	2.10^{-16}	0.147	81.846	2.10^{-16}

Berdasarkan Tabel 4.15 menunjukkan bahwa tidak terdapat estimasi parameter variabel prediktor secara *univariable* yang tidak signifikan. Saat dilakukan pemodelan yang ditambahkan *dummy* pada variabel inputnya, maka diperoleh nilai estimasi dan signifikansinya pada Tabel 4.16.

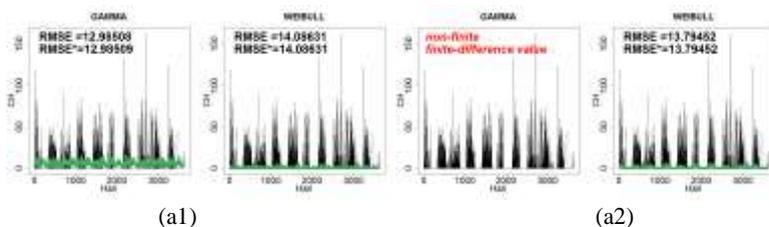
Tabel 4.16 Estimasi Parameter & Signifikansi Prediktor *Univariable* Stasiun Perak 1 + Variabel *Dummy* terhadap $CH_{1,t}$

Para- meter	Gamma			Weibull		
	Est.	<i>z-value</i>	<i>p-value</i>	Est.	<i>z-value</i>	<i>p-value</i>
$X_{1,3,t} = T_{3,t} = \text{Temperatur Udara}$						
β_0				12,070	639.39	2.10^{-16}
β_1	<i>Tidak Konvergen</i>			-0,431	-637.78	2.10^{-16}
D				1,276	237.92	2.10^{-16}
α				0,157	74.99	2.10^{-16}

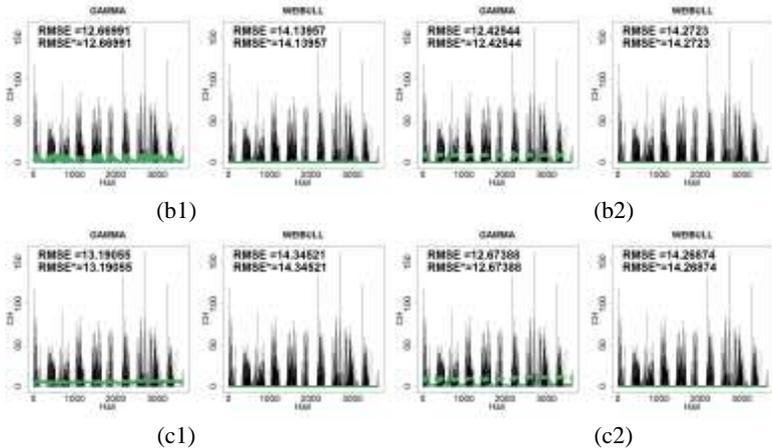
Tabel 4.16 Estimasi Parameter & Signifikansi Prediktor *Univariable* Stasiun Perak 1 + *Dummy* terhadap $CH_{1,t}$

Parameter	Gamma			Weibull		
	Est.	<i>z-value</i>	<i>p-value</i>	Est.	<i>z-value</i>	<i>p-value</i>
$X_{2,3,t} = RH_{3,t} = \text{Kelembaban Udara}$						
β_0	-2,225	-85.48	2.10^{-16}	-2,200	-1417.58	2.10^{-16}
β_1	0,041	88.97	2.10^{-16}	0,032	1469.22	2.10^{-16}
D	1,952	17.67	2.10^{-16}	-0,006	-9.09	2.10^{-16}
α	0,095	43.35	2.10^{-16}	0,183	84.43	2.10^{-16}
$X_{3,3,t} = ff_{3,t} = \text{Kecepatan Angin}$						
β_0	1,768	17.57	2.10^{-16}	0,311	10.88	2.10^{-16}
β_1	-0.197	-7.41	$1,2.10^{-13}$	-0,123	-10.92	2.10^{-16}
D	1,852	14.18	2.10^{-16}	1,090	4.77	$1,9.10^{-6}$
α	0,090	57.76	2.10^{-16}	0,168	76.16	2.10^{-16}

Tabel 4.16 juga menunjukkan bahwa keseluruhan parameter yang pada variabel input adalah signifikan secara keseluruhan. Dapat diketahui terdapat model yang memberikan hasil yang tidak konvergen, yaitu pada saat menggunakan variabel input temperatur dan *dummy*. Gambar 4.24 menunjukkan plot prediksi & RMSE untuk setiap model pada Tabel 4.15 dan tabel 4.16. Untuk plot prediksi juga tidak mengikuti pola data aktualnya.



Gambar 4.24 Plot Prediksi $CH_{1,t}$ dengan Prediktor (*Univariable*) Stasiun Perak1 (a1)T, (b1)RH, (c1)ff dan Prediktor Tambahan Variabel *Dummy* (a2,b2,c2), Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)



Gambar 4.24 Plot Prediksi $CH_{1,t}$ dengan Prediktor (*Univariable*) Stasiun Perak 1 (a1)T, (b1)RH, (c1)ff dan Prediktor Tambahan Variabel *Dummy* (a2,b2,c2), Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan) [lanjutan]

Sama halnya pada saat memodelkan curah hujan pada saat variabel input unsur iklim di Stasiun Juanda maupun Stasiun Perak 2, RMSE model yang ditambahkan variabel *dummy*, akan memberikan nilai yang lebih kecil jika dibandingkan dengan model yang tidak menggunakan variabel *dummy* sebagai variabel inputnya. Sedangkan untuk model secara *multivariable* dapat diketahui estimasi dan signifikansi pada Tabel 4.17

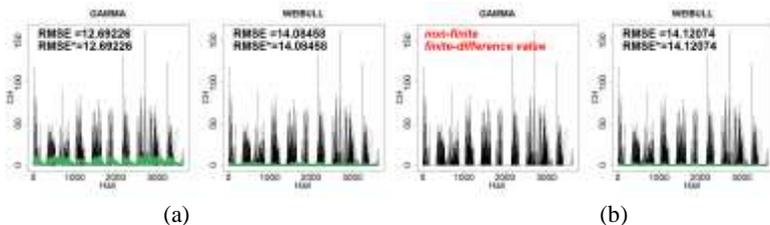
Tabel 4.17 Estimasi Parameter & Signifikansi Prediktor *Multivariable* Stasiun Perak 1 terhadap $CH_{1,t}$

Parameter	Gamma			Weibull		
	Est.	<i>z-value</i>	<i>p-value</i>	Est.	<i>z-value</i>	<i>p-value</i>
<i>Multivariable</i>						
β_0	-5,70	-4171,9	2.10^{-16}	-5,66	-3732,5	2.10^{-16}
$\beta_1.T_{3,t}$	-0,01	-62,0	2.10^{-16}	0,04	421,0	2.10^{-16}
$\beta_2.RH_{3,t}$	0,10	1696,0	2.10^{-16}	0,06	1881,3	2.10^{-16}
$\beta_3.ff_{3,t}$	0,05	70,6	2.10^{-16}	0,09	100,5	2.10^{-16}
α	0,09	84,1	2.10^{-16}	0,16	76,2	2.10^{-16}

Tabel 4.17 Estimasi Parameter & Signifikansi Prediktor *Multivariable* Stasiun Perak 1 terhadap $CH_{1,t}$ [lanjutan]

Parameter	Gamma			Weibull		
	Est.	<i>z-value</i>	<i>p-value</i>	Est.	<i>z-value</i>	<i>p-value</i>
<i>Multivariable + Dummy</i>						
β_0				-3,913	-6418	2.10^{-16}
$\beta_1.T_{3,t}$				0,007	298	2.10^{-16}
$\beta_2.RH_{3,t}$				0,046	5736	2.10^{-16}
$\beta_3.ff_{3,t}$	<i>Tidak Konvergen</i>			0,163	926	2.10^{-16}
D				1,714	257507	2.10^{-16}
α				0,160	267	2.10^{-16}
β_0				-3,913	-6418	2.10^{-16}

Tabel 4.17 menunjukkan bahwa keseluruhan variabel prediktor di Stasiun Perak 1 menunjukkan estimasi parameter yang signifikan. Adanya variabel *dummy* pada model, menjadikan model dengan marginal Gamma yang pada awalnya konvergen menjadi tidak konvergen. Plot prediksi beserta RMSE plot prediksi dan data aktualnya dapat tunjukkan pada Gambar 4.21. Pada gambar tersebut menunjukkan dengan menambahkan variabel *dummy* tidak memberikan nilai RMSE semakin baik.



Gambar 4.25 Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (*Multivariable*) Stasiun Perak 1 dan (b) Prediktor Tambahan Variabel *Dummy*, Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

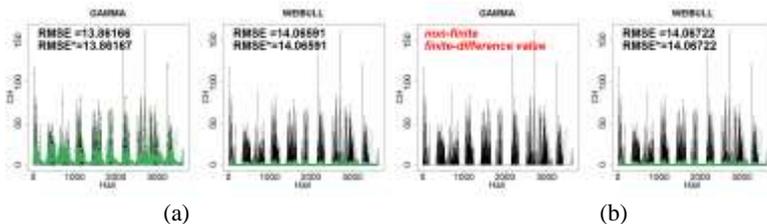
Menambahkan variabel curah hujan satu hari sebelumnya dan variabel *dummy* pada model yang telah di inputkan dengan variabel

stasiun Perak 1, maka akan memberikan hasil estimasi dan signifikansinya pada Tabel 4.18.

Tabel 4.18 Estimasi Parameter & Signifikansi Prediktor *Multivariable* Stasiun Perak 1 + *Dummy* + $CH_{1,t-1}$ terhadap $CH_{1,t}$

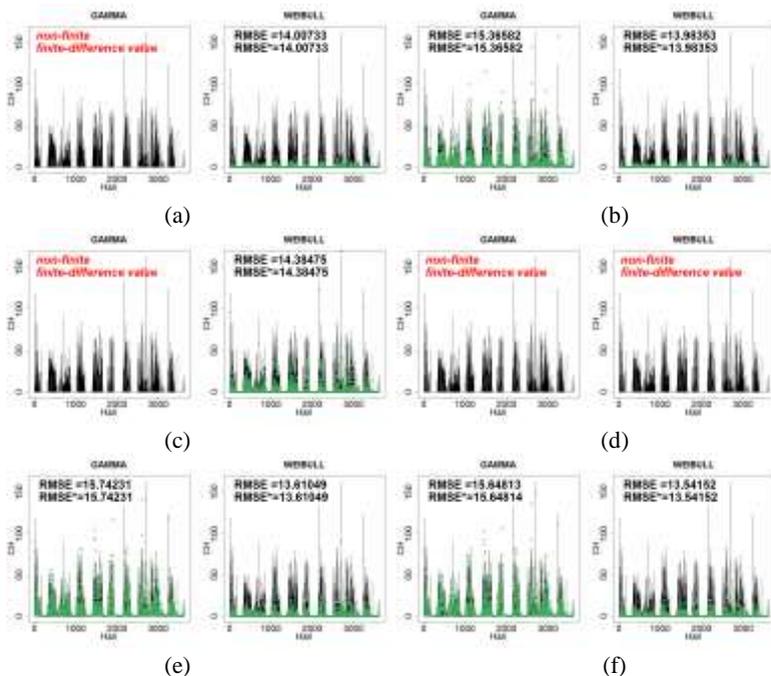
Parameter	Gamma			Weibull		
	Est.	<i>z-value</i>	<i>p-value</i>	Est.	<i>z-value</i>	<i>p-value</i>
<i>Multivariable</i> + $CH_{1,t-1}$						
β_0				-4,57	-717,41	2.10^{-16}
$\beta_1 \cdot T_{3,t}$				0,02	427,25	2.10^{-16}
$\beta_2 \cdot RH_{3,t}$				0,05	1139,82	2.10^{-16}
$\beta_3 \cdot ff_{3,t}$			<i>Tidak Konvergen</i>	0,09	180,74	2.10^{-16}
$\beta_4 \cdot CH_{1,t-1}$				0,01	4,04	$5,2.10^{-5}$
α				0,171	67,13	2.10^{-16}
<i>Multivariable</i> + <i>Dummy</i> + $CH_{1,t-1}$						
β_0	-2,95	-203,56	2.10^{-16}	-2,94	-335,10	2.10^{-16}
$\beta_1 \cdot T_{3,t}$	-6.10^{-3}	-8,58	2.10^{-16}	0,02	82,77	2.10^{-16}
$\beta_2 \cdot RH_{3,t}$	0,05	193,30	2.10^{-16}	0,03	753,36	2.10^{-16}
$\beta_3 \cdot ff_{3,t}$	0,09	53,61	2.10^{-16}	0,11	211,58	2.10^{-16}
$\beta_4 \cdot CH_{1,t-1}$	0,06	6,87	6.10^{-12}	0,02	4,60	$4,0.10^{-6}$
d	1,41	55,16	2.10^{-16}	0,31	107,02	2.10^{-16}
α	0,09	63,85	2.10^{-16}	0,15	77,51	2.10^{-16}

Menambahkan curah hujan pada hari sebelumnya sebagai input menjadikan marginal Gamma kembali konvergen.



Gambar 4.26 Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (*Multivariable*) Stasiun Perak 1 + $CH_{1,t-1}$ dan (b) Prediktor Tambahan Variabel *Dummy*, Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Gambar 4.26 (a) juga menunjukkan bahwa plot prediksi dengan menggunakan marginal Gamma sudah mulai mengikuti pola data aslinya, namun nilai RMSE masih cukup tinggi. Sama halnya dengan variabel input unsur iklim di dua stasiun lainnya, pada saat curah hujan di Balai Keputih dimodelkan dengan keseluruhan variabel dan curah hujan beberapa hari sebelumnya, prediksi data *training* tidak memberikan hasil yang membaik. Untuk plot prediksi dan RMSE dapat dilihat pada Gambar 4.27.



Gambar 4.27 Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (*Multivariable*) Stasiun Perak 1 + (a) $CH_{1,t-2}$ + (b) $CH_{1,t-3}$ + (c) $CH_{1,t-4}$ + (d) $CH_{1,t-5}$ + (e) $CH_{1,t-6}$ + (f) $CH_{1,t-7}$, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Model yang terbaik pada saat Stasiun Perak 1 menjadi variabel prediktornya, terdapat pada model yang hanya memasukkan

variabel kelembaban dan *dummy*. Hal ini dikarenakan nilai RMSE yang terkecil yaitu 12 dan variabel keseluruhan di model tersebut signifikan. Namun dikarenakan keseluruhan unsur iklim harus dimasukkan dalam model, maka dapat diketahui model secara *multivariable* tanpa menambahkan variabel *dummy* dan variabel curah hujan beberapa hari sebelumnya merupakan yang terbaik jika dilihat dari nilai RMSE terkecil. Namun plot tidak terlalu mengikuti pola data aktualnya.

4.4.1.4 PCA

Dikarenakan tiga variabel unsur iklim antar tiga Stasiun BMKG diduga saling berpengaruh. Maka dari itu dilakukan PCA terlebih dahulu untuk setiap variabel. Berdasarkan hasil analisis pada BAB. 4.3 mengenai PCA, hasil estimasi dan signifikansi pada saat melakukan analisis dengan menjadikan PC yang sesuai sebagai variabel input pada model dapat dilihat pada Tabel 4.19.

Tabel 4. 19 Estimasi Parameter & Signifikansi Prediktor *Univariable* PC terhadap $CH_{1,t}$

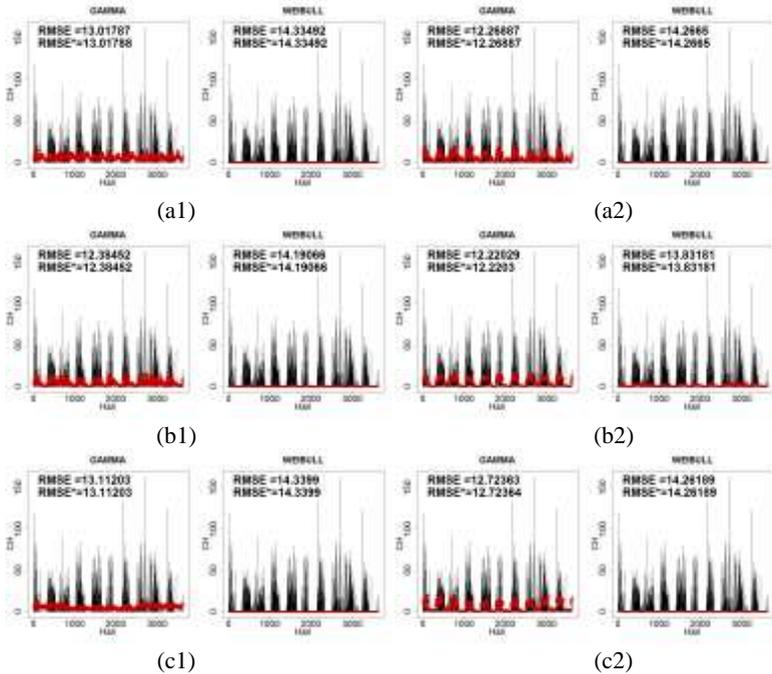
Parameter	Gamma			Gamma		
	Est.	<i>z-value</i>	<i>p-value</i>	Est.	<i>z-value</i>	<i>p-value</i>
$X_{1,PCA,t} = T_{PCA,t} =$ Temperatur Udara						
β_0	2,28	35,17	2.10^{-16}	0,24	104,69	2.10^{-16}
$\beta_1, PC1_T$	-0,29	-11,61	2.10^{-16}	-0,06	-94,96	2.10^{-16}
α	0,09	57,81	2.10^{-16}	0,15	81,86	2.10^{-16}
$X_{2,PCA,t} = RH_{PCA,t} =$ Kelembaban Udara						
β_0	2,08	471,50	2.10^{-16}	0,253	376,12	2.10^{-16}
$\beta_1, PC1_{RH}$	-0,08	-442,50	2.10^{-16}	-0,01	-344,73	2.10^{-16}
α	0,09	57,60	2.10^{-16}	0,17	81,43	2.10^{-16}
$X_{3,PCA,t} = ff_{PCA,t} =$ Kecepatan Angin						
β_0	2,31	2,30	2.10^{-16}	2,07	471,50	2.10^{-16}
$\beta_1, PC1_{ff}$	-0,28	-0,27	2.10^{-16}	-0,08	-442,50	2.10^{-16}
$\beta_2, PC2_{ff}$	-0,10	-0,10	2.10^{-16}	0,09	57,60	2.10^{-16}
α	2,31	0,08	2.10^{-16}	2,07	471,50	2.10^{-16}

Pada Tabel 4.19 menunjukkan keseluruhan variabel PC signifikan terhadap curah hujan di Balai Keputih. Tabel 4.20 menunjukkan estimasi dan signifikansi pada saat curah hujan di Balai Keputih dimodelkan dengan variabel prediktor *univariable* PC ditambahkan variabel *dummy*.

Tabel 4.20 Estimasi Parameter & Signifikansi Prediktor *Univariable* PC + Variabel *Dummy* terhadap $CH_{1,t}$

Parameter	Gamma			Weibull		
	Est.	<i>z-value</i>	<i>p-value</i>	Est.	<i>z-value</i>	<i>p-value</i>
$X_{1,PCA,t} = T_{PCA,t} = \text{Temperatur Udara}$						
β_0	1,36	55,24	2.10^{-16}	0,02	13,46	2.10^{-16}
$\beta_1.PC1_T$	-0,30	-41,86	2.10^{-16}	-3.10^{-3}	-6,55	$5,8.10^{-11}$
D	1,55	13,76	2.10^{-16}	0,48	14,16	2.10^{-16}
α	0,09	58,13	2.10^{-16}	0,16	83,45	2.10^{-16}
$X_{2,PCA,t} = RH_{PCA,t} = \text{Kelembaban Udara}$						
β_0				0,95	924,99	2.10^{-16}
$\beta_1.PC1_{RH}$	<i>Tidak Konvergen</i>			-0,05	-211,06	2.10^{-16}
D				-0,73	-478,49	2.10^{-16}
α				0,15	72,26	2.10^{-16}
$X_{3,PCA,t} = ff_{PCA,t} = \text{Kecepatan Angin}$						
β_0	1,13	79,79	2.10^{-16}	0,03	9,71	2.10^{-16}
$\beta_1.PC1_{ff}$	-0,34	-85,82	2.10^{-16}	-0,01	-10,23	2.10^{-16}
$\beta_2.PC2_{ff}$	-0,23	-24,05	2.10^{-16}	-0,05	-9,83	2.10^{-16}
D	1,76	20,88	2.10^{-16}	-0,69	-10,99	2.10^{-16}
α	0,09	42,15	2.10^{-16}	0,16	81,63	2.10^{-16}

Tabel 4.20 kembali menunjukkan keseluruhan estimasi parameter pada model signifikan terhadap curah hujan di Balai Keputih. Gambar 4.28 menunjukkan plot prediksi dan RMSE yang dihasilkan pada pemodelan curah hujan dengan estimasi parameter dan signifikansi pada Tabel 4.19 dan 4.20. Gambar 4.20 menunjukkan hasil yang tidak jauh berbeda jika dibandingkan dengan variabel prediktor di tiga Stasiun BMKG.



Gambar 4.28 Plot Prediksi $CH_{1,t}$ dengan Prediktor (*Univariable*) PC (a1)T, (b1)RH, (c1)ff dan Prediktor Tambahan Variabel *Dummy* (a2,b2,c2), Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Memodelkan curah hujan di Balai Keputih dengan keseluruhan variabel *Principal Component* (PC), Tabel 4.21 menunjukkan hasil estimasi dan signifikansinya. Gambar 4.29 menunjukkan bahwa RMSE semakin membaik jika variabel ditambahkan dengan variabel *dummy*-nya. Namun pada marginal Gamma dengan input PC kelembaban udara dan *variabel dummy* menjadikan hasil yang tidak convergen.

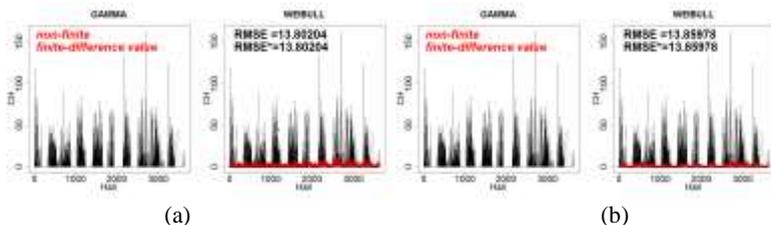
Menjadikan PC yang sesuai dari tiga variabel unsur iklim di tiga Stasiun BMKG memberikan nilai yang signifikan terhadap parameter pada model tersebut. Keseluruhan PC yang sesuai sebagai input, juga memberikan estimasi setiap variabel signifikan.

Hanya dengan menggunakan marginal Weibull, pemodelan curah hujan di Balai Keputih dapat memberikan hasil yang konvergen.

Tabel 4. 21 Estimasi Parameter & Signifikansi Prediktor *Multivariable* PC terhadap $CH_{1,t}$

Parameter	Gamma			Weibull		
	Est.	<i>z-value</i>	<i>p-value</i>	Est.	<i>z-value</i>	<i>p-value</i>
<i>Multivariable</i>						
β_0				0,15	469,30	2.10^{-16}
β_1 .PC1 _T				0,23	1190,20	2.10^{-16}
β_2 .PC1 _{RH}		<i>Tidak Konvergen</i>		-0,05	-1336,20	2.10^{-16}
β_3 .PC1 _{ff}				-0,07	-200,90	2.10^{-16}
β_4 .PC2 _{ff}				-0,08	-283,30	2.10^{-16}
α				0,14	100,60	2.10^{-16}
<i>Multivariable + Dummy</i>						
β_0				0,99	1122,47	2.10^{-16}
β_1 .PC1 _T				2.10^{-3}	3,16	0,002
β_2 .PC1 _{RH}		<i>Tidak Konvergen</i>		-0,06	-686,87	2.10^{-16}
β_3 .PC1 _{ff}				-0,03	-80,71	2.10^{-16}
β_4 .PC2 _{ff}				-0,09	-26,42	2.10^{-16}
D				1,66	8,77	2.10^{-16}
α				0,15	67,40	2.10^{-16}

Jika dibandingkan kedua model, maka diperoleh plot estimasi dan RMSE nya pada Gambar 4.29.



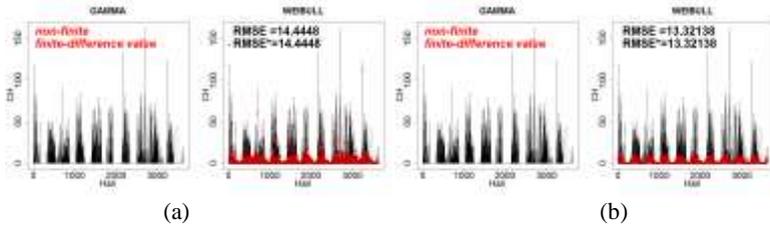
Gambar 4.29 Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (*Multivariable*) PC dan (b) Prediktor Tambahan Variabel *Dummy* , Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Gambar 4.29 menunjukkan bahwa pada saat menggunakan marginal Gamma, model tersebut memebrikan hasil yang tidak konvergen.

Tabel 4.22 Estimasi Parameter & Signifikansi Prediktor *Multivariable* PC + *Dummy* + $CH_{1,t-1}$ terhadap $CH_{1,t}$

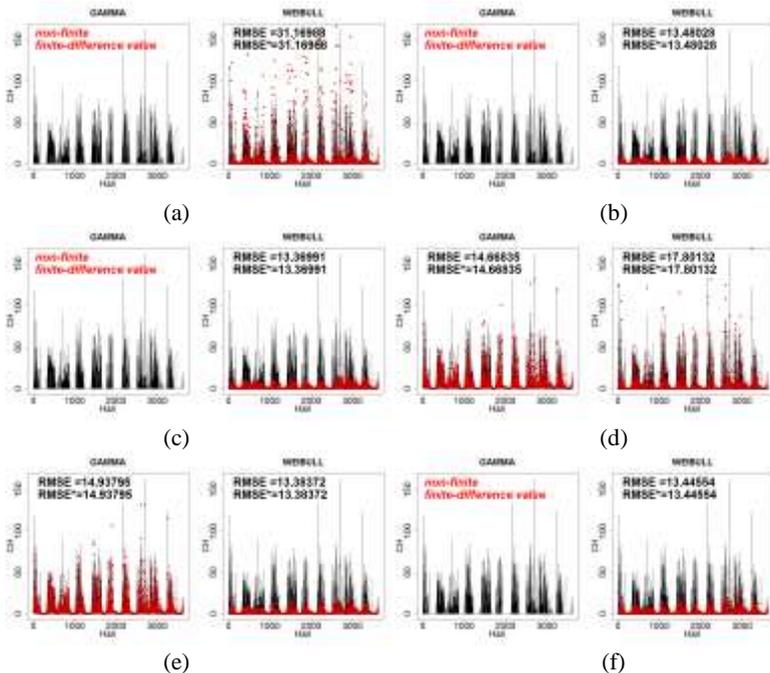
Parameter	Gamma			Weibull		
	Est.	z-value	p-value	Est.	z-value	p-value
<i>Multivariable</i> + $CH_{1,t-1}$						
β_0				0,54	276,07	2.10^{-16}
$\beta_1.PC1_T$				0,14	224,61	2.10^{-16}
$\beta_2.PC1_{RH}$				-0,03	-192,02	2.10^{-16}
$\beta_3.PC1_{ff}$		<i>Tidak Konvergen</i>		-0,18	-260,59	2.10^{-16}
$\beta_4.PC2_{ff}$				0,13	87,56	2.10^{-16}
$\beta_5.CH_{1,t-1}$				-0,22	-123,05	2.10^{-16}
α				0,15	73,47	2.10^{-16}
<i>Multivariable</i> + $CH_{1,t-1}$ + <i>Dummy</i>						
β_0				0,25	168,83	2.10^{-16}
$\beta_1.PC1_T$				0,02	107,15	2.10^{-16}
$\beta_2.PC1_{RH}$				-0,01	-172,40	2.10^{-16}
$\beta_3.PC1_{ff}$		<i>Tidak Konvergen</i>		-0,01	-18,63	2.10^{-16}
$\beta_4.PC2_{ff}$				-0,04	-35,34	2.10^{-16}
$\beta_5.CH_{1,t-1}$				1,43	52,73	2.10^{-16}
ν				-0,48	-44,58	2.10^{-16}
α				0,17	69,11	2.10^{-16}

Tabel 4.22 menunjukkan, menambahkan variabel curah hujan hari sebelumnya sebagai input menjadikan marginal Gamma kembali tidak konvergen, dan mamberikan estimasi yang signifikan secara keseluruhan pada saat menggunakan marginal Weibull. Gambar 4.30 menunjukkan plot prediksi pada pemodelan pada Tabel 4.22.



Gambar 4.30 Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (*Multivariable*) PC + $CH_{1,t-1}$ dan (b) Prediktor Tambahan Variabel *Dummy*, Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Nilai RMSE masih cukup tinggi, lalu dicobakan dengan menambahkan variabel input curah hujan beberapa hari sebelum.

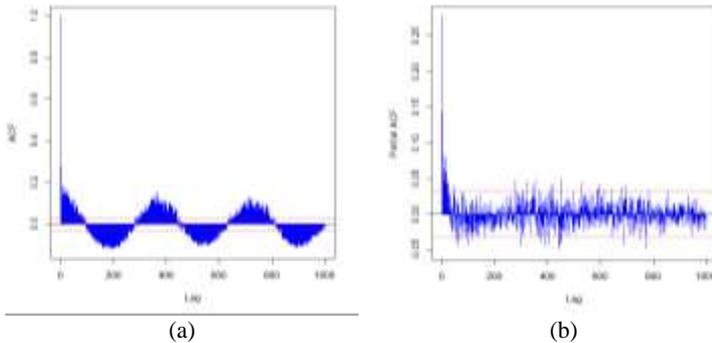


Gambar 4.31 Plot Prediksi $CH_{1,t}$ dengan (a) Prediktor (*Multivariable*) PC + (a) $CH_{1,t-2}$ + (b) $CH_{1,t-3}$ + (c) $CH_{1,t-4}$ + (d) $CH_{1,t-5}$ + (e) $CH_{1,t-6}$ + (f) $CH_{1,t-7}$, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Dapat diketahui bahwa dari beberapa pemodelan yang telah dilakukan baik itu prediktor pada Stasiun Juanda, Perak 2 maupun Perak 1, dan PCA dapat diketahui bahwa RMSE terkecil yang diperoleh yaitu dengan memodelkan kelembaban udara di Stasiun Juanda dengan ditambahkan variabel *dummy*-nya yaitu memberikan nilai RMSE sebesar 12,29. Penelitian ini mewajibkan ketiga unsur iklim berada dalam model, maka jika dilihat berdasarkan nilai RMSE minimum dengan input *multivariable* dapat diketahui pada saat curah hujan dimodelkan dengan prediktor unsur iklim Stasiun Juanda ditambahkan variabel *dummy* dengan RMSE 12,50. Maka model tersebut dapat dikatakan model yang terbaik.

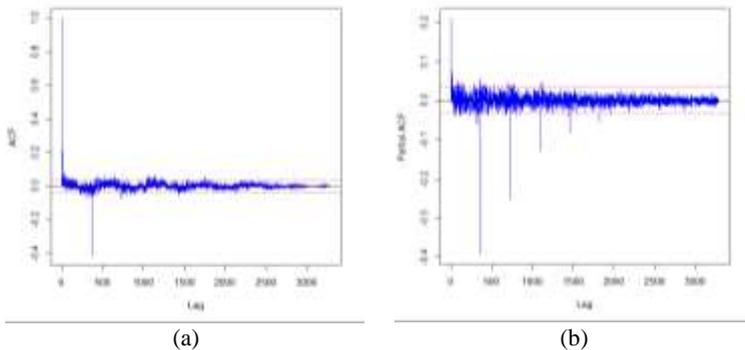
4.4.1.5 Evaluasi Model

Berdasarkan hasil analisis sebelumnya, dapat diketahui bahwa nilai model yang memiliki nilai RMSE terkecil baik secara keseluruhan maupun berdasarkan ke-empat variabel prediktor yang berbeda menunjukkan bahwa plot prediksi masih tidak telalu mengikuti pola data aktualnya dan nilai RMSE tidak cukup kecil yaitu memiliki nilai RMSE di antara 12 sampai dengan 16. Dikarenakan rata-rata model terbaik yang diperoleh yaitu dengan memasukkan keseluruhan variabel dan ataupun di tambah variabel *dummy* tanpa memasukkan variabel curah hujan pada hari-hari sebelumnya. Dapat diketahui dari analisis yang telah dilakukan bahwa variabel lag curah hujan yang dapat membantu nilai prediksi mengikuti pola data aktualnya. Maka dari itu perlu dilakukannya evaluasi pada model dimana mengidentifikasi lag apa saja yang diduga benar-benar dapat mempengaruhi curah hujan di Balai Keputih. Sebelum mengetahui lag apa saja yang akan berpengaruh, maka perlu dilakukan pengamatan pada plot ACF dan PACF pada data yang disajikan pada Gambar 4.32.



Gambar 4.32 Plot (a) ACF dan (b) PACF Data $CH_{1,t}$

Berdasarkan Gambar 4.32 dapat dilihat bahwa data membentuk pola musiman dan belum stasioner. Maka dari itu dicobakan kembali pemodelan menggunakan ARIMA guna mengetahui input yang benar-benar sesuai. Data di duga tidak stasioner dalam musiman yaitu dalam 365 hari, sehingga perlu dilakukan *differencing* musiman, yaitu 365 agar dapat diperoleh lag-lag yang signifikan. Berikut ini merupakan plot ACF dan PACF curah hujan Keputih hasil *differencing* yang disajikan pada Gambar 4.33.



Gambar 4.33 Plot (a) ACF dan (b) PACF Data $CH_{1,t}$ (*differencing* seasonal 365)

Plot ACF dan PACF pada Gambar 4.33 diduga bahwa sudah terdapat lag-lag yang signifikan untuk identifikasi model ARIMA(p,d,q)(P,D,Q)³⁶⁵ yang selanjutnya akan didapatkan lag-lag curah hujan yang diduga berpengaruh signifikan terhadap prediksi curah hujan di Balai Keputih. Sehingga di duga diperoleh model ARIMA(1,0,1)(5,1,1)³⁶⁵. Hal ini dikarenakan jika dilihat berdasarkan PACF untuk AR, seasonalnya ada lima. Serta sarusnya terdapat komponen MA, namun jika komponen MA dilibatkan maka tidak dapat menentukan input. Hal tersebut dikarenakan komponen MA tidak dapat milih input dari error. Sehingga dilakukan penyederhanaan, menjadikan model ARIMA(1,0,0)(5,1,0)³⁶⁵. Model AR(p) dianggap satu saja yang keluar. Melakukan penyederhanaan model ARIMA guna mendapatkan variabel input yang di duga mempengaruhi model. Sehingga dari model ARIMA tersebut diperoleh lag- yang diduga berpengaruh signifikan berdasarkan perhitungan secara matematis sebagai berikut.

$$Y_t = ARIMA(p, d, q)(P, D, Q)^s \rightarrow Y_t = ARIMA(1, 0, 0)(5, 1, 0)^{365}$$

$$\phi_p(B)\theta_q(B^s)(1-B^d)(1-B^s)^p Y_t = \theta_0 + \theta_q(B)\Theta_Q(B^s)\alpha_t$$

$$(1 - \phi_1 B)(1 - \Phi_1 B^{365} - \Phi_2 B^{2(365)} - \Phi_3 B^{3(365)} - \Phi_4 B^{4(365)} - \Phi_5 B^{5(365)})(1 - B^{365})Y_t = \alpha_t$$

Dengan $d = 1$ dan $s = 365$, maka :

$$\alpha_t = (1 - \phi_1 B)(1 - \Phi_1 B^{365} - \Phi_2 B^{2(365)} - \Phi_3 B^{3(365)} - \Phi_4 B^{4(365)} - \Phi_5 B^{5(365)})(1 - B^{365})Y_t$$

$$\alpha_t = (1 - \phi_1 B)(1 - \Phi_1 B^{365} - \Phi_2 B^{2(365)} - \Phi_3 B^{3(365)} - \Phi_4 B^{4(365)} - \Phi_5 B^{5(365)})(Y_t - Y_{t-365})$$

$$\alpha_t = \{(1 - \phi_1 B^{365} - \phi_2 B^{730} - \phi_3 B^{1095} - \phi_4 B^{1460} - \phi_5 B^{1825}) - (\phi_1 B - \phi_1 \Phi_1 B B^{365} - \phi_1 \Phi_2 B B^{730} - \phi_1 \Phi_3 B B^{1095} - \phi_1 \Phi_4 B B^{1460} - \phi_1 \Phi_5 B B^{1825})\}(W_t)$$

$$\alpha_t = \{(1 - \phi_1 B^{365} - \phi_2 B^{730} - \phi_3 B^{1095} - \phi_4 B^{1460} - \phi_5 B^{1825}) - (\phi_1 B - \psi_1 B^{366} - \psi_2 B^{731} - \psi_3 B^{1096} - \psi_4 B^{1461} - \psi_5 B^{1826})\}(W_t)$$

$$\alpha_t = \{(1 - \phi_1 B - \phi_1 B^{365} + \psi_1 B^{366} - \phi_2 B^{730} + \psi_2 B^{731} - \phi_3 B^{1095} + \psi_3 B^{1096} - \phi_4 B^{1460} + \psi_4 B^{1461} - \phi_5 B^{1825} + \psi_5 B^{1826})\}(W_t)$$

$$a_t = \{W_t - \phi_1 W_{t-1} - \phi_1 W_{t-365} + \psi_1 W_{t-366} - \phi_2 W_{t-730} + \psi_2 W_{t-731} - \phi_3 W_{t-1095} + \psi_3 W_{t-1096} - \phi_4 W_{t-1460} + \psi_4 W_{t-1461} - \phi_5 W_{t-1825} + \psi_5 W_{t-1826}\}$$

dikarenakan $w_t = (Y_t - Y_{t-36})$ maka :

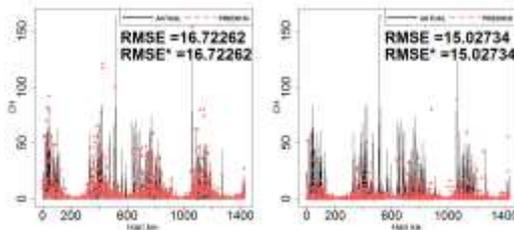
$$w_t = \{\phi_1(Y_{t-1} - Y_{t-366}) + \Phi_1(Y_{t-365} - Y_{t-730}) - \psi_1(Y_{t-366} - Y_{t-731}) + \Phi_2(Y_{t-730} - Y_{t-1095}) - \psi_2(Y_{t-731} - Y_{t-1096}) + \Phi_3(Y_{t-1095} - Y_{t-1460}) - \psi_3(Y_{t-1096} - Y_{t-1461}) + \Phi_4(Y_{t-1461} - Y_{t-1826}) - \psi_4(Y_{t-1461} - Y_{t-1826}) + \Phi_5(Y_{t-1825} - Y_{t-2190}) - \psi_5(Y_{t-1826} - Y_{t-2191}) + a_t\}$$

Maka lag yang diduga dapat memprediksi curah hujan di Balai Keputih dengan baik adalah sebagai berikut.

$$Y_t = f(Y_{t-1}, Y_{t-365}, Y_{t-366}, Y_{t-730}, Y_{t-731}, Y_{t-1095}, Y_{t-1096}, Y_{t-1460}, Y_{t-1461}, Y_{t-1825}, Y_{t-1826}, Y_{t-2190}, Y_{t-2191}) + e$$

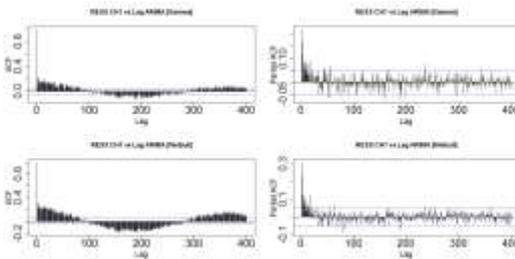
$$CH_t = f(CH_{t-1}, CH_{t-365}, CH_{t-366}, CH_{t-730}, CH_{t-731}, CH_{t-1095}, CH_{t-1096}, CH_{t-1460}, CH_{t-1461}, CH_{t-1825}, CH_{t-1826}, CH_{t-2190}, CH_{t-2191}) + e$$

Berdasarkan perhitungan di atas, didapatkan hasil bahwa lag-lag yang diduga berpengaruh signifikan terhadap curah hujan di Balai Keputih adalah pada lag-1, lag-365, lag-366, lag-730, lag-731, lag-1095, lag-1096, lag-1460, lag-1461, lag-1825, lag-1826, lag-2190, dan lag-2191. Total terdapat 13 lag yang dapat dinamakan dengan lag-differencing seasonal atau lag-ARIMA. Plot preidksi beserta ACF dan PACF pada saat memodelkan curah hujan terhadap 13 lag tersebut dapat dilihat pada Gambar 4.34.



(a)

Gambar 4.34 Plot (a) Prediksi & (b) ACF & PACF Residual Model $CH_{1,t}$ dengan PrediktorLag dari Model ARIMA(1,0,0)(5,1,0)³⁶⁵, Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

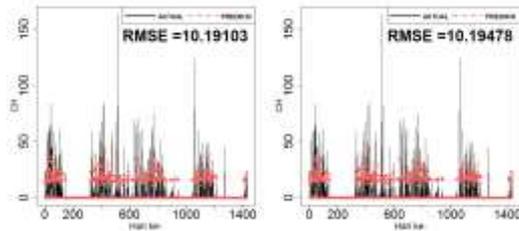


(b)

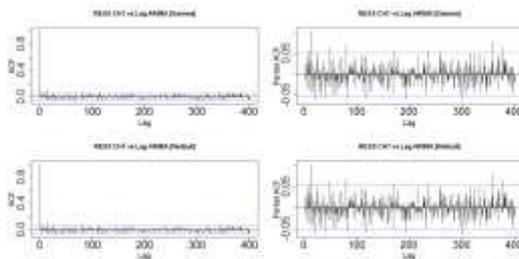
Gambar 4.34 Plot (a) Prediksi & (b) ACF & PACF Residual Model $CH_{1,t}$ dengan Prediktor Lag dari Model $ARIMA(1,0,0)(5,1,0)^{365}$, Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Gambar 4.34 menunjukkan bahwa nilai RMSE tidak jauh berbeda dengan pemodelan curah hujan di Balai Keputih dengan menambahkan variabel curah hujan sampai dengan tujuh hari sebelumnya dan empat belas hari sebelumnya (minimal nilai RMSE 11 dan maksimal 14). Tidak hanya itu, jika dilihat berdasarkan ACF & PACF juga tidak menunjukkan pola yang stasioner. Walaupun variabel prediktor unsur iklim di inputkan kembali, nilai RMSE tidak menunjukkan nilai yang semakin membaik.

Maka perlu dilakukan alternatif lain guna mendapatkan pemodelan yang lebih baik. Berdasarkan Rob Hyndman (salah satu guru Time Series di dunia), menyarankan dalam pengolahan data time series yang memiliki banyak observasi nol dapat di NA atau di *convert* menjadi *missing value* (Hyndman & Athanasopoulos, 2018). Berikut hasil prediksi serta ACF dan PACF residual dari pemodelan curah hujan di Balai Keputih terhadap 13 lag atau lag signifikan hasil *differencing* seasonal dengan menjadikan curah hujan di Balai Keputih yang bernilai nol menjadi NA ($CH_{1,t} = 0 \rightarrow CH_{1,t} = NA$).



(a)



(b)

Gambar 4.35 Plot (a) Prediksi & (b) ACF & PACF Residual Model $CH_{1,t}$ dengan Prediktor Lag dari Model $ARIMA(1,0,0)(5,1,0)^{365}$, Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Gambar 4.35 menunjukkan bahwa hasil prediksi dengan menggunakan marginal Gamma dan Weibull tidak jauh berbeda, dengan menghasilkan prediksi dengan RMSE lebih kecil jika dibandingkan dengan pemodelan curah hujan tanpa menjadikan curah hujan sama dengan NA. Jika dilihat berdasarkan ACF nya, maka dapat terlihat lag lebih signifikan jika di bandingkan dengan ACF pada model dengan inputasi lag-lag sebelumnya.

Setelah melakukan berbagai pemodelan terhadap curah hujan di Balai Keputih, maka dapat diketahui bahwa pemodelan lag dengan lag *differencing seasonal* atau lag model $ARIMA(1,0,0)(5,1,0)^{365}$ memberikan hasil yang membaik, jika dilihat berdasarkan nilai RMSE data prediksi terhadap data aktual. Lalu

pemodelan selanjutnya yaitu meingputkan keseluruhan variabel unsur iklim (temperatur udara, kelembaban dan kecepatan angin) di tiga Stasiun BMKG dan variabel hasil analisis PCA secara bergantian. Untuk plot prediksi dapat dilihat pada Lampiran 29-32. Dapat diketahui bahwa dengan memasukkan variabel unsur iklim, dapat diketahui Perak-1 merupakan pemodelan terbaik dengan menggunakan lag-hasil *differencing seasonal*. Namun jika dimodelkan kembali sama dengan menambahkan variabel lag-1 s.d lag-7 satu persatu maka berikut nilai RMSE minimum dari berbagai pemodelan terhadap curah hujan di balai Keputih yang telah dilakukan.

Tabel 4.23 RMSE Terkecil pada Pemodelan $CH_{1,t}$

Marginal	$CH_{1,t-d}$	Juanda	Perak-2	Perak-1	PCA
Gamma	9,40711	9,30232	9,29053	9,24082	*9,25969
Weibull	9,43803	9,34574	9,33136	9,28069	*9,29814

* *RMSE terkecil*

Tabel 2.3 menunjukkan bahwa nilai RMSE terkecil tersebut masing-masing diperoleh dari pemodelan curah hujan di Balai Keputih dengan variabel input yang ditambahkan dengan variabel prediktor $CH_{1,t-1}$ sampai dengan $CH_{1,t-6}$ baik itu pada saat menggunakan marginal Gamma ataupun marginal Weibull. Jika dilihat nilai minimum pada Tabel 4.23, dapat diketahui bahwa pemodelan terbaik yang diperoleh yaitu dengan memodelkan curah hujan di Balai Keputih terhadap unsur iklim di Stasiun Perak 1 ditambahkan variabel $CH_{1,t-1}$ sampai dengan $CH_{1,t-6}$. Untuk pemodelan data *train* terbaik saat memodelkan curah hujan di Balai Keputih dapat dituliskan sebagai berikut.

$$CH_{1,t} = (\beta_0 + \beta_1 T_{3,t} + \beta_2 RH_{3,t} + \beta_3 ff_{3,t} + \beta_4 CH_{1,t-1} + \beta_5 CH_{1,t-2} + \beta_6 CH_{1,t-3} + \beta_7 CH_{1,t-4} + \beta_8 CH_{1,t-5} + \beta_9 CH_{1,t-6})^2$$

4.4.2 Kedung Cowek

Sama halnya dengan analisis yang telah dilakukan pada curah hujan di Balai Keputih, pada saat memodelkan curah hujan di Balai Kedung Cowek dengan berbagai variabel input tanpa menjadikan respon 0 menjadi NA maka di dapatkan nilai RMSE paling minimum diperoleh pada saat variabel input yang digunakan adalah unsur iklim di Stasiun Perak 2 dengan ditambahkan variabel *dummy*, yaitu dengan nilai RMSE 10.95. Namun, pada saat memodelkan curah hujan di Balai Kedung Cowek dengan menjadikan respon yang sama dengan nol menjadi NA ($CH_{2,t} = 0 \rightarrow CH_{2,t} = NA$) terhadap variabel prediktor dengan input yang berbeda, maka nilai RMSE minimum yang diperoleh dapat dilihat pada Tabel 4.24 berikut. Untuk plot prediksi pada pemodelan curah hujan di Balai Kedung Cowek dapat dilihat pada Lampiran 33-36.

Tabel 4.24 RMSE Terkecil pada Pemodelan $CH_{2,t}$

Marginal	$CH_{2,t,d}$	Juanda	Perak-2	Perak-1	PCA
Gamma	7,95767	7,84329	7,81238	7,79053	*7,78327
Weibull	8,01228	7,90627	7,88602	7,86306	*7,85353

* RMSE terkecil

Tabel 4.24 menunjukkan bahwa nilai RMSE terkecil tersebut masing-masing diperoleh dari pemodelan terhadap curah hujan di Balai Kedung Cowek dengan variabel input merupakan model dengan menambahkan variabel *lag-differencing seasonal*. Serta dari Tabel 4.24 menunjukkan bahwa dengan input variabel hasil PCA menjadikan nilai RMSE paling kecil dari keseluruhan model, baik itu menggunakan marginal Gamma ataupun marginal Weibull. Untuk pemodelan data *tarin* terbaik saat memodelkan curah hujan di Balai Kedung Cowek sebagai berikut.

$$CH_{2,t} = \{\beta_0 + \beta_1(PC1_T) + \beta_2(PC1_{RH}) + \beta_3(PC1_{ff}) + \beta_4(PC2_{ff}) + \gamma \cdot (\text{lag model ARIMA}(1,0,0)(5,1,0))\}^2$$

4.4.3 Gubeng

Untuk melakukan pemodelan curah hujan di Balai Gubeng juga menggunakan langkah analisis yang sama dengan balai sebelumnya. Dapat diketahui bahwa model yang terbaik pada saat memodelkan curah hujan di Balai Gubeng tanpa menjadikan NA adalah dengan menggunakan prediktor di Stasiun Perak 1 ditambah variabel *dummy*-nya, dengan nilai RMSE 12,93. Namun nilai RMSE dapat dikatakan cukup tinggi dan prediksi belum mengikuti nilai aktualnya. Maka dari itu, berikut nilai RMSE minimum jika curah hujan di Balai Gubeng dimodelkan dengan variabel prediktornya dengan $CH_{3,t} = 0 \rightarrow CH_{3,t} = NA$. Untuk plot prediksi pada pemodelan curah hujan di Balai Gubeng dapat dilihat pada Lampiran 37-40.

Tabel 4.25 RMSE Terkecil pada Pemodelan $CH_{3,t}$

Marginal	Lag	Juanda	Perak-2	Perak-1	PCA
Gamma	9,36797	9,23218	9,23504	9,19129	*9,18283
Weibull	9,43514	9,30395	9,31561	9,26894	*9,25141

*RMSE terkecil

Tabel 4.25 menunjukkan bahwa nilai RMSE terkecil tersebut masing-masing diperoleh dari pemodelan curah hujan di Balai Gubeng dengan prediktor yang ditambahkan dengan variabel lag *diffrencing seasonal*. Sama halnya pada saat memodelkan curah hujan di balai Kedung Cowek, bahwa input yang terbaik yaitu dengan menggunakan variabel yang telah melalui tahap PCA. Hal ini diduga karena letak balai yang saling berdekatan atau masih dalam satu Rayon Keputih. Untuk pemodelan data *tarin* terbaik saat memodelkan curah hujan di Balai Gubeng dapat dituliskan sebagai berikut.

$$CH_{3,t} = \{\beta_0 + \beta_1(PC1_T) + \beta_2(PC1_{RH}) + \beta_3(PC1_{ff}) + \beta_4(PC2_{ff}) + \gamma \cdot (\text{lag model ARIMA}(1,0,0)(5,1,0))\}^2$$

4.4.4 Wonorejo

Pemodelan curah hujan di Balai Wonorejo memberikan hasil yang terbaik pada saat memodelkan curah hujan dengan variabel prediktor stasiun Perak 1 yang ditambahkan variabel *dummy* pada saat data respon sama dengan nol tidak di convert ke NA, yaitu dengan nilai RMSE 12,91. Namun Jika dilakukan pemodelan dengan $CH_{4,t} = 0 \rightarrow CH_{4,t} = NA$ maka dapat diketahui nilai RMSE terkecil pada Tabel 4.26. Untuk plot prediksi pada pemodelan curah hujan di Balai Wonorejo dapat dilihat pada Lampiran 41-44.

Tabel 4.26 RMSE Terkecil pada Pemodelan $CH_{4,t}$

Marginal	$CH_{4,t-d}$	Juanda	Perak-2	Perak-1	PCA
Gamma	9,89376	9,79372	9,76394	9,75997	*9,74914
Weibull	9,92105	9,83104	9,79968	9,79824	*9,78582

*RMSE terkecil

Beda halnya dengan pemodelan curah hujan di balai sebelumnya, jika dilihat dari nilai RMSE terkecil dapat diketahui bahwa pada saat memodelkan curah hujan dengan lag-nya dan curah hujan dengan variabel prediktor Juanda, maka dapat diketahui bahwa nilai RMSE terkecil terjadi pada saat model ditambahkan variabel $CH_{4,t-1}$ & $CH_{4,t-2}$. Namun pada pemodelan dengan menggunakan prediktor di Stasiun Perak2, Perak1 dan melalui proses PCA dapat diketahui nilai RMSE terkecil diperoleh pada saat setiap prediktor ditambahkan dengan variabel $CH_{4,t-1}$, $CH_{4,t-2}$ & $CH_{4,t-3}$. Sehingga secara keseluruhan model terbaik saat memodelkan curah hujan di Balai Wonorejo yaitu pada saat variabel prediktor telah melalui proses PCA dan ditambah variabel lag sampai dengan $CH_{4,t-3}$. Untuk pemodelan data *train* terbaik sebagai berikut.

$$CH_{4,t} = (\beta_0 + \beta_1(PC1_T) + \beta_2(PC1_{RH}) + \beta_3(PC1_{ff}) + \beta_4(PC2_{ff}) + \beta_5 CH_{4,t-1} + \beta_6 CH_{4,t-2} + \beta_7 CH_{4,t-3})^2$$

4.4.5 Wonokromo

Pemodelan curah hujan di Balai Wonokromo memberikan hasil yang terbaik pada saat memodelkan curah hujan dengan variabel prediktor stasiun Perak 1 pada saat data respon sama dengan nol tidak di convert ke NA, yaitu dengan nilai RMSE 13,37. Namun Jika dilakukan pemodelan dengan $CH_{5,t} = 0 \rightarrow CH_{5,t} = NA$ maka dapat diketahui nilai RMSE terkecil pada Tabel 4.26 berikut. Untuk plot prediksi pada pemodelan curah hujan di Balai Wonokromo dapat dilihat pada Lampiran 45-48.

Tabel 4.27 RMSE Terkecil pada Pemodelan $CH_{5,t}$

Marginal	$CH_{5,t-d}$	Juanda	Perak-2	Perak-1	PCA
Gamma	10,03674	9,89344	9,89389	9,86761	*9,85561
Weibull	10,10478	9,95828	9,98629	9,94253	*9,92777

* RMSE terkecil

Jika dilihat nilai RMSE pada Tabel 4.27 dapat diketahui bahwa nilai RMSE terkecil yang diperoleh yaitu sama halnya dengan pemodelan curah hujan di Balai Kedung Cowek & Gubeng, dimana model terbaik yang diperoleh yaitu dengan menginputkan variabel yang telah melalui proses PCA dan ditambahkan 13 variabel lag hasil *differencing seasonal* atau lag ARIMA(1,0,0)(5,1,0)³⁶⁵.

Berdasarkan tabel RMSE minimum yang diperoleh sampai dengan curah hujan Balai Wonokromo, menunjukkan dengan menggunakan marginal curah hujan Gamma ataupun Weibull, model menggunakan marginal Gamma konsisten memberikan RMSE minimum antara data prediksi terhadap data aktual. Untuk pemodelan data *train* terbaik saat memodelkan curah hujan di Balai Wonokromo dapat dituliskan sebagai berikut.

$$CH_{5,t} = \{\beta_0 + \beta_1(PC1_T) + \beta_2(PC1_{RH}) + \beta_3(PC1_{ff}) + \beta_4(PC2_{ff}) + \gamma \cdot (\text{lag model ARIMA}(1,0,0)(5,1,0))\}^2$$

4.4.6 Gunung Sari

Saat memodelkan curah hujan di Balai Gunung Sari dengan beberapa variabel input yang berbeda tanpa menjadikan $CH_{6,t} = 0 \rightarrow CH_{6,t} = NA$ maka diperoleh nilai RMSE terkecil dengan pemodelan yang sama dengan curah hujan di Balai Wonorejo yaitu dengan pemodelan menggunakan variabel input unsur iklim di Stasiun Perak 1, yaitu dengan nilai RMSE 13,18. Sedangkan pada saat pemodelan yang dilakukan pada saat $CH_{6,t} = 0 \rightarrow CH_{6,t} = NA$, kembali memberikan nilai RMSE yang semakin kecil yang dapat dilihat pada Tabel 4.28. Plot prediksi pada pemodelan curah hujan di Balai Gunung Sari dapat dilihat pada Lampiran 49-52.

Tabel 4.28 RMSE Terkecil pada Pemodelan $CH_{6,t}$

Marginal	$CH_{5,t-d}$	Juanda	Perak-2	Perak-1	PCA
Gamma	9,73726	9,37334	9,41068	9,37902	*9,35635
Weibull	9,76165	9,38784	9,43508	9,40607	*9,37689

* RMSE terkecil

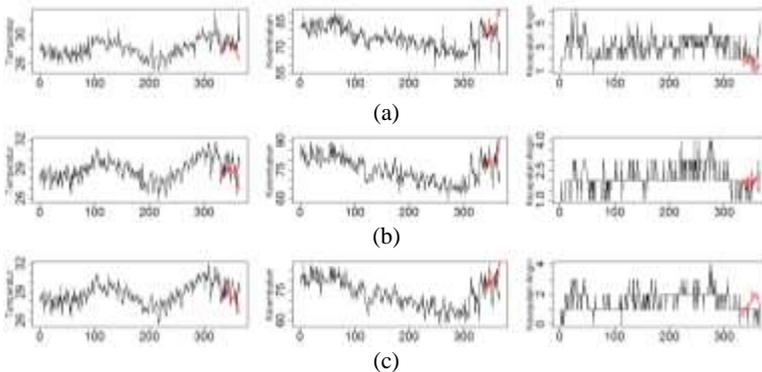
Tabel 4.28 menunjukkan pemodelan terkecil sama halnya dengan pemodelan pada curah hujan di Balai Kedung Cowek, Gubeng dan Wonokromo, yaitu dengan menggunakan variabel input PCA dan 13 lag yang dianggap signifikan dari hasil *differencing* seasonal Untuk pemodelan data *tarin* terbaik saat memodelkan curah hujan di Balai Gunung Sari dapat dituliskan sebagai berikut.

$$CH_{6,t} = (\beta_0 + \beta_1(PC1_T) + \beta_2(PC1_{RH}) + \beta_3(PC1_{ff}) + \beta_4(PC2_{ff}) + \gamma \cdot (\text{lag model ARIMA (1,0,0)(5,1,0)})^2$$

4.5 Prediksi Unsur Iklim (Prediktor)

Sebelum melakukan prediksi curah hujan berdasarkan pemodelan terbaik yang telah didapatkan di enam balai curah hujan di Kota Surabaya, perlu dilakukannya prediksi untuk setiap data prediktor. Untuk melakukan prediksi pada variabel prediktor di tiga Stasiun pengamatan BMKG yaitu dengan menggunakan

metode Holt Winter's. Hal ini dikarenakan ke-3 variabel prediktor di tiga stasiun BMKG memiliki pola yang relatif sama. Sehingga untuk memprediksi 31 hari kedepannya dianggap sudah cukup baik jika menggunakan metode time-series sederhana seperti Holt-Winters. Untuk nilai hasil prediksinya dapat dilihat pada Lampiran. 26. Untuk visualisasi prediksi dari variabel prediktor di setiap stasiun dapat dilihat pada gambar berikut.



Gambar 4.36 Plot Prediksi Variabel Prediktor (Holt Winter's) di (a) Juanda, (b) Perak 2 & (c) Perak 1

Gambar 4.36 menunjukkan pola hasil prediksi di setiap variabel input. *Series* berwarna hitam menunjukkan plot aktual pada 01 Januari s.d 31 Desember 2018, dan *series* berwarna merah merupakan plot nilai prediksi selama 31 hari di Bulan Desember 2018. Setelah mendapatkan nilai prediksi untuk setiap prediktor, maka dapat dilakukan prediksi curah hujan untuk masing-masing balai berdasarkan model terbaik. Variabel input yang digunakan yaitu variabel hasil prediksi variabel prediktor. Perlunya memprediksi data unsur iklim pada data *testing* dikarenakan data yang digunakan merupakan data pengamatan, pada kenyataannya jika ingin memprediksi curah hujan maka variabel unsur iklim juga tidak diketahui sehingga perlu diprediksi terlebih dahulu.

4.6 Prediksi Curah Hujan di Kota Surabaya

Berdasarkan analisis sebelumnya, dapat diketahui bahwa mayoritas model dengan nilai RMSE terkecil di enam balai curah hujan merupakan model dengan menggunakan variabel input unsur iklim ditambahkan dengan lag hasil *differencing seasonal*-nya. Maka dari itu, setiap curah hujan di enam balai akan diprediksi berdasarkan lag hasil *differencing seasonal*-nya. Walaupun, pada kenyataannya terdapat beberapa model curah hujan (curah hujan di Balai Keputih & Wonorejo) tidak memberikan nilai RMSE minimum pada model tersebut. Sehingga dalam melakukan prediksi pada data *testing* akan dilakukan prediksi berdasarkan model dengan nilai RMSE terkecil dan dibandingkan dengan train yang ditambahkan variabel lag hasil *differencing seasonal*-nya. Tidak hanya itu, sebelum melakukan prediksi juga tidak hanya dilihat berdasarkan nilai RMSE terkecil pada model. Melainkan juga dengan mempertimbangkan hasil estimasi parameter yang signifikan pada model.

Sebelum melakukan analisis lebih lanjut, maka dapat diketahui pola curah hujan di Bulan Desember pada sembilan tahun terakhir dapat divisualisasi menggunakan grafik yang dapat dilihat pada Lampiran 53. Plot serta box-plot di setiap balai memiliki sebuah pola curah hujan selama Bulan Desember di sembilan tahun terakhir. Namun, setiap harinya selama 31 hari tersebut minimal pernah mengalami keadaan tidak pernah hujan atau $CH = 0$. Keadaan curah hujan yang tinggi juga tidak selalu terjadi pada hari yang sama setiap tahunnya. Yang membedakan hanyalah, batas minimal jumlah keadaan tidak pernah hujan di 31 hari selama 10 tahun tersebut. Sehingga dalam melakukan prediksi juga mempertimbangkan *trade record* curah hujan yang terjadi pada tahun-tahun sebelumnya.

Dapat diketahui, dari keseluruhan analisis prediksi curah hujan di enam balai PSAWS menunjukkan bahwa dengan menggunakan marginal Gamma selalu memiliki RMSE terkecil jika dibandingkan dengan menggunakan model yang sama dan menggunakan marginal Weibull. Untuk lebih jelasnya, berikut hasil analisis prediksi curah hujan di enam balai PSAWS di Kota Surabaya.

4.6.1 Keputih

Dikarenakan nilai RMSE terkecil yang diperoleh pada curah hujan di Balai Keputih merupakan dengan pemodelan curah hujan dengan variabel input ditambahkan dengan variabel $CH_{1,t-1}$ sampai dengan $CH_{1,t-6}$. Tabel 4.29 menunjukkan RMSE hasil prediksi pada data *testing* dengan menggunakan model terbaik pada data *train* (Model 1) dan model dengan menambahkan variabel lag hasil *differencing seasonal* (Model 2).

Tabel 4.29 RMSE Data Testing $CH_{1,t}$

Model	Juanda	Perak 2	Perak 1	PCA
1	15,37	15,52	14,21	15,59
2	16,00	15,52	14,49	*11,86

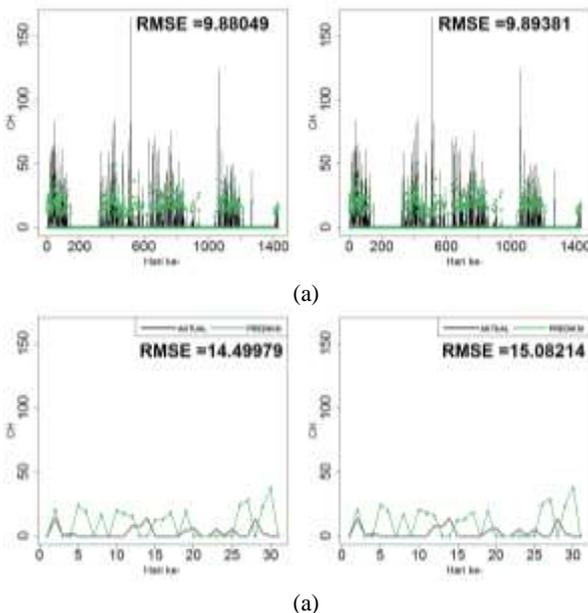
* RMSE terkecil

Berdasarkan tabel 4.29, menunjukkan bahwa dengan memodelkan curah hujan di Balai Keputih memberikan nilai RMSE data *testing* minimum pada saat memodelkan curah hujan dengan variabel input PCA di tambahkan variabel lag hasil *differencing seasonal*. Namun jika dilihat berdasarkan nilai estimasi parameter delapan model, dapat diketahui model dengan input variabel unsur iklim di Perak 1 di tambahkan variabel lag hasil *differencing seasonal* menunjukkan ke-tiga unsur iklim signifikan (Lampiran 54). Maka diperoleh model terbaik dalam memprediksi curah hujan di Balai Keputih yaitu sebagai berikut.

$$CH_{1,t} = \{\beta_0 + \beta_1 T_{3,t} + \beta_2 RH_{3,t} + \beta_3 ff_{3,t} + \gamma(\text{lag model ARIMA}(1,0,0)(5,1,0))\}^2$$

$$CH_{1,t} = \{24,267 - 0,601(T_{3,t}) - 0,035(RH_{3,t}) - 0,326(ff_{3,t}) + 0,021(CH_{1,t-1}) + 0,006(CH_{1,t-365}) - 0,001(CH_{1,t-366}) + 0,001(CH_{1,t-730}) + 0,001(CH_{1,t-731}) + 0,0118(CH_{1,t-1095}) - 0,006(CH_{1,t-1096}) + 0,003(CH_{1,t-1460}) + 0,002(CH_{1,t-1461}) - 0,012(CH_{1,t-1825}) - 0,005(CH_{1,t-1826}) + 0,004(CH_{1,t-2190}) + 0,006(CH_{1,t-2191})\}^2$$

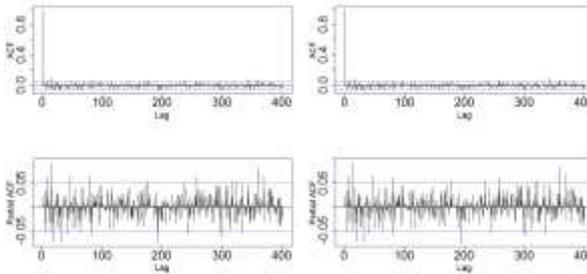
Berikut plot prediksi pada data *training* dan *testing* untuk curah hujan di Balai Keputih.



Gambar 4.37 Plot Prediksi $CH_{1,t}$ Data (a) *Training* dan (b) *Testing*, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Dikarenakan peran copula pada pemodelan GCMR berperan dalam menjadikan error atau residual dari model menjadi saling independen, maka dapat dilihat berdasarkan plot ACF dan PACF dari model terpilih pada Gambar 4.38. Berdasarkan Gambar 4.38 menunjukkan bahwa model telah stasioner dalam rata-rata (saling independen). Walaupun jika

dilihat pada plot PACF masih terdapat beberapa lag yang berada di luar batas.



Gambar 4.38 ACF & PACF Error pada Pemodelan $CH_{1,t}$, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Maka diperoleh hasil prediksi curah hujan di Balai Keputih pada bulan Desember 2018 yang dapat dilihat pada Tabel 4.30.

Tabel 4.30 Hasil Prediksi $CH_{1,t}$

Tgl	Hasil Prediksi	Tgl	Hasil Prediksi
1	0,000	17	18,096
2	20,074	18	0,000
3	0,000	19	19,018
4	0,000	20	0,000
5	23,612	21	0,000
6	19,179	22	0,000
7	0,000	23	0,000
8	16,316	24	0,000
9	0,000	25	0,000
10	19,838	26	23,940
11	17,438	27	27,823
12	15,364	28	0,000
13	0,000	29	22,898
14	0,000	30	37,169
15	12,218	31	0,000
16	12,852		

**bold = hujan maks*

Curah hujan maksimum di Balai Keputih akan digunakan sebagai salah satu indikator dalam memprediksi banjir di beberapa saluran di Rayon Gubeng.

4.6.2 Kedung Cowek

Jika dilihat berdasarkan estimasi parameter pada model dengan RMSE terkecil, tidak ada satupun parameter pada variabel prediktor yang signifikan. Maka dari itu dilakukan perbandingan RMSE data *testing* minimum (Tabel 4.31), dengan menggunakan model dengan RMSE minimum pada data *train*.

Tabel 4.31 RMSE Data Testing CH_{2,t}

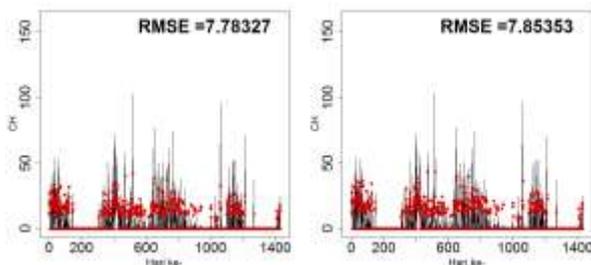
Juanda	Perak 2	Perak 1	PCA
10,38	10,64	10,51	*10,27

* RMSE terkecil

Maka dapat diketahui model terbaik yaitu pada saat menggunakan model dengan variabel input hasil analisis PCA yang ditambahkan dengan variabel lag hasil *differencing seasonalnya*, pemodelan pada curah hujan di Balai Kedung Cowek sebagai berikut.

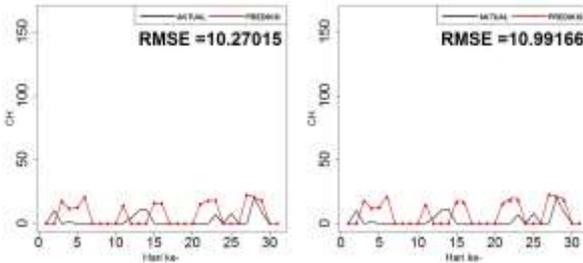
$$\begin{aligned} CH_{2,t} = & \{\beta_0 + \beta_1(PC1_T) + \beta_2(PC1_{RH}) + \beta_3(PC1_{ff}) + \beta_4(PC2_{ff}) + \gamma(\text{lag model ARIMA}(1,0,0)(5,1,0))\}^2 \\ CH_{2,t} = & \{3,588 - 0,101(PC1_T) - 0,028(PC1_{RH}) + 0,100(PC1_{ff}) + 0,072(PC2_{ff}) + 0,025(CH_{2,t-1}) + \\ & 0,014(CH_{2,t-365}) - 0,006(CH_{2,t-366}) + 0,001(CH_{2,t-730}) - 0,014(CH_{2,t-731}) + \\ & 0,006(CH_{2,t-1095}) - 0,008(CH_{2,t-1096}) + 0,009(CH_{2,t-1460}) + 0,016(CH_{2,t-1461}) - \\ & 0,009(CH_{2,t-1825}) - 0,012(CH_{2,t-1826}) + 4 \cdot 10^{-4}(CH_{2,t-2190}) + 0,008(CH_{2,t-2191})\}^2 \end{aligned}$$

Berikut plot prediksi pada data *training* dan *testing* untuk curah hujan di Balai Kedung Cowek.



(a)

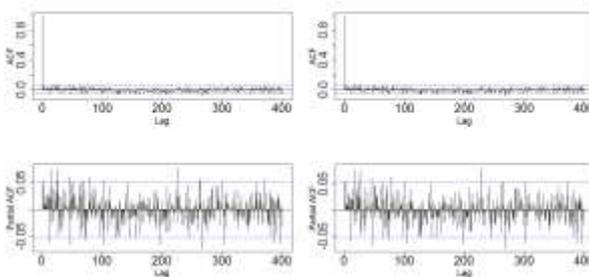
Gambar 4.39 Plot Prediksi CH_{2,t} Data (a) *Training* dan (b) *Testing*, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)



(b)

Gambar 4.39 Plot Prediksi $CH_{2,t}$ Data (a) *Training* dan (b) *Testing*, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Sama halnya dengan prediksi curah hujan di Balai Keputih, peran copula pada pemodelan GCMR berperan dalam menjadikan error atau residual dari model menjadi saling independen, maka dapat dilihat berdasarkan plot ACF dan PACF dari model terpilih pada Gambar 4.40. Berdasarkan Gambar 4.40 menunjukkan bahwa model telah stasioner dalam rata-rata (saling independen). Walaupun jika dilihat pada plot PACF masih terdapat beberapa lag yang berada di luar batas.



Gambar 4.40 ACF & PACF Error pada Pemodelan $CH_{2,t}$, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Sehingga dapat dikatakan model sudah cukup baik dalam memprediksi curah hujan di Balai Kedung Cowek. Untuk hasil

prediksi curah hujan di balai Kedung Cowek untuk 31 hari pada bulan Desember 2018, dapat disajikan pada Tabel 4.32 berikut.

Tabel 4.32 Hasil Prediksi $CH_{2,t}$

Tgl	Hasil Prediksi	Tgl	Hasil Prediksi
1	0,000	17	0,000
2	0,000	18	0,000
3	17,220	19	0,000
4	11,396	20	0,000
5	11,934	21	15,050
6	20,472	22	17,661
7	0,000	23	17,823
8	0,000	24	0,000
9	0,000	25	0,000
10	0,000	26	0,000
11	13,841	27	22,186
12	0,000	28	20,435
13	0,000	29	17,513
14	0,000	30	0,000
15	15,874	31	0,000
16	15,440	* bold = CH maks	

Curah hujan maksimum di Balai Kedung Cowek akan digunakan sebagai salah satu indikator dalam memprediksi banjir di beberapa saluran di Rayon Gubeng.

4.6.3 Gubeng

Jika dilihat berdasarkan estimasi parameter pada model dengan RMSE terkecil, tidak ada satupun parameter pada variabel input yang signifikan. Maka dari itu dilakukan perbandingan RMSE data *testing* minimum (Tabel 4.33), dengan menggunakan model dengan RMSE minimum pada data *train*.

Tabel 4.33 RMSE Data *Testing* $CH_{3,t}$

Juanda	Perak 2	Perak 1	PCA
15,51	16,32	15,73	*14,01

*RMSE terkecil

Maka dapat diketahui model terbaik yaitu pada saat menggunakan model dengan variabel input hasil PCA yang ditambahkan dengan variabel lag hasil *differencing seasonalnya*, yang dapat dimodelkan sebagai berikut.

$$CH_{3,t} = \{\beta_0 + \beta_1(PC1_T) + \beta_2(PC1_{RH}) + \beta_3(PC1_{ff}) + \beta_4(PC2_{ff}) + \gamma(\text{lag model ARIMA}(1,0,0)(5,1,0))\}^2$$

$$CH_{3,t} = \{3,810 - 0,206(PC1_T) - 5,6.10^{-4}(PC1_{RH}) + 0,028(PC1_{ff}) + 0,209(PC2_{ff}) +$$

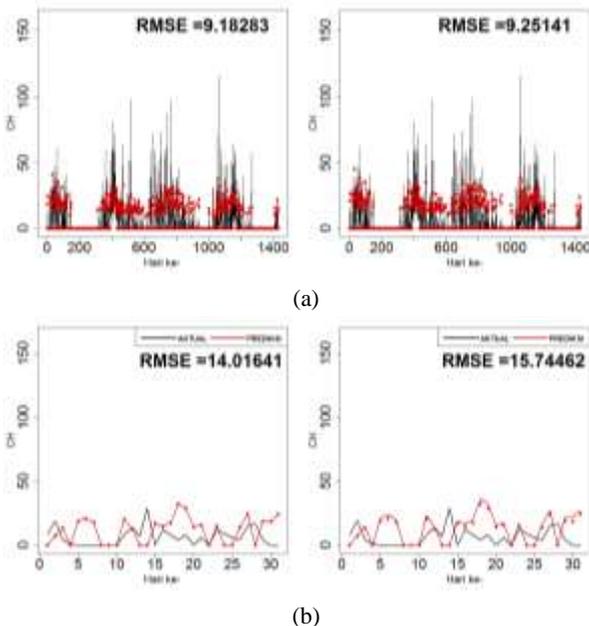
$$0,009(CH_{3,t-1}) - 7,5.10^{-4}(CH_{3,t-365}) + 0,009(CH_{3,t-366}) - 0,005(CH_{3,t-730}) -$$

$$0,003(CH_{3,t-731}) + 0,004(CH_{3,t-1095}) + 0,002(CH_{3,t-1096}) + 0,005(CH_{3,t-1460}) +$$

$$0,012(CH_{3,t-1461}) - 0,002(CH_{3,t-1825}) - 0,005(CH_{3,t-1826}) - 0,006(CH_{3,t-2190}) +$$

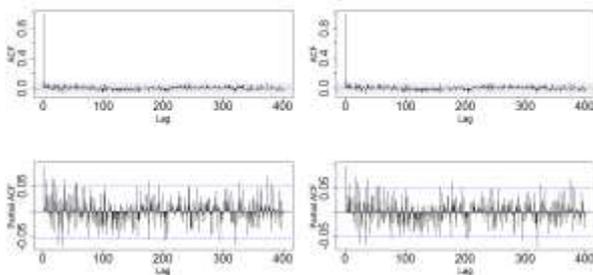
$$0,010(CH_{3,t-2191})\}^2$$

Berikut plot prediksi pada data *training* dan *testing* untuk curah hujan di Balai Gubeng.



Gambar 4.41 Plot Prediksi $CH_{2,t}$ Data (a) *Training* dan (b) *Testing*, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Gambar 4.42 menunjukkan plot ACF dan PACF dari residual pada model terpilih curah hujan di Balai Gubeng. Dapat diketahui bahwa model telah stasioner dalam rata-rata (saling independen). Walaupun jika dilihat pada plot PACF masih terdapat beberapa lag yang berada di luar batas. Namun jika dilihat plot ACF dan PACF tidak jauh berbeda dengan plot ACF dan PACF pada pemodelan curah hujan di Balai Keputih dan juga Kedung Cowek.



Gambar 4.42 ACF & PACF Error pada Pemodelan $CH_{3,t}$ dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Didapatkan hasil prediksi curah hujan di Balai Gubeng untuk bulan Desember 2018.

Tabel 4.34 Hasil Prediksi $CH_{3,t}$

Tgl	Hasil Prediksi	Tgl	Hasil Prediksi
1	0,000	17	17,287
2	7,234	18	32,192
3	13,654	19	28,811
4	0,000	20	14,061
5	18,651	21	15,640
6	20,688	22	0,000
7	17,936	23	14,786
8	0,000	24	0,000
9	0,000	25	0,000
10	0,000	26	13,846
11	20,506	27	24,465
12	12.829	28	0.000
13	0.000	29	18.795

Tabel 4.34 Hasil Prediksi CH_{3,t} [lanjutan]

Tgl	Hasil Prediksi	Tgl	Hasil Prediksi
14	0.000	30	18.534
15	16.946	31	24.221
16	14.601	*bold = CH maks	

Curah hujan maksimum tersebut digunakan sebagai salah satu indikator prediksi banjir di beberapa saluran di Rayon Gubeng.

4.6.4 Wonorejo

Jika dilihat berdasarkan estimasi parameter pada model dengan RMSE terkecil, tidak ada satupun parameter pada variabel prediktor yang signifikan. Maka dari itu dilakukan perbandingan RMSE data *testing* minimum. Tabel 4.35 menunjukkan RMSE hasil prediksi pada data *testing* dengan menggunakan model terbaik pada data *train* (Model 1) dan model dengan menambahkan variabel lag hasil *differencing seasonal* (Model 2).

Tabel 4.35 RMSE Data *Testing* CH_{4,t}

Model	Juanda	Perak-2	Perak-1	PCA
1	16.74	15.99	16.48	19.64
2	15.03	15.52	14.50	*13.97

* RMSE terkecil

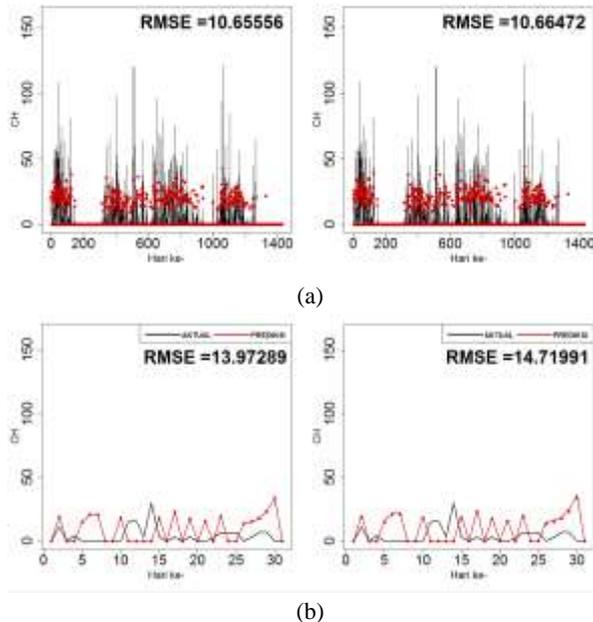
Maka dapat diketahui model terbaik yaitu pada saat model dengan variabel input merupakan variabel hasil analisis PCA yang ditambahkan dengan variabel 13 lag hasil *differencing seasonalnya*, yang didapatkan model sebagai berikut

$$CH_{4,t} = \{\beta_0 + \beta_1(PC1_T) + \beta_2(PC1_{RH}) + \beta_3(PC1_{ff}) + \beta_4(PC2_{ff}) + \gamma(\text{lag model ARIMA}(1,0,0)(5,1,0))\}^2$$

$$CH_{4,t} = \{4,227 - 0,279(PC1_T) + 0,009(PC1_{RH}) + 0,120(PC1_{ff}) + 0,083(PC2_{ff}) + 0,016(CH_{4,t-1}) + 0,008(CH_{4,t-365}) - 0,009(CH_{4,t-366}) + 0,005(CH_{4,t-730}) - 0,005(CH_{4,t-731}) - 7,6 \cdot 10^{-4}(CH_{4,t-1095}) - 0,002(CH_{4,t-1096}) + 0,005(CH_{4,t-1460}) + 0,001(CH_{4,t-1461}) - 0,013(CH_{4,t-1825}) - 0,002(CH_{4,t-1826}) - 2,6 \cdot 10^{-4}(CH_{4,t-2190}) - 0,006(CH_{4,t-2191})\}^2$$

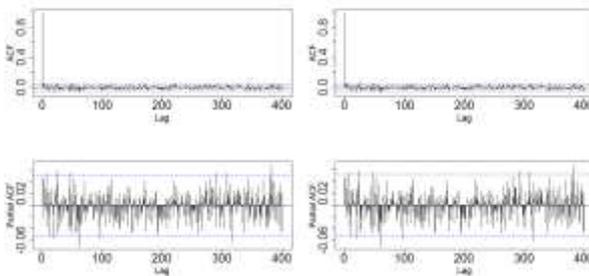
Berikut plot prediksi pada data *training* dan *testing* untuk curah

hujan di balai Wonorejo yang dapat dilihat pada Gambar 4.43. Plot prediksi pada Gambar 4.43 terlihat tidak jauh berbeda jika dibandingkan dengan balai curah hujan lainnya, yaitu nilai prediksi terlihat konstan pada data *train*.



Gambar 4.43 Plot Prediksi $CH_{4,t}$ Data (a) *Training* dan (b) *Testing*, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Prediksi yang dihasilkan pada data *testing* melihat *trade record* curah hujan di Bulan Desember pada sembilan tahun yang lalu. Jika terdapat curah hujan lebih dari sama dengan lima kali dalam sembilan tahun, maka curah hujan di prediksi berdasarkan model yang telah diperoleh dan begitu sebaliknya. Gambar 4.42 menunjukkan plot ACF dan PACF dari residual pada model terpilih curah hujan di Balai Wonorejo. Dapat diketahui bahwa model telah stasioner dalam rata-rata (saling independen).



Gambar 4.44 ACF & PACF Error pada Pemodelan $CH_{4,t}$, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Didapatkan hasil prediksi curah hujan di Balai Wonorejo untuk bulan Desember 2018. Yang disajikan pada Tabel 4.36.

Tabel 4.36 Hasil Prediksi $CH_{4,t}$

Tgl	Hasil Prediksi	Tgl	Hasil Prediksi
1	0.000	17	22.797
2	18.634	18	0.000
3	0.000	19	17.479
4	0.000	20	0.000
5	14.728	21	15.694
6	20.924	22	0.000
7	20.889	23	19.393
8	0.000	24	0.000
9	0.000	25	0.000
10	18.072	26	13.460
11	0.000	27	15.183
12	0.000	28	17.552
13	0.000	29	23.276
14	0.000	30	33.866
15	18.071	31	0.000
16	0.000		*bold = CH maks

Curah hujan maksimum di Balai Wonorejo akan digunakan sebagai salah satu indikator dalam memprediksi banjir pada saluran yang berada di Rayon Genteng.

4.6.5 Wonokromo

Setelah dilakukan perbandingan RMSE data *testing* minimum dengan menggunakan model dengan RMSE minimum pada data *testing*. Maka diperoleh nilai RMSE terkecil pada data *testing* yang dapat dilihat pada Tabel 4.37.

Tabel 4.37 RMSE Data *Testing* CH_{5,t}

Juanda	Perak 2	Perak 1	PCA
17,48	18,22	17,49	*16,36

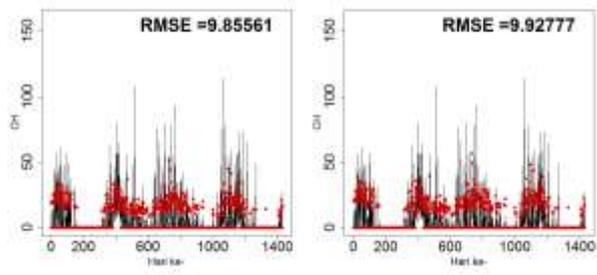
* RMSE terkecil

Sama halnya dengan model terpilih untuk meprediksi curah hujan di Balai Kedung Cowek, Gubeng dan Wonorejo, dapat diketahui model terbaik untuk memprediksi yaitu dengan menggunakan variabel input hasil PCA, yang didapatkan model sebagai berikut.

$$CH_{5,t} = \{\beta_0 + \beta_1(PC1_T) + \beta_2(PC1_{RH}) + \beta_3(PC1_{ff}) + \beta_4(PC2_{ff}) + \gamma(\text{lag model ARIMA}(1,0,0)(5,1,0))\}^2$$

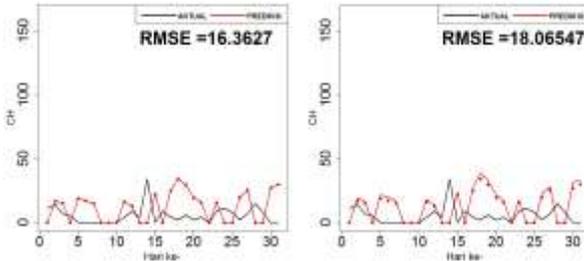
$$CH_{5,t} = \{3,539 - 0,180(PC1_T) - 0,010(PC1_{RH}) - 0,001(PC1_{ff}) + 0,146(PC2_{ff}) + 0,007(CH_{5,t-1}) - 4,5 \cdot 10^{-5}(CH_{5,t-365}) + 0,006(CH_{5,t-366}) + 0,004(CH_{5,t-730}) - 9,10^{-6}(CH_{5,t-731}) - 0,006(CH_{5,t-1095}) - 0,009(CH_{5,t-1096}) + 0,005(CH_{5,t-1460}) + 0,007(CH_{5,t-1461}) + 0,008(CH_{5,t-1825}) + 0,009(CH_{5,t-1826}) - 0,008(CH_{5,t-2190}) - 0,009(CH_{5,t-2191})\}^2$$

Berikut plot prediksi pada data *training* dan *testing* untuk curah hujan di Balai Wonorejo.



(a)

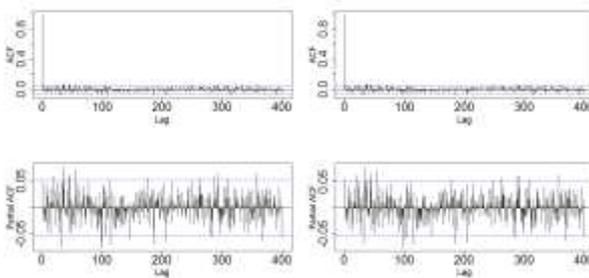
Gambar 4.45 Plot Prediksi CH_{5,t} Data (a) *Training* dan (b) *Testing*, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)



(b)

Gambar 4.45 Plot Prediksi $CH_{5,t}$ Data (a) *Training* dan (b) *Testing*, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan) [lanjutan]

Plot prediksi pada data *train* dan *testing* tidak jauh berbeda dengan plot prediksi pada data curah hujan pada balai sebelumnya yang telah dianalisis. Gambar 4.46 menunjukkan plot ACF dan PACF dari residual pada model terpilih curah hujan di Balai Wonokromo.



Gambar 4.46 ACF & PACF Error pada Pemodelan $CH_{5,t}$, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Didapatkan hasil prediksi curah hujan di Balai Wonokromo untuk bulan Desember 2018. Data hasil prediksi tersebut disajikan pada Tabel 4.38. Curah hujan maksimum di Balai Wonorejo, merupakan salah satu indikator untuk memprediksi banjir di Rayon Jambangan.

Tabel 4.38 Hasil Prediksi CH_{5,t}

Tgl	Hasil Prediksi	Tgl	Hasil Prediksi
1	0.000	17	27.581
2	18.905	18	38.447
3	16.689	19	32.956
4	0.000	20	21.393
5	21.669	21	17.503
6	20.004	22	0.000
7	16.486	23	17.653
8	0.000	24	0.000
9	0.000	25	0.000
10	0.000	26	22.701
11	18.082	27	28.176
12	14.000	28	0.000
13	0.000	29	0.000
14	0.000	30	31.114
15	23.777	31	33.262
16	0.000		

***bold** = hujan maks

4.6.6 Gunung Sari

Setelah dilakukan perbandingan RMSE data *testing* minimum dengan menggunakan model dengan RMSE minimum pada data testing.

Tabel 4.39 RMSE Data *Testing* CH_{6,t}

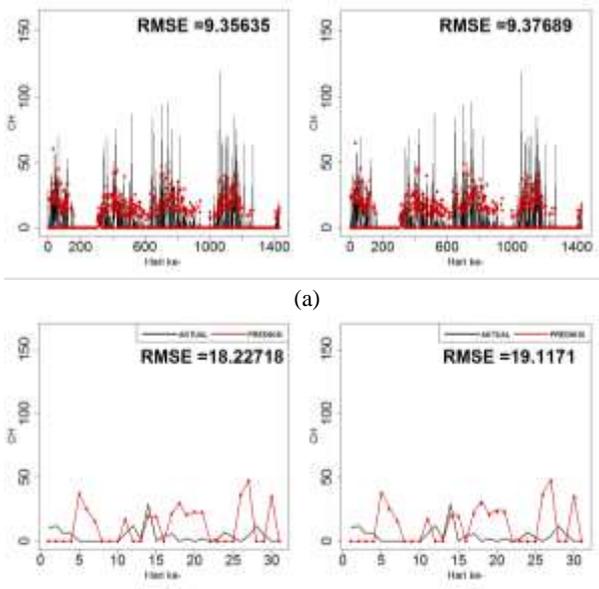
Juanda	Perak 2	Perak 1	PCA
19,74	18,25	19,62	*18,22

* RMSE terkecil

Maka dapat diketahui model terbaik yaitu sama halnya dengan model terbaik untuk prediksi curah hujan di Balai Kedung Cowek, Gubeng, Wonorejo dan Wonokromi.

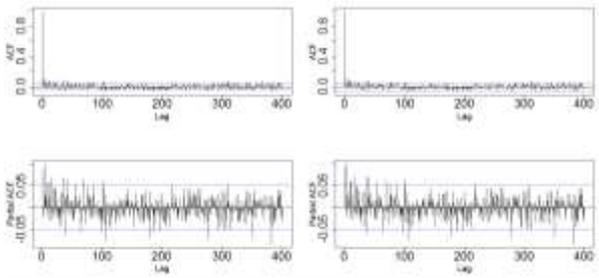
$$\begin{aligned}
 CH_{6,t} &= \{\beta_0 + \beta_1(PC1_T) + \beta_2(PC1_{RH}) + \beta_3(PC1_{ff}) + \beta_4(PC2_{ff}) + \gamma(\text{lag model ARIMA}(1,0,0)(5,1,0))\}^2 \\
 CH_{6,t} &= \{3,427 - 0,313(PC1_T) + 0,007(PC1_{RH}) - 0,123(PC1_{ff}) + 0,046(PC2_{ff}) + \\
 &\quad 0,017(CH_{6,t-1}) + 1,3 \cdot 10^{-5}(CH_{6,t-365}) - 0,002(CH_{6,t-366}) + 0,003(CH_{6,t-730}) + \\
 &\quad 0,001(CH_{6,t-731}) + 0,006(CH_{6,t-1095}) + 0,003(CH_{6,t-1096}) + 0,013(CH_{6,t-1460}) + \\
 &\quad 0,006(CH_{6,t-1461}) + 0,007(CH_{6,t-1825}) - 0,004(CH_{6,t-1826}) + 0,005(CH_{6,t-2190}) - \\
 &\quad 0,019(CH_{6,t-2191})\}^2
 \end{aligned}$$

Berikut plot prediksi pada data *training* dan *testing* untuk curah hujan di balai Gunung sari (Gambar 4.47).



Gambar 4.47 Plot Prediksi $CH_{6,t}$ Data (a) *Training* dan (b) *Testing*, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Gambar 4.48 menunjukkan plot ACF dan PACF dari residual pada model terpilih curah hujan di Balai Gunung Sari.



Gambar 4.48 ACF & PACF Error pada Pemodelan $CH_{6,t}$, dengan Distribusi Marginal CH adalah Gamma (kiri), Weibull (kanan)

Didapatkan hasil prediksi curah hujan di Balai Gunung Sari untuk bulan Desember 2018. Data hasil prediksi tersebut disajikan pada Tabel 4.40. Curah hujan maksimum di Balai Gunung Sari, merupakan salah satu indikator untuk memprediksi banjir di Rayon Wiyung.

Tabel 4.40 Hasil Prediksi $CH_{6,t}$

Tgl	Hasil Prediksi	Tgl	Hasil Prediksi
1	0.000	17	21.437
2	0.000	18	29.396
3	0.000	19	20.499
4	0.000	20	22.884
5	37.232	21	22.663
6	24.838	22	0.000
7	15.683	23	0.000
8	0.000	24	0.000
9	0.000	25	0.000
10	0.000	26	36.145
11	16.671	27	47.326
12	0.000	28	0.000
13	0.000	29	0.000
14	19.558	30	34.593
15	18.977	31	0.000
16	0.000	*bold = hujan maks	

4.7 Prediksi Banjir di Kota Surabaya

Berdasarkan perhitungan matematis rasional, pada keadaan Q -Hidrolika lebih besar dari Q -Hidrologi, maka diprediksi tidak berpotensi banjir. Hidrolika dan hidrologi akan dilihat berdasarkan setiap saluran di setiap rayon. Dapat diketahui bahwa berdasarkan PU Binamarga & Pematusan Kota Surabaya dibagi dalam lima rayon dalam pengevaluasian saluran di Kota Surabaya. Ke-lima rayon dapat dilihat berdasarkan Gambar 2.4.

Setiap rayon memiliki saluran sungai (primer maupun skunder) yang memiliki nilai hidrolika masing-masing. Curah

hujan di enam balai PSAWS diduga akan berpengaruh terhadap Q -hidrologi setiap saluran di Kota Surabaya. Dikarenakan letak balai curah hujan tidak berada di setiap rayon, maka dari itu perlu dilakukan sinkronisasi antara saluran di setiap rayon berdasarkan letak balai curah hujan. Sehingga dapat diketahui bahwa saluran di setiap rayon akan menggunakan curah hujan sesuai lokasi balai (dapat dilihat berdasarkan kecamatan yang sesuai). Sinkronisasi antara lokasi balai PSAWS Kota Surabaya terhadap lima rayon pengamatan banjir di Kota Surabaya dapat dilihat pada Tabel. 4.41.

Tabel 4.41 Sinkronisasi 6 Balai CH terhadap 5 Rayon

No	Rayon	Balai	Jumlah Saluran
1	Gubeng	Keputih Ked. Cowek Gubeng	47
2	Genteng	Wonorejo	37
3	Jambangan	Wonokromo	31
4	Wiyung	Gunung Sari	18
5	Tandes	-	37

Tabel menunjukkan bahwa terdapat 4 dari 5 rayon yang diamati pada penelitian kali ini. Hal ini dikarenakan rayon tandes tidak dapat dijelaskan berdasarkan enam balai curah hujan yang telah dianalisis sebelumnya. Sehingga pada penelitian ini, prediksi banjir dilihat berdasarkan 133 saluran, sudah termasuk saluran primer dan skunder di Kota Surabaya.

Jadi setiap saluran akan memiliki Q -hidrolika. Q -hidrolika atau debit saluran sangat dipengaruhi oleh luas penampang basah dan kecepatan aliran. Pada penelitian kali ini diasumsikan keseluruhan koefisien kekerasan *manning* disetiap saluran adalah 0,03. Sedangkan untuk kemiringan saluran di asumsikan konstan (2%). Dalam praktik lapangan, nilai S pada umumnya diperoleh dari hasil pengukuran *long-section* dan *cross-section*. Jika Q -

hidrolika < Q -hidrologi, maka dapat dikatakan saluran tersebut akan diprediksi menimbulkan banjir dalam 31 hari ke depan. Untuk perbandingan Q -Hidrolika dan Q -Hidrologinya dapat dilihat pada Lampiran. 56. Keseluruhan nilai yang dihasilkan berdasarkan perhitungan metode rasional sesuai dengan perumusan yang telah di jelaskan pada sub bab 2.9. Untuk dapat mengetahui Q -hidrologi, maka diperlukan curah hujan maksimum.

Berdasarkan hasil prediksi selama 31 hari di Bulan Desember tahun 2018, maka diperoleh nilai maksimum dari setiap balai PSAWS dapat dilihat pada Tabel 4.42.

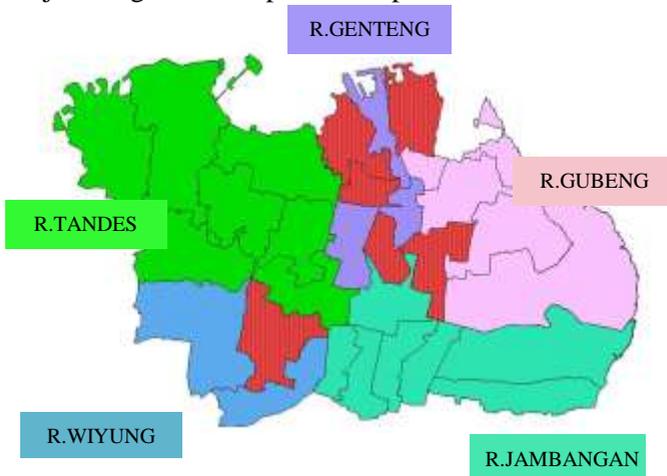
Tabel 4.42 Hasil Prediksi Curah Hujan Maksimum di Setiap Balai

Balai	Prediksi Curah Hujan Maksimum
Keputih	37.16
Kedung Cowek	22.18
Gubeng	24.46
Wonorejo	33.86
Wonokromo	29.98
Gunung Sari	47.00

Berdasarkan hasil prediksi curah hujan maksimum di enam Balai PSAWS Kota Surabaya, maka dapat diketahui Q -hidrologi beserta Q -hidrolika setiap saluran berdasarkan ke-empat rayon dapat dilihat pada Lampiran 46. Menunjukkan terdapat beberapa saluran di lima rayon yang diperkirakan akan menyebabkan permasalahan banjir.

Berdasarkan perbandingan Q -hidrologi dan Q -hidroliki pada Lampir. 46 menunjukkan, dari 47 saluran yang ada di Rayon Gubeng, diperkirakan terdapat air yang akan meluap dari empat saluran. Keempat saluran tersebut diantaranya adalah saluran HKSN/Kalijudan (Kec Mulyorejo), Mojo (Kec Gubeng), Sidoluhur dsk (Kec Krembangan) dan Tenggumung Karya (Kec Semampir). Sedangkan pada Rayon Genteng, dari 37 saluran

terdapat enam saluran yang dapat dikatakan tidak mampu menampung curah hujan hasil prediksi. Ke-enam saluran tersebut diantaranya adalah saluran Kedung Turi, Pregolan Bunder, Embong Kemiri, Embong Malang (Kec.Tegalsari) dan Jl.Semarang, Bubutan (Kec Bubutan). Pada Rayon Wiyung terdeteksi satu saluran berpotensi tidak dapat menampung curah hujan maksimal hasil prediksi, yaitu pada saluran Babatan Indah (Kec Wiyung). Untuk Rayon Jambangan tidak ada satupun saluran yang terdeteksi tidak dapat menampung curah hujan maksimum. Dapat diketahui terdapat beberapa saluran yang diprediksi tidak mampu menampung curah hujan maksimum hasil prediksi yang berakibat pada meluapnya air pada saluran sehingga mengakibatkan terjadinya banjir genangan. Kecamatan-kecamatan yang memiliki saluran yang diprediksi tidak mampu menampung curah hujan dengan baik dapat dilihat pada Gambar 4.49.



Gambar 4.49 Peta Prediksi Banjir di Kota Surabaya

Berdasarkan Gambar 4.49 menunjukkan bahwa kecamatan berwarna merah terindikasi adanya saluran yang mengakibatkan

daerah tersebut diprediksi akan banjir. Jika dikaitkan dengan Draft Laporan Akhir Surabaya Drainase Master Plan tahun 2018-2038 yang diterbitkan oleh Badan Perencanaan Pembangunan Kota Surabaya terdapat kesesuaian hasil prediksi dengan pengamatan di lapangan.

Seperti halnya pada Rayon Gubeng diprediksi Saluran kalijudan analisa genangan menyatakan bahwa saluran kalijudan merupakan saluran kecil dan banyak sampah sehingga diusulkan adanya pelebaran saluran. Untuk saluran Tenggumung, dianalisa saluran air kecil, pendangkalan saluran, dan banyak sampah rumah tangga. Pada rayon Genteng, perlu adanya penanganan segera untuk saluran Jl. Tegalsari di alirkan ke saluran Embong Malang Sisi Selatan. Untuk saluran Sekunder Jl. Semarang juga memiliki masalah, hal tersebut dikarenakan adanya penyempimpitan di gorong-gorong Kereta Api, Jl. Tembakan. Serta aliran sangat tergantung dengan muka air Sal. Jl. Semarang yang bermasalah di gorong-gorong KA.

(Halaman ini sengaja di kosongkan)

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

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

1. Karakteristik curah hujan harian di Kota Surabaya cenderung sama antar enam balai PSAWS. 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 1 Mei s.d 31 Oktober cenderung rendah (musim kemarau) sedangkan pada bulan 1 November s.d 30 April cenderung tinggi (musim hujan). Sedangkan untuk unsur iklim (temperatur, kelembaban dan kecepatan angin) di tiga Stasiun BMKG relatif konstan dengan pola musiman.
2. Model optimum pada saat menggunakan metode *Gaussian Copula Marginal Regression* (GCMR) untuk curah hujan di enam balai PSAWS berbeda-beda. Namun mayoritas model terbaik dalam memprediksi curah hujan yaitu pada saat data curah hujan bernilai nol tidak dilibatkan atau menjadi sama dengan *missing value*. Model terbaik juga diperoleh ketika variabel prediktor menggunakan variabel PC hasil reduksi data unsur iklim menggunakan PCA terhadap tiga Stasiun BMKG dan ditambahkan variabel lag hasil *differencing seasonal* tahunannya (365) atau lag model $ARIMA(1,0,0)(5,1,0)^{365}$. Walaupun plot prediksi pada data *training* dan *testing* belum sepenuhnya mengikuti pola data aktualnya.
3. Hasil prediksi banjir di Kota Surabaya berdasarkan prediksi curah hujan maksimum, pada Bulan Desember 2018

terdeteksi akan terjadi banjir di beberapa Kecamatan diantaranya adalah Kecamatan Mulyorejo, Gubeng, Krembangan, Semampir, Tegalsari, Bubutan dan Wiyung. Hanya pada Rayon Jambangan tidak terdeteksi adanya saluran yang diprediksi mengakibatkan banjir.

5.1.1 Saran

Berdasarkan kesimpulan yang didapatkan, maka perlu mengkaji kembali model GCMR yang telah diaplikasikan pada model, dikarenakan nilai plot pada setiap pemodelan belum sepenuhnya dapat mengikuti pola curah hujan aktual di enam balai PSAWS Kota Surabaya. Serta dapat mengoptimalkan fungsi *arma.cormat* pada saat pemodelan GCMR guna memperoleh error yang independen. Untuk input yang menambahkan *lag differencing seasonal* harapannya dapat menggunakan *lag* hasil *differencing* masing-masing curah hujan di enam balai. Untuk penelitian selanjutnya, dapat dicobakan analisis PCA terhadap tiga unsur iklim di tiga stasiun yang berbeda secara bersamaan, hal ini dikarenakan antar unsur iklim saling signifikan berpengaruh. Selanjutnya, perlu dilakukan kajian mendalam terkait mendapatkan prediksi curah hujan harian. Hal ini dikarenakan, curah hujan harian yang terjadi tidak menentu pada setiap tanggalnya.

DAFTAR PUSTAKA

- Aldrian, A., Budiman & Karmini, M. (2011). *Adaptasi dan Mitigasi Perubahan Iklim di Indonesia*. Jakarta: Pusat Perubahan Iklim dan Kualitas Udara Kedeputusan Bidang Klimatologi BMKG
- Bahri, A. S. & Madlazim, M. (2012). Pemetaan Topografi, Geofisika dan Geologi Kota Surabaya. *Jurnal Penelitian Fisika dan Aplikasinya (JPFA)*, 2(2), 23-28.
- Bassio, M. C. & Cuervo, E. C. (2015). Gamma Regression Model with the Gammareg R package. *Comunicaciones en Estadística*, 8(2), 211-223.
- BNPB. (2017). *Badan Nasional Penanggulangan Bencana*. Diakses pada Maret, 2019. <https://bnpb.go.id/>
- Case, M., Ardiansyah, F. & Spector, E. (n.d.). *Climate Change in Indonesia : Implications for Humans and Nature*. Diakses pada Maret, 2019. <http://www.worldwildlife.org/climate/Publications/WWFBinaryitem7664.pdf>.
- Charpentier, A., Fermanian, J. & Scaillet, O. (2007). The Estimation of Copulas : Theory and Practice. In: *Rank, J. (ed.) Copulas: From Theory to Application in Finance*, (pp. 35–60). New York: Risk Books.
- Choroś, B., Ibragimov, R. & Permiakova, E. (2010). Copula Estimation. In P. Jaworski, F. Durante, W. Härdle, & T. Rychlik, *Copula theory and its applications* (pp. 77-92). Netherlands: Springer.
- Cryer, J., & Chan, K.S. (2008). *Time Series Analysis with Applications in R*. USA: Springer.
- Genest, C. & Rivest, L. P. (1993). Statistical Inference Procedures for Bivariate Archimedean Copulas. *Journal of the American Statistical Association*, 88(423), 1034-1043.

- Genest, C. & Segers, J. (2010). On the covariance of the asymptotic empirical copula process. *Journal of Multivariate Analysis*. 101, 1837-1845.
- Geost, F. (2018). *GeologiNesia*. Diakses pada Maret, 2019. <https://www.geologinesia.com/2018/09/letak-astronomis-geografis-dan-geologis-indonesia.html>
- Han, J., Kamber, M. & Pei, J. (2012). *Data Mining Concepts and Techniques, 3rd Edition*. USA : Elsevier.
- Hyndman, R. & Athanasopoulos, G. (2018). *Forecasting : principles and practice*. Australia. Diakses pada Juni, 2019. OTexts.com/fpp2
- IPCC (2007) *Summary for policy makers*. In: Solomon S, Qin D, Manning M, Chen Z, Marquis M, Averyt KB, Tignor MMHL (eds) *Climate Change 2007: The physical science basis*. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press, Cambridge
- Istifadah, N., Wasiaturrehman, & Dumauli, M. T. (2017). Sektor Perdagangan Kota Surabaya di Era Kompetisi Global. *Riset Ekonomi dan Manajemen*, 17(2), 147-161.
- Johnson , R. A. & Wichern, D. W. (2002). *Applied Multivariate Statistical Analysis*. New Jersey: Prentice Hall.
- Kodoatie, R. J. & Sugiyanto. (2002). *Banjir, Beberapa Penyebab dan Metode Pengendaliannya dalam Prespektif Lingkungan*. Yogyakarta: Pustaka Pelajar.
- Masarotto, G. & Varin, C. (2012). Gaussian Copula Marginal Regression. *Electronic Journal of Statistic*, 6, 1517-1549.
- Masarotto, G. & Varin, C. (2017). Gaussian Copula Regression in R. *Journal of Statistics Software*, 77(8), 1-26.
- Measey, M. (2010). Indonesia: A Vulnerable Country in the Face of Climate Change. *Global Majority E-Journal*, 1(1), 31-45.

- Mung'atu, J. (2015). *Copula Based Risks Classification Models for General Insurance : A Kenyan General Insurance Business Case*. Kenya : LAP LAMBERT Academic Publishing.
- Nelsen, R. (2005). *An Introduction to Copulas*. New York: Springer.
- PTSP, D. (2017). *Dinas Penanaman Modal dan Pelayanan Terpadu Stu Pintu*. Diakses pada Maret, 2019. <http://dpm-ptsp.surabaya.go.id/v3/>
- Purwo, S. (2019, Januari 31). *Ungkapan Kepala Pusat Data dan Humas BNPB*. Diakses pada Maret, 2019. https://twitter.com/Sutopo_PN
- Schölzel, C. & Friederich, P. (2008). Multivariate non-normally distributed random variables in climate research-introduction to the copula approach. *Nonlinear Processes in Geophysics*, 15, 761-772.
- Sebastian, L. (2008). Pendekatan Pencegahan dan Penanggulangan Banjir. *Dinamika Teknik Sipil*, 8(2), 162-169.
- Sklar, A. (1959). Fonctions de repartition a n dimensions et leurs marges. *Inst. Statist. Univ. Paris*, 8, 229-231.
- Soesilo, I. (2014). *Climate change: Indonesia's adaptation and mitigation efforts*. Diakses pada Maret, 2019. <https://www.thejakartapost.com/news/2014/04/26/climate-change-indonesia-s-adaptation-and-mitigation-efforts.html>
- Sosrodarsono, S. & Takeda, L. (2003). *Hidrologi untuk Pengairan, Edisi ke-9*. Jakarta: PT. Pradnya Paramita.
- Surabaya, H. (2019, Januari 14). *Bangga Surabaya : Satu Satunya di Indonesia, Kota Surabaya Raih Penghargaan Adipura Kencana*. Diakses pada Maret 2019. <https://humas.surabaya.go.id/2019/01/15/satu-satunya-di-indonesia-kota-surabaya-raih-penghargaan-adipura-kencana/>
- Syntetos, A. A. (2006). *Business Forecasting, 8th Edition*. Prentice Hall, New Jersey: Pearson.

- Tjasyono, B. (2006). *Klimatologi*. Bandung: Institut Teknologi Bandung (ITB).
- Wei, W. W. (2006). *Time Series Analysis Univariate and Multivariate Methods, 2nd Edition*. New York: Pearson Education, Inc.
- Zhang, Y. & Wang, S. (2015). Detection of Alzheimer's Disease by Displacement Field and Machine Learning. *PeerJ*, 3, 1-29.

LAMPIRAN

Lampiran 1. Surat Keterangan Pengambilan Data

SURAT PERNYATAAN

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

Nama : AFIFAH NUR ISWARI

NRP : 06211540000109

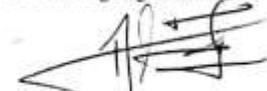
menyatakan bahwa data yang digunakan dalam Tugas Akhir ~~/Thesis-~~ ini merupakan data sekunder yang diambil dari ~~penelitian / buku / Tugas Akhir / Thesis /~~ publikasi lainnya yaitu:

Sumber : Website Data Online BMKG
(<http://dataonline.bmkg.go.id/home>)

Keterangan : Data Prediktor (Rata-Rata Temperatur Udara, Kelembaban Udara & Kecepatan angin di 3 Stasiun BMKG : Stasiun Juanda, Perak 2 & Perak 1)

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 P., S.Si., M.Si.
NIP. 19831204 200812 1 002

Surabaya, Juli 2019



Afifah Nur Iswari
NRP. 06211540000109

(Halaman ini sengaja di kosongkan)

Lampiran 1. Surat Keterangan Pengambilan Data [lanjutan]

SURAT KETERANGAN

Saya yang bertanda tangan di bawah ini menerangkan bahwa :

1. Mahasiswa Statistika FMKSD-ITS dengan identitas berikut :

Nama : AFIFAH NUR ISWARI

NRP : 06211540000109

Telah mengambil data di instansi/perusahaan kami :

Nama Instansi : DINAS PU BINA MARGA & PEMATUSAN KOTA SURABAYA

Divisi/ bagian : SUB. BAGIAN PENYUSUNAN PROGRAM & PELAPORAN

sejak tanggal 1 MARET 2019 sampai dengan 30 APRIL 2019 untuk keperluan Tugas Akhir Semester Genap 2018/ 2019.

2. Tidak Keberatan/Keberatan* nama perusahaan 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 perusahaan dipublikasikan dalam E journal ITS yaitu Jurnal Sains dan Seni ITS.

Surabaya, 2 Juli 2019

Pimpinan Perusahaan



(Halaman ini sengaja di kosongkan)

Lampiran 2. *Syntax* R untuk Menggabungkan Data BMKG

```

MENGGABUNGKAN DATA DARI FILE EXCELL YANG BERBEDA  
DALAM SATU FOLDER YANG SAMA
setwd('D:/++TUGAS AKHIR/DATA/BMKG/STASIUN')
files <- list.files()

# Membaca seluruh data dari file yang berebeda
STASIUN <- NA
for(x in files){
  BMKG <- read_excel(x)
  STASIUN <- rbind(STASIUN, BMKG[9:39,])
}

# Menghapus missing satu baris
STASIUN <- STASIUN [rowSums(is.na(STASIUN)) !=
ncol(STASIUN), ]
colnames(STASIUN) <- c("Tanggal", "Tn", "Tx", "Tavg",
"RH_avg", "RR", "ss", "ff_x", "ddd_x", "ff_avg", "ddd_car")

# Memastikan setiap variabel memiliki format sesuai
STASIUN <- transform(Perak1_R,
  Tanggal = as.Date(Tanggal, "%d-%m-%Y"),
  Tn = as.numeric(Tn),
  Tx = as.numeric(Tx),
  Tavg = as.numeric(Tavg),
  RH_avg = as.numeric(RH_avg),
  RR = as.numeric(RR),
  ss = as.numeric(ss),
  ff_x = as.numeric(ff_x),
  ff_avg = as.numeric(ff_avg)
)
sapply(STASIUN, mode)
summary(STASIUN)
STASIUN

```

Lampiran 3. *Syntax R Menggabungkan Data Curah Hujan*

MENGABUNGKAN DATA DARI FILE EXCELL YANG BERBEDA DI SHEET YANG BERBEDA
<pre> setwd('D:/++TUGAS AKHIR/DATA/BALAI PSAWS (CH)') CH <- list.files() # CH_Keputih 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)) #export data ?write.table write.table(CH_Keputih, file="D:/1.CH_Keputih.csv", sep=";") </pre>

Lampiran 4. *Syntax R Imputasi Data Missing*

```

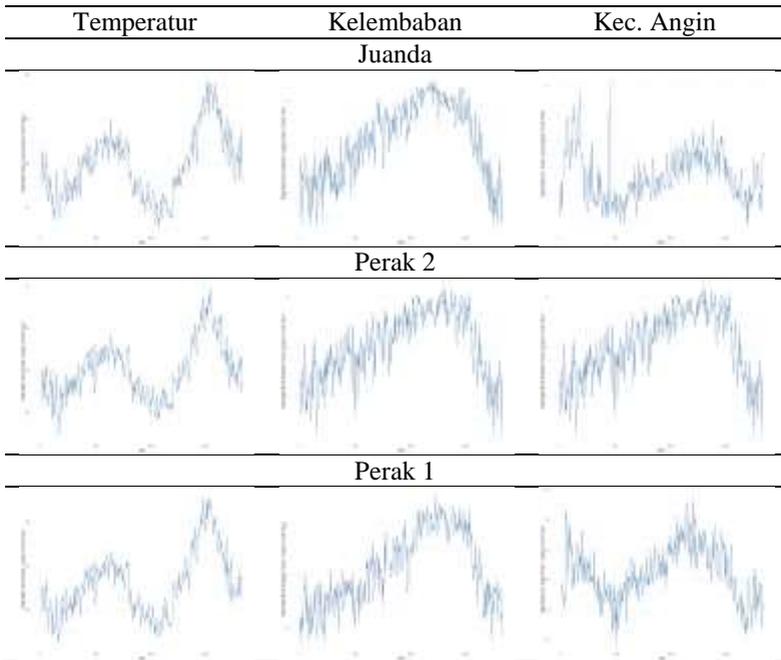
IMPUTASI DATA HARIAN IN MULTI YEAR (355/356)
library(dplyr)
library(lubridate)
#####
# Mengambil Data yang Dibutuhkan
STASIUN <- STASIUN [c(1,4,5,6,10)]
STASIUN <- STASIUN [-c(3653:3742),]

# Menghapus Data 8888 = 0 dan 9999 = NA
STASIUN [STASIUN == 8888] <- 0
STASIUN [STASIUN == 9999] <- NA
STASIUN [STASIUN == 8888.0] <- 0
STASIUN [STASIUN == 9999.0] <- NA
  *Ket : 8888 = data tidak terukur
        : 9999 = tidak dilakukan pengukuran

# Imputasi Data
NEW_FILE <- FILE %>%
group_by(Bulan=month(Tanggal),Hari =day(Tanggal)) %>%
  mutate(Tavg = replace(Tavg, is.na(Tavg),
    mean(Tavg,na.rm = TRUE))) %>%
  mutate(RH_avg = replace(RH_avg, is.na(RH_avg),
    mean(RH_avg, na.rm = TRUE))) %>%
  mutate(RR = replace(RR, is.na(RR), mean(RR, na.rm =
    TRUE))) %>%
  mutate(ff_avg = replace(ff_avg, is.na(ff_avg),
    mean(ff_avg, na.rm = TRUE)))

# Mengetahui Letak Missing
library(imputeTS)
plotNA.distribution(DATA$VARIABEL)

```

Lampiran 5. *Output R Time-Series Plot Imputasi Data Missing*

Lampiran 6. *Syntax R Pre-Processing Data*

CEK MISSING VALUE
<pre>library(mice) library(VIM) md.pattern(DATA) aggr_plot <- aggr(DATA, col=c('navyblue','red'), numbers=TRUE, sortVars=TRUE, labels=names(Perak1), cex.axis=.7, gap=3, ylab=c("Missing DATA", "Pattern"))</pre>

Lampiran 7. *Syntax R Visualisasi Data*

VISUALISASI DATA (PLOT)
<pre>library(ggplot2) library(ggpubr) library(cowplot)</pre>
TIME-SERIES PLOT
<pre>win.graph() plot_grid(ggplot(data = DATA) + aes(y = Juanda_T, x = Tanggal) + labs(x = "Hari ke-", y = "Juanda") + geom_line(color = "#0c4c8a") + theme_minimal()+ theme(axis.text=element_text(size=15), axis.title=element_text(size=20)), ggplot(data = DATA) + aes(y = Perak2_T, x = Tanggal) + labs(x = "Hari ke-", y = "Perak 2") + geom_line(color = "#ef562d") + theme_minimal()+ theme(axis.text=element_text(size=15), axis.title=element_text(size=20)), ggplot(data = DATA) + aes(y = Perak1_T, x = Tanggal) + labs(x = "Hari ke-", y = "Perak 1") + geom_line(color = "#41ab5d") + theme_minimal()+ theme(axis.text=element_text(size=15), axis.title=element_text(size=20)), labels = NULL, nrow = 3, ncol = 1, label_y = "HARI")</pre>

Lampiran 7. *Syntax* R Visualisasi Data (lanjutan 1)**BOX-PLOT**

```

Hari <- strptime(DATA$Tanggal,"%d")
Bulan <- strptime(DATA$Tanggal,"%b")
Tahun <- strptime(DATA$Tanggal,"%Y")

month.abb <- c("Jan", "Feb", "Mar", "Apr", "Mei", "Jun",
              "Jul", "Agu", "Sep", "Okt", "Nov", "Des")

      *Ket : VAR = VARIABEL

win.graph()
plot_grid(
  ggplot(DATA) +
    aes(x = factor(Bulan,levels= month.abb),y= VAR)+
    labs(x = "Bulan", y = "Juanda") +
    geom_boxplot(color="#0c4c8a",fill = "#9ecae1") +
    theme_minimal()+
    theme(axis.text=element_text(size=15),
          axis.title=element_text(size=20)),
  ggplot(DATA) +
    aes(x =factor(Bulan,levels= month.abb),y= VAR)+
    labs(x = "Bulan", y = "Perak 2") +
    geom_boxplot(color="#ef562d",fill = "#fec98d")+
    theme_minimal()+
    theme(axis.text=element_text(size=15),
          axis.title=element_text(size=20)),
  ggplot(data = DATA) +
    aes(x =factor(Bulan,levels= month.abb),y= VAR)+
    labs(x = "Bulan", y = "Perak 1") +
    geom_boxplot(color="#41ab5d",fill="#c7e9c0") +
    theme_minimal()+
    theme(axis.text=element_text(size=15),
          axis.title=element_text(size=20)),
  labels = NULL, nrow = 3, ncol = 1)

```

Lampiran 7. *Syntax* R Visualisasi Data (lanjutan 2)

```

SCATTER PLOT
win.graph()
plot_grid(
#Juanda vs CH Keputih
ggplot(DATA) +
  aes(x = Juanda_T, y = CH_Keputih) +
  labs(x = "Juanda", y = NULL, subtitle =
"Temperatur Stasiun BMKG v.s Curah Hujan diKeputih")+
  geom_point(color = "#0c4c8a") +
  stat_cor(
    method="pearson",label.x=24,label.y=145,size=4) +
  geom_smooth(method = "lm", se = FALSE) +
  xlim(24,33) + ylim(0,150) +
  theme_minimal(),
#Perak 2 vs CH Keputih
ggplot(DATA) +
  aes(x = Perak2_T, y = CH_Keputih) +
  labs(x = "Perak 2", y = NULL, subtitle = " ") +
  geom_point(color = "#ef562d") +
  stat_cor(
    method="pearson",label.x=24,label.y=145,size=4) +
  geom_smooth(method = "lm", se = FALSE) +
  xlim(24,33) + ylim(0,150) +
  theme_minimal(),

#Perak 1 vs CH Gn Sari
ggplot(DATA) +
  aes(x = Perak1_T, y = CH_Gnsari) +
  labs(x = "Perak 1", y = NULL, subtitle = " ") +
  geom_point(color = "#41ab5d") +
  stat_cor(
    method="pearson",label.x=24,label.y=145,size=4) +
  geom_smooth(method = "lm", se = FALSE) +
  xlim(24,33) + ylim(0,150) +
  Theme_minimal(),
labels = NULL, nrow = 3, ncol = 6)

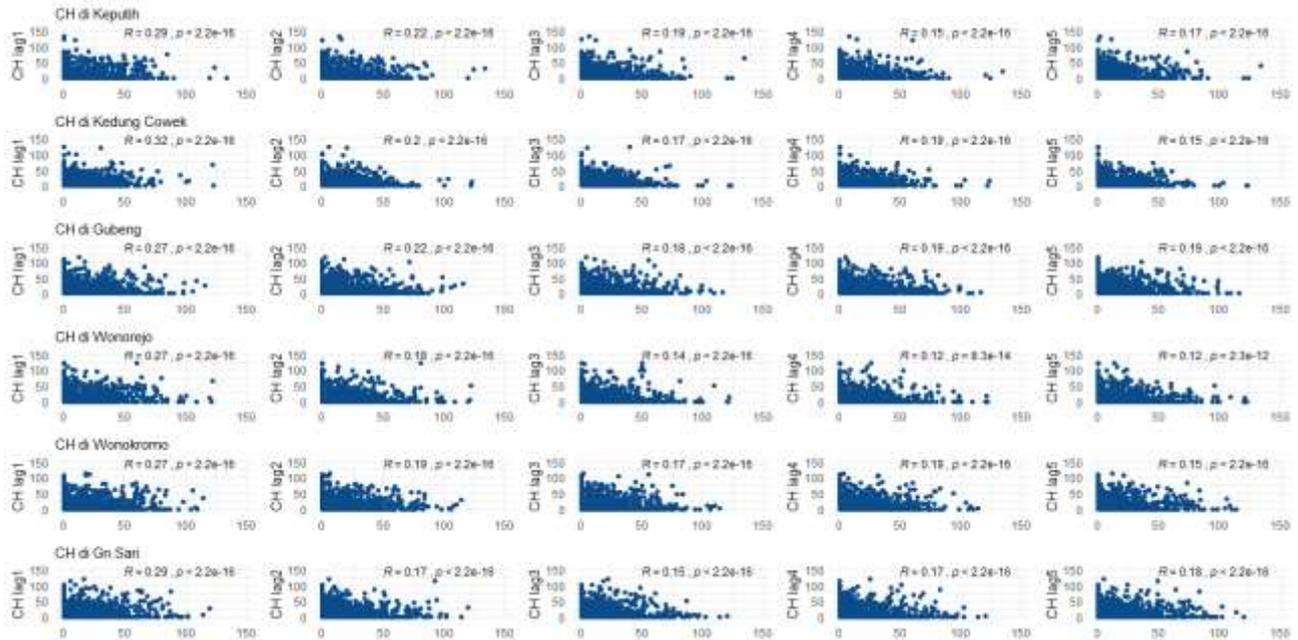
```

Lampiran 8. Data Variabel Prediktor & Respon

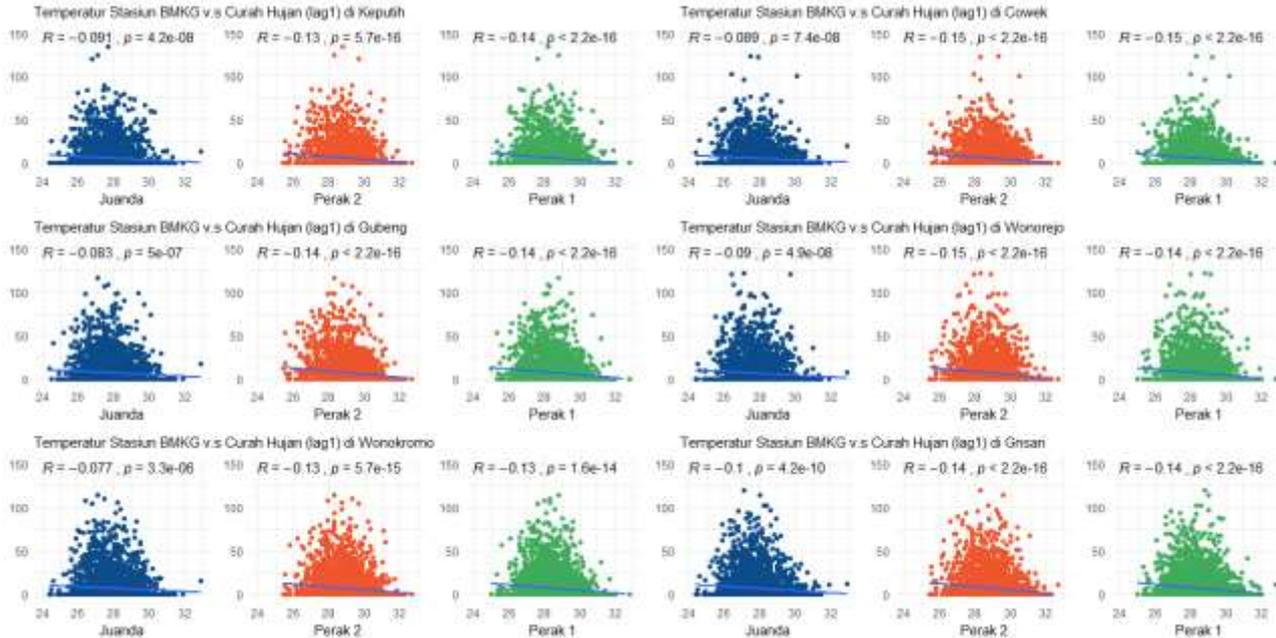
	Tanggal (hh/bb/tttt)	n	Stasiun BMKG									Balai PSAWS				Dummy
			Juanda			Perak 2			Perak 1			1	2	...	7	
			T	RH	ff	T	RH	ff	T	RH	ff					
TRAINING	01/01/2009	1	27.1	86	3	29.2	77	2	28.3	80	3	9	7	...	12	1
	01/01/2009	2	28.5	77	4	28.6	81	1	28	81	2	0	8	...	0	1
	01/01/2009	3	29.3	70	3	29.5	73	1	29.4	72	2	6	7	...	16	1
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	28/11/2018	3619												...	21	0
	29/11/2018	3620	28.7	80	2	28.5	68	2	29.4	78	1	15	14	...	21	0
30/11/2018	3621	27.6	85	2	27.9	73	3	28.1	81	1	0	0	...	0	0	
TESTING	01/12/2018	3622	28.7	78	2	28.9	76	2	28.7	78	1	0	0	...	10	1
	02/12/2018	3623	29.3	75	3	29.4	75	2	30.1	72	1	14	10	...	0	1
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	31/12/2018	3652	29.6	74	5	29.5	74	2	29.1	75	1	0	0	...	0	0

* T = Temperature Rata – Rata * Wilayah Stasiun CH (PSAWS) :
 RH = Kelembaban Rata – Rata 1. Keputih; 2. Kd. Cowek; 3. Gubeng;
 ff = Kec. Angin Rata – Rata 4. Wonorejo; 5. Wonokromo; 6. Gn. Sari;
 7. Simo

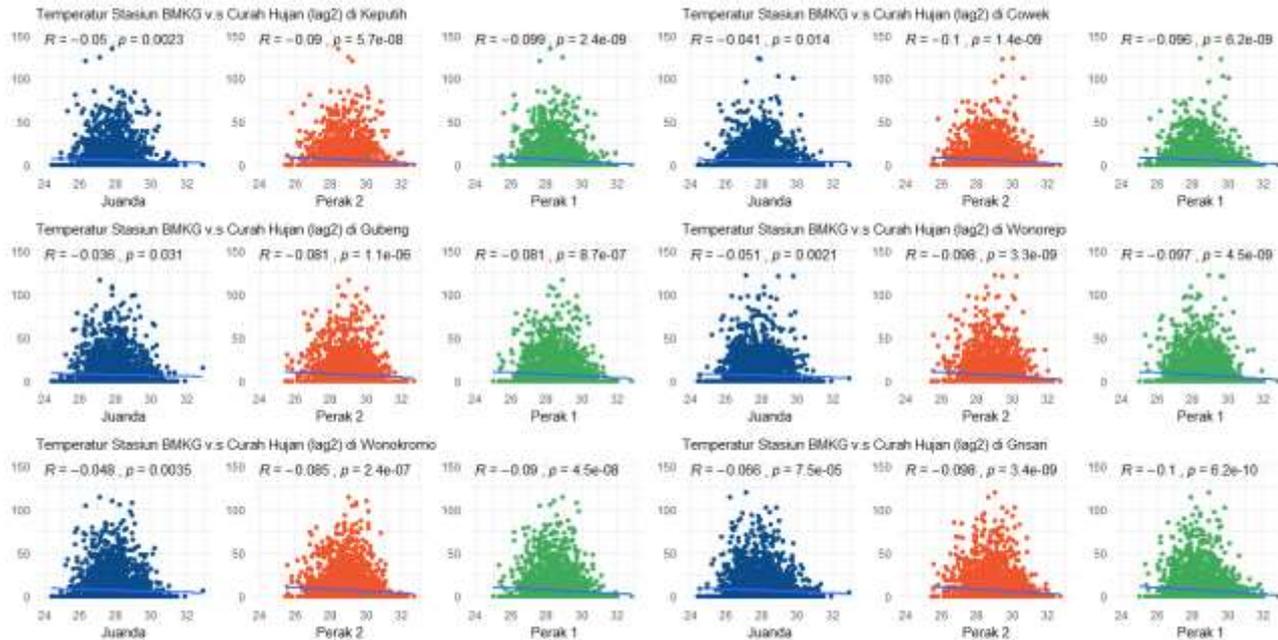
Lampiran 9. Scatter-Plot Curah Hujan & Curah Hujan ($CH_{b,t-1}$ s. d $CH_{b,t-5}$) di 6 Balai PSAWS



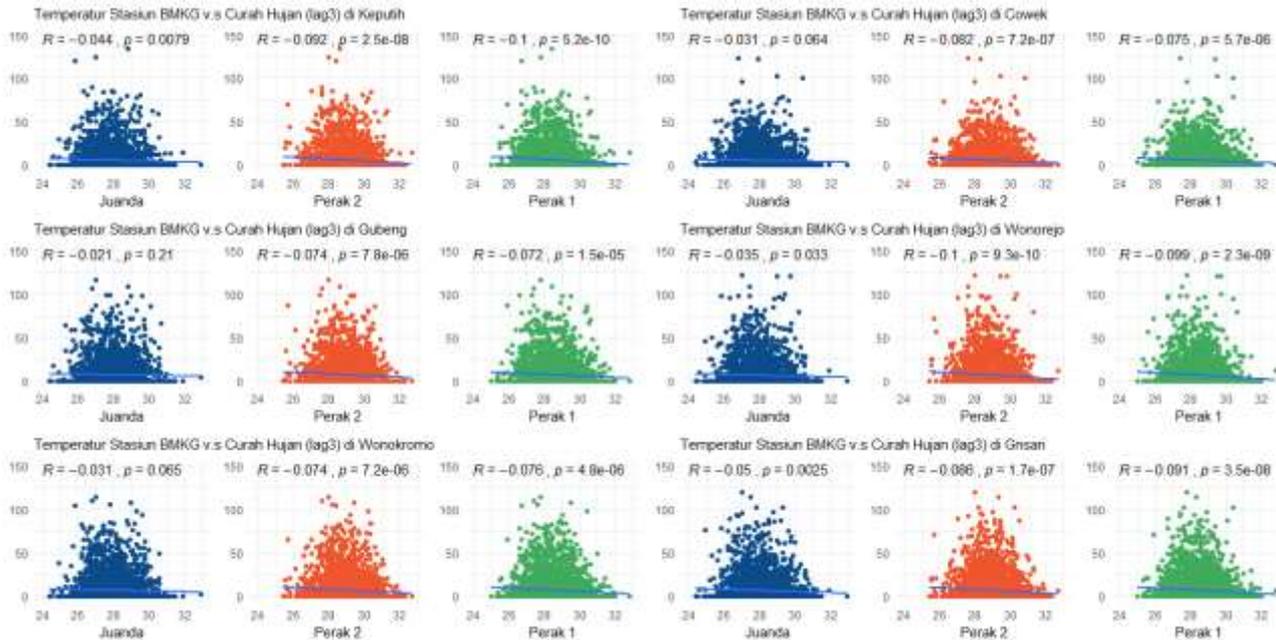
Lampiran 10. Scatter-Plot Temperatur di 3 Stasiun BMKG & CH_{b,t-1} di 6 Balai PSAWS



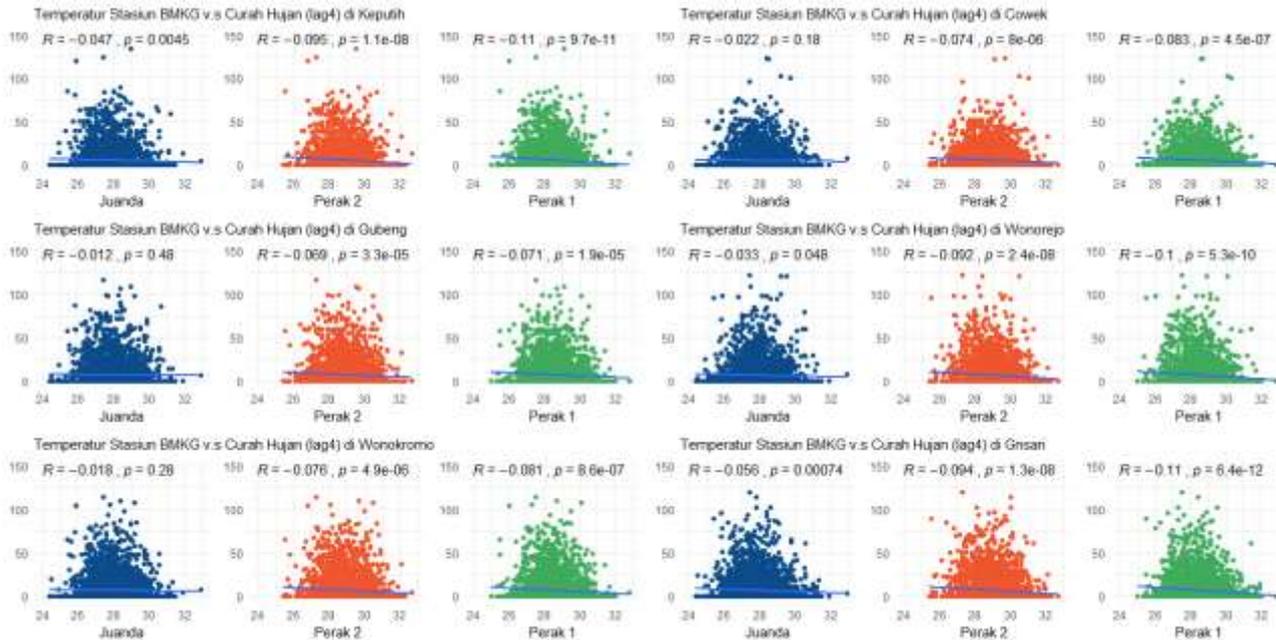
Lampiran 11. Scatter-Plot Temperatur di 3 Stasiun BMKG & CH_{b,t-2} di 6 Balai PSAWS



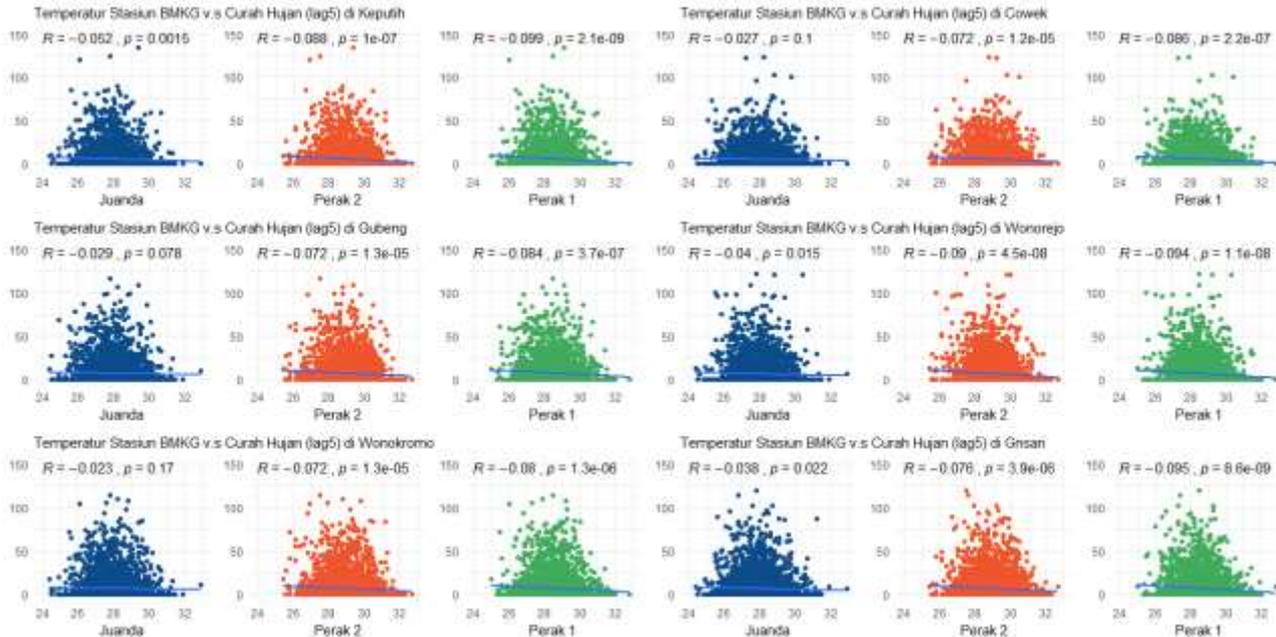
Lampiran 12. Scatter-Plot Temperatur di 3 Stasiun BMKG & CH_{b,t-3} di 6 Balai PSAWS



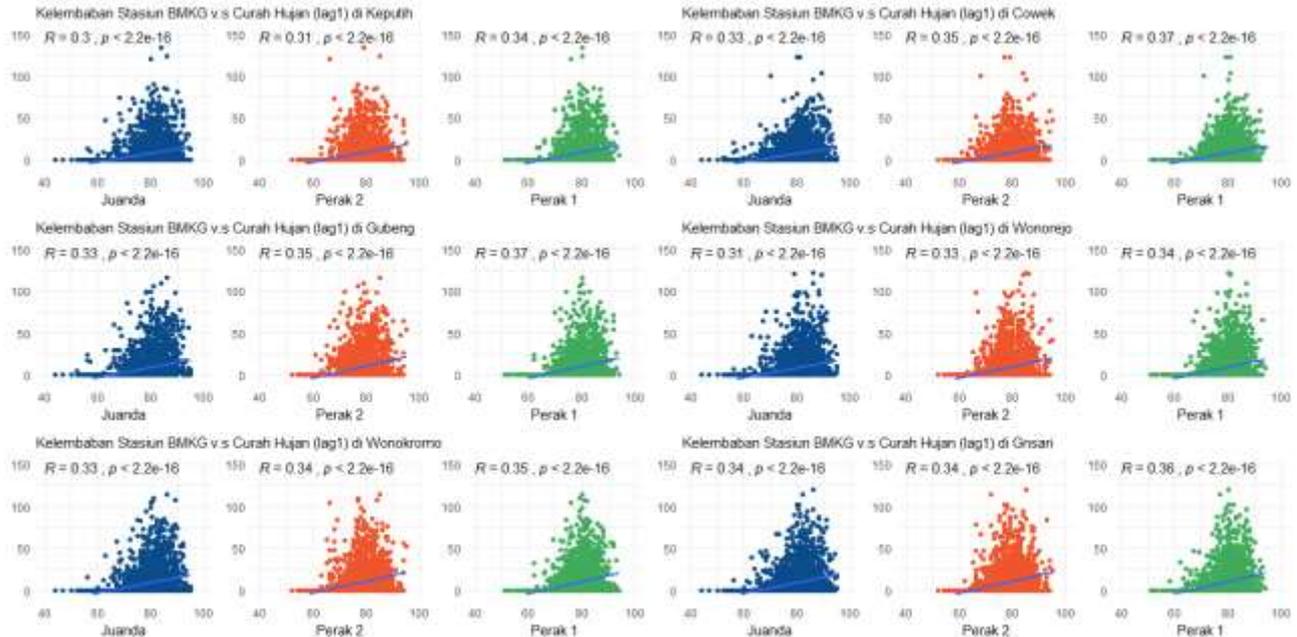
Lampiran 13. Scatter-Plot Temperatur di 3 Stasiun BMKG & CH_{b,t-4} di 6 Balai PSAWS



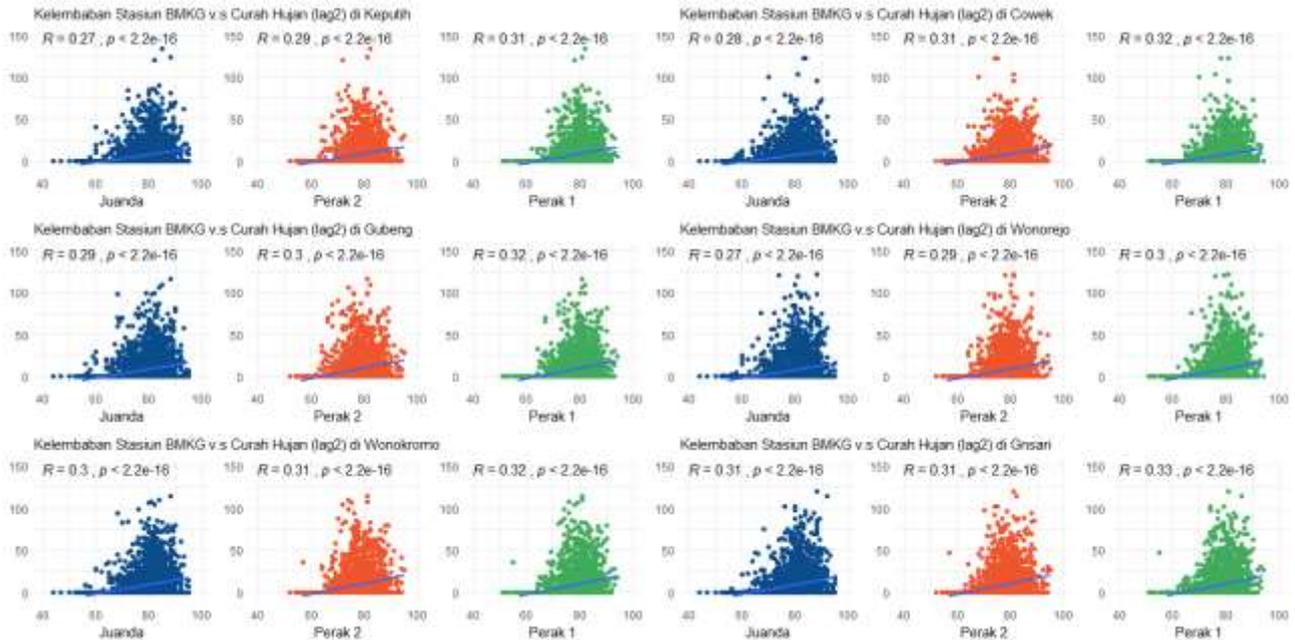
Lampiran 14. Scatter-Plot Temperatur di 3 Stasiun BMKG & CH_{b,t-5} di 6 Balai PSAWS



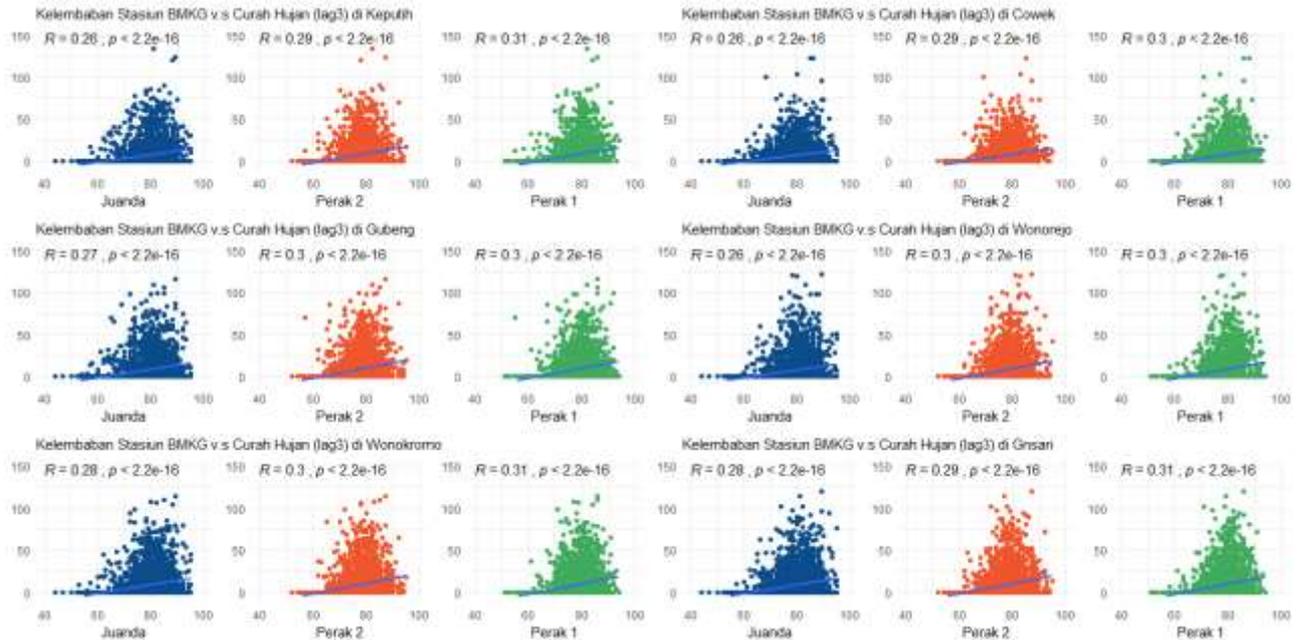
Lampiran 15. Scatter-Plot Kelembaban di 3 Stasiun BMKG & $CH_{b,t-1}$ di 6 Balai PSAWS



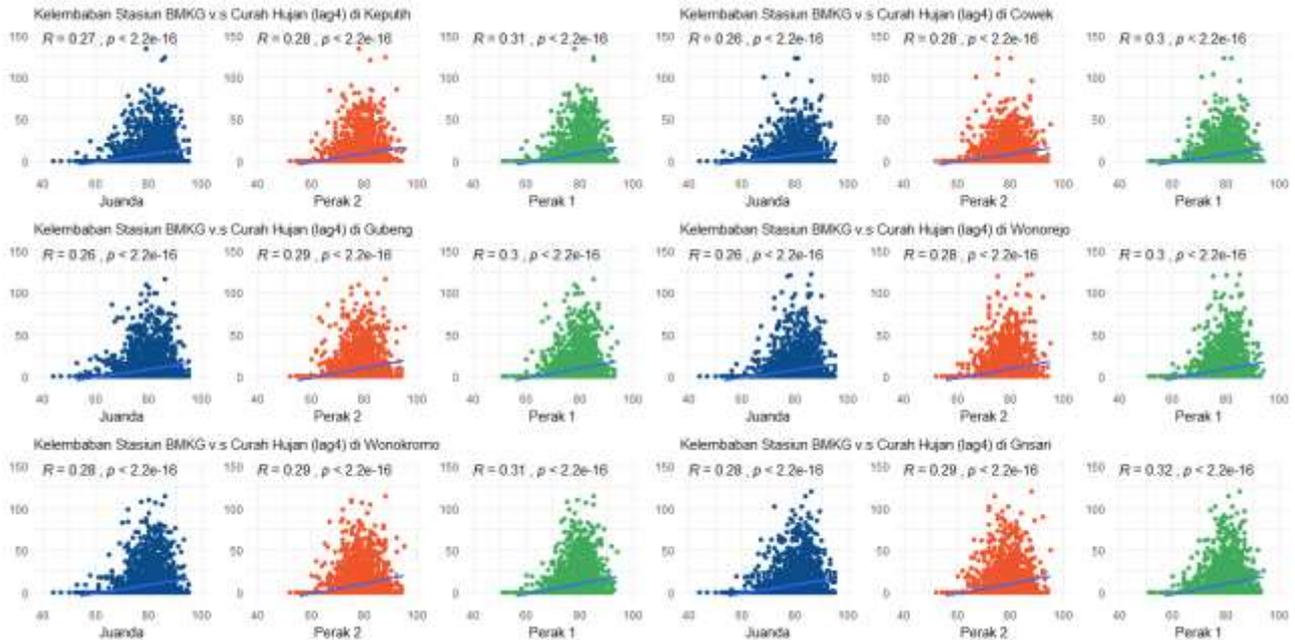
Lampiran 16. Scatter-Plot Kelembaban di 3 Stasiun BMKG & $CH_{b,t-2}$ di 6 Balai PSAWS



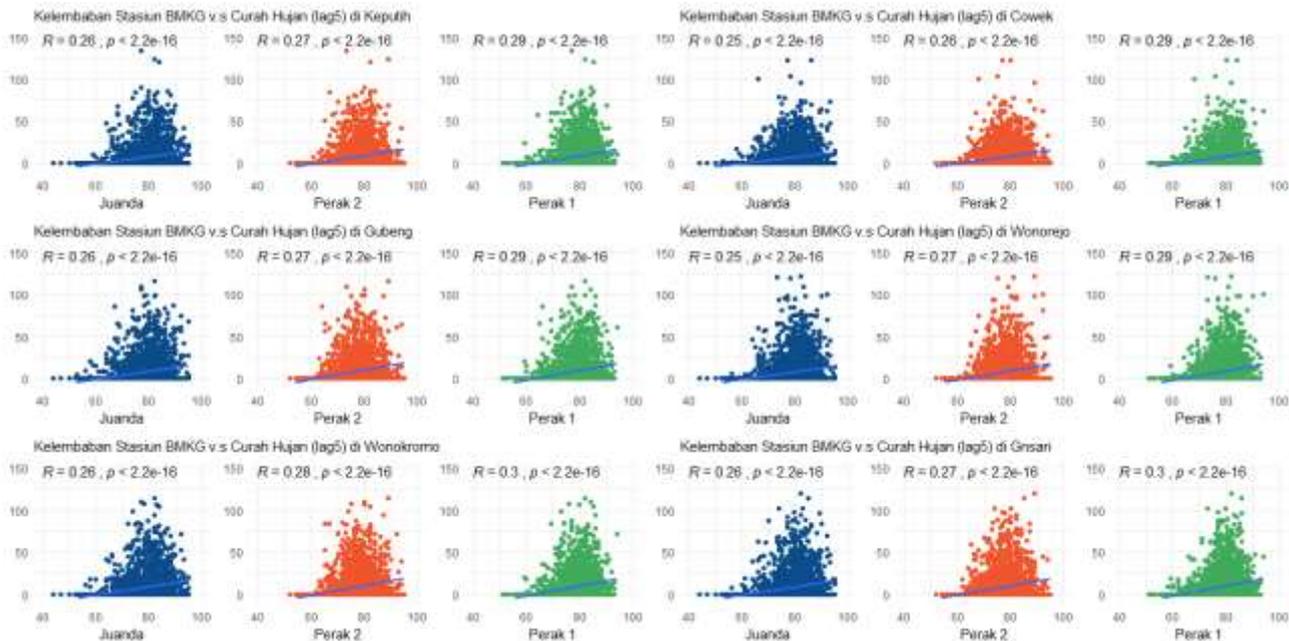
Lampiran 17. Scatter-Plot Kelembaban di 3 Stasiun BMKG & $CH_{b,t-3}$ di 6 Balai PSAWS



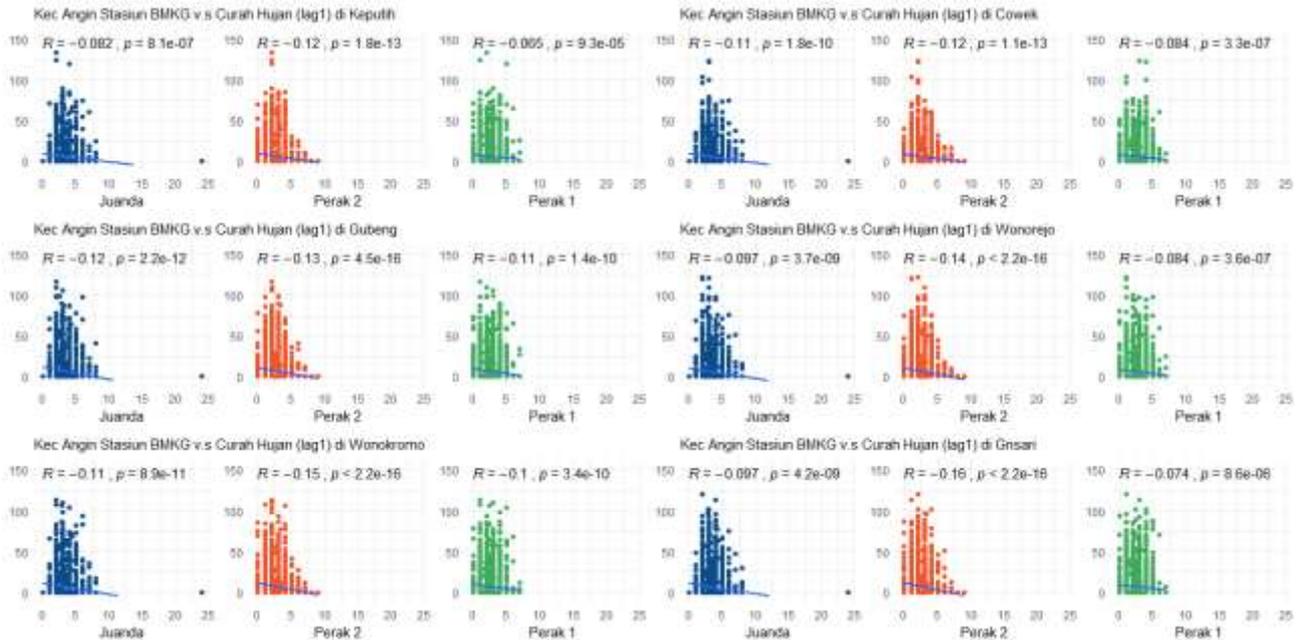
Lampiran 18. Scatter-Plot Kelembaban di 3 Stasiun BMKG & $CH_{b,t-4}$ di 6 Balai PSAWS



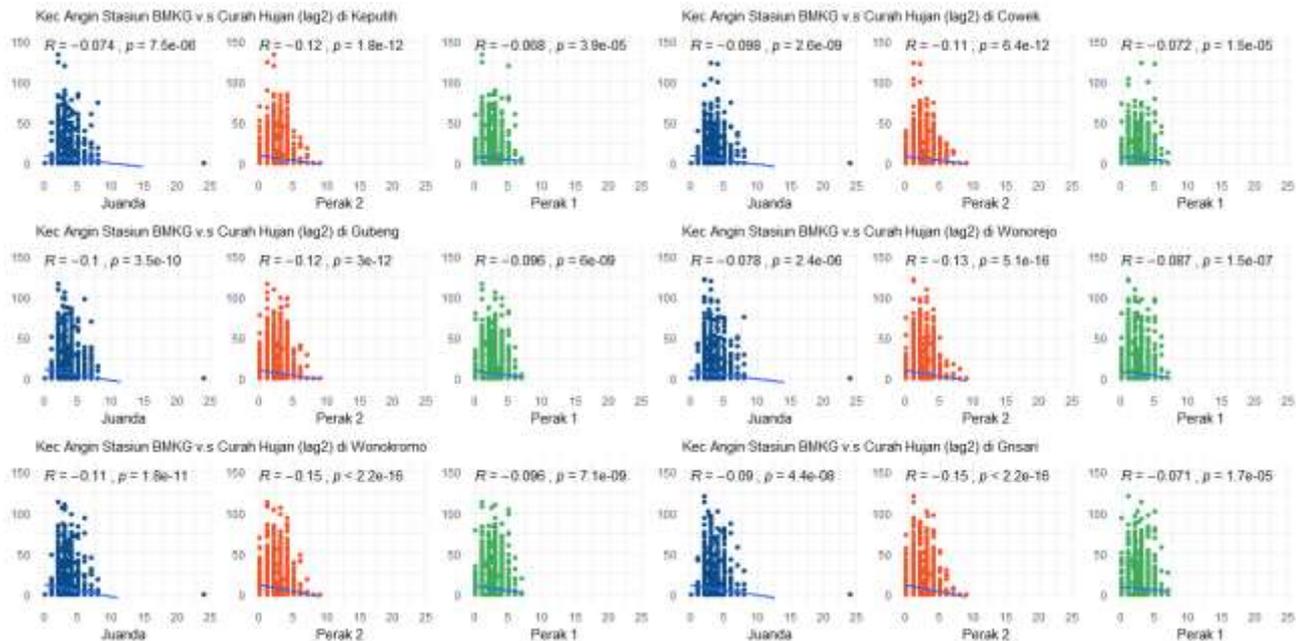
Lampiran 19. Scatter-Plot Kelembaban di 3 Stasiun BMKG & $CH_{b,t-5}$ di 6 Balai PSAWS



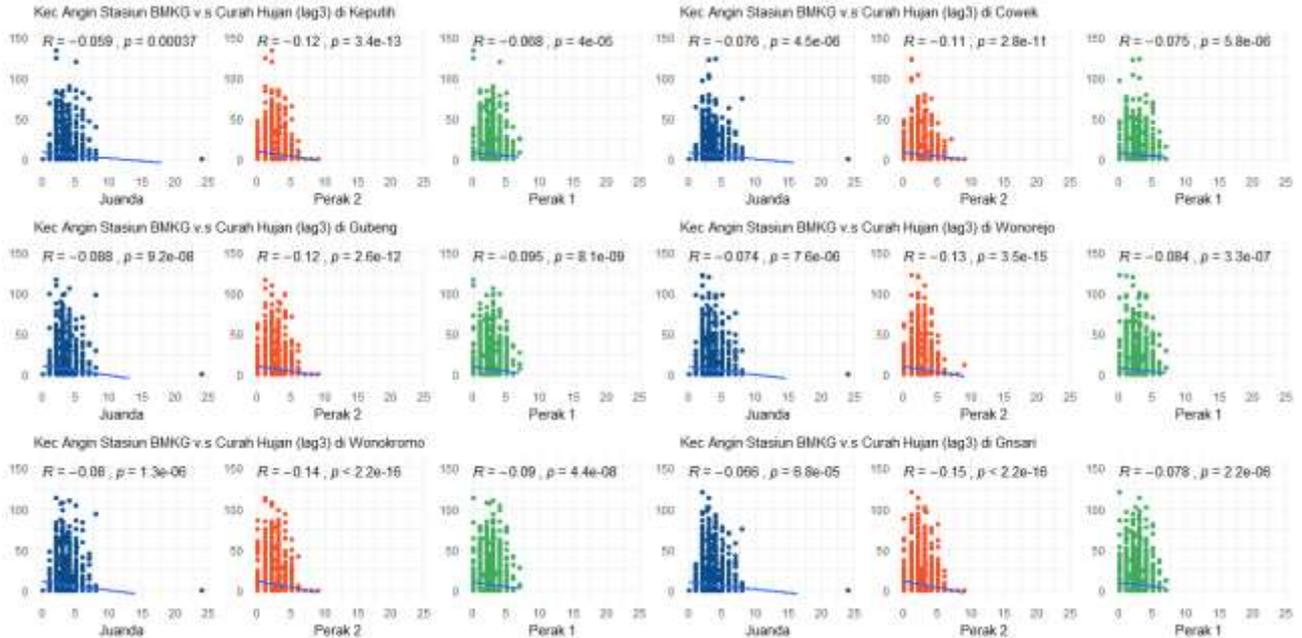
Lampiran 20. Scatter-Plot Kec. Angin di 3 Stasiun BMKG & $CH_{b,t-1}$ di 6 Balai PSAWS



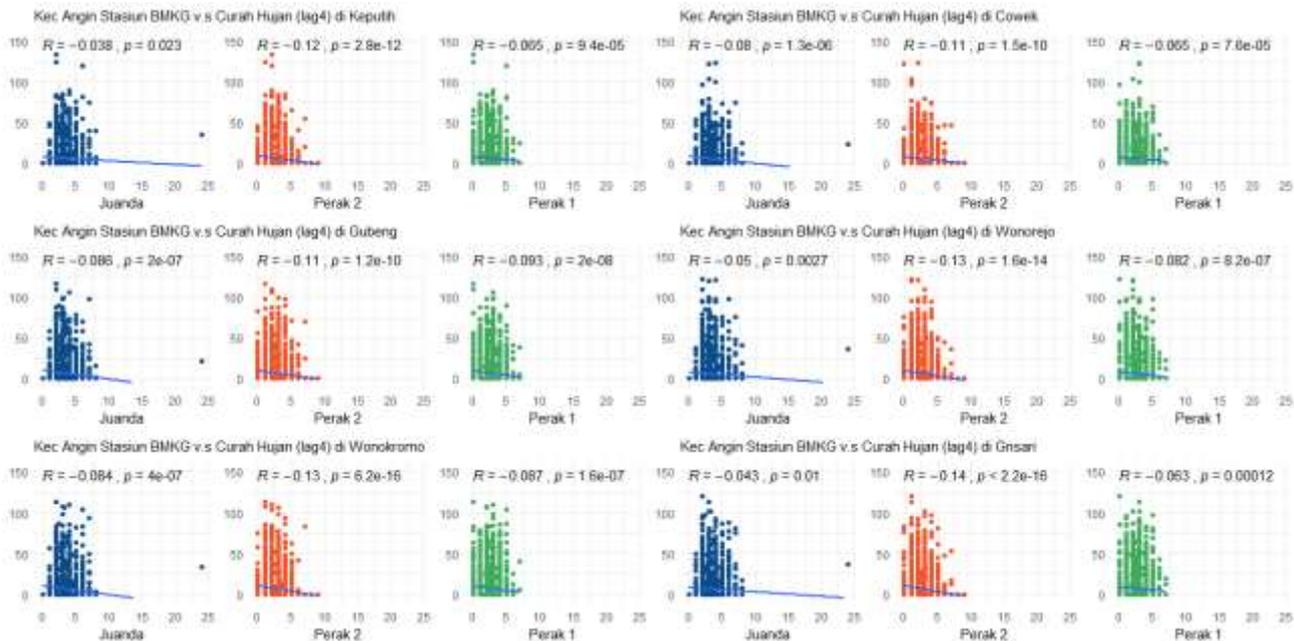
Lampiran 21. Scatter-Plot Kec. Angin di 3 Stasiun BMKG & CH_{b,t-2} di 6 Balai PSAWS



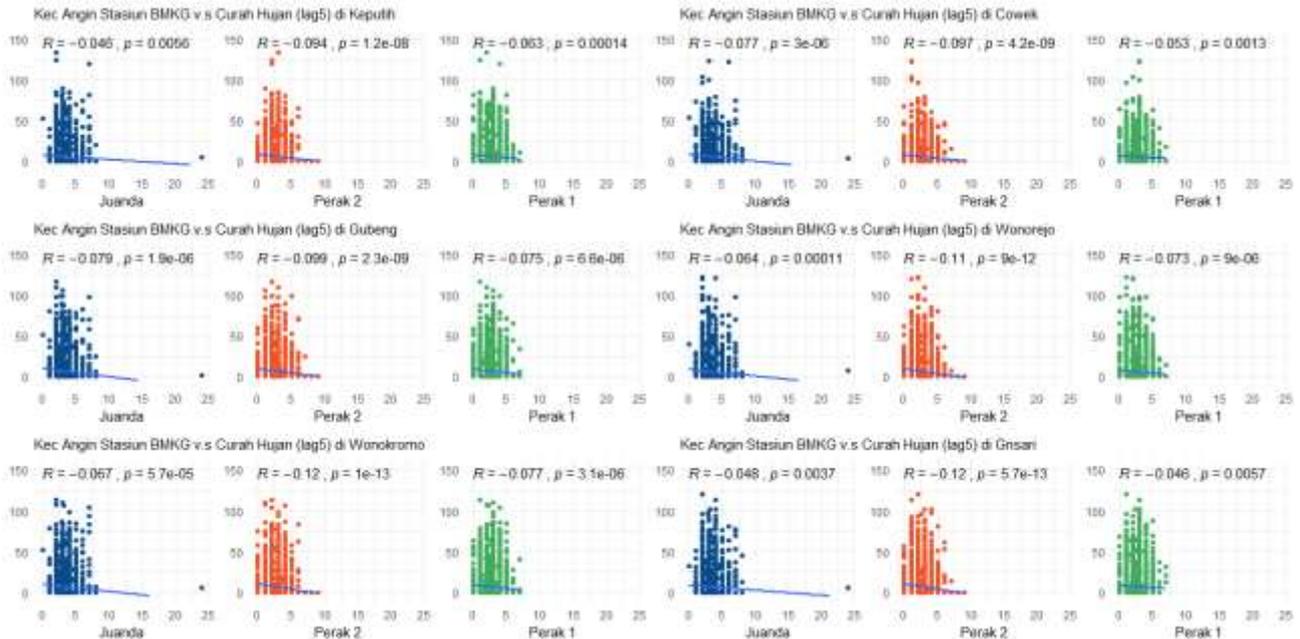
Lampiran 22. Scatter-Plot Kec. Angin di 3 Stasiun BMKG & $CH_{b,t-3}$ di 6 Balai PSAWS



Lampiran 23. Scatter-Plot Kec. Angin di 3 Stasiun BMKG & $CH_{b,t-4}$ di 6 Balai PSAWS



Lampiran 24. Scatter-Plot Kec. Angin di 3 Stasiun BMKG & $CH_{b,t-5}$ di 6 Balai PSAWS



Lampiran 25. Syntax R PCA dan Output

```

## Temperature
Temp <- as.data.frame(cbind(DATA_train$J_X1,
DATA_train$P2_X1, DATA_train$P1_X1))
data.pca_T <- prcomp(Temp)
summary(data.pca_T)
data.pca_T
result_X1=as.data.frame(data.pca_T$x)
PC1_X1= result_X1[,1]
PC2_X1= result_X1[,2]
## Kelembapan
Lembab <- as.data.frame(cbind(DATA_train$J_X2,
DATA_train$P2_X2, DATA_train$P1_X2))
data.pca_RH <- prcomp(Lembab)
summary(data.pca_RH)
data.pca_RH
result_X2=as.data.frame(data.pca_RH$x)
PC1_X2= result_X2[,1]
PC2_X2= result_X2[,2]
## Kecepatan angin
KecAngin <- as.data.frame(cbind(DATA_train$J_X3,
DATA_train$P2_X3, DATA_train$P1_X3))
data.pca_angin <- prcomp(KecAngin)
summary(data.pca_angin)
data.pca_angin
result_X3=as.data.frame(data.pca_angin$x)
PC1_X3= result_X3[,1]
PC2_X3= result_X3[,2]

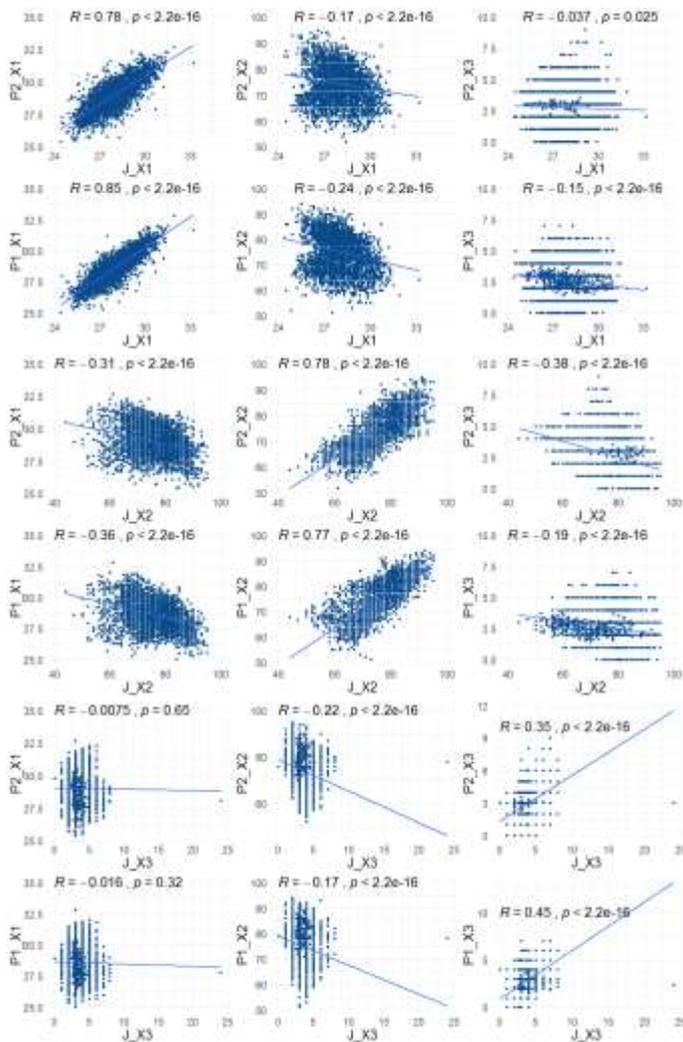
library(factoextra)
fviz_eig(data.pca_VAR)
fviz_eig(data.pca_VAR, choice = "eigenvalue",
          addlabels=TRUE,
          linecolor ="red")

```

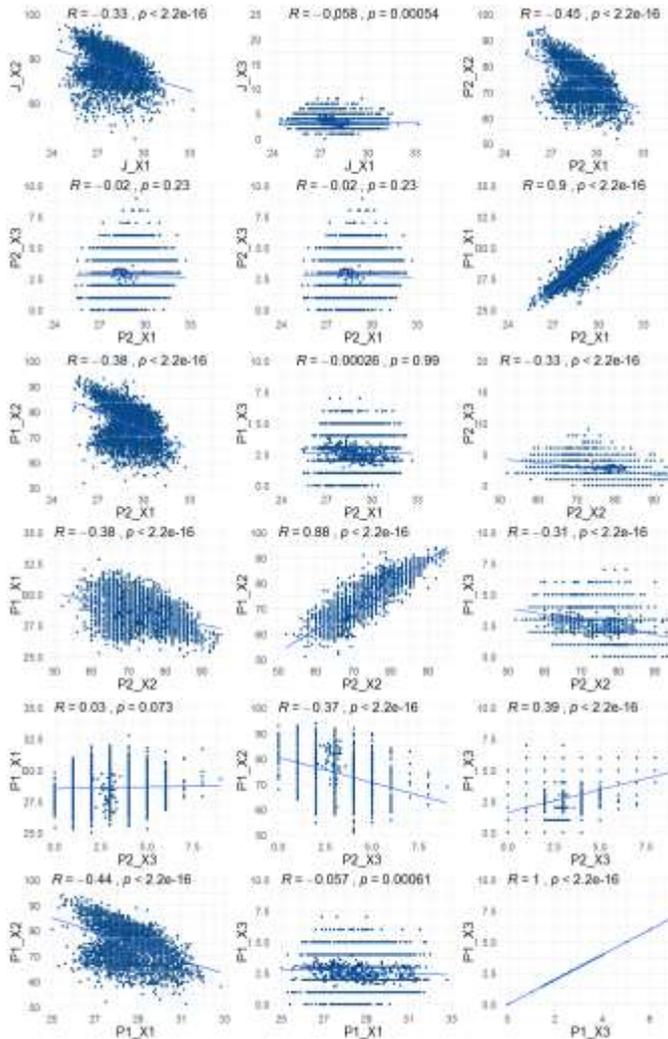
Lampiran 26. Hasil Prediksi Variabel Prediktor (Data Testing)

<i>n</i>	<i>J_X1</i>	<i>J_X1</i>	<i>J_X1</i>	<i>P2_X1</i>	<i>P2_X1</i>	<i>P2_X1</i>	<i>P2_X1</i>	<i>P2_X1</i>	<i>P2_X1</i>
1	27.88	82.37	1.83	28.41	80.01	2.04	28.66	79.08	0.4
2	28.41	81.37	1.86	28.74	78.69	1.85	28.85	78.06	1.17
3	28.33	81.13	1.4	28.94	76.48	1.78	28.86	75.9	1.1
4	28.05	83.11	1.83	29.05	81.08	2.08	28.75	81.05	0.81
5	27.77	84.91	1.83	28.46	80.89	2.07	28.37	80.24	1.09
6	28.46	81.14	1.71	28.71	80.82	1.46	28.77	79.47	0.97
7	29.08	77.05	2.45	28.55	79.97	1.9	28.86	79.87	1.18
8	28.72	77.95	1.78	28.79	79.8	1.8	28.7	79.26	1.41
9	29.44	74.81	1.61	29.5	77.26	2.21	29.78	75.15	1.31
10	28.75	77.48	2	28.59	80.52	2.07	28.85	78.4	0.69
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
15	28.24	80.74	2.17	28.98	78.25	2.3	28.78	78.35	1.77
16	28.49	79.87	2.33	29.14	78.35	2.5	28.77	78.64	1.52
17	27.84	81.79	2.18	28.79	78.48	2.32	28.42	79.21	1.58
18	28.14	81.15	2.27	28.55	80.95	2.22	28.19	81.87	2.28
19	28.63	78.79	2.34	28.76	79.16	2.26	28.38	80.92	2.3
20	28.7	79.29	2.33	29.09	79.37	1.73	28.84	78.7	1.77
21	28.35	79.74	2.39	29.01	79.16	2.02	28.81	78.27	1.96
22	28.4	80.09	1.9	28.62	79.73	1.7	28.31	79.24	1.84
23	28.25	80.99	1.67	29.41	76.18	2.23	29.24	76.33	1.7
24	28.35	79.54	1.24	29.33	76.95	2.16	28.65	76.05	2.08
25	27.13	86.2	0.76	29.12	78.33	2.03	28.57	78.46	1.93
26	27.33	89.47	1.47	28.51	84.91	1.88	27.87	85.88	2.08
27	26.98	91.26	1.42	28.39	84.74	1.9	28.06	84.34	1.97
28	27.38	88.79	1.06	28.41	82.93	1.41	27.83	81.83	1.7
29	27.24	88.21	1.82	28.29	85.81	1.65	27.9	84.6	1.98
30	26.45	93.12	1.42	26.66	93.92	1.4	26.68	91.38	0.91
31	26.65	90.59	1.65	27.32	88.96	1.85	27.28	87.27	1.43

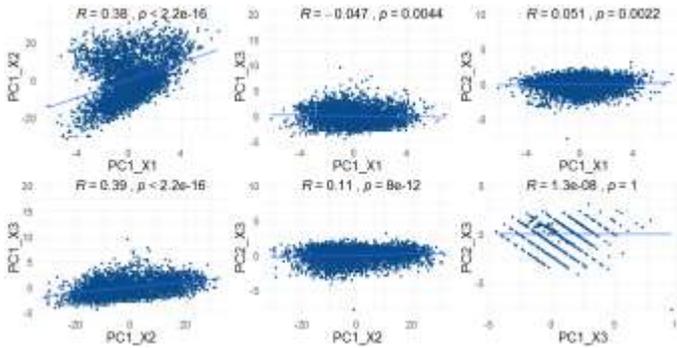
Lampiran 28. *Output R* Korelasi & Signifikansi antar Unsur Iklim
Korelasi & Signifikansi antar Unsur Iklim



Lampiran 28. *Output R Korelasi & Signifikansi antar Unsur Iklim*
 Korelasi & Signifikansi antar Unsur Iklim [lanjutan]

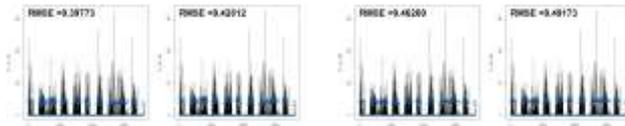


Lampiran 28. *Output R Korelasi & Signifikansi antar Unsur Iklim*
Korelasi & Signifikansi antar Unsur Iklim [lanjutan]



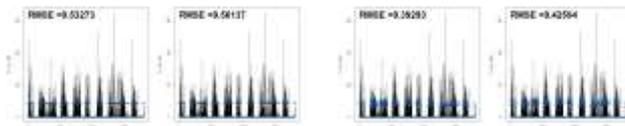
Lampiran 29. Plot Prediksi $CH_{1,t}$ (NA) & Prediktor Juanda

STASIUN JUANDA



$Y_1 \sim X_1$

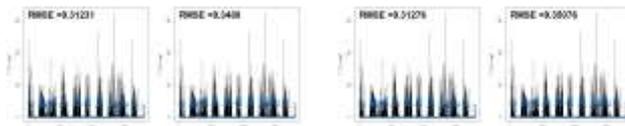
$Y_1 \sim X_2$



$Y_1 \sim X_3$

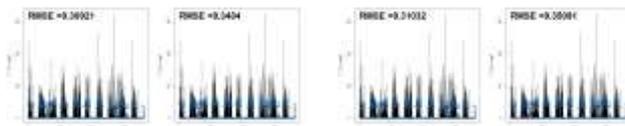
$Y_1 \sim X \leftrightarrow Y_1 \sim X_1 + X_2 + X_3$

STASIUN JUANDA + LAG



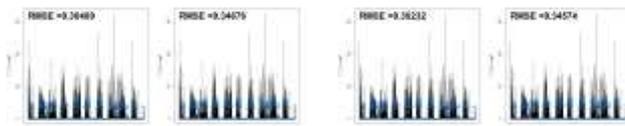
$Y_1 \sim X + \text{lag1}$

$Y_1 \sim X + \text{lag1} + \text{lag2}$



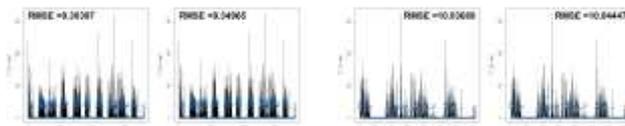
$Y_1 \sim X + \text{lag1} + \text{lag2} + \text{lag3}$

$Y_1 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag4}$



$Y_1 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag5}$

$Y_1 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag6}$

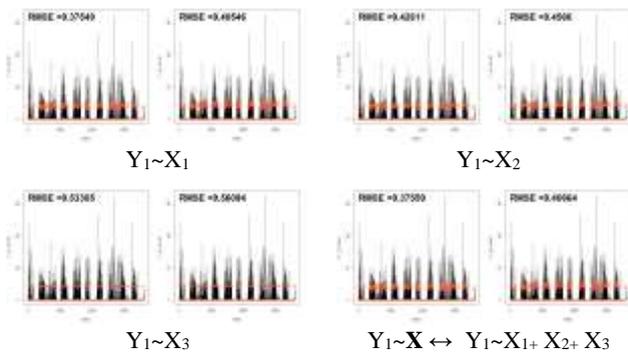


$Y_1 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag7}$

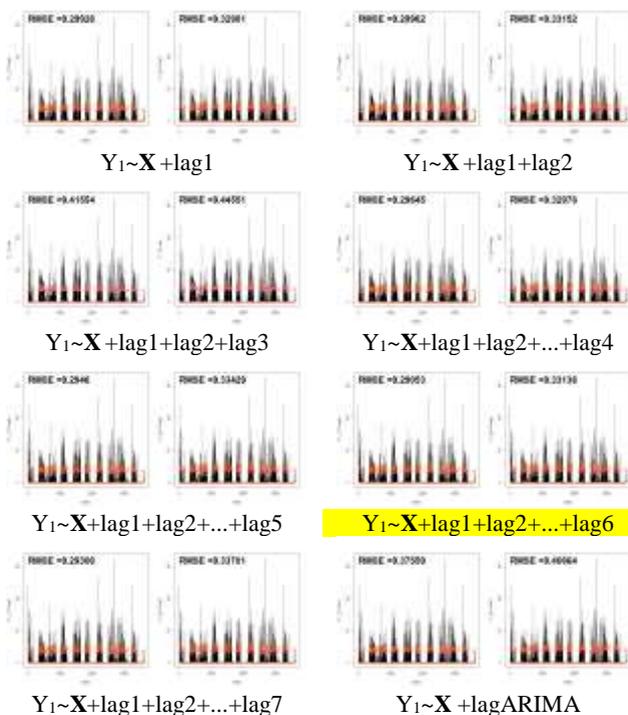
$Y_1 \sim X + \text{lagARIMA}$

Lampiran 30. Plot Prediksi $CH_{1,t}$ (NA) & Prediktor Perak2

STASIUN PERAK 2

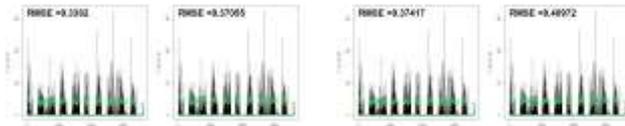


STASIUN PERAK 2 + LAG



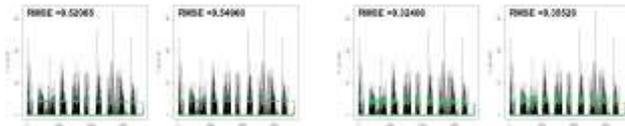
Lampiran 31. Plot Prediksi $CH_{1,t}$ (NA) & Prediktor Perak1

STASIUN PERAK 1



$Y_1 \sim X_1$

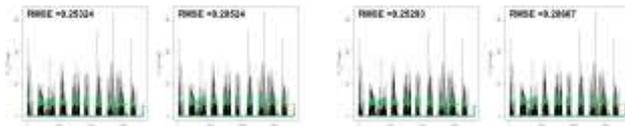
$Y_1 \sim X_2$



$Y_1 \sim X_3$

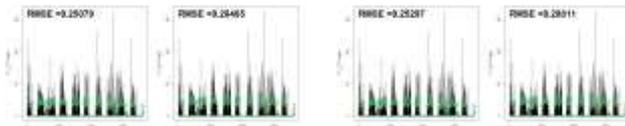
$Y_1 \sim X \leftrightarrow Y_1 \sim X_1 + X_2 + X_3$

STASIUN PERAK 1 + LAG



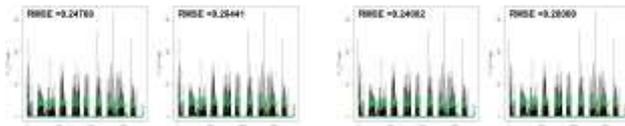
$Y_1 \sim X + \text{lag}1$

$Y_1 \sim X + \text{lag}1 + \text{lag}2$



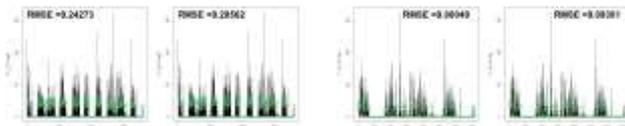
$Y_1 \sim X + \text{lag}1 + \text{lag}2 + \text{lag}3$

$Y_1 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}4$



$Y_1 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}5$

$Y_1 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}6$

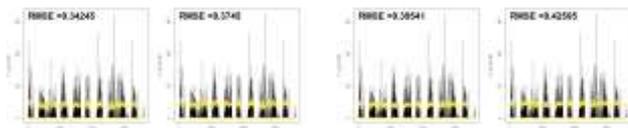


$Y_1 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}7$

$Y_1 \sim X + \text{lagARIMA}$

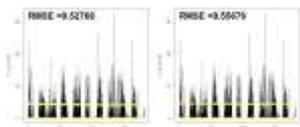
Lampiran 32. Plot Prediksi $CH_{1,t}$ (NA) & Prediktor PCA

PCA



$Y_1 \sim X_1$

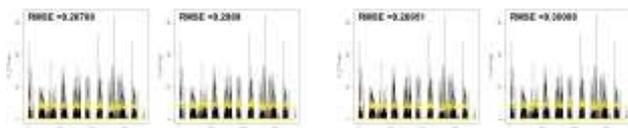
$Y_1 \sim X_2$



$Y_1 \sim X_3$

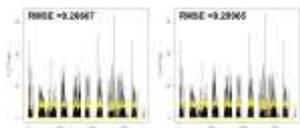
$Y_1 \sim X \leftrightarrow Y_1 \sim X_1 + X_2 + X_3$

PCA + LAG



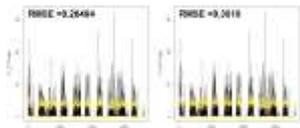
$Y_1 \sim X + \text{lag}1$

$Y_1 \sim X + \text{lag}1 + \text{lag}2$



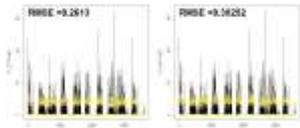
$Y_1 \sim X + \text{lag}1 + \text{lag}2 + \text{lag}3$

$Y_1 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}4$



$Y_1 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}5$

$Y_1 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}6$



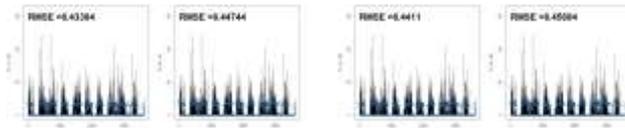
$Y_1 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}7$

$Y_1 \sim X + \text{lag}ARIMA$

$Y_1 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}6$

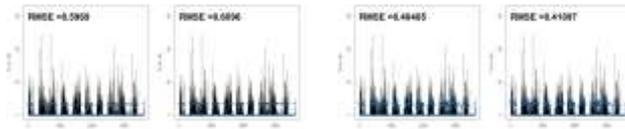
Lampiran 33. Plot Prediksi CH_2_t (NA) & Prediktor Juanda

STASIUN JUANDA



$Y_2 \sim X_1$

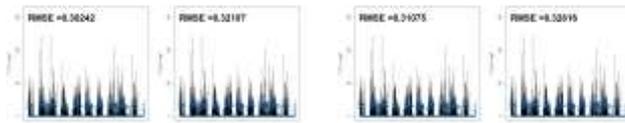
$Y_2 \sim X_2$



$Y_2 \sim X_3$

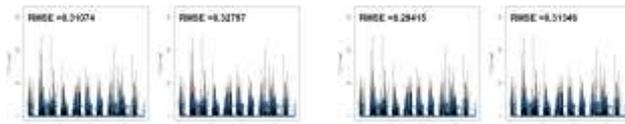
$Y_2 \sim X \leftrightarrow Y_2 \sim X_1 + X_2 + X_3$

STASIUN JUANDA + LAG



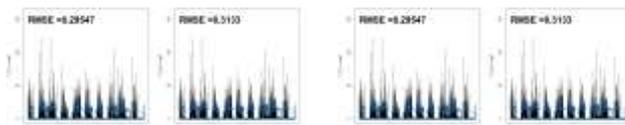
$Y_2 \sim X + \text{lag1}$

$Y_2 \sim X + \text{lag1} + \text{lag2}$



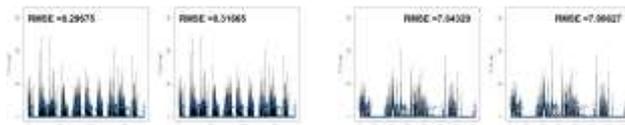
$Y_2 \sim X + \text{lag1} + \text{lag2} + \text{lag3}$

$Y_2 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag4}$



$Y_2 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag5}$

$Y_2 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag6}$

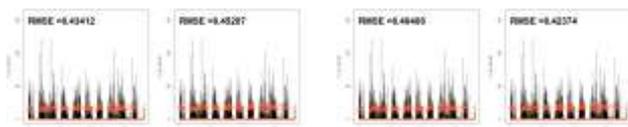


$Y_2 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag7}$

$Y_2 \sim X + \text{lagARIMA}$

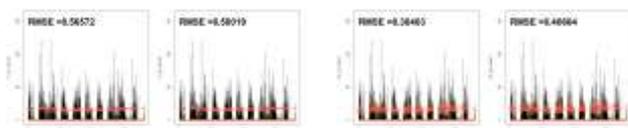
Lampiran 34. Plot Prediksi CH_{2,t} (NA) & Prediktor Perak2

STASIUN PERAK 2



$Y_2 \sim X_1$

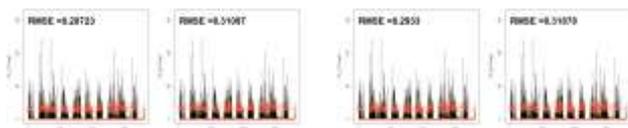
$Y_2 \sim X_2$



$Y_2 \sim X_3$

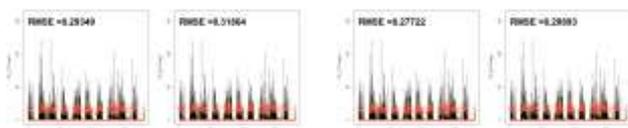
$Y_2 \sim X \leftrightarrow Y_2 \sim X_1 + X_2 + X_3$

STASIUN PERAK 2 + LAG



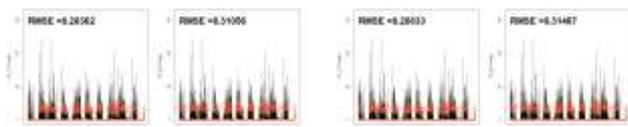
$Y_2 \sim X + \text{lag1}$

$Y_2 \sim X + \text{lag1} + \text{lag2}$



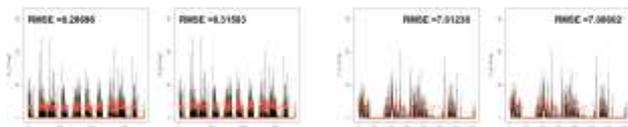
$Y_2 \sim X + \text{lag1} + \text{lag2} + \text{lag3}$

$Y_2 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag4}$



$Y_2 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag5}$

$Y_2 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag6}$

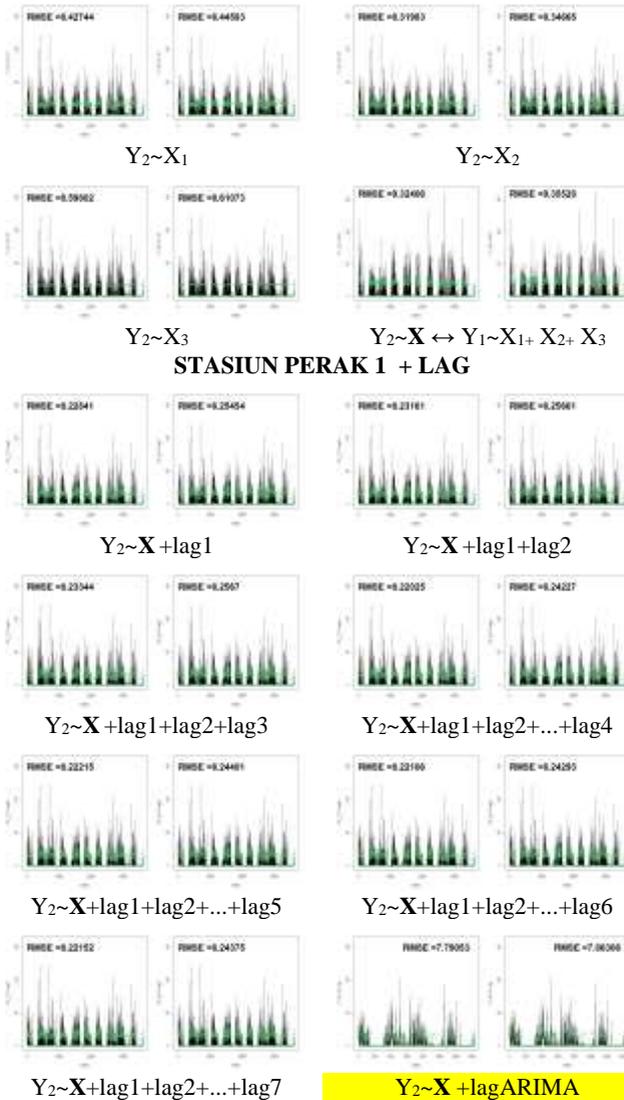


$Y_2 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag7}$

$Y_2 \sim X + \text{lagARIMA}$

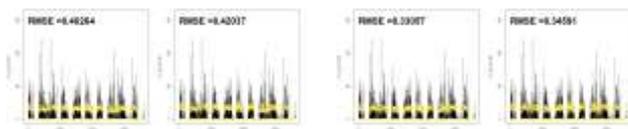
Lampiran 35. Plot Prediksi CH_{2,t} (NA) & Prediktor Perak 1

STASIUN PERAK 1



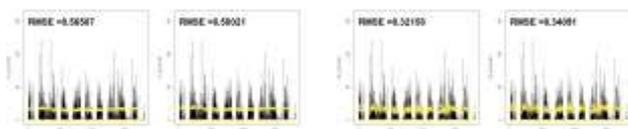
Lampiran 36. Plot Prediksi CH_{2,t} (NA) & Prediktor PCA

PCA



$Y_2 \sim X_1$

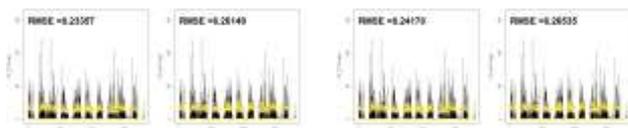
$Y_2 \sim X_2$



$Y_2 \sim X_3$

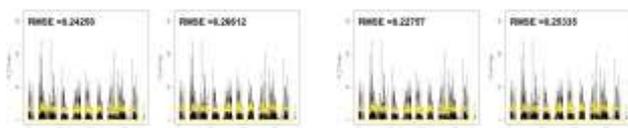
$Y_2 \sim X \leftrightarrow Y_1 \sim X_1 + X_2 + X_3$

PCA + LAG



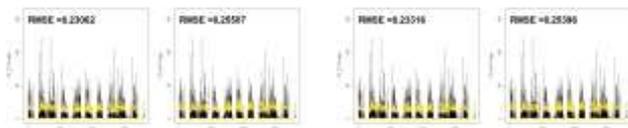
$Y_2 \sim X + \text{lag1}$

$Y_2 \sim X + \text{lag1} + \text{lag2}$



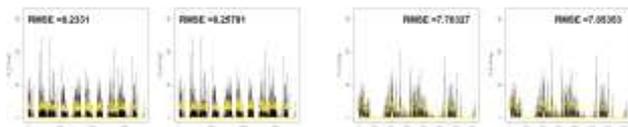
$Y_2 \sim X + \text{lag1} + \text{lag2} + \text{lag3}$

$Y_2 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag4}$



$Y_2 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag5}$

$Y_2 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag6}$

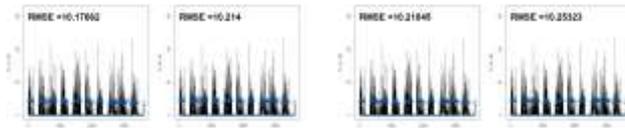


$Y_2 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag7}$

$Y_2 \sim X + \text{lagARIMA}$

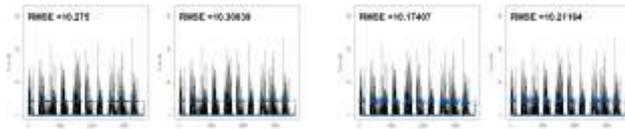
Lampiran 37. Plot Prediksi CH_3 ,_t (NA) & Prediktor Juanda

STASIUN JUANDA



$Y_3 \sim X_1$

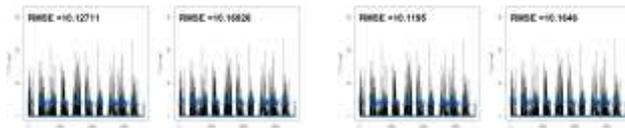
$Y_3 \sim X_2$



$Y_3 \sim X_3$

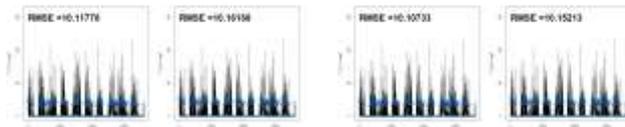
$Y_3 \sim X \leftrightarrow Y_3 \sim X_1 + X_2 + X_3$

STASIUN JUANDA + LAG



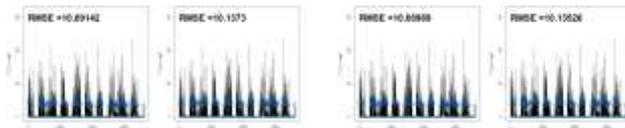
$Y_3 \sim X + \text{lag}1$

$Y_3 \sim X + \text{lag}1 + \text{lag}2$



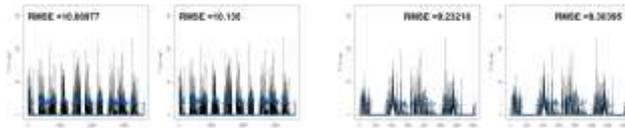
$Y_3 \sim X + \text{lag}1 + \text{lag}2 + \text{lag}3$

$Y_3 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}4$



$Y_3 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}5$

$Y_3 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}6$

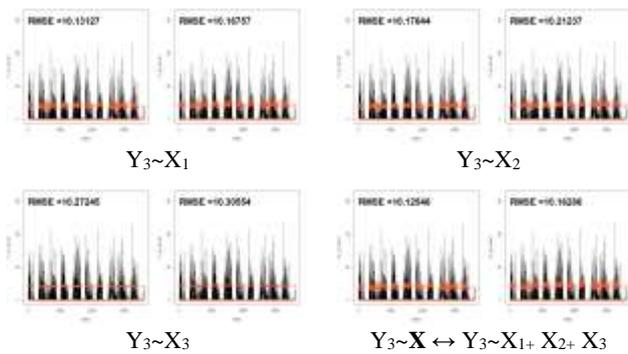


$Y_3 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}7$

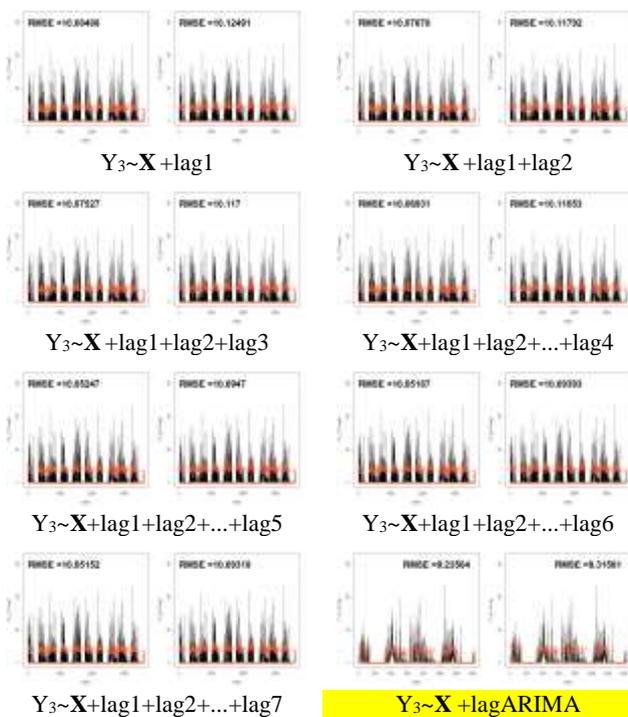
$Y_3 \sim X + \text{lagARIMA}$

Lampiran 38. Plot Prediksi CH_3, t (NA) & Prediktor Perak2

STASIUN PERAK 2

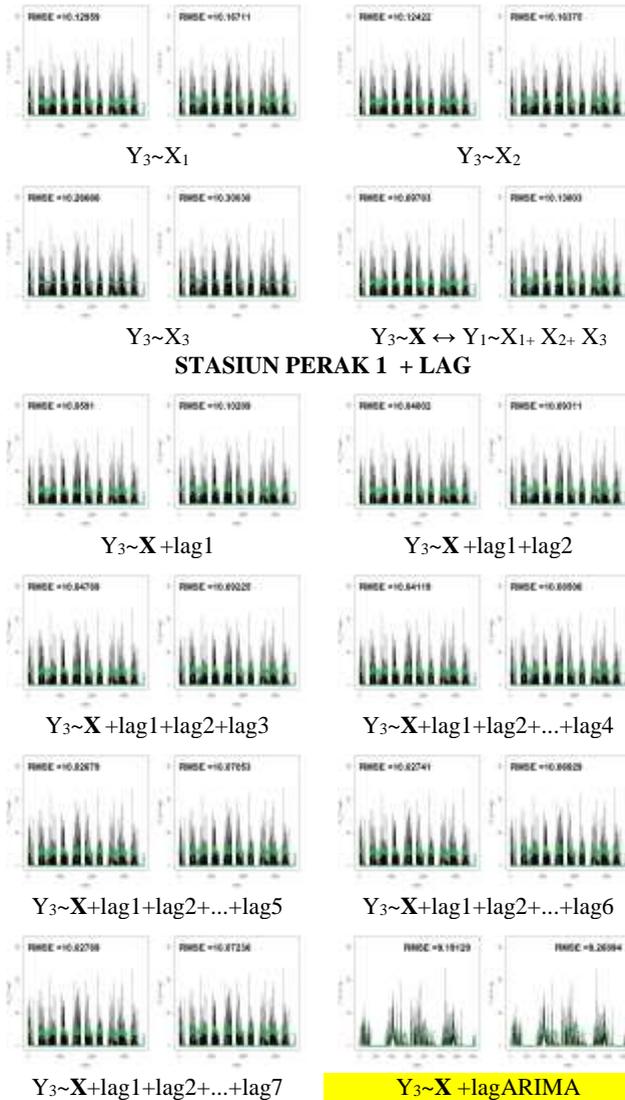


STASIUN PERAK 2 + LAG



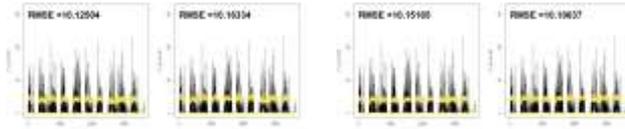
Lampiran 39. Plot Prediksi CH_3 ,_t (NA) & Prediktor Perak 1

STASIUN PERAK 1



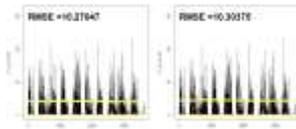
Lampiran 40. Plot Prediksi CH_{3,t} (NA) & Prediktor PCA

PCA



$Y_3 \sim X_1$

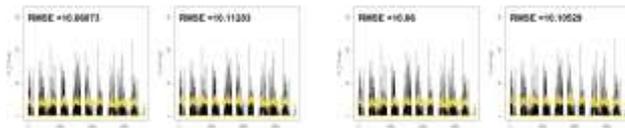
$Y_3 \sim X_2$



$Y_3 \sim X_3$

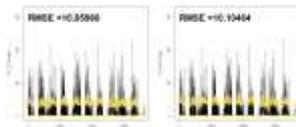
$Y_3 \sim X \leftrightarrow Y_3 \sim X_1 + X_2 + X_3$

PCA + LAG



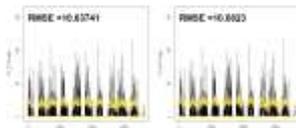
$Y_3 \sim X + \text{lag1}$

$Y_3 \sim X + \text{lag1} + \text{lag2}$



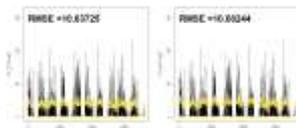
$Y_3 \sim X + \text{lag1} + \text{lag2} + \text{lag3}$

$Y_3 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag4}$



$Y_3 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag5}$

$Y_3 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag6}$

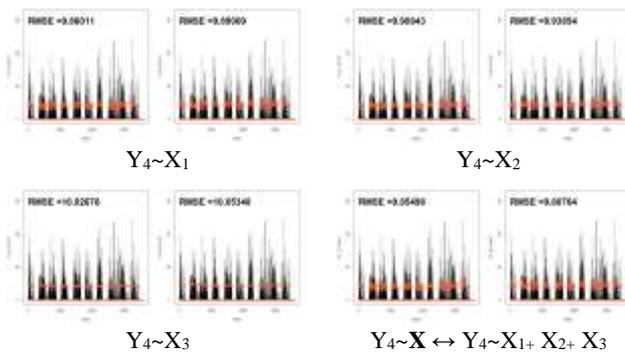


$Y_3 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag7}$

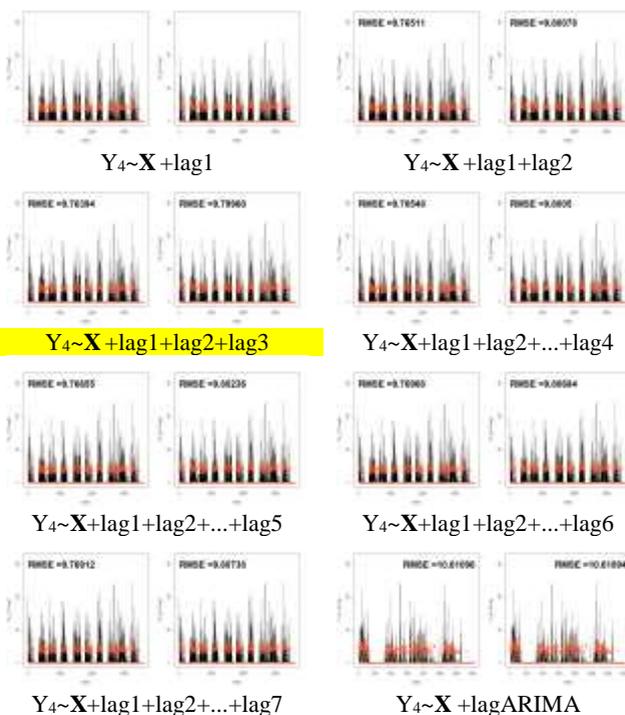
$Y_3 \sim X + \text{lagARIMA}$

Lampiran 42. Plot Prediksi CH_{4,t} (NA) & Prediktor Perak2

STASIUN PERAK 2

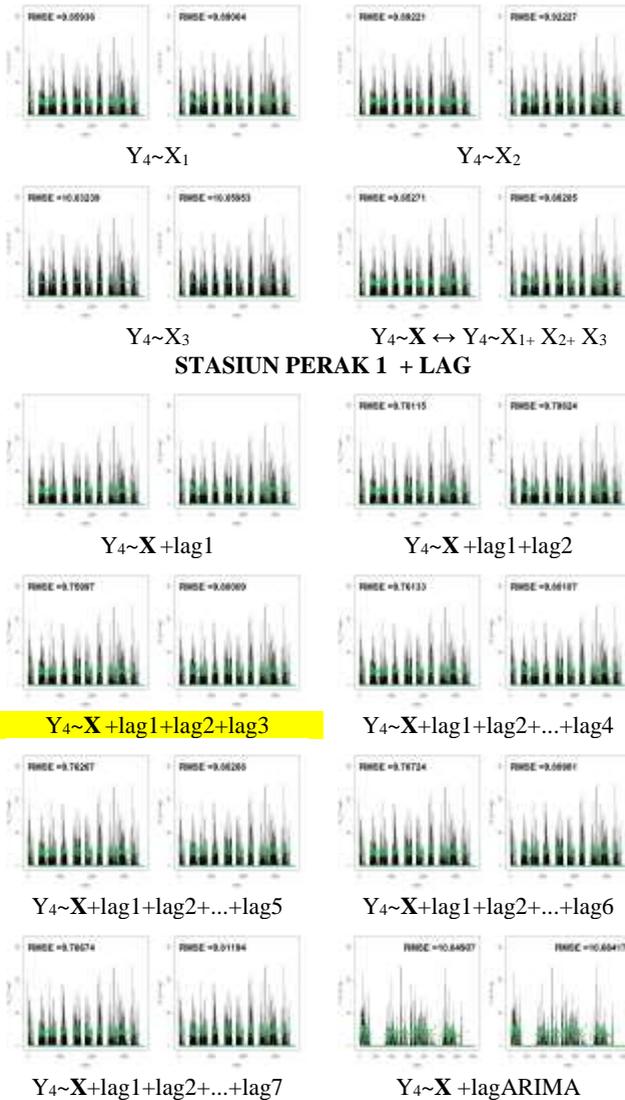


STASIUN PERAK 2 + LAG



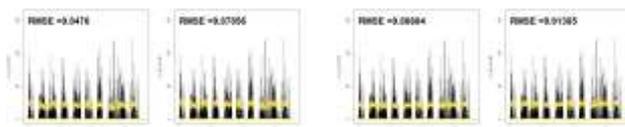
Lampiran 43. Plot Prediksi $\text{CH}_{4,t}$ (NA) & Prediktor Perak1

STASIUN PERAK 1



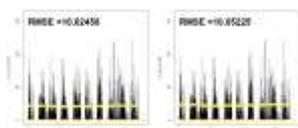
Lampiran 44. Plot Prediksi CH_{4,t} (NA) & Prediktor PCA

PCA

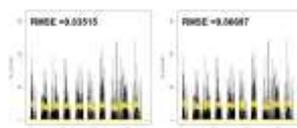


$Y_4 \sim X_1$

$Y_4 \sim X_2$

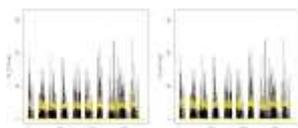


$Y_4 \sim X_3$



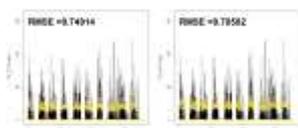
$Y_4 \sim X \leftrightarrow Y_4 \sim X_1 + X_2 + X_3$

PCA + LAG

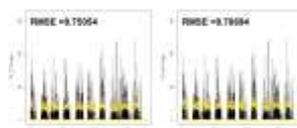


$Y_4 \sim X + \text{lag1}$

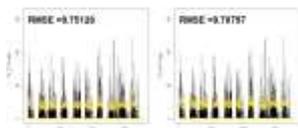
$Y_4 \sim X + \text{lag1} + \text{lag2}$



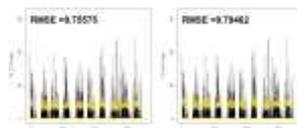
$Y_4 \sim X + \text{lag1} + \text{lag2} + \text{lag3}$



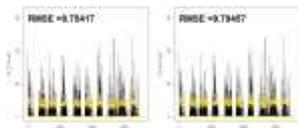
$Y_4 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag4}$



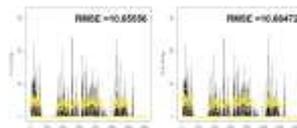
$Y_4 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag5}$



$Y_4 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag6}$



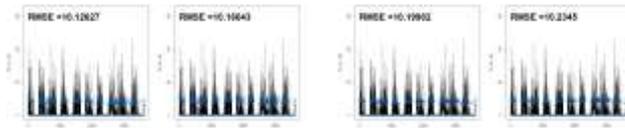
$Y_4 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag7}$



$Y_4 \sim X + \text{lagARIMA}$

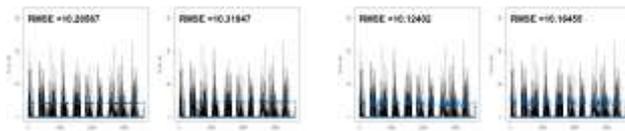
Lampiran 45. Plot Prediksi $CH_{5,t}$ (NA) & Prediktor Juanda

STASIUN JUANDA



$Y_5 \sim X_1$

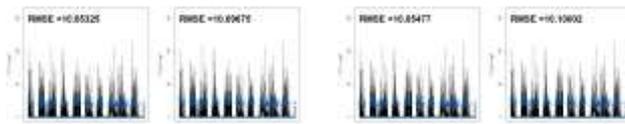
$Y_5 \sim X_2$



$Y_5 \sim X_3$

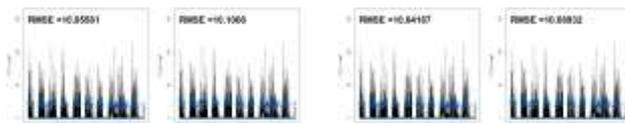
$Y_5 \sim X \leftrightarrow Y_5 \sim X_1 + X_2 + X_3$

STASIUN JUANDA + LAG



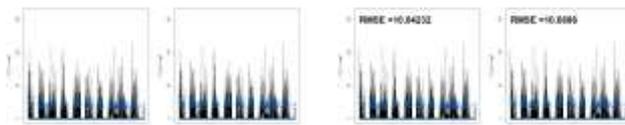
$Y_5 \sim X + \text{lag}1$

$Y_5 \sim X + \text{lag}1 + \text{lag}2$



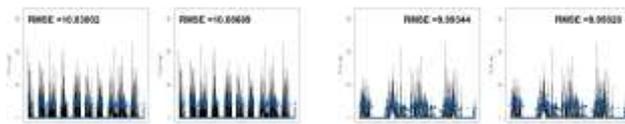
$Y_5 \sim X + \text{lag}1 + \text{lag}2 + \text{lag}3$

$Y_5 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}4$



$Y_5 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}5$

$Y_5 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}6$

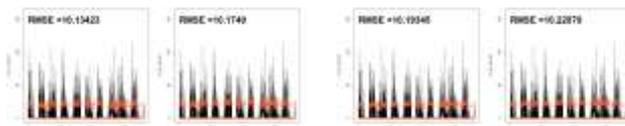


$Y_5 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}7$

$Y_5 \sim X + \text{lagARIMA}$

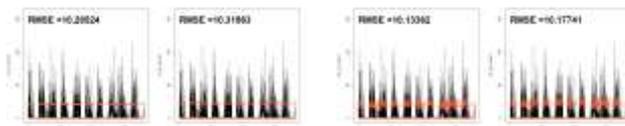
Lampiran 46. Plot Prediksi CH_{5,t} (NA) & Prediktor Perak2

STASIUN PERAK 2



$Y_5 \sim X_1$

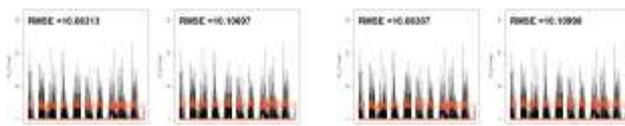
$Y_5 \sim X_2$



$Y_5 \sim X_3$

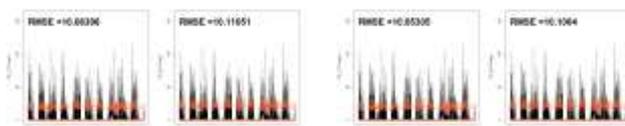
$Y_5 \sim X \leftrightarrow Y_5 \sim X_1 + X_2 + X_3$

STASIUN PERAK 2 + LAG



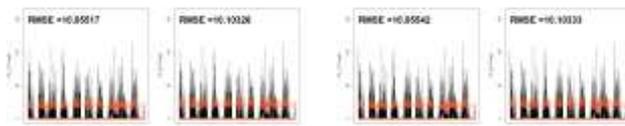
$Y_5 \sim X + \text{lag}1$

$Y_5 \sim X + \text{lag}1 + \text{lag}2$



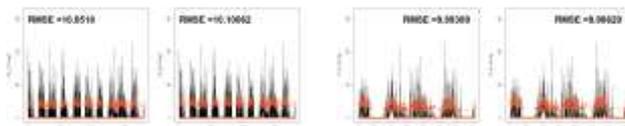
$Y_5 \sim X + \text{lag}1 + \text{lag}2 + \text{lag}3$

$Y_5 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}4$



$Y_5 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}5$

$Y_5 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}6$

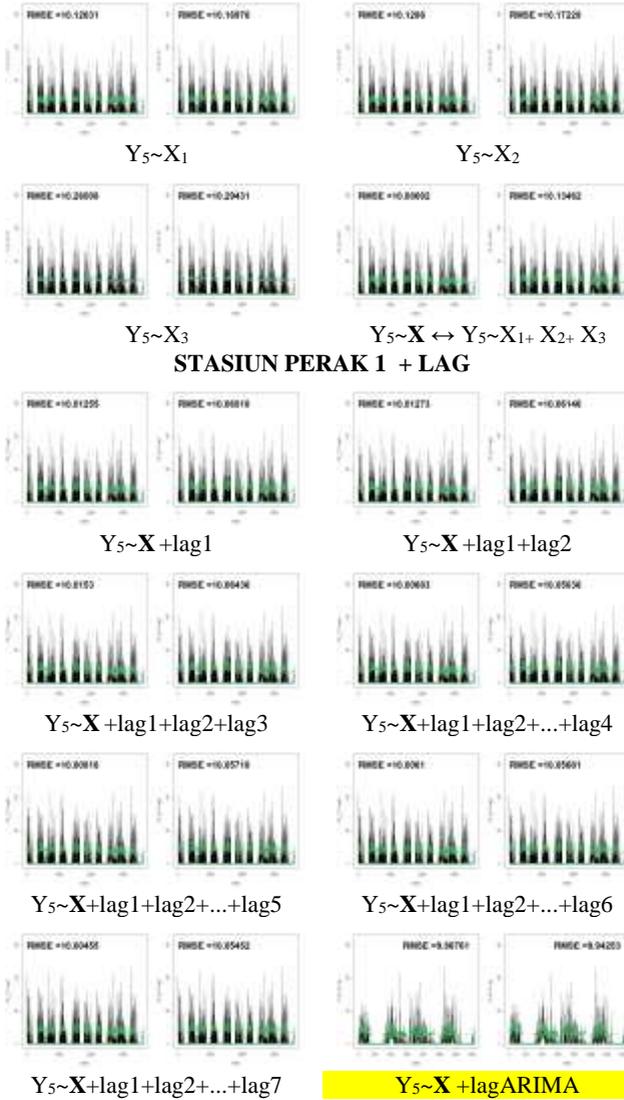


$Y_5 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}7$

$Y_5 \sim X + \text{lagARIMA}$

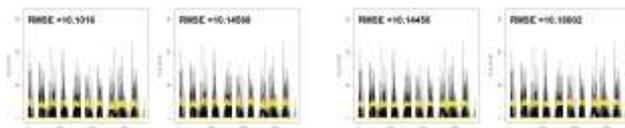
Lampiran 47. Plot Prediksi $\text{CH}_{5,t}$ (NA) & Prediktor Perak 1

STASIUN PERAK 1



Lampiran 48. Plot Prediksi CH_{5,t} (NA) & Prediktor PCA

PCA

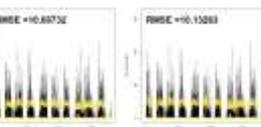


$Y_5 \sim X_1$

$Y_5 \sim X_2$

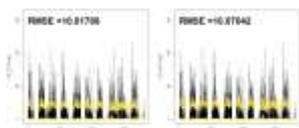


$Y_5 \sim X_3$



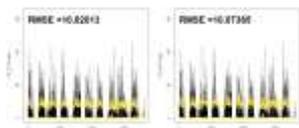
$Y_5 \sim X \leftrightarrow Y_5 \sim X_1 + X_2 + X_3$

PCA + LAG



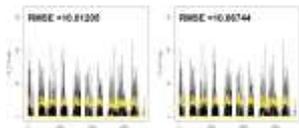
$Y_5 \sim X + \text{lag}1$

$Y_5 \sim X + \text{lag}1 + \text{lag}2$



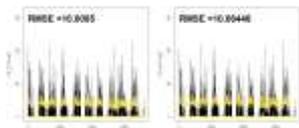
$Y_5 \sim X + \text{lag}1 + \text{lag}2 + \text{lag}3$

$Y_5 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}4$



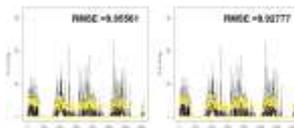
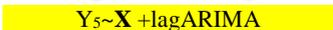
$Y_5 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}5$

$Y_5 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}6$



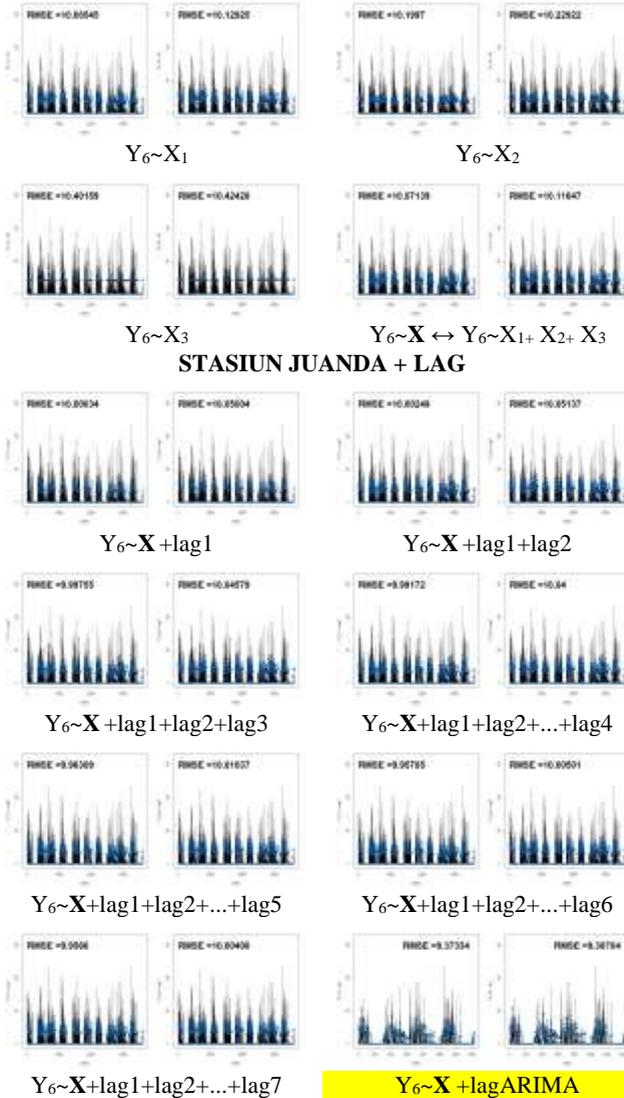
$Y_5 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}7$

$Y_5 \sim X + \text{lagARIMA}$



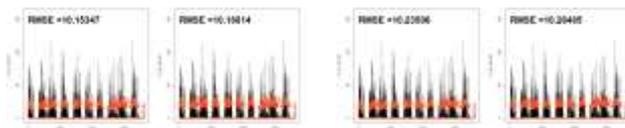
Lampiran 49. Plot Prediksi $CH_{6,t}$ (NA) & Prediktor Juanda

STASIUN JUANDA



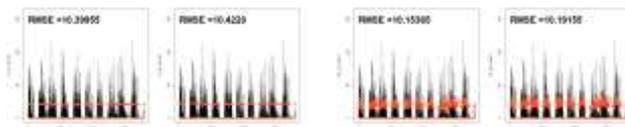
Lampiran 50. Plot Prediksi CH_{6,t} (NA) & Prediktor Perak2

STASIUN PERAK 2



$Y_6 \sim X_1$

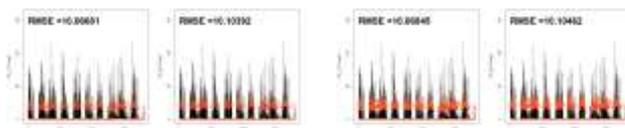
$Y_6 \sim X_2$



$Y_6 \sim X_3$

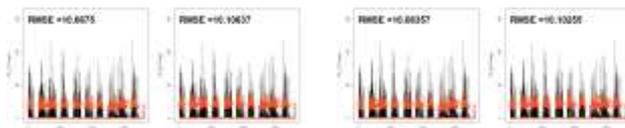
$Y_6 \sim X \leftrightarrow Y_6 \sim X_1 + X_2 + X_3$

STASIUN PERAK 2 + LAG



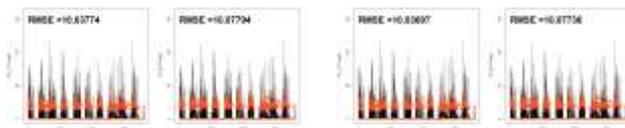
$Y_6 \sim X + \text{lag}1$

$Y_6 \sim X + \text{lag}1 + \text{lag}2$



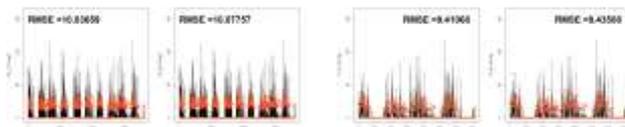
$Y_6 \sim X + \text{lag}1 + \text{lag}2 + \text{lag}3$

$Y_6 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}4$



$Y_6 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}5$

$Y_6 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}6$

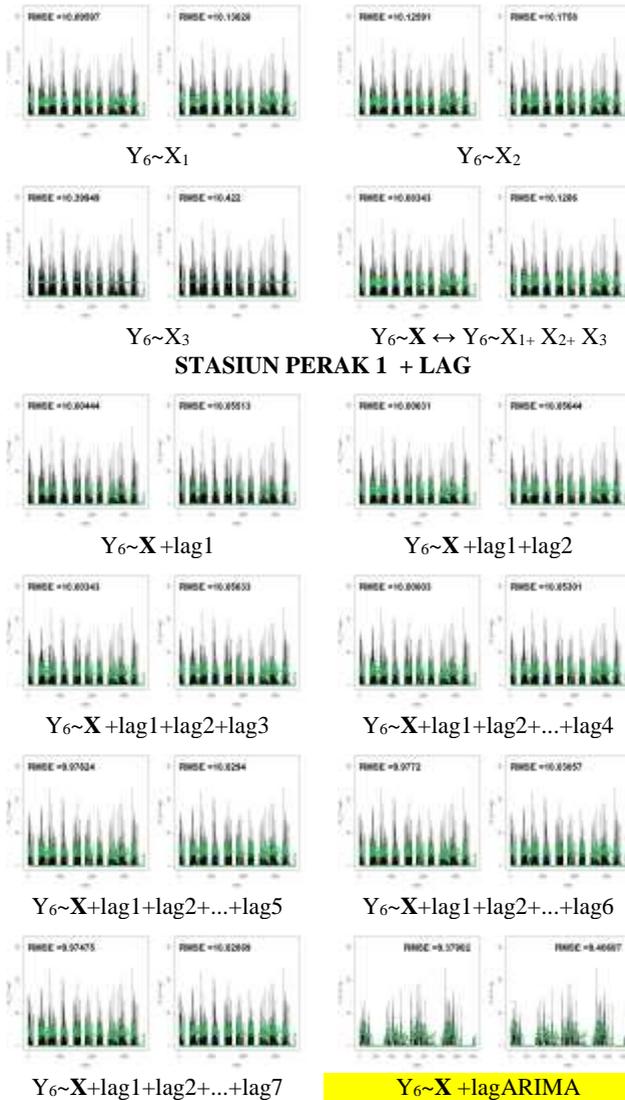


$Y_6 \sim X + \text{lag}1 + \text{lag}2 + \dots + \text{lag}7$

$Y_6 \sim X + \text{lagARIMA}$

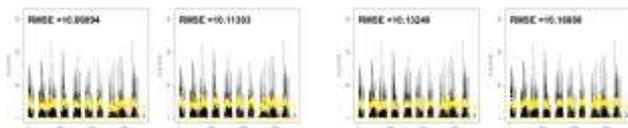
Lampiran 51. Plot Prediksi CH_{6,t} (NA) & Prediktor Perak 1

STASIUN PERAK 1



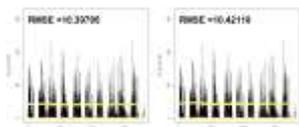
Lampiran 52. Plot Prediksi CH_{6,t} (NA) & Prediktor PCA

PCA

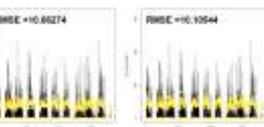


$Y_6 \sim X_1$

$Y_6 \sim X_2$

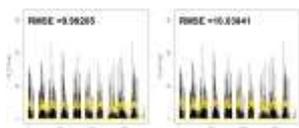


$Y_6 \sim X_3$



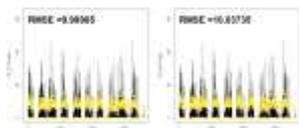
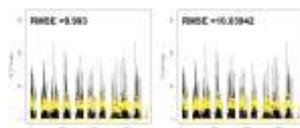
$Y_6 \sim X \leftrightarrow Y_6 \sim X_1 + X_2 + X_3$

PCA + LAG



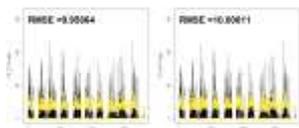
$Y_6 \sim X + \text{lag1}$

$Y_6 \sim X + \text{lag1} + \text{lag2}$



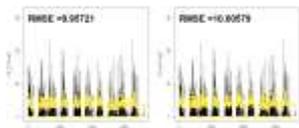
$Y_6 \sim X + \text{lag1} + \text{lag2} + \text{lag3}$

$Y_6 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag4}$



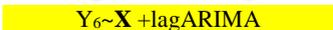
$Y_6 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag5}$

$Y_6 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag6}$

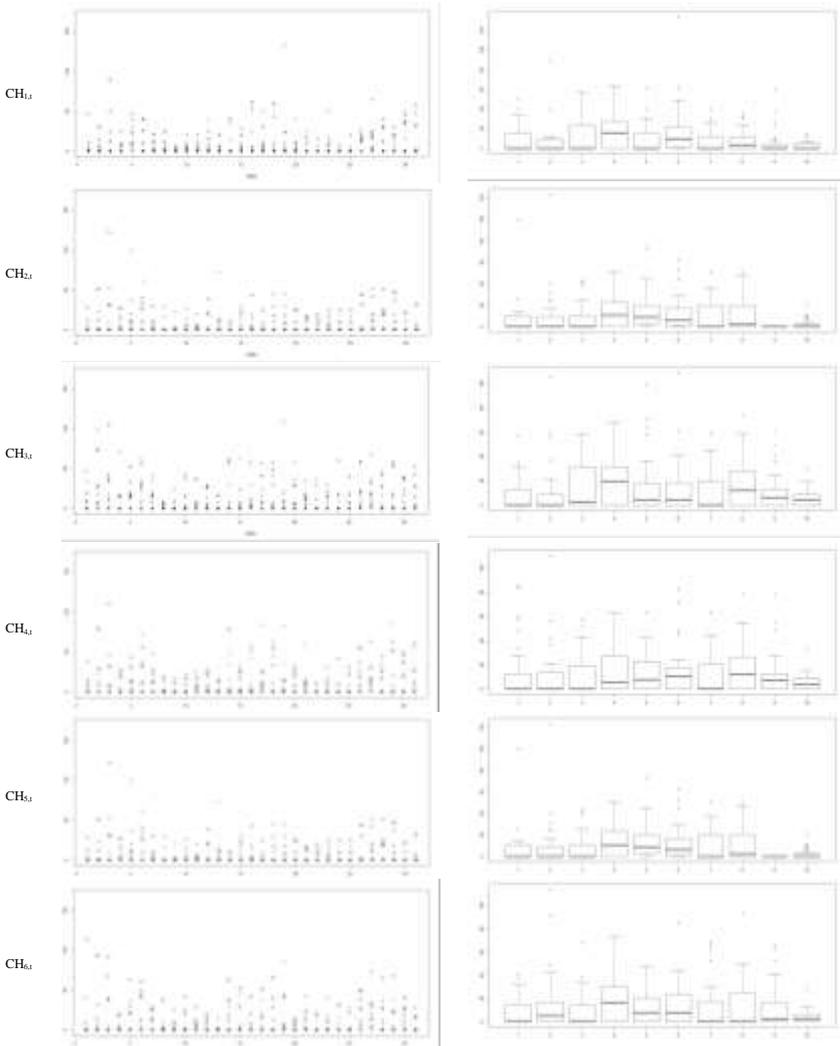


$Y_6 \sim X + \text{lag1} + \text{lag2} + \dots + \text{lag7}$

$Y_6 \sim X + \text{lagARIMA}$



Lampiran 53. Plot & Boxplot Harian CH 6 Balai PSAWS (Bulan Desember Selama 10 Tahun)



Lampiran 54. Estimasi & Signifikansi Parameter pada Model Terbaik

KEPUTIH					
Coefficients marginal model:					
	Estimate	Std. Error	z value	Pr(> z)	
(Intercept)	24.2667179	0.0008045	30164.128	< 2e-16	***
P1_X1	-0.6005093	0.0323516	-18.562	< 2e-16	***
P1_X2	-0.0350250	0.0116497	-3.007	0.00264	**
P1_X3	-0.3256304	0.1391096	-2.341	0.01924	*
Y1.lag1	0.0209411	0.0075153	2.786	0.00533	**
Y1.lag365	0.0056963	0.0070734	0.805	0.42064	
Y1.lag366	-0.0008456	0.0065962	-0.128	0.89799	
Y1.lag730	0.0010142	0.0061678	0.164	0.86939	
Y1.lag731	0.0012893	0.0056159	0.230	0.81842	
Y1.lag1095	0.0108380	0.0059378	1.825	0.06796	.
Y1.lag1096	-0.0065855	0.0054097	-1.217	0.22347	
Y1.lag1460	0.0026831	0.0067709	0.396	0.69191	
Y1.lag1461	0.0017928	0.0069477	0.258	0.79637	
Y1.lag1825	-0.0123280	0.0070500	-1.749	0.08035	.
Y1.lag1826	-0.0046852	0.0062430	-0.750	0.45297	
Y1.lag2190	0.0042830	0.0082452	0.519	0.60344	
Y1.lag2191	0.0062974	0.0079753	0.790	0.42975	
shape	1.1969422	0.0765555	15.635	< 2e-16	***
log likelihood = 1518.8, AIC = 3073.5					
KEDUNG COWEK					
Coefficients marginal model:					
	Estimate	Std. Error	z value	Pr(> z)	
(Intercept)	3.5882867	0.2473002	14.510	< 2e-16	***
PC1_X1	-0.1010794	0.0888830	-1.137	0.255447	
PC1_X2	-0.0276694	0.0205471	-1.347	0.178099	
PC1_X3	0.1003179	0.0785758	1.277	0.201707	
PC2_X3	0.0767822	0.1177050	0.652	0.514190	
Y2.lag1	0.0253898	0.0067817	3.744	0.000181	***
Y2.lag365	0.0138696	0.0072828	1.904	0.056852	.
Y2.lag366	0.0056940	0.0053984	1.055	0.291536	
Y2.lag730	0.0012005	0.0069419	0.173	0.862703	
Y2.lag731	-0.0143292	0.0062975	-2.275	0.022882	*
Y2.lag1095	0.0060285	0.0064119	0.940	0.347113	
Y2.lag1096	-0.0078095	0.0070308	-1.111	0.266673	

Y2.lag1460	-0.0091058	0.0059665	-1.526	0.126967	
Y2.lag1461	0.0156510	0.0086253	1.815	0.069595	.
Y2.lag1825	-0.0090272	0.0058873	-1.533	0.125198	
Y2.lag1826	0.0118755	0.0061053	1.945	0.051761	.
Y2.lag2190	-0.0004285	0.0056437	-0.076	0.939478	
Y2.lag2191	0.0080528	0.0055733	1.445	0.148487	
shape	1.2955129	0.0484323	26.749	< 2e-16	***
log likelihood = 1579.6, AIC = 3197.3					
GUBENG					
Coefficients marginal model:					
	Estimate	Std. Error	z value	Pr(> z)	
(Intercept)	3.8104621	0.2144233	17.771	< 2e-16	***
PC1_X1	-0.2059772	0.0792390	-2.599	0.00934	**
PC1_X2	-0.0005645	0.0181091	-0.031	0.97513	
PC1_X3	0.0278798	0.0697944	0.399	0.68956	
PC2_X3	0.2098523	0.1067264	1.966	0.04927	*
Y3.lag1	0.0095921	0.0049896	1.922	0.05455	.
Y3.lag365	-0.0007599	0.0046696	-0.163	0.87073	
Y3.lag366	0.0093740	0.0057092	1.642	0.10061	
Y3.lag730	-0.0048459	0.0041834	-1.158	0.24672	
Y3.lag731	0.0035838	0.0048656	0.737	0.46139	
Y3.lag1095	0.0036175	0.0044436	0.814	0.41560	
Y3.lag1096	0.0023271	0.0048154	0.483	0.62890	
Y3.lag1460	0.0048224	0.0043663	1.104	0.26939	
Y3.lag1461	0.0116667	0.0054840	2.127	0.03338	*
Y3.lag1825	-0.0019081	0.0042787	-0.446	0.65564	
Y3.lag1826	-0.0053518	0.0042344	-1.264	0.20627	
Y3.lag2190	-0.0062628	0.0039103	-1.602	0.10924	
Y3.lag2191	0.0099108	0.0053874	1.840	0.06582	.
shape	1.8106844	0.1068003	16.954	< 2e-16	***
log likelihood = 1867.8, AIC = 3773.6					
WONOREJO					
Coefficients marginal model:					
	Estimate	Std. Error	z value	Pr(> z)	
(Intercept)	4.2270281	0.3005263	14.065	<2e-16	***
PC1_X1	-0.2797781	0.1122710	-2.492	0.0127	*
PC1_X2	0.0094270	0.0258774	0.364	0.7156	
PC1_X3	-0.1200276	0.1037710	-1.157	0.2474	

PC2_x3	0.0832111	0.1828067	0.455	0.6490	
Y4.lag1	0.0163742	0.0066679	2.456	0.0141	*
Y4.lag365	0.0085066	0.0068724	1.238	0.2158	
Y4.lag366	-0.0092557	0.0055401	-1.671	0.0948	.
Y4.lag730	0.0041704	0.0071849	0.580	0.5616	
Y4.lag731	0.0054017	0.0073499	0.735	0.4624	
Y4.lag1095	-0.0007603	0.0058012	-0.131	0.8957	
Y4.lag1096	-0.0019039	0.0056600	-0.336	0.7366	
Y4.lag1460	-0.0047368	0.0066652	-0.711	0.4773	
Y4.lag1461	0.0014632	0.0074110	0.197	0.8435	
Y4.lag1825	-0.0129827	0.0060254	-2.155	0.0312	*
Y4.lag1826	0.0016353	0.0064691	0.253	0.8004	
Y4.lag2190	-0.0002658	0.0069720	-0.038	0.9696	
Y4.lag2191	-0.0064086	0.0080357	-0.798	0.4252	
shape	1.2628243	0.0799762	15.790	<2e-16	***
log likelihood = 1598.5, AIC = 3235					
WONOKROMO					
Coefficients marginal model:					
	Estimate	Std. Error	z value	Pr(> z)	
(Intercept)	3.539e+00	2.138e-01	16.550	<2e-16	***
PC1_x1	-1.802e-01	8.112e-02	-2.222	0.0263	*
PC1_x2	-1.022e-02	1.830e-02	-0.559	0.5764	
PC1_x3	-1.239e-03	7.940e-02	-0.016	0.9875	
PC2_x3	1.461e-01	1.133e-01	1.289	0.1973	
Y5.lag1	7.631e-03	5.386e-03	1.417	0.1566	
Y5.lag365	-4.585e-04	5.637e-03	-0.081	0.9352	
Y5.lag366	6.565e-03	6.161e-03	1.066	0.2866	
Y5.lag730	-4.439e-03	5.008e-03	-0.886	0.3754	
Y5.lag731	-9.431e-05	5.513e-03	-0.017	0.9864	
Y5.lag1095	5.933e-03	5.275e-03	1.125	0.2607	
Y5.lag1096	-9.910e-03	4.872e-03	-2.034	0.0420	*
Y5.lag1460	4.612e-03	5.337e-03	0.864	0.3876	
Y5.lag1461	7.498e-03	6.135e-03	1.222	0.2217	
Y5.lag1825	8.276e-03	4.976e-03	1.663	0.0963	.
Y5.lag1826	9.763e-03	5.161e-03	1.892	0.0585	.
Y5.lag2190	8.623e-03	4.711e-03	1.830	0.0672	.
Y5.lag2191	9.653e-03	4.814e-03	2.005	0.0449	*
shape	1.545e+00	8.994e-02	17.175	<2e-16	***

log likelihood = 1888.3, AIC = 3814.6					
GUNUNG SARI					
Coefficients marginal model:					
	Estimate	Std. Error	z value	Pr(> z)	
(Intercept)	3.4278410	0.2550158	13.442	< 2e-16	***
PC1_X1	-0.3130962	0.0917932	-3.411	0.000648	***
PC1_X2	0.0070633	0.0197174	0.358	0.720175	
PC1_X3	-0.1233197	0.0881385	-1.399	0.161765	
PC2_X3	0.0465224	0.1244063	0.374	0.708437	
Y6.lag1	0.0168183	0.0063013	2.669	0.007607	**
Y6.lag365	0.0001377	0.0061766	0.022	0.982208	
Y6.lag366	-0.0017042	0.0058122	-0.293	0.769359	
Y6.lag730	0.0033336	0.0064665	0.516	0.606192	
Y6.lag731	0.0011925	0.0058182	0.205	0.837602	
Y6.lag1095	0.0065502	0.0057506	1.139	0.254684	
Y6.lag1096	0.0034131	0.0056291	0.606	0.544298	
Y6.lag1460	0.0133229	0.0069310	1.922	0.054580	.
Y6.lag1461	0.0059830	0.0059820	1.000	0.317230	
Y6.lag1825	0.0072426	0.0050422	1.436	0.150886	
Y6.lag1826	-0.0048397	0.0043702	-1.107	0.268105	
Y6.lag2190	0.0052381	0.0052506	0.998	0.318458	
Y6.lag2191	0.0187032	0.0059465	3.145	0.001660	***
shape	1.1992986	0.0430894	27.833	< 2e-16	***
log likelihood = 1734.3, AIC = 3506.5					

Lampiran 55. Syntax R GCMR

```

library(gcmr)

#Model dengan Menggunakan Marginal Gamma
MODEL <- gcmr
  (formula = CH ~ PREDIKTOR,
   data = MY_DATA,
   marginal = Gamma.marg(link = "sqrt"),
   cormat = arma.cormat(0,0))
#Model dengan Menggunakan Marginal Weibull
MODEL <- gcmr
  (formula = CH ~ PREDIKTOR,
   data = MY_DATA,
   marginal = weibull.marg(link = "sqrt"),
   cormat = arma.cormat(0,0))

#Plot Prediksi & Aktual (RMSE)
win.graph()
par(mfrow = c(1, 2))
plot(AKTUAL, type = "l", ylab = "GAMMA")
points(pch = 19, FITT_MODEL, col="#f1605d")
text(550, 160, font = 2, adj = 0, cex = 2.6,
     paste0(
       "RMSE =", round(RMSE(FITT_MODEL, AKTUAL), 5)))

# Plot Prediksi & Aktual (RMSE)
win.graph()
par (mgp=c(2.6,1,0))
plot (DATA$AKTUAL, type = "l", xlab = "Hari ke-", ylab
      = "CH", ylim=c(0,164), lwd = 2, cex.axis = 2,
      cex.lab=1.5, cex = 3)
lines (lwd = 2, PRED.Y1_G_P1.lag, col="#41ab5d" )
points(pch = 19, PRED.Y1_G_P1.lag, col="#41ab5d" )
text (13, 145, font = 2, adj = 0, cex =
      2.6, paste0("RMSE=", round(RMSE(DATA$AKTUAL], MODEL
      PREDIKSI), 5)))
legend(11, 155, legend=c("AKTUAL", "PREDIKSI"),
      col=c("black", "#41ab5d"), box.lty=0, lty=1:1,
      cex=1, text.font=2, horiz=TRUE, lwd = 3,
      x.intersp=0.1, xjust=0, yjust=0, text.width = 2)

```

Lampiran 56. Banjir Prediksi di 5 Rayon

No	Saluran	Q Hidrolika	Q Hidrologi	Status
GUBENG				
1	Gading	1,259	20.09	OK
2	Jeblokan	1,462	18.98	OK
3	Kenjeran AL	1,462	21.60	OK
4	Kenjeran Lama	2,494	21.51	OK
5	Kenjeran Pantai Ria	750	21.31	OK
6	Pegirian	4,355	17.28	OK
7	HKSN / Kalijudan	12	32.78	BANJIR
8	Jeblokan	1,259	18.75	OK
9	Juwingan	230	22.25	OK
10	Kalibokor	4,022	17.18	OK
11	Kalidami	18,127	22.39	OK
12	Kalijudan	117	26.01	OK
13	Kalisari THR	78	23.22	OK
14	Kalisari Timur	117	33.72	OK
15	Kamboja	78	22.84	OK
16	Kampung Seng	157	22.17	OK
17	Kapas Madya	1,462	22.62	OK
18	Kedung Sroko	303	22.89	OK
19	Kedung Tarukan	2,494	23.56	OK
20	Kertajaya Viaduck	303	25.24	OK
21	laban Sari	303	34.57	OK
22	Larangan	899	35.84	OK
23	Manyar Kertoadi	117	31.98	OK
24	Manyar Sabrangan	117	33.27	OK
25	Menur	230	22.79	OK
26	Mojo	4	21.01	BANJIR
27	Mulyorejo	1,685	40.80	OK
28	Pacar	78	24.87	OK
29	Pucang Adi	48	23.25	OK
30	Pucang Jajar	169	21.69	OK
31	Pucang Rinenggo	26	22.31	OK
32	Putra Agung	899	22.20	OK
33	Ring Road ITS	495	34.13	OK
34	Simokerto / Donorejo	230	23.81	OK
35	Simolawang	117	24.25	OK
36	Slamet	48	22.05	OK
37	Srikana	117	21.90	OK
38	Sutorejo	48	31.38	OK

39	Tambaksari	78	19.78	OK
40	Tambak Segaran	611	22.24	OK
41	Sawah Pulo	78	23.68	OK
42	Sidoluhur dsk	5	21.14	BANJIR
43	Sidotopo Lor	750	23.42	OK
44	Sidotopo Wetan	109	16.83	OK
45	Tambak Wedi	12,196	19.95	OK
46	Tenggumung karya	12	17.14	BANJIR
47	Wonosari Lor	62	22.21	OK
GENTENG				
1	Wonorejo III - IV	25	24.75	OK
2	Jatisari	48	32.49	OK
3	Kedung Turi	5	24.50	BANJIR
4	Kedungsari	78	28.52	OK
5	Indrapura	245	32.40	OK
6	Rembang	303	32.50	OK
7	Pelemahan	80,132	35.30	OK
8	Jl.Semarang	15	24.39	BANJIR
9	Keputran	62	29.42	OK
10	Wonorejo I - II	65	30.66	OK
11	Sumber Mulyo	183	32.97	OK
12	Tembok Dukuh	4,305,760	36.82	OK
13	Jalan Opak	527,661	36.56	OK
14	Jepara	689	34.58	OK
15	Dupak Ps.Turi	106	30.61	OK
16	Kutilang PA.Pesapen	48,030	35.49	OK
17	Ronggolawe	96	28.50	OK
18	Mojopahit	22,440	33.85	OK
19	Bubutan	9	27.50	BANJIR
20	Embong Malang	18	29.78	BANJIR
21	Komering	62	34.95	OK
22	Petemon Kuburan	48	32.80	OK
23	Pregolan Bunder	26	27.62	BANJIR
24	Krembangan Jaya Sel	62	32.45	OK
25	Ikan Mungsing	62	30.35	OK
26	Juwono	117	33.05	OK
27	Embong Kemiri	26	27.62	BANJIR
28	Keputran	62	34.95	OK
29	Cempaka	62	34.28	OK
30	Ciliwung	78	32.14	OK
31	Ikan Cucut	62	30.11	OK

32	Anwari	117	31.61	OK
33	Sriwijaya	1,718	36.69	OK
34	Brawijaya	53	30.14	OK
35	Serayu	2,207	36.08	OK
36	Greges	4,355	28.05	OK
37	Kali Mas	24,573	25.95	OK
JAMBANGAN				
1	Kebon Agung	1,259	45.96	OK
2	Avoor Wonorejo	230	43.48	OK
3	Medokan Ayu	26	39.42	BANJIR
4	Dukuh Menanggal	169	41.89	OK
5	Gayungsari	394	41.92	OK
6	Gayung Kebonsari	48	37.52	OK
7	Wonokromo Tangkis	2,207	47.51	OK
8	Jetis Kulon	611	47.59	OK
9	Margorejo	443	44.79	OK
10	Bendul Merisi Timur	750	42.15	OK
11	Bendul Merisi Besar	78	40.70	OK
12	Tepi Jl. A. Yani	37	36.20	OK
13	Jemursari Prapen	96	39.02	OK
14	Jemur Wonosari	96	41.13	OK
15	Kutisari	169	42.73	OK
16	Sarono Jiwo	96	42.92	OK
17	Kali Rejo	169	42.20	OK
18	Kali Rungkut	5,751,773	50.82	OK
19	Tenggilis Mejoyo	26	39.42	BANJIR
20	Rungkut Kidul	169	41.89	OK
21	Rungkut Asri Lor	394	41.92	OK
22	Kedung Asem	48	37.52	OK
23	Penjaringan Sari	2,207	47.51	OK
24	Medokan Semampir	611	47.59	OK
25	Semolowaru	443	44.79	OK
26	Manyar	750	42.15	OK
27	Manyar Rejo	78	40.70	OK
28	Ngagel Wasono	37	36.20	OK
29	Kalisumo	96	39.02	OK
30	Ngagel Jaya Selatan	96	41.13	OK
31	Krukah	169	42.73	OK
WIYUNG				
1	Lidah wetan - Kulon	2,494	18.01	OK
2	Jeruk	2,207	15.54	OK

3	Babadan Indah	495	19.19	OK
4	Babadan Karang	230	22.32	OK
5	Wiyung	230	26.07	OK
6	Menganti	265	25.71	OK
7	Gemol Kedurus	349	22.81	OK
8	Gogor	26	24.45	OK
9	jajar Tunggal	26	24.04	OK
10	Gunung Sari	230	27.77	OK
11	Bogangin I	230	28.81	OK
12	Bogangin Baru	37	24.15	OK
13	Kebraon	349	22.27	OK
14	Kebraon Manis	62	29.51	OK
15	Prima Kebraon	62	27.31	OK
16	Pondok Maritim	265	26.25	OK
17	Karang Klumprik Barat	117	26.84	OK

BIODATA PENULIS



Penulis dengan nama lengkap Afifah Nur Iswari dilahirkan di Kota Padang pada 11 Juni 1997, yang memiliki hobi *travelling*. Penulis telah menempuh pendidikan formal di SDIT Adzkia Padang, SMP N 8 Padang dan SMA Insan Cendekia Madani Tangerang Selatan. Kemudian penulis diterima sebagai mahasiswi Statistika ITS melalui jalur mandiri pada tahun 2015 yang selanjutnya bergabung bersama keluarga besar VIVACIOUS Σ 26. Selama masa perkuliahan, penulis aktif di berbagai kepanitiaan dan organisasi tingkat jurusan maupun institut. Penulis bergabung pada organisasi UKM CLICK-ITS (Cinematography) sebagai Bendahara 2 pada tahun 2016 s.d 2017 dan melanjutkan sebagai Bendahara 1 hingga tahun 2018. Forum Studi Islam Statistika (FORSIS) sebagai staff dan ketua Departemen Media pada tahun 2016 s.d 2017. HIMASTA-ITS sebagai Kabiro Prestasi dan Apresiasi tahun 2017 s.d 2018. Dalam pengaplikasian ilmu statistika, penulis mengikuti beberapa kegiatan survei seperti MPM Honda dan SSH Kota Surabaya. Apabila pembaca ingin memberikan kritik dan saran serta diskusi lebih lanjut mengenai Tugas Akhir (TA) ini, dapat menghubungi penulis melalui e-mail afifah.nur.iswari@gmail.com.

(Halaman ini sengaja di kosongkan)