



TESIS - KS185411

**PEMODELAN INDEKS CURAH HUJAN EKSTREM
DENGAN PENDEKATAN GAMLSS
(Studi Kasus : Indeks RX5day dan CDD
di Provinsi Nusa Tenggara Timur)**

**FAUSANIA HIBATULLAH
06211850010015**

**Dosen Pembimbing
Dr. rer. pol. Heri Kuswanto, M.Si
Dr. Sutikno, M.Si**

**Program Magister
Departemen Statistika
Fakultas Sains dan Analitika Data
Institut Teknologi Sepuluh Nopember
Surabaya
2020**



TESIS - KS185411

**PEMODELAN INDEKS CURAH HUJAN EKSTREM
DENGAN PENDEKATAN GAMLSS
(Studi Kasus : Indeks RX5day dan CDD
di Provinsi Nusa Tenggara Timur)**

**FAUSANIA HIBATULLAH
06211850010015**

**Dosen Pembimbing
Dr. rer. pol. Heri Kuswanto, M.Si
Dr. Sutikno, M.Si**

**Program Magister
Departemen Statistika
Fakultas Sains dan Analitika Data
Institut Teknologi Sepuluh Nopember
Surabaya
2020**



THESIS - KS185411

**GAMLSS-BASED MODELLING OF EXTREME
PRECIPITATION INDICES
(Case Study : RX5day and CDD Indices
in East Nusa Tenggara Province)**

**FAUSANIA HIBATULLAH
06211850010015**

Supervisors
Dr. rer. pol. Heri Kuswanto, M.Si
Dr. Sutikno, M.Si

**Magister Program
Departement of Statistics
Faculty of Science and Data Analytics
Institut Teknologi Sepuluh Nopember
Surabaya
2020**

LEMBAR PENGESAHAN TESIS

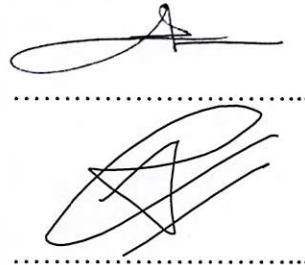
Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Statistika (M.Stat)
di
Institut Teknologi Sepuluh Nopember

Oleh:
FAUSANIA HIBATULLAH
NRP: 06211850010015

Tanggal Ujian : 28 Juli 2020
Periode Wisuda : September 2020

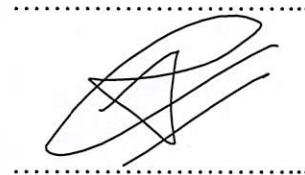
Disetujui oleh:
Pembimbing:

1. Dr. rer. pol. Heri Kuswanto, M.Si.
NIP: 19820326 200312 1 004



.....

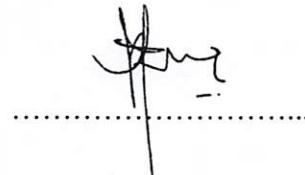
2. Dr. Sutikno, M.Si.
NIP: 19710313 199702 1 001



.....

Penguji :

1. Dr. Kartika Fithriasari, M.Si.
NIP: 19691212 199303 2 002



.....

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



.....



Pemodelan Indeks Curah Hujan Ekstrem dengan Pendekatan GAMLSS
(Studi Kasus : Indeks RX5day dan CDD di Provinsi Nusa Tenggara Timur)

Nama Mahasiswa : Fausania Hibatullah

NRP : 062118 5001 0015

Pembimbing : Dr. rer. pol. Heri Kuswanto, M.Si

Co-pembimbing : Dr. Sutikno, M.Si

ABSTRAK

Provinsi NTT menjadi prioritas pertama provinsi di Indonesia yang secara signifikan dipengaruhi oleh kekeringan sehingga rentan terhadap risiko kekeringan. Pemantauan dan pengukuran yang efektif atas kejadian curah hujan ekstrem penting untuk mengevaluasi perubahan di masa depan dan dampak curah hujan ekstrem. Non-stasioneritas sering ditemukan dalam data deret waktu hidrologi, Metode *Generalized Additive Model for Location, Scale and Shape* (GAMLSS) menyediakan kerangka kerja pemodelan yang fleksibel yang lebih cocok untuk memodelkan perubahan iklim ekstrem. Penelitian ini menggunakan 2 indeks curah hujan ekstrem, yaitu RX5DAY (*Maximum 5 Day Precipitation Total*) dan CDD (*Maximum Number of Consecutive Dry Days*). Penelitian ini juga menganalisis pengaruh SOI dan NINO3.4 SST sebagai indeks iklim skala besar terhadap kejadian curah hujan ekstrem. Studi simulasi terhadap model GAMLSS dilakukan dan model terbaik dipilih untuk memodelkan indeks curah hujan ekstrem. Berdasarkan studi simulasi disimpulkan bahwa metode GAMLSS dapat menyesuaikan distribusi data dengan baik pada sampel besar. Kesimpulan lain diperoleh bahwa di sebagian besar stasiun di NTT, kejadian curah hujan ekstrem lebih dijelaskan oleh model non-stasioner menggunakan indeks iklim sebagai variabel prediktor daripada model stasioner dan non-stasioner dengan waktu sebagai variabel prediktor.

Kata Kunci : Curah hujan ekstrem, GAMLSS, indeks iklim, non-stasioner.

(Halaman ini sengaja dikosongkan)

GAMLSS-Based Modelling of Extreme Precipitation Indices
(Case Study : RX5day and CDD Indices in East Nusa Tenggara Province)

Student's Name : Fausania Hibatullah
Student Identity Number : 062118 5001 0015
Supervisor : Dr. rer. pol. Heri Kuswanto, M.Si
Co-supervisor : Dr. Sutikno, M.Si

ABSTRACT

East Nusa Tenggara (denoted as NTT) is being listed on the first priority of province in Indonesia which is significantly affected by drought. The effective monitoring and measurement of extreme precipitation events are crucial for evaluating future changes and impacts of extreme precipitation. Non-stationarity is often found in hydrological time series data, The Generalized Additive Model for Location, Scale and Shape (GAMLSS) method provides a flexible modelling framework which is more suitable for modelling extreme climate change. This study uses 2 indices of extreme precipitation, the RX5DAY (Maximum 5 Day Precipitation Total) and the CDD (Maximum Number of Consecutive Dry Days), this study also analyzes the effect of SOI and NINO3.4 SST as large scale climate indices. Simulation study towards GAMLSS models is carried out and the best model is chosen to model the extreme precipitation indices. GAMLSS method can adjust data distribution well on large samples based on the simulation study. It also can be concluded that at most stations in NTT, the extreme precipitation events can be better explained by non-stationary models using climate indices as independent variables compared to stationary and non-stationary models with time as independent variables.

Keywords : *Climate indices, extreme precipitation, GAMLSS, non-stationary.*

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Puji syukur kehadirat Allah SWT yang telah memberikan limpahan hidayah, karunia dan rahmat-Nya yang tidak pernah berhenti sehingga penulis dapat menyelesaikan Tesis yang berjudul “**Pemodelan Indeks Curah Hujan Ekstrem dengan Pendekatan GAMLSS (Studi Kasus : Indeks RX5day dan CDD di Provinsi Nusa Tenggara Timur)**” dengan baik. Penulis menyadari bahwa penyusunan Tesis ini tidak lepas dari bantuan, arahan, petunjuk serta motivasi dari berbagai pihak. Oleh karena itu penulis ingin mengucapkan banyak terima kasih kepada :

1. Bapak Dr. rer. pol. Heri Kuswanto, M.Si dan Dr. Sutikno, S.Si, M.Si, selaku dosen pembimbing Tesis yang telah sangat banyak membantu dalam memberikan bimbingan, saran, ide dan motivasi pada penulis mulai dari penyusunan proposal Tesis hingga Tesis dapat terselesaikan.
2. Ibu Dr. Kartika Fithriasari, M.Si, selaku Kepala Departemen Statistika FSAD ITS, sekaligus dosen wali dan dosen penguji yang telah memberikan bimbingan dan saran agar Tesis ini menjadi lebih baik.
3. Bapak Dr. rer. pol. Dedy Dwi Prastyo, M.Si, selaku Kepala Program Studi Pascasarjana Departemen Statistika FSAD ITS, sekaligus dosen penguji yang telah banyak memberikan bimbingan dan saran pada penulis agar Tesis ini menjadi lebih baik.
4. Ibu Santi Wulan Purnami, M.Si., Ph.D selaku Sekretaris Departemen I (Bidang Akademik, Kemahasiswaan, Penelitian dan Pengabdian Kepada Masyarakat) dan Ibu Dr. Vita Ratnasari, M.Si selaku Sekretaris Departemen II (Bidang Sumber Daya Keuangan, Sumber Daya Manusia, dan Sarana Prasarana).
5. Institut Teknologi Sepuluh Nopember yang telah memberikan beasiswa kepada penulis melalui beasiswa *fresh graduate*, sehingga penulis bisa melanjutkan pendidikan pascasarjana hingga selesai.
6. Seluruh dosen Departemen Statistika ITS yang telah memberikan ilmu yang berharga serta seluruh karyawan yang telah membantu kelancaran pelaksanaan perkuliahan.

7. Bapak Antonius Sumitro, yang telah banyak membantu kelancaran administrasi Tesis di Departemen Statistika FSAD ITS.
8. Rosyida Inas yang telah banyak membantu dalam perolehan data Tesis.
9. Kedua orang tua (Moch. Ma'ruf dan Susi Indrawati) serta keluarga yang selalu memberikan doa, bimbingan, dukungan, kasih sayang serta kesabarannya dalam mendidik baik secara materiil, moril, maupun spiritual.
10. Duta Darma dan teman-teman Program Studi Magister Statistika ITS angkatan 2018, yang juga selalu memberikan doa, dukungan dan bantuan dalam penyelesaian Tesis ini baik secara langsung ataupun tidak langsung.

Penulis menyadari bahwa laporan Tesis ini masih jauh dari kesempurnaan, oleh karena itu penulis terbuka atas kritik dan saran yang membangun agar Tesis ini dapat mencapai kesempurnaan serta dapat dijadikan pertimbangan dalam penggerjaan Tesis berikutnya.

Surabaya, Agustus 2020

Fausania Hibatullah

DAFTAR ISI

HALAMAN JUDUL	i
TITLE PAGE	iii
LEMBAR PENGESAHAN	v
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR.....	xi
DAFTAR ISI.....	xiii
DAFTAR TABEL	xv
DAFTAR GAMBAR.....	xvii
DAFTAR NOTASI.....	xix
DAFTAR SINGKATAN.....	xxi
DAFTAR LAMPIRAN	xxiii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	4
1.3 Tujuan Penelitian	5
1.4 Manfaat Penelitian	5
1.5 Batasan Masalah	5
BAB II TINJAUAN PUSTAKA.....	7
2.1 Definisi Metode GAMLSS	7
2.2 Model GAMLSS	8
2.3 Prediktor Linier dari Model GAMLSS	10
2.3.1 Komponen Parametrik (<i>Parametric Terms</i>)	11
2.3.2 Komponen Aditif (<i>Additive Terms</i>)	11
2.4 Distribusi Populasi GAMLSS	13
2.5 Algoritma GAMLSS	18
2.5.1 Algoritma RS	18
2.5.2 Algoritma CG	20
2.5.3 Memaksimalkan Fungsi <i>Penalized Likelihood</i>	21

2.6 Seleksi Model GAMLSS dengan GAIC	24
2.7 Koefisien Filliben	26
2.8 <i>Random Variate Generation</i>	27
2.9 <i>Worm Plot</i>	28
2.10 Curah Hujan Ekstrem	28
2.10.1 R5D (<i>Maximum 5 Day Precipitation Total</i>)	29
2.10.2 CDD (<i>Maximum Number of Consecutive Dry Days</i>)	30
BAB III METODE PENELITIAN.....	31
3.1 Sumber Data	31
3.2 Variabel Penelitian	31
3.2.1 SST Daerah Nino	32
3.2.2 SOI	33
3.3 Langkah Analisis.....	35
BAB IV ANALISIS DAN PEMBAHASAN	41
4.1 Kajian Simulasi	41
4.4.1 Kajian Simulasi Indeks Curah Hujan Ekstrem RX5day	41
4.4.2 Kajian Simulasi Indeks Curah Hujan Ekstrem CDD	42
4.2 Pemodelan Indeks Curah Hujan Ekstrem di Provinsi NTT	43
4.2.1 Karakteristik Data Curah Hujan	44
4.2.2 Pemodelan Indeks Curah Hujan Ekstrem RX5day	48
4.2.3 Pemodelan Indeks Curah Hujan Ekstrem CDD	51
4.2.4 Hasil Evaluasi Kebaikan Model	55
BAB V KESIMPULAN DAN SARAN	59
5.1 Kesimpulan.....	59
5.2 Saran	60
DAFTAR PUSTAKA	61
LAMPIRAN	67
BIODATA PENULIS	117

DAFTAR TABEL

Tabel 2.1 Distribusi Diskrit untuk GAMLSS	14
Tabel 2.2 Distribusi Kontinyu untuk GAMLSS	14
Tabel 3.1 Struktur Data	35
Tabel 4.1 Kajian Simulasi Indeks Curah Hujan Ekstrem RX5day	42
Tabel 4.2 Kajian Simulasi Indeks Curah Hujan Ekstrem CDD	43
Tabel 4.3 Nilai rata-rata, standar deviasi, minimum, median dan maksimum dari indeks curah hujan ekstrem RX5day dan CDD	47
Tabel 4.4 Nilai GAIC Pemodelan RX5day di Stasiun Fransiskus dengan Model Stasioner 0	48
Tabel 4.5 Nilai GAIC Pemodelan RX5day di Stasiun Fransiskus dengan Model Non- Stasioner 1	48
Tabel 4.6 Nilai GAIC Pemodelan RX5day di Stasiun Fransiskus dengan Model Non- Stasioner 2	49
Tabel 4.7 Model Terbaik RX5day di 8 Stasiun Meteorologi NTT	51
Tabel 4.8 Nilai GAIC Pemodelan CDD di Stasiun Komodo dengan Model Stasioner 0	52
Tabel 4.9 Nilai GAIC Pemodelan CDD di Stasiun Komodo dengan Model Non- Stasioner 1	52
Tabel 4.10 Nilai GAIC Pemodelan CDD di Stasiun Komodo dengan Model Non- Stasioner 2	53
Tabel 4.11 Model Terbaik CDD di 8 Stasiun Meteorologi NTT	55
Tabel 4.12 Koefisien Filliben dari Model Terbaik RX5day	56
Tabel 4.13 Koefisien Filliben dari Model Terbaik CDD	56

(Halaman ini sengaja dikosongkan)

DAFTAR GAMBAR

Gambar 2.1 Plot PDF Distribusi Lognormal	16
Gambar 2.2 Plot PDF Distribusi Gamma.....	16
Gambar 2.3 Plot PDF Distribusi <i>Generalized Gamma</i>	16
Gambar 2.4 Plot PDF Distribusi <i>Generalized Poisson</i>	17
Gambar 2.5 Plot PDF Distribusi Binomial Negatif	17
Gambar 2.6 Plot PDF Distribusi <i>Poisson Inverse Gaussian</i>	17
Gambar 3.1 Persebaran Stasiun meteorologi di NTT	31
Gambar 3.2 Lokasi Pengamatan SST Daerah Nino	33
Gambar 3.3 Diagram Alir Kajian Simulasi.....	39
Gambar 3.3 Diagram Alir Kajian Empiris	40
Gambar 4.1 Pola Curah Hujan Harian	44
Gambar 4.2 Curah Hujan Ekstrem RX5day	45
Gambar 4.3 Curah Hujan Ekstrem CDD	46
Gambar 4.4 Plot antara Data RX5day dan <i>Fitted Value</i> di Stasiun Fransiskus	50
Gambar 4.5 Plot antara Data CDD dan <i>Fitted Value</i> di Stasiun Komodo	54
Gambar 4.6 <i>Worm Plot</i> dari Model Terbaik RX5day	56
Gambar 4.7 <i>Worm Plot</i> dari Model Terbaik CDD	57

(Halaman ini sengaja dikosongkan)

DAFTAR NOTASI

- $Y_{1,i,j}$: Variabel respon R5D (*Maximum 5 Day Precipitation Total*) pada tahun ke- i dan stasiun ke- j
- $Y_{2,i,j}$: Variabel respon CDD (*Maximum Number of Consecutive Dry Days*) pada tahun ke- i dan stasiun ke- j
- $X_{1,i,j}$: Variabel prediktor Nino 3.4 SST (*Sea Surface Temperature*) pada tahun ke- i dan stasiun ke- j
- $X_{2,i,j}$: Variabel prediktor SOI (*Southern Oscillation Index*) pada tahun ke- i dan stasiun ke- j
- n : Jumlah observasi
- θ_k : Parameter ke- k dari distribusi yang digunakan
- $g_k(\bullet)$: *Monotonic link function* yang menghubungkan θ_k dengan variabel prediktor dan *random effects*
- $\mathbf{X}_k \boldsymbol{\beta}_k$: Komponen parametrik
- $\boldsymbol{\beta}^T k$: Vektor parameter regresi dengan panjang l_k
- \mathbf{X}_k : Matriks variabel prediktor dengan order $n \times l_k$
- l_k : Banyaknya variabel untuk komponen parametrik pada parameter ke- k
- $\mathbf{Z}_{jk} \gamma_{jk}$: Komponen aditif yang memodelkan berbagai bentuk seperti *smoothing* dan *random effects*
- \mathbf{Z}_{jk} : *Fixed known* matriks berukuran $n \times q_{jk}$
- γ_{jk} : Variabel random berdimensi q_{jk}
- J_k : Banyaknya variabel untuk komponen aditif pada parameter ke- k
- h_{jk} : Fungsi yang tidak diketahui dari variabel prediktor
- $h_{jk}(x_{jk})$: Vektor untuk mengevaluasi fungsi h_{jk} pada x_{jk}
- l_p : Fungsi *penalized log-likelihood*
- \mathbf{G}_{jk} : Matriks simetris yang berukuran $q_{jk} \times q_{jk}$
- λ_{jk} : Vektor *hyperparameter*

(Halaman ini sengaja dikosongkan)

DAFTAR SINGKATAN

AIC : Akaike Information Criterion

CDD : Maximum Number of Consecutive Dry Days

GAIC : Generalized Akaike Information Criterion

GAM : Generalized Additive Model

GAMLSS : Generalized Additive Model for Location, Scale and Shape

GD : Global Deviance

NINO3.4 SST : NINO3.4 Sea Surface Temperature

PDO : Pacific Decadal Oscillation

RR : Curah hujan harian

RX5day : Maximum 5 Day Precipitation Total

SBC : Schwarz Bayesian Criterion

SOI : Southern Oscillation Index

WGCCD : Working Group on Climate Change Detection

(Halaman ini sengaja dikosongkan)

DAFTAR LAMPIRAN

Lampiran 1 Data Curah Hujan Harian di 8 Stasiun meteorologi Provinsi NTT ...	67
Lampiran 2 Data Indeks Curah Hujan Ekstrem RX5day	69
Lampiran 3 Data Indeks Curah Hujan Ekstrem CDD.....	69
Lampiran 4 Kajian Simulasi RX5day Distribusi Lognormal.....	70
Lampiran 5 Kajian Simulasi RX5day Distribusi Gamma.....	71
Lampiran 6 Kajian Simulasi RX5day Distribusi <i>Generalized Gamma</i>	72
Lampiran 7 Kajian Simulasi CDD Distribusi <i>Generalized Poisson</i>	73
Lampiran 8 Kajian Simulasi CDD Distribusi Binomial Negatif	74
Lampiran 9 Kajian Simulasi CDD Distribusi <i>Poisson Inverse Gaussian</i>	75
Lampiran 10 Syntax Pemodelan Indeks Curah Hujan Ekstrem RX5day	76
Lampiran 11 Syntax Pemodelan Indeks Curah Hujan Ekstrem CDD	79
Lampiran 12 Hasil Pemodelan RX5day di Stasiun Komodo.....	82
Lampiran 13 Hasil Pemodelan RX5day di Stasiun Frans	84
Lampiran 14 Hasil Pemodelan RX5day di Stasiun Fransiskus.....	86
Lampiran 15 Hasil Pemodelan RX5day di Stasiun Gewayantana	88
Lampiran 16 Hasil Pemodelan RX5day di Stasiun Umbu.....	90
Lampiran 17 Hasil Pemodelan RX5day di Stasiun Lasiana	91
Lampiran 18 Hasil Pemodelan RX5day di Stasiun Eltari.....	94
Lampiran 19 Hasil Pemodelan RX5day di Stasiun Tardamu	97
Lampiran 20 Hasil Pemodelan CDD di Stasiun Komodo.....	99
Lampiran 21 Hasil Pemodelan CDD di Stasiun Frans.....	101
Lampiran 22 Hasil Pemodelan CDD di Stasiun Fransiskus	103
Lampiran 23 Hasil Pemodelan CDD di Stasiun Gewayantana	105
Lampiran 24 Hasil Pemodelan CDD di Stasiun Umbu.....	107
Lampiran 25 Hasil Pemodelan CDD di Stasiun Lasiana	109
Lampiran 26 Hasil Pemodelan CDD di Stasiun Eltari.....	111
Lampiran 27 Hasil Pemodelan CDD di Stasiun Tardamu	114

(Halaman ini sengaja dikosongkan)

BAB I

PENDAHULUAN

1.1 Latar Belakang

Pemanasan global dan intensifikasi aktivitas manusia cenderung mempercepat siklus hidrologi global yang dapat menghasilkan lebih banyak kejadian hidroklimat ekstrem seperti banjir, banjir bandang, atau kekeringan yang berdampak buruk pada permukiman, pertanian, ekosistem, industri, dan pembangunan sosial ekonomi (Liu, et al., 2017). *Intergovernmental Panel on Climate Change* (IPCC) melaporkan bahwa intensitas curah hujan ekstrem secara global akan meningkat dengan pemanasan global pada tingkat yang sama sekitar $7\% \text{ }^{\circ}\text{C}^{-1}$, jauh lebih cepat daripada respons rata-rata curah hujan yaitu $1\text{-}3\% \text{ }^{\circ}\text{C}^{-1}$ (IPCC, 2013). Salah satu dampak yang lebih buruk daripada perubahan iklim ekstrem dalam pengembangan negara adalah kerentanan yang lebih tinggi terhadap bencana karena populasi yang padat dan infrastruktur drainase yang tidak sempurna (Croitoru et al., 2015).

Peristiwa curah hujan ekstrem meningkat dalam nilai dan frekuensi pada skala global atau benua, maupun di daerah kering dan basah yang berpotensi memicu lebih banyak banjir dan kekeringan (Hao, et al., 2019), termasuk di Indonesia. Bulletin Pengawasan Keamanan Pangan Indonesia pada tahun 2018 memasukkan Provinsi Nusa Tenggara Timur (NTT) pada prioritas pertama provinsi di Indonesia yang secara signifikan dipengaruhi oleh kekeringan sehingga rentan terhadap risiko kekeringan. Kepala Badan Penanggulangan Bencana Daerah (BPBD) NTT pada tahun 2015 menyebutkan bahwa 20 kabupaten (terdiri atas 270 desa dan kelurahan) di NTT terkena dampak kekeringan hebat. Kabupaten prioritas pertama adalah kabupaten yang tidak memiliki hujan lebih dari 60 hari dan memiliki tingkat kemiskinan diatas 20%. Analisis *Standardized Precipitation Index* (SPI) menunjukkan bahwa NTT telah mengalami sekitar 25 bulan peristiwa kekeringan dalam periode 1999 hingga 2015, selain itu peta risiko kekeringan yang berasal dari besarnya dan durasi kekeringan di NTT pada masa yang akan datang

menunjukkan bahwa tingkat keparahan kekeringan di NTT meningkat dari waktu ke waktu (Kuswanto, et al., 2018).

Pemantauan dan pengukuran yang efektif atas kejadian curah hujan ekstrem untuk memahami sifat dasar dari fenomena iklim ekstrem sangat penting untuk mengevaluasi perubahan di masa depan dan dampak dari curah hujan ekstrem (Demirdjian, et al., 2018). Analisis statistik dari deret waktu meteorologis dan hidrologi umumnya bergantung pada beberapa asumsi dasar sebagai berikut : (1) Rangkaian waktu yang cukup panjang; (2) Elemen-elemen dari seri yang independen dan terdistribusi secara identik; dan (3) Stasioneritas, yang berarti bahwa variabel yang diamati tidak tergantung pada waktu atau bebas dari tren, perubahan, dan periodikitas (Salas, 1993). Akan tetapi, nonstasioneritas seringkali ditemukan pada data deret waktu hidrologi karena adanya variabilitas iklim atau perubahan iklim antropogenik (Caroni, et al., 2015), sehingga mengabaikan nonstasioneritas pada data deret waktu hidrologi dapat menyebabkan hasil analisis yang bias.

Metode analisis curah hujan ekstrem perlu ditingkatkan untuk dapat beradaptasi dengan ketidakpastian dalam kondisi lingkungan yang berubah. Ulasan dari berbagai metodologi termasuk penggabungan tren dalam parameter distribusi, metode *time-varying moment*, metode *local likelihood* dan metode regresi kuantil telah dikembangkan untuk analisis frekuensi pengamatan non-stasioner (Khaliq et al., 2006), begitu pula model *Generalized Extreme Value* (GEV) nonstasioner untuk menggambarkan puncak banjir (Seidou et al., 2012) dan memodelkan curah hujan ekstrem dengan data TRMM (Demirdjian, 2018). Metode yang diadopsi dalam sebagian besar studi sebelumnya belum menganalisis hubungan antara perubahan indeks iklim dan curah hujan ekstrem. Oleh karena itu, dengan asumsi nonstasioneritas, model statistik seharusnya tidak hanya memperhitungkan perubahan parameter dari waktu ke waktu, tetapi juga pada indeks iklim skala besar yang dapat mempengaruhi curah hujan ekstrem (Hao, et al., 2019).

Generalized Additive Model for Location, Scale and Shape (GAMLSS) telah diusulkan oleh Rigby dan Stasinopoulos (2005) untuk pemodelan nonstasioner. Dibandingkan dengan *Generalized Additive Model* klasik (Hastie dan Tibshirani, 1990), GAMLSS menyediakan kerangka kerja pemodelan yang fleksibel. Dalam

GAMLSS, variabel respon dapat mengikuti distribusi yang lebih umum selain dari keluarga eksponensial (misalkan Gaussian dan Eksponensial), seperti distribusi yang kurtotik atau *highly skewed*, yang lebih sesuai untuk memodelkan perubahan iklim ekstrem. Parameter distribusi sering dianggap terkait dengan beberapa variabel prediktor untuk merepresentasikan nonstasioneritas dalam analisis frekuensi, metode GAMLSS memungkinkan semua parameter distribusi bersyarat untuk dimodelkan sebagai fungsi parametrik dan atau aditif nonparametrik (*smooth*) dari variabel prediktor (Rigby dan Stasinopoulos, 2005). Villarini et al. (2010) menggunakan GAMLSS untuk memodelkan curah hujan musiman dan temperatur di Roma, yang menunjukkan bahwa model GAMLSS dapat mewakili nilai dan sebaran dalam deret waktu musiman dengan fungsi *smoothing* parameter untuk indeks waktu dan indeks iklim skala besar. Pemodelan curah hujan ekstrem di wilayah Beijing–Tianjin–Hebei, China dengan metode GAMLSS juga telah dilakukan oleh Zhang (2015) yang menyatakan bahwa parameter distribusi curah hujan yang dimodelkan dengan indeks iklim mampu menangkap dispersi nilai presipitasi lebih baik dibandingkan dengan model yang hanya melibatkan waktu sebagai variabel prediktor. Penelitian lain oleh Hao (2019) memodelkan curah hujan ekstrem di Hanjiang River basin, China dengan metode GAMLSS menyatakan bahwa curah hujan ekstrem secara signifikan juga dipengaruhi oleh indeks iklim berskala besar.

Penelitian yang menjelaskan hubungan antara faktor-faktor yang memengaruhi distribusi parameter curah hujan dari waktu ke waktu dilakukan oleh Hao, et al. pada tahun 2019 yang menginformasikan bahwa indeks iklim *Pacific Decadal Oscillation* (PDO) dan *Southern Oscillation Index* (SOI) diidentifikasi sebagai faktor utama yang mempengaruhi curah hujan ekstrem di beberapa stasiun di HJRB China, selain itu pengaruh dari suhu permukaan laut daerah Nino 3 (NINO Sea Surface Temperature) juga terkait dengan fluktuasi indeks curah hujan RX5DAY di beberapa stasiun. Penelitian lain oleh Wen et al. pada tahun (2011) menunjukkan bahwa peristiwa hujan deras memiliki hubungan yang sangat kuat dengan suhu permukaan laut (NINO3 SST) di bagian tengah Sungai Yangtze selama musim hujan. Penelitian oleh Lembaga Penerangan dan Antariksa Nasional (LAPAN) pada tahun 2012 menjelaskan bahwa korelasi antara *Southern*

Oscillation Index (SOI) dan curah hujan cukup kuat di beberapa wilayah di Indonesia.

Indikator tunggal curah hujan ekstrem memiliki keterbatasan untuk menangkap gambaran penuh curah hujan ekstrem. Terdapat beberapa indikator yang direkomendasikan oleh *Working Group on Climate Change Detection* (WGCCD) untuk menganalisis perubahan iklim ekstrem, dua diantaranya adalah RX5DAY dan CDD (WGCCD, 2001). Penelitian ini menggunakan 2 indikator yang mewakili curah hujan ekstrem yang tinggi dan rendah. Curah hujan tinggi dijelaskan oleh indikator RX5DAY (*Maximum 5 Day Precipitation Total*) dan curah hujan rendah dijelaskan oleh indikator CDD (*Maximum Number of Consecutive Dry Days*). Pemodelan RX5DAY sebagai indikator curah hujan ekstrem dengan metode GAMLSS sebelumnya juga pernah dilakukan oleh Hao et al. (2019) di Hanjiang River Basin, China, sedangkan pemodelan CDD sebelumnya dilakukan oleh Duan et al. (2017) dengan metode *Ensemble Empirical Mode Decomposition* (EEMD). Berdasarkan penelitian sebelumnya, penelitian ini menganalisis pengaruh SOI dan NINO SST sebagai indeks iklim skala besar terhadap indeks curah hujan ekstrem RX5DAY dan CDD di Provinsi NTT dengan metode GAMLSS.

1.2 Rumusan Masalah

Nonstasioneritas seringkali ditemukan pada data deret waktu hidrologi karena terdapat variabilitas iklim atau perubahan iklim antropogenik, sehingga mengabaikan nonstasioneritas pada data deret waktu hidrologi dapat menyebabkan hasil analisis yang bias. Latar belakang yang telah dijelaskan sebelumnya menghasilkan rumusan masalah yang ingin dibahas dalam penelitian ini, yakni bagaimana kajian simulasi dari beberapa distribusi untuk model GAMLSS serta bagaimana model terbaik untuk masing-masing indeks curah hujan ekstrem RX5DAY (*Maximum 5 Day Precipitation Total*) dan CDD (*Maximum Number of Consecutive Dry Days*) dengan pendekatan GAMLSS di NTT dan hasil evaluasi kebaikan model dari masing-masing model yang terpilih di setiap stasiun.

1.3 Tujuan Penelitian

Tujuan yang ingin dicapai dalam penelitian ini berdasarkan rumusan masalah yang telah dijelaskan adalah sebagai berikut :

1. Mengetahui kinerja (kebaikan) metode GAMLSS dalam penyesuaian distribusi data melalui kajian simulasi pada masing-masing indeks curah hujan ekstrem.
2. Mendapatkan model indeks curah hujan ekstrem RX5DAY (*Maximum 5 Day Precipitation Total*) dan CDD (*Maximum Number of Consecutive Dry Days*) dengan pendekatan GAMLSS di 8 stasiun meteorologi di NTT dan mengevaluasi kebaikan model dari masing-masing model yang terpilih di setiap stasiun.

1.4 Manfaat Penelitian

Manfaat hasil penelitian ini adalah sebagai berikut :

1. Penelitian ini diharapkan mampu memberikan tambahan informasi tentang pengembangan metode statistika pada bidang klimatologi terkait perubahan curah hujan ekstrem dan memberikan informasi penting untuk estimasi curah hujan ekstrem di suatu daerah dengan kondisi iklim yang berubah.
2. Hasil penelitian ini juga diharapkan dapat dijadikan informasi bagi Badan Meteorologi Klimatologi dan Geofisika (BMKG) untuk pengembangan dan penerapan dalam memprediksi dan identifikasi curah hujan ekstrem serta mengembangkan strategi mitigasi dan adaptasi terhadap dampak curah hujan ekstrem. Penggunaan indeks curah hujan tahunan mampu menyederhanakan analisis dan menunjukkan perubahan intensitas curah hujan ekstrem.

1.5 Batasan Masalah

Batasan masalah dalam penelitian ini agar tidak menyimpang dari tujuan penelitian adalah sebagai berikut :

1. Terdapat 10 stasiun meteorologi di NTT, namun data curah hujan harian pada 2 stasiun (stasiun meteorologi Mali dan David Constatijn) mengandung *missing value* lebih dari 30%, sehingga hanya 8 stasiun yang digunakan dalam

penelitian ini dan pemodelan GAMLSS pada masing-masing indeks curah hujan dilakukan pada masing-masing stasiun.

2. Indeks curah hujan ekstrem yang digunakan adalah RX5DAY (*Maximum 5 Day Precipitation Total*) dan CDD (*Maximum Number of Consecutive Dry Days*) periode tahunan.
3. Penelitian ini menggunakan 3 tipe model GAMLSS : model stasioner, model non-stasioner dengan variabel prediktor waktu dan model non-stasioner dengan variabel prediktor indeks iklim skala besar.
4. Kajian simulasi untuk model GAMLSS bertujuan untuk mengetahui ketepatan metode GAMLSS dalam menyesuaikan distribusi data dari masing-masing indeks curah hujan ekstrem dilakukan menggunakan 3 distribusi untuk indeks RX5DAY (Lognormal, Gamma dan *Generalized Gamma*) dan indeks CDD (*Generalized Poisson*, Negatif Binomial dan *Poisson Inverse Gaussian*).
5. Metode *smoothing* yang digunakan untuk memodelkan GAMLSS dengan variabel prediktor adalah *cubic smoothing splines* dan *penalized splines terms*.
6. Model yang didapatkan dari hasil penelitian ini adalah pemodelan semua parameter dari distribusi yang paling sesuai untuk memodelkan masing-masing indeks curah hujan ekstem RX5day dan CDD di setiap stasiun meteorologi.

BAB II

TINJAUAN PUSTAKA

Bab ini menjelaskan konsep dan teori metode statistika yang digunakan dalam penelitian ini, yaitu *Generalized Additive Model for Location, Scale and Shape* (GAMLSS). Selain itu, pada bab ini juga dijelaskan pengertian curah hujan ekstrem sebagai variabel respon penelitian.

2.1 Definisi Metode *Generalized Additive Model for Location, Scale and Shape* (GAMLSS)

GAMLSS adalah pengembangan model tipe regresi yang sistematis dan fleksibel dengan algoritma yang memungkinkan eksplorasi cepat dari kumpulan data yang besar dan kompleks (Rigby dan Stasinopoulos, 2005). Dalam kerangka teknik pemodelan regresi univariat, *Generalized Linear Model* (GLM) dan *Generalized Additive Model* (GAM) telah sering digunakan (Nelder dan Wedderburn, 1972; Hastie dan Tibshirani, 1990). Kedua model mengasumsikan variabel respon y berdistribusi keluarga eksponensial dengan rata-rata μ yang dimodelkan sebagai fungsi dari variabel prediktor (*explanatory variables*) dan varians dari y dengan $V(y) = \phi v(\mu)$, bergantung pada parameter dispersi konstan ϕ dan pada rata-rata μ melalui fungsi varians $v(\mu)$. Selain itu, *skewness* dan kurtosis dari distribusi keluarga eksponensial secara umum adalah fungsi dari μ dan ϕ . Oleh karena itu, dalam model GLM dan GAM, varians, *skewness* dan kurtosis tidak dimodelkan secara eksplisit dalam variabel prediktor namun secara implisit melalui dependensinya terhadap μ .

Model lain yang penting adalah *the linear mixed (random effect) models* untuk memodelkan variabel dependen pada skema sampel spasial, hierarkis dan longitudinal dan mengasumsikan normalitas untuk distribusi kondisional dari y yang diberi *random effects* sehingga tidak dapat memodelkan *skewness* dan kurtosis secara eksplisit. Terdapat pula metode *Generalized Linear Mixed Model* (GLMM) yang menggabungkan metode GLM dan *linear mixed model*, dengan memperkenalkan istilah *random effects* yang biasanya berdistribusi normal dalam

prediktor linier untuk rata-rata dari GLM. Prosedur Bayesian untuk GLMM menggunakan algoritma EM dan metode *Markov Chain Monte Carlo* dijelaskan oleh McCulloch (1997) serta Zeger dan Karim (1991). Lin dan Zhang (1999) memberikan contoh model *Generalized Additive Mixed Model* (GAMM). Fahrmeir dan Lang (2001) membahas pemodelan GAMM menggunakan inferensi Bayesian. Fahrmeir dan Tutz (2001) membahas prosedur estimasi alternatif untuk GLMM dan GAMM.

GLMM dan GAMM, meskipun lebih fleksibel daripada GLM dan GAM, metode tersebut juga mengasumsikan distribusi keluarga eksponensial dengan mengabaikan parameter yang lain dari distribusi variabel respon sebagai fungsi dari variabel-variabel prediktor. Metode tersebut juga membutuhkan komputasi yang kompleks karena penyesuaianya bergantung pada Markov Chain Monte Carlo atau *Integrated Likelihood*. Selain itu juga membutuhkan waktu yang lama untuk menyelesaikan *dataset* besar karena pemilihan model memerlukan investigasi banyak model alternatif.

Penelitian ini menggunakan pengembangan model regresi univariat *Generalized Additive Models for Location, Scale and Shape* (GAMLSS), dimana distribusi variabel respon yang digunakan lebih fleksibel, bukan hanya dari keluarga eksponensial. Dengan kerangka kerja baru, bagian sistematis dari model diperluas untuk memungkinkan pemodelan respon tidak hanya berdasarkan pada parameter rata-rata (atau parameter lokasi) tetapi semua parameter distribusi bersyarat dari y yang akan dimodelkan sebagai fungsi parametrik dan atau fungsi aditif nonparametrik (*smooth*) dari variabel prediktor (Rigby dan Stasinopoulos, 2005).

2.2 Model GAMLSS

Generalized Additive Models for Location, Scale and Shape (GAMLSS) adalah tipe model regresi semi-parametrik. p parameter $\theta^T = (\theta_1, \theta_2, \dots, \theta_p)$ *probability density function* (pdf) $f(y|\theta)$ dimodelkan dengan model aditif. Secara spesifik, model mengasumsikan observasi y_i kondisional independen pada θ^i

dengan pdf $f(y_i | \boldsymbol{\theta}^i)$ dimana $i=1,2,\dots,n$. $\boldsymbol{\theta}^{iT} = (\theta_{i1}, \theta_{i2}, \dots, \theta_{ip})$ adalah vektor p parameter yang berhubungan dengan variabel prediktor dan *random effects* (Jika nilai kovariat bersifat stokastik atau pengamatan y_i bergantung pada nilai periode sebelumnya, maka $f(y_i | \boldsymbol{\theta}^i)$ kondisional pada nilai-nilai ini). Jika pengamatan diamati dari waktu ke waktu, maka indeks i dapat diganti menjadi t sehingga $f(y_t | \boldsymbol{\theta}^t)$, dimana $t=1,2,\dots,n$ dan $\boldsymbol{\theta}^{iT} = (\theta_{t1}, \theta_{t2}, \dots, \theta_{tp})$.

Misalkan $y^T = (y_1, y_2, \dots, y_n)$ adalah vektor observasi variabel respon y , dan $k=1,2,\dots,p$, $g_k(\bullet)$ diketahui sebagai *monotonic link function* yang menghubungkan $\boldsymbol{\theta}_k$ dengan variabel prediktor dan *random effects* melalui aditif model yang diberikan pada persamaan (2.1).

$$g_k(\boldsymbol{\theta}_k) = \boldsymbol{\eta}_k = \mathbf{X}_k \boldsymbol{\beta}_k + \sum_{j=1}^{J_k} \mathbf{Z}_{jk} \boldsymbol{\gamma}_{jk} \quad (2.1)$$

$\boldsymbol{\theta}_k$ dan $\boldsymbol{\eta}_k$ adalah vektor dengan panjang n , misalkan $\boldsymbol{\theta}^T_k = (\theta_{1k}, \theta_{2k}, \dots, \theta_{ik}, \dots, \theta_{nk})$, $\boldsymbol{\beta}^T_k = (\beta_{1k}, \beta_{2k}, \dots, \beta_{lk})$ adalah vektor parameter dengan panjang l_k , maka \mathbf{X}_k diketahui sebagai matriks dengan order $n \times l_k$, dengan l_k adalah banyaknya variabel untuk komponen parametrik pada parameter distribusi ke- k . \mathbf{Z}_{jk} adalah *fixed known* matriks berukuran $n \times q_{jk}$ dan $\boldsymbol{\gamma}_{jk}$ adalah variabel random berdimensi q_{jk} , dengan q_{jk} adalah banyaknya knot *smoothing* ($K_1, K_2, \dots, K_{q_{jk}}$) untuk variabel ke- j dan parameter ke- k . Bentuk matriks \mathbf{Z}_{jk} adalah sebagai berikut :

$$\mathbf{Z}_{jk}^{(n \times q_{jk})} = \begin{pmatrix} (X_{j1} - K_1)_+ & (X_{j1} - K_2)_+ & \cdots & (X_{j1} - K_{q_{jk}})_+ \\ (X_{j2} - K_1)_+ & (X_{j2} - K_2)_+ & \cdots & (X_{j2} - K_{q_{jk}})_+ \\ \vdots & \vdots & \ddots & \vdots \\ (X_{jn} - K_1)_+ & (X_{jn} - K_2)_+ & \cdots & (X_{jn} - K_{q_{jk}})_+ \end{pmatrix}$$

Model pada persamaan (2.1) adalah model GAMLSS. Vektor $\boldsymbol{\gamma}_{jk}$ untuk $j = 1, 2, \dots, J_k$ dapat dikombinasikan kedalam vektor tunggal $\boldsymbol{\gamma}_k$ dengan matriks \mathbf{Z}_k , dengan J_k adalah banyaknya variabel untuk komponen aditif pada parameter distribusi ke- k .

Jika, untuk $k = 1, 2, \dots, p$ dan $J_k = 0$, maka model pada persamaan (2.1) dapat dituliskan menjadi persamaan (2.2) sebagai berikut :

$$g_k(\boldsymbol{\theta}_k) = \boldsymbol{\eta}_k = \mathbf{X}_k \boldsymbol{\beta}_k \quad (2.2)$$

Jika $\mathbf{Z}_{jk} = \mathbf{I}_n$, dimana \mathbf{I}_n adalah matriks identitas berukuran $n \times n$, dan $\gamma_{jk} = \mathbf{h}_{jk} = h_{jk}(x_{jk})$ untuk semua kombinasi dari j dan k , maka model pada persamaan (2.1) berubah menjadi model yang dituliskan pada persamaan (2.3).

$$g_k(\boldsymbol{\theta}_k) = \boldsymbol{\eta}_k = \mathbf{X}_k \boldsymbol{\beta}_k + \sum_{j=1}^{J_k} h_{jk}(\mathbf{x}_{jk}) \quad (2.3)$$

\mathbf{x}_{jk} adalah vektor berukuran n dengan $j = 1, 2, \dots, m_k$ dan $k = 1, 2, \dots, p$. Fungsi h_{jk} adalah fungsi yang tidak diketahui dari variabel prediktor \mathbf{X}_{jk} dan $\mathbf{h}_{jk} = h_{jk}(x_{jk})$ adalah vektor untuk kalkulasi fungsi h_{jk} pada \mathbf{x}_{jk} . Variabel prediktor vektor \mathbf{x}_{jk} diasumsikan diketahui. Model pada persamaan (2.3) adalah model semi-parametrik GAMLSS. Model pada persamaan (2.3) adalah kasus khusus dari model pada persamaan (2.1). Jika $\mathbf{Z}_{jk} = \mathbf{I}_n$ dan $\gamma_{jk} = \mathbf{h}_{jk} = h_{jk}(x_{jk})$ adalah kombinasi spesifik dari j dan k pada persamaan (2.1), maka model yang dihasilkan mengandung bentuk parametrik, nonparametrik dan *random effects*. Kedua parameter populasi pertama θ_1 dan θ_2 pada model persamaan (2.1) biasanya dikarakterisasikan sebagai parameter lokasi dan skala (*location and scale*), atau μ dan σ , jika terdapat parameter lain, maka parameter tersebut dikarakterisasikan sebagai parameter bentuk (*shape*), untuk beberapa distribusi populasi dengan maksimum 2 parameter bentuk $\nu (= \theta_3)$ dan $\tau (= \theta_4)$, model yang dibentuk dapat dituliskan pada persamaan (2.4).

$$\left. \begin{aligned} g_1(\mu) &= \eta_1 = \mathbf{X}_1 \boldsymbol{\beta}_1 + \sum_{j=1}^{J_1} \mathbf{Z}_{j1} \gamma_{j1} \\ g_2(\sigma) &= \eta_2 = \mathbf{X}_2 \boldsymbol{\beta}_2 + \sum_{j=1}^{J_2} \mathbf{Z}_{j2} \gamma_{j2} \\ g_3(\nu) &= \eta_3 = \mathbf{X}_3 \boldsymbol{\beta}_3 + \sum_{j=1}^{J_3} \mathbf{Z}_{j3} \gamma_{j3} \\ g_4(\tau) &= \eta_4 = \mathbf{X}_4 \boldsymbol{\beta}_4 + \sum_{j=1}^{J_4} \mathbf{Z}_{j4} \gamma_{j4} \end{aligned} \right\} \quad (2.4)$$

$\mathbf{Z}_{jk}\gamma_{jk}$ pada persamaan (2.4) merupakan komponen aditif yang dapat memodelkan bentuk *smoothing*. Model GAMLSS pada persamaan (2.1) bersifat lebih umum daripada GLM, GAM, GLMM atau GAMM di mana distribusi variabel respon tidak terbatas pada keluarga eksponensial dan semua parameter (bukan hanya rata-rata) dapat dimodelkan baik dalam efek tetap (*fixed effects*) ataupun efek random (*random effects*).

2.3 Prediktor Linier dari Model GAMLSS

Terdapat beberapa bentuk prediktor linier dari model GAMLSS, diantaranya adalah komponen parametrik dan komponen aditif yang dijelaskan pada sub-bab berikut :

2.3.1 Komponen Parametrik (*Parametric Terms*)

Prediktor linier $\eta_k; k = 1, 2, \dots, p$ dalam model GAMLSS pada persamaan (2.1) mengandung komponen parametrik $\mathbf{X}_k\beta_k$ dan komponen aditif $\mathbf{Z}_{jk}\gamma_{jk}$ untuk $j = 1, 2, \dots, J_k$. Komponen parametrik dapat meliputi interaksi linier dari variabel prediktor dan faktor-faktor lain, *polynomial*, *fractional polynomials* (Royston dan Altman, 1994) dan *piecewise polynomials* (dengan *fixed knots*) untuk variabel yang digunakan (Smith, 1979; Stasinopoulos dan Rigby, 1992).

Parameter non-linier dapat dimasukkan ke dalam model GAMLSS pada persamaan (2.1) dengan menggunakan metode derivatif atau *The Derivative Method*. Dalam metode derivatif, derivatif dari prediktor η_k sebagai parameter non-linier dilibatkan dalam matriks \mathbf{X}_k dengan algoritma *fitting*.

2.3.2 Komponen Aditif (*Additive Terms*)

Komponen aditif $\mathbf{Z}_{jk}\gamma_{jk}$ dari model GAMLSS pada persamaan (2.1) dapat memodelkan berbagai bentuk seperti *smoothing* dan *random effects* sebagaimana digunakan pada analisis deret waktu (*time series*). Pada penelitian ini, metode *smoothing* komponen aditif model GAMLSS yang digunakan adalah *Cubic Smoothing Splines* dan *Penalized Splines Terms*.

A. Cubic Smoothing Splines

Dengan metode *Cubic Smoothing Splines*, diasumsikan model GAMLSS pada persamaan (2.3) bahwa fungsi $h(t)$ dapat diturunkan sebanyak dua kali berturut-turut dan memaksimumkan fungsi *penalized log-likelihood*. Fungsi *penalized log-likelihood* dituliskan pada persamaan (2.5).

$$l_p = l - \frac{1}{2} \sum_{k=1}^p \sum_{j=1}^{J_k} \gamma_j^T G_{jk} \gamma_j \quad (2.5)$$

$l = \sum_{i=1}^n \log \left\{ f(y_i | \theta^i) \right\}$ adalah fungsi log-likelihood dengan $i = 1, 2, \dots, n$.

Bentuk *random effects* γ_{jk} pada persamaan (2.1) diasumsikan berdistribusi normal dengan $\gamma_{jk} \sim N_{qjk}(0, \mathbf{G}_{jk}^-)$, dimana \mathbf{G}_{jk}^- adalah *generalized inverse* dari matriks simetris \mathbf{G}_{jk} yang berukuran $q_{jk} \times q_{jk}$ dan bergantung pada *hyperparameter* λ_{jk} .

Fungsi log-likelihood l mengikuti bentuk *penalty* $\lambda \int_{-\infty}^{\infty} h''(t)^2 dt$. Reinsch (1967) menjelaskan bahwa fungsi yang memaksimalkan $h(t)$ adalah *natural cubic splines* dan dapat dinyatakan sebagai kombinasi linier dari fungsi basis *natural cubic spline* $B_i(t)$ dengan $i = 1, 2, \dots, n$ (de Boor, 1978), misalkan $h(t) = \sum_{i=1}^n \delta_i B_i(t)$.

Jika $\mathbf{h} = h(x)$ adalah vektor yang mengevaluasi fungsi $h(t)$ pada nilai x dari variabel prediktor X yang diasumsikan berbeda untuk menyederhanakan eksposisi. Diberikan \mathbf{N} adalah matriks non singular berdimensi $n \times n$ yang elemen kolomnya berisi evaluasi fungsi $B_i(t)$ untuk $i = 1, 2, \dots, n$ pada x . Kemudian \mathbf{h} dapat dinyatakan dengan menggunakan vektor koefisien $\boldsymbol{\delta}$ sebagai kombinasi linier dari elemen kolom matriks \mathbf{N} dengan $\mathbf{h} = \mathbf{N}\boldsymbol{\delta}$. Diberikan $\mathbf{\Omega}$ adalah matriks berukuran $n \times n$ yang berisi turunan kedua dari fungsi basis *natural cubic spline*, dengan elemen ke- (r,s) sebagai berikut :

$$\Omega_{rs} = \int B_r^n(t) B_s^n(t) dt. \quad (2.6)$$

Fungsi *penalty* kemudian didapatkan dari bentuk kuadratik :

$$Q(\mathbf{h}) = \lambda \int_{-\infty}^{\infty} h''(t)^2 dt = \lambda \boldsymbol{\delta}^T \mathbf{\Omega} \boldsymbol{\delta} = \lambda \mathbf{h}^T \mathbf{N}^T \mathbf{\Omega} \mathbf{N}^{-1} \mathbf{h} = \lambda \mathbf{h}^T \mathbf{K} \mathbf{h}. \quad (2.7)$$

Dengan $\mathbf{K} = \mathbf{N}^T \boldsymbol{\Omega} \mathbf{N}^{-1}$ diketahui sebagai matriks *penalty* yang tergantung hanya pada nilai dari variabel prediktor \mathbf{x} (Hastie dan Tibshirani, 1990).

B. *Penalized Splines Terms*

Penalized Splines Terms adalah metode pemulusan dengan jumlah basis fungsi yang kurang dari jumlah observasi dengan koefisien regresi yang ditentukan sesuai dengan *penalized spline* atau *P-spline* (Eilers dan Marx, 1996; Wood, 2001). Eilers dan Marx menggunakan set dari fungsi basis q *B-spline* pada variabel prediktor X (evaluasi dari nilai \mathbf{x} dari X adalah elemen kolom dari matriks \mathbf{Z} berdimensi $n \times q$ pada persamaan (2.1)). Eilers dan Marx menyarankan untuk menggunakan *moderately large number of equal spaced knots* (berkisar antara 20 dan 40), di mana segmen spline terhubung untuk memastikan fleksibilitas yang cukup dalam kurva, tetapi mereka menerapkan *penalties* pada parameter fungsi basis-B spline parameter γ untuk menjamin pemulusan (*smoothing*) yang cukup dari kurva yang dihasilkan. Eilers dan Marx mengasumsikan bahwa $\mathbf{D}_r \gamma \sim N_{n-r}(\mathbf{0}, \lambda^{-1} \mathbf{I})$, dimana \mathbf{D}_r adalah matriks berukuran $(q-r) \times q$ dengan selisih ke- r dari q -dimensional vektor γ (Pendekatan yang sama juga digunakan oleh Wood pada tahun 2001). Oleh karena itu, terkait dengan model GAMLSS pada persamaan (2.1) : $\mathbf{G} = \lambda \mathbf{K}$ sehingga $\gamma \sim N_{n-r}(\mathbf{0}, \lambda^{-1} \mathbf{K}^{-1})$ dengan $\mathbf{K} = \mathbf{D}_r^T \mathbf{D}_r$.

2.4 Distribusi Populasi GAMLSS

Fungsi kepekatan peluang (pdf) $f(y|\theta)$ dari model pada persamaan (2.1) tetap dibiarkan dalam bentuk umum tanpa ada persyaratan eksplisit untuk distribusi dari variabel respon y yang digunakan. Satu-satunya batasan adalah implementasi GAMLSS pada *software R* yang menentukan distribusi dari y adalah fungsi $f(y|\theta)$ dengan turunan pertama (dan secara opsional turunan kedua) untuk setiap parameter θ harus dapat dihitung (*computable*). Metode derivatif secara eksplisit lebih baik, tetapi derivatif secara numerik juga dapat digunakan (menghasilkan kecepatan komputasi yang lama). Tabel 2.1 dan 2.2 menunjukkan macam-macam distribusi untuk model GAMLSS (Rigby dan Stasinopoulos, 2005).

Tabel 2.1 Distribusi Diskrit untuk GAMLSS

Jumlah parameter	Distribusi
Diskrit, 1 parameter	Binomial
	Geometrik
	Logaritmik
	Poisson
	Positive Poisson
Diskrit, 2 parameter	Beta-binomial
	Generalized Poisson
	Binomial negatif tipe I
	Binomial negatif tipe II
	Poisson-inverse Gaussian
Diskrit, 3 parameter	Sichel

Tabel 2.2 Distribusi Kontinu untuk GAMLSS

Jumlah parameter	Distribusi
Kontinu, 1 parameter	Exponential
	Double exponential
	Pareto
	Rayleigh
Kontinu, 2 parameter	Gamma
	Gumbel
	Inverse Gaussian
	Logistic
	Log-logistic
	Normal
	Reverse Gumbel
	Weibull
Kontinu, 3 parameter	Weibull (proportional hazards)
	Box-cox Normal
	Generalized extreme family
	Generalized gamma family (Box-cox Gamma)
	Power exponential family
Kontinu, 4 parameter	<i>t</i> -family
	Box-cox <i>t</i>
	Box-cox power exponential
	Johson-Su original
	Reparameterized Johnson-Su

Pada penelitian ini, tipe data dari indeks RX5DAY adalah kontinu, sedangkan indeks CDD adalah diskrit. Distribusi parameter kontinu yang akan digunakan pada penelitian ini adalah *Lognormal*, *Gamma* dan *Generalized Gamma*. Sedangkan distribusi parameter diskrit yang akan digunakan adalah *Generalized Poisson*,

Binomial Negatif dan *Poisson Inverse Gaussian*. *Probability density function* (PDF) masing-masing distribusi diskrit dan kontinu disajikan pada Tabel 2.4 dan 2.5.

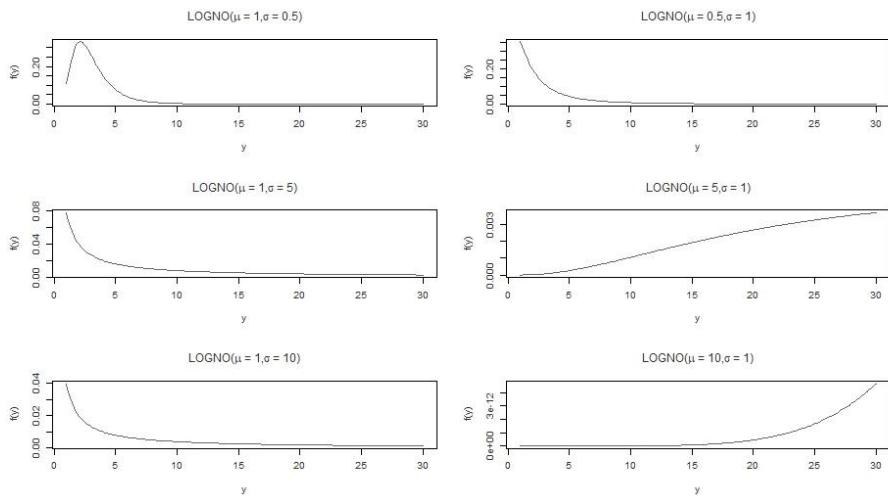
Tabel 2.4 PDF Distribusi Probabilitas Diskrit

No	Distribusi	PDF	Link Functions	
			μ	σ
1	<i>Generalized Poisson</i>	$f_y(y \mu, \sigma) = \left(\frac{\mu}{1+\sigma\mu}\right)^y \frac{(1+\sigma y)^{y-1}}{y!} \exp\left[\frac{-\mu(1+\sigma y)}{1+\sigma\mu}\right]; \mu > 0; 0 \leq \sigma < 1$	ln(.)	ln(.)
2	<i>Binomial Negatif</i>	$f_y(y \mu, \sigma) = \frac{\Gamma(y+\sigma^{-1})}{\Gamma(\sigma^{-1})\Gamma(y+1)} \left(\frac{\sigma\mu}{1+\sigma\mu}\right)^y \left(\frac{1}{1+\sigma\mu}\right)^{1/\sigma}; 0 < \mu < \infty; 0 < \sigma < \infty$	ln(.)	ln(.)
3	<i>Poisson Inverse Gaussian</i>	$f_y(y \mu, \sigma) = \left(\frac{2\alpha}{\pi}\right)^{1/2} \frac{\mu^y e^{y/\sigma} K_{\frac{y-1}{2}}(\alpha)}{y!(\alpha\sigma)^y}; \mu, \sigma > 0$ $\alpha^2 = \frac{1}{\sigma^2} + \frac{2\mu}{c\sigma}$	ln(.)	ln(.)

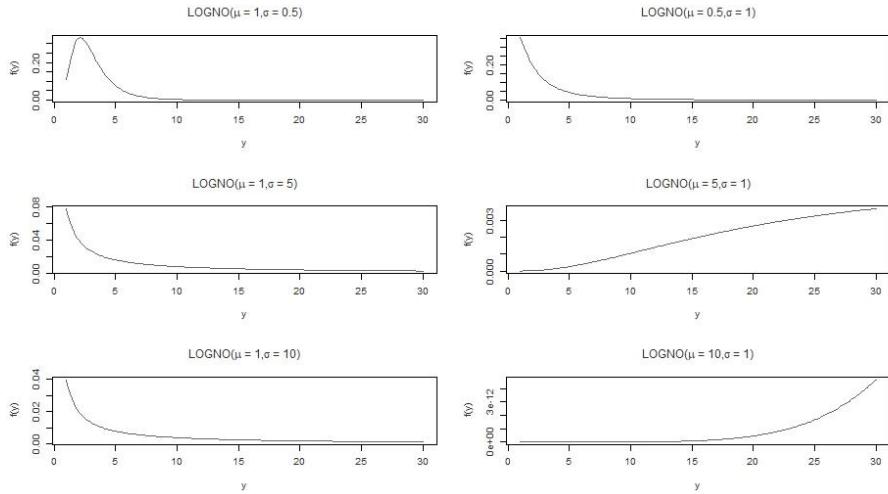
Tabel 2.5 PDF Distribusi Probabilitas Kontinu

No	Distribusi	PDF	Link Functions		
			μ	σ	ν
1	<i>Lognormal</i>	$f_y(y \mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma}} \frac{1}{y} \exp\left\{-\frac{[\log(y)-\mu]^2}{2\sigma^2}\right\}; \mu, \sigma > 0$	Identity(.)	ln(.)	-
2	<i>Gamma</i>	$f_y(y \mu, \sigma) = \frac{1}{(\sigma^2\mu)^{\frac{1}{\sigma^2}}} \frac{y^{\left[\frac{1}{\sigma^2}-1\right]} \exp\left(-\frac{y}{\sigma^2\mu}\right)}{\Gamma\left(\frac{1}{\sigma^2}\right)}$; $\mu, \sigma > 0$	ln(.)	ln(.)	-
3	<i>Generalized Gamma</i>	$f_y(y \mu, \sigma, \nu) = \frac{ \mu y^{\mu\nu-1}}{\Gamma(\theta_3)\sigma^{\mu\nu}} \exp\left\{-\left(\frac{y}{\sigma}\right)^\nu\right\}; -\infty < \mu < \infty; \sigma, \nu > 0$	ln(.)	ln(.)	Identity(.)

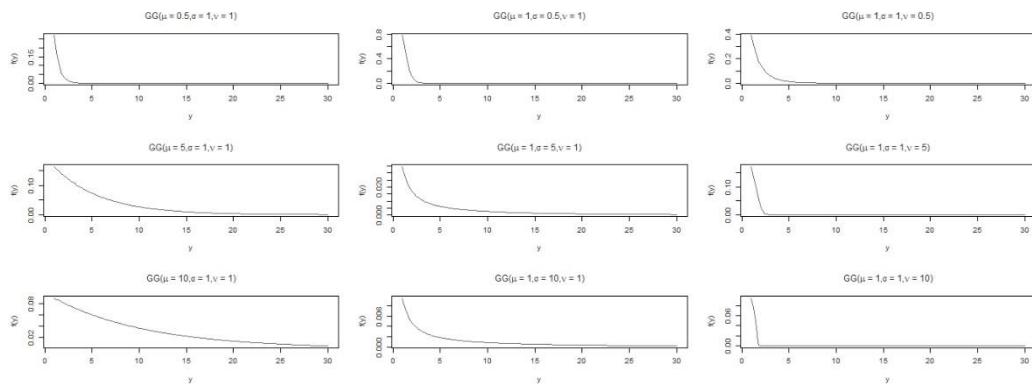
Plot PDF dari masing-masing distribusi diskrit dan kontinu dengan parameter yang berbeda-beda disajikan pada Gambar 2.1 hingga 2.6.



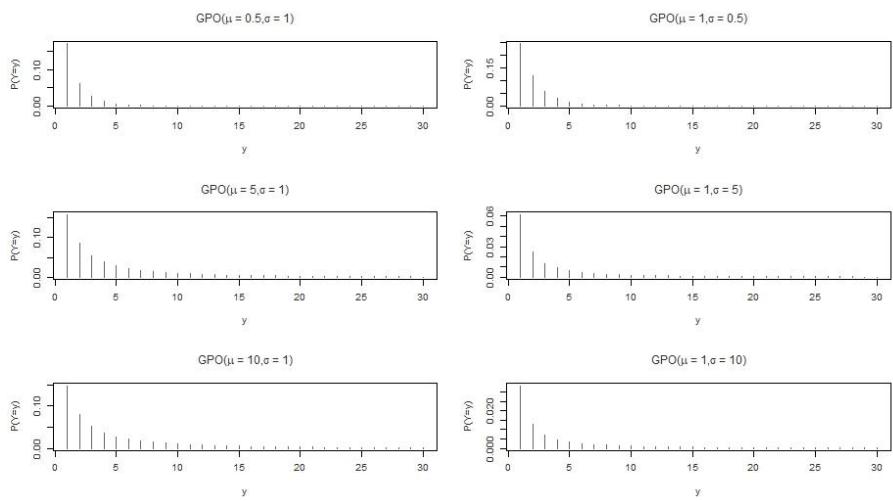
Gambar 2.1 Plot PDF Distribusi Lognormal dengan Parameter Berbeda



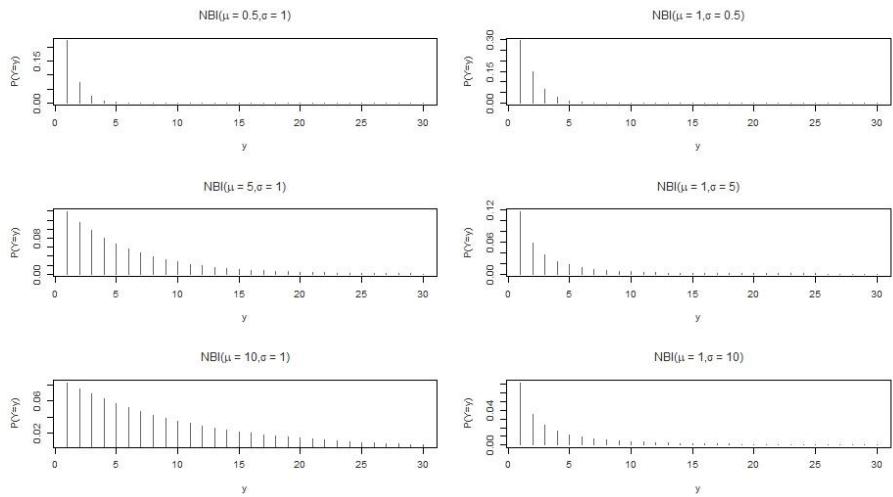
Gambar 2.2 Plot PDF Distribusi Gamma dengan Parameter Berbeda



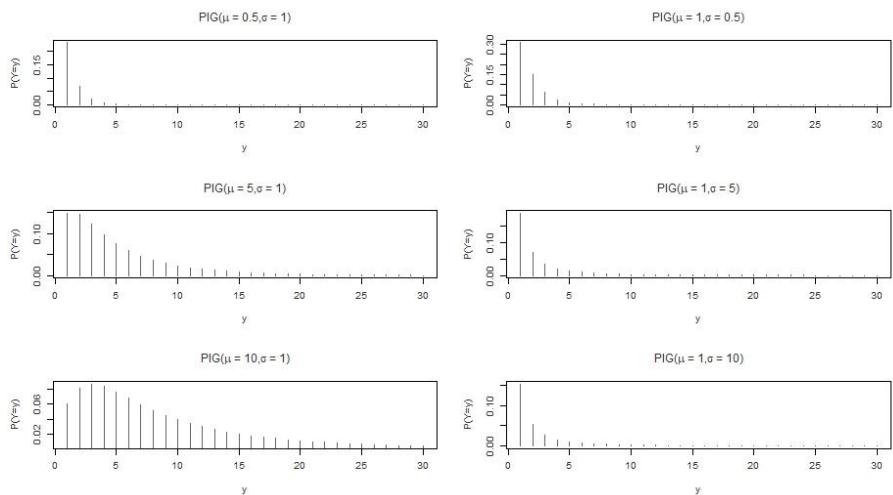
Gambar 2.3 Plot PDF Distribusi *Generalized Gamma* dengan Parameter Berbeda



Gambar 2.4 Plot PDF Distribusi *Generalized Poisson* dengan Parameter Berbeda



Gambar 2.5 Plot PDF Distribusi Binomial Negatif dengan Parameter Berbeda



Gambar 2.6 Plot PDF Distribusi *Poisson Inverse Gaussian* dengan Parameter Berbeda

2.5 Algoritma Estimasi Parameter Model GAMLSS

Terdapat dua algoritma dasar yang digunakan untuk memaksimalkan fungsi *penalized likelihood* pada persamaan (2.5). Algoritma yang pertama adalah Algoritma CG yang digeneralisasi dari algoritma Cole dan Green pada tahun 1992 yang menggunakan ekspektasi atau aproksimasi kemudian menggunakan metode *cross-derivatives* dari fungsi *likelihood* terhadap parameter θ . Namun, untuk beberapa pdf $f(y|\theta)$, parameter θ adalah orthogonal (nilai ekspektasi dari metode *cross-derivatives* untuk fungsi likelihoodnya adalah 0), misalkan untuk parameter lokasi, skala dan dispersi. Dalam kasus ini, terdapat algoritma yang lebih sederhana yakni algoritma RS yang digeneralisasi dari algoritma yang digunakan oleh Rigby dan Stasinopoulos (1996) untuk menyesuaikan *mean* dan model dispersi aditif (*dispersion additive models*) tanpa menggunakan metode *cross-derivatives*. Parameter θ orthogonal hanya pada distribusi Binomial Negatif, Gamma, inverse Gaussian, Logistik dan Normal. Namun, algoritma RS telah berhasil digunakan untuk menyesuaikan beberapa distribusi yang disajikan pada Tabel 2.1 dan 2.2 meskipun terkadang membutuhkan waktu yang cukup lama untuk mencapai konvergen. Penjelasan kedua algoritma tersebut adalah sebagai berikut :

2.5.1 Algoritma RS

Dasar dari algoritma RS adalah memaksimalkan fungsi *penalized likelihood* terhadap parameter β_k dan γ_{jk} untuk $j=1,2,\dots,J_k$ pada model untuk setiap θ_k dengan $k=1,2,\dots,p$. Pada setiap perhitungan dalam algoritma, nilai yang diperbarui dari semua kuantitas digunakan. Algoritma RS bukan merupakan kasus khusus dari Algoritma CG karena diagonal matriks pembobot \mathbf{W}_{kk} pada algoritma RS akan diperbarui bersamaan dengan penyesuaian setiap parameter θ_k , padahal dalam algoritma CG, semua elemen matriks pembobot \mathbf{W}_{ks} untuk $k=1,2,\dots,p$ dan $s=1,2,\dots,p$ dievaluasi atau diperbarui setelah menyesuaikan semua nilai θ_k untuk $k=1,2,\dots,p$ (Rigby dan Stasinopoulos, 2005). Penjelasan algoritma RS adalah sebagai berikut :

1. Langkah pertama : Menginisialisasi nilai $\theta_k^{(1,1)}$ dan efek random $\gamma_{jk}^{(1,1)}$ untuk $j = 1, 2, \dots, J_k$ dan $k = 1, 2, \dots, p$. Kalkulasi nilai inisial prediktor linier $\eta_k^{(1,1)} = g_k(\theta_k^{(1,1)})$ untuk $k = 1, 2, \dots, p$ seperti yang ditampilkan pada persamaan 2.2.
2. Langkah kedua : lakukan iterasi siklus luar ke- $r = 1, 2, \dots$ sampai konvergen, untuk $k = 1, 2, \dots, p$
 - (a) Mulai iterasi siklus dalam ke- $i = 1, 2, \dots$ sampai konvergen :
 - (i) Kalkulasi nilai $\mathbf{u}_k^{(r,i)}, \mathbf{W}_{kk}^{(r,i)}$ dan $\mathbf{z}_k^{(r,i)}$;
 - (ii) Mulai metode *backfitting* untuk $m = 1, 2, \dots$ sampai konvergen;
 - (iii) Meregresikan nilai residual parsial :

$\mathcal{E}_{0k}^{(r,i,m)} = \mathbf{z}_k^{(r,i)} - \sum_{j=1}^{J_k} \mathbf{Z}_{jk} \gamma_{jk}^{(r,i,m)}$ terhadap matriks \mathbf{X}_k dengan pembobot iteratif $\mathbf{W}_{kk}^{(r,i)}$ untuk mendapatkan nilai parameter yang baru $\beta_k^{(r,i,m+1)}$;

 - (iv) Untuk $j = 1, 2, \dots, J_k$, perlu dilakukan penghalusan (*smoothing*) untuk residual parsial :
$$\mathcal{E}_{jk}^{(r,i,m)} = \mathbf{z}_k^{(r,i)} - \mathbf{X}_k \beta_k^{(r,i,m+1)} - \sum_{t=1, t \neq j}^{J_k} \mathbf{Z}_{tk} \gamma_{tk}^{(r,i,m)}$$

menggunakan *shrinking* matriks $\mathbf{S}_{jk} = \mathbf{Z}_{jk} (\mathbf{Z}_{jk}^T \mathbf{W}_{kk} \mathbf{Z}_{jk} + \mathbf{G}_{jk})^{-1} \mathbf{Z}_{jk}^T \mathbf{W}_{kk}$ untuk mendapatkan nilai prediktor bentuk aditif $\mathbf{Z}_{jk} \gamma_{jk}^{(r,i,m+1)}$ yang baru dengan persamaan $\mathbf{Z}_{jk} \gamma_{jk}^{(r,i,m+1)} = \mathbf{S}_{jk}^{(r)} \mathcal{E}_{jk}^{(r,i,m)}$;

- (v) Akhiri metode *backfitting* pada nilai $\beta_k^{(r,i,.)}$ dan $\mathbf{Z}_{jk} \gamma_{jk}^{(r,i,.)}$ yang konvergen sehingga $|\beta_k^{(r,i+1)} - \beta_k^{(r,i,.)}| \leq \varepsilon$ dan $|\gamma_{jk}^{(r,i+1)} - \gamma_{jk}^{(r,i,.)}| \leq \varepsilon$ untuk $j = 1, 2, \dots, J_k$. Jika tidak, perbarui nilai m dan lanjutkan metode iterasi *backfitting* ($\varepsilon \approx 0,000\dots$) pada langkah ke 2(a) poin ke (ii).

- (vi) Hitung nilai $\eta_k^{(r,i+1)}$ dan $\theta_k^{(r,i+1)}$ yang telah diperbarui $\eta_k^{(r,i+1)} = g_k(\theta_k^{(r,i+1)})$ seperti yang ditampilkan pada persamaan 2.2;
- (b) Akhiri iterasi siklus dalam pada nilai $\beta_k^{(r..)}$ dan prediktor bentuk aditif $\mathbf{Z}_{jk}\gamma_{jk}^{(r..)}$ yang konvergen sehingga $|\beta_k^{(r+1,1)} - \beta_k^{(r..)}| \leq \varepsilon$, $|\gamma_{jk}^{(r+1,1)} - \gamma_{jk}^{(r..)}| \leq \varepsilon$ untuk $j = 1, 2, \dots, J_k$, $|\eta_k^{(r+1,1)} - \eta_k^{(r..)}| \leq \varepsilon$ dan $|\theta_k^{(r+1,1)} - \theta_k^{(r..)}| \leq \varepsilon$ dengan $\varepsilon \approx 0,000\dots$. Jika tidak, perbarui nilai i dan lanjutkan iterasi siklus dalam pada Langkah 2(a).

2.5.2 Algoritma CG

Algoritma CG yang didasarkan pada Cole dan Green (1992) adalah sebagai berikut :

1. Langkah pertama : Menginisialisasi nilai $\theta_k^{(1,1)}$ dan efek random $\gamma_{jk}^{(1,1)}$ untuk dan $k = 1, 2, \dots, p$. Kalkulasi nilai $\eta_k^{(1)} = \eta_k^{(1,1)} = g_k(\theta_k^{(1,1)})$ untuk $k = 1, 2, \dots, p$ seperti yang ditampilkan pada persamaan 2.2.
2. Langkah kedua : Mulai iterasi siklus luar untuk $r = 1, 2, \dots$ hingga konvergen.
3. Langkah ketiga : Kalkulasi dan tetapkan nilai $\mathbf{u}_k^{(r)}, \mathbf{W}_{ks}^{(r)}$ dan $\mathbf{z}_k^{(r)}$ untuk $k = 1, 2, \dots, p$ dan $s = 1, 2, \dots, p$. Lakukan iterasi Newton-Raphson ke-r dengan algoritma sebagai berikut :
 - (a) Mulai siklus dalam ke- $i = 1, 2, \dots$ sampai konvergen untuk $k = 1, 2, \dots, p$,
 - (i) Mulai proses *backfitting* $m = 1, 2, \dots$ hingga konvergen $X_k \beta_k^{(r,i,m+1)} = \mathbf{H}_k \varepsilon_{0k}^{(r,i,m)}$, dan untuk $j = 1, 2, \dots, J_k$:

$$\mathbf{Z}_{jk} \gamma_{jk}^{(r,i,m+1)} = \mathbf{S}_{jk}^{(r)} \varepsilon_{jk}^{(r,i,m)},$$
 - (ii) Akhiri proses *backfitting* pada nilai $\beta_k^{(r,i..)}$ dan $\mathbf{Z}_{jk} \gamma_{jk}^{(r,i..)}$ yang konvergen sehingga $|\beta_k^{(r,i+1)} - \beta_k^{(r,i..)}| \leq \varepsilon$ dan $|\gamma_{jk}^{(r,i+1)} - \gamma_{jk}^{(r,i..)}| \leq \varepsilon$ untuk $j = 1, 2, \dots, J_k$. Jika tidak, perbarui nilai m dan lanjutkan

metode iterasi *backfitting*. ($\varepsilon \approx 0,000\dots$) pada langkah ke 3 (a) poin ke (i)

(vii) Hitung nilai $\eta_k^{(r,i+1)}$ dan $\theta_k^{(r,i+1)}$ yang telah diperbarui

$$\eta_k^{(r,i+1)} = g_k(\theta_k^{(r,i+1)}) \text{ seperti pada persamaan 2.2;}$$

(b) Akhiri iterasi siklus dalam pada nilai $\beta_k^{(r..)}$ dan prediktor bentuk aditif

$$\mathbf{Z}_{jk} \gamma_{jk}^{(r..)} \text{ yang konvergen sehingga } |\beta_k^{(r+1,1)} - \beta_k^{(r..)}| \leq \varepsilon,$$

$$|\gamma_{jk}^{(r+1,1)} - \gamma_{jk}^{(r..)}| \leq \varepsilon, |\eta_k^{(r+1,1)} - \eta_k^{(r..)}| \leq \varepsilon \text{ dan } |\theta_k^{(r+1,1)} - \theta_k^{(r..)}| \leq \varepsilon \text{ dengan}$$

$\varepsilon \approx 0,000\dots$ untuk $j = 1, 2, \dots, J_k$ dan $k = 1, 2, \dots, p$. Jika tidak, perbarui nilai i dan lanjutkan iterasi siklus dalam pada Langkah 2(a).

Matriks $\mathbf{H}_k^{(r)}$ dan $\mathbf{S}_k^{(r)}$ akan dijelaskan pada Sub-bab 2.5.3 mengenai memaksimalkan fungsi *penalized likelihood*, kedua matriks tersebut adalah adalah matriks proyeksi dan *shrinking* untuk komponen parametrik dan aditif dari masing-masing model pada iterasi ke- r untuk $j = 1, 2, \dots, J_k$ dan $k = 1, 2, \dots, p$.

Residual parsial $\varepsilon_{0k}^{(r,i,m)}$ dan $\varepsilon_{jk}^{(r,i,m)}$ adalah variabel yang digunakan untuk menyesuaikan komponen parametrik dan aditif (*random effects* atau *smoothing*) dari masing-masing model yang didefinisikan sebagai berikut :

$$\begin{aligned} \varepsilon_{0k}^{(r,i,m)} &= \mathbf{z}_k^{(r)} - \sum_{t=1}^{J_k} \mathbf{Z}_{tk} \gamma_{tk}^{(r,i,c)} - (\mathbf{W}_{kk}^{(r)})^{-1} \sum_{s=1, s \neq k}^p \mathbf{W}_{ks}^{(r)} (\eta_s^{(r,c)} - \eta_s^{(r)}), \\ \varepsilon_{jk}^{(r,i,m)} &= \mathbf{z}_k^{(r)} - \mathbf{X}_k \beta_k^{(r,i,m+1)} - \sum_{t=1}^{J_k} \mathbf{Z}_{tk} \gamma_{tk}^{(r,i,c)} - (\mathbf{W}_{kk}^{(r)})^{-1} \sum_{s=1, s \neq k}^p \mathbf{W}_{ks}^{(r)} (\eta_s^{(r,c)} - \eta_s^{(r)}). \end{aligned} \quad (2.8)$$

Panjang langkah dari metode Newton – Raphson secara keseluruhan dalam algoritma dapat untuk langkah ke- α , dengan memperbarui prediktor linier sebagai berikut :

$$\eta_k^{(r+1)}(\alpha) = \alpha \eta_k^{(r+1)} + (1 - \alpha) \eta_k^{(r)} \quad (2.9)$$

Persamaan (2.9) dengan $\eta_k^{(r+1)}(\alpha)$ untuk $k = 1, 2, \dots, p$ lebih baik digunakan daripada menggunakan $\eta_k^{(r+1)}$ untuk $k = 1, 2, \dots, p$, pada akhir dari siklus dalam untuk siklus luar ke- r kemudian kalkulasi $\mathbf{u}_k^{(r+1)}, \mathbf{W}_{ks}^{(r+1)}$ dan $\mathbf{z}_k^{(r+1)}$ untuk $k = 1, 2, \dots, p$ dan

$s = 1, 2, \dots, p$. Panjang langkah optimal untuk iterasi ke- r tertentu dapat diperoleh dengan memaksimalkan $l_p(\alpha)$ terhadap α (Rigby dan Stasinopoulos, 2005).

2.5.3 Memaksimalkan Fungsi *Penalized Likelihood*

Memaksimalkan fungsi *penalized likelihood* l_p yang dituliskan pada persamaan (2.5) terhadap parameter β_k dan γ_{jk} untuk $j = 1, 2, \dots, J_k$ dan $k = 1, 2, \dots, p$ mengarah pada algoritma yang telah dijelaskan pada sub-bab 2.5.1 dan 2.5.2. Memaksimalkan fungsi *penalized likelihood* dapat dicapai dengan 2 langkah sebagai berikut :

- (a) Turunan pertama dan kedua dari persamaan (2.5) didapatkan untuk mengerjakan langkah Newton-Raphson untuk memaksimalkan persamaan (2.5) terhadap parameter β_k dan γ_{jk} untuk $j = 1, 2, \dots, J_k$ dan $k = 1, 2, \dots, p$.
- (b) Setiap langkah dari algoritma Newton-Raphson dicapai dengan menggunakan prosedur *backfitting* melalui parameter dan melalui bentuk aditif dari k prediktor linier.

1. Step (a)

Algoritma untuk memaksimumkan fungsi *penalized likelihood* l_p pada persamaan (2.5) dengan menggunakan algoritma Newton-Raphson. Turunan pertama (*score function*) dan turunan kedua dari l_p terhadap β_k dan γ_{jk} untuk $j = 1, 2, \dots, J_k$ dan $k = 1, 2, \dots, p$ dikalkulasi pada iterasi ke- r pada prediktor $\eta_k^{(r)}$ untuk $k = 1, 2, \dots, p$

Langkah Newton-Raphson : diberikan $\mathbf{A}^{(r)}(\alpha^{(r+1)} - \alpha^{(r)}) = \mathbf{a}^{(r)}$, misalkan :

$$\begin{pmatrix} A_{11} & A_{12} & \cdots & A_{1p} \\ A_{21} & A_{22} & \cdots & A_{2p} \\ \vdots & \vdots & \cdots & \vdots \\ A_{p1} & A_{p2} & \cdots & A_{pp} \end{pmatrix}^{(r)} \begin{pmatrix} \alpha_1^{(r+1)} - \alpha_1^{(r)} \\ \alpha_2^{(r+1)} - \alpha_2^{(r)} \\ \vdots \\ \alpha_p^{(r+1)} - \alpha_p^{(r)} \end{pmatrix} = \begin{pmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{pmatrix}^{(r)} \quad (2.10)$$

Dimana matriks \mathbf{A}_{ks} didefinisikan sebagai :

$$\mathbf{A} = \begin{pmatrix} \mathbf{X}_k^T \mathbf{W}_{ks} \mathbf{X}_s & \mathbf{X}_k^T \mathbf{W}_{ks} \mathbf{Z}_{1s} & \cdots & \mathbf{X}_k^T \mathbf{W}_{ks} \mathbf{Z}_{J_s s} \\ \mathbf{Z}_{1k}^T \mathbf{W}_{ks} \mathbf{X}_s & \mathbf{Z}_{1k}^T \mathbf{W}_{ks} \mathbf{Z}_{1s} + \mathbf{G}_{1k} (\text{if } s = k) & \cdots & \mathbf{Z}_{1k}^T \mathbf{W}_{ks} \mathbf{Z}_{J_s s} \\ \vdots & \vdots & \cdots & \vdots \\ \mathbf{Z}_{J_k k}^T \mathbf{W}_{ks} \mathbf{X}_s & \mathbf{Z}_{J_k k}^T \mathbf{W}_{ks} \mathbf{Z}_{1s} & \cdots & \mathbf{Z}_{J_k k}^T \mathbf{W}_{ks} \mathbf{Z}_{J_s s} + \mathbf{G}_{J_k k} (\text{if } s = k) \end{pmatrix} \quad (2.11)$$

dan vektor

$$\mathbf{a}_k^{(r)} = \begin{pmatrix} \mathbf{X}_k^T \mathbf{u}_k^{(r)} \\ \mathbf{Z}_{1k}^T \mathbf{u}_k^{(r)} - \mathbf{G}_{1k}^T \gamma_{1k}^{(r)} \\ \vdots \\ \mathbf{Z}_{J_k k}^T \mathbf{u}_k^{(r)} - \mathbf{G}_{J_k k}^T \gamma_{J_k k}^{(r)} \end{pmatrix} \quad (2.12)$$

Dimana $\mathbf{u}_k = \partial l / \partial \eta_k$ dan $\mathbf{W}_{ks} = -\partial^2 l / \partial \eta_k \partial \eta_s = -\text{diag}(\partial^2 l_i / \partial \eta_{ik} \partial \eta_{is})$ dengan $i = 1, 2, \dots, n$, $k = 1, 2, \dots, p$ dan $s = 1, 2, \dots, p$.

2. Step (b)

Sekarang pertimbangkan baris yang berhubungan dengan memperbarui nilai γ_{jk} :

$$\mathbf{G}_{jk}(\gamma_{jk}^{(r+1)} - \gamma_{jk}^{(r)}) + \mathbf{Z}_{jk}^T \sum_{s=1}^p \mathbf{W}_{ks}^{(r)} (\eta_s^{(r+1)} - \eta_s^{(r)}) = \mathbf{Z}_{jk}^T \mathbf{u}_k^{(r)} - \mathbf{G}_{jk} \gamma_{jk}^{(r)} \quad (2.13)$$

Memperluas dan menata kembali persamaan :

$$\mathbf{Z}_{jk}^T \gamma_{jk}^{(r)} = \mathbf{S}_{jk}^{(r)} \varepsilon_{jk}^{(r)} \quad (2.14)$$

Dimana, untuk $j = 1, 2, \dots, J_k$ dan $k = 1, 2, \dots, p$,

$$\mathbf{S}_{jk}^{(r)} = \mathbf{Z}_{jk} (\mathbf{Z}_{jk}^T \mathbf{W}_{kk}^{(r)} \mathbf{Z}_{jk} + \mathbf{G}_{jk})^{-1} \mathbf{Z}_{jk}^T \mathbf{W}_{kk}^{(r)} \quad (2.15)$$

Adalah matriks *shrinking* atau *smoothing*, dimana :

$$\varepsilon_{jk}^{(r)} = \mathbf{z}_k^{(r)} - \mathbf{X}_k \beta_k^{(r+1)} - \sum_{i=1, i \neq j}^{J_k} \mathbf{Z}_{ik} \gamma_{ik}^{(r+1)} - (\mathbf{W}_{kk}^{(r)})^{-1} \sum_{s=1, s \neq k}^p \mathbf{W}_{ks}^{(r)} (\eta_s^{(r+1)} - \eta_s^{(r)}) \quad (2.16)$$

Adalah residual parsial dan $\mathbf{z}_k^{(r)} = \eta_k^{(r)} + (\mathbf{W}_{kk}^{(r)})^{-1} \mathbf{u}_k^{(r)}$ adalah variabel respon yang disesuaikan.

(Alat untuk mendapatkan estimasi nilai $\gamma_{jk}^{(r+1)}$ yang telah diperbarui pada persamaan (2.14) adalah dengan menerapkan metode estimasi *Weighted Least Squares* pada model data *augmented* sebagai berikut :

$$\begin{pmatrix} \varepsilon_{jk}^{(r)} \\ \mathbf{0} \end{pmatrix} = \begin{pmatrix} \mathbf{Z}_{jk} \\ -\mathbf{D}_{jk} \end{pmatrix} \gamma_{jk} + \begin{pmatrix} e_{0k} \\ e_{jk} \end{pmatrix} \quad (2.17)$$

Dimana $\mathbf{0}$ adalah vektor 0 dengan panjang q_{jk} , $\mathbf{D}_{jk}^T \mathbf{D}_{jk} = \mathbf{G}_{jk}$, $e_{0k} \sim N(0, (\mathbf{W}_{kk}^{(r)})^{-1})$

dan $e_{jk} \sim N(0, \mathbf{I})$. Metode ini dapat digeneralisasi untuk mengestimasi α_k dan bahkan α .)

Dengan cara yang sama, ambil baris yang berhubungan dengan β_k dan menata ulang persamaan :

$$\mathbf{X}_k \beta_k^{(r+1)} = \mathbf{H}_k^{(r)} \varepsilon_{0k}^{(r)} \quad (2.18)$$

Dimana, untuk $k = 1, 2, \dots, p$,

$$\mathbf{H}_k^{(r)} = \mathbf{X}_k (\mathbf{X}_k^T \mathbf{W}_{kk}^{(r)} \mathbf{X}_k)^{-1} \mathbf{X}_k^T \mathbf{W}_{kk}^{(r)} \quad (2.19)$$

dan

$$\varepsilon_{0k}^{(r)} = z_k^{(r)} - \sum_{i=1}^{J_k} Z_{ik} \gamma_{ik}^{(r+1)} - (\mathbf{W}_{kk}^{(r)})^{-1} \sum_{s=1, s \neq k}^p \mathbf{W}_{ks}^{(r)} (\eta_s^{(r+1)} - \eta_s^{(r)}) \text{ untuk } k = 1, 2, \dots, p \quad (2.20)$$

Langkah metode iterasi Newton-Raphson ke- r dicapai dengan menggunakan prosedur *backfitting* untuk masing-masing k melalui persamaan (2.18) kemudian persamaan (2.14) untuk $j = 1, 2, \dots, J_k$ dan $k = 1, 2, \dots, p$ hingga konvergen dari nilai $\alpha_k^{(r+1)}$ yang telah diperbarui untuk $k = 1, 2, \dots, p$. Nilai prediktor $\eta_k^{(r+1)}$ yang telah diperbarui, turunan pertama $\mathbf{u}_k^{(r+1)}$, diagonal matriks pembobot $\mathbf{W}_{ks}^{(r+1)}$ dan variabel respon yang telah disesuaikan $z_k^{(r+1)}$ untuk $k = 1, 2, \dots, p$ dan $s = 1, 2, \dots, p$ kemudian dihitung untuk mendapatkan iterasi Newton Raphson ke- $r+1$ hingga mencapai konvergensi.

2.6 Seleksi Model GAMLSS dengan GAIC (*Generalized Akaike Information Criterion*)

Statistical Modelling Model GAMLSS dituliskan dengan $M = (D, G, T, \lambda)$:

- (a) D menjelaskan distribusi dari variabel respon,
- (b) G menjelaskan set dari *link function* (g_1, \dots, g_p) untuk parameter $(\theta_1, \dots, \theta_p)$,
- (c) T menjelaskan set istilah prediktor (t_1, \dots, t_p) untuk prediktor (η_1, \dots, η_p) dan
- (d) λ menjelaskan set dari *hyperparameter*

Setiap model M dapat dinilai oleh *Global Deviance* (GD) untuk model-model

GAMLSS parametrik dengan $GD = -2l(\hat{\theta})$ dimana $l(\hat{\theta}) = \sum_{i=1}^n l(\hat{\theta}^i)$. Dua model

nested GAMLSS parametrik M_0 dan M_1 dengan *fitted Global Deviance* GD_0 dan GD_1 serta derajat bebas eror df_{e0} dan df_{e1} dibandingkan dengan menggunakan

generalized likelihood ratio test statistic $\Lambda = GD_0 - GD_1$ yang berdistribusi asimtotik χ^2 dibawah M_0 dengan derajat bebas $d = df_{e0} - df_{e1}$ (dengan syarat asumsi terpenuhi). Untuk setiap model M dengan derajat bebas df_e yang didapatkan dari $df_e = n - \sum_{k=1}^p df_{\theta_k}$, dimana df_{θ_k} adalah derajat bebas yang digunakan dalam prediktor model untuk parameter θ_k dengan $k = 1, 2, \dots, p$.

Untuk membandingkan model-model *non-nested* GAMLSS (termasuk model dengan bentuk *smoothing*) dan untuk membatasi *overfitting*, metode GAIC dapat digunakan. Nilai GAIC didapatkan dari penambahan *fixed penalty* # dalam *fitted global deviance* untuk setiap derajat bebas efektif yang digunakan dalam model, misalkan $GAIC(\#) = GD + \#df$, dimana df adalah total derajat bebas efektif yang dalam model dan GD adalah *fitted global deviance*. Model dengan nilai GAIC terkecil kemudian dipilih. Kriteria AIC (*Akaike Information Criterion*) dan SBC (*Schwarz Bayesian Criterion*) adalah kasus khusus dari metode GAIC, secara asimtotik kedua kriteria AIC dan SBC dibenarkan sebagai prediksi tingkat kecocokan dalam kumpulan data baru, yaitu perkiraan terhadap kesalahan prediksi rata-rata. Kriteria SBC bersifat sangat membatasi (*restrictive*) dalam model, sedangkan AIC sebaliknya, konsekuensinya adalah model yang dipilih berdasarkan kriteria AIC biasanya sangat rumit (mengarah ke *overfitting* dan estimasi parameter yang tidak stabil *unstable*), sedangkan model yang dipilih berdasarkan kriteria SBC biasanya sangat sederhana (mengarah ke *underfitting* dan estimasi parameter yang bias). Metode GAIC memungkinkan untuk mencoba *penalties* yang berbeda untuk tujuan pemodelan yang berbeda, sehingga sensitivitas dan *robust* dari model yang terpilih dapat diselidiki (Rigby dan Stasinopoulos, 2017). Rumus dari GAIC dituliskan pada persamaan (2.21).

$$GAIC = -2l(\hat{\theta}) + 2tr(\mathbf{F}^{-1}\mathbf{R}) \quad (2.21)$$

Dimana \mathbf{F} adalah invers dari *Fisher Information Matrix* dalam *inner product* atau bentuk Hessian, dan \mathbf{R} adalah *Fisher Information Matrix* dalam *outer product*, kedua matriks berdimensi $k \times k$, dengan k adalah jumlah prediktor. GAIC ditafsirkan sama dengan AIC dengan pengecualian bahwa bentuk *penalty*nya

adalah $2tr(\mathbf{F}^{-1}\mathbf{R})$. GAIC digunakan apabila diragukan apakah kelas model potensial telah ditentukan dengan benar dengan menguji hubungan antara dua bentuk estimasi matriks informasi. Dengan kata lain, GAIC digunakan untuk menghindari kesalahan menentukan model. Selain itu, GAIC seharusnya digunakan pada data dengan *skewness* dan *kurtosis* yang tinggi karena kriteria AIC tidak memadai untuk mengimbangi bias dalam estimasi *Maximum Likelihood* dari parameter dalam model (Bozdogan, 2000), sehingga kriteria GAIC tepat diterapkan pada model GAMLSS.

2.7 Koefisien Filliben

Uji normalitas dari residual juga dilakukan untuk menganalisis *goodness-of-fit* dari model optimal dengan menghitung koefisien Filliben. Koefisien Filliben dinotasikan dengan statistik uji r dengan kelebihan 1) mudah dipahami secara konseptual dengan menggabungkan dua konsep sederhana yang mendasar: plot probabilitas dan koefisien korelasi; 2) komputasi sederhana karena semua koefisien operasional secara internal dapat dihitung; dan 3) siap dikembangkan sebagai statistik uji distribusi untuk hipotesis tidak normal.

Koefisien Filliben dapat meringkas dan memformalkan informasi distribusi yang terkandung dalam plot probabilitas normal. Plot probabilitas normal didefinisikan sebagai plot ke- i order statistik X , versus beberapa ukuran lokasi lokasi (X_i) dari statistik order ke- i dari distribusi normal standar. Hingga saat ini, ukuran lokasi yang paling sering digunakan untuk statistik order ke- i adalah nilai statistik *mean* atau rata-rata ($loc(X_i) = E(X_i) = E_i$). Secara umum, statistik *mean* memiliki tiga sifat yang tidak diinginkan: 1) Teknik integrasi untuk menghitung E_i bervariasi dari distribusi ke distribusi-tidak ada teknik seragam untuk menghasilkan E_i untuk semua distribusi; 2) Untuk beberapa distribusi, statistik order *mean* sulit atau memakan waktu untuk dihitung sehingga harus diperkirakan; dan 3) Untuk distribusi lain (misalkan, Cauchy), statistik order *mean* mungkin tidak selalu ditentukan. Ketiga kelemahan ini dihindari secara umum dengan memilih untuk mengukur lokasi statistik order ke- i dengan mediannya ($loc(X_i) = Med(X_i) = M_i$) daripada rata-ratanya. Statistik uji r Filliben dituliskan pada persamaan (2.24).

$$r_{X,M} = \text{Corr}(X, M) = \frac{\sum_{i=1}^n (X_i - \bar{X})(M_i - \bar{M})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (M_i - \bar{M})^2}} \quad (2.22)$$

Singkatnya, bahwa normalitas yang mendasari statistik r akan cenderung menghasilkan plot probabilitas normal linier yang akan tercermin oleh nilai koefisien korelasi Filliben r yang mendekati satu (Filliben, 1975).

2.8 Random Variate Generation

Random Variate Generation adalah proses untuk menghasilkan pengamatan yang memiliki sifat stokastik (distribusi) dari variabel random. Dalam konteks simulasi, *Random Variate Generation* (RVG) bukanlah konsep yang berdiri sendiri, pemodelan input simulasi yang berfokus pada desain, pengembangan, dan pemilihan distribusi probabilitas yang sesuai untuk mewakili perilaku sistem diperlukan untuk menghasilkan nilai-nilai generasi distribusi yang representatif (Kuhl, 2017). Metode RVG yang digunakan dalam penelitian ini adalah *univariate transformation* dan algoritma *acceptance-rejection*.

2.8.1 Univariate Transformation

Salah satu metode dari RVG adalah *univariate transformation*. Berikut ini adalah aturan umum yang diterapkan dalam transformasi variabel random ke variabel lain. Misalkan Z adalah variabel random kontinu dengan pdf yang didefinisikan pada *space A*, Y adalah variabel baru dengan $Y = g(Z)$, di mana fungsi $g(\cdot)$ adalah transformasi satu-satu yang memetakan set $Z \in A$. Invers dari $g(\cdot)$ adalah $z = g^{-1}(y) = h(y)$ dengan turunan pertama kontinu dan non-zero $\frac{dz}{dy} = h'(y)$

untuk semua poin di set B , kemudian pdf dari Y dituliskan sebagai berikut :

$$\begin{aligned} f_Y(y) &= f_Z(h(y))|h'(y)| \\ &= f_Z(h(y)) \frac{dz}{dy} \end{aligned} \quad (2.23)$$

$F_Y(y) = f_Z(z)$ menyatakan bahwa fungsi $g(\cdot)$ adalah fungsi monoton naik (Rigby et al., 2017).

2.8.2 Acceptance-Rejection

Metode *acceptance-rejection* dapat digunakan ketika fungsi distribusi kumulatif tidak *closed-from*. Dalam metode ini, variabel random dibangkitkan dari satu distribusi dan dapat diterima atau ditolak sedemikian rupa sehingga nilai yang diterima mengikuti distribusi yang diinginkan. Schmeiser (1980) menjelaskan algoritma metode *acceptance-rejection* secara umum sebagai berikut :

Diketahui variabel random X dengan pdf $f(x)$, $t(x)$ adalah *majorizing function* dari $f(x)$ sedemikian hingga $t(x) \geq f(x)$ untuk semua nilai x . $g(x) = t(x)/c$ menunjukkan *density function proportional* untuk $t(x)$ dengan

$$c = \int_{-\infty}^{\infty} t(x)dx.$$

1. Bangkitkan $x \sim g(x)$
2. Bangkitkan $u \sim U(0,1)$
3. Apabila $u > f(x)/t(x)$, kemudian tolak x dan kembali ke langkah pertama
4. Mendapatkan nilai x

Waktu eksekusi dari algoritma *acceptance-rejection* tergantung pada tiga faktor utama: (1) waktu untuk menghasilkan x dari $g(x)$; (2) waktu untuk melakukan perbandingan pada langkah 3; dan (3) jumlah iterasi yang diperlukan untuk mendapatkan nilai x yang diterima (Kuhl, 2017).

2.9 Worm Plot

Worm plot merupakan *detrended Q-Q plot*, sumbu vertikal dari *worm plot* menggambarkan perbedaan antar lokasi dalam distribusi teoritis dan empiris untuk setiap pengamatan. Poin data di setiap plot membentuk string seperti cacing (*worm*), bentuk cacing menunjukkan bagaimana data berbeda dari asumsi distribusi yang mendasarinya. *Detrended plot* berisi interval kepercayaan 95% dari unit normal kuantil. Diketahui kuantil z dengan probabilitas p dan ukuran sampel n , interval kepercayaan 95% dihitung dari : $\pm 1,96 \times f(z)^{-1} \sqrt{p(1-p)n}$, dengan $f(z)$ adalah pdf dari distribusi normal (Van dan Fredriks, 2001).

2.10 Curah Hujan Ekstrem

Curah hujan merupakan ketinggian air hujan yang terkumpul dalam tempat datar, tidak menguap, tidak meresap, dan tidak mengalir. Ketika curah hujan satu milimeter artinya dalam luasan satu meter persegi pada tempat yang datar tertampung air setinggi satu milimeter atau tertampung air sebanyak satu liter (Kadarsah, 2007). Peristiwa curah hujan ekstrem dapat digambarkan dalam berbagai skala waktu dari satu jam hingga beberapa hari. Namun, karena pendekatan keseluruhan adalah untuk menggambarkan besarnya dan durasi untuk suatu peristiwa, oleh karena itu lebih praktis untuk menggunakan suatu satuan waktu sebagai ukuran curah hujan ekstrem. Curah hujan yang ekstrem didefinisikan sebagai peristiwa presipitasi yang ditandai terjadi selama periode satu hingga beberapa hari dengan total curah hujan harian melebihi ambang tertentu yang ditentukan untuk lokasi tertentu (berbasis stasiun). Curah hujan ekstrem tidak sama dengan curah hujan deras atau hujan lebat. Dalam kosakata meteorologi internasional (WMO-No 182) hujan lebat didefinisikan sebagai hujan dengan tingkat akumulasi melebihi nilai tertentu mis. 7,6 mm / jam. Oleh karena itu, hujan lebat mungkin tidak ekstrem (seperti di iklim tropis) dan curah hujan ekstrem mungkin bukan hasil dari hujan lebat (WMO, 2018). Terdapat beberapa indikator yang direkomendasikan oleh *Working Group on Climate Change Detection* (WGCCD) untuk menganalisis perubahan iklim ekstrem, dua diantaranya adalah RX5DAY dan CDD (WGCCD, 2001).

2.10.1 RX5DAY (*Maximum 5 Day Precipitation Total*)

RX5DAY merupakan indeks berbasis durasi, didefinisikan sebagai total curah hujan 5 hari berturut-turut tertinggi di setiap periode. Penggunaan indeks ini mampu menyederhanakan analisis dan menunjukkan perubahan intensitas curah hujan ekstrem. Satuan dari indeks RX5DAY adalah mm (satuan curah hujan). Misalkan RR_{kj} adalah jumlah curah hujan untuk interval 5 hari yang berakhir pada interval k , periode j . Maka nilai RX5DAY untuk periode j adalah :

$$\text{RX5DAY}_j = \max (RR_{kj}) \quad (2.24)$$

2.10.2 CDD (*Maximum Number of Consecutive Dry Days*)

CDD juga merupakan indeks berbasis durasi dan berpotensi menjadi indikator kekeringan yang seringkali digunakan. CDD merupakan jumlah maksimum hari berturut-turut dengan $RR < 1 \text{ mm}$. Satuan dari indeks CDD adalah hari. Misalkan RR_{ij} merupakan jumlah curah hujan harian pada hari I dalam periode j . Perhitungan CDD untuk periode j adalah :

$$RR_{ij} < 1 \text{ mm} \quad (2.25)$$

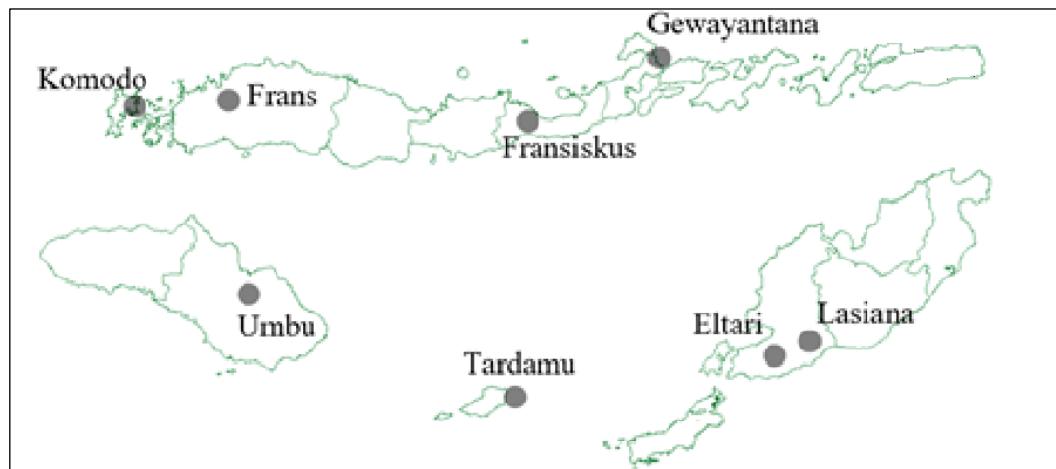
BAB III

METODE PENELITIAN

Bab ini menjelaskan tahapan penelitian untuk memodelkan curah hujan ekstrem di Provinsi Nusa Tenggara Timur secara non-stasioner dengan *Generalized Additive Models for Location, Scale and Shape* (GAMLSS). Pembahasan metodologi penelitian pada bab ini meliputi sumber data, variabel penelitian, langkah analisis.

3.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang didapatkan dari Badan Meteorologi, Klimatologi dan Geofisika (BMKG), yakni data curah hujan di 8 stasiun meteorologi di Provinsi NTT. Provinsi NTT adalah provinsi yang terdiri dari beberapa pulau. Data dikumpulkan dari 8 stasiun meteorologi di NTT yang terletak di pulau yang berbeda. Ilustrasi peta lokasi stasiun meteorologi di NTT disajikan pada Gambar 3.1.



Gambar 3.1 Persebaran Stasiun di NTT (Kuswanto et al., 2018)

Gambar 3.1 menunjukkan bahwa 8 stasiun tersebar di seluruh pulau. Oleh karena itu, hasil analisis data dari stasiun tertentu mewakili kondisi kabupaten di wilayah tersebut dan daerah sekitarnya. Selain itu, data indeks iklim skala besar NINO3.4 SST (*Sea Surface Temperature*) dan SOI (*Southern Oscillation Index*) yang digunakan dalam penelitian ini berasal dari NOAA (*National Oceanic and*

Atmospheric Administration). Periode data yang digunakan adalah curah hujan harian mulai 01 Januari 1999 hingga 31 Desember 2019.

3.2 Variabel Penelitian

Terdapat beberapa indikator yang dapat menjelaskan peristiwa curah hujan ekstrem. Indikator tunggal memiliki keterbatasan untuk menangkap gambaran penuh curah hujan ekstrem, sehingga penelitian ini menggunakan 2 indikator yang mewakili curah hujan ekstrem yang tinggi dan rendah.

Variabel respon yang digunakan dalam penelitian ini adalah sebagai berikut :

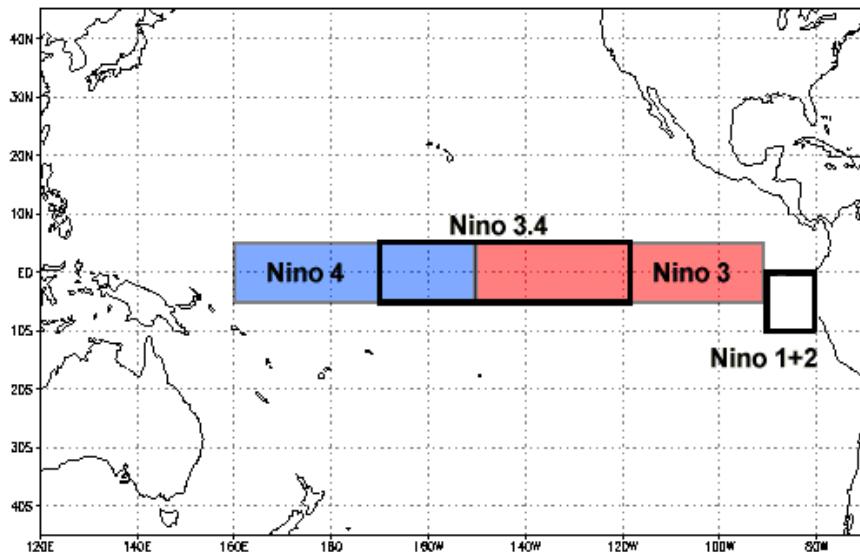
- A. Curah hujan tinggi dijelaskan oleh indikator RX5DAY (*Maximum 5 Day Precipitation Total*)
- B. Curah hujan rendah dijelaskan oleh indikator CDD (*Maximum Number of Consecutive Dry Days*)

Selain itu, pada penelitian ini digunakan indikator iklim sebagai variabel prediktor yang diduga berpengaruh terhadap curah hujan ekstrem. Parameter distribusi untuk pemodelan curah hujan ekstrem dengan GAMLSS sering dianggap terkait dengan beberapa variabel prediktor (Zhang et al., 2015). Parameter distribusi diasumsikan bervariasi dengan waktu untuk pemodelan *hydrologic time series* dalam kondisi lingkungan yang berubah (Villarini et al., 2010). Beberapa penelitian menunjukkan bahwa variasi indeks iklim dapat menyebabkan perubahan terhadap curah hujan ekstrem (Kevin, 2010; Tian dan Fan, 2012; Wen et al., 2011; Zhang et al., 2015). Indikator iklim yang digunakan dalam penelitian ini adalah NINO34 SST (*El-Nino 3.4 Sea Surface Temperature*) dan SOI (*Southern Oscillation Index*). Definisi operasional dari indikator iklim yang digunakan pada penelitian ini dijelaskan sebagai berikut :

3.2.1 SST Daerah Nino

Suhu muka laut (*Sea surface Temperature ~ SST*) di perairan Indonesia sebagai indeks banyaknya uap air pembentuk awan di atmosfer (Kadarsah, 2007). Jika suhu muka laut dingin uap air di atmosfer menjadi berkurang, sebaliknya jika suhu muka laut panas uap air di atmosfer banyak. Pola suhu muka laut di Indonesia secara umum mengikuti gerak tahunan matahari. Suhu muka laut di Samudera

Hindia mempunyai rentang perubahan yang cukup lebar yaitu minimum berkisar 26.0° C pada bulan Agustus hingga maksimum berkisar 31.5° C pada bulan Februari – Maret. Wilayah perairan lainnya umumnya mempunyai rentang perubahan lebih sempit yaitu berkisar 29.0° C hingga 31.5° C dan waktu terjadinya minimum dan maksimumnya tidak sama disetiap perairan. Posisi dari daerah-daerah Nino diilustrasikan pada Gambar 3.2. Data daerah Nino34 dipilih sebagai data untuk dianalisis dengan alasan bahwa daerah tersebut mempunyai respon yang baik terhadap fenomena menghangatnya suhu muka laut di timur (Peru) dan di barat (Pasifik Barat) serta mempunyai korelasi yang cukup kuat terhadap nilai SOI, (Syaifulullah dan Djoko, 1999).



Gambar 3.2 Lokasi Pengamatan SST Daerah Nino (NOAA, 2019).

Nilai anomali SST di kawasan ini juga mempunyai hubungan yang cukup erat dengan tingkat kekeringan di wilayah Indonesia. Daerah Nino1.2 berada di $00\sim100^{\circ}\text{ S}$ dan $900\text{ W}\sim800\text{ W}$, daerah Nino3 di $50^{\circ}\text{ N}\sim50^{\circ}\text{ S}$ dan $1500\text{ W}\sim900\text{ W}$, daerah Nino4 berada di $50^{\circ}\text{ N}\sim50^{\circ}\text{ S}$ dan $1600^{\circ}\text{ E}\sim1500^{\circ}\text{ W}$, sementara daerah Nino34 merupakan interseksi dari Nino3 dan Nino4 yang berada di daerah $50^{\circ}\text{ N}\sim50^{\circ}\text{ S}$ dan $1700^{\circ}\text{ E}\sim1200^{\circ}\text{ E}$ (Syaifulullah, 2010).

3.2.2 SOI

Southern Oscillation Index (SOI) merupakan salah satu ukuran fluktuasi skala besar antara tekanan udara yang terjadi di barat Pasifik dengan di timur Pasifik wilayah tropis selama episode El Niño dan La Niña. Indeks ini telah dihitung

berdasarkan perbedaan anomali tekanan udara antara Tahiti dan Darwin, Australia. Salah satu metode untuk menghitung nilai SOI dikenalkan oleh Bureau of Meteorologi Australia (BOM) menggunakan metode Troup yang menghitung perbedaan standar anomali suhu muka laut ratarata antara Tahiti dan Darwin.

$$SOI = \frac{[P_{diff} - P_{diffav}]}{SD(P_{diff})}$$

Keterangan :

P_{diff} = Tekanan MSL_{Tahiti} – Tekanan MSL_{Darwin}

P_{diffav} = Rata-rata dari P_{diff} jangka waktu panjang

$SD(P_{diff})$ = Standar deviasi dari P_{diff}

Jika nilai SOI negatif maka tekanan di Tahiti relatif lebih kecil dibandingkan dengan tekanan di Darwin. Kondisi ini antara lain menyebabkan; bergesernya kolam hangat dari Pasifik Barat ke Pasifik Timur; terjadi pertumbuhan awan di Pasifik Timur di atas normalnya; terjadi kekeringan di Pasifik Barat terutama di Indonesia Timur karena suplai uap air bergeser ke timur dan lain-lain. Fenomena ini yang disebut dengan fenomena ElNino. Jika nilai SOI positif maka keadaan akan sebaliknya dan fenomena ini dikenal dengan fenomena La-Nina. Nilai SOI yang dianalisis dalam tulisan ini adalah Equatorial SOI (antara tekanan mmsl wilayah Indonesia dengan wilayah Pasifik Timur) dan Darwin-Tahiti SOI. Nilai SOI yang kadang positif dan kadang negatif memberi pengertian bahwa kejadian atau fenomena El-Nino maupun La-Nina mempunyai perulangan (Syaifullah, 2010).

Penelitian ini menggunakan periode tahunan untuk menghitung indeks curah hujan ekstrem. Indeks iklim skala besar tahunan yang digunakan dalam penelitian ini adalah rata-rata indeks iklim skala besar selama periode Desember hingga Februari, penelitian oleh Hao pada tahun 2019 menyebutkan bahwa indeks iklim skala besar pada periode tersebut berpotensi mempengaruhi terjadinya curah hujan ekstrem. Struktur data dari variabel-variabel yang digunakan dalam penelitian ini disajikan pada Tabel 3.1. Data hasil pengamatan selengkapnya disajikan pada Lampiran 1 hingga Lampiran 3.

Tabel 3.1 Struktur Data

Stasiun (j)	Tahun (i)	RX5DAY ($Y_{1,i,j}$)	CDD ($Y_{2,i,j}$)	NINO34 SST ($X_{1,i,j}$)	SOI ($X_{2,i,j}$)
1. Komodo	1999	$Y_{1,1,1}$	$Y_{2,1,1}$	$X_{1,1,1}$	$X_{2,1,1}$
	2000	$Y_{1,2,1}$	$Y_{2,2,1}$	$X_{1,2,1}$	$X_{2,2,1}$
	\vdots	\vdots	\vdots	\vdots	\vdots
	2018	$Y_{1,n-1,1}$	$Y_{2,n-1,1}$	$X_{1,n-1,1}$	$X_{2,n-1,1}$
	2019	$Y_{1,n,1}$	$Y_{2,n,1}$	$X_{1,n,1}$	$X_{2,n,1}$
2. Frans	1999	$Y_{1,1,2}$	$Y_{2,1,2}$	$X_{1,1,2}$	$X_{2,1,2}$
	2000	$Y_{1,2,2}$	$Y_{2,2,2}$	$X_{1,2,2}$	$X_{2,2,2}$
	\vdots	\vdots	\vdots	\vdots	\vdots
	2018	$Y_{1,n-1,2}$	$Y_{2,n-1,2}$	$X_{1,n-1,2}$	$X_{2,n-1,2}$
	2019	$Y_{1,n,2}$	$Y_{2,n,2}$	$X_{1,n,2}$	$X_{2,n,2}$
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
8. Tardamu	1999	$Y_{1,1,8}$	$Y_{2,1,8}$	$X_{1,1,8}$	$X_{2,1,8}$
	2000	$Y_{1,2,8}$	$Y_{2,2,8}$	$X_{1,2,8}$	$X_{2,2,8}$
	\vdots	\vdots	\vdots	\vdots	\vdots
	2018	$Y_{1,n-1,8}$	$Y_{2,n-1,8}$	$X_{1,n-1,8}$	$X_{2,n-1,8}$
	2019	$Y_{1,n,8}$	$Y_{2,n,8}$	$X_{1,n,8}$	$X_{2,n,8}$

3.3 Langkah Analisis

Langkah analisis penelitian untuk pemodelan curah hujan ekstrem secara non-stasioner dengan metode GAMLSS dijelaskan sebagai berikut :

- A. Kajian simulasi untuk metode GAMLSS dengan distribusi yang berbeda

Kajian simulasi dilakukan dengan membangkitkan data menggunakan konsep *Random Variate Generation* (RVG).

 1. Kajian simulasi untuk indeks curah hujan ekstrem RX5DAY (*Maximum 5 Day Precipitation Total*)
 - a. Membangkitkan data berdistribusi *Lognormal*, *Gamma* dan *Generalized Gamma* dengan parameter konstan untuk jumlah sampel $n = 20, 50$ dan 100 . Metode RVG yang digunakan untuk membangkitkan data dalam kajian simulasi ini adalah *univariate transformation* dan algoritma *acceptance-rejection* yang telah dijelaskan pada sub-bab 2.8 dalam Tinjauan Pustaka Parameter untuk masing-masing distribusi yang akan dibangkitkan adalah sebagai berikut :
 - Distribusi *Lognormal* : $\theta_1 = 5$ dan $\theta_2 = 1$
 - Distribusi *Gamma* : $\theta_1 = 30$ dan $\theta_2 = 2$
 - Distribusi *Generalized Gamma* : $\theta_1 = 50$, $\theta_2 = 1$ dan $\theta_3 = 1$

- b. Memodelkan masing-masing data simulasi RX5DAY yang telah dibangkitkan dengan beberapa distribusi kontinu dalam metode GAMLSS, yakni distribusi Lognormal, Gamma, *Generalized Gamma*, Logistik dan Weibull
 - a. Menganalisis nilai GAIC dari masing-masing model yang dihasilkan oleh data yang telah dibangkitkan. Replikasi data pada langkah a) dilakukan masing-masing sebanyak 100 kali untuk mengetahui persentase kesesuaian model yang memiliki nilai GAIC terkecil dengan distribusi awal dari skenario data simulasi. Perhitungan untuk mendapatkan nilai GAIC disajikan pada Persamaan 2.21 (sub-bab 2.6 dalam Tinjauan Pustaka).
2. Kajian simulasi untuk indeks curah hujan ekstrem dan CDD (*Maximum Number of Consecutive Dry Days*)
- b. Membangkitkan data berdistribusi *Generalized Poisson*, Binomial Negatif dan *Poisson Inverse Gaussian* dengan parameter konstan untuk jumlah sampel $n = 20, 50$ dan 100 . Metode RVG yang digunakan dalam kajian simulasi ini adalah *univariate transformation* dan algoritma *acceptance-rejection* yang telah dijelaskan pada sub-bab 2.8 dalam Tinjauan Pustaka. Parameter untuk masing-masing distribusi yang akan dibangkitkan adalah sebagai berikut :
 - Distribusi *Generalized Poisson* : $\theta_1 = 20$ dan $\theta_2 = 1$
 - Distribusi Binomial Negatif : $\theta_1 = 30$ dan $\theta_2 = 2$
 - Distribusi *Poisson Inverse Gaussian* : $\theta_1 = 20$ dan $\theta_2 = 5$ - c. Memodelkan masing-masing data simulasi CDD yang telah dibangkitkan dengan beberapa distribusi diskrit dalam metode GAMLSS, yakni distribusi *Generalized Poisson*, Binomial Negatif dan *Poisson Inverse Gaussian*
 - d. Menganalisis nilai GAIC dari masing-masing model yang dihasilkan oleh data yang telah dibangkitkan. Replikasi data pada langkah a) dilakukan masing-masing sebanyak 100 kali untuk mengetahui persentase kesesuaian model yang memiliki nilai GAIC terkecil dengan

distribusi awal dari skenario data simulasi. Perhitungan untuk mendapatkan nilai GAIC disajikan pada Persamaan 2.21 (sub-bab 2.6 dalam Tinjauan Pustaka).

- B. Mendapatkan model indeks curah hujan ekstrem RX5DAY (*Maximum 5 Day Precipitation Total*) dan CDD (*Maximum Number of Consecutive Dry Days*) dengan pendekatan GAMLSS di 8 stasiun meteorologi di NTT dan mengevaluasi kebaikan model dari masing-masing model yang terpilih di setiap stasiun dengan langkah-langkah sebagai berikut :

1. Mendeskripsikan karakteristik dari indikator curah hujan ekstrim (RX5DAY dan CDD) di masing-masing stasiun meteorologi dengan *time series plot*.
2. Pemodelan indikator curah hujan ekstrem dengan GAMLSS

GAMLSS digunakan untuk membangun fungsi distribusi parametrik dari masing-masing variabel respon RX5DAY dan CDD dengan mengembangkan hubungan antara parameter distribusi dan variabel prediktor menggunakan *cubic smoothing splines* dan *penalized splines terms*. Tiga model yang dipertimbangkan untuk memodelkan masing-masing indeks curah hujan ekstrem secara non-stasioner dengan metode GAMLSS pada penelitian ini adalah sebagai berikut :

- a. Model stasioner 0 : parameter distribusi konstan, tanpa adanya variabel prediktor
- b. Model non-stasioner 1 : parameter distribusi berubah seiring waktu (waktu dipertimbangkan sebagai variabel prediktor)
- c. Model non-stasioner 2 : parameter distribusi berubah berdasarkan indeks iklim (NINO34 dan SOI)

Distribusi parameter kontinu yang digunakan dalam penelitian ini untuk memodelkan RX5day adalah *Lognormal*, *Gamma* dan *Generalized Gamma*. Sedangkan distribusi parameter diskrit yang digunakan untuk memodelkan CDD adalah *Generalized Poisson*, *Binomial Negatif* dan *Poisson Inverse Gaussian*. *Probability density function* (PDF) dan plot PDF dari masing-masing distribusi diskrit dan kontinu disajikan pada Tabel 2.4 dan 2.5.

Misalkan respon Y berdistribusi *Lognormal* dengan pdf $f(Y|\theta_1, \theta_2)$, maka parameter distribusi dari Y berdasarkan tipe model GAMLSS dituliskan sebagai berikut :

- (a) Model stasioner 0, parameter θ_1 dan θ_2 bernilai konstan ($f(y_i|\boldsymbol{\theta})$)
- (b) Model non-stasioner 1 ($f(y_t|\boldsymbol{\theta}^t)$), parameter distribusi berubah seiring waktu, sehingga kedua parameter untuk model non-stasioner 1 dapat dituliskan menjadi : $\boldsymbol{\theta}_1^T = (\theta_{11}, \theta_{21}, \dots, \theta_{i1}, \dots, \theta_{n1})$ dan $\boldsymbol{\theta}_2^T = (\theta_{12}, \theta_{22}, \dots, \theta_{i2}, \dots, \theta_{n2})$. *Link function* untuk parameter lokasi dan skala dalam distribusi Lognormal berbentuk \ln . Sehingga, parameter distribusi dituliskan sebagai berikut :

$$\ln(\theta_{1t}) = \eta_{1t} = \beta_1 t + \sum_{j=1}^{J_1} \mathbf{Z}_{j1} \gamma_{j1}$$

$$\ln(\theta_{2t}) = \eta_{2t} = \beta_2 t + \sum_{j=1}^{J_2} \mathbf{Z}_{j2} \gamma_{j2}$$

- (c) Model non-stasioner 2 ($f(y_i|\boldsymbol{\theta}^i)$), parameter distribusi dipengaruhi oleh indeks iklim skala besar (SOI dan NINO3.4 SST), sehingga kedua parameter untuk model non-stasioner 2 dapat dituliskan menjadi :

$\boldsymbol{\theta}_1^T = (\theta_{11}, \theta_{21}, \dots, \theta_{i1}, \dots, \theta_{n1})$ dan $\boldsymbol{\theta}_2^T = (\theta_{12}, \theta_{22}, \dots, \theta_{i2}, \dots, \theta_{n2})$. *Link function* untuk parameter lokasi dan skala dalam distribusi Lognormal berbentuk \ln . Sehingga, parameter distribusi dituliskan sebagai berikut :

$$\ln(\theta_{1i}) = \eta_{1i} = \mathbf{X}_1 \beta_1 + \sum_{j=1}^{J_1} \mathbf{Z}_{j1} \gamma_{j1}$$

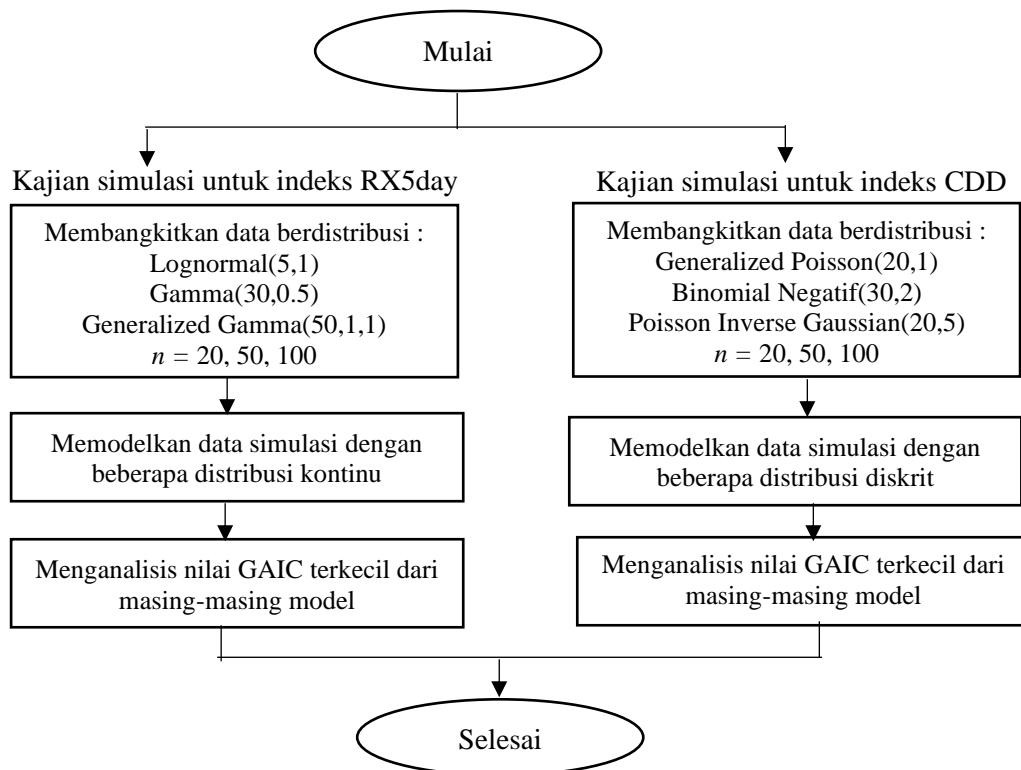
$$\ln(\theta_{2i}) = \eta_{2i} = \mathbf{X}_2 \beta_2 + \sum_{j=1}^{J_2} \mathbf{Z}_{j2} \gamma_{j2}$$

3. Evaluasi kriteria kebaikan model

Generalized Akaike Information Criterion (GAIC) digunakan untuk memilih model yang optimal antara tiga model GAMLSS yang dipertimbangkan. Seleksi model GAMLSS dengan metode GAIC dijelaskan pada sub-bab 2.6 dalam Tinjauan Pustaka.

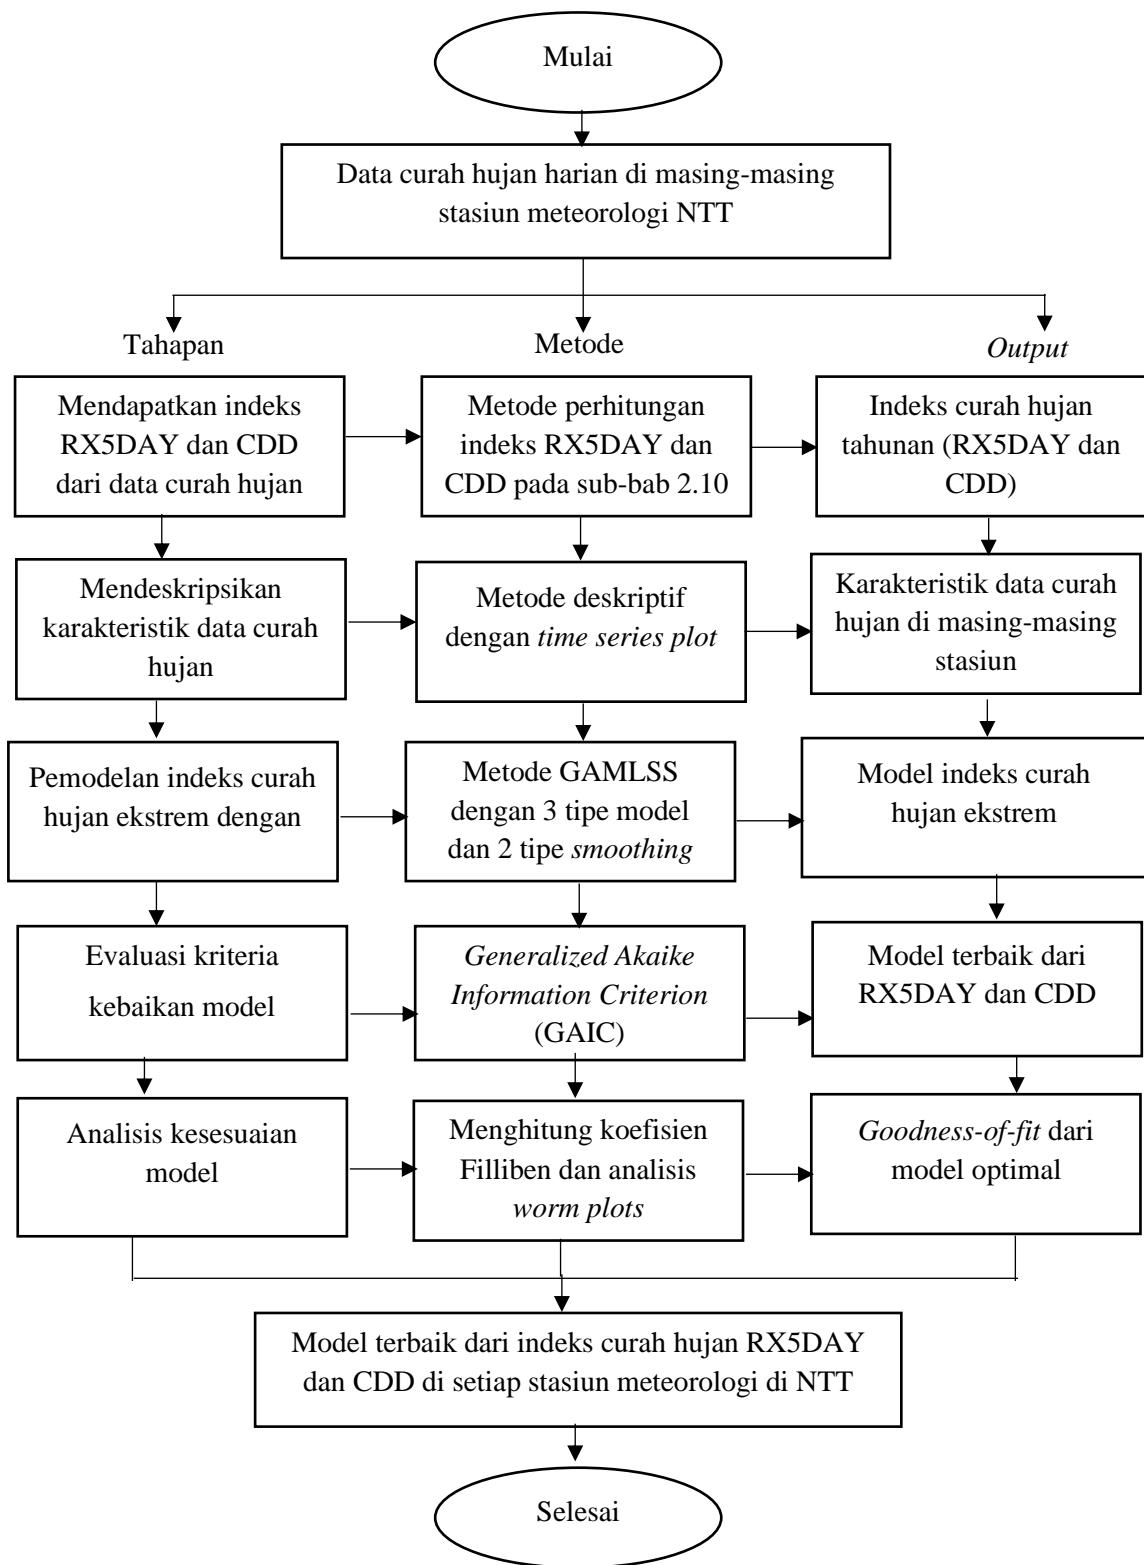
- Evaluasi *goodness-of-fit* dari model optimal dengan menghitung koefisien Filliben (Filliben 1975) dan *worm plots* (Van dan Fredriks, 2010) dari residual model optimal. Konsep tentang Koefisien Filliben dan *Worm plots* telah dijelaskan pada sub-bab 2.7 dan 2.9 dalam Tinjauan Pustaka.

Langkah analisis penelitian ini digambarkan dalam diagram alir. Diagram alir untuk kajian simulasi disajikan pada Gambar 3.3.



Gambar 3.3 Diagram Alir Kajian Simulasi

Diagram alir untuk kajian empiris disajikan pada Gambar 3.4.



Gambar 3.4 Diagram Alir Kajian Empiris

BAB IV

ANALISIS DAN PEMBAHASAN

Bab ini menyajikan hasil kajian simulasi untuk beberapa distribusi dalam metode GAMLSS (*Generalized Additive Models for Location, Scale and Shape*). Selanjutnya, disajikan model terbaik untuk masing-masing indeks curah hujan ekstrem RX5Day (*Maximum 5 Day Precipitation Total*) dan CDD (*Maximum Number of Consecutive Dry Days*) di 8 stasiun meteorologi di NTT serta hasil evaluasi kebaikan model dari masing-masing model yang terpilih di setiap stasiun.

4.1 Kajian Simulasi

Kajian simulasi dilakukan dengan membangkitkan data berdistribusi tertentu dengan parameter konstan untuk jumlah sampel $n = 20, 50$ dan 100 . Kajian simulasi pada penelitian ini bertujuan untuk mengetahui kebaikan metode GAMLSS dalam menyesuaikan distribusi data dengan menganalisis nilai GAIC dari masing-masing model yang dihasilkan. Replikasi data dilakukan sebanyak 100 kali untuk mengetahui persentase kesesuaian distribusi dari model yang memiliki nilai GAIC terkecil dengan skenario distribusi data awal yang telah dibangkitkan. Kajian simulasi dilakukan untuk masing-masing indeks curah hujan ekstrem RX5Day (*Maximum 5 Day Precipitation Total*) dan CDD (*Maximum Number of Consecutive Dry Days*).

4.1.1 Kajian Simulasi Indeks Curah Hujan Ekstrem RX5Day

Kajian simulasi untuk indeks curah hujan ekstrem RX5Day (*Maximum 5 Day Precipitation Total*) dilakukan dengan membangkitkan data berdistribusi Lognormal, Gamma dan *Generalized Gamma* dengan parameter konstan masing-masing dengan jumlah sampel sebesar $n = 20, 50$ dan 100 . Data yang telah dibangkitkan kemudian dimodelkan dengan beberapa distribusi kontinu yang tersedia pada metode GAMLSS dan sesuai untuk memodelkan indeks curah hujan ekstrem RX5Day yakni distribusi Lognormal, Gamma dan *Generalized Gamma*, Logistik dan Weibull. Replikasi dilakukan sebanyak 100 kali, hasil kajian simulasi untuk indeks curah hujan ekstrem RX5Day disajikan pada Tabel 4.1.

Tabel 4.1 Kajian Simulasi Indeks Curah Hujan Ekstrem RX5Day

<i>n</i>	Lognormal	Gamma	<i>Generalized Gamma</i>
20	79%	80%	50%
50	80%	90%	83%
100	98%	93%	94%

Data simulasi untuk indeks curah hujan ekstrem RX5day dibangkitkan dari setiap distribusi dengan parameter yang konstan sesuai dengan yang tertulis di langkah analisis, data yang telah dibangkitkan kemudian dimodelkan dengan tipe model stasioner 0 (model dengan parameter konstan) untuk distribusi kontinu yang berbeda pada metode GAMLSS. Tabel 4.1 menunjukkan bahwa data berdistribusi Lognormal, Gamma dan *Generalized Gamma* dengan sampel besar sampel besar ($n = 100$) telah dimodelkan secara tepat dengan baik, yakni lebih dari 90% data yang dimodelkan dengan distribusi yang bersesuaian memiliki nilai GAIC yang lebih kecil dibandingkan dengan nilai GAIC dari hasil pemodelan dengan distribusi yang tidak bersesuaian. Hasil kajian simulasi untuk indeks curah hujan ekstrem RX5day menyimpulkan bahwa semakin tinggi jumlah sampel maka persentase kemampuan metode GAMLSS dalam menangkap distribusi data juga semakin baik, secara keseluruhan metode GAMLSS mampu menangkap distribusi data kontinu dengan baik sesuai dengan skenario distribusi data awal yang telah dibangkitkan baik pada sampel kecil ($n = 20$) ataupun sampel besar ($n = 100$).

4.1.2 Kajian Simulasi Indeks Curah Hujan Ekstrem CDD

Data berdistribusi *Generalized Poisson*, Binomial Negatif dan *Poisson Inverse Gaussian* dengan parameter konstan masing-masing dengan jumlah sampel $n = 20, 50$ dan 100 dibangkitkan untuk kajian simulasi indeks curah hujan ekstrem CDD (*Maximum Number of Consecutive Dry Days*). Data yang telah dibangkitkan kemudian dimodelkan dengan beberapa distribusi diskrit yang tersedia pada metode GAMLSS dan sesuai untuk memodelkan indeks curah hujan ekstrem CDD yakni distribusi *Generalized Poisson*, Binomial Negatif dan *Poisson Inverse Gaussian*. Tabel 4.2 menampilkan hasil kajian simulasi untuk indeks curah hujan ekstrem CDD.

Tabel 4.2 Kajian Simulasi Indeks Curah Hujan Ekstrem CDD

<i>n</i>	<i>Generalized Poisson</i>	Binomial Negative	<i>Poisson Inverse Gaussian</i>
20	33%	84%	57%
50	59%	95%	69%
100	83%	98%	80%

Hasil kajian simulasi untuk indeks curah hujan ekstrem CDD dilakukan dengan cara yang sama dengan kajian simulasi untuk indeks curah hujan ekstrem RX5day, data yang telah dibangkitkan kemudian dimodelkan dengan tipe model stasioner 0 (model dengan parameter konstan) untuk distribusi diskrit yang berbeda pada metode GAMLSS. Hasil kajian simulasi untuk indeks curah hujan ekstrem CDD pada Tabel 4.2 menunjukkan bahwa persentase kemampuan metode GAMLSS dalam menangkap distribusi data berdistribusi *Generalized Poisson* pada sampel kecil ($n = 20$) hanya mencapai 33%, sedangkan pada sampel besar ($n = 100$) dapat mencapai 83%. Lebih dari 80% data yang dibangkitkan dengan distribusi Binomial Negatif dengan jumlah sampel $n = 20, 50$ dan 100 dan distribusi *Poisson Inverse Gaussian* dengan $n = 100$ juga telah dimodelkan dengan sesuai, sedangkan hanya 57% dari replikasi data yang dibangkitkan dengan distribusi *Poisson Inverse Gaussian* dengan jumlah sampel $n = 20$ dapat dimodelkan dengan sesuai. Secara keseluruhan, persentase ketepatan pemodelan pada kajian simulasi untuk indeks curah hujan ekstrem CDD terbilang cukup tinggi pada sampel besar, sehingga metode GAMLSS dapat dikatakan mampu menangkap distribusi data diskrit dengan baik sesuai dengan skenario distribusi data awal yang telah dibangkitkan baik pada sampel besar ($n = 100$).

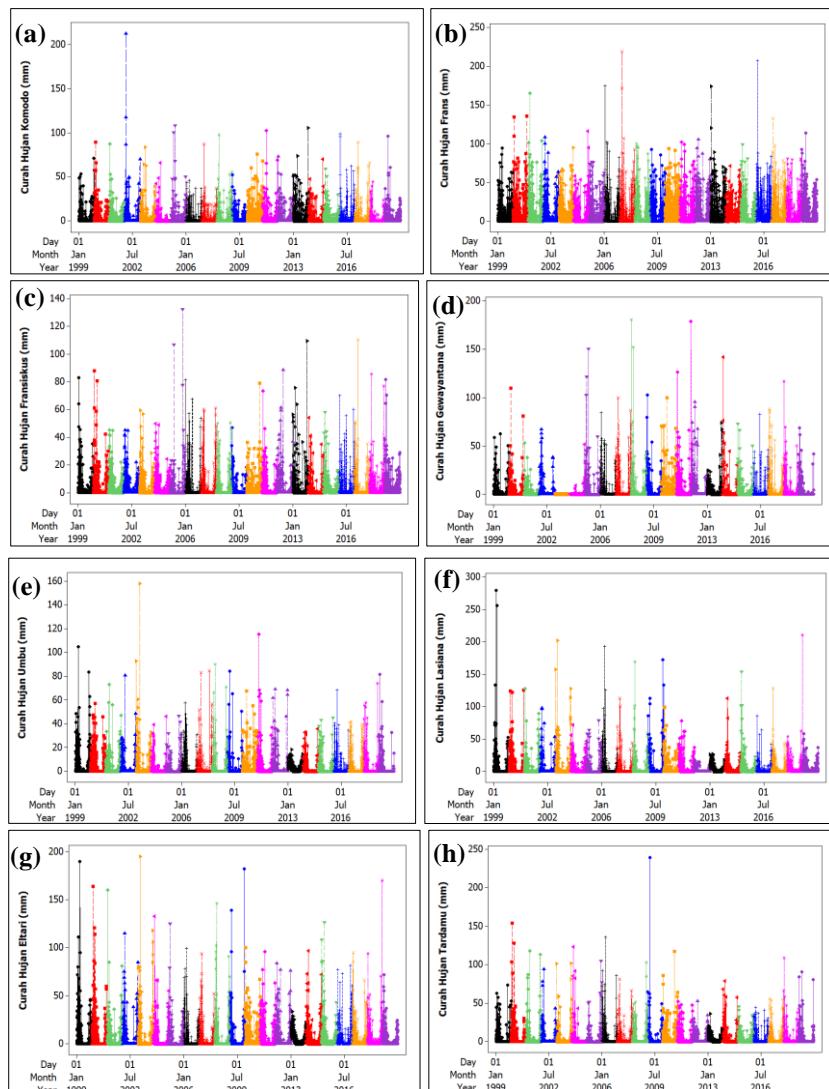
4.2 Pemodelan Indeks Curah Hujan Ekstrem di Provinsi Nusa Tenggara Timur

Nonstasioneritas seringkali ditemukan pada data deret waktu hidrologi karena adanya variabilitas iklim atau perubahan iklim antropogenik, sehingga analisis selanjutnya adalah pemodelan masing-masing indeks curah hujan ekstrem R5D (*Maximum 5 Day Precipitation Total*) dan CDD (*Maximum Number of Consecutive Dry Days*) secara non-stasioner dengan pendekatan GAMLSS di 8 stasiun meteorologi di NTT. Analisis karakteristik data curah hujan harian dan indeks curah

hujan ekstrem tahunan dengan *time series plot* dilakukan sebelum melakukan pemodelan. Pemodelan dilakukan dengan beberapa tipe model, distribusi dan metode smoothing yang berbeda dan menganalisis nilai GAIC dari masing-masing model untuk mendapatkan model terbaik di setiap stasiun. Hasil evaluasi kebaikan model di setiap stasiun dilakukan setelah didapatkan model terbaik.

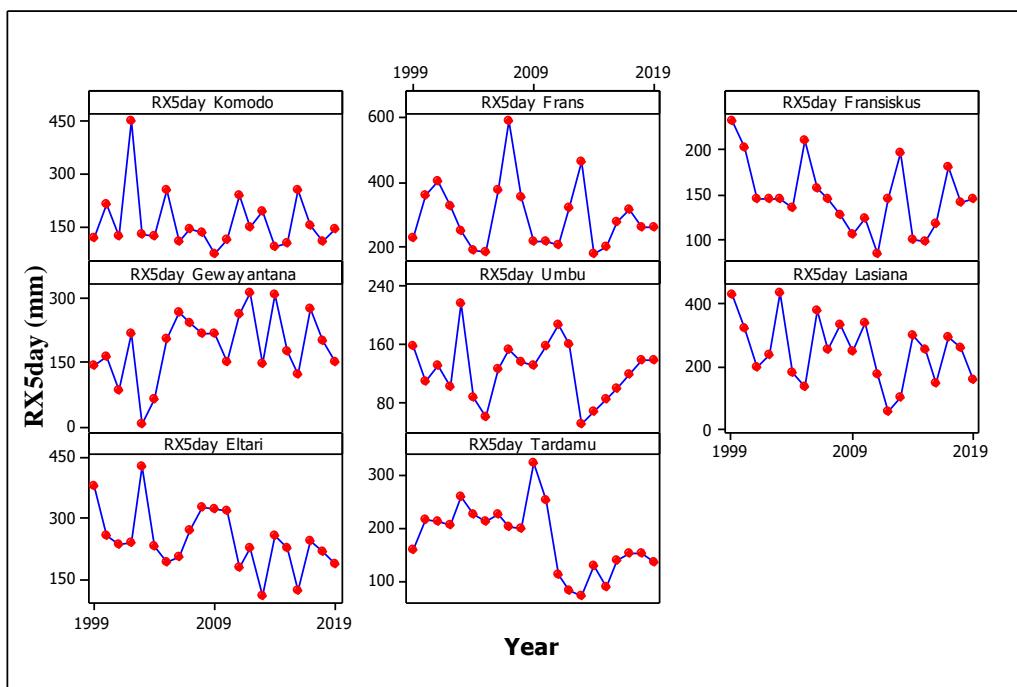
4.2.1 Karakteristik Data Curah Hujan

Analisis karakteristik data curah hujan dilakukan sebelum melakukan pemodelan curah hujan. Karakteristik data curah hujan harian di 8 stasiun meteorologi di Nusa Tenggara Timur selama periode 1999-2019 dianalisis secara visual dengan *time series plot* dan hasilnya disajikan dalam Gambar 4.1.



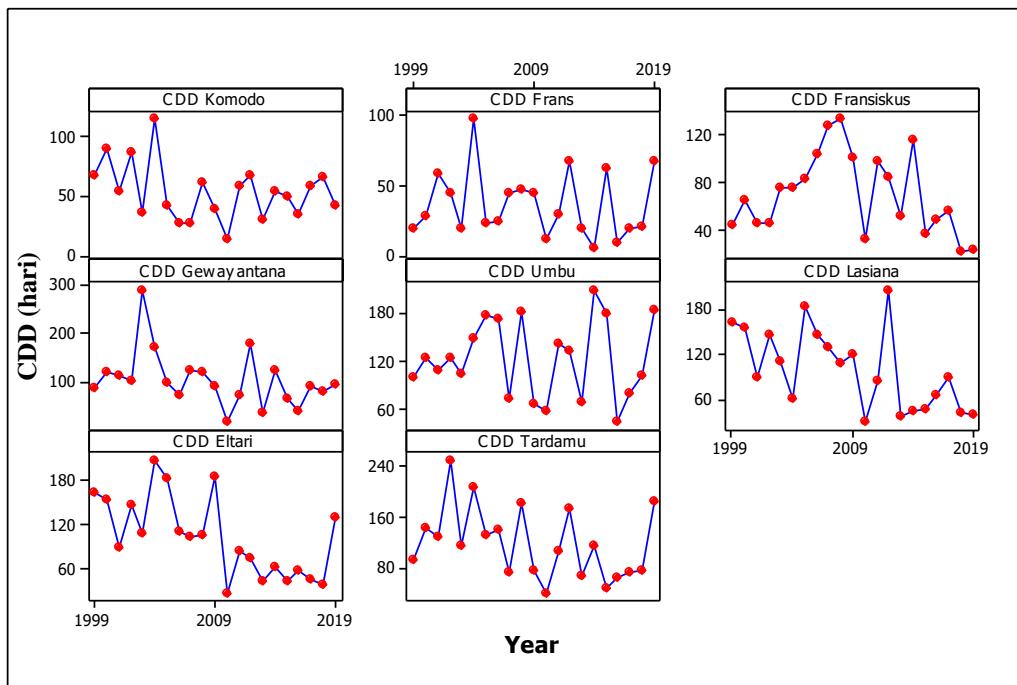
Gambar 4.1 Pola Curah Hujan Harian di Stasiun (a) Komodo (b) Frans (c) Fransiskus (d) Gewayantana (e) Umbu (f) Lasiana (g) Eltari (h) Tardamu

Gambar 4.1 menunjukkan bahwa curah hujan tinggi terjadi pada setiap awal tahun secara keseluruhan di 8 stasiun meteorologi NTT. Hasil dari analisis data dari setiap stasiun merepresentasikan kondisi dari kabupaten dan area sekitar dari wilayah tersebut. *Time series plot* menunjukkan bahwa Stasiun meteorologi Frans Sales Lega yang terletak di Kabupaten Manggarai cenderung memiliki curah hujan yang lebih tinggi daripada dengan stasiun yang lain, hal ini dibuktikan oleh rata-rata curah hujan di Stasiun Frans yang mencapai 293mm dalam 5 hari (seperti yang ditunjukkan pada Tabel 4.3). Terdapat banyak kondisi curah hujan harian di beberapa stasiun adalah nol, hal ini dapat dikarenakan provinsi NTT merupakan prioritas pertama provinsi di Indonesia yang secara signifikan dipengaruhi oleh kekeringan sehingga rentan terhadap kekeringan. Data curah hujan harian di setiap stasiun kemudian diagregatkan menjadi indeks curah hujan ekstrem tahunan RX5Day (*Maximum 5 Day Precipitation Total*) dan CDD (*Maximum Number of Consecutive Dry Days*). Hasil analisis *time series plot* untuk indeks curah hujan ekstrem RX5day dan CDD disajikan pada Gambar 4.2 dan 4.3.



Gambar 4.2 Curah Hujan Ekstrem RX5day di 8 Stasiun Meteorologi NTT

Gambar 4.2 dan 4.3 menunjukkan bahwa indeks curah hujan ekstrem RX5Day (*Maximum 5 Day Precipitation Total*) dan CDD (*Maximum Number of Consecutive Dry Days*) dari setiap stasiun berbeda-beda dan dapat diindikasikan bahwa terdapat nonstasioneritas pada data deret waktu hidrologi tersebut karena adanya variabilitas iklim atau perubahan iklim antropogenik setiap tahunnya.



Gambar 4.3 Curah Hujan Ekstrem CDD di 8 Stasiun Meteorologi NTT

Analisis selanjutnya adalah statistika deskriptif indeks curah hujan ekstrem RX5day di setiap stasiun meteorologi NTT, nilai dari rata-rata akan diinterpretasikan tanpa memperhatikan variabilitas dari masing-masing indeks curah hujan ekstrem setiap tahun. Tabel 4.3 menunjukkan bahwa curah hujan tertinggi terdapat di Kabupaten Manggarai (lokasi stasiun meteorologi Frans Sales Lega) yang mencapai 293mm dalam waktu 5 hari. Indeks curah hujan ekstrem CDD dihitung berdasarkan jumlah hari dengan curah hujan < 1 mm secara berturut-turut, sehingga dapat dikatakan bahwa mayoritas kabupaten di Provinsi NTT merupakan daerah kering dengan intensitas curah hujan yang rendah karena rata-rata dari indeks CDD dari 5 stasiun meteorologi (Gewayantana, Umbu, Lasiana, Eltari dan Tardamu) bernilai lebih dari 100 hari, hal ini berarti bahwa rata-rata kekeringan

pada daerah dimana stasiun-stasiun tersebut terletak berlangsung selama lebih dari 100 hari.

Tabel 4.3 Nilai rata-rata, standar deviasi, minimum, median dan maksimum dari indeks curah hujan ekstrem RX5day dan CDD

Indeks Curah Hujan Ekstrem RX5day (mm)					
Stasiun	Rata-rata	Standar deviasi	Minimum	Median	Maksimum
Komodo	160,40	85,00	72,40	132,10	449,60
Frans	293,00	104,00	180,90	259,70	586,30
Fransiskus	146,57	38,74	84,60	144,45	231,60
Gewayantana	188,30	79,90	7,20	203,10	314,30
Umbu	124,80	41,78	50,40	131,40	217,40
Lasiana	250,00	104,60	54,40	253,00	440,30
Eltari	248,10	76,10	112,70	237,20	429,00
Tardamu	178,90	64,40	73,80	198,60	322,80
Indeks Curah Hujan Ekstrem CDD (hari)					
Komodo	53,57	23,93	14,00	54,00	115,00
Frans	36,62	23,72	6,00	28,00	98,00
Fransiskus	70,10	33,27	23,00	65,00	133,00
Gewayantana	104,90	57,60	20,00	97,00	289,00
Umbu	123,10	48,50	45,00	124,00	209,00
Lasiana	100,20	53,60	30,00	90,00	207,00
Eltari	104,30	53,70	29,00	105,00	208,00
Tardamu	119,20	56,40	42,00	115,00	250,00

Tingginya variabilitas iklim atau perubahan iklim antropogenik ditunjukkan dari tingginya nilai standar deviasi dari indeks curah hujan tahunan pada Tabel 4.3. Curah hujan ekstrem tertinggi yang dialami di provinsi NTT terjadi pada tahun 2007 di Kabupaten Manggarai (lokasi stasiun meteorologi Frans Sales Lega) yang mencapai 586,30 mm dalam 5 hari, sedangkan pada tahun 2014 hanya mencapai 180,90mm dalam 5 hari. Hal serupa dialami oleh Kota Kupang (lokasi stasiun klimatologi Lasiana dan stasiun meteorologi Eltari), dimana curah hujan ekstrem tertinggi mencapai 440,30 dan 429 mm dalam 5 hari, sedangkan terdapat kondisi dimana curah hujan tertinggi hanya mencapai 54,40 dan 112,70 mm dalam 5 hari. Kekeringan ekstrem yang dialami di provinsi NTT terjadi pada tahun 2004 di Kabupaten Flores Timur (lokasi stasiun meteorologi Gewayantana), nilai indeks curah hujan CDD di stasiun Gewayantana pada tahun 2004 mencapai 289, hal ini berarti bahwa kekeringan terjadi selama 289 hari berturut-turut di stasiun

Gewayantana pada tahun 2004 dengan nilai curah hujan maksimum sebesar 7,20 mm dalam 5 hari.

4.2.2 Pemodelan Indeks Curah Hujan Ekstrem RX5day

Analisis karakteristik indeks curah hujan ekstrem menunjukkan bahwa diindikasikan terdapat nonstasioneritas pada indeks curah hujan ekstrem RX5day (*Maximum 5 Day Precipitation Total*) di hampir semua stasiun di Provinsi NTT, sehingga pemodelan indeks curah hujan ekstrem RX5day dilakukan dengan 3 tipe model, yakni ; model non-stasioner 0 (parameter konstan), model non-stasioner 1 (parameter berubah seiring waktu atau menjadikan waktu sebagai variabel prediktor) serta model non-stasioner 2 (menjadikan indeks iklim skala besar NINO3.4 SST dan SOI sebagai variabel prediktor). Distribusi yang digunakan dalam pemodelan indeks curah hujan ekstrem RX5day adalah distribusi Lognormal, Gamma dan *Generalized Gamma*, selain itu juga digunakan 2 tipe *smoothing* yakni *cubic spline smoothing* dan *penalized spline term*. Pemodelan indeks curah hujan ekstrem RX5day dilakukan di 8 stasiun meteorologi di NTT. Pemilihan model terbaik untuk memodelkan indeks RX5day di stasiun meteorologi Fransiskus Xaverius Seda disajikan pada Tabel 4.4 hingga 4.6.

Tabel 4.4 Nilai GAIC Pemodelan RX5day di Stasiun Fransiskus dengan Model Stasioner 0

Tipe Model	Distribusi	GAIC
Model 0	Lognormal	216.50
	Gamma	216.70
	Gen Gamma	219.54

Tabel 4.5 Nilai GAIC Pemodelan RX5day di Stasiun Fransiskus dengan Model Non-stasioner 1

Tipe Model	Tipe <i>smoothing</i>	Distribusi	θ_1	θ_2	GAIC
Model 1	<i>Cubic</i>	Lognormal	cs(t)	t	217,66
		Gen Gamma	cs(t)	t	217,76
		Gamma	cs(t)	t	218,48
		Lognormal	t	cs(t)	221,19
		Gamma	t	cs(t)	221,52
		Gen Gamma	t	cs(t)	224,27
Model 1	<i>Penalized</i>	Lognormal	pb(t)	t	216,76
		Gamma	pb(t)	t	217,32
		Lognormal	t	pb(t)	218,18
		Gamma	t	pb(t)	218,57
		Gen Gamma	t	pb(t)	220,96

Tabel 4.6 Nilai GAIC Pemodelan RX5day di Stasiun Fransiskus dengan Model Non-stasioner 2

Tipe Model	Tipe <i>smoothing</i>	Distribusi	θ_1	θ_2	GAIC
Model 2	<i>Cubic</i>	Gamma	SOI+NINO3.4	cs(t)	203,22
		Lognormal	SOI+NINO3.4	cs(t)	203,63
		Gen Gamma	SOI+NINO3.4	cs(t)	206,15
		Gamma	cs(SOI)+cs(NINO3.4)	t	215,54
		Lognormal	cs(SOI)+cs(NINO3.4)	t	216,31
		Lognormal	cs(SOI)	NINO3.4	224,94
		Gamma	cs(SOI)	NINO3.4	225,25
		Gamma	NINO3.4	cs(SOI)	226,00
		Lognormal	NINO3.4	cs(SOI)	226,16
		Lognormal	SOI	cs(NINO3.4)	226,88
		Gamma	cs(NINO3.4)	SOI	227,05
		Gamma	SOI	cs(NINO3.4)	227,26
		Lognormal	cs(NINO3.4)	SOI	227,68
		Gen Gamma	cs(SOI)	NINO3.4	227,82
Model 2	<i>Penalized</i>	Gen Gamma	NINO3.4	cs(SOI)	229,04
		Gamma	cs(NINO3.4)	cs(SOI)	232,03
		Lognormal	cs(NINO3.4)	cs(SOI)	232,44
		Gen Gamma	cs(NINO3.4)	cs(SOI)	234,97
		Gamma	SOI+NINO3.4	pb(t)	203,93
		Lognormal	SOI+NINO3.4	pb(t)	204,17
		Gen Gamma	SOI+NINO3.4	pb(t)	207,04
		Gamma	pb(SOI)+pb(NINO3.4)	t	209,49
		Lognormal	pb(SOI)+pb(NINO3.4)	t	210,07
		Gamma	pb(NINO3.4)	SOI	219,75
		Lognormal	pb(NINO3.4)	SOI	219,91
		Gamma	NINO3.4	pb(SOI)	220,01
		Gamma	pb(NINO3.4)	pb(SOI)	220,01
		Lognormal	NINO3.4	pb(SOI)	220,18
		Lognormal	pb(NINO3.4)	pb(SOI)	220,18
		Lognormal	pb(SOI)	NINO3.4	220,62
		Lognormal	pb(SOI)	pb(NINO3.4)	220,62
		Gamma	pb(SOI)	NINO3.4	221,11
		Gamma	pb(SOI)	pb(NINO3.4)	221,11
		Gen Gamma	pb(NINO3.4)	SOI	222,80
		Gen Gamma	NINO3.4	pb(SOI)	223,04
		Gen Gamma	pb(NINO3.4)	pb(SOI)	223,04
		Gen Gamma	pb(SOI)	NINO3.4	223,05
		Gen Gamma	pb(SOI)	pb(NINO3.4)	223,05

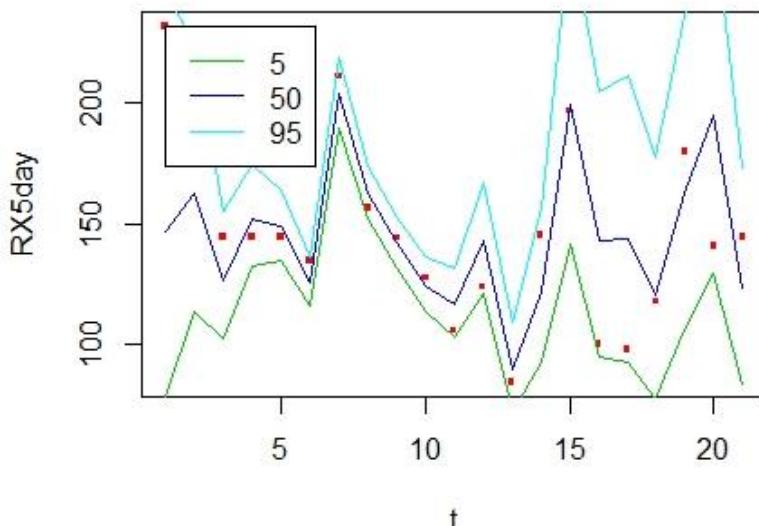
Stasiun meteorologi Fransiskus berada di kabupaten Sikka. Distribusi yang paling sesuai untuk memodelkan indeks curah hujan ekstrem RX5day di stasiun meteorologi Fransiskus dengan tipe model stasioner (dengan parameter konstan) dan model non-stasioner 1 (parameter berubah seiring waktu) adalah distribusi Lognormal, sedangkan distribusi yang paling sesuai untuk memodelkan RX5day dengan tipe model non-stasioner 2 (parameter dipengaruhi oleh indeks iklim skala

besar) adalah distribusi Gamma. GAIC pada tipe model non-stasioner 2 bernilai lebih kecil dibandingkan dengan model stasioner 0 dan model non-stasioner 1, hal ini menunjukkan bahwa terdapat non-stasioneritas dalam indeks curah hujan ekstrem RX5day di stasiun meteorologi Fransiskus. Intensitas curah hujan ekstrem RX5day pada stasiun meteorologi Fransiskus dipengaruhi oleh NINO3.4 SST dan SOI karena parameter θ_1 terkait dengan kedua indeks iklim tersebut, sedangkan varians dari RX5day pada stasiun meteorologi Fransiskus dipengaruhi oleh waktu karena parameter θ_2 terkait dengan waktu (t), tipe *smoothing* yang digunakan pada model terbaik untuk indeks curah hujan ekstrem RX5day di stasiun meteorologi Fransiskus adalah *cubic smoothing spline*. *Link function* untuk parameter θ_1 dan θ_2 pada distribusi Gamma adalah $\ln(\cdot)$, sehingga model terbaik untuk indeks curah hujan ekstrem RX5day di stasiun meteorologi Fransiskus dapat dituliskan sebagai berikut :

$$\ln(\theta_{1i}) = \eta_{1i} = 14,092 - 0,234SOI_i - 0,339NINO3.4_i$$

$$\ln(\theta_{2t}) = \eta_{2t} = -2,662 + 0,049cs(t)$$

Plot antara data indeks curah hujan ekstrem RX5day dan *centiles fitted value* (0,05; 0,50 dan 0,95) dari model optimal untuk RX5day di stasiun meteorologi Fransiskus disajikan pada Gambar 4.4.



Gambar 4.4 Plot antara data RX5day dan *Fitted Value* di Stasiun Fransiskus

Gambar 4.4 menunjukkan bahwa model optimal untuk indeks curah hujan ekstrem RX5day di stasiun meteorologi Fransiskus dengan intensitas curah hujan ekstrem yang dipengaruhi oleh kedua indeks iklim NINO3.4 SST dan SOI, serta varians yang dipengaruhi oleh waktu dapat menangkap pola data aktual dengan baik. Pemilihan model optimal untuk indeks curah hujan ekstrem RX5day di 8 stasiun meteorologi di NTT dirangkum dalam Tabel 4.7.

Tabel 4.7 Model Terbaik RX5day di 8 Stasiun Meteorologi NTT

Stasiun	Tipe model	Distribusi	θ_1	θ_2	GAIC
Komodo	Model 0	Gen Gamma	konstan	konstan	238,08
Frans	Model 0	Lognormal	konstan	konstan	254,01
Fransiskus	Model 2	Gamma	SOI+NINO3.4	cs(t)	203,22
Gewayantana	Model 2	Gamma	SOI	cs(NINO3.4)	241,86
Umbu	Model 2	Gen Gamma	SOI	cs(NINO3.4)	220,36
Lasiana	Model 0	Gamma	konstan	konstan	261,10
Eltari	Model 0	Gamma	konstan	konstan	245,81
Tardamu	Model 1	Gamma	t	cs(t)	222,50

Tabel 4.7 menunjukkan bahwa stasioneritas terjadi pada indeks curah hujan ekstrem RX5day di 4 stasiun meteorologi di NTT, yakni stasiun Komodo, Frans, Lasiana dan Eltari, hal ini dikarenakan nilai GAIC yang didapatkan dari model stasioner 0 lebih rendah dibandingkan model non-stasioner 1 (parameter berubah seiring waktu) dan non-stasioner 2 (parameter dipengaruhi oleh indeks iklim skala besar). Waktu diidentifikasi sebagai faktor utama yang mempengaruhi intensitas dan fluktuasi curah hujan ekstrem RX5day di stasiun meteorologi Tardamu, sedangkan indeks iklim skala besar NINO3.4 SST dan SOI diidentifikasi sebagai faktor utama yang mempengaruhi intensitas dan fluktuasi curah hujan ekstrem RX5day di stasiun meteorologi Fransiskus, Gewayantana dan Umbu, hal ini dikarenakan nilai GAIC yang didapatkan dari non-stasioner 2 lebih rendah dibandingkan model stasioner 0 (dengan parameter konstan) dan model non-stasioner 1 (parameter berubah seiring waktu). Metode *smoothing* yang digunakan pada model optimal indeks curah hujan ekstrem RX5day di stasiun meteorologi Fransiskus, Gewayantana, Umbu dan Tardamu NTT adalah *cubic smoothing spline*. Estimasi parameter dari model terbaik indeks curah hujan ekstrem RX5day di masing-masing stasiun NTT ditampilkan pada Lampiran 12 hingga Lampiran 19.

4.2.3 Pemodelan Indeks Curah Hujan Ekstrem CDD

Pemodelan indeks curah hujan ekstrem CDD (*Maximum Number of Consecutive Dry Days*) dilakukan dengan 3 tipe model, yakni ; model non-stasioner 0 (parameter konstan), model non-stasioner 1 (parameter berubah seiring waktu atau menjadikan waktu sebagai variabel prediktor) serta model non-stasioner 2 (parameter dipengaruhi oleh indeks iklim skala besar NINO3.4 SST dan SOI sebagai variabel prediktor) dikarenakan analisis karakteristik indeks curah hujan ekstrem menunjukkan bahwa diindikasikan terdapat nonstasioneritas pada indeks curah hujan ekstrem CDD di hampir semua stasiun di Provinsi NTT. Distribusi yang digunakan dalam pemodelan indeks curah hujan ekstrem CDD adalah distribusi *Generalized Poisson*, Binomial Negatif dan *Poisson Inverse Gaussian*, selain itu juga digunakan 2 tipe *smoothing* yakni *cubic spline smoothing* dan *penalized spline term*. Pemodelan indeks curah hujan ekstrem CDD dilakukan di 8 stasiun meteorologi di NTT. Pemilihan model terbaik untuk memodelkan CDD di Stasiun Meteorologi Komodo disajikan pada Tabel 4.8 hingga 4.10.

Tabel 4.8 Nilai GAIC Pemodelan CDD di Stasiun Komodo dengan Model Stasioner 0

Tipe Model	Distribusi	GAIC
Model 0	Binomial Negatif	195,72
	Gen Poisson	195,94
	Poisson Inv Gauss	196,33

Tabel 4.9 Nilai GAIC Pemodelan CDD di Stasiun Komodo dengan Model Non-stasioner 1

Tipe Model	Tipe <i>smoothing</i>	Distribusi	θ_1	θ_2	GAIC
Model 1	<i>Cubic</i>	Poisson Inv Gauss	t	cs(t)	200,15
		Gen Poisson	t	cs(t)	200,35
		Binomial Negatif	t	cs(t)	200,90
		Poisson Inv Gauss	cs(t)	t	203,84
		Binomial Negatif	cs(t)	t	204,12
		Gen Poisson	cs(t)	t	204,40
Model 1	<i>Penalized</i>	Poisson Inv Gauss	t	pb(t)	195,77
		Binomial Negatif	t	pb(t)	196,44
		Binomial Negatif	pb(t)	t	199,13
		Poisson Inv Gauss	pb(t)	t	199,21
		Gen Poisson	t	pb(t)	199,84
		Gen Poisson	pb(t)	t	199,84

Tabel 4.8 menunjukkan bahwa distribusi yang paling sesuai untuk memodelkan indeks CDD di Stasiun Komodo secara stasioner adalah distribusi Binomial Negatif, sedangkan Tabel 4.9 dan 4.10 menunjukkan bahwa distribusi

yang paling sesuai untuk memodelkan indeks CDD secara non-stasioner adalah distribusi *Poisson Inverse Gaussian*.

Tabel 4.10 Nilai GAIC Pemodelan CDD di Stasiun Komodo dengan Model Non-stasioner 2

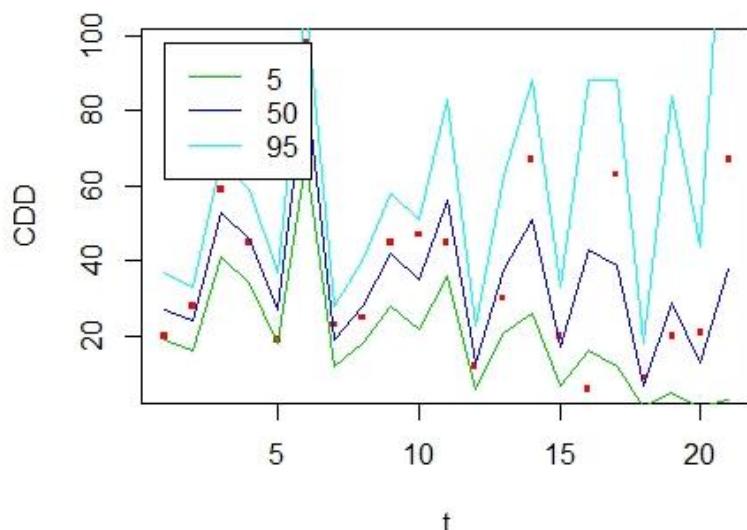
Tipe Model	Tipe <i>smoothing</i>	Distribusi	θ_1	θ_2	GAIC
Model 2	<i>Cubic</i>	Poisson Inv Gauss	SOI+NINO3.4	cs(t)	191,03
		Gen Poisson	cs(NINO3.4)	SOI	191,53
		Gen Poisson	cs(NINO3.4)	cs(SOI)	193,35
		Binomial Negatif	cs(NINO3.4)	SOI	193,45
		Poisson Inv Gauss	cs(NINO3.4)	cs(SOI)	193,97
		Poisson Inv Gauss	NINO3.4	cs(SOI)	195,16
		Gen Poisson	NINO3.4	cs(SOI)	195,22
		Binomial Negatif	cs(SOI)	NINO3.4	198,54
		Gen Poisson	SOI	cs(NINO3.4)	198,88
		Binomial Negatif	SOI	cs(NINO3.4)	198,95
		Binomial Negatif	cs(SOI)+cs(NINO3.4)	t	199,25
Model 2	<i>Penalized</i>	Poisson Inv Gauss	SOI+NINO3.4	pb(t)	187,71
		Gen Poisson	SOI+NINO3.4	pb(t)	189,48
		Binomial Negatif	SOI+NINO3.4	pb(t)	189,55
		Binomial Negatif	NINO3.4	pb(SOI)	193,04
		Binomial Negatif	pb(NINO3.4)	pb(SOI)	193,04
		Gen Poisson	NINO3.4	pb(SOI)	193,23
		Poisson Inv Gauss	NINO3.4	pb(SOI)	193,77
		Poisson Inv Gauss	pb(NINO3.4)	pb(SOI)	193,77
		Poisson Inv Gauss	pb(NINO3.4)	SOI	193,77
		Gen Poisson	pb(NINO3.4)	pb(SOI)	194,37
		Gen Poisson	pb(NINO3.4)	SOI	194,38
		Binomial Negatif	pb(NINO3.4)	SOI	194,90
		Poisson Inv Gauss	SOI	pb(NINO3.4)	194,96
		Poisson Inv Gauss	pb(SOI)	NINO3.4	194,96
		Poisson Inv Gauss	pb(SOI)	pb(NINO3.4)	194,96
		Gen Poisson	pb(SOI)	NINO3.4	195,22
		Gen Poisson	pb(SOI)	pb(NINO3.4)	195,22
		Gen Poisson	SOI	pb(NINO3.4)	195,22
		Binomial Negatif	pb(SOI)	NINO3.4	195,41
		Binomial Negatif	pb(SOI)	pb(NINO3.4)	195,41
		Binomial Negatif	SOI	pb(NINO3.4)	195,72
		Binomial Negatif	pb(SOI)+pb(NINO3.4)	t	195,85
		Poisson Inv Gauss	pb(SOI)+pb(NINO3.4)	t	195,95
		Gen Poisson	pb(SOI)+pb(NINO3.4)	t	196,95

Pemodelan non-stasioner untuk CDD di Stasiun Komodo dengan metode *penalized spline* cenderung menghasilkan nilai GAIC yang lebih kecil dibandingkan dengan *cubic smoothing*. GAIC pada tipe model non-stasioner 2 (parameter dipengaruhi oleh indeks iklim skala besar NINO3.4 SST dan SOI) bernilai lebih kecil dibandingkan dengan model stasioner 0 (parameter konstan) dan

model non-stasioner 1 (parameter berubah seiring waktu), hal ini menunjukkan bahwa terdapat non-stasioneritas dalam indeks curah hujan ekstrem CDD di stasiun meteorologi Komodo yang dipengaruhi oleh indeks iklim skala besar. Tabel 4.10 menunjukkan bahwa intensitas kekeringan (curah hujan ekstrem CDD) pada stasiun meteorologi Komodo dipengaruhi oleh kedua indeks iklim skala besar (NINO3.4 SST dan SOI), sedangkan fluktuasi atau varians dari CDD pada stasiun meteorologi Komodo dipengaruhi oleh waktu (t). *Link function* untuk parameter θ_1 dan θ_2 pada distribusi *Poisson Inverse Gaussian* adalah $\ln(\cdot)$, sehingga model terbaik untuk indeks curah hujan ekstrem CDD di stasiun meteorologi Komodo dituliskan sebagai berikut :

$$\begin{aligned}\ln(\theta_{1t}) &= \eta_{1t} = 8,917 + 0,021SOI_i - 0,186NINO3.4_i \\ \ln(\theta_{2t}) &= \eta_{2t} = -0,260 - 0,168pb(t)\end{aligned}$$

Plot antara data indeks curah hujan ekstrem CDD dan *centiles fitted value* (0,05; 0,50 dan 0,95) dari model optimal untuk CDD di stasiun meteorologi Komodo disajikan pada Gambar 4.5.



Gambar 4.5 Plot antara Data CDD dan *Fitted Value* di Stasiun Komodo

Gambar 4.5 menunjukkan bahwa model optimal untuk indeks curah hujan ekstrem CDD di stasiun meteorologi Komodo dengan intensitas curah hujan ekstrem yang dipengaruhi oleh kedua indeks iklim NINO3.4 SST dan SOI, serta varians yang dipengaruhi oleh waktu dapat menangkap pola data aktual CDD

dengan cukup baik. Pemilihan model optimal untuk indeks curah hujan ekstrem CDD di 8 stasiun meteorologi di NTT dirangkum dalam Tabel 4.11.

Tabel 4.11 Model Terbaik CDD di 8 Stasiun Meteorologi NTT

Stasiun	Tipe model	Distribusi	θ_1	θ_2	GAIC
Komodo	Model 2	Poisson Inv Gauss	SOI+NINO3.4	pb(t)	187,71
Frans	Model 2	Binomial Negatif	cs(SOI)+cs(NINO3.4)	t	189,19
Fransiskus	Model 1	Gen Poisson	pb(t)	t	200,56
Gewayantana	Model 2	Gen Poisson	NINO3.4	pb(SOI)	225,77
Umbu	Model 0	Binomial Negatif	konstan	konstan	227,36
Lasiana	Model 2	Gen Poisson	pb(SOI)+pb(NINO3.4)	t	222,99
Eltari	Model 1	Binomial Negatif	t	cs(t)	223,23
Tardamu	Model 0	Poisson Inv Gauss	konstan	konstan	230,49

Tabel 4.11 menunjukkan bahwa stasioneritas terjadi pada indeks curah hujan ekstrem CDD di 2 stasiun meteorologi di NTT, yakni stasiun Umbu dan Tardamu, hal ini dikarenakan nilai GAIC yang didapatkan dari model stasioner 0 lebih rendah dibandingkan model non-stasioner 1 (parameter berubah seiring waktu) dan non-stasioner 2 (parameter dipengaruhi oleh indeks iklim skala besar). Waktu diidentifikasi sebagai faktor utama yang mempengaruhi intensitas dan fluktuasi curah hujan ekstrem CDD di stasiun meteorologi Fransiskus dan Tardamu, sedangkan indeks iklim skala besar NINO3.4 SST dan SOI diidentifikasi sebagai faktor utama yang mempengaruhi intensitas dan fluktuasi curah hujan ekstrem di stasiun meteorologi Komodo, Frans, Gewayantana dan Lasiana, hal ini dikarenakan nilai GAIC yang didapatkan dari non-stasioner 2 lebih rendah dibandingkan model stasioner 0 (dengan parameter konstan) dan model non-stasioner 1 (parameter berubah seiring waktu). Estimasi parameter dari model terbaik indeks curah hujan ekstrem CDD di masing-masing stasiun NTT ditampilkan pada Lampiran 20 hingga Lampiran 27.

4.2.4 Hasil Evaluasi Kebaikan Model

Analisis *goodness-of-fit* atau kebaikan dari model optimal dilakukan dengan menghitung koefisien Filliben dan *worm plots*. Perhitungan koefisien Filliben dari model optimal untuk masing-masing indeks curah hujan ekstrem RX5Day (*Maximum 5 Day Precipitation Total*) dan CDD (*Maximum Number of Consecutive Dry Days*) di stasiun meteorologi di NTT disajikan pada Tabel 4.12 dan 4.13.

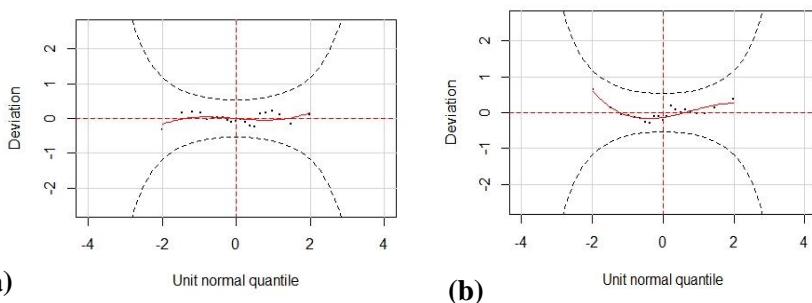
Tabel 4.12 Koefisien Filliben dari Model Terbaik RX5day

Stasiun	Tipe model	Distribusi	θ_1	θ_2	Filliben
Komodo	Model 0	Gen Gamma	konstan	konstan	0,9886
Frans	Model 0	Lognormal	konstan	konstan	0,9779
Fransiskus	Model 2	Gamma	SOI+NINO3.4	cs(t)	0,9648
Gewayantana	Model 2	Gamma	SOI	cs(NINO3.4)	0,9507
Umbu	Model 2	Gen Gamma	SOI	cs(NINO3.4)	0,9889
Lasiana	Model 0	Gamma	konstan	konstan	0,9812
Eltari	Model 0	Gamma	konstan	konstan	0,9814
Tardamu	Model 1	Gamma	t	cs(t)	0,9802

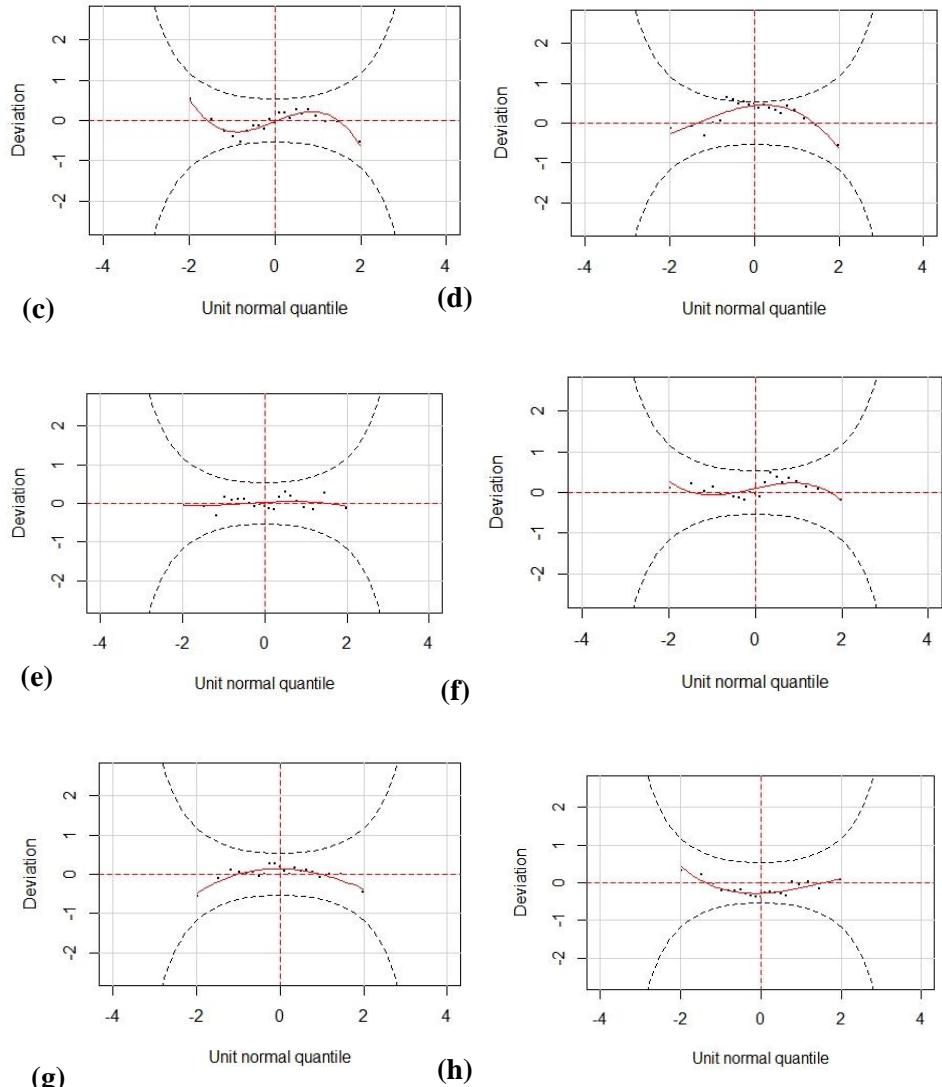
Tabel 4.13 Koefisien Filliben dari Model Terbaik CDD

Stasiun	Tipe model	Distribusi	θ_1	θ_2	Filliben
Komodo	Model 2	Poisson Inv Gauss	SOI+NINO3.4	pb(t)	0,9811
Frans	Model 2	Binomial Negatif	cs(SOI)+cs(NINO3.4)	t	0,9365
Fransiskus	Model 1	Gen Poisson	pb(t)	t	0,9684
Gewayantana	Model 2	Gen Poisson	NINO3.4	pb(SOI)	0,9907
Umbu	Model 0	Binomial Negatif	konstan	konstan	0,9827
Lasiana	Model 2	Gen Poisson	pb(SOI)+pb(NINO3.4)	t	0,9838
Eltari	Model 1	Binomial Negatif	t	cs(t)	0,9686
Tardamu	Model 0	Poisson Inv Gauss	konstan	konstan	0,9891

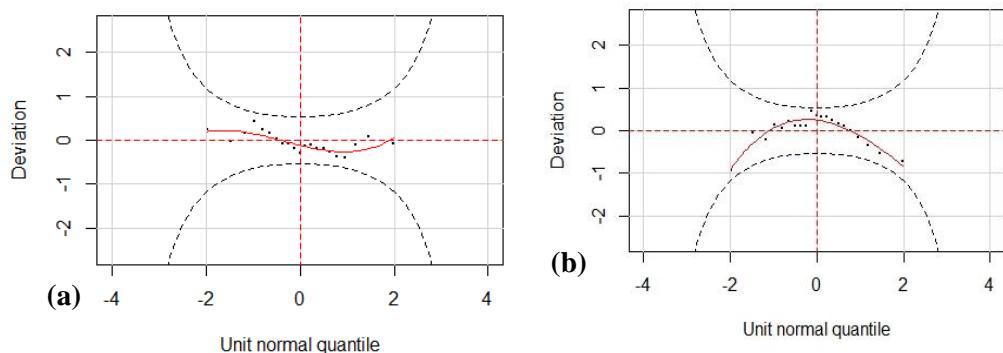
Tabel 4.12 dan 4.13 menginformasikan bahwa koefisien Filliben dari indeks RX5day dan CDD di setiap stasiun bernilai cukup tinggi. Sebagian besar koefisien Filliben bernilai lebih dari 0,95, normalitas dari residual yang mendasarinya akan cenderung menghasilkan plot probabilitas normal linier yang akan tercermin oleh nilai koefisien korelasi Filliben r yang mendekati satu. Hal ini menunjukkan bahwa residual dari model optimal untuk indeks curah hujan RX5day dan CDD di setiap stasiun telah berdistribusi normal. Normalitas dan kesesuaian model juga tercermin dari analisis *worm plots* yang disajikan pada Gambar 4.6 dan 4.7. Konsep dan perhitungan interval *Worm plots* telah dijelaskan pada sub-bab 2.9.



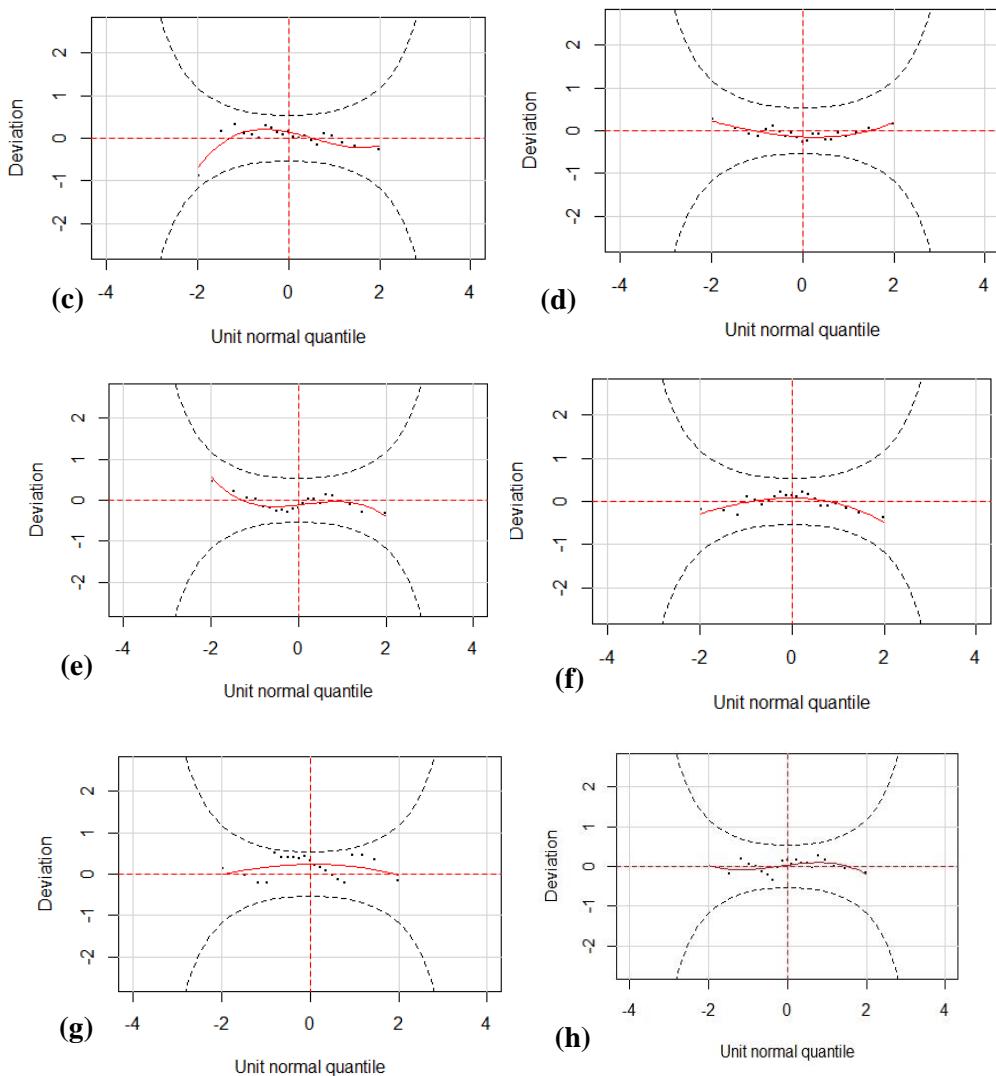
Gambar 4.6 Worm plot dari Model Terbaik RX5day di Stasiun (a) Komodo (b) Frans (c) Fransiskus (d) Gewayantana (e) Umbu (f) Lasiana (g) Eltari (h) Tardamu



Gambar 4.6 Worm plot dari Model Terbaik RX5day di Stasiun (a) Komodo (b) Frans (c) Fransiskus (d) Gewayantana (e) Umbu (f) Lasiana (g) Eltari (h) Tardamu (Lanjutan)



Gambar 4.7 Worm plot dari Model Terbaik CDD (a) Komodo (b) Frans (c) Fransiskus (d) Gewayantana (e) Umbu (f) Lasiana (g) Eltari (h) Tardamu



Gambar 4.7 *Worm plot* dari Model Terbaik CDD (a) Komodo (b) Frans (c) Fransiskus (d) Gewayantana (e) Umbu (f) Lasiana (g) Eltari (h) Tardamu (Lanjutan)

Worm plot adalah representasi dari *de-trended* QQ plot, indikasi tentang kesesuaian model yang terpilih ditandai dengan poin-poin residual yang berada dalam interval kepercayaan 95%. Interval kepercayaan 95% pada Gambar 4.6 dan 4.7 ditunjukkan dengan garis putus-putus, sehingga didapatkan informasi bahwa plot residual dari model terbaik dari indeks curah hujan ekstrem RX5Day (*Maximum 5 Day Precipitation Total*) dan CDD (*Maximum Number of Consecutive Dry Days*) di masing-masing stasiun meteorologi di NTT berada didalam interval kepercayaan 95%, sehingga dapat dikatakan bahwa model optimal yang didapatkan telah sesuai.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Nonstasioneritas seringkali ditemukan pada data deret waktu hidrologi karena adanya variabilitas iklim atau perubahan iklim antropogenik, sehingga mengabaikan nonstasioneritas pada data deret waktu hidrologi dapat menyebabkan hasil analisis yang bias. Memodelkan kejadian curah hujan ekstrem di bawah nonstasioneritas penting untuk memahami perubahan curah hujan ekstrem sehingga dapat dijadikan pertimbangan untuk membuat keputusan dalam pengurangan risiko bencana. Indeks curah hujan ekstrem yang dimaksud dalam penelitian ini adalah RX5Day (*Maximum 5 Day Precipitation Total*) dan CDD (*Maximum Number of Consecutive Dry Days*). Beberapa kesimpulan yang dirangkum dari penelitian ini adalah sebagai berikut:

1. Hasil dari kajian simulasi untuk indeks curah hujan ekstrem RX5day dan CDD menunjukkan bahwa metode GAMLSS mampu menangkap distribusi data kontinu dan diskrit dengan baik sesuai dengan skenario distribusi data awal yang telah dibangkitkan, semakin tinggi jumlah sampel maka persentase kemampuan metode GAMLSS dalam menangkap distribusi data juga semakin baik.
2. Dua indeks iklim : SOI (*Southern Oscillation Index*) dan NINO3.4 SST (*NINO Sea Surface Temperature*) yang digunakan dalam penelitian ini diidentifikasi sebagai faktor utama yang mempengaruhi peristiwa curah hujan ekstrem RX5DAY di 3 stasiun (Fransiskus, Gewayantana dan Umbu) dan curah hujan ekstrem CDD di 4 stasiun (Komodo, Frans, Gewayantana dan Lasiana) di NTT. Waktu diidentifikasi sebagai faktor utama yang mempengaruhi peristiwa curah hujan ekstrem RX5day di stasiun meteorologi Tardamu dan peristiwa CDD di stasiun meteorologi Fransiskus dan Eltari. Di sebagian besar stasiun, informasi terperinci tentang peristiwa curah hujan ekstrem dapat dijelaskan dengan lebih baik oleh model non-stasioner dengan indeks iklim skala besar (NINO3.4 SST dan SOI) sebagai variabel prediktor

dibandingkan dengan model stasioner (dengan parameter konstan) dan model non-stasioner 1 (dengan parameter berubah seiring waktu). Model yang melibatkan formulasi *cubic spline smoothing* cenderung lebih sesuai digunakan untuk memodelkan indeks curah hujan ekstrem RX5day di 4 stasiun (meteorologi Fransiskus, Gewayantana, Umbu dan Tardamu) dan CDD di 2 stasiun (Frans dan Eltari), sedangkan *penalized spline* sesuai digunakan untuk memodelkan indeks curah hujan ekstrem CDD di 4 stasiun (Komodo, Fransiskus, Gewayantana dan Lasiana).

5.2 Saran

Pengembangan dan penerapan metode non-stasioner dalam memprediksi dan identifikasi kejadian curah hujan ekstrem dengan mempertimbangkan pengaruh waktu dan indeks iklim skala besar NINO3.4 SST dan SOI diperlukan untuk mengembangkan strategi mitigasi dan adaptasi terhadap dampak curah hujan ekstrem di NTT. Pemodelan non-stasioner pada penelitian ini dilakukan dengan memodelkan semua parameter dari distribusi yang digunakan untuk memodelkan indeks curah hujan RX5day dan CDD, sehingga perlu dilakukan perbandingan dengan memodelkan salah satu parameter dari distribusi (*location/scale/shape*) untuk pemilihan model terbaik pada penelitian selanjutnya, hal ini dikarenakan penelitian sebelumnya mengenai *extreme value* hanya memodelkan parameter skala (*scale*).

Curah hujan non-stasioner mungkin disebabkan oleh perubahan iklim dan aktivitas manusia, tetapi hanya indeks iklim yang digunakan dalam penelitian ini, penelitian selanjutnya diharapkan dapat melibatkan tidak hanya indeks iklim tetapi juga indeks yang dapat mewakili aktivitas manusia sebagai variabel prediktor yang mempengaruhi indeks curah hujan ekstrem. Salah satu aktivitas manusia yang dapat berpengaruh terhadap perubahan iklim ekstrem adalah pengelolaan sistem drainase dan aktivitas yang menghasilkan gas CO₂ seperti penggunaan kendaraan bermotor, aktivitas industri maupun aktivitas lain yang tidak ramah lingkungan sehingga dapat berdampak pada kondisi atmosfer bumi.

DAFTAR PUSTAKA

- Bozdogan, H. 2000. Akaike's Information Criterion and Recent Developments in Information Complexity. *Journal of Mathematical Psychology*. Volume 44, pp. 62-91.
- Caroni, C., Panagoulia, D. dan Economou, P., 2015. *Non-stationary modelling of extremes of precipitation and temperature over mountainous areas under climate change*. Greece, ResearchGate.
- Cole, T. J., dan Green, P. J., 1992. Smoothing reference centile curves: The LMS method and penalized likelihood. *Statistics in Medicine*, Volume 11(10), pp. 1305–1319.
- Croitoru, A.E., Piticar, A. dan Burada, D.C., 2015. Changes in precipitation extremes in Romania. *Quatern. Int.* Volume 415, pp. 1–11.
- De Boor, C., 1978. A Practical Guide to Splines. Revised Edition. *Book in Mathematics of Computation* : Springer.
- Demirdjian, L., Zhou, Y. dan Huffman, G. J., 2018. Statistical Modeling of Extreme Precipitation with TRMM Data. *Journal Of Applied Meteorologi And Climatology*, Volume 57, pp. 15-30.
- Duan, Y., Ma, Z., dan Yang, Q., 2017. Characteristics of consecutive dry days variations in China. *Theor Appl Climatol.* Volume 130, pp. 701-709.
- Eilers, P. H. C., dan Marx, B. D., 1996. Flexible Smoothing with B-splines and Penalties. *Statistical Science*. Volume 11(2), pp. 89-102.
- Fahrmeir, L. dan Lang, S, 2001. Bayesian inference for generalized additive mixed models based on Markov random field priors. *Appl. Statist.*, Volume 50, pp. 201–220.
- Fahrmeir, L dan Tutz, G., 2001. Multivariate Statistical Modelling based on Generalized Linear Models, 2nd edn. New York : Springer.
- Filliben, J. J., 1975. The Probability Plot Correlation Coefficient Test for Normality. *Technometrics*. Volume 17(1), pp. 111-117.

Hao, W., Shao, Q., Hao, Z., Ju, Q., Baima, W dan Zhang, D., 2019. Non-stationary modelling of extreme precipitation by climate indices during rainy season in Hanjiang River Basin, China. *International Journal of Climatology*, 39(10), pp. 4154-4169.

Hastie, T. J. dan Tibshirani, R. J., 1990. Generalized additive models. CRC Press : Florida.

Hosking, J. R. M. dan Wallis, J. R., 1997. *Regional Frequency Analysis—An Approach Based on L-Moments*. Cambridge University Press, Cambridge, UK.

IPCC, 2013. Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change. *Summary for Policymakers*. In : Stocker, T.F., Qin, D., Plattner, G.-K., Tignor, M., Allen, S.K., Boschung, J., Nauels, A., Xia, Y., Bex, V., Midgley, P.M. e. (Eds.).

Kadarsah, 2007. Tiga Pola Curah Hujan Indonesia. Diakses melalui <http://kadarsah.wordpress.com/2019/01/30/tiga-daerah-iklim-indonesia/#comment-2613>, ditulis oleh: Kadarsah. Berkunjung pada tanggal 08 Oktober 2019.

Kevin, E. T., 2010. Changes in precipitation with climate change. *Climate Research*. Volume 47, pp. 123-138.

Khaliq, M., Ouarda, T., Ondo, J.C., Gachon, P. dan Bobe, B., 2006. Frequency analysis of a sequence of dependent and/or non-stationary hydro-meteorological observations : a review. *J Hydrol*. Volume 329, pp. 534–552.

Kuhl, M. E., 2017. History Of Random Variate Generation. *Proceedings of the 2017 Winter Simulation Conference*, pp. 231-242.

Kuswanto, H., Fithriasari, K. dan Inas, R., 2018. Drought Risk Mapping in East Nusa Tenggara Indonesia Based on Return Periods. *Asian Journal of Scientific Research* , 11(4), pp. 489-497.

LAPAN, 2012. Pengaruh SOI Terhadap Curah Hujan dan Produksi Padi di Indonesia. *Prosiding Sains Atmosfer dan Antariksa Tahun 2012*, pp. 241-247.

- Lin, X. dan Zhang, D, 1999. Inference in generalized additive mixed models by using smoothing splines. *J. R. Statist. Soc. B*, Volume 61, pp. 381–400.
- Liu, S., Huang, S., Huang, Q., Xie, Y., Leng, G., Luan, J., Song, X., Xiu, W. dan Li, X., 2017. Identification of the non-stationarity of extreme precipitation events and correlations with large-scale ocean-atmospheric circulation patterns: A case study in the Wei River Basin, China. *Journal of Hydrology*, Volume 548, pp. 184-195.
- McCulloch, C. E., 1997. Maximum likelihood algorithms for generalized linear mixed models. *J. Am. Statist. Ass.*, Volume 92, pp. 162–170.
- NOAA, 2019. Equatorial Pacific Sea Surface Temperatures. Diakses melalui <https://www.ncdc.noaa.gov/teleconnections/enso/indicators/sst/> oleh National Centers for Environmental Information : National Oceanic and Atmospheric Administration. Berkunjung pada tanggal 25 Oktober 2019.
- Nelder, J. A. dan Wedderburn, R. W. M, 1972. Generalized linear models. *J. R. Statist. Soc. A*, Volume 135, pp. 370–384.
- Reed, D. W., Jakob, D., Robson, A. J., Faulkner, D. S. dan Stewart, E. J., 1999. Regional Frequency Analysis: a New Vocabulary. *Hydrological Extremes: Understanding, Predicting, Mitigating*. IAHS Publ. 255, pp. 237–243.
- Rigby, R. dan Stasinopoulos, D. M, 2005. Generalized additive models for location, scale and shape. *J Roy Stat Soc: Ser C (Appl Stat)* 54:507–554.
- Rigby, R., Stasinopoulos, D. M., Heller, G. dan Bastiani, F. D., 2017. Distributions for Modelling Location, Scale and Shape: Using GAMLSS in R. Chapman and Hall/CRC Press.
- Royston, P. dan Altman, D. G., 1994. Regression Using Fractional Polynomials of Continuous Covariates: Parsimonious Parametric Modelling. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*. Volume 43(3), pp. 429-467.
- Salas, J. D., 1993. Analysis and modeling of hydrologic time series. *Handb Hydrol.* Volume 19, pp. 1–72.

- Seidou, O., Ramsay, A. dan Nistor, I., 2012. Climate change impacts on extreme floods II: improving flood future peaks simulation using non-stationary frequency analysis. *Nat Hazards*. Volume 60(2), pp. 715–726.
- Silverman, B. W., 1985. Some Aspects of the Spline Smoothing Approach to Non-Parametric Regression Curve Fitting. *J. R. Statist. Soc. B*. Volume 47(1), pp. 1-52.
- Smith, P. L., 1979. Splines as a useful and convenient statistical tool. *Am. Statistn*, Volume 33, pp. 57–62.
- Stasinopoulos, D. M. dan Rigby, R. A., 1992. Detecting break points in generalised linear models. *Comput. Statist. Data Analysis*, Volume 13, pp. 461–471.
- Stedinger, J. R., Vogel, R. dan Foufoula-Georgiou, E., 1993. Frequency analysis of extreme events. In: Maidment, D.R. (Ed.), *Handbook of Hydrology*. McGraw-Hill, New York (Chap. 18).
- Syaifullah, D., 2009. Kajian Sea Surface Temperature (SST), Southern Oscillation Index (SOI) Dan Dipole Mode pada Kegiatan Penerapan Teknologi Modifikasi Cuaca Di Propinsi Riau Dan Sumatera Barat Juli – Agustus 2009. *Jurnal Sains & Teknologi Modifikasi Cuaca*, Vol. 11, No. 1, 2010: 1-7.
- Syaifullah, D. dan Gunawan, 1999: Variasi SST & SOI Terhadap Kejadian El-Nino & La Nina di Wilayah Indonesia. *Prosiding Konferensi Energi, Sumberdaya Alam dan Lingkungan (ESDAL)* : Jakarta.
- Tian, B. Q. dan Fan, K., 2012. Relationship between the Late Spring NAO and Summer Extreme Precipitation Frequency in the Middle and Lower Reaches of the Yangtze River. *Atmospheric and Oceanic Science Letters* 5 : 455-460.
- Van, B.S. and Fredriks, M. (2010) Worm plot: a simple diagnostic device for modelling growth reference curves. *Statistics in Medicine*, 20, 1259–1277.
- Villarini, G., Smith, J. A., dan Napolitano, F., 2010. Nonstationary modeling of a long record of rainfall and temperature over Rome. *Advances in Water Resources*. Volume 33(10), pp. 1256–1267.
- Wen, L. K., Cui, P., Yang, H. J., Zou, Q. dan Xiang, L. Z., 2011. The relationship between ENSO and the precipitation extremes along the middle reaches of

Yangtze River during the monsoon season. *Journal of Mountain Science*. Volume 29, pp. 229-305.

WGCCD, 2001. Report on the Activities of the Working Group on Climate Change Detection and Related Rapporteurs. In : Peterson, T. C., Folland, C., Gruza, G., Hogg, W., Mokssit, A., Plummer, N. e. (Eds.).

WMO, 2018. Guidelines On The Definition And Monitoring Of Extreme Weather And Climate Events. WMO Commission For Climatology Task Team On The Definition Of Extreme Weather And Climate Events (Eds.).

Wood, S. N. 2001. GAMs and Generalized Ridge Regression for R. R News. Volume 1(2), pp.20-25.

Zhang, D. D., Yan, D. H. dan Wang, Y. C., 2015. GAMLSS-based nonstationary modeling of extreme precipitation in Beijing–Tianjin–Hebei region of China. *Nature Hazards*. Volume 77, pp. 1037-1053.

Zeger, S. L dan Karim, M. R., 1991. Generalized linear models with random effects : a Gibbs sampling approach. *J. Am. Statist. Ass.*, Volume 86, pp. 79–95.

(Halaman ini sengaja dikosongkan)

LAMPIRAN

Lampiran 1 Data Curah Hujan Harian di 8 Stasiun meteorologi di Provinsi NTT

Tanggal	Tahun	Komodo	Frans	Fransiskus	Gewayantana
01/01/1999	1999	0,0	20,3	0,0	2,0
02/01/1999	1999	0,0	15,6	0,0	1,6
03/01/1999	1999	2,5	2,3	0,0	0,0
04/01/1999	1999	5,0	0,7	3,3	9,8
05/01/1999	1999	1,0	0,0	3,5	0,0
06/01/1999	1999	2,3	7,8	6,9	0,0
07/01/1999	1999	10,5	2,0	3,0	3,3
08/01/1999	1999	0,0	4,5	0,0	0,0
09/01/1999	1999	0,3	4,2	0,0	8,2
:	:	:	:	:	:
01/01/2009	2009	0,0	0,0	0,0	23,2
02/01/2009	2009	0,2	0,0	0,0	0,8
03/01/2009	2009	51,9	3,8	0,0	1,5
04/01/2009	2009	12,7	22,5	9,2	0,3
05/01/2009	2009	2,4	1,5	0,0	0,7
06/01/2009	2009	0,0	23,5	0,0	0,0
07/01/2009	2009	5,4	4,4	0,0	0,0
08/01/2009	2009	0,8	12,5	6,0	0,2
09/01/2009	2009	38,6	29,1	5,1	1,5
10/01/2009	2009	19,8	1,7	4,1	8,9
:	:	:	:	:	:
01/01/2019	2019	12,0	46,6	22,1	10,3
02/01/2019	2019	36,2	11,5	24,5	41,3
03/01/2019	2019	8,1	92,8	38,1	32,3
04/01/2019	2019	13,7	32,3	1,0	3,0
05/01/2019	2019	4,3	5,6	3,4	7,3
06/01/2019	2019	0,0	35,1	0,9	3,2
07/01/2019	2019	0,0	35,1	1,0	0,0
08/01/2019	2019	0,1	2,0	1,7	0,0
09/01/2019	2019	1,1	34,8	4,7	0,0
10/01/2019	2019	0,0	88,1	0,4	1,0
:	:	:	:	:	:
23/12/2019	2019	11,2	7,0	9,1	0,0
24/12/2019	2019	19,0	4,5	9,9	4,2
25/12/2019	2019	11,0	10,0	12,6	0,0
26/12/2019	2019	1,5	39,4	0,0	0,0
27/12/2019	2019	0,0	35,5	11,5	0,0
28/12/2019	2019	4,5	3,0	13,4	0,0
29/12/2019	2019	11,4	23,9	1,9	0,0
30/12/2019	2019	18,8	53,4	29,0	41,6
31/12/2019	2019	22,3	18,2	0,0	0,0

Lampiran 1 Data Curah Hujan Harian di 8 Stasiun meteorologi di Provinsi NTT
 (Lanjutan)

Tanggal	Tahun	Umbu	Lasiana	Eltari	Tardamu
01/01/1999	1999	16,5	0,8	0,0	0,0
02/01/1999	1999	0,0	0,0	0,0	0,0
03/01/1999	1999	0,0	0,0	2,0	0,0
04/01/1999	1999	0,0	2,2	1,0	13,6
05/01/1999	1999	0,2	3,0	0,0	5,2
06/01/1999	1999	9,5	0,0	14,0	0,9
07/01/1999	1999	33,0	6,5	3,0	7,9
08/01/1999	1999	0,0	8,0	34,0	44,1
09/01/1999	1999	0,6	27,4	15,0	3,4
:	:	:	:	:	:
01/01/2009	2009	8,3	57,8	40,0	0,4
02/01/2009	2009	6,0	86,0	53,0	0,0
03/01/2009	2009	5,7	38,4	6,0	13,6
04/01/2009	2009	6,0	1,2	26,0	0,0
05/01/2009	2009	1,4	34,1	1,0	1,8
06/01/2009	2009	15,8	7,2	0,0	0,0
07/01/2009	2009	0,0	6,9	11,0	0,8
08/01/2009	2009	0,1	1,1	3,0	5,7
09/01/2009	2009	9,5	0,8	13,0	6,3
10/01/2009	2009	0,0	20,5	45,0	64,3
:	:	:	:	:	:
01/01/2019	2019	0,0	6,8	5,0	0,3
02/01/2019	2019	30,5	5,2	1,2	1,0
03/01/2019	2019	2,0	0,0	0,0	0,0
04/01/2019	2019	3,8	13,1	5,7	3,7
05/01/2019	2019	2,8	1,5	2,2	6,5
06/01/2019	2019	0,0	6,1	28,8	0,0
07/01/2019	2019	0,0	8,0	6,1	22,8
08/01/2019	2019	0,0	7,9	20,6	84,2
09/01/2019	2019	0,0	3,1	10,3	9,7
10/01/2019	2019	0,0	4,5	0,0	0,0
:	:	:	:	:	:
23/12/2019	2019	2,0	1,5	14,2	14,5
24/12/2019	2019	0,0	37,0	4,6	5,0
25/12/2019	2019	0,0	0,0	0,0	0,0
26/12/2019	2019	0,0	0,0	4,2	0,0
27/12/2019	2019	0,0	12,3	12,7	0,0
28/12/2019	2019	0,0	0,0	0,0	0,0
29/12/2019	2019	0,0	4,8	0,0	2,5
30/12/2019	2019	15,0	28,0	20,2	0,3
31/12/2019	2019	0,0	0,0	6,4	1,7

Lampiran 2 Data Indeks Curah Hujan Ekstrem RX5day di 8 Stasiun meteorologi di Provinsi NTT (mm)

Tahun	Komodo	Frans	Fransiskus	Gewayantana	Umbu	Lasiana	Eltari	Tardamu
1999	115,0	225,0	231,6	144,1	159,1	429,9	379,9	160,1
2000	210,5	359,8	201,6	162,9	110,1	323,6	260,0	214,5
2001	119,9	401,7	144,5	83,0	131,5	195,5	237,2	212,0
2002	449,6	325,3	144,5	217,3	101,8	237,1	240,0	205,0
2003	124,8	248,6	144,5	7,2	217,4	440,3	429,0	259,0
2004	122,3	188,0	134,8	64,3	87,7	179,4	231,0	227,0
2005	254,0	181,9	210,9	205,8	61,1	134,9	192,0	213,8
2006	103,6	373,9	156,6	269,4	125,7	383,4	207,0	226,4
2007	142,6	586,3	144,0	245,0	152,7	253,0	274,0	202,5
2008	132,1	350,3	127,5	218,7	136,1	337,0	327,0	198,6
2009	72,4	217,2	105,7	216,7	131,4	249,9	322,0	322,8
2010	109,9	214,9	123,7	152,9	158,9	341,5	318,0	251,2
2011	238,4	206,3	84,6	262,8	189,1	174,7	182,0	110,8
2012	144,7	320,2	145,4	314,3	160,1	54,4	229,0	80,8
2013	190,9	461,5	196,7	146,7	50,4	101,6	112,7	73,8
2014	90,5	180,9	100,4	312,0	68,0	301,1	260,6	129,4
2015	98,3	198,2	98,1	174,8	84,7	254,8	229,5	89,8
2016	254,2	278,8	117,9	124,3	99,2	148,0	124,8	138,7
2017	149,8	316,9	179,8	275,7	118,7	293,9	244,3	151,9
2018	103,5	259,7	140,6	203,1	139,0	258,6	220,5	152,3
2019	141,5	258,2	144,6	153,0	138,1	157,2	189,8	137,1

Lampiran 3 Data Indeks Curah Hujan Ekstrem CDD di 8 Stasiun meteorologi di Provinsi NTT

Tahun	Komodo	Frans	Fransiskus	Gewayantana	Umbu	Lasiana	Eltari	Tardamu
1999	68	20	45	87	99	164	164	93
2000	90	28	65	120	125	156	155	144
2001	54	59	46	112	109	90	90	129
2002	87	45	46	102	124	147	147	250
2003	36	19	76	289	105	110	110	115
2004	115	98	76	171	148	60	208	209
2005	42	23	83	99	177	186	183	132
2006	27	25	103	72	173	147	112	140
2007	28	45	127	125	74	131	105	73
2008	62	47	133	121	183	108	108	183
2009	40	45	100	93	66	121	186	76
2010	14	12	32	20	58	30	29	42
2011	58	30	98	73	142	85	85	107
2012	68	67	84	181	134	207	77	176
2013	31	20	52	37	68	36	44	69
2014	54	6	116	124	209	44	65	115
2015	50	63	37	67	180	45	44	48
2016	35	9	49	39	45	66	60	66
2017	58	20	57	93	80	90	48	74
2018	66	21	23	81	102	42	39	76
2019	42	67	24	97	185	39	131	187

Lampiran 4 Kajian Simulasi RX5day Distribusi Lognormal

```
library(gamlss)
library(gamlss.dist)
powerlogno0dist=function(m)
{
  j=0
  rdata=matrix(ncol=100, nrow=m)
  logno0=matrix(ncol=1, nrow=100)
  gamma0=matrix(ncol=1, nrow=100)
  logistic0=matrix(ncol=1, nrow=100)
  weibull0=matrix(ncol=1, nrow=100)
  GAIClogno0=matrix(ncol=1, nrow=100)
  GAICgam0=matrix(ncol=1, nrow=100)
  GAIClogis0=matrix(ncol=1, nrow=100)
  GAICwei0=matrix(ncol=1, nrow=100)
  #GAICmat=matrix(ncol=4,nrow=100)
  #m.power=matrix(ncol=1, nrow=100)
  for (j in 1:100) {
    rdata[j]=rLOGNO(m,5,1)
    dataku=data.frame(rdata[j])
    y=dataku[,1]
    logno0=gamlss(y~1,data=dataku,family=LOGNO(),method=RS(),trace=FALSE)
    gamma0=gamlss(y~1,data=dataku,family=GA(),method=RS(),trace=FALSE)
    logistic0=gamlss(y~1,data=dataku,family=LO(),method=RS(),trace=FALSE)
    weibull0=gamlss(y~1,data=dataku,family=WEI(),method=RS(),trace=FALSE)
    GAIClogno0[j,]=GAIC(logno0,k=log(length(y)),c=FALSE)
    GAICgam0[j,]=GAIC(gamma0,k=log(length(y)),c=FALSE)
    GAIClogis0[j,]=GAIC(logistic0,k=log(length(y)),c=FALSE)
    GAICwei0[j,]=GAIC(weibull0,k=log(length(y)),c=FALSE)
    GAICmat=cbind(GAIClogno0,GAICgam0,GAIClogis0,GAICwei0)
    GAICmat=data.frame(GAICmat)
  }
  powerlogno_dist=dim(GAICmat[(GAICmat[1]<GAICmat[2])&(GAICmat[1]<GAICmat[3])&(GAICmat[1]<GAICmat[4]),])[1]/100
  list(powerlogno_dist=powerlogno_dist)
}
powerlogno0dist(20)
powerlogno0dist(50)
powerlogno0dist(100)

> powerlogno0dist(20)
$powerlogno_dist
[1] 0.79
> powerlogno0dist(50)
$powerlogno_dist
[1] 0.8
> powerlogno0dist(100)
$powerlogno_dist
[1] 0.98
```

Lampiran 5 Kajian Simulasi RX5day Distribusi Gamma

```
library(gamlss)
library(gamlss.dist)
powergamma0dist=function(m)
{
  j=0
  rdata=matrix(ncol=100, nrow=m)
  logno0=matrix(ncol=1, nrow=100)
  gamma0=matrix(ncol=1, nrow=100)
  logistic0=matrix(ncol=1, nrow=100)
  weibull0=matrix(ncol=1, nrow=100)
  GAIClogno0=matrix(ncol=1, nrow=100)
  GAICgam0=matrix(ncol=1, nrow=100)
  GAIClogis0=matrix(ncol=1, nrow=100)
  GAICwei0=matrix(ncol=1, nrow=100)
  GAICmat=matrix(ncol=4,nrow=100)
  m.power=matrix(ncol=1, nrow=100)
  for (j in 1:100) {
    rdata[,j]=rGA(m,30,2)
    dataku=data.frame(rdata[,j])
    y=dataku[,1]
    logno0=gamlss(y~1,data=dataku,family=LOGNO(),method=RS(),trace=FALSE)
    gamma0=gamlss(y~1,data=dataku,family=GA(),method=RS(),trace=FALSE)
    logistic0=gamlss(y~1,data=dataku,family=LO(),method=RS(),trace=FALSE)
    weibull0=gamlss(y~1,data=dataku,family=WEI(),method=RS(),trace=FALSE)
    GAIClogno0[j,]=GAIC(logno0,k=log(length(y)),c=FALSE)
    GAICgam0[j,]=GAIC(gamma0,k=log(length(y)),c=FALSE)
    GAIClogis0[j,]=GAIC(logistic0,k=log(length(y)),c=FALSE)
    GAICwei0[j,]=GAIC(weibull0,k=log(length(y)),c=FALSE)
    GAICmat=cbind(GAIClogno0,GAICgam0,GAIClogis0,GAICwei0)
    GAICmat=data.frame(GAICmat)
  }
  powergamma0dist=dim(GAICmat[(GAICmat[2]<GAICmat[1])&(GAICmat[2]<GAICmat[3])&(GAICmat[2]<GAICmat[4]),])[1]/100
  list(powergamma0dist=powergamma0dist)
}
powergamma0dist(20)
powergamma0dist(50)
powergamma0dist(100)

> powergamma0dist(20)
$powergamma0dist
[1] 0.8
> powergamma0dist(50)
$powergamma0dist
[1] 0.9
> powergamma0dist(100)
$powergamma0dist
[1] 0.93
```

Lampiran 6 Kajian Simulasi RX5day Distribusi *Generalized Gamma*

```
library(gamlss)
library(gamlss.dist)
powerGG0dist=function(m)
{
  j=0
  rdata=matrix(ncol=100, nrow=m)
  logno0=matrix(ncol=1, nrow=100)
  logistic0=matrix(ncol=1, nrow=100)
  gengam0=matrix(ncol=1, nrow=100)
  GAIClogno0=matrix(ncol=1, nrow=100)
  GAIClogis0=matrix(ncol=1, nrow=100)
  GAICgg0=matrix(ncol=1, nrow=100)
  GAICmat=matrix(ncol=3,nrow=100)
  m.power=matrix(ncol=1, nrow=100)
  for (j in 1:100) {
    rdata[,j]=rGG(m,30,1,1)
    dataku=data.frame(rdata[,j])
    y=dataku[,1]
    logno0=gamlss(y~1,data=dataku,family=LOGNO(),method=RS(),trace=FALSE)
    logistic0=gamlss(y~1,data=dataku,family=LO(),method=RS(),trace=FALSE)
    gengam0=gamlss(y~1,data=dataku,family=GG(),method=RS(),trace=FALSE)
    GAIClogno0[j,]=GAIC(logno0,k=log(length(y)),c=FALSE)
    GAIClogis0[j,]=GAIC(logistic0,k=log(length(y)),c=FALSE)
    GAICgg0[j,]=GAIC(gengam0,k=log(length(y)),c=FALSE)
    GAICmat=cbind(GAIClogno0,GAIClogis0,GAICgg0)
    GAICmat=data.frame(GAICmat)
  }
  powerGG0dist=dim(GAICmat[(GAICmat[3]<GAICmat[1])&(GAICmat[3]<GAICmat[2]),])[1]/100
  list(powerGG0dist=powerGG0dist)
}
powerGG0dist(20)
powerGG0dist(50)
powerGG0dist(100)

> powerGG0dist(20)
$powerGG0dist
[1] 0.5
> powerGG0dist(50)
$powerGG0dist
[1] 0.83
> powerGG0dist(100)
$powerGG0dist
[1] 0.94
```

Lampiran 7 Kajian Simulasi CDD Distribusi *Generalized Poisson*

```
library(gamlss)
library(gamlss.dist)
powerGP0dist=function(m)
{
  j=0
  rdata=matrix(ncol=100, nrow=m)
  GP0=matrix(ncol=1, nrow=100)
  NB0=matrix(ncol=1, nrow=100)
  PIG0=matrix(ncol=1, nrow=100)
  GAICGP0=matrix(ncol=1, nrow=100)
  GAICNB0=matrix(ncol=1, nrow=100)
  GAICPIG0=matrix(ncol=1, nrow=100)
  GAICmat=matrix(ncol=3,nrow=100)
  for (j in 1:100) {
    rdata[,j]=rGPO(m,20,1,max.value=365)
    dataku=data.frame(rdata[,j])
    y=dataku[,1]
    GP0=gamlss(y~1,data=dataku,family=GPO,method=RS(),trace=FALSE)
    NB0=gamlss(y~1,data=dataku,family=NBI,method=RS(),trace=FALSE)
    PIG0=gamlss(y~1,data=dataku,family=PIG,method=RS(),trace=FALSE)
    GAICGP0[j,]=GAIC(GP0,k=log(length(y)),c=FALSE)
    GAICNB0[j,]=GAIC(NB0,k=log(length(y)),c=FALSE)
    GAICPIG0[j,]=GAIC(PIG0,k=log(length(y)),c=FALSE)
    GAICmat=cbind(GAICGP0,GAICNB0,GAICPIG0)
    GAICmat=data.frame(GAICmat)
  }

  powerGP0dist=dim(GAICmat[(GAICmat[1]<GAICmat[2])&(GAICmat[1]<GAICmat[3]),])[1]/100
  list(powerGP0dist=powerGP0dist)
}
powerGP0dist(20)
powerGP0dist(50)
powerGP0dist(100)

> powerGP0dist(20)
$powerGP0dist
[1] 0.33
> powerGP0dist(50)
$powerGP0dist
[1] 0.59
> powerGP0dist(100)
$powerGP0dist
[1] 0.83
```

Lampiran 8 Kajian Simulasi CDD Distribusi Binomial Negatif

```
library(gamlss)
library(gamlss.dist)
powerNB0dist=function(m)
{
  j=0
  rdata=matrix(ncol=100, nrow=m)
  GP0=matrix(ncol=1, nrow=100)
  NB0=matrix(ncol=1, nrow=100)
  PIG0=matrix(ncol=1, nrow=100)
  GAICGP0=matrix(ncol=1, nrow=100)
  GAICNB0=matrix(ncol=1, nrow=100)
  GAICPIG0=matrix(ncol=1, nrow=100)
  GAICmat=matrix(ncol=3,nrow=100)
  for (j in 1:100) {
    rdata[,j]=rNBI(m,30,2)
    dataku=data.frame(rdata[,j])
    y=dataku[,1]
    GP0=gamlss(y~1,data=dataku,family=GPO,method=RS(),trace=FALSE)
    NB0=gamlss(y~1,data=dataku,family=NBI,method=RS(),trace=FALSE)
    PIG0=gamlss(y~1,data=dataku,family=PIG,method=RS(),trace=FALSE)
    GAICGP0[j,]=GAIC(GP0,k=log(length(y)),c=FALSE)
    GAICNB0[j,]=GAIC(NB0,k=log(length(y)),c=FALSE)
    GAICPIG0[j,]=GAIC(PIG0,k=log(length(y)),c=FALSE)
    GAICmat=cbind(GAICGP0,GAICNB0,GAICPIG0)
    GAICmat=data.frame(GAICmat)
  }
  powerNB0dist=dim(GAICmat[(GAICmat[2]<GAICmat[1])&(GAICmat[2]<GAICmat[3])])[1]/100
  list(powerNB0dist=powerNB0dist)
}
powerNB0dist(20)
powerNB0dist(50)
powerNB0dist(100)

> powerNB0dist(20)
$powerNB0dist
[1] 0.84
> powerNB0dist(50)
$powerNB0dist
[1] 0.95
> powerNB0dist(100)
$powerNB0dist
[1] 0.98
```

Lampiran 9 Kajian Simulasi CDD Distribusi Poisson Inverse Gaussian

```
library(gamlss)
library(gamlss.dist)
powerPIG0dist=function(m)
{
  j=0
  rdata=matrix(ncol=100, nrow=m)
  GP0=matrix(ncol=1, nrow=100)
  NB0=matrix(ncol=1, nrow=100)
  PIG0=matrix(ncol=1, nrow=100)
  GAICGP0=matrix(ncol=1, nrow=100)
  GAICNB0=matrix(ncol=1, nrow=100)
  GAICPIG0=matrix(ncol=1, nrow=100)
  GAICmat=matrix(ncol=3,nrow=100)
  m.power=matrix(ncol=1, nrow=100)
  for (j in 1:100) {
    rdata[,j]=rPIG(m,20,5,max.value=365)
    dataku=data.frame(rdata[,j])
    y=dataku[,1]
    GP0=gamlss(y~1,data=dataku,family=GPO,method=RS(),trace=FALSE)
    NB0=gamlss(y~1,data=dataku,family=NBI,method=RS(),trace=FALSE)
    PIG0=gamlss(y~1,data=dataku,family=PIG,method=RS(),trace=FALSE)
    GAICGP0[j,]=GAIC(GP0,k=log(length(y)),c=FALSE)
    GAICNB0[j,]=GAIC(NB0,k=log(length(y)),c=FALSE)
    GAICPIG0[j,]=GAIC(PIG0,k=log(length(y)),c=FALSE)
    GAICmat=cbind(GAICGP0,GAICNB0,GAICPIG0)
    GAICmat=data.frame(GAICmat)
  }
  powerPIG0dist=dim(GAICmat[(GAICmat[3]<GAICmat[1])&(GAICmat[3]<GAICmat[1
  l]),])[1]/100
  list(powerPIG0dist=powerPIG0dist)
}
powerPIG0dist(20)
powerPIG0dist(50)
powerPIG0dist(100)

> powerPIG0dist(20)
$powerPIG0dist
[1] 0.57
> powerPIG0dist(50)
$powerPIG0dist
[1] 0.69
> powerPIG0dist(100)
$powerPIG0dist
[1] 0.80
```

Lampiran 10 Syntax Pemodelan Indeks Curah Hujan Ekstrem RX5day

```
library(gamlss)
library(gamlss.dist)
library(ppcc)
dataku=data.frame(data)
y=dataku[,2]
t=dataku[,1]
NINO=dataku[,3]
SOI=dataku[,4]

#Model Stasioner 0
R5Dlogno0=gamlss(y~1,data=dataku,family=LOGNO,method=RS(),trace=FALSE)
R5Dgamma0=gamlss(y~1,data=dataku,family=GA,method=RS(),trace=FALSE)
R5Dgengam0=gamlss(y~1,data=dataku,family=GG,method=RS(),trace=FALSE)

#Model Non-Stasioner 1 cs
csR5Dlogno1_1=gamlss(y~cs(t),sigma.fo=~t,data=dataku,family=LOGNO,method=RS(),trace=FALSE)
csR5Dgamma1_1=gamlss(y~cs(t),sigma.fo=~t,data=dataku,family=GA,method=RS(),trace=FALSE)
csR5Dgengam1_1=gamlss(y~cs(t),sigma.fo=~t,data=dataku,family=GG,method=RS(),trace=FALSE)
csR5Dlogno1_2=gamlss(y~t,sigma.fo=~cs(t),data=dataku,family=LOGNO,method=RS(),trace=FALSE)
csR5Dgamma1_2=gamlss(y~t,sigma.fo=~cs(t),data=dataku,family=GA,method=RS(),trace=FALSE)
csR5Dgengam1_2=gamlss(y~t,sigma.fo=~cs(t),data=dataku,family=GG,method=RS(),trace=FALSE)

#Model Non-Stasioner 1 pb
pbR5Dlogno1_1=gamlss(y~pb(t),sigma.fo=~t,data=dataku,family=LOGNO,method=RS(),trace=FALSE)
pbR5Dgamma1_1=gamlss(y~pb(t),sigma.fo=~t,data=dataku,family=GA,method=RS(),trace=FALSE)
pbR5Dgengam1_1=gamlss(y~pb(t),sigma.fo=~t,data=dataku,family=GG,method=RS(),trace=FALSE)
pbR5Dlogno1_2=gamlss(y~t,sigma.fo=~pb(t),data=dataku,family=LOGNO,method=RS(),trace=FALSE)
pbR5Dgamma1_2=gamlss(y~t,sigma.fo=~pb(t),data=dataku,family=GA,method=RS(),trace=FALSE)
pbR5Dgengam1_2=gamlss(y~t,sigma.fo=~pb(t),data=dataku,family=GG,method=RS(),trace=FALSE)

#Model Non-Stasioner 2 cs
csR5Dlogno2_1=gamlss(y~NINO,sigma.fo=~cs(SOI),data=dataku,family=LOGNO,method=RS(),trace=FALSE)
csR5Dgamma2_1=gamlss(y~NINO,sigma.fo=~cs(SOI),data=dataku,family=GA,method=RS(),trace=FALSE)
```

Lampiran 10 Syntax Pemodelan Indeks Curah Hujan Ekstrem RX5day (Lanjutan)

```

csR5Dgengam2_1=gamlss(y~NINO,sigma.fo=~cs(SOI),data=dataku,family=GG,method=RS(),trace=FALSE)
csR5Dlogno2_2=gamlss(y~cs(NINO),sigma.fo=~SOI,data=dataku,family=LOGNO,method=RS(),trace=FALSE)
csR5Dgamma2_2=gamlss(y~cs(NINO),sigma.fo=~SOI,data=dataku,family=GA,method=RS(),trace=FALSE)
csR5Dgengam2_2=gamlss(y~cs(NINO),sigma.fo=~SOI,data=dataku,family=GG,method=RS(),trace=FALSE)
csR5Dlogno2_3=gamlss(y~SOI,sigma.fo=~cs(NINO),data=dataku,family=LOGNO,method=RS(),trace=FALSE)
csR5Dgamma2_3=gamlss(y~SOI,sigma.fo=~cs(NINO),data=dataku,family=GA,method=RS(),trace=FALSE)
csR5Dgengam2_3=gamlss(y~SOI,sigma.fo=~cs(NINO),data=dataku,family=GG,method=RS(),trace=FALSE)
csR5Dlogno2_4=gamlss(y~cs(SOI),sigma.fo=~NINO,data=dataku,family=LOGNO,method=RS(),trace=FALSE)
csR5Dgamma2_4=gamlss(y~cs(SOI),sigma.fo=~NINO,data=dataku,family=GA,method=RS(),trace=FALSE)
csR5Dgengam2_4=gamlss(y~cs(SOI),sigma.fo=~NINO,data=dataku,family=GG,method=RS(),trace=FALSE)
csR5Dlogno2_5=gamlss(y~cs(NINO),sigma.fo=~cs(SOI),data=dataku,family=LOGNO,method=RS(),trace=FALSE)
csR5Dgamma2_5=gamlss(y~cs(NINO),sigma.fo=~cs(SOI),data=dataku,family=GA,method=RS(),trace=FALSE)
csR5Dgengam2_5=gamlss(y~cs(NINO),sigma.fo=~cs(SOI),data=dataku,family=GG,method=RS(),trace=FALSE)
csR5Dlogno2_6=gamlss(y~cs(SOI),sigma.fo=~cs(NINO),data=dataku,family=LOGNO,method=RS(),trace=FALSE)
csR5Dgamma2_6=gamlss(y~cs(SOI),sigma.fo=~cs(NINO),data=dataku,family=GA,method=RS(),trace=FALSE)
csR5Dgengam2_6=gamlss(y~cs(SOI),sigma.fo=~cs(NINO),data=dataku,family=GG,method=RS(),trace=FALSE)
csR5Dlogno2_7=gamlss(y~cs(SOI)+cs(NINO),sigma.fo=~t,data=dataku,family=LOGNO,method=RS(),trace=FALSE)
csR5Dgamma2_7=gamlss(y~cs(SOI)+cs(NINO),sigma.fo=~t,data=dataku,family=GA,method=RS(),trace=FALSE)
csR5Dgengam2_7=gamlss(y~cs(SOI)+cs(NINO),sigma.fo=~t,data=dataku,family=GG,method=RS(),trace=FALSE)
csR5Dlogno2_8=gamlss(y~SOI+NINO,sigma.fo=~cs(t),data=dataku,family=LOGNO,method=RS(),trace=FALSE)
csR5Dgamma2_8=gamlss(y~SOI+NINO,sigma.fo=~cs(t),data=dataku,family=GA,method=RS(),trace=FALSE)
csR5Dgengam2_8=gamlss(y~SOI+NINO,sigma.fo=~cs(t),data=dataku,family=GG,method=RS(),trace=FALSE)

#Model Non-Stasioner 2 pb
pbR5Dlogno2_1=gamlss(y~NINO,sigma.fo=~pb(SOI),data=dataku,family=LOGNO,method=RS(),trace=FALSE)

```

Lampiran 10 Syntax Pemodelan Indeks Curah Hujan Ekstrem RX5day (Lanjutan)

```
pbR5Dgamma2_1=gamlss(y~NINO,sigma.fo=~pb(SOI),data=dataku,family=GA,method=RS(),trace=FALSE)
pbR5Dgengam2_1=gamlss(y~NINO,sigma.fo=~pb(SOI),data=dataku,family=GG,method=RS(),trace=FALSE)
pbR5Dlogno2_2=gamlss(y~pb(NINO),sigma.fo=~SOI,data=dataku,family=LOGNO,method=RS(),trace=FALSE)
pbR5Dgamma2_2=gamlss(y~pb(NINO),sigma.fo=~SOI,data=dataku,family=GA,method=RS(),trace=FALSE)
pbR5Dgengam2_2=gamlss(y~pb(NINO),sigma.fo=~SOI,data=dataku,family=GG,method=RS(),trace=FALSE)
pbR5Dlogno2_3=gamlss(y~SOI,sigma.fo=~pb(NINO),data=dataku,family=LOGNO,method=RS(),trace=FALSE)
pbR5Dgamma2_3=gamlss(y~SOI,sigma.fo=~pb(NINO),data=dataku,family=GA,method=RS(),trace=FALSE)
pbR5Dgengam2_3=gamlss(y~SOI,sigma.fo=~pb(NINO),data=dataku,family=GG,method=RS(),trace=FALSE)
pbR5Dlogno2_4=gamlss(y~pb(SOI),sigma.fo=~NINO,data=dataku,family=LOGNO,method=RS(),trace=FALSE)
pbR5Dgamma2_4=gamlss(y~pb(SOI),sigma.fo=~NINO,data=dataku,family=GA,method=RS(),trace=FALSE)
pbR5Dgengam2_4=gamlss(y~pb(SOI),sigma.fo=~NINO,data=dataku,family=GG,method=RS(),trace=FALSE)
pbR5Dlogno2_5=gamlss(y~pb(NINO),sigma.fo=~pb(SOI),data=dataku,family=LOGNO,method=RS(),trace=FALSE)
pbR5Dgamma2_5=gamlss(y~pb(NINO),sigma.fo=~pb(SOI),data=dataku,family=GA,method=RS(),trace=FALSE)
pbR5Dgengam2_5=gamlss(y~pb(NINO),sigma.fo=~pb(SOI),data=dataku,family=GG,method=RS(),trace=FALSE)
pbR5Dlogno2_6=gamlss(y~pb(SOI),sigma.fo=~pb(NINO),data=dataku,family=LOGNO,method=RS(),trace=FALSE)
pbR5Dgamma2_6=gamlss(y~pb(SOI),sigma.fo=~pb(NINO),data=dataku,family=GA,method=RS(),trace=FALSE)
pbR5Dgengam2_6=gamlss(y~pb(SOI),sigma.fo=~pb(NINO),data=dataku,family=GG,method=RS(),trace=FALSE)
pbR5Dlogno2_7=gamlss(y~pb(SOI)+pb(NINO),sigma.fo=~t,data=dataku,family=LOGNO,method=RS(),trace=FALSE)
pbR5Dgamma2_7=gamlss(y~pb(SOI)+pb(NINO),sigma.fo=~t,data=dataku,family=GA,method=RS(),trace=FALSE)
pbR5Dgengam2_7=gamlss(y~pb(SOI)+pb(NINO),sigma.fo=~t,data=dataku,family=GG,method=RS(),trace=FALSE)
pbR5Dlogno2_8=gamlss(y~SOI+NINO,sigma.fo=~pb(t),data=dataku,family=LOGNO,method=RS(),trace=FALSE)
pbR5Dgamma2_8=gamlss(y~SOI+NINO,sigma.fo=~pb(t),data=dataku,family=GA,method=RS(),trace=FALSE)
pbR5Dgengam2_8=gamlss(y~SOI+NINO,sigma.fo=~pb(t),data=dataku,family=GG,method=RS(),trace=FALSE)
```

Lampiran 10 Syntax Pemodelan Indeks Curah Hujan Ekstrem RX5day (Lanjutan)

```
#GAIC
model0=GAIC(R5Dlogno0,R5Dgamma0,R5Dgengam0,k=log(length(y)))
model1cs=GAIC(csR5Dlogno1_1,csR5Dgamma1_1,csR5Dgengam1_1,csR5Dlogno1_2,csR5Dg
mma1_2,csR5Dgengam1_2,k=log(length(y)))
model1pb=GAIC(pbR5Dlogno1_1,pbR5Dgamma1_1,pbR5Dgengam1_1,pbR5Dlogno1_2,pbR5D
gamma1_2,pbR5Dgengam1_2,k=log(length(y)))
model2cs=GAIC(csR5Dlogno2_1,csR5Dgamma2_1,csR5Dgengam2_1,
csR5Dlogno2_2,csR5Dgamma2_2,csR5Dgengam2_2,csR5Dlogno2_3,csR5Dgamma2_3,csR5Dge
ngam2_3,csR5Dlogno2_4,csR5Dgamma2_4,csR5Dgengam2_4,csR5Dlogno2_5,csR5Dgamma2_5
,csR5Dgengam2_5,csR5Dlogno2_6,csR5Dgamma2_6,csR5Dgengam2_6,csR5Dlogno2_7,csR5D
gamma2_7,csR5Dgengam2_7, csR5Dlogno2_8,csR5Dgamma2_8,csR5Dgengam2_8,
k=log(length(y)))
model2pb=GAIC(pbR5Dlogno2_1,pbR5Dgamma2_1,pbR5Dgengam2_1,
pbR5Dlogno2_2,pbR5Dgamma2_2,pbR5Dgengam2_2,pbR5Dlogno2_3,pbR5Dgamma2_3,pbR5
Dgengam2_3,pbR5Dlogno2_4,pbR5Dgamma2_4,pbR5Dgengam2_4,pbR5Dlogno2_5,pbR5Dgam
ma2_5,pbR5Dgengam2_5,pbR5Dlogno2_6,pbR5Dgamma2_6,pbR5Dgengam2_6,pbR5Dlogno2_
7,pbR5Dgamma2_7,pbR5Dgengam2_7,pbR5Dlogno2_8,pbR5Dgamma2_8,pbR5Dgengam2_8,k=
log(length(y)))
list(model0=model0, model1cs=model1cs, model1pb=model1pb, model2cs=model2cs,
model2pb=model2pb)
```

Lampiran 11 Syntax Pemodelan Indeks Curah Hujan Ekstrem CDD

```
#Model Stasioner 0
CDDGP0=gamlss(CDD~1,data=dataku,family=GPO,method=RS(),trace=FALSE)
CDDNB0=gamlss(CDD~1,data=dataku,family=NBI,method=RS(),trace=FALSE)
CDDPIG0=gamlss(CDD~1,data=dataku,family=PIG,method=RS(),trace=FALSE)

#Model Non-Stasioner 1 cs
csCDDGP1_1=gamlss(CDD~cs(t),sigma.fo=~t,data=dataku,family=GPO,method=RS(),trace=FA
LSE)
csCDDNB1_1=gamlss(CDD~cs(t),sigma.fo=~t,data=dataku,family=NBI,method=RS(),trace=FAL
SE)
csCDDPIG1_1=gamlss(CDD~cs(t),sigma.fo=~t,data=dataku,family=PIG,method=RS(),trace=FA
LSE)
csCDDGP1_2=gamlss(CDD~t,sigma.fo=~cs(t),data=dataku,family=GPO,method=RS(),trace=FA
LSE)
csCDDNB1_2=gamlss(CDD~t,sigma.fo=~cs(t),data=dataku,family=NBI,method=RS(),trace=FAL
SE)
csCDDPIG1_2=gamlss(CDD~t,sigma.fo=~cs(t),data=dataku,family=PIG,method=RS(),trace=FA
LSE)

#Model Non-Stasioner 1 pb
pbCDDGP1_1=gamlss(CDD~pb(t),sigma.fo=~t,data=dataku,family=GPO,method=RS(),trace=FA
LSE)
pbCDDNB1_1=gamlss(CDD~pb(t),sigma.fo=~t,data=dataku,family=NBI,method=RS(),trace=FAL
SE)
```

Lampiran 11 Syntax Pemodelan Indeks Curah Hujan Ekstrem CDD (Lanjutan)

```
pbCDDPIG1_1=gamlss(CDD~pb(t),sigma.fo=~t,data=dataku,family=PIG,method=RS(),trace=FALSE)
pbCDDGP1_2=gamlss(CDD~t,sigma.fo=~pb(t),data=dataku,family=GPO,method=RS(),trace=FALSE)
pbCDDNB1_2=gamlss(CDD~t,sigma.fo=~pb(t),data=dataku,family=NBI,method=RS(),trace=FALSE)
pbCDDPIG1_2=gamlss(CDD~t,sigma.fo=~pb(t),data=dataku,family=PIG,method=RS(),trace=FALSE)

#Model Non-Stasioner 2 cs
csCDDGP2_1=gamlss(CDD~NINO,sigma.fo=~cs(SOI),data=dataku,family=GPO,method=RS(),trace=FALSE)
csCDDNB2_1=gamlss(CDD~NINO,sigma.fo=~cs(SOI),data=dataku,family=NBI,method=RS(),trace=FALSE)
csCDDPIG2_1=gamlss(CDD~NINO,sigma.fo=~cs(SOI),data=dataku,family=PIG,method=RS(),trace=FALSE)
csCDDGP2_2=gamlss(CDD~cs(NINO),sigma.fo=~SOI,data=dataku,family=GPO,method=RS(),trace=FALSE)
csCDDNB2_2=gamlss(CDD~cs(NINO),sigma.fo=~SOI,data=dataku,family=NBI,method=RS(),trace=FALSE)
csCDDPIG2_2=gamlss(CDD~cs(NINO),sigma.fo=~SOI,data=dataku,family=PIG,method=RS(),trace=FALSE)
csCDDGP2_3=gamlss(CDD~SOI,sigma.fo=~cs(NINO),data=dataku,family=GPO,method=RS(),trace=FALSE)
csCDDNB2_3=gamlss(CDD~SOI,sigma.fo=~cs(NINO),data=dataku,family=NBI,method=RS(),trace=FALSE)
csCDDPIG2_3=gamlss(CDD~SOI,sigma.fo=~cs(NINO),data=dataku,family=PIG,method=RS(),trace=FALSE)
csCDDGP2_4=gamlss(CDD~cs(SOI),sigma.fo=~NINO,data=dataku,family=GPO,method=RS(),trace=FALSE)
csCDDNB2_4=gamlss(CDD~cs(SOI),sigma.fo=~NINO,data=dataku,family=NBI,method=RS(),trace=FALSE)
csCDDPIG2_4=gamlss(CDD~cs(SOI),sigma.fo=~NINO,data=dataku,family=PIG,method=RS(),trace=FALSE)
csCDDGP2_5=gamlss(CDD~cs(NINO),sigma.fo=~cs(SOI),data=dataku,family=GPO,method=RS(),trace=FALSE)
csCDDNB2_5=gamlss(CDD~cs(NINO),sigma.fo=~cs(SOI),data=dataku,family=NBI,method=RS(),trace=FALSE)
csCDDPIG2_5=gamlss(CDD~cs(NINO),sigma.fo=~cs(SOI),data=dataku,family=PIG,method=RS(),trace=FALSE)
csCDDGP2_6=gamlss(CDD~cs(SOI),sigma.fo=~cs(NINO),data=dataku,family=GPO,method=RS(),trace=FALSE)
csCDDNB2_6=gamlss(CDD~cs(SOI),sigma.fo=~cs(NINO),data=dataku,family=NBI,method=RS(),trace=FALSE)
csCDDPIG2_6=gamlss(CDD~cs(SOI),sigma.fo=~cs(NINO),data=dataku,family=PIG,method=RS(),trace=FALSE)
csCDDGP2_7=gamlss(CDD~cs(SOI)+cs(NINO),sigma.fo=~t,data=dataku,family=GPO,method=RS(),trace=FALSE)
```

Lampiran 11 Syntax Pemodelan Indeks Curah Hujan Ekstrem CDD (Lanjutan)

```
csCDDNB2_7=gamlss(CDD~cs(SOI)+cs(NINO),sigma.fo=~t,data=dataku,family=NBI,method=RS(),trace=FALSE)
csCDDPIG2_7=gamlss(CDD~cs(SOI)+cs(NINO),sigma.fo=~t,data=dataku,family=PIG,method=RS(),trace=FALSE)
csCDDGP2_8=gamlss(CDD~SOI+NINO,sigma.fo=~cs(t),data=dataku,family=GPO,method=RS(),trace=FALSE)
csCDDNB2_8=gamlss(CDD~SOI+NINO,sigma.fo=~cs(t),data=dataku,family=NBI,method=RS(),trace=FALSE)
csCDDPIG2_8=gamlss(CDD~SOI+NINO,sigma.fo=~cs(t),data=dataku,family=PIG,method=RS(),trace=FALSE)

#Model Non-Stasioner 2 pb
pbCDDGP2_1=gamlss(CDD~NINO,sigma.fo=~pb(SOI),data=dataku,family=GPO,method=RS(),t
race=FALSE)
pbCDDNB2_1=gamlss(CDD~NINO,sigma.fo=~pb(SOI),data=dataku,family=NBI,method=RS(),t
race=FALSE)
pbCDDPIG2_1=gamlss(CDD~NINO,sigma.fo=~pb(SOI),data=dataku,family=PIG,method=RS(),t
race=FALSE)
pbCDDGP2_2=gamlss(CDD~pb(NINO),sigma.fo=~SOI,data=dataku,family=GPO,method=RS(),t
race=FALSE)
pbCDDNB2_2=gamlss(CDD~pb(NINO),sigma.fo=~SOI,data=dataku,family=NBI,method=RS(),t
race=FALSE)
pbCDDPIG2_2=gamlss(CDD~pb(NINO),sigma.fo=~SOI,data=dataku,family=PIG,method=RS(),t
race=FALSE)
pbCDDGP2_3=gamlss(CDD~SOI,sigma.fo=~pb(NINO),data=dataku,family=GPO,method=RS(),t
race=FALSE)
pbCDDNB2_3=gamlss(CDD~SOI,sigma.fo=~pb(NINO),data=dataku,family=NBI,method=RS(),t
race=FALSE)
pbCDDPIG2_3=gamlss(CDD~SOI,sigma.fo=~pb(NINO),data=dataku,family=PIG,method=RS(),t
race=FALSE)
pbCDDGP2_4=gamlss(CDD~pb(SOI),sigma.fo=~NINO,data=dataku,family=GPO,method=RS(),t
race=FALSE)
pbCDDNB2_4=gamlss(CDD~pb(SOI),sigma.fo=~NINO,data=dataku,family=NBI,method=RS(),t
race=FALSE)
pbCDDPIG2_4=gamlss(CDD~pb(SOI),sigma.fo=~NINO,data=dataku,family=PIG,method=RS(),t
race=FALSE)
pbCDDGP2_5=gamlss(CDD~pb(NINO),sigma.fo=~pb(SOI),data=dataku,family=GPO,method=R
S(),trace=FALSE)
pbCDDNB2_5=gamlss(CDD~pb(NINO),sigma.fo=~pb(SOI),data=dataku,family=NBI,method=R
S(),trace=FALSE)
pbCDDPIG2_5=gamlss(CDD~pb(NINO),sigma.fo=~pb(SOI),data=dataku,family=PIG,method=R
S(),trace=FALSE)
pbCDDGP2_6=gamlss(CDD~pb(SOI),sigma.fo=~pb(NINO),data=dataku,family=GPO,method=R
S(),trace=FALSE)
pbCDDNB2_6=gamlss(CDD~pb(SOI),sigma.fo=~pb(NINO),data=dataku,family=NBI,method=R
S(),trace=FALSE)
pbCDDPIG2_6=gamlss(CDD~pb(SOI),sigma.fo=~pb(NINO),data=dataku,family=PIG,method=R
S(),trace=FALSE)
```

Lampiran 11 Syntax Pemodelan Indeks Curah Hujan Ekstrem CDD (Lanjutan)

```

pbCDDGP2_7=gamlss(CDD~pb(SOI)+pb(NINO),sigma.fo=~t,data=dataku,family=GPO,method=RS(),trace=FALSE)
pbCDDNB2_7=gamlss(CDD~pb(SOI)+pb(NINO),sigma.fo=~t,data=dataku,family=NBI,method=RS(),trace=FALSE)
pbCDDPIG2_7=gamlss(CDD~pb(SOI)+pb(NINO),sigma.fo=~t,data=dataku,family=PIG,method=RS(),trace=FALSE)
pbCDDGP2_8=gamlss(CDD~SOI+NINO,sigma.fo=~pb(t),data=dataku,family=GPO,method=RS(),trace=FALSE)
pbCDDNB2_8=gamlss(CDD~SOI+NINO,sigma.fo=~pb(t),data=dataku,family=NBI,method=RS(),trace=FALSE)
pbCDDPIG2_8=gamlss(CDD~SOI+NINO,sigma.fo=~pb(t),data=dataku,family=PIG,method=RS(),trace=FALSE)

#GAIC
model0=GAIC(CDDGP0,CDDNB0,CDDPIG0,k=log(length(y)))
model1cs=GAIC(csCDDGP1_1,csCDDNB1_1,csCDDPIG1_1,csCDDGP1_2,csCDDNB1_2,csCDDPIG1_2,k=log(length(y)))
model1pb=GAIC(pbCDDGP1_1,pbCDDNB1_1,pbCDDPIG1_1,pbCDDGP1_2,pbCDDNB1_2,pbCDDPIG1_2,k=log(length(y)))
model2cs=GAIC(csCDDGP2_1,csCDDNB2_1,csCDDPIG2_1,csCDDGP2_2,csCDDNB2_2,csCDDPIG2_2,csCDDGP2_3,csCDDNB2_3,csCDDPIG2_3,csCDDGP2_4,csCDDNB2_4,csCDDPIG2_4,csCDDGP2_5,csCDDNB2_5,csCDDPIG2_5,csCDDGP2_6,csCDDNB2_6,csCDDPIG2_6,csCDDGP2_7,csCDDNB2_7,csCDDPIG2_7,csCDDGP2_8,csCDDNB2_8,csCDDPIG2_8,k=log(length(y)))
model2pb=GAIC(pbCDDGP2_1,pbCDDNB2_1,pbCDDPIG2_1,pbCDDGP2_2,pbCDDNB2_2,pbCDDPIG2_2,pbCDDGP2_3,pbCDDNB2_3,pbCDDPIG2_3,pbCDDGP2_4,pbCDDNB2_4,pbCDDPIG2_4,pbCDDGP2_5,pbCDDNB2_5,pbCDDPIG2_5,pbCDDGP2_6,pbCDDNB2_6,pbCDDPIG2_6,pbCDDGP2_7,pbCDDNB2_7,pbCDDPIG2_7,pbCDDGP2_8,pbCDDNB2_8,pbCDDPIG2_8,k=log(length(y)))

list(model0=model0,model1cs=model1cs,model1pb=model1pb,model2cs=model2cs,
model2pb=model2pb)

```

Lampiran 12 Hasil Pemodelan RX5day di Stasiun Komodo

```

$model0
      df      AIC
R5Dgengam0 3 238.0809
R5Dlogno0  2 238.2448
R5Dgamma0  2 241.4096

$model1cs
      df      AIC
csR5Dlogno1_2 6.999304 249.1238
csR5Dlogno1_1 6.999471 249.6370
csR5Dgamma1_1 6.999473 251.1255
csR5Dgamma1_2 6.999471 251.4711

$model1pb
      df      AIC
pbR5Dlogno1_2 4.000012 242.7642
pbR5Dlogno1_1 4.000032 242.7642

```

Lampiran 12 Hasil Pemodelan RX5day di Stasiun Komodo (Lanjutan)

```

pbR5Dgengam1_2 5.000014 243.6084
pbR5Dgengam1_1 5.000046 243.6085
pbR5Dgamma1_2 4.000014 244.9542
pbR5Dgamma1_1 4.000031 244.9543

$mode12cs
      df      AIC
CSR5Dlogno2_2 7.000666 246.7812
CSR5Dlogno2_4 7.000526 247.3070
CSR5Dlogno2_3 6.999405 248.5010
CSR5Dgamma2_2 7.000672 248.5219
CSR5Dgengam2_8 8.999480 248.7724
CSR5Dlogno2_8 7.999304 249.2628
CSR5Dlogno2_7 10.999693 249.5956
CSR5Dlogno2_1 7.000468 250.1931
CSR5Dgengam2_1 8.000531 250.5541
CSR5Dgamma2_4 7.000526 250.7792
CSR5Dgamma2_3 6.999380 251.6631
CSR5Dgamma2_7 10.999717 252.0291
CSR5Dgamma2_8 7.999472 253.3494
CSR5Dlogno2_5 10.001098 253.3938
CSR5Dgamma2_1 7.000466 253.4540
CSR5Dgamma2_5 9.999832 254.7969

$mode12pb
      df      AIC
pbR5Dgengam2_3 5.000014 242.4859
pbR5Dlogno2_7 6.446709 242.6278
pbR5Dgengam2_1 5.000012 243.3284
pbR5Dgengam2_2 5.000054 243.3285
pbR5Dgengam2_5 5.000066 243.3285
pbR5Dlogno2_4 4.687581 243.8013
pbR5Dlogno2_6 4.687595 243.8014
pbR5Dlogno2_3 4.000010 243.8657
pbR5Dlogno2_1 4.000009 243.9779
pbR5Dlogno2_2 4.000030 243.9779
pbR5Dlogno2_5 4.000039 243.9780
pbR5Dgengam2_7 7.662062 244.0913
pbR5Dlogno2_8 5.000010 245.0174
pbR5Dgamma2_7 6.101187 245.3058
pbR5Dgamma2_4 4.000024 247.0840
pbR5Dgamma2_6 4.000035 247.0840
pbR5Dgamma2_3 4.000011 247.0840
pbR5Dgamma2_1 4.000010 247.1819
pbR5Dgamma2_2 4.000027 247.1820
pbR5Dgamma2_5 4.000036 247.1820
pbR5Dgamma2_8 5.000014 247.6728

> summary(R5Dgengam0)
Family: c("GG", "generalised Gamma Lopatatsidis-Green")

Call: gamlss(formula = y ~ 1, family = GG, data = dataku,
method = RS(), trace = FALSE)                         m

Fitting method: RS()

Mu link function: log
Mu Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) 4.7941     0.1215   39.47 <2e-16 ***
---
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

Lampiran 12 Hasil Pemodelan RX5day di Stasiun Komodo (Lanjutan)

```

Sigma link function: log
Sigma Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) -1.0952    0.2058 -5.322 4.65e-05 ***
---
Signif. codes:  0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1
-----
-
Nu link function: identity
Nu Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) -2.907    2.045 -1.422   0.172
-----
-
No. of observations in the fit: 21
Degrees of Freedom for the fit: 3
      Residual Deg. of Freedom: 18
                           at cycle: 14
Global Deviance: 228.9474
AIC: 234.9474
SBC: 238.0809
*****


```

Lampiran 13 Hasil Pemodelan RX5day di Stasiun Frans

```

$model0
df      AIC
R5Dlogno0 2 254.0067
R5Dgamma0 2 255.3509

$model1cs
df      AIC
cSR5Dlogno1_2 6.999304 258.5038
cSR5Dgamma1_2 6.999471 259.2408
cSR5Dgengam1_2 7.999470 261.4257
cSR5Dlogno1_1 6.999470 266.1149
cSR5Dgamma1_1 6.999299 267.0300

$model1pb
df      AIC
pBR5Dlogno1_1 4.000054 259.1570
pBR5Dgamma1_1 4.000053 260.3853

```

Lampiran 13 Hasil Pemodelan RX5day di Stasiun Frans (Lanjutan)

```
$model2cs
      df      AIC
CSR5Dgamma2_3  6.999360 256.1046
CSR5Dgengam2_3 7.999388 258.1869
CSR5Dlogno2_8  7.999304 262.4503
CSR5Dgengam2_8 8.999473 264.3790
CSR5Dgamma2_8  7.999471 264.5751
CSR5Dlogno2_4  6.999321 264.8593
CSR5Dgamma2_4  6.999305 265.0296
CSR5Dlogno2_1  7.000468 265.8684
CSR5Dgamma2_1  7.000460 266.5310
CSR5Dlogno2_2  6.999350 266.7161
CSR5Dgamma2_2  7.000451 268.1090
CSR5Dgengam2_1 8.000441 268.4924
CSR5Dlogno2_7  10.999003 273.3948
CSR5Dgamma2_7  11.000034 274.6728

$model2pb
      df      AIC
pbr5Dlogno2_1  4.000011 259.3199
pbr5Dlogno2_2  4.000047 259.3200
pbr5Dlogno2_5  4.000058 259.3201
pbr5Dlogno2_4  4.000044 259.7991
pbr5Dgamma2_1  4.000011 260.6881
pbr5Dgamma2_2  4.000044 260.6882
pbr5Dgamma2_5  4.000055 260.6882
pbr5Dgamma2_4  4.000043 260.7290
pbr5Dlogno2_7  5.000116 261.2979
pbr5Dlogno2_8  7.514935 261.8250
pbr5Dgamma2_7  5.000112 262.6924
pbr5Dgamma2_8  6.840038 262.8432
pbr5Dgengam2_7 6.000142 263.0939

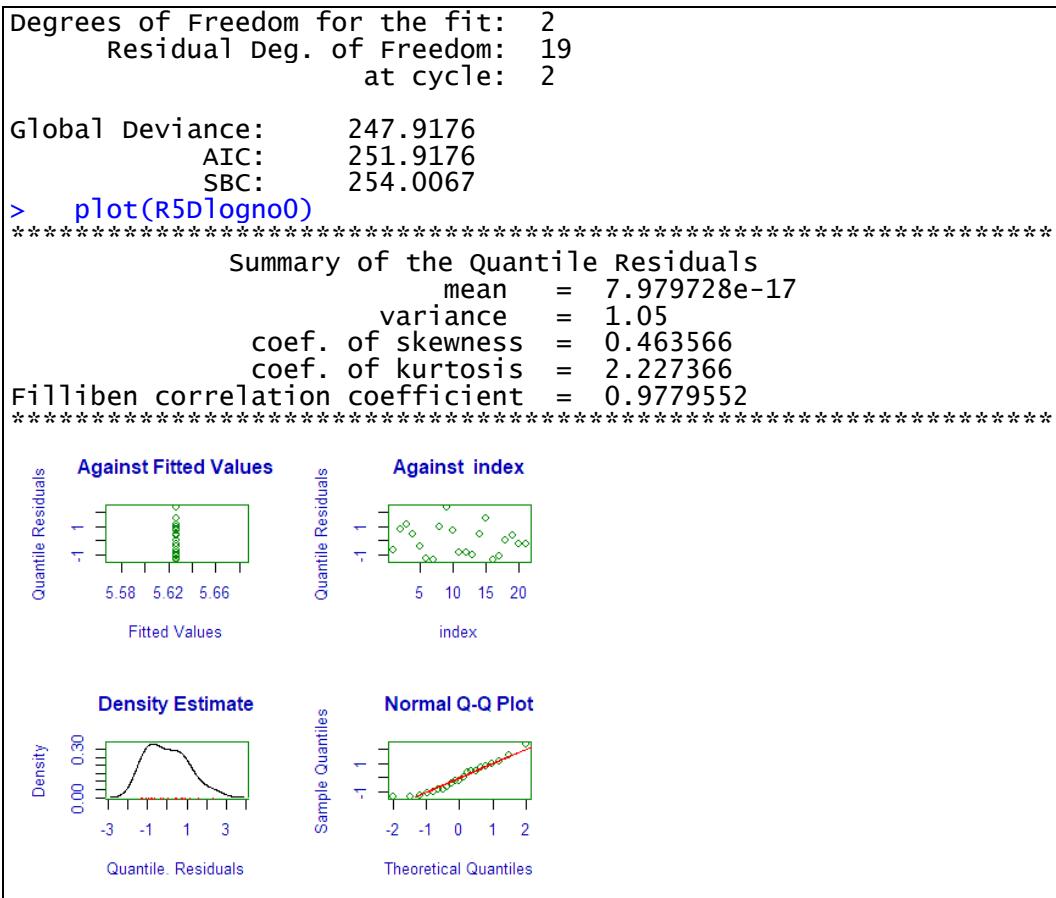
> summary(R5Dlogno0)
*****
*
Family: c("LOGNO", "Log Normal")
Call: gamlss(formula = y ~ 1, family = LOGNO, data = dataku,
method = RS(), trace = FALSE)
Fitting method: RS()

-----
-
Mu link function: identity
Mu Coefficients:
  Estimate Std. Error t value Pr(>|t|)
(Intercept) 5.62704   0.06957 80.88 <2e-16 ***
---
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

-----
-
Sigma link function: log
Sigma Coefficients:
  Estimate Std. Error t value Pr(>|t|)
(Intercept) -1.1432    0.1543 -7.409 5.14e-07 ***
---
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

-----
No. of observations in the fit: 21
```

Lampiran 13 Hasil Pemodelan RX5day di Stasiun Frans (Lanjutan)



Lampiran 14 Hasil Pemodelan RX5day di Stasiun Fransiskus

```
$model0
      df      AIC
R5Dlogno0 2 216.5016
R5Dgamma0 2 216.7089
R5Dgengam0 3 219.5447

$model1cs
      df      AIC
cSR5Dlogno1_1 6.999320 217.6695
cSR5Dgengam1_1 7.999488 217.7694
cSR5Dgamma1_1 6.999324 218.4898
cSR5Dlogno1_2 6.999304 221.1922
cSR5Dgamma1_2 6.999301 221.5244
cSR5Dgengam1_2 7.999304 224.2778

$model1pb
      df      AIC
pbR5Dlogno1_1 5.070073 216.7641
pbR5Dgamma1_1 4.955707 217.3277
pbR5Dlogno1_2 4.000018 218.1893
pbR5Dgamma1_2 4.000020 218.5782
pbR5Dgengam1_2 5.000017 220.9683

$model2cs
      df      AIC
cSR5Dgamma2_8 7.999313 203.2177
```

Lampiran 14 Hasil Pemodelan RX5day di Stasiun Fransiskus (Lanjutan)

```

CSR5Dlogno2_8    7.999304 203.6319
CSR5Dgengam2_8   8.999334 206.1528
CSR5Dgamma2_7   11.001029 215.5392
CSR5Dlogno2_7   11.000995 216.3104
CSR5Dlogno2_4   7.000527 224.9409
CSR5Dgamma2_4   7.000520 225.2450
CSR5Dgamma2_1   6.999468 225.9996
CSR5Dlogno2_1   7.000468 226.1594
CSR5Dlogno2_3   6.999405 226.8822
CSR5Dgamma2_2   7.000652 227.0478
CSR5Dgamma2_3   6.999435 227.2574
CSR5Dlogno2_2   7.000652 227.6819
CSR5Dgengam2_4   8.000525 227.8211
CSR5Dgengam2_1   7.999466 229.0400
CSR5Dgamma2_5   9.998815 232.0343
CSR5Dlogno2_5   9.999830 232.4443
CSR5Dgengam2_5  10.999871 234.9698

$mode12pb
              df      AIC
pbr5Dgamma2_8  8.365035 203.9316
pbr5Dlogno2_8  8.283025 204.1740
pbr5Dgengam2_8 9.445861 207.0421
pbr5Dgamma2_7  5.695624 209.4924
pbr5Dlogno2_7  5.632982 210.0718
pbr5Dgamma2_2  4.000109 219.7545
pbr5Dlogno2_2  4.000107 219.9097
pbr5Dgamma2_1  4.574626 220.0063
pbr5Dgamma2_5  4.574718 220.0066
pbr5Dlogno2_1  4.560798 220.1753
pbr5Dlogno2_5  4.560888 220.1755
pbr5Dlogno2_4  4.411747 220.6221
pbr5Dlogno2_6  4.411759 220.6221
pbr5Dgamma2_4  4.000082 221.1123
pbr5Dgamma2_6  4.000096 221.1123
pbr5Dgengam2_2 5.000109 222.7993
pbr5Dgengam2_1 5.573360 223.0420
pbr5Dgengam2_5 5.573452 223.0423
pbr5Dgengam2_4 5.621784 223.0529
pbr5Dgengam2_6 5.621799 223.0530

> summary(csr5Dgamma2_8)
*****
*
Family: c("GA", "Gamma")
Call: gamlss(formula = y ~ SOI + NINO, sigma.formula = ~cs(t),
family = GA, data = dataku, method = RS(), trace = FALSE)
Fitting method: RS()

-----
-
Mu link function: log
Mu Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) 14.09192   1.19382 11.804 2.54e-08 ***
SOI        -0.23399   0.02291 -10.213 1.41e-07 ***
NINO       -0.33977   0.04471  -7.599 3.91e-06 ***
---
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
-----
```

Lampiran 14 Hasil Pemodelan RX5day di Stasiun Fransiskus (Lanjutan)

```

Sigma link function: log
Sigma Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) -2.66249 0.32474 -8.199 1.71e-06 ***
cs(t) 0.04959 0.02592 1.913 0.078 .
---
Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

-----
-
NOTE: Additive smoothing terms exist in the formulas:
i) Std. Error for smoothers are for the linear effect only.
ii) Std. Error for the linear terms maybe are not accurate.

-
No. of observations in the fit: 21
Degrees of Freedom for the fit: 7.999313
Residual Deg. of Freedom: 13.00069
at cycle: 10

Global Deviance: 178.8636
AIC: 194.8623
SBC: 203.2177
> plot(csR5Dgamma2_8)
*****
```

Summary of the Quantile Residuals

mean = -0.0378094
variance = 1.04769
coef. of skewness = -0.07618583
coef. of kurtosis = 1.471987
Filliben correlation coefficient = 0.9647679

Against Fitted Values

Against index

Density Estimate

Normal Q-Q Plot

Lampiran 15 Hasil Pemodelan RX5day di Stasiun Gewayantana

```

$model0
      df      AIC
R5Dgamma0 2 257.8682
R5Dlogn0 2 268.5182

$model1cs
      df      AIC
CSR5Dgamma1_1 7.000645 261.0473
CSR5Dlogn01_1 7.000629 265.4173
```

Lampiran 15 Hasil Pemodelan RX5day di Stasiun Gewayantana (Lanjutan)

```
$model1pb
      df      AIC
pbR5Dgamma1_2 4.000012 255.9012
pbR5Dgamma1_1 4.912092 256.1719
pbR5Dlogno1_1 4.798620 261.3282
pbR5Dlogno1_2 4.000010 261.7385

$model12cs
      df      AIC
CSR5Dgamma2_3 7.000609 241.8559
CSR5Dlogno2_3 6.999405 242.7369
CSR5Dgengam2_3 7.999510 245.7971
CSR5Dgamma2_8 7.999472 251.6998
CSR5Dgamma2_1 7.000709 251.8421
CSR5Dgamma2_7 11.000711 253.7764
CSR5Dlogno2_8 7.999304 254.1498
CSR5Dlogno2_7 11.001106 257.1628
CSR5Dgamma2_4 7.000615 262.1404
CSR5Dgamma2_2 6.999392 265.2062
CSR5Dlogno2_4 7.000634 265.4854
CSR5Dlogno2_2 6.999362 270.5707

$model12pb
      df      AIC
pbR5Dgamma2_8 5.000012 250.3199
pbR5Dgamma2_7 5.000163 250.3203
pbR5Dlogno2_8 5.000010 255.6338
pbR5Dlogno2_7 5.000127 255.6341
pbR5Dgamma2_3 4.000012 256.0743
pbR5Dgamma2_4 4.000027 256.0744
pbR5Dgamma2_6 4.000039 256.0744
pbR5Dgamma2_1 4.000010 258.0676
pbR5Dgamma2_2 4.000019 258.0676
pbR5Dgamma2_5 4.000029 258.0676
pbR5Dlogno2_3 4.000010 261.1310
pbR5Dlogno2_4 4.000017 261.1311
pbR5Dlogno2_6 4.000027 261.1311
pbR5Dlogno2_2 4.000008 264.1581
pbR5Dlogno2_1 4.000009 264.1581
pbR5Dlogno2_5 4.000017 264.1581

> summary(csR5Dgamma2_3)
*****
*
Family: c("GA", "Gamma")
Call: gamlss(formula = y ~ SOI, sigma.formula = ~cs(NINO), family = GA,
  data = dataku, method = RS(), trace = FALSE)
Fitting method: RS()

-----
-
Mu link function: log
Mu Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) 5.06866 0.03788 133.804 < 2e-16 ***
SOI         0.09460 0.01457   6.493 3.2e-06 ***
---
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Lampiran 15 Hasil Pemodelan RX5day di Stasiun Gewayantana (Lanjutan)

```

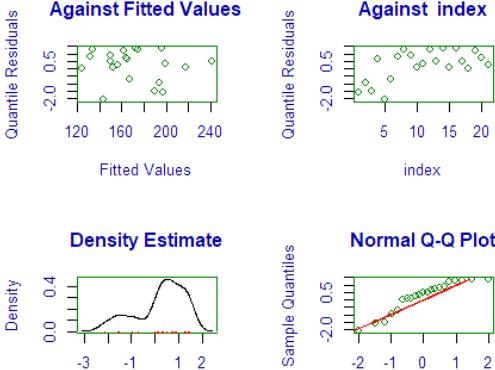
Sigma link function: log
Sigma Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) 17.5138    3.7583   4.660 0.000261 ***
cs(NINO)    -0.7076    0.1419  -4.988 0.000134 ***
---
Signif. codes:  0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

-
NOTE: Additive smoothing terms exist in the formulas:
i) Std. Error for smoothers are for the linear effect only.
ii) Std. Error for the linear terms may not be reliable.

-
No. of observations in the fit: 21
Degrees of Freedom for the fit: 7.000609
      Residual Deg. of Freedom: 13.99939
                                at cycle: 11

Global Deviance: 220.5424
      AIC: 234.5436
      SBC: 241.8559
> plot(csR5Dgamma2_3)
*****  

Summary of the Quantile Residuals
      mean = 0.2217496
      variance = 1.080785
      coef. of skewness = -0.788625
      coef. of kurtosis = 2.438633
Filliben correlation coefficient = 0.9506663
*****  



```

Lampiran 16 Hasil Pemodelan RX5day di Stasiun Umbu

```

$model0
      df      AIC
R5Dgamma0 2 221.8467
R5Dlogno0 2 223.1666
R5Dgengam0 3 224.1017

$model1cs
      df      AIC
CSR5Dgamma1_2 6.999471 221.7035
CSR5Dlogno1_2 6.999304 223.3470

```

Lampiran 16 Hasil Pemodelan RX5day di Stasiun Umbu (Lanjutan)

```

CSR5Dgamma1_1 6.999472 229.4245
CSR5Dlogno1_1 6.999471 229.7028

$model1pb
      df      AIC
pbr5Dgamma1_1 4.000045 227.4528
pbr5Dlogno1_1 4.000041 228.7287
pbr5Dgengam1_1 5.000065 229.3713

$model2cs
      df      AIC
CSR5Dgengam2_3 7.999366 220.3587
CSR5Dgamma2_2 6.999532 220.7518
CSR5Dlogno2_2 6.999528 221.4215
CSR5Dgengam2_8 8.999486 226.2822
CSR5Dgamma2_5 9.999963 226.8327
CSR5Dlogno2_5 9.999970 227.4867
CSR5Dgamma2_7 11.000115 227.8351
CSR5Dgamma2_1 7.000461 228.0591
CSR5Dlogno2_7 10.998631 228.2130
CSR5Dlogno2_1 7.000468 229.2693
CSR5Dgamma2_4 6.999332 229.7864
CSR5Dlogno2_4 6.999365 230.3492
CSR5Dgengam2_1 8.000447 230.9085

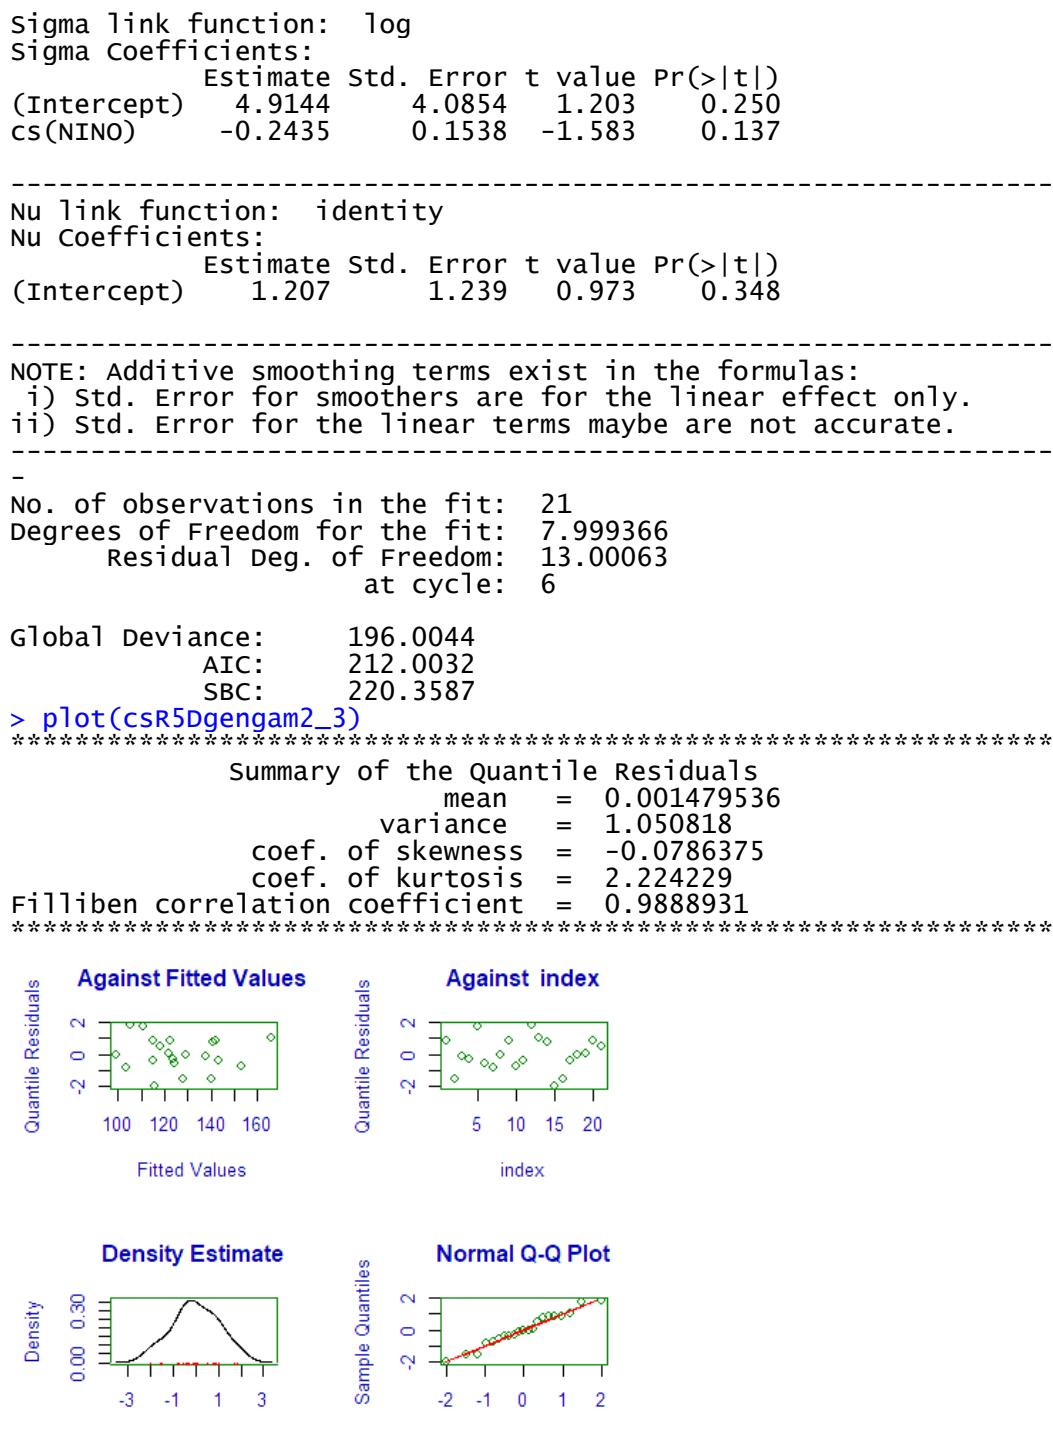
$model2pb
      df      AIC
pbr5Dlogno2_3 4.000010 222.4089
pbr5Dlogno2_4 4.000050 222.4090
pbr5Dgamma2_4 4.000051 222.5541
pbr5Dlogno2_7 7.965142 222.9926
pbr5Dgamma2_1 4.000009 224.5692
pbr5Dgamma2_2 4.927118 224.6658
pbr5Dgamma2_5 4.927569 224.6660
pbr5Dgengam2_4 5.000050 225.4241
pbr5Dlogno2_2 4.850131 225.5726
pbr5Dlogno2_1 4.000009 225.6849
pbr5Dlogno2_8 5.000011 225.8646
pbr5Dgamma2_8 5.000011 226.2126
pbr5Dgamma2_7 5.000101 226.2128
pbr5Dgengam2_1 5.000010 227.2014
pbr5Dgengam2_8 6.000012 228.7785
pbr5Dgengam2_7 6.000100 228.7787

> summary(csr5Dgengam2_3)
*****
*
Family: c("GG", "generalised Gamma Lopatatsidis-Green")
Call: gamlss(formula = y ~ SOI, sigma.formula = ~cs(NINO),
family = GG, data = dataku, method = RS(), trace = FALSE)
Fitting method: RS()

-----
-
Mu link function: log
Mu Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) 4.78768 0.02844 168.347 < 2e-16 ***
SOI 0.07328 0.01094 6.701 1.47e-05 ***
---
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

Lampiran 16 Hasil Pemodelan RX5day di Stasiun Umbu (Lanjutan)



Lampiran 17 Hasil Pemodelan RX5day di Stasiun Lasiana

\$model0	df	AIC
R5Dgamma0	2	261.1032
R5Dlogno0	2	263.8277

Lampiran 17 Hasil Pemodelan RX5day di Stasiun Lasiana (Lanjutan)

```
$model1cs
      df      AIC
CSR5Dgamma1_2 6.999472 268.0392
CSR5Dlogno1_2 6.999304 270.2051
CSR5Dgamma1_1 6.999484 270.4324
CSR5Dlogno1_1 6.999257 271.2946

$model1pb
      df      AIC
pbr5Dgamma1_1 4.000033 264.3578
pbr5Dgamma1_2 4.883346 264.8691
pbr5Dlogno1_1 4.000024 266.9146
pbr5Dlogno1_2 4.883974 267.1746
$model12cs
      df      AIC
CSR5Dgamma2_8 7.999472 269.4881
CSR5Dgengam2_2 7.999525 269.7857
CSR5Dlogno2_8 7.999304 270.1637
CSR5Dgamma2_1 7.000468 270.4012
CSR5Dgamma2_2 6.999331 270.6093
CSR5Dgamma2_4 7.000515 271.6793
CSR5Dlogno2_1 7.000468 272.3100
CSR5Dgengam2_8 8.999473 272.5403
CSR5Dgamma2_3 6.999344 272.6363
CSR5Dlogno2_2 7.000654 273.1164
CSR5Dgamma2_7 11.001122 273.6270
CSR5Dlogno2_4 7.000518 274.0998
CSR5Dgamma2_5 9.999812 275.9015
CSR5Dgengam2_5 10.999996 276.5740
CSR5Dlogno2_7 10.998751 276.6947
CSR5Dlogno2_5 9.999940 278.5419

$model12pb
      df      AIC
pbr5Dgamma2_1 4.000010 266.5386
pbr5Dgamma2_2 4.000029 266.5387
pbr5Dgamma2_5 4.000038 266.5387
pbr5Dgamma2_3 4.000011 266.9173
pbr5Dgamma2_4 4.000025 266.9173
pbr5Dgamma2_6 4.000035 266.9173
pbr5Dgengam2_1 5.000012 267.8910
pbr5Dgengam2_2 5.000039 267.8911
pbr5Dgengam2_5 5.000051 267.8911
pbr5Dgamma2_8 6.067201 268.3734
pbr5Dgamma2_7 5.000054 269.0495
pbr5Dlogno2_8 6.725040 269.0591
pbr5Dlogno2_1 4.000009 269.1504
pbr5Dlogno2_2 4.000023 269.1505
pbr5Dlogno2_5 4.000032 269.1505
pbr5Dlogno2_3 4.000010 269.3118
pbr5Dlogno2_4 4.000020 269.3118
pbr5Dlogno2_6 4.000030 269.3118
pbr5Dlogno2_7 5.000038 272.0970
> summary(R5Dgamma0)
*****
Family: c("GA", "Gamma")

Call: gamlss(formula = y ~ 1, family = GA, data = dataku, method = RS(), trace = FALSE)

Fitting method: RS()
```

Lampiran 17 Hasil Pemodelan RX5day di Stasiun Lasiana (Lanjutan)

```

Mu link function: log
Mu Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) 5.5214     0.0983   56.17 <2e-16 ***
---
Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

Sigma link function: log
Sigma Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) -0.7974    0.1494  -5.339 3.75e-05 ***
---
Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

No. of observations in the fit: 21
Degrees of Freedom for the fit: 2
      Residual Deg. of Freedom: 19
                     at cycle: 2

Global Deviance: 255.0141
      AIC: 259.0141
      SBC: 261.1032
*****
Degrees of Freedom for the fit: 2 Residual Deg. of Freedom 19
Global Deviance: 255.014
      AIC: 259.014
      SBC: 261.103
> plot(R5Dgamma0)
*****
Summary of the Quantile Residuals
      mean = 0.003662516
      variance = 1.05135
      coef. of skewness = -0.5823366
      coef. of kurtosis = 2.775048
Filliben correlation coefficient = 0.981251
*****


```

Lampiran 18 Hasil Pemodelan RX5day di Stasiun Eltari

	df	AIC
\$model0		
R5Dgamma0	2	245.8089
R5Dlogno0	2	246.4701
R5Dgengam0	3	248.7895

Lampiran 18 Hasil Pemodelan RX5day di Stasiun Eltari (Lanjutan)

	df	AIC
\$model1cs		
CSR5Dgamma1_2	6.999470	251.0767
CSR5Dlogno1_2	6.999304	251.5452
CSR5Dgamma1_1	6.999474	252.7680
CSR5Dlogno1_1	6.999481	252.7793
CSR5Dgengam1_2	7.999484	253.7884
\$model1pb		
PBR5Dgamma1_2	4.000014	246.5396
PBR5Dgamma1_1	4.000073	246.5398
PBR5Dlogno1_2	4.000014	247.1385
PBR5Dlogno1_1	4.000069	247.1387
\$model2cs		
CSR5Dlogno2_1	7.000468	249.1514
CSR5Dgamma2_1	6.999463	249.3999
CSR5Dgamma2_4	6.999307	250.0707
CSR5Dlogno2_4	6.999320	250.5671
CSR5Dgamma2_5	9.998997	250.7676
CSR5Dlogno2_5	10.000007	250.9344
CSR5Dgamma2_2	6.999334	251.1515
CSR5Dlogno2_2	6.999326	252.0333
CSR5Dgengam2_1	8.000470	252.1784
CSR5Dgengam2_4	7.999298	252.6314
CSR5Dgengam2_2	7.999352	253.3524
CSR5Dgamma2_7	10.999753	253.3674
CSR5Dlogno2_7	10.999769	253.8202
CSR5Dgengam2_5	10.998997	253.8286
CSR5Dlogno2_8	7.999304	253.8824
CSR5Dgengam2_8	8.999474	255.2501
CSR5Dgamma2_3	6.999474	255.4662
CSR5Dlogno2_3	6.999405	255.5647
CSR5Dgengam2_7	11.998753	255.7908
CSR5Dgamma2_6	9.998854	256.0532
CSR5Dgengam2_3	7.999449	258.4485
CSR5Dgengam2_6	10.998856	259.1138
\$model2pb		
PBR5Dgamma2_1	4.952876	248.8109
PBR5Dgamma2_5	4.950908	248.8126
PBR5Dlogno2_5	4.858385	248.8737
PBR5Dlogno2_1	4.858456	248.8741
PBR5Dgamma2_2	4.000052	249.3461
PBR5Dlogno2_2	4.000049	249.5368
PBR5Dgamma2_3	4.000010	249.6079
PBR5Dgamma2_4	4.000053	249.6079
PBR5Dgamma2_6	4.000064	249.6080
PBR5Dlogno2_3	4.000010	249.8774
PBR5Dlogno2_4	4.000051	249.8774
PBR5Dlogno2_6	4.000061	249.8775
PBR5Dgengam2_1	5.939740	251.7673
PBR5Dgengam2_5	5.939789	251.7677
PBR5Dgengam2_2	5.000051	252.3758
PBR5Dgengam2_3	5.000010	252.6497
PBR5Dgengam2_4	5.000053	252.6498
PBR5Dgengam2_6	5.000064	252.6498
PBR5Dgamma2_7	7.022792	252.7121
PBR5Dlogno2_7	6.676678	253.5720
PBR5Dgamma2_8	5.000011	254.0748

Lampiran 18 Hasil Pemodelan RX5day di Stasiun Eltari (Lanjutan)

```

pbR5Dlogno2_8 5.000010 254.1040
pbR5Dgengam2_8 6.000011 257.0651
> summary(R5Dgamma0)
*****
Family: c("GA", "Gamma")

Call: gamlss(formula = y ~ 1, family = GA, data = dataku, method = RS(), trace = FALSE)

Fitting method: RS()

-----
Mu link function: log
Mu Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) 5.51387    0.06613   83.38 <2e-16 ***
---
Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

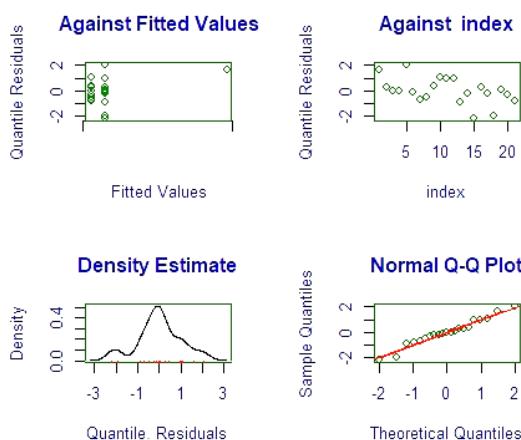
-----
Sigma link function: log
Sigma Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) -1.194     0.152   -7.854 2.2e-07 ***
---
Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

-----
No. of observations in the fit: 21
Degrees of Freedom for the fit: 2
      Residual Deg. of Freedom: 19
                           at cycle: 2

Global Deviance: 239.7199
      AIC: 243.7199
      SBC: 245.8089
> plot(R5Dgamma0)
*****
```

Summary of the Quantile Residuals

mean	= 0.0003853714
variance	= 1.050095
coef. of skewness	= -0.1311105
coef. of kurtosis	= 2.89151
Filliben correlation coefficient	= 0.9814078

*****

Lampiran 19 Hasil Pemodelan RX5day di Stasiun Tardamu

	df	AIC
R5Dgamma0	2	239.7295
R5Dlogno0	2	240.9356
R5Dgengam0	3	242.0588
\$model1cs		
	df	AIC
CSR5Dgamma1_2	6.999470	222.5030
CSR5Dlogno1_2	6.999304	222.7829
CSR5Dgengam1_2	7.999472	225.7894
CSR5Dlogno1_1	7.000570	230.3956
CSR5Dgamma1_1	6.999459	231.0296
\$model1pb		
	df	AIC
pbr5Dgamma1_2	8.065065	222.8972
pbr5Dlogno1_2	8.145930	223.3165
pbr5Dgengam1_2	9.075615	225.9451
pbr5Dlogno1_1	6.459651	230.8115
pbr5Dgamma1_1	6.102119	231.6625
\$model2cs		
	df	AIC
CSR5Dgamma2_8	7.999470	237.5999
CSR5Dlogno2_8	7.999304	238.8963
CSR5Dgengam2_8	8.999474	240.4290
CSR5Dgamma2_4	6.999466	250.3019
CSR5Dgamma2_1	7.000468	251.5923
CSR5Dgamma2_2	7.000667	251.7272
CSR5Dlogno2_4	6.999468	251.8489
CSR5Dgamma2_3	6.999343	251.8651
CSR5Dlogno2_1	7.000468	252.4064
CSR5Dlogno2_2	6.999331	252.9603
CSR5Dgamma2_7	11.000047	252.9760
CSR5Dgengam2_3	8.000507	253.6008
CSR5Dlogno2_7	11.000040	254.3055
CSR5Dgengam2_1	7.999456	254.3686
\$model2pb		
	df	AIC
pbr5Dgamma2_8	8.452901	238.4763
pbr5Dlogno2_8	8.486442	239.8383
pbr5Dgamma2_7	5.000117	240.2943
pbr5Dgengam2_8	9.409684	241.1435
pbr5Dlogno2_7	5.000099	242.2397
pbr5Dgengam2_7	6.000138	242.3623
pbr5Dgamma2_1	4.000011	245.6890
pbr5Dgamma2_2	4.000039	245.6891
pbr5Dgamma2_5	4.000050	245.6891
pbr5Dgamma2_3	4.000013	245.7485
pbr5Dgamma2_4	4.000034	245.7486
pbr5Dgamma2_6	4.000046	245.7486
pbr5Dlogno2_1	4.000011	246.9232
pbr5Dlogno2_2	4.000034	246.9232
pbr5Dlogno2_5	4.000045	246.9232
pbr5Dlogno2_3	4.000012	246.9283
pbr5Dlogno2_4	4.000031	246.9284
pbr5Dlogno2_6	4.000043	246.9284
pbr5Dgengam2_1	5.000014	247.9202
pbr5Dgengam2_2	5.000051	247.9203
pbr5Dgengam2_5	5.000065	247.9203
pbr5Dgengam2_3	5.000016	248.0576

Lampiran 19 Hasil Pemodelan RX5day di Stasiun Tardamu (Lanjutan)

```
pbR5Dgengam2_4 5.000044 248.0577
pbR5Dgengam2_6 5.000060 248.0577

> summary(csR5Dgamma1_2)
*****
* Family: c("GA", "Gamma")
call: gamlss(formula = y ~ t, sigma.formula = ~cs(t), family = GA,
  data = dataku, method = RS(), trace = FALSE)
Fitting method: RS()

-----
- Mu link function: log
Mu Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) 5.600815  0.052874 105.93 < 2e-16 ***
t           -0.031668  0.002946 -10.75 3.78e-08 ***
---
Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

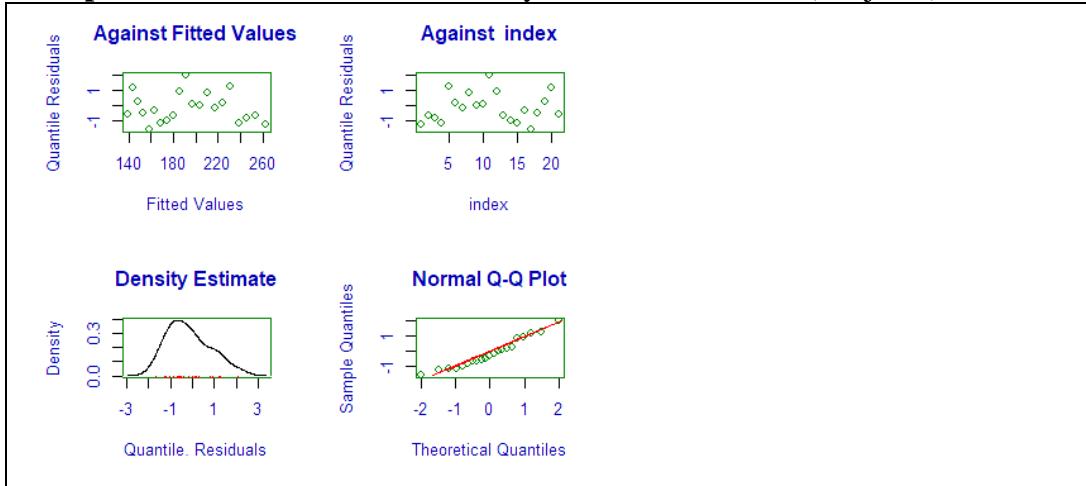
-----
- Sigma link function: log
Sigma Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) -1.62164   0.32574 -4.978 0.000202 ***
cs(t)        -0.01114   0.02608 -0.427 0.675714
---
Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

-----
- NOTE: Additive smoothing terms exist in the formulas:
  i) Std. Error for smoothers are for the linear effect only.
  ii) Std. Error for the linear terms maybe are not accurate.

No. of observations in the fit: 21
Degrees of Freedom for the fit: 6.99947
      Residual Deg. of Freedom: 14.00053
                                at cycle: 10

Global Deviance:    201.1929
      AIC:    215.1919
      SBC:    222.503
> plot(csR5Dgamma1_2)
*****
Summary of the Quantile Residuals
      mean     = -0.1540057
      variance = 0.9615239
      coef. of skewness = 0.5259973
      coef. of kurtosis = 2.291417
      Filliben correlation coefficient = 0.9802417
*****
```

Lampiran 19 Hasil Pemodelan RX5day di Stasiun Tardamu (Lanjutan)



Lampiran 20 Hasil Pemodelan CDD di Stasiun Komodo

```
$model0
      df      AIC
CDDNB0  2 195.7197
CDDGP0  2 195.9353
CDDPIG0 2 196.3306

$model1cs
      df      AIC
CSCDDPIG1_2 7.000688 200.1548
CSCDDGP1_2  6.999296 200.3525
CSCDDNB1_2  7.000340 200.9087
CSCDDPIG1_1 6.999230 203.8434
CSCDDNB1_1  6.999471 204.1229
CSCDDGP1_1  6.999351 204.4064

$model1pb
      df      AIC
pbCDDPIG1_2 5.026727 195.7757
pbCDDNB1_2  4.942861 196.4442
pbCDDNB1_1  4.660046 199.1379
pbCDDPIG1_1 4.832742 199.2160
pbCDDGP1_2  4.000002 199.8424
pbCDDGP1_1  4.000018 199.8442

$model2cs
      df      AIC
CSCDDPIG2_8  7.999393 191.0304
CSCDDGP2_2  6.999534 191.5255
CSCDDGP2_5  10.001169 193.3469
CSCDDNB2_2  6.999503 193.4472
CSCDDPIG2_5  9.999915 193.9657
CSCDDPIG2_1  6.999444 195.1579
CSCDDGP2_1  7.000794 195.2182
CSCDDNB2_4  7.000334 198.5443
CSCDDGP2_3  7.000558 198.8843
CSCDDNB2_3  6.999502 198.9480
CSCDDNB2_7  10.999782 199.2503

$model2pb
      df      AIC
pbCDDPIG2_8 6.058204 187.7052
```

Lampiran 20 Hasil Pemodelan CDD di Stasiun Komodo (Lanjutan)

```

pbCDDGP2_8  6.124170 189.4829
pbCDDNB2_8  6.098943 189.5469
pbCDDNB2_1  4.843660 193.0370
pbCDDNB2_5  4.843703 193.0371
pbCDDGP2_1  4.782445 193.2329
pbCDDPIG2_1 4.000001 193.7694
pbCDDPIG2_5 4.000016 193.7695
pbCDDPIG2_2 4.000015 193.7696
pbCDDGP2_5  4.000012 194.3737
pbCDDGP2_2  4.000011 194.3778
pbCDDNB2_2  4.000026 194.9022
pbCDDPIG2_3 4.000001 194.9613
pbCDDPIG2_4 4.000020 194.9613
pbCDDPIG2_6 4.000021 194.9613
pbCDDGP2_4  4.000016 195.2217
pbCDDGP2_6  4.000019 195.2217
pbCDDGP2_3  4.000003 195.2218
pbCDDNB2_4  4.809288 195.4066
pbCDDNB2_6  4.809289 195.4066
pbCDDNB2_3  4.000001 195.7155
pbCDDNB2_7  5.000100 195.8501
pbCDDPIG2_7 5.000049 195.9478
pbCDDGP2_7  5.000045 196.9468
> summary(pbCDDPIG2_8)
Family: c("PIG", "Poisson.Inverse.Gaussian")

Call: gamlss(formula = CDD ~ SOI + NINO, sigma.formula = ~pb(t),
  family = PIG, data = dataku, method = RS(), trace = FALSE)

Fitting method: RS()

-----
-
Mu link function: log
Mu Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) 8.91677 2.73975 3.255 0.00536 **
SOI         0.02076 0.08079 0.257 0.80074
NINO        -0.18575 0.10256 -1.811 0.09026 .
---
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

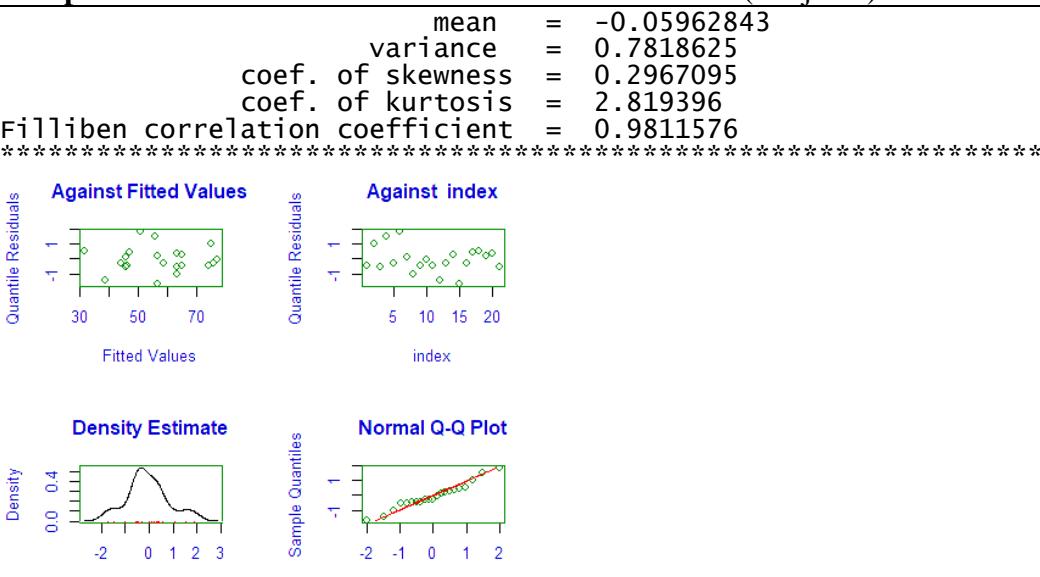
-----
Sigma link function: log
Sigma Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) -0.25999 0.95601 -0.272 0.789
pb(t)       -0.16854 0.09814 -1.717 0.107
---
NOTE: Additive smoothing terms exist in the formulas:
  i) Std. Error for smoothers are for the linear effect only.
  ii) Std. Error for the linear terms maybe are not accurate.

No. of observations in the fit: 21
Degrees of Freedom for the fit: 6.058204
  Residual Deg. of Freedom: 14.9418
    at cycle: 15

Global Deviance: 169.2608
      AIC: 181.3772
      SBC: 187.7052
> plot(pbCDDPIG2_8)
*****
Summary of the Randomised Quantile Residuals

```

Lampiran 20 Hasil Pemodelan CDD di Stasiun Komodo (Lanjutan)



Lampiran 21 Hasil Pemodelan CDD di Stasiun Frans

```
$model0
      df      AIC
CDDNB0  2 191.9851
CDDGP0  2 191.9962
CDDPIG0 2 192.3215

$model1cs
      df      AIC
cscddpig1_1 6.999300 201.4570
cscddgp1_1  7.000704 201.7063
cscddnb1_1  6.999337 202.6046

$model1pb
      df      AIC
pbCDDPIG1_2 4.000001 196.3282
pbCDDPIG1_1  4.000010 196.3283
pbCDDGP1_2   4.000002 196.4642
pbCDDGP1_1   4.000009 196.4642
pbCDDNB1_2   4.000001 196.9017
pbCDDNB1_1   4.000014 196.9018

$model12cs
      df      AIC
cscddnb2_7  10.998702 189.1871
cscddgp2_8   7.999208 192.4348
cscddnb2_8   8.000770 193.9446
cscddnb2_2   6.999316 197.1626
cscddgp2_1   7.000526 197.2594
cscddnb2_1   6.999377 199.7257
cscddnb2_4   7.000549 199.7852
cscddnb2_3   7.000638 201.4257

$model12pb
      df      AIC
pbCDDGP2_7  6.079415 192.9915
pbCDDGP2_8   5.000003 193.6524
pbCDDPIG2_2  4.000007 194.3321
pbCDDPIG2_1  4.000000 194.3322
pbCDDPIG2_5  4.000008 194.3322
```

Lampiran 21 Hasil Pemodelan CDD di Stasiun Frans (Lanjutan)

```

pbCDDGP2_2  4.000004 194.3961
pbCDDGP2_1  4.000001 194.3965
pbCDDGP2_5  4.000005 194.3965
pbCDDGP2_4  4.000005 194.4698
pbCDDGP2_3  4.000001 194.4701
pbCDDGP2_6  4.000006 194.4701
pbCDDPIG2_3 4.000000 194.5422
pbCDDPIG2_6 4.000005 194.5422
pbCDDPIG2_4 4.000005 194.5422
pbCDDNB2_8  5.000001 194.5700
pbCDDNB2_6  4.000013 194.9167
pbCDDNB2_3  4.000000 194.9170
pbCDDNB2_4  4.000013 194.9171
pbCDDNB2_1  4.000001 195.6146
pbCDDPIG2_7 5.000031 195.6993
pbCDDPIG2_8 5.000001 195.6995
pbCDDNB2_5  5.265617 195.7555
pbCDDNB2_2  5.265632 195.7555

Family: c("NBI", "Negative Binomial type I")
Call: gamlss(formula = CDD ~ cs(SOI) + cs(NINO), sigma.formula =
~t,
family = NBI, data = dataku, method = RS(), trace = FALSE)
Fitting method: RS()

-----
-
Mu link function: log
Mu Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) -13.25207   3.81268  -3.476  0.00596 **
cs(SOI)      0.53136   0.08386   6.337 8.49e-05 ***
cs(NINO)     0.62138   0.14252   4.360  0.00142 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

-----
-
Sigma link function: log
Sigma Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) -6.3124    2.0132  -3.135  0.0106 *
t            0.2962    0.1329   2.229  0.0499 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

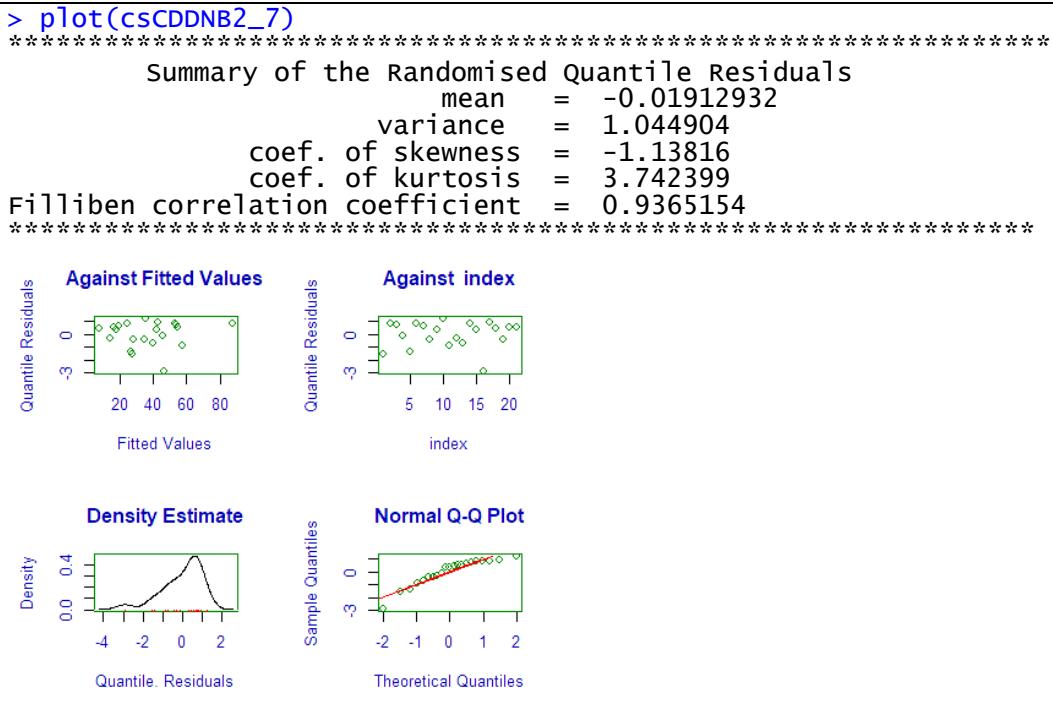
-----
-
NOTE: Additive smoothing terms exist in the formulas:
i) Std. Error for smoothers are for the linear effect only.
ii) Std. Error for the linear terms maybe are not accurate.

-----
-
No. of observations in the fit: 21
Degrees of Freedom for the fit: 10.9987
Residual Deg. of Freedom: 10.0013
at cycle: 10

Global Deviance: 155.7013
AIC: 177.6987
SBC: 189.1871

```

Lampiran 21 Hasil Pemodelan CDD di Stasiun Frans (Lanjutan)



Lampiran 22 Hasil Pemodelan CDD di Stasiun Fransiskus

```
$model0
      df      AIC
CDDNB0  2 209.9605
CDDGP0  2 210.2067
CDDPIG0 2 210.4493

$model1cs
      df      AIC
cscDDPIG1_1 6.999432 202.6123
cscDDNB1_2  6.999195 217.1110

$model1pb
      df      AIC
pbCDDGP1_1 5.703231 200.5596
pbCDDPIG1_2 4.000000 207.5941
pbCDDGP1_2  4.000001 208.3276
pbCDDNB1_2  4.000000 211.8373

$model12cs
      df      AIC
cscDDGP2_5 10.000971 208.8928
cscDDPIG2_3 6.999490 215.8471
cscDDNB2_1  6.999285 216.3075
cscDDNB2_3  7.000595 216.3226
cscDDGP2_3  7.000555 216.6316
cscDDPIG2_8 7.999254 217.5321
cscDDPIG2_4 6.999356 217.6213
cscDDGP2_8  7.999293 218.6984
cscDDNB2_8  8.000655 219.2349
cscDDNB2_4  6.999285 219.2447
cscDDPIG2_6 9.999839 219.9407
cscDDGP2_2  6.999434 221.4851
```

Lampiran 22 Hasil Pemodelan CDD di Stasiun Fransiskus (Lanjutan)

```
cscddnb2_2 6.999523 222.0767
cscddnb2_7 11.000095 226.3247

$model2pb
      df      AIC
pbCDDGP2_1 4.856361 212.5527
pbCDDGP2_5 4.856373 212.5528
pbCDDPIG2_1 5.004268 212.7021
pbCDDPIG2_5 5.004283 212.7021
pbCDDNB2_3 4.000001 212.9757
pbCDDNB2_6 4.000023 212.9758
pbCDDNB2_4 4.000022 212.9758
pbCDDNB2_1 4.819864 213.0227
pbCDDNB2_5 4.819912 213.0229
pbCDDPIG2_3 4.000001 213.3247
pbCDDPIG2_4 4.000010 213.3247
pbCDDPIG2_6 4.000011 213.3247
pbCDDGP2_3 4.000002 213.4204
pbCDDGP2_2 4.000007 213.8800
pbCDDNB2_2 4.000021 213.8887
pbCDDPIG2_7 5.000027 214.3701
pbCDDPIG2_8 5.000001 214.3712
pbCDDPIG2_2 4.000008 214.4178
pbCDDGP2_8 5.000003 214.6876
pbCDDNB2_8 5.000001 214.8739
pbCDDNB2_7 5.000047 214.8740
pbCDDGP2_7 5.000000 250.0586

> summary(pbCDDGP1_1)
*****
Family: c("GPO", "Generalised Poisson")
Call: gamlss(formula = CDD ~ pb(t), sigma.formula = ~t, family =
GPO,
  data = dataku, method = RS(), trace = FALSE)
Fitting method: RS()

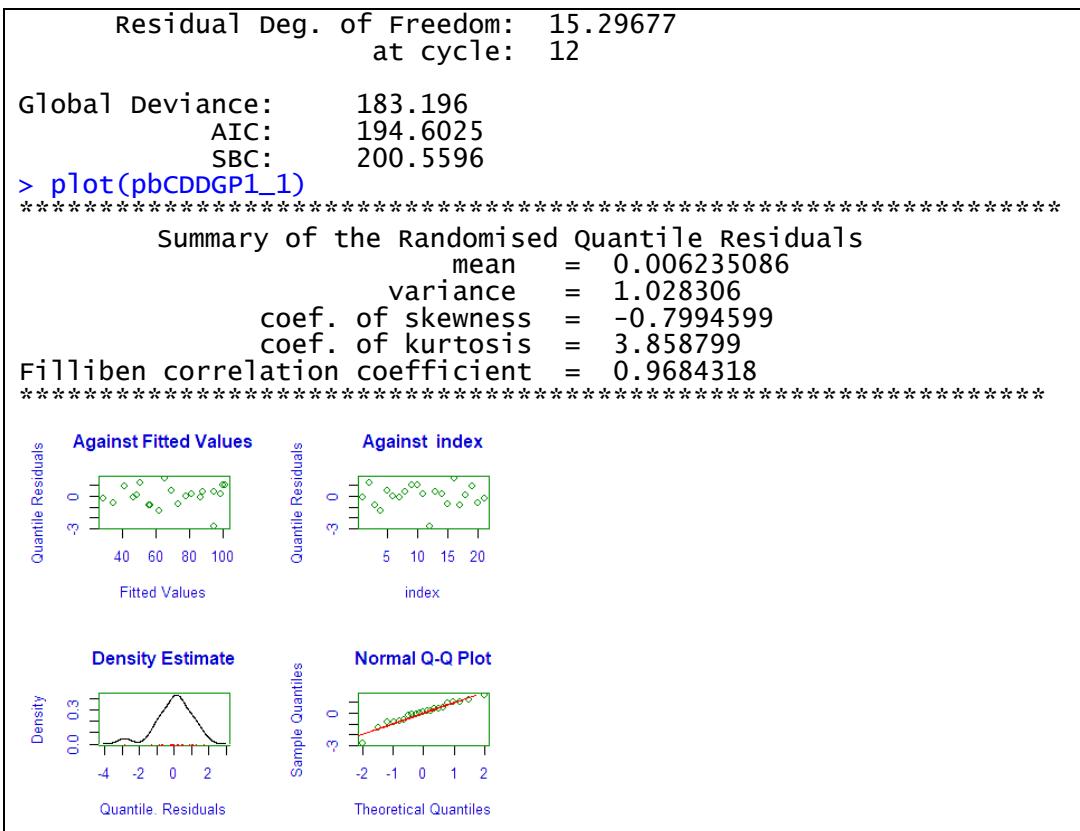
-----
Mu link function: log
Mu Coefficients:
  Estimate Std. Error t value Pr(>|t|)
(Intercept) 6.05049   0.10668  56.72 < 2e-16 ***
pb(t)       0.34164   0.01154  29.62 6.29e-15 ***
---
Signif. codes:  0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

-----
Sigma link function: log
Sigma Coefficients:
  Estimate Std. Error t value Pr(>|t|)
(Intercept) -4.96055   0.81045 -6.121 1.8e-05 ***
t           0.09911   0.06016  1.647    0.12
---
Signif. codes:  0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

-----
NOTE: Additive smoothing terms exist in the formulas:
  i) Std. Error for smoothers are for the linear effect only.
  ii) Std. Error for the linear terms maybe are not accurate.

No. of observations in the fit: 21
Degrees of Freedom for the fit: 5.703231
```

Lampiran 22 Hasil Pemodelan CDD di Stasiun Fransiskus (Lanjutan)



Lampiran 23 Hasil Pemodelan CDD di Stasiun Gewayantana

```

$model0
      df      AIC
CDDNB0  2 229.7375
CDDGP0  2 230.3841
CDDPIG0 2 231.2856

$model1cs
      df      AIC
CSCDDNB1_2 6.999221 230.1233
CSCDDPIG1_2 6.999295 231.6061
CSCDDNB1_1 6.999300 237.3029
CSCDDGP1_2 7.000790 269.4235

$model1pb
      df      AIC
pbCDDNB1_2 4.896268 231.9140
pbCDDPIG1_2 5.189017 232.2604
pbCDDNB1_1 4.000022 232.7363
pbCDDPIG1_1 4.000013 234.1815
pbCDDGP1_2 4.000001 264.9113

$model2cs
      df      AIC
CSCDDPIG2_2 7.000652 229.0671
CSCDDPIG2_1 6.999320 230.0749
CSCDDPIG2_4 6.999375 230.2657
CSCDDGP2_1 7.000157 230.7453
CSCDDNB2_2 6.999387 232.0045
CSCDDNB2_4 7.000509 232.3133

```

Lampiran 23 Hasil Pemodelan CDD di Stasiun Gewayantana (Lanjutan)

```

CSCDDGP2_8    8.000738 232.7057
CSCDDPIG2_8   7.999351 232.8372
CSCDDNB2_6    9.999750 235.0677
CSCDDNB2_7    11.000234 241.6299
CSCDDGP2_4    7.000335 275.9548

$model2pb
      df      AIC
pbCDDGP2_1   4.551098 225.7696
pbCDDGP2_5   4.551110 225.7697
pbCDDGP2_2   4.000012 226.1182
pbCDDGP2_3   4.000002 226.5272
pbCDDGP2_6   4.000026 226.5272
pbCDDGP2_4   4.000024 226.5274
pbCDDPIG2_4  4.000026 226.5768
pbCDDPIG2_3  4.000001 226.5768
pbCDDPIG2_6  4.000027 226.5768
pbCDDPIG2_1  4.000002 226.6928
pbCDDPIG2_5  4.000018 226.6928
pbCDDPIG2_2  4.000016 226.6929
pbCDDNB2_4   4.000025 227.2089
pbCDDNB2_6   4.000026 227.2089
pbCDDNB2_3   4.000001 227.2089
pbCDDNB2_1   4.000001 227.5393
pbCDDNB2_5   4.000019 227.5395
pbCDDNB2_2   4.000018 227.5395
pbCDDPIG2_8  6.222943 233.4245
pbCDDNB2_7   5.962762 236.2707
pbCDDGP2_8   5.874195 236.3849
pbCDDGP2_7   5.000010 237.7552
pbCDDPIG2_7  5.000030 237.8145
pbCDDNB2_8   5.000002 238.0823
> summary(pbCDDGP2_1)
*****
*
Family: c("GPO", "Generalised Poisson")
Call: gamlss(formula = CDD ~ NINO, sigma.formula = ~pb(SOI),
  family = GPO, data = dataku, method = RS(), trace = FALSE)
Fitting method: RS()

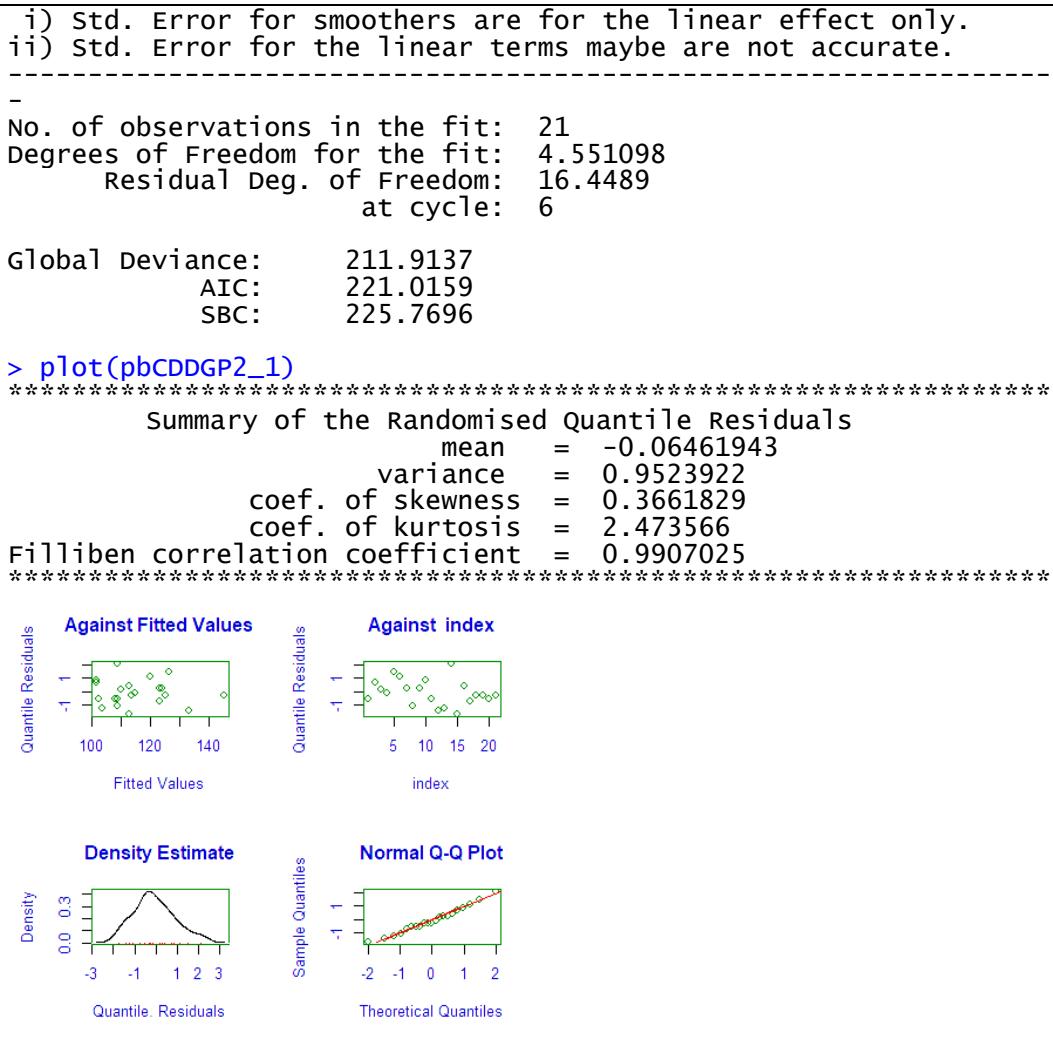
-----
-
Mu link function: log
Mu Coefficients:
  Estimate Std. Error t value Pr(>|t|)
(Intercept) 2.45135   2.93405   0.835   0.415
NINO        0.08676   0.11384   0.762   0.457

-----
-
Sigma link function: log
Sigma Coefficients:
  Estimate Std. Error t value Pr(>|t|)
(Intercept) -3.2089   0.2106 -15.240 3.98e-11 ***
pb(SOI)     -0.3331   0.1201  -2.773  0.0133 *
---
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

-----
-
NOTE: Additive smoothing terms exist in the formulas:

```

Lampiran 23 Hasil Pemodelan CDD di Stasiun Gewayantana (Lanjutan)



Lampiran 24 Hasil Pemodelan CDD di Stasiun Umbu

```

$model0
df      AIC
CDDNB0 2 227.3757
CDDGPO 2 227.8801
CDDPIGO 2 228.1972

$model1cs
df      AIC
CSCDDPIG1_2 6.999279 227.8512
CSCDDGP1_2 7.000825 228.2723
CSCDDNB1_2 7.000479 228.4580
CSCDDPIG1_1 7.000770 233.1991
CSCDDNB1_1 7.000598 234.1325
CSCDDGP1_1 6.999692 380.8154

$model1pb
df      AIC
pbCDDNB1_1 4.000039 229.0744
pbCDDNB1_2 4.000001 229.0758

```

Lampiran 24 Hasil Pemodelan CDD di Stasiun Umbu (Lanjutan)

```

pbCDDPIG1_1 4.000028 229.1257
pbCDDPIG1_2 4.000001 229.1277
pbCDDGP1_2 4.000002 229.4522
pbCDDGP1_1 4.000023 229.4541

$model2cs
      df      AIC
cSCDDPIG2_2 7.000425 231.0900
cSCDDNB2_2 7.000482 232.0880
cSCDDGP2_8 7.999372 233.0671
cSCDDNB2_4 6.999320 233.4665
cSCDDPIG2_8 7.999486 234.3130
cSCDDNB2_7 10.998777 234.4473

$model2pb
      df      AIC
pbCDDPIG2_3 4.000000 228.4487
pbCDDPIG2_6 4.000019 228.4487
pbCDDPIG2_4 4.000019 228.4488
pbCDDGP2_3 4.000001 228.6107
pbCDDGP2_6 4.000020 228.6108
pbCDDGP2_4 4.000020 228.6113
pbCDDNB2_4 4.000034 228.9822
pbCDDNB2_3 4.000000 228.9823
pbCDDNB2_6 4.000034 228.9824
pbCDDPIG2_1 4.000001 229.0005
pbCDDPIG2_5 4.000027 229.0005
pbCDDPIG2_2 4.000027 229.0012
pbCDDGP2_2 4.000024 229.1761
pbCDDGP2_1 4.000001 229.1761
pbCDDGP2_5 4.000025 229.1761
pbCDDNB2_1 4.000000 229.4280
pbCDDNB2_5 5.223361 229.6683
pbCDDNB2_7 6.135354 230.7992
pbCDDPIG2_7 5.000060 231.2241
pbCDDPIG2_8 5.000001 231.2246
pbCDDNB2_8 5.000001 231.3467
pbCDDGP2_8 5.000002 231.6147
pbCDDGP2_7 5.000057 231.6152

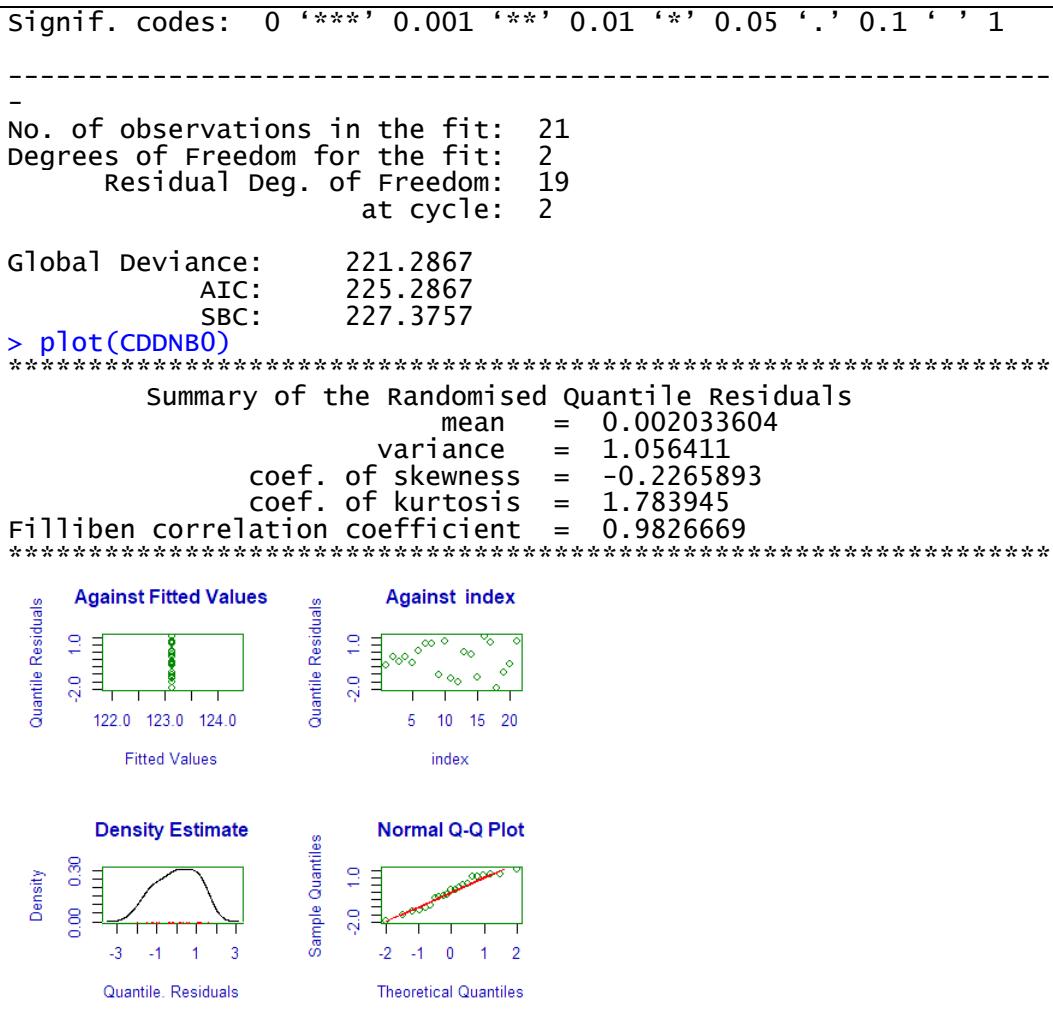
Family: c("NBI", "Negative Binomial type I")
Call: gamlss(formula = CDD ~ 1, family = NBI, data = dataku,
method = RS(), trace = FALSE)
Fitting method: RS()

-----
-
Mu link function: log
Mu Coefficients:
  Estimate Std. Error t value Pr(>|t|)
(Intercept) 4.81335   0.08751  55.01 <2e-16 ***
---
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

-----
-
Sigma link function: log
Sigma Coefficients:
  Estimate Std. Error t value Pr(>|t|)
(Intercept) -1.8794    0.3182 -5.907 1.1e-05 ***
---

```

Lampiran 24 Hasil Pemodelan CDD di Stasiun Umbu (Lanjutan)



Lampiran 25 Hasil Pemodelan CDD di Stasiun Lasiana

```

$mode10
      df      AIC
CDDNB0  2 229.4150
CDDGP0  2 229.6644
CDDPIG0 2 229.7707

$mode11cs
      df      AIC
CSCDDPIG1_2 6.999292 223.2808
CSCDDGP1_2 6.999318 224.1386
CSCDDGP1_1 6.999440 230.4711
CSCDDPIG1_1 6.999335 230.6119
CSCDDNB1_1 6.999334 231.9394

$mode11pb
      df      AIC
pbCDDGP1_2 4.000003 225.0089
pbCDDGP1_1 4.000009 225.0091
pbCDDPIG1_2 4.000001 225.0233
pbCDDPIG1_1 4.000010 225.0234

```

Lampiran 25 Hasil Pemodelan CDD di Stasiun Lasiana (Lanjutan)

```

pbCDDNB1_2  4.000001 225.4020
pbCDDNB1_1  4.000028 225.4020

$model2cs
      df      AIC
CSCDDGP2_8  7.999339 224.2882
CSCDDPIG2_8 7.999354 225.6250
CSCDDNB2_8   8.000467 227.6464
CSCDDPIG2_4  7.000573 231.7204
CSCDDNB2_4   6.999320 234.1369
CSCDDPIG2_3  6.999317 235.8264
CSCDDNB2_1   6.999218 236.6111
CSCDDGP2_3   7.000618 236.8900
CSCDDNB2_3   6.999290 237.2385
CSCDDNB2_7   11.000147 237.4119
CSCDDNB2_2   6.999475 238.3372
CSCDDNB2_5   10.000233 243.7197

$model2pb
      df      AIC
pbCDDGP2_7  5.000042 222.9978
pbCDDGP2_8  5.000002 223.0016
pbCDDPIG2_7 5.000056 223.5321
pbCDDPIG2_8 5.000001 223.5353
pbCDDNB2_8   5.000001 225.1249
pbCDDNB2_7   5.000067 225.1250
pbCDDGP2_5   4.000008 230.0336
pbCDDGP2_1   4.000002 230.0342
pbCDDGP2_2   4.000006 230.0343
pbCDDPIG2_1  4.000001 230.1859
pbCDDPIG2_5  4.000009 230.1859
pbCDDPIG2_2  4.000008 230.1859
pbCDDNB2_1   4.000001 230.4900
pbCDDNB2_5   4.000017 230.4900
pbCDDNB2_2   4.000016 230.4902
pbCDDPIG2_4  4.000015 232.2981
pbCDDPIG2_3  4.000001 232.2992
pbCDDPIG2_6  4.000015 232.2993
pbCDDGP2_3   4.000002 232.9370
pbCDDGP2_4   4.000012 232.9386
pbCDDGP2_6   4.000014 232.9412
pbCDDNB2_3   4.000001 233.1397
pbCDDNB2_6   4.000017 233.1397
pbCDDNB2_4   4.000016 233.1404

> summary(pbCDDGP2_7)
*****
Family: c("GPO", "Generalised Poisson")
Call: gamlss(formula = CDD ~ pb(SOI) + pb(NINO), sigma.formula =
~t,
  family = GPO, data = dataku, method = RS(), trace = FALSE)
Fitting method: RS()

-----
Mu link function: log
Mu Coefficients:
      Estimate Std. Error t value Pr(>|t|)
(Intercept) 10.20873    4.16703    2.45   0.0262 *
pb(SOI)      0.20838    0.09827    2.12   0.0500 *
pb(NINO)     -0.18445    0.15625   -1.18   0.2551
---

```

Lampiran 25 Hasil Pemodelan CDD di Stasiun Lasiana (Lanjutan)

```

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1
-----
-
Sigma link function: log
Sigma Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) -5.58161 0.72934 -7.653 9.81e-07 ***
t            0.18387 0.05406  3.401 0.00365 **
-----
Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1
-----
-
NOTE: Additive smoothing terms exist in the formulas:
i) Std. Error for smoothers are for the linear effect only.
ii) Std. Error for the linear terms maybe are not accurate.
-----
-
No. of observations in the fit: 21
Degrees of Freedom for the fit: 5.000042
Residual Deg. of Freedom: 15.99996
at cycle: 8
Global Deviance: 207.775
AIC: 217.7751
SBC: 222.9978
> plot(pbCDDGP2_7)
*****
Summary of the Randomised Quantile Residuals
mean      = -0.03154989
variance   = 0.9627145
coef. of skewness = -0.4817062
coef. of kurtosis = 2.329633
Filliben correlation coefficient = 0.9838009
*****


```

Lampiran 26 Hasil Pemodelan CDD di Stasiun Eltari

	df	AIC
CDDNB0	2	229.7175
CDDGPO	2	230.0775
CDDPIGO	2	230.3067

Lampiran 26 Hasil Pemodelan CDD di Stasiun Eltari (Lanjutan)

```
$model1cs
      df      AIC
cSCDDNB1_2 7.000574 223.2373
cSCDDPIG1_2 7.000764 224.4912
cSCDDGP1_1  6.999436 224.9636
cSCDDPIG1_1 6.999397 225.5897
cSCDDNB1_1  6.999339 225.9155

$model1pb
      df      AIC
pbCDDGP1_1 4.000027 223.3810
pbCDDPIG1_2 4.000001 223.4557
pbCDDPIG1_1 4.000028 223.4558
pbCDDNB1_2  4.000002 223.6860
pbCDDNB1_1  4.000033 223.6860
pbCDDGP1_2  4.000001 264.2427

$model2cs
      df      AIC
cSCDDNB2_7 11.000018 234.5236
cSCDDNB2_6 10.001037 234.5592
cSCDDPIG2_8 7.999462 235.8054
cSCDDGP2_8  8.000671 236.1110
cSCDDPIG2_2 6.999400 236.3250
cSCDDPIG2_1 6.999253 237.0085
cSCDDNB2_2  7.000491 237.0873
cSCDDNB2_1  6.999303 237.9830
cSCDDNB2_8  7.999248 238.7634
cSCDDNB2_4  6.999311 238.8430

$model2pb
      df      AIC
pbCDDPIG2_8 5.000001 230.7224
pbCDDPIG2_7 5.000024 230.7224
pbCDDGP2_7  5.000021 231.7475
pbCDDGP2_8  5.000004 231.7476
pbCDDPIG2_2 4.000007 231.8366
pbCDDPIG2_1 4.000001 231.8367
pbCDDPIG2_5 4.000008 231.8367
pbCDDGP2_1  4.000002 232.0602
pbCDDGP2_5 4.000008 232.0603
pbCDDGP2_2  4.000006 232.0603
pbCDDNB2_1  4.000001 232.6547
pbCDDNB2_5 4.000017 232.6548
pbCDDNB2_2 4.000016 232.6548
pbCDDPIG2_3 4.000001 233.4694
pbCDDPIG2_4 4.000015 233.4696
pbCDDPIG2_6 4.000015 233.4705
pbCDDNB2_3 4.000001 233.9296
pbCDDNB2_6 4.000018 233.9296
pbCDDNB2_4 4.000017 233.9307
pbCDDGP2_3 4.000002 233.9373
pbCDDGP2_6 4.000015 233.9374
pbCDDGP2_4 4.000013 233.9374
pbCDDNB2_8 5.000001 234.0696
pbCDDNB2_7 5.000041 234.0697

Family: c("NBI", "Negative Binomial type I")
Call: gamlss(formula = CDD ~ t, sigma.formula = ~cs(t), family =
NBI,
  data = dataku, method = RS(), trace = FALSE)
```

Lampiran 26 Hasil Pemodelan CDD di Stasiun Eltari (Lanjutan)

```
Fitting method: RS()

-----
Mu link function: log
Mu Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) 5.164465 0.086320 59.829 < 2e-16 ***
t -0.065420 0.008003 -8.174 1.07e-06 ***
---
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

-----
Sigma link function: log
Sigma Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) -2.82469 0.71383 -3.957 0.00143 **
cs(t) 0.14551 0.05662 2.570 0.02223 *
---
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

-----
NOTE: Additive smoothing terms exist in the formulas:
i) Std. Error for smoothers are for the linear effect only.
ii) Std. Error for the linear terms maybe are not accurate.

No. of observations in the fit: 21
Degrees of Freedom for the fit: 7.000574
Residual Deg. of Freedom: 13.99943
at cycle: 9

Global Deviance: 201.9239
AIC: 215.925
SBC: 223.2373
> plot(cscDDNB1_2)
*****
*
Summary of the Randomised Quantile Residuals
mean = 0.1671233
variance = 1.066407
coef. of skewness = -0.221533
coef. of kurtosis = 2.345836
Filliben correlation coefficient = 0.9680193
*****
```

Quantile Residuals

Quantile Residuals

Density Estimate

Normal Q-Q Plot

Lampiran 27 Hasil Pemodelan CDD di Stasiun Tardamu

```
$model0
      df      AIC
CDDPIG0  2 230.4957
CDDGP0   2 230.5225
CDDNB0   2 230.7434

$model1cs
      df      AIC
cSCDDPIG1_1 6.999480 234.9555
cSCDDGP1_1  6.999409 235.3996
cSCDDNB1_1  6.999308 235.9647
cSCDDPIG1_2 7.000698 238.4974
cSCDDNB1_2  6.999352 239.3808
cSCDDGP1_2  6.999292 304.2835

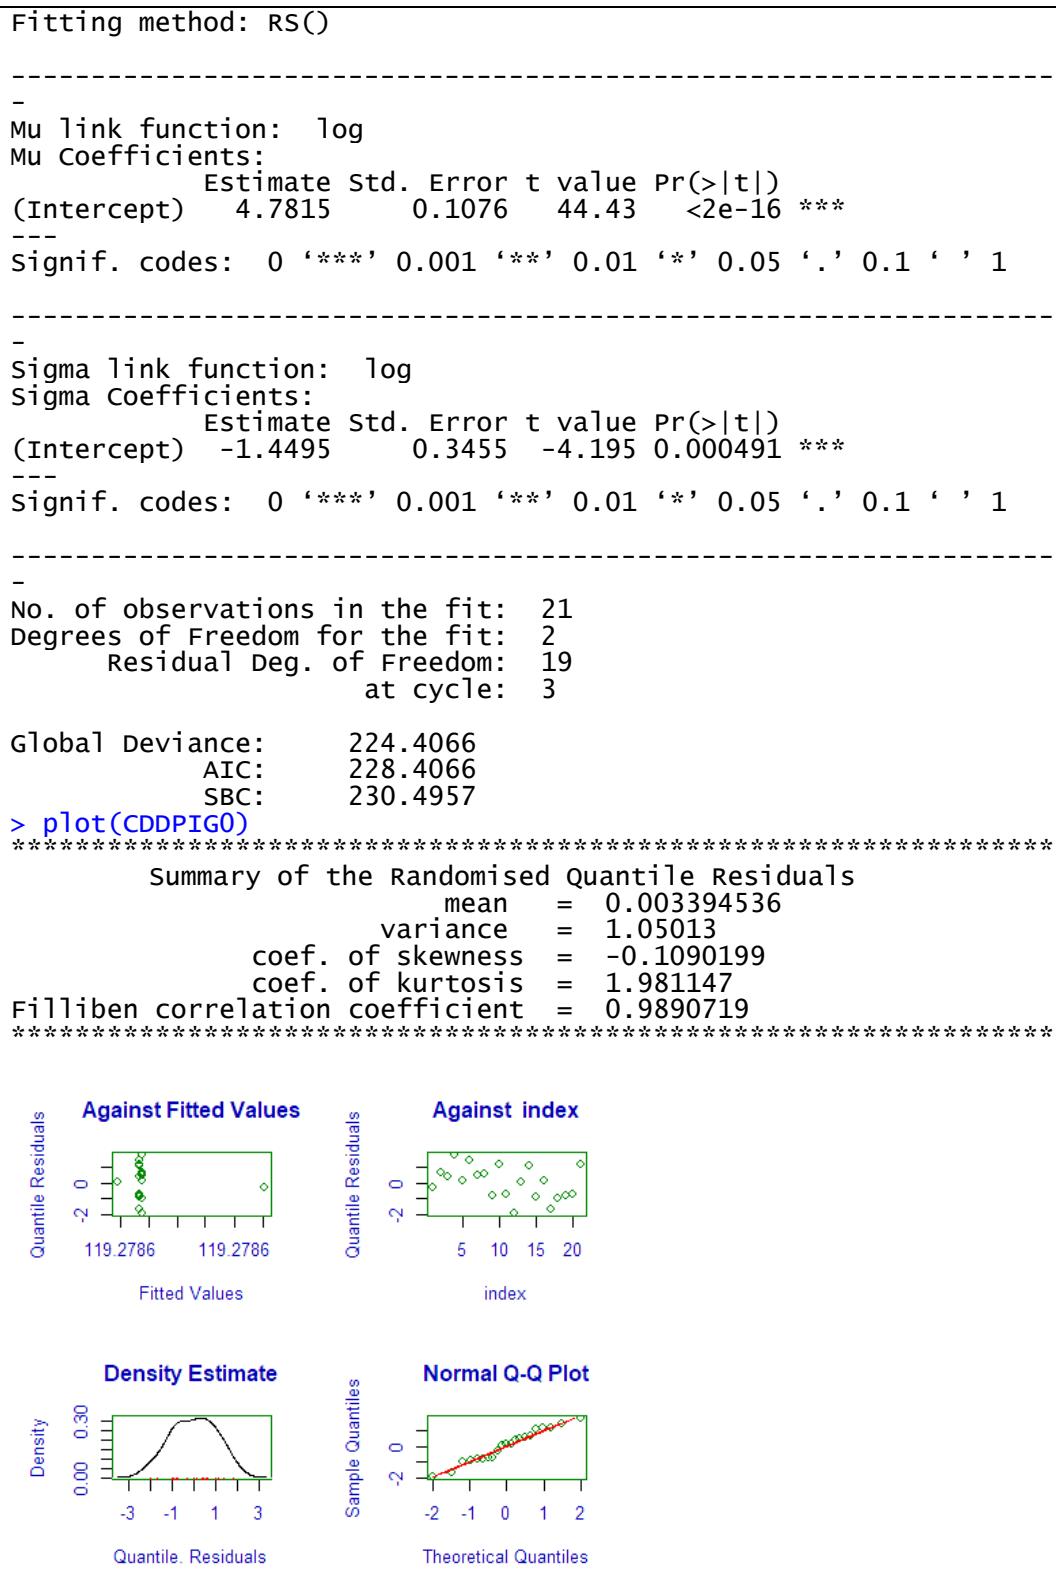
$model1pb
      df      AIC
pbCDDPIG1_2 4.000001 232.6080
pbCDDPIG1_1  4.000033 232.6082
pbCDDNB1_2  4.000002 233.3261
pbCDDNB1_1  4.000029 233.3262
pbCDDGP1_1  4.000001 270.9367
pbCDDGP1_2  4.000001 271.0400

$model2cs
      df      AIC
cSCDDGP2_3 6.999410 236.0448
cSCDDGP2_4 7.000591 236.5171
cSCDDGP2_2 7.000426 236.7151
cSCDDNB2_2 6.999509 238.4987
cSCDDNB2_4 6.999295 238.5519
cSCDDNB2_6 9.999998 242.3352
cSCDDNB2_8 7.999298 242.5027
cSCDDGP2_8 7.999334 243.7748

$model2pb
      df      AIC
pbCDDPIG2_4 4.000016 231.6163
pbCDDPIG2_3 4.000001 231.6164
pbCDDPIG2_6 4.000017 231.6164
pbCDDGP2_3 4.000002 232.0720
pbCDDPIG2_2 4.000012 232.1786
pbCDDPIG2_1 4.000000 232.1787
pbCDDPIG2_5 4.000012 232.1787
pbCDDGP2_1 4.000001 232.7163
pbCDDGP2_5 4.000013 232.7163
pbCDDGP2_2 4.000012 232.7163
pbCDDNB2_6 4.000026 233.0019
pbCDDNB2_4 4.000025 233.0019
pbCDDNB2_3 4.000001 233.0022
pbCDDNB2_1 4.000000 233.7586
pbCDDNB2_5 4.000022 233.7586
pbCDDNB2_2 4.000021 233.7586
pbCDDPIG2_7 5.000029 236.0004
pbCDDPIG2_8 5.000001 236.0005
pbCDDNB2_8 5.000001 237.4862
pbCDDGP2_8 5.000001 272.4295

Family: c("PIG", "Poisson.Inverse.Gaussian")
Call: gamlss(formula = CDD ~ 1, family = PIG, data = dataku,
method = RS(), trace = FALSE)
```

Lampiran 27 Hasil Pemodelan CDD di Stasiun Tardamu (Lanjutan)



(Halaman ini sengaja dikosongkan)

BIODATA PENULIS



Penulis terlahir dengan nama Fausania Hibatullah, biasa dipanggil Sania. Penulis dilahirkan di Surabaya pada tanggal 02 Maret 1996 dan merupakan anak pertama dari pasangan Bapak Moch. Ma'ruf dan Ibu Susi Indrawati, juga merupakan anak pertama dari dua bersaudara. Pendidikan formal yang ditempuh penulis adalah TK Bahrul Ulum Surabaya, SDN Wiyung Surabaya, SMPN 16 Surabaya, dan SMAN 15 Surabaya. Setelah lulus dari SMA, penulis diterima di jalur reguler tes masuk DIII di ITS Surabaya tepatnya di program Studi Diploma III Departemen Statistika. Selama kuliah, penulis aktif di

Himpunan Mahasiswa Diploma Statistika ITS (HIMADATA-ITS) dan menjabat menjadi *staff* departemen kewirausahaan pada tahun kedua perkuliahan (periode 2014-2015) hingga akhirnya menjadi Ketua Biro Riset dan Pengembangan Departemen KWU HIMADATA-ITS pada tahun ketiga (periode 2015-2016). Aktifitas lain dari penulis selama kuliah adalah pernah menjadi asisten dosen pada mata kuliah Metode Regresi, Eksperimen Desain dan Biostatistika. Setelah lulus pendidikan Diploma pada tahun 2016, penulis melanjutkan kuliah untuk program Sarjana Lintas Jalur di Statistika ITS. Pada tahun 2018, penulis berkesempatan menjadi Finalis Pekan Ilmiah Mahasiswa Nasional (PIMNAS) ke-30 pada bidang Penelitian Sosial Humaniora (PKM-PSH). Setelah lulus pendidikan Sarjana pada tahun 2018, penulis melanjutkan kuliah untuk program Magister di Statistika ITS dengan mendapatkan beasiswa *fresh graduate* dari ITS. Aktivitas penulis selama kuliah pada program pascasarjana adalah mengerjakan beberapa penelitian dalam bidang cuaca dan iklim bersama dengan Bapak Dr. rer. pol. Heri Kuswanto, M.Si, Bagi penulis, berbagi ilmu sama halnya dengan memperkaya diri baik dari segi keilmuan ataupun berkah yang akan didapatkan dari Allah SWT. Penulis terbuka atas segala kritik, saran maupun pertanyaan terkait Tesis ini melalui alamat email fausaniah@gmail.com. Terima kasih.

(Halaman ini sengaja dikosongkan)