



TESIS - KS185411

**PERBANDINGAN METODE KOREKSI BIAS DAN  
STATISTICAL DOWNSCALING PADA DATA LUARAN  
EARTH SYSTEM MODELS UNTUK PROYEKSI IKLIM  
(Studi kasus: Curah Hujan dan Temperatur Maksimum di Indonesia)**

**FATKHUROKHMAN FAUZI  
06211750012006**

**Dosen Pembimbing  
Dr.rer.pol. Heri Kuswanto, M.Si  
R. Mohamad Atok, M.Si., Ph.D**

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



TESIS - KS185411

**PERBANDINGAN METODE KOREKSI BIAS DAN  
STATISTICAL DOWNSCALING PADA DATA LUARAN  
EARTH SYSTEM MODELS UNTUK PROYEKSI IKLIM  
(Studi Kasus: Curah Hujan dan Temperatur Maksimum di Indonesia)**

**FATKHUROKHMAN FAUZI  
06211750012006**

**Dosen Pembimbing  
Dr.rer.pol. Heri Kuswanto, M.Si  
R. Mohamad Atok, M.Si., Ph.D**

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



THESIS - KS185411

**COMPARISON OF BIAS CORRECTION AND STATISTICAL  
DOWNSCALING METHODS IN OUTPUT EARTH SYSTEM  
MODELS DATA FOR CLIMATE PROJECTION**

(Case Study: Rainfall and Maximum Temperature in Indonesia)

**FATKHUROKHMAN FAUZI**  
**06211750012006**

**Supervisor**  
**Dr.rer.pol. Heri Kuswanto, M.Si**  
**R. Mohamad Atok, M.Si., Ph.D**

**Department of Statistics**  
**Faculty of Science and Data Analytics**  
**Institut Teknologi Sepuluh Nopember**  
**2020**



## LEMBAR PENGESAHAN TESIS

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar

**Magister Statistika (M.Stat)**

di

**Institut Teknologi Sepuluh Nopember**

Oleh:

**FATKHUROKHMAM FAUZI**

**NRP: 06211750012006**

Tanggal Ujian: 24 Januari 2020

Periode Wisuda: Maret 2020

Disetujui oleh:

**Pembimbing:**

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

2. R. Mohamad Atok, M.Si., Ph.D  
NIP: 19710915 199702 1 001

**Penguji:**

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

2. Dr. Agus Suharsono, MS  
NIP: 19580823 198403 1 003



**Kepala Departemen Statistika  
Fakultas Sains dan Analitika Data**

Dr. Dra. Kartika Fitriyasi, M.Si

NIP: 19691212 199303 2 002

*(Halaman ini sengaja dikosongkan)*

**PERBANDINGAN METODE KOREKSI BIAS DAN  
STATISTICAL DOWNSCALING PADA DATA LUARAN EARTH  
SYSTEM MODELS UNTUK PROYEKSI IKLIM**  
**(Studi Kasus: Curah Hujan dan Temperatur Maksimum di  
Indonesia)**

Nama Mahasiswa : Fatkhurokhman Fauzi  
NRP : 06211750012006  
Dosen Pembimbing : Dr.rer.pol. Heri Kuswanto, M.Si  
R. Mohamad Atok, M.Si., Ph.D

**ABSTRAK**

*Earth System Models* (ESM) adalah model yang dapat mensimulasikan, memprediksi perubahan iklim yang terjadi di masa lalu, sekarang, dan membuat skenario perubahan iklim di masa depan. Luaran ESM belum mampu mewakili iklim skala lokal. *Statistical Downscaling* (SD) adalah proses penurunan skala statis data pada grid skala besar dengan acuan grid skala kecil (skala lokal). Hasil SD masih memiliki bias yang cukup besar, dibutuhkan suatu metode yang berfungsi untuk mengurangi bias. Metode koreksi bias yang digunakan dalam penelitian ini adalah *Quantile Delta Mapping* (QDM), *Analogues with Quantile Mapping Reordering* (BCCAQ), dan *Inter-Sectoral Impact Model Intercomparison Project* (ISIMIP). Penelitian ini menurunkan skala (*downscale*) dan koreksi bias pada data curah hujan dan temperatur maksimum luaran ESM skenario *historical*, G4, dan RCP4.5 terhadap data ERA-Interim sebagai proksi pengamatan bersekala lokal. *Skill* dari metode koreksi bias QDM, BCCAQ, dan ISIMIP pada data skenario *historical* akan dievaluasi menggunakan diagram Taylor. *Skill* metode koreksi bias terbaik pada data *historical* akan diterapkan untuk proyeksi iklim pada data skenario G4 dan RCP4.5. Berdasarkan diagram Taylor ISIMIP memiliki *skill* yang lebih baik dibandingkan dengan metode koreksi bias QDM dan BCCAQ pada region 1, region 2, dan region 3 serta musiman dan non-musiman. Periode musiman yang memiliki *skill* terbaik adalah periode musiman September-Oktober-November (SON). Region yang memiliki *skill* terbaik adalah region 1. Hasil proyeksi iklim pada curah hujan skenario G4 dan RCP4.5 sangat fluktuatif, sedangkan pada temperatur maksimum skenario G4 memiliki temperatur maksimum lebih rendah dibandingkan dengan skenario RCP4.5 pada tahun 2020-2070. Skenario G4 berhasil menurunkan temperatur bumi khususnya di Indonesia pada tahun 2020-2070 sebesar 0-2°C.

Kata Kunci: Koreksi Bias, *Downscaling*, ESM, Diagram Taylor, Proyeksi Iklim.

*(Halaman ini sengaja dikosongkan)*

# **COMPARISON OF BIAS CORRECTION AND STATISTICAL DOWNSCALING METHODS IN OUTPUT EARTH SYSTEM MODELS DATA FOR CLIMATE PROJECTION**

## **(Case Study: Rainfall and Maximum Temperature in Indonesia)**

Name	:	Fatkurokhman Fauzi
NRP	:	06211750012006
Supervisor	:	Dr.rer.pol. Heri Kuswanto, M.Si
Co-Supervisor	:	R. Mohamad Atok, M.Si., Ph.D

## **ABSTRACT**

Earth System Models (ESM) are models that can simulate, predict climate change that occurred in the past, present, and create climate change scenarios in the future. ESM outputs have not been able to represent local-scale climate. Statistical Downscaling (SD) is the process of decreasing the static scale of data on a large scale grid by referring to a small scale grid (local scale). SD results still have a large enough bias, we need a method that works to reduce bias. The bias correction methods used in this study are Quantile Delta Mapping (QDM), Analogues with Quantile Mapping Reordering (BCCAQ), and Inter-Sectoral Impact Model Intercomparison Project (ISIMIP). This study downscale and corrected bias in the rainfall data and the maximum temperature of the ESM output historical, G4, and RCP4.5 scenarios to the ERA-Interim data as a proxy for local-scale observations. The skills of the QDM, BCCAQ, and ISIMIP bias correction methods on historical scenario data will be evaluated using the Taylor diagram. The best bias correction method skills on historical data will be applied to climate projections on G4 and RCP4.5 scenario data. Based on Taylor's diagram, ISIMIP has better skills compared to the QDM and BCCAQ bias correction methods in region 1, region 2, and region 3 as well as seasonal and non-seasonal. The seasonal period that has the best skills is the September-October-November (SON) seasonal period. The region with the best skills is region 1. The results of the climate projection in the G4 and RCP4.5 rainfall scenarios are very volatile, whereas in the maximum temperature the G4 scenario has a lower maximum temperature compared to the RCP4.5 scenario in 2020-2070. The G4 scenario succeeded in reducing the earth's temperature, especially in Indonesia in 2020-2070 by 0-2°C.

Keywords: Bias Correction, Downscaling, ESM, Taylor Diagram, Climate Projection.

*(Halaman ini sengaja dikosongkan)*

## KATA PENGANTAR

Puji dan syukur penulis panjatkan kepada Allah SWT atas segala karunia-Nya sehingga penulis dapat menyelesaikan penyusunan Tesis yang berjudul “Perbandingan Metode Koreksi Bias dan *Statistical Downscaling* pada Data Luaran *Earth System Models* untuk Proyeksi Iklim (Studi Kasus: Curah Hujan dan Temperatur maksimum di Indonesia)”. Penyusunan Tesis ini merupakan kewajiban akademis sebagai salah satu syarat untuk menyelesaikan pendidikan Program Magister Statistika pada Program Pasca Sarjana Institut Teknologi Sepuluh Nopember, Surabaya.

Dalam penyusunan tesis ini, penulis banyak memperoleh bimbingan dan petunjuk, serta bantuan dan dukungan dari berbagai pihak baik dari institusi maupun luar institusi. Melalui kesempatan ini penulis mengucapkan terimakasih yang sebesar-besarnya kepada yang terhormat:

1. Ayahanda Masturi dan Ibunda Khuripah atas semangat, kasih sayang dan doa yang tidak pernah putus kepada penulis.
2. Bapak Dr.rer.pol. Heri Kuswanto, M.Si dan Bapak R. Mohamad Atok, M.Si., Ph.D selaku dosen pembimbing yang telah meluangkan waktu untuk memberikan ilmu, bimbingan, dan arahan dalam menyelesaikan tesis ini.
3. Bapak Dr.rer.pol. Dedy Dwi Prastyo, M.Si dan Bapak Dr. Agus Suharsono, MS. selaku dosen penguji yang telah memberikan saran serta perbaikan dalam tesis ini.
4. Ibu Dr. Dra. Kartika Fithriasari, M.Si selaku ketua Departemen Statistika FSAD ITS.
5. Bapak Dr.rer.pol. Dedy Dwi Prastyo, M.Si selaku Ketua Program Studi Pascasarjana Departemen Statistika ITS.
6. Seluruh Bapak/Ibu Dosen pengajar, staf administrasi, dan staf perpustakaan Jurusan Statistika ITS yang berkenan memberikan waktu dan bantuan.
7. Adik-adikku, Ismi Hilmiyati dan Irfan Nur Fakhrudin yang tidak berhenti mendoakan dan dukungan kepada penulis.

8. Teman-teman seperjuangan mahasiswa Magister Statistika ITS Angkatan 2017 Genap Selly Acita, Gabriella H.W, R.J. Mega P, Aisyah A., Meirinda F, Marsuddin Musa, Romy Yunika P, dan Ilhamna Aulia atas dukungan, motivasi, dan kebersamaan selama menempuh pendidikan bersama.
9. *Mathematic Computing Club* (MCC) UNNES Lab. Matematika yang telah memberikan dukungan, bantuan, dan motivasi terhadap penulis.
10. Teman-teman penulis Arip, Ikhsan, Sony, Brina, Indira Ihnu, Siska, Yoga, Moko, dan Trimono yang selalu memberikan motivasi dan bantuan terhadap penulis.
11. Semua pihak yang telah membantu dalam penulisan Tesis ini yang tidak dapat penulis sebutkan satu per satu.

Penulis menyadari masih terdapat kekurangan pada Tesis ini. Oleh karena itu, saran dan kritik dari semua pihak yang bersifat membangun sangat penulis harapkan demi kesempurnaan penulisan selanjutnya.

Surabaya, 24 Januari 2020

Fatkhurowkhman Fauzi

## DAFTAR ISI

	Halaman
<b>HALAMAN JUDUL .....</b>	i
<b>TITLE PAGE .....</b>	iii
<b>LEMBAR PENGESAHAN TESIS .....</b>	v
<b>ABSTRAK .....</b>	vii
<b>ABSTRACT .....</b>	ix
<b>KATA PENGANTAR.....</b>	xi
<b>DAFTAR ISI.....</b>	xiii
<b>DAFTAR GAMBAR.....</b>	xvii
<b>DAFTAR TABEL .....</b>	xix
<b>DAFTAR LAMPIRAN .....</b>	xxi
<b>BAB 1 PENDAHULUAN .....</b>	1
1.1.    Latar Belakang.....	1
1.2.    Rumusan Masalah.....	6
1.3.    Tujuan Penelitian .....	7
1.4.    Manfaat Penelitian .....	7
1.5.    Batasan Masalah .....	8
<b>BAB 2 TINJAUAN PUSTAKA.....</b>	9
2.1. <i>Bias Correction/Constructed Analogues with Quantile mapping Reordering.....</i>	9
2.2. <i>Constucted Analogues.....</i>	10
2.3. <i>Climate-Imprint .....</i>	13
2.3.1.    Curah Hujan .....	13
2.3.2.    Temperatur .....	13
2.4. <i>Quantile Mapping .....</i>	14
2.5. <i>Quantile Delta Mapping .....</i>	15
2.6. <i>Ensemble Copula Coupling .....</i>	17
2.6.1.    Pendekatan ECC .....	18
2.6.2.    Interpretasi <i>Empirical Copula</i> .....	19

2.6.3. ECC-Q, ECC-R dan ECC-T .....	20
2.7. <i>Inter-Sectoral Impact Model Intercomparison Project (ISIMIP)</i> ....	21
2.7.1. Koreksi Data Rata-Rata Bulanan.....	22
2.7.1.1. Temperatur: Additive Correction .....	22
2.7.1.2. Curah Hujan: Multiplicative Correction .....	23
2.7.2. Koreksi Variabilitas Harian.....	23
2.7.2.1. Temperatur dalam regresi linier .....	24
2.7.2.2. Curah Hujan: regresi nonlinier .....	25
2.7.3. Aplikasi dari Koreksi Bias.....	29
2.7.3.1. Temperatur .....	29
2.7.3.2. Curah Hujan .....	30
2.8. Metode Evaluasi <i>Skill</i> .....	32
2.9. <i>Earth System Model</i> .....	34
2.10. <i>Downscaling</i> .....	39
2.11. Indeks Iklim Ekstrim.....	41
<b>BAB 3 METODOLOGI PENELITIAN .....</b>	<b>43</b>
3.1. Sumber Data.....	43
3.2. Variabel Penelitian .....	43
3.3. Struktur Data .....	45
3.4. Tahapan Analisis .....	47
3.5. Diagram Alir Penelitian .....	50
<b>BAB 4 ANALISIS DAN PEMBAHASAN .....</b>	<b>51</b>
4.1. Statistika Deskriptif Data Curah Hujan dan Temperatur Maksimum .....	51
4.1.1. Pembagian Zona .....	51
4.1.2. Plot Data Skenario <i>Historical</i> dan ERA-Interim ECMWF .....	52
4.1.3. Peta Sebelum dan Sesudah dilakukan Downscaling dan Bias Koreksi .....	57
4.2. Evaluasi <i>Skill</i> .....	63
4.2.1. Peta Korelasi dan Peta RMSE Curah Hujan dan Temperatur Maksimum .....	64

4.2.2. Taylor Diagram .....	75
4.3. Poyeksi Iklim Skenario G4 dan RCP4.5.....	85
<b>BAB 5 KESIMPULAN DAN SARAN.....</b>	<b>93</b>
5.1. Kesimpulan .....	93
5.2. Saran .....	94
<b>DAFTAR PUSTAKA .....</b>	<b>95</b>
<b>LAMPIRAN.....</b>	<b>99</b>
<b>BIODATA PENULIS.....</b>	<b>117</b>

*(Halaman ini sengaja dikosongkan)*

## DAFTAR GAMBAR

	Halaman
Gambar 2. 1 <i>Downscale Construted Analogues</i> (Sumber: Hidalgo dkk., 2008) ..	11
Gambar 2. 2 Diagram Taylor (Sumber: Taylor, 2001) .....	33
Gambar 2. 3 Struktur Dasar ESM. ....	35
Gambar 2. 4 Fitur Utama dari Model Iklim dan Earth System Models.....	35
Gambar 2. 5 Perubahan Rata-Rata Temperatur Global CMIP5 <i>Historical</i> (1900-2005), RCP2.6 (Biru Tua), RCP 4.5 (Biru Muda), RCP6.0 (Orange), dan RCP8.5 (Merah) .....	37
Gambar 2. 6 Alur <i>Climate Projection</i> .....	37
Gambar 2. 7 Skenario Injeksi SO <sub>2</sub> Skenario G4 .....	39
Gambar 2. 8 Ilustrasi <i>downscaling</i> .....	40
Gambar 2. 9 Ilustrasi Komponen yang Terlibat dalam Pengembangan Proyeksi Iklim Global dan Regional.....	40
Gambar 4. 1 Pembagian Zonan Iklim di Indonesia.....	51
Gambar 4. 2 <i>Time Series Plot</i> Rata-rata Curah Hujan Bulanan (mm <sup>2</sup> ).....	53
Gambar 4. 3 <i>Time Series Plot</i> Rata-rata Curah Hujan Perbulan (mm <sup>2</sup> ).....	54
Gambar 4. 4 <i>Time Series Plot</i> Rata-rata Temperatur maksimum Bulanan (°C) ...	56
Gambar 4. 5 <i>Time Series Plot</i> Rata-rata Temperatur maksimum Perbulan (°C) ..	57
Gambar 4. 6 Peta Curah Hujan Observasi ERA-Interim ECMWF, Skenario Historical Model BNU-ESM Sebelum dan Sesudah Koreksi Bias. ..	58
Gambar 4. 7 Peta Curah Hujan Observasi ERA-Interim ECMWF, Skenario Historical Model MIROC-ESM Sebelum dan Sesudah Koreksi Bias. .....	59
Gambar 4. 8 Peta Curah Hujan Observasi ERA-Interim ECMWF, Skenario Historical Model MIROC-ESM-CHEM Sebelum dan Sesudah Koreksi Bias.....	60
Gambar 4. 9 Peta Temperatur Maksimum Observasi ERA-Interim ECMWF, Skenario Historical Model BNU-ESM Sebelum dan Sesudah Koreksi Bias.....	61

Gambar 4. 10 Peta Temperatur Maksimum Observasi ERA-Interim ECMWF, Skenario Historical Model MIROC-ESM Sebelum dan Sesudah Koreksi Bias .....	62
Gambar 4. 11 Peta Temperatur Maksimum Observasi ERA-Interim ECMWF, Skenario Historical Model MIROC-ESM-CHEM Sebelum dan Sesudah Koreksi Bias.....	63
Gambar 4. 12 Peta Korelasi dan Peta RMSE Curah Hujan Model MIROC-ESM .....	65
Gambar 4. 13 Peta Korelasi dan Peta RMSE Curah Hujan Model BNU-ESM ...	66
Gambar 4. 14 Peta Korelasi dan Peta RMSE Curah Hujan Model BNU-ESM ....	67
Gambar 4. 15 Peta Korelasi dan RMSE Temperatur Maksimum Model BNU-ESM.....	70
Gambar 4. 16 Peta Korelasi dan RMSE Temperatur Maksimum Model MIROC-ESM .....	72
Gambar 4. 17 Peta Korelasi dan RMSE Temperatur Maksimum Model MIROC-ESM .....	73
Gambar 4. 18 Diagram Taylor Curah Hujan Model BNU-ESM.....	76
Gambar 4. 19 Diagram Taylor Curah Hujan Model MIROC-ESM .....	78
Gambar 4. 20 Diagram Taylor Curah Hujan Model MIROC-ESM-CHEM. ....	79
Gambar 4. 21 Diagram Taylor Temperatur Maksimum Model BNU-ESM .....	81
Gambar 4. 22 Diagram Taylor Temperatur Maksimum Model MIROC-ESM....	83
Gambar 4. 23 Diagram Taylor Temperatur Maksimum Model MIROC-ESM-CHEM. ....	84
Gambar 4. 24 <i>Time Series Plot</i> Indeks Ekstrim Rx1day .....	86
Gambar 4. 25 <i>Time Series Plot</i> Indeks Ekstrim TXx .....	88
Gambar 4. 26 <i>Time Series Plot</i> G4-RCP4.5 untuk Setiap Model Skenario G4 dan RCP4.5 .....	89
Gambar 4. 27 <i>Time Series Plot</i> untuk Mengetahui Perubahan Skenario G4 dan RCP4.5 Terhadap Rata-Rata Skenario Historical.....	90
Gambar 4. 28 Peta Selisih Temperatur Maksimum antara G4 dan RCP4.5 dengan Historical Model BNU-ESM.....	91

## **DAFTAR TABEL**

	Halaman
Tabel 2. 1 Skenario RCP.....	36
Tabel 2. 2 Skenario GeoMIP.....	38
Tabel 2. 3 Indeks Ekstrim ETCCDI.....	41
Tabel 3. 1 Model Luaran ESM.....	44
Tabel 3. 2 Struktur Data Skenario <i>Historical</i> Model BNU-ESM .....	45
Tabel 3. 3 Struktur Data ECMWF .....	46

*(Halaman ini sengaja dikosongkan)*

## **DAFTAR LAMPIRAN**

Halaman

Lampiran 1. Link Data Hasil Downscaling dan Bias Koreksi untuk Curah Hujan.....	99
Lampiran 2. Link Data Hasil Downscaling dan Bias Koreksi untuk Temperatur Maksimum.....	100
Lampiran 3 <i>Syntax Crop</i> Data untuk Wilayah Indonesia .....	101
Lampiran 4. <i>Syntax</i> Menggabungkan File NetCDF.....	104
Lampiran 5. <i>Syntax Downscaling</i> dan Koreksi Bias Menggunakan QDM dan BCCAQ .....	107
Lampiran 6. <i>Syntax ISIMIP</i> .....	108
Lampiran 7. <i>Syntax convert</i> NetCDF ke Excel (.csv) .....	109
Lampiran 8. <i>Syntax</i> korelasi dan RMSE untuk Peta .....	110
Lampiran 9. <i>Syntax Taylor Diagram</i> .....	111
Lampiran 10. <i>Syntax</i> Fungsi Creat Map (Membuat Peta).....	113
Lampiran 11. <i>Syntax</i> fungsi IndonesianMap.....	114
Lampiran 12. <i>Syntax</i> fungsi Map .....	114
Lampiran 13. Surat Ijin Penggunaan Data .....	115

*(Halaman ini sengaja dikosongkan)*

# **BAB I**

## **PENDAHULUAN**

### **1.1. Latar Belakang**

Cuaca dan iklim sangat penting bagi kelangsungan hidup manusia. Banyak sektor yang berelasi langsung dengan iklim diantaranya perkebunan, pertanian, dan transportasi. Perlu perkiraan yang tepat terkait iklim, untuk keberlangsungan sektor tersebut. Beberapa tahun terakhir iklim mengalami perubahan antara lain temperatur dan curah hujan, sehingga memberi dampak pada berbagai sektor. Informasi mengenai cuaca dalam bidang pertanian dan perkebunan sangat penting demi memperoleh hasil panen yang maksimal serta menentukan pola dan varietas tanaman yang akan ditanam. Hal ini dikarenakan cuaca sangat berpengaruh terhadap ketersediaan air. Proporsi ketersediaan air harus terus dijaga agar tetap seimbang, apabila ketersediaan air kurang akan berdampak kekeringan, sedangkan apabila kelebihan air akan membanjiri lahan pertanian.

Indonesia terletak pada  $5^{\circ} LU - 10^{\circ} LS$ ,  $94^{\circ} BT - 141^{\circ} BT$  merupakan negara yang terletak di garis lintang katulistiwa antara Asia Tengara dan Australia, serta di garis bujur antara Samudra Pasifik dan Samudra Hindia yang menyebabkan Indonesia hanya mempunyai dua musim yaitu musim hujan dan musim kemarau. Masyarakat Indonesia sebagian besar bekerja atau mempunyai usaha dalam bidang pertanian dan perkebunan, terutama pulau Jawa. Pulau Jawa merupakan pulau yang mempunyai lahan sawah terbesar di Indonesia. Berdasarkan data BPS tahun 2016 Provinsi Jawa Timur merupakan provinsi dengan luas lahan sawah terbesar yaitu 1.087.018 ha, diikuti provinsi Jawa Tengah 963.665 ha, dan provinsi Jawa Barat 913.976 ha. Luas lahan sawah berbanding lurus dengan luas panen. Tercatat berdasarkan data BPS tahun 2015 51,69% produksi padi, 54,12% produksi jagung, 65,30% produksi kacang hijau, 78,59% produksi kacang tanah, 62,28% produksi kedelai, di Indonesia berasal dari provinsi yang berada di pulau Jawa.

Sebelum terjadinya efek rumah kaca di bumi, masyarakat mampu memprediksi musim yang akan berlangsung dengan melihat pola kejadian pada tahun-tahun sebelumnya. Efek rumah kaca disebabkan karena meningkatnya

konsentrasi gas karbon dioksida ( $\text{CO}_2$ ) dan gas-gas lainnya di atmosfer. Meningkatnya konsentrasi gas  $\text{CO}_2$  ini disebabkan oleh banyaknya pembakaran bahan bakar minyak, batu bara dan bahan bakar organik lainnya yang melebihi kemampuan tumbuhan-tumbuhan dan laut untuk menyerapnya. Dampak terjadinya efek rumah kaca diantaranya *global warming*, mencairnya es di kutub, meningkatnya ketinggian air laut, laut menjadi semakin asam, dan berkurangnya lapisan ozon, selain itu juga menyebabkan frekuensi atau intensitas cuaca ekstrim. Menurut penemuan *Intergovernmental Panel on Climate Change* (IPCC) menunjukkan bahwa perbedaan kenaikan suhu sebesar setengah derajat memiliki dampak yang sangat besar. Badan yang meneliti tentang iklim IPCC mengkaji bahwa perbedaan dampak kenaikan temperatur dibawah  $1,5^\circ\text{C}$  dan  $2^\circ\text{C}$  menimbulkan dampak yang parah bagi dunia. Oleh karena itu, dibutuhkan kesigapan pemerintah untuk menanggulangi efek rumah kaca.

*Solar Radiation Management* (SRM atau *solar geoengineering*) adalah pendekatan teoritis untuk mengurangi beberapa dampak perubahan iklim dengan memantulkan sejumlah kecil sinar matahari yang masuk kembali ke luar angkasa. *Solar Radiation Management* (SRM) dilakukan dengan cara melakukan *bloking* terhadap sejumlah sinar matahari untuk mendinginkan bumi, contohnya dengan menyemprotkan partikel-partikel pemantul di atmosfer. Kravitz dkk (2011) meneliti dampak SRM dan melakukan percobaan terhadap 4 skenario GeoMIP yaitu G1, G2, G3, dan G4. Ji dkk (2018) meneliti tentang suhu ekstrim dan respons curah hujan terhadap peredupan matahari dan *geoengineering aerosol stratosfer*. Penelitian tentang *solar geoengineering* juga dilakukan oleh Jones dkk, (2018) tentang dampak iklim regional dari stabilisasi pemanasan global pada  $1,5^\circ\text{K}$  menggunakan *solar geoengineering*.

Selama beberapa tahun terakhir, musim tahunan dirubah oleh kondisi berskala besar yang terkait peristiwa *El-Nino-Southern Oscilation* (ENSO) secara bersamaan (Aldrian dan Susanto, 2003). El-Nino paling kuat terkait dengan curah hujan di Indonesia terutama di pulau bagian selatan khatulistiwa (Jawa Bali, dan Nusa Tenggara) selama musim kemarau (Juni-Agustus) dan transisi (September-November), dan sebagian besar tidak terkait dengan variasi curah hujan selama

puncak musim hujan (Desember-Februari) (Hendon dan Liebmann, 2002). Naylor dkk. (2007) dan Falcon dkk. (2004) menunjukkan bahwa ENSO menjadi penentu utama dari variabel produksi padi di Indonesia dari tahun ke tahun selama tiga dekade terakhir. Bahan pokok makanan Indonesia dipengaruhi oleh curah hujan yang tertunda akibat peristiwa *El-Nino* sehingga terjadi paceklik dan kelangkaan produksi padi (Vimont dkk., 2009).

Diperlukan suatu model yang dapat mensimulasikan iklim, memprediksi perubahan-perubahan iklim yang terjadi pada masa lampau, sekarang, dan membuat skenario perubahan iklim masa yang akan datang dengan melibatkan data skala besar seperti *Earth System Models* (ESM). Dibandingkan dengan generasi model sebelumnya, ESM ini menggabungkan komponen tambahan yang menggambarkan interaksi atmosfer dengan penggunaan lahan dan vegetasi, serta secara eksplisit memperhitungkan kimia atmosfer, aerosol, dan siklus karbon atmosfer (Taylor dkk., 2012). Luaran ESM masih berskala global, belum mampu merepresentasikan iklim berskala lokal. Indonesia merupakan negara tropis yang pembentukan hujan dipengaruhi oleh topografi dan interaksi antara laut, darat dan atmosfer yang kompleks, sehingga menyebabkan terdapat kendala dalam membuat simulasi untuk memprediksi curah hujan. Geografis negara Indonesia mengarah pada angin darat dan laut skala kecil yang mempengaruhi skala diurnal dan intensitas rata-rata konveksi (Qian, 2008).

Resolusi yang dimiliki oleh data luaran ESM dianggap terlalu rendah sehingga menyulitkan untuk memprediksi curah hujan regional yang membutuhkan resolusi yang tinggi, diperlukan penurunan skala spasial dan koreksi bias pada luaran ESM. Terdapat teknik yang sering digunakan dalam dunia klimatologi untuk menurunkan skala spasial sampai ketingkat regional yaitu *downscaling*. Teknik *downscaling* merupakan teknik yang berfungsi mentransformasikan grid dengan unit berskala besar menjadi data pada grid-grid dengan unit berskala lebih kecil (Wigena, 2006). Terdapat dua jenis teknik *downscaling* yaitu *dynamic downscaling* dan *statistical downscaling*. *Statistical Downscaling* (SD) adalah proses *downscaling* yang bersifat statik dimana data pada grid-grid berskala besar dalam periode dan jangka waktu tertentu digunakan sebagai dasar untuk menentukan data pada grid berskala kecil (Wigena, 2006).

Metode *downscaling* memberikan cara yang efisien dan efektif secara komputasi untuk menghasilkan hidroklimatologi yang masuk akal dari ansambel besar (Salath dkk., 2007). Metode *downscaling* yang paling sederhana dan gampang dilakukan adalah metode interpolasi. Beberapa penelitian tentang statistik *downscaling* diantaranya Hunter dan Eentemeyer (2005) membandingan metode interpolasi dengan metode *climate-imprint* dalam menurunkan skala GCM hujan dan temperatur di California dalam kurun waktu 24 tahun, hasil yang didapatkan bahwa penurunan skala dengan metode *climate-imprint* memiliki nilai MAE untuk prediksi curah hujan harian adalah  $\pm 2,5$  mm, dengan bias 0,01, sedangkan MAE untuk prediksi *maksimal* dan *minimum* temperatur adalah  $\pm 1,7^\circ$  dan  $\pm 2,00^\circ\text{C}$  sedangkan biasnya adalah  $-0,41^\circ$  dan  $-0,38^\circ\text{C}$ .

Dalam beberapa tahun terakhir berkembang metode yang menggabungkan antara *statistical downscaling* dengan koreksi bias, dengan tujuan memperkecil bias hasil *downscaling* agar lebih *representative* terhadap iklim lokal Wood dkk., (2004) membandingkan tiga metode *downscaling* yaitu interpolasi linier, disagregasi spasial (SD), dan *bias-correction and spatial disaggregation* (BCSD) pada curah hujan pada dua model output iklim yaitu *Parallel Climate Model* (PCM) dan hasil *downscaling* dinamis *Regional Climate Model* (RCM). Output model tersebut akan dilakukan *downscale* terhadap resolusi  $1/8^\circ$ . Hasil yang diperoleh bahwa interpolasi linier menghasilkan hasil yang lebih baik output RCM dari pada PCM, tetapi metode interpolasi linier menghasilkan bias yang tidak bisa ditolerir. Metode BCSD mampu menghasilkan hasil yang masuk akal secara hidrologis. Model output RCM lebih *sensitive* terhadap perubahan iklim.

Bias koreksi dianggap mampu meminimalisir bias yang terdapat dalam data output GCM maka Piani, Haerter, dan Coppola (2010) mengembangkan metode bias koreksi yaitu *quantile mapping*. *Quantile mapping* mampu mengoreksi bias luaran GCM dengan baik. Maraun (2013) menerapkan *quantile mapping* untuk mengoreksi bias luaran GCM pada model RCM REMO dari *institute of Meteorology* (Jacob, 2001). Harsa (2017) melakukan penelitian koreksi bias terhadap data *Climate Hazard Grup* (CHG) dengan dataset *Climate Hazard Infra-Red Precipitation* (CHIRP) dan dibandingakan dengan data *Climate Hazard Infra-*

*Red Precipitation with Station* (CHIRPS). Hasilnya bahwa data CHIRP yang dikoreksi bias dengan data observasi memiliki bias yang lebih kecil dibandingkan dengan dataset CHIRPS. Metode *Statistical Downscaling and Bias Correction* (SDBC) diterapkan untuk menurunkan skala data *maksimal* dan *minimum* temperatur dan curah hujan di Inggris bagian timur laut kedalam skala  $1/8^\circ$  oleh Ahmed dkk (2013). Hasilnya data simulasi luaran RCM berbantuan metode *dynamical downscaling* dan luaran GCM tidak berbeda jauh hasil koreksi biasnya, namun luaran GCM sedikit lebih baik. Maurer dkk (2010) membandingkan 3 metode *statistical downscaling* yang diterapkan pada data NCEP/NCAR *reanalysis* di California. Ketiga metode tersebut adalah BCSD, *Constructed Analogues* (CA), dan metode *hybrid* (BCCA) menggunakan koreksi bias *quantile mapping* pada data skala besar sebelum pendekatan CA. Hasilnya metode BCCA secara konsisten mengungguli metode lain dalam ketampilan *downscale* skala besar kedalam skala kecil.

Hempel dkk. (2013) mengembangkan metode koreksi bias statistik yang merupakan modifikasi dari metode yang dijelaskan oleh Piani, Haerter, dan Coppola (2010), metode tersebut adalah *Inter-Sectoral Impact Model Intercomparison Project* (ISIMIP). Metode ISIMIP dirancang untuk mensintesis proyeksi dampak di sektor pertanian, air, bioma, kesehatan, dan infrastruktur di berbagai tingkat pemanasan global (Hempel dkk., 2013). Metode ISI-MIP telah dikembangkan untuk mempertahankan sinyal perubahan *tren* iklim. Metode ISIMIP juga diterapkan oleh Gusev dkk. (2018) untuk menyelidiki kemungkinan perubahan dalam berbagai karakteristik limpasan sungai tahunan (nilai rata-rata, simpangan baku, frekuensi limpasan tahunan ekstrim) hingga 2100 berdasarkan penerapan model permukaan tanah SWAP dan proyeksi meteorologi yang disimulasikan oleh lima General Circulation Model (GCM) sesuai dengan empat skenario RCP.

Algoritma koreksi bias *quantile mapping* digunakan untuk memperbaiki bias distribusi sistematis dalam *output* curah hujan dari model iklim, meskipun efektif dalam menghilangkan bias namun ditemukan bahwa *quantile mapping* secara artifisial dapat merusak *tren* proyeksi model dimasa depan (Cannon, Sobie,

dan Murdock, 2015). Oleh karena itu (Cannon, Sobie, dan Murdock, 2015) memperkenalkan metode *Quantile Delta Mapping* (QDM) yang secara eksplisit menjaga perubahan *relative* dalam curah hujan. QDM dibandingkan dengan *Detrended Quantile Mapping* (DQM) dan *Standard Quantile Mapping* (QM) pada lima proyeksi curah hujan harian ekstrim *Model Coupling Model Intercomparison Project* (CMIP5). Pada tahun 2080 perubahan *relative* lebih dari +500% sedangkan perubahan maksimal oleh DQM dan QDM masing - masing +240% dan +140%, sedangkan perubahan GCM tidak pernah diproyeksikan melebihi +120%.

*Bias Correction/Constructed Analogues with Quantile Mapping* (BCCAQ) merupakan metode *downscaling hybrid* yang menggunakan output dari CA dan *quantile mapping* pada resolusi skala halus. Werner dan Cannon (2016) menerapkan metode BCCAQ dan dibandingkan dengan metode *downscaling* lainnya seperti *bias correction constructed analogues* (BCCA), *double BCCA* (DBCCA), *BCCA with quantile mapping reordering* (BCCAQ), *bias correction spatial disaggregation* (BCSD), *BCSD using minimum/temperatur maksimum* (BCSDX), the *climate imprint delta method* (CI), dan *bias corrected CI* (BCCI), BCCAQ memberikan representasi yang lebih akurat. Sobie dan Murdock (2017) menunjukkan bahwa metode BCCAQ mampu menurunkan skala kasar ke skala yang lebih tinggi/halus untuk kasus curah hujan dan temperatur. Pada penelitian ini akan mengambil beberapa metode yang telah dikembangkan diantaranya BCCAQ, QDM, dan ISIMIP untuk mengoreksi bias luaran ESM wilayah Indonesia.

## 1.2. Rumusan Masalah

*Earth System Models* (ESM) merupakan model untuk menganalisis iklim atau curah hujan yang mampu menangkap variabilitas dari suatu peristiwa, namun masih bersifat global dan memiliki bias. *Statistical downscaling* merupakan teknik *downscaling* bersifat statik dimana grid-grid berskala besar (luaran model ESM) dalam jangka waktu tertentu digunakan untuk menentukan data pada grid skala kecil. Hasil *statistical downscaling* luaran ESM pada grid berskala lokal (observasi) dengan menambahkan koreksi bias didalamnya diharapkan informasi yang terkandung dalam data luaran ESM menyerupai data observasi. Berdasarkan uraian

latar belakang di atas permasalahan yang akan dibahas yaitu bagaimana *statistical downscaling* data luaran ESM terhadap skala (lokal) observasi dengan metode *climate-imprint*, hasil *statistical downscaling* akan dikoreksi bias menggunakan QDM, ISIMIP, dan BCCAQ. Dari ketiga metode koreksi bias tersebut akan dibandingkan guna memperoleh metode koreksi bias terbaik dengan melihat nilai korelasi, *centered RMS difference*, dan standar deviasi pada diagram Taylor. Metode koreksi bias terbaik akan digunakan untuk mengoreksi bias pada proyeksi iklim (curah hujan dan temperatur maksimum) data skenario G4 dan RCP4.5.

### **1.3. Tujuan Penelitian**

Tujuan penelitian ini adalah sebagai berikut:

1. Mendapatkan data hasil bias koreksi (sudah terkoreksi bias) dari data hasil *statistical downscaling climate-imprint* curah hujan dan temperatur maksimum dengan metode QDM, ISI-MIP, dan BCCAQ.
2. Membandingkan tiga metode koreksi bias, QDM, ISIMIP, dan BCCAQ berdasarkan nilai korelasi, *centered RMS difference* dan standar deviasi pada diagram Taylor.
3. Mendapatkan proyeksi iklim data skenario G4 dan RCP4.5 (curah hujan dan temperatur maksimum) dengan metode koreksi bias terbaik.

### **1.4. Manfaat Penelitian**

Manfaat penelitian ini adalah sebagai berikut:

1. Membantu Badan Meteorologi Klimatologi dan Geofisika (BMKG) dalam mendapatkan proyeksi iklim (curah hujan dan temperatur maksimum) yang telah terkoreksi bias.
2. Memberi gambaran dampak dari SRM apabila diimplementasikan di Indonesia.

## **1.5. Batasan Masalah**

Batasan masalah dalam penelitian ini adalah.

1. Wilayah yang diteliti adalah Indonesia.
2. Data *European Centre for Medium-Range Weather Forecasts* (ECMWF), skenario G4, RCP 45, dan *Historical*, dengan variabel curah hujan dan temperatur maksimum.
3. Model yang digunakan adalah BNU-ESM, MIROC-ESM, dan MIROC-ESM-CHEM.
4. Metode yang digunakan dalam penelitian ini *climate-imprint*, ISIMIP, BCCAQ, dan QDM.
5. Penelitian ini tidak melibatkan efek spasial didalamnya, karena efek spasial telah diperhitungkan dalam proses dinamis.

## **BAB 2**

### **TINJAUAN PUSTAKA**

Bab ini membahas mengenai tinjauan pustaka yang terdiri dari tinjauan statistika dan tinjauan non statistika. Tinjauan statistik membahas tentang metode-metode *climate analogues*, *climate imprint*, *quantile mapping*, *quantile delta mapping*, *empirical copula coupling*, dan *inter-sectoral impact model intercomparison project*, dan evaluasi *skill* menggunakan diagram Taylor. Tinjauan non statistik membahas mengenai *downscaling* dan *earth system models*.

#### **2.1. Bias Correction/Constructed Analogues with Quantile mapping Reordering**

*Bias Correction/Constructed Analogues with Quantile mapping Reordering* (BCCAQ) adalah metode *downscaling hybrid* yang menggabungkan *output* dari *Climate Analogues* (CA) dan pemetaan *quantile* pada resolusi skala halus. Pertama, algoritma CA dan *Climate imprint* (CI) ditambah dengan *Quantile Delta Mapping* (QDM) dijalankan secara independen. BCCAQ kemudian menggabungkan output dari keduanya dengan mengambil *output* QDM harian pada setiap titik grid skala halus dan menyusun ulang dalam bulan tertentu sesuai dengan peringkat CA harian, yaitu, menggunakan bentuk *empirical copula coupling* (Werner dan Cannon, 2016).

Kombinasi ini mengurangi beberapa masalah potensial dengan algoritma terpisah. Pertama, karena bobot optimal yang digunakan untuk menggabungkan analog dalam BCCA diturunkan setiap hari, tanpa mengacu pada set data historis penuh, algoritma mungkin gagal mereproduksi *tren* jangka panjang dari model iklim. Kedua, langkah koreksi bias CI / QDM memperbaiki curah hujan "gerimis" dan bias residual lainnya yang disebabkan oleh kombinasi linear dari bidang harian dari CA. Ketiga, menyusun kembali data untuk setiap titik grid skala halus dalam sebulan secara efektif memecah representasi yang terlalu mulus dari variabilitas spasial skala sub-grid yang diwarisi dari CI / QDM, sehingga menghasilkan representasi yang lebih akurat, hal ini juga mencegah *output downscale* dari pengaruh *tren* jangka panjang dari model iklim.

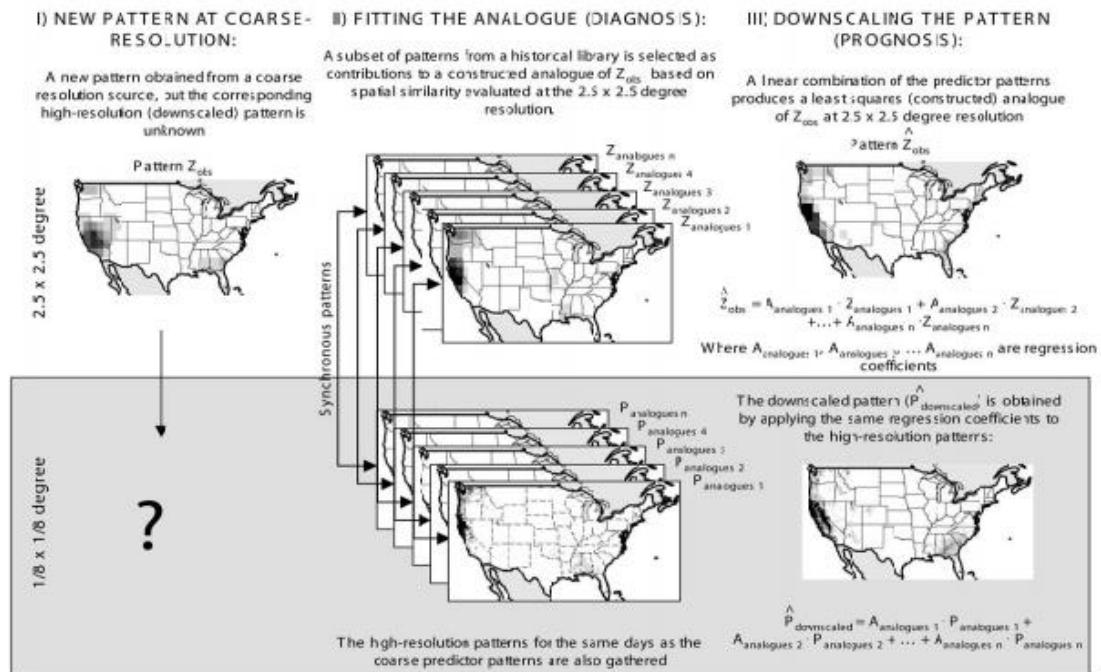
## **2.2. Constructed Analogues**

Metode analog telah digunakan dalam prediksi cuaca dan musim sejak tahun 1969 oleh Lorenz, namun menghasilkan hasil yang kurang baik, hal ini disebabkan karena *analog* dipilih dari *database* pola atmosfer yang kasar (van den Dool, 2003). Sementara penggunaan metode analog untuk proses *downscaling* sendiri dimulai oleh (Zorita, 1995). Salah satu tujuan dari metode *downscaling* adalah untuk memperoleh statistik iklim lokal yang konsisten dengan kondisi atmosfer skala luas (Zorita dan Stroch, 1999).

Metode analog merupakan metode *downscaling* yang relatif mudah diaplikasikan, dan metode ini menggunakan iklim dari data observasi sehingga struktur spasial iklim lokal terwakilkan dengan baik dihasil simulasi. Metode *analog* ini menggunakan analogi skala lokal dengan suatu kondisi atau pola iklim skala luas. Hidalgo, Dettinger, dan Cayan (2008) membagi dua pendekatan yang digunakan dalam penentuan prediktor yaitu *indirect analogue* dengan menggunakan variabel sirkulasi atmosfer skala luas sebagai prediktor, dan metode *direct analogue* yang aman variabel skala luas sama dengan variabel lokal.

Hidalgo, Dettinger, dan Cayan (2008) menunjukkan bahwa *indirect method* pada umumnya disertai dengan penggunaan analisis *empirical orthogonal function* (EOF). Tujuannya untuk memfilter *noise* dari data dan juga mengurangi derajat kebebasan dari variabel prediktornya yang dipilih. Konsep dari derajat bebas variabel sirkulasi atmosfer sangat penting dalam metode analog. Lorenz (1969) telah menunjukkan bahwa kemungkinan ditemukannya suatu analog dari pola iklim skala *hemisfer* dengan kualitas yang dapat diterima sangat kecil, oleh karena tingginya derajat bebas sirkulasi atmosfer dan pendeknya rentan waktu observasi yang tersedia. Penyelesaian masalah tersebut Hidalgo, Dettinger, dan Cayan (2008) mengajukan metode *direct analogue* yaitu menggunakan variabel yang sama baik sebagai prediktor maupun respon. Kontras dengan metode yang diajukan oleh Zorita dan Stroch (1999) yang menggunakan metode *indirect analogue* dan analisis EOF untuk mengurangi derajat bebas Hidalgo dkk. (2008) mengikuti prosedur van den Dool (1994) untuk mencari sekumpulan analog-analog yang berpotensi, lalu membangun satu analog berdasarkan hubungan linier dari sekumpulan analog-

analog tersebut, metode ini disebut *Constructed Analogue* (CA). Adapun ilustrasi CA disajikan pada Gambar 2.1.



Gambar 2. 1 *Downscale Construted Analogues* (Sumber: Hidalgo dkk., 2008)

Langkah menggunakan metode analog untuk *downscaling* atau prediksi dibagi menjadi dua yaitu diagnosis dan prognosis (Hidalgo dkk., 2008). Aplikasi *downscaling constructed analogues* langkah prognosis adalah deriviasi dari pola resolusi tinggi dengan menerapkan kecocokan linier yang dikembangkan dari subset prediktor resolusi kasar yang paling cocok. Koefisien regresi yang diturunkan untuk setiap pola resolusi kasar pada langkah diagnosis diterapkan pada resolusi tinggi untuk setiap hari yang sama (Gambar 2.1). Langkah diagnosis membangun resolusi kasar terdapat beberapa skema untuk memilih subset prediktor. Semua pola cuaca sebelumnya dapat dimasukkan dalam regresi yang membentuk analog, tetapi pendekatan ini menghasilkan inefesensi besar, karena ketrampilan *downscale*, serta korelasi tidak meningkat secara signifikan dengan menambahkan lebih banyak prediktor, atau beberapa pola yang diketahui sangat mirip dengan pola observasional dapat digunakan untuk membentuk analog.

Setelah memperoleh prediktor untuk temperatur atau curah hujan resolusi kasar untuk hari dan tahun tertentu  $\mathbf{Z}_{\text{obs}}$ , analog dari pola tersebut  $\hat{\mathbf{Z}}_{\text{obs}}$  dapat dikontruksikan sebagai kombinasi linier dari pola prediktor,

$$\mathbf{Z}_{\text{obs}} \gg \hat{\mathbf{Z}}_{\text{obs}} = \mathbf{Z}_{\text{analogues}} \mathbf{A}_{\text{analogues}} \quad (2.1)$$

dengan  $\mathbf{Z}_{\text{analogues}}$  adalah matriks dari *vector* kolom yang terdiri dari subset pola resolusi kasar yang diidentifikasi khusus untuk  $\mathbf{Z}_{\text{obs}}$  dan  $\mathbf{A}_{\text{analogues}}$  adalah *vector* yang paling tidak sesuai perkiraan kuadrat koefisien regresi yang merupakan proporsi linier dari kontribusi masing-masing kolom dari  $\mathbf{Z}_{\text{analogues}}$  ke *constructed analogue*. Dimensi matriks dari  $\mathbf{Z}_{\text{obs}}$  adalah  $p_{\text{coarse}} \times 1$ , dimana  $p_{\text{coarse}}$  adalah jumlah titik-titik yang terkandung dalam setiap pola iklim (GCM) resolusi kasar. Dimensi  $\mathbf{Z}_{\text{analogues}}$  adalah  $p_{\text{coarse}} \times n$  adalah jumlah pola dalam subset prediktor yang paling cocok. Dimensi  $\mathbf{A}_{\text{analogues}}$  adalah  $n \times 1$ , dengan asumsi  $\mathbf{Z}_{\text{analogues}}$  *full rank* dan menggunakan definit *pseudo-invers* (Moore-Penrose-inverse),  $\mathbf{A}_{\text{analogues}}$  diperoleh dari persamaan 2.1.

$$\mathbf{A}_{\text{analogues}} = \left[ (\mathbf{Z}'_{\text{analogues}} \mathbf{Z}_{\text{analogues}})^{-1} \mathbf{Z}'_{\text{analogues}} \right] \mathbf{Z}_{\text{obs}} \quad (2.2)$$

Prognosis adalah menurunkan pola cuaca, untuk menurunkan skala  $\mathbf{Z}_{\text{obs}}$ , koefisien  $\mathbf{A}_{\text{analogues}}$  dari persamaan 2.2 diterapkan pada pola iklim beresolusi tinggi yang sesi hari yang sama dengan prediktor resolusi kasar  $\mathbf{Z}_{\text{analogues}}$ , sesuai dengan.

$$\hat{\mathbf{P}}_{\text{downscaled}} = \mathbf{P}_{\text{analogues}} \mathbf{A}_{\text{analogues}} \quad (2.3)$$

Subtitusi persamaan 2.2 kedalam persamaan 2.3

$$\hat{\mathbf{P}}_{\text{downscaled}} = \mathbf{P}_{\text{analogues}} \left[ (\mathbf{Z}'_{\text{analogues}} \mathbf{Z}_{\text{analogues}})^{-1} \mathbf{Z}'_{\text{analogues}} \right] \mathbf{Z}_{\text{obs}} \quad (2.4)$$

Dengan  $\hat{\mathbf{P}}_{\text{downscaled}}$  adalah *constructed high-resolution analogue* dan  $\mathbf{P}_{\text{analogues}}$  adalah serangkaian pola historis resolusi tinggi yang sesuai dengan hari yang sama dengan  $\mathbf{Z}_{\text{analogues}}$ . Dimensi *vector*  $\mathbf{P}_{\text{analogues}}$  adalah  $p_{\text{VIC}} \times n$ , dengan  $p_{\text{VIC}}$  jumlah dari titik-titik dalam iklim resolusi tinggi dan n jumlah pola dalam subset

prediktor yang paling cocok sama dengan  $\mathbf{Z}_{\text{analogues}}$ . Matriks  $\mathbf{Z}'_{\text{analogues}} \mathbf{Z}_{\text{analogues}}$  berdimensi  $n \times n$ .

### **2.3. Climate-Imprint**

Hunter dan Meentemeyer (2005) mengenalkan metode *downscaling Climate Imprint* (CI) atau disebut juga delta. Hasil metode CI menghasilkan *downscale* untuk curah hujan dan temperatur.

#### **2.3.1. Curah Hujan**

Persamaan yang digunakan dalam metode *climate-imprint* untuk menghitung nilai harian sebagai rasio pengamatan curah hujan harian yaitu,

$$P_{\text{ratio}} = \frac{P_{\text{daily}}}{P_{\text{monthly}}} \quad (2.5)$$

$P_{\text{ratio}}$  adalah rasio dari curah hujan harian pada data luaran ESM ( $P_{\text{daily}}$ ) dibagi dengan curah hujan bulanan luaran ESM ( $P_{\text{monthly}}$ ). Interpolasi biliner digunakan untuk menginterpolasi permukaan grid  $P_{\text{ratio}}$  untuk hari tertentu yang secara visual menyerupai output dari metode interpolasi pada umumnya, setelah dilakukan interpolasi biliner persamaan 2.5 dapat dimodifikasi menjadi persamaan 2.6 untuk mendapatkan curah hujan harian berskala lokal ( $P_{\text{dialy\_obs}}$ ).

$$P_{\text{daily\_obs}} = P_{\text{interpolated ratio}} \times P_{\text{monthly\_obs}} \quad (2.6)$$

dengan  $P_{\text{interpolated ratio}}$  adalah rasio curah hujan luaran ESM pada suatu titik yang telah diinterpolasi dan  $P_{\text{monthly\_obs}}$  adalah curah hujan bulanan pada skala lokal.

#### **2.3.2. Temperatur**

Perhitungan temperatur minimum dan maksimal dihitung dengan cara yang sama seperti curah hujan, namun dalam input harian sebagai perbedaan antara suhu rata-rata bulanan (minimum atau maksimal) dan nilai harian yang diamati,

$$T_{\text{difference}} = T_{\text{monthly}} - T_{\text{daily}} \quad (2.7)$$

$T_{\text{difference}}$  adalah temperatur harian data luaran ESM ( $T_{\text{daily}}$ ) dikurangi dengan temperatur bulanan ( $T_{\text{monthly}}$ ) data luaran ESM. Interpolasi bilinier digunakan untuk menginterpolasi permukaan grid  $T_{\text{difference}}$  untuk hari tertentu yang secara visual menyerupai *output* dari metode interpolasi pada umumnya, maka persamaan 2.7 dimodifikasi menjadi persamaan 2.8 untuk mendapatkan temperatur bersekala lokal ( $T_{\text{daily\_obs}}$ ),

$$T_{\text{daily\_obs}} = T_{\text{monthly\_obs}} - T_{\text{interpolated difference}} \quad (2.8)$$

dengan  $T_{\text{interpolated difference}}$  adalah hasil interpolasi bilinier dari perbedaan temperatur luaran ESM dan  $T_{\text{monthly\_obs}}$  adalah temperatur bulanan skala lokal.

## 2.4. Quantile Mapping

*Quantile mapping* (QM) adalah menyamakan fungsi distribusi kumulatif (CDF)  $F_{o,h}$  dan  $F_{m,h}$ , masing-masing data yang diamati  $x_{o,h}$ , dilambangkan dengan subskrip  $o$ , dan data model  $x_{m,h}$ , dilambangkan dengan subskrip  $m$ , dalam periode historis, dilambangkan dengan subskrip  $h$ . Ini mengarah ke fungsi *transfer* berikut,

$$\hat{x}_{m,p}(t) = \hat{F}_{o,h}^{-1} \left\{ \hat{F}_{m,h} \left[ x_{m,p}(t) \right] \right\} \quad (2.9)$$

dengan  $x_{m,p}(t)$  untuk bias koreksi, nilai model pada waktu  $t$  dalam beberapa periode yang diproyeksikan, dilambangkan dengan subskrip  $p$ . Pada penelitian ini CDF  $F_{o,h}$  dan  $F_{m,h}$  ditaksir dengan CDF empiris  $\hat{F}_n$  pada persamaan 2.10. Berikut merupakan fungsi distribusi komulatif empiris (ECDF) jika diberikan suatu sampel  $X_1, \dots, X_n$

$$\hat{F}_n(x) = \frac{1}{(N+1)} \sum_{i=1}^N 1(X_i \leq x) \quad (2.10)$$

Jika CDF dan invers CDF (yaitu, fungsi kuantil) diperkirakan secara empiris dari data, algoritma dapat diilustrasikan dengan bantuan *plot* kuantil-kuantil, yang merupakan sebaran antara kuantil empiris dari data yang diamati dan data yang

dimodelkan (yaitu, diurutkan nilai dalam setiap sampel ketika jumlah sampel yang diamati dan dimodelkan adalah sama). Dalam kasus ini, QM berjumlah tabel pencarian yang entri-entrinya ditemukan dengan menginterpolasi antara titik-titik dalam *plot* kuantil-kuantil dari data historis. Fungsi transfer dibangun menggunakan informasi dari periode historis secara eksklusif; informasi yang diberikan oleh proyeksi model masa depan diabaikan. Seperti semua algoritma *postprocessing* statistik, QM sangat bergantung pada asumsi bahwa bias model iklim yang akan diperbaiki adalah stasioner (yaitu, bahwa karakteristik dalam periode historis akan bertahan hingga masa depan).

Fungsi CDF empiris, persamaan (2.9) hanya ditentukan pada rentan historis dari dataset yang dimodelkan. Jika nilai yang diproyeksikan berada di luar kisaran historis, maka beberapa bentuk ekstrapolasi diperlukan, misalnya menggunakan distribusi parametrik Wood dkk. (2004) atau pendekatan koreksi konstan Boé dkk. (2007). Terdapat satu cara ekstrapolasi yang sering dapat dihindari adalah dengan secara eksplisit memperhitungkan perubahan nilai-nilai yang diproyeksikan, misalnya dengan menghapus *tren* model dalam rata-rata jangka panjang yang akan menggeser distribusi masa depan sehingga cenderung terletak dalam dukungan distribusi historis, dan kemudian menerapkannya kembali sesudahnya. Variabel rasio seperti curah hujan, *tren* dihapus dan kemudian diterapkan kembali dengan penskalaan dan penskalaan ulang.

$$\hat{x}_{m,p}(t) = \hat{F}_{o,h}^{-1} \left\{ \hat{F}_{m,h} \left[ \frac{\bar{x}_{m,h} x_{m,p}(t)}{\bar{x}_{m,p}(t)} \right] \right\} \frac{\bar{x}_{m,p}(t)}{\bar{x}_{m,h}} \quad (2.11)$$

Definisi dari  $\bar{x}_{m,h}$  dan  $\bar{x}_{m,p}(t)$  masing-masing adalah estimasi rata-rata model jangka panjang selama periode historis dan pada waktu  $t$  dalam periode yang diproyeksikan  $p$ .

## 2.5. Quantile Delta Mapping

*Quantile Delta Mapping* (QDM) dimulai dengan CDF yang tergantung waktu dari model yang diproyeksikan  $x_{m,p}$ , misalnya seperti yang diperkirakan dari CDF empiris pada rentan waktu  $t$  (Cannon dkk., 2015),

$$\tau_{m,p}(t) = \hat{F}_{m,p}^{(t)}[x_{m,p}(t)], \tau_{m,p}(t) \in \{0,1\} \quad (2.12)$$

dimana  $\tau_{m,p}$  adalah probabilitas tidak ada kelanjutan yang terkait dengan nilai pada waktu  $t$ ,  $x_{m,p}$ . Perubahan absolut dalam kuantil antara periode historis dan masa depan.

$$\Delta_m(t) = \frac{\hat{F}_{m,p}^{(t)-1}[\tau_{m,p}(t)]}{\hat{F}_{m,h}^{-1}[\tau_{m,p}(t)]} = \frac{x_{m,p}(t)}{\hat{F}_{m,h}^{-1}[\tau_{m,p}(t)]} \quad (2.13)$$

Model  $\tau_{m,p}$  kuantil pada waktu ke  $t$  dapat bias koreksi dengan menerapkan invers CDF yang diperkirakan dari nilai yang diamati  $x_{o,h}$  selama periode historis.

$$\hat{x}_{o:m,h;p}(t) = \hat{F}_{o,h}^{-1}[\tau_{m,p}(t)] \quad (2.14)$$

Proyeksi masa depan yang dikoreksi bias pada waktu  $t$  diberikan dengan menerapkan perubahan relatif  $\Delta_m(t)$  secara berganda ke nilai koreksi bias historis,

$$\hat{x}_{m,p}(t) = \hat{x}_{o:m,h;p}(t)\Delta_m(t) \quad (2.15)$$

Memasukan persamaan 2.12, persamaan 2.13, persamaan 2.14, dan kepersamaan 2.15.

$$\hat{x}_{m,p}(t) = \hat{F}_{o,h}^{-1}\left\{\hat{F}_{m,p}^{(t)}[x_{m,p}(t)]\right\} \left[ \frac{x_{m,p}(t)}{\hat{F}_{m,h}^{-1}\left\{\hat{F}_{m,p}^{(t)}[x_{m,p}(t)]\right\}} \right] \quad (2.16)$$

untuk mempertahankan perubahan absolut daripada relatif dalam kuantil dapat diterapkan secara adiptif. Maka persamaan (2.13) menjadi.

$$\begin{aligned} \Delta_m(t) &= \hat{F}_{m,p}^{(t)-1}[\tau_{m,p}(t)] - \hat{F}_{m,h}^{-1}[\tau_{m,p}(t)] \\ &= x_{m,p}(t) - \hat{F}_{m,h}^{-1}[\tau_{m,p}(t)] \end{aligned} \quad (2.17)$$

Proyeksi masa depan yang dikoreksi bias pada waktu  $t$  diberikan dengan menambahkan (adiptif) sinyal perubahan dalam kuantil  $\Delta_m(t)$  ke nilai historis yang dikoreksi bias.

$$\hat{x}_{m,p}(t) = \hat{x}_{o:m,h;p}(t) + \Delta_m(t) \quad (2.18)$$

Berarti bahwa perubahan absolut yang diproyeksikan dengan model dipertahankan. Memasukkan persamaan 2.12, persamaan 2.14 dan persamaan 2.17 terhadap persamaan 2.18,

$$\begin{aligned}\hat{x}_{m,p} = & \hat{F}_{o,h}^{-1} \left\{ \hat{F}_{m,p}^{(t)} \left[ x_{m,p}(t) \right] \right\} + x_{m,p}(t) \\ & - \hat{F}_{m,h}^{-1} \left\{ \hat{F}_{m,p}^{(t)} \left[ x_{m,p}(t) \right] \right\}\end{aligned}\quad (2.19)$$

setelah menata ulang, menghasilkan.

$$\begin{aligned}\hat{x}_{m,p}(t) = & x_{m,p}(t) + \hat{F}_{o,h}^{-1} \left\{ \hat{F}_{m,p}^{(t)} \left[ x_{m,p}(t) \right] \right\} \\ & - \hat{F}_{m,h}^{-1} \left\{ \hat{F}_{m,p}^{(t)} \left[ x_{m,p}(t) \right] \right\}\end{aligned}\quad (2.20)$$

Pada persamaan 2.9 hanya ditentukan pada rentan historis dari dataset yang dimodelkan untuk CDF empiris, jika nilai yang diproyeksikan ( $\hat{x}_{m,p}$ ) berada diluar kisaran historis maka bentuk ekstrapolasi diperlukan (persamaan 2.11). Metode QM efektif dalam menghilangkan bias historis relatif terhadap pengamatan, namun QM secara artifisial dapat merusak tren proyeksi model di masa depan (Canon dkk., 2015). Sehingga Canon dkk. (2015) menambahkan perubahan relatif ( $\Delta_m$ ) pada persamaan 2.16 (multiplikatif) dan persamaan 2.20 (aditif).

## 2.6. Ensemble Copula Coupling

Pendekatan *Ensemble Copula Coupling* (ECC) mengacu pada informasi urutan peringkat yang tersedia dalam ramalan *raw ensemble*, berdasarkan asumsi implisit bahwa anggotanya dapat dipertukarkan dan bahwa ensemble *Numerical Weather Prediction* (NWP) mampu mewakili struktur variabel-silang, ketergantungan spasial dan temporal yang diamati. Sementara yang terakhir diharapkan, mengingat bahwa model NWP mendiskritisasi persamaan yang mengatur fisika atmosfer, disarankan pemeriksaan diagnostik, untuk menilai secara empiris apakah struktur ketergantungan pada ramalan *ensemble* individu sesuai dengan catatan observasional.

### 2.6.1. Pendekatan ECC

Pendekatan ECC adalah prosedur multi-tahap yang umum untuk menghasilkan *postprocessed ensemble* dengan ukuran yang sama  $M$  sebagai *raw ensemble*, dapat ditulis dengan  $x_1^l, \dots, x_M^l$ , untuk *margin univariate* dari *raw ensemble*, dimana multi indeks  $l = (i, j, k)$  mengacu pada variabel iklim  $i \in \{1, \dots, I\}$ , untuk lokasi  $j \in \{1, \dots, J\}$ , dan *lead time*  $k \in \{1, \dots, K\}$ , untuk menyusun *output NWP* dalam  $\mathbb{R}^L$ , dimana dimensinya  $L = I \times J \times K$ . Untuk mengasilkan peramalan *postprocessed ensemble* proses ECC sebagai berikut.

a. *Univariate postprocessing*

Untuk setiap margin  $l$ , dapatkan distribusi prediktif *postprocessed*,  $F_l$ , dengan menerapkan teknik *univariat postprocessing*, seperti *Ensemble Bayesian Model Averaging* (BMA) atau NR, ke *output raw ensemble*.

$$x_1^l, \dots, x_M^l \quad (2.21)$$

b. *Quantized*

Mewakili setiap distribusi prediktif *univariate*  $F_l$  dengan sampel diskrit ukuran  $M$ .

$$\tilde{x}_1^l, \dots, \tilde{x}_M^l \quad (2.22)$$

Sampel diskrit dapat dihasilkan dengan berbagai cara, Schefzik dkk. (2013) membedakan varian ECC-Q, ECC-R dan ECC-T, tergantung pada bagaimana *quantized* dilakukan.

c. *Ensemble reordering*,

Setiap margin  $l$ , statistik urutan nilai *raw ensemble* sebagai berikut.

$$x_{(1)}^l \leq \dots \leq x_{(M)}^l$$

Menginduksi permutasi  $\sigma_l$  dari bilangan bulat  $\{1, \dots, M\}$ , didefinisikan oleh  $\sigma_l(m) = rk(x_m^l)$  dengan  $m = 1, \dots, M$ . Jika ada ikatan antara nilai-nilai *ensemble*, peringkat yang sesuai dapat dialokasikan secara acak. Margin masing-masing dari *ensemble* setelah-pemrosesan ECC.

$$\hat{x}_1^l = \tilde{x}_{(\sigma(1))}^l, \dots, \hat{x}_M^l = \tilde{x}_{(\sigma(M))}^l \quad (2.23)$$

Permutasi  $\sigma_i$  ditentukan oleh statistik urutan *raw ensemble*, persamaan (2.23) menerapkan permutasi ini ke nilai-nilai *postprocessed* dan *quantized*. Pendekatan ECC adalah komputasi yang menarik, karena pemodelan struktur ketergantungan multivariat hanya membutuhkan perhitungan peringkat *marginal* (Schefzik, Thorarinsdottir, dan Gneiting, 2013), teknik ECC juga diterapkan oleh Wilks, (2015).

### 2.6.2. Interpretasi *Empirical Copula*

*Ensemble Copula Copuling* dapat dianggap sebagai teknik kopula empiris. Diasumsikan bahwa tidak ada ikatan di antara *margin raw ensemble*,  $R_1, \dots, R_L$  untuk fungsi distribusi kumulatif empiris marginal yang sesuai, yang mengambil nilai dalam himpunan.

$$I_M = \left\{ 0, \frac{1}{M}, \dots, \frac{M-1}{M}, 1 \right\}$$

Fungsi distribusi kumulatif empiris *multivariate*  $R : \mathbb{R}^L \rightarrow I_M$ . Menurut versi diskor teorema Sklar yang dijelaskan oleh Mayor, Suner dan Torrens (2007) dalam kasus bivariat, terdapat kopula empiris yang ditentukan secara unik  $E_M : I_M^L \rightarrow I_M$  sedemikian rupa,

$$R(y_1, \dots, y_L) = E_M(R_1(y_1), \dots, R_L(y_L)) \quad (2.24)$$

semua  $y_1, \dots, y_L \in \mathbb{R}$ . Pertimbangan analog berlaku untuk *postprocessed ensemble quantized* yang dikuantisasi secara independen (2.22) dan *postprocessed ensemble ECC* (2.23). Menggunakan notasi yang jelas  $\tilde{F}$  dan  $\hat{F}$  untuk fungsi distribusi kumulatif empiris multivariat yang sesuai. Selain itu, fungsi distribusi kumulatif empiris *marginal* dari *postprocessed ensemble* yang dikuantisasi secara independen masing-masing oleh  $\tilde{F}_1, \dots, \tilde{F}_L$  dan menggunakan simbol  $\tilde{E}_M$  untuk menunjukkan kopula yang sesuai,

$$\tilde{F}(y_1, \dots, y_L) = \tilde{E}_M(\tilde{F}_1(y_1), \dots, \tilde{F}_L(y_L)) \quad (2.25)$$

dan,

$$\hat{F}(y_1, \dots, y_L) = E_M(\tilde{F}_1(y_1), \dots, \tilde{F}_L(y_L)) \quad (2.26)$$

semua  $y_1, \dots, y_L \in \mathbb{R}$ . Seperti yang dijelaskan oleh persamaan (2.24), (2.25) dan (2.26), *postprocessed ensemble* yang dikuantisasi secara independen dan *postprocessed ensemble* ECC berbagi *margin*, sedangkan *raw ensemble* dan *postprocessed ensemble* ECC membagi kopula. *Postprocessed ensemble* ECC mempertahankan struktur ketergantungan peringkat multivariat yang bergantung pada aliran dan koefisien korelasi peringkat Spearman bivariat dalam *output NWP raw ensemble*.

### 2.6.3. ECC-Q, ECC-R dan ECC-T

Opsi untuk pembuatan sampel diskrit (2.21) pada tahap kuantisasi pendekatan ECC. Mungkin cara paling alami untuk mendapatkan sampel diskrit ukuran  $M$  dari fungsi distribusi kumulatif prediktif *postprocessed*  $F_l$  adalah dengan mengambil Jumlah yang sama dari bentuk,

$$\tilde{x}_1^l = F_l^{-1}\left(\frac{1}{M+1}\right), \dots, \tilde{x}_M^l = F_l^{-1}\left(\frac{M}{M+1}\right)$$

pendekatan ini sebagai ECC-Q. Pilihan lain adalah mengambil sampel acak.

$$\tilde{x}_1^l = F_l^{-1}(u_1), \dots, \tilde{x}_M^l = F_l^{-1}(u_M)$$

dengan  $u_1, \dots, u_M$  adalah varian random uniform standar yang independen, opsi ini disebut sebagai ECC-R. Pemetaan kuantil atau pendekatan transformasi yang menggeneralisasi Pinson (2012) dalam kasus vektor angin. Dalam teknik ini, (Schefzik, Thorarinsdottir, dan Gneiting, 2013) mengadopsi pendekatan *smoothing ensemble* dari Wilks (2002) dan menyesuaikan fungsi distribusi kumulatif parametrik berkelanjutan  $S_l$  ke margin *raw ensemble*  $R_l$ . (Schefzik, Thorarinsdottir, dan Gneiting, 2013) kemudian mengekstrak kuantil dari  $F_l$  yang sesuai dengan persentil nilai *raw ensemble* di  $S_l$ .

$$\tilde{x}_1^l = F_l^{-1}(S_l(x_1^l)), \dots, \tilde{x}_M^l = F_l^{-1}(S_l(x_M^l))$$

Schefzik dkk, (2013) merujuk pada pendekatan transformasi ini untuk variabel kontinu sebagai ECC-T. Seringkali, seperti dalam kasus suhu, tekanan  $u$  dan  $v$  komponen vektor angin,  $S_l$  dapat dianggap normal, rata-rata sama dengan rata-rata *ensemble* dan varians sama dengan varians *ensemble*. Dalam situasi khusus di mana  $S_l$  dan  $F_l$  milik keluarga skala lokasi yang sama,  $S_l(x) = G((x - \mu)/\sigma)$  dan  $F_l(x) = G((x - \tilde{\mu})/\tilde{\sigma})$  untuk beberapa fungsi distribusi kumulatif  $G$ ,  $\mu, \tilde{\mu} \in \mathbb{R}$  dan  $\sigma, \tilde{\sigma} > 0$ , transformasi dari  $x$  ke.

$$\tilde{x} = F_l^{-1}(S_l(x)) = \tilde{\mu} + \frac{\tilde{\sigma}}{\sigma}(x - \mu)$$

## **2.7. Inter-Sectoral Impact Model Intercomparison Project (ISIMIP)**

Metode ISIMIP mempertahankan data simulasi temperatur (curah hujan, tekanan, radiasi, dan angin). Metode ini memodifikasi variabilitas harian dari data yang disimulasikan tentang bulanan untuk mencocokkan variabilitas harian yang diamati (Hempel dkk., 2013). Variabilitas dan rata-rata bulanan dikoreksi hanya dengan menggunakan *offset konstan* atau faktor koreksi multiplikatif yang mengoreksi perbedaan jangka panjang antara data rata-rata bulanan yang disimulasikan dan diamati dalam periode historis. *Tren absolut* atau relatif dari data simulasi dipertahankan.

Semua koreksi bias dalam pendekatan ISI-MIP dilakukan berdasarkan bulan, sel grid, variabel iklim, dan ESM. Dalam koreksi suhu, *offset* bulanan ditambahkan ke seluruh seri waktu harian untuk menghilangkan perbedaan nilai rata-rata dalam periode kalibrasi antara ESM dan observasi. Untuk memperbaiki variabilitas harian dari data ESM, fungsi linier yang mengubah nilai suhu residual (misal: Penyimpangan suhu harian relatif terhadap rata-rata bulanan) dari ESM ke observasi yang digunakan. Koreksi curah hujan, faktor koreksi bulanan dikalikan dengan seluruh rangkaian waktu harian. Faktor koreksi diturunkan sebagai rasio antara observasi dan ESM rata-rata curah hujan harian dalam periode kalibrasi. Fungsi nonlinier yang mengubah curah hujan normal hari basah ESM menjadi observasi diterapkan untuk mengoreksi intensitas hujan hari basah. Curah hujan

harian normal sesuai dengan curah hujan harian dibagi dengan rata-rata bulanan. Koreksi frekuensi hari basah juga dipertimbangkan dalam pendekatan ISIMIP.

Koreksi variabilitas harian dideskripsikan oleh bulan-bulan kalender dan fungsi yang spesifik sel-sel yang diterapkan pada data yang disimulasikan setiap hari. Hempel dkk, (2013) mengambil nilai-nilai April (selanjutnya disebut sebagai “contoh sel grid”) untuk ilustrasi metode. Jadi,  $X_{ij}^{data}$  menunjukkan nilai April untuk tahun  $i$  dan hari  $j$  pada satu sel grid tertentu dari rangkaian waktu simulasi (data ESM) atau observasi (data WFD), di mana  $X = T$  untuk suhu rata-rata harian dan  $P$  untuk curah hujan. Selain itu,  $X_i^{data}$  menjelaskan rata-rata bulanan di sel kisi itu. Data residual dilambangkan dengan  $\Delta X_{ij}^{data}$ , sedangkan  $\delta X_{ij}^{data}$  mengacu pada data yang dinormalisasi. Data simulasi yang dikoreksi bias dilambangkan  $\tilde{X}_{ij}^{GCM}$  (harian) atau  $\tilde{X}_i^{GCM}$  (bulanan).

### 2.7.1. Koreksi Data Rata-Rata Bulanan

Tahap pertama adalah penyesuaian perbedaan jangka panjang antara data rata-rata bulanan yang disimulasikan (ESM) dan data observasi selama periode pengamatan.

#### 2.7.1.1. Temperatur: *Additive Correction*

Pada temperatur keseluruhan rangkaian waktu *offset* konstan ( $C$ ) yang sama dengan perbedaan rata-rata antara observasi (WFD) dan simulasi (ESM) selama periode historis,

$$C = \frac{\left( \sum_{i=1}^{m=N} T_i^{WFD} - \sum_{i=1}^{m=N} T_i^{ESM} \right)}{N} \quad (2.27)$$

dengan  $N$  dalam tahun. Temperatur yang dikoreksi.

$$\tilde{T}_{ij}^{ESM} = C + T_{ij}^{ESM} \quad (2.28)$$

Mempertahankan perubahan *absolut* temperatur dalam simulasi,

$$\tilde{T}_{ij}^{ESM} - \tilde{T}_0^{ESM} = T_{ij}^{ESM} - T_0^{ESM} \quad (2.29)$$

dimana  $T_0^{ESM}$  dan  $\tilde{T}_0^{ESM}$  adalah temperatur yang tidak dikoreksi dan dikoreksi. Metode ini adalah koreksi temperatur paling dasar yang secara teratur diterapkan dalam studi dampak. Metode ini mempertahankan *tren absolut*, dan variabilitas data yang disimulasikan di semua skala waktu.

### 2.7.1.2. Curah Hujan: *Multiplicative Correction*

Mengingat bahwa terdapat *constraints* positif pada data curah hujan, maka pendekatan *additive* tidak tepat, oleh karena itu koreksi nilai rata-rata curah hujan bulanan menggunakan faktor *multiplikative*, yang didefinisikan.

$$C = \frac{\sum_{i=1}^{m=N} P_i^{WFD}}{\sum_{i=1}^{m=N} P_i^{ESM}} \quad (2.30)$$

Deret waktu curah hujan.

$$\tilde{P}_{ij}^{ESM} = C \cdot P_{ij}^{ESM} \quad (2.31)$$

Pendekatan *multiplikative* memodifikasi simulasi perubahan curah hujan *absolut*, tetapi mempertahankan *relative* perubahan curah hujan.

$$\frac{\tilde{P}_{ij}^{ESM} - \tilde{P}_0^{ESM}}{P_0^{ESM}} = \frac{P_{ij}^{ESM} - P_0^{ESM}}{P_0^{ESM}} \quad (2.32)$$

dimana  $P_0^{ESM}$  dan  $\tilde{P}_0^{ESM}$  adalah curah hujan yang tidak dikoreksi dan dikoreksi.

### 2.7.2. Koreksi Variabilitas Harian

Langkah kedua, adalah untuk memperbaiki variabilitas harian dari data yang disimulasikan dengan data pengamatan (Hempel dkk., 2013). Langkah ini sangat penting untuk representasi yang tepat dari banyak dampak yang bergantung pada perubahan baik dalam rerata maupun variabilitas data: dengan cara ini, peristiwa cuaca ekstrim lebih terwakili dalam data yang dikoreksi. Penyesuaian variabilitas harian penting ketika data iklim diinterpolasi ke grid yang lebih.

Interpolasi sederhana tidak dapat menjelaskan variabilitas temporal yang ditingkatkan yang diharapkan pada skala spasial yang lebih kecil. Koreksi bias variabilitas data yang diinterpolasi dapat mengatasi masalah tersebut. Berikut, penyesuaian variabilitas harian dari residual suhu (Hempel dkk., 2013).

$$\Delta T_{ij}^{ESM} = T_{ij}^{ESM} - T_i^{ESM} \quad (2.33)$$

normalisasi untuk data curah hujan adalah.

$$\delta P_{ij}^{ESM} = \frac{P_{ij}^{ESM}}{P_i^{ESM}} \quad (2.34)$$

Umumnya variasi suhu tidak diharapkan menjadi sangat besar karena koreksi dilakukan berdasarkan kalender-bulan tertentu. Setiap ketergantungan varians harian pada nilai rata-rata bulanan dalam model atau data yang diamati tidak diabadikan oleh koreksi bias, untuk mengkarakterisasi ketergantungan ini, Hempel dkk. (2013) telah menghitung mean dan varians setiap bulan dalam periode pengamatan dan memperkirakan koefisien determinasi (*R-squared*) dari korelasi *Pearson linier* antara *mean* dan varians pada setiap titik grid. Untuk temperatur, nilai *R-squared* rendah untuk seluruh area lahan global, menunjukkan bahwa penerapan faktor koreksi varians umum konsisten dengan data pengamatan dan ESM. Untuk temperatur, varians didasarkan pada temperatur residual, sedangkan varians curah hujan dihitung setelah menormalkan data harian dengan rata-rata bulanan.

Kasus curah hujan, perhatian khusus harus diberikan untuk memperhitungkan bulan dengan curah hujan rendah (kering). Koreksi variabilitas harian terdiri dari dua langkah: (1) koreksi frekuensi hari kering dan (2) koreksi intensitas curah hujan pada hari hujan (basah). Koreksi yang diusulkan dari variabilitas dalam data harian memperluas metode yang dijelaskan oleh (Piani dkk, 2010) dalam Hempel dkk, (2013) dan diterapkan dalam Water-MIP (Hagemann dkk, 2011).

### 2.7.2.1. Temperatur dalam Regresi Linier

Untuk mengoreksi variabilitas nilai temperatur rata-rata harian terhadap data observasi harus disesuaikan dengan residual ESM (persamaan 2.33) dengan

WFD menggunakan pemetaan kuantil parametrik. Secara umum nilai temperatur dianggap mengikuti distribusi normal. Ini berarti distribusi diharapkan akan dijelaskan dengan baik hanya dengan dua momen (mean dan standar deviasi). Linear *fit* dianggap sebagai pendekatan yang tepat dalam banyak kasus dan dengan demikian telah dipilih untuk memetakan disimulasikan ke nilai temperatur pengamatan. Sehingga fungsi transfernya adalah (Hempel, 2013),

$$f(\Delta T^{ESM}) = B \cdot \Delta T^{WFD} \quad (2.35)$$

dimana  $B$  adalah *slope* dari linier regresi dalam *rank order*  $WFD(\Delta T^{WFD})$  dan pada data  $ESM(\Delta T^{GCM})$  untuk satu bulan kalender selama periode pengamatan N tahun.

### 2.7.2.2. Curah Hujan: Regresi Nonlinier

Curah hujan cenderung memiliki pola-pola yang nonlinier (Kristianda dan Fithriasari, 2016). Dalam kasus curah hujan, Hempel dkk, (2013) mempertimbangkan nilai-nilai yang dinormalisasi (persamaan 2.34) untuk menyesuaikan variabilitas tentang rata-rata bulanan, di mana kedua set data harus dijelaskan oleh fungsi distribusi yang sama. Seperti dalam aplikasi koreksi bias sebelumnya (Water-MIP), diasumsikan bahwa dataset pengamatan dan simulasi diperkirakan dengan baik oleh distribusi gamma (tidak termasuk hari-hari dengan curah hujan nol). Mengikuti asumsi itu, Hempel dkk, (2013) mengoreksi frekuensi dan intensitas curah hujan secara terpisah, karena distribusi gamma tidak ditentukan pada nol. Hempel dkk, (2013) melakukan pemetaan kuantitatif parametrik dengan tiga parameter untuk menyesuaikan intensitas curah hujan, di mana algoritma nonlinier yang didasarkan pada metode ekspansi-gradien yang diadaptasi dari Marquardt (1963) digunakan. Pada bulan-bulan terjadi kekeringan normalisasi dengan rata-rata bulanan tidak dimungkinkan. Untuk mengatasi masalah bulan kering ini Hampel dkk, (2013) mendefinisikan nilai *threshoold* untuk bulanan.

$$\epsilon_m = \max \left[ (P_k^{ESM} \mid P_k^{WFD} \leq 0.01, P_k^{ESM} \leq 0) \right] \quad (2.36)$$

Pengklasifikasian bulan menjadi kering dan basah, di mana variabilitas harian disesuaikan dengan bulan basah. Variabel  $P_k^{WFD}$  dan  $P_k^{ESM}$  mewakili *rank ordered* nilai curah hujan bulanan  $P_i^{data}$ .

Bulan dengan curah hujan rata-rata dibawah 0.01 mm dan 3.6 mm per tahun dinyatakan sebagai kering (Hempel dkk, 2013). Kemudian Hempel dkk, (2013) mempertimbangkan dua kasus: (1) jika ada lebih banyak bulan kering di WFD (data observasi) daripada bulan dengan nol curah hujan di ESM, bulan tidak termasuk dalam rangka meningkatkan curah hujan rata-rata bulanan hingga jumlah yang diinginkan (yaitu jumlah bulan kering di WFD) terpenuhi, mulai dari bulan ESM terkering. (2) Jika jumlah bulan dengan nol curah hujan di ESM lebih besar dari jumlah bulan kering di WFD, hanya bulan-bulan dengan nol curah hujan di ESM yang diklasifikasikan sebagai kering dalam ESM. Menerapkan persamaan (2.36) Hempel dkk, (2013) memastikan bahwa jumlah bulan yang sama dari ESM dan perangkat WFD dihilangkan. Dalam kedua kasus, curah hujan rata-rata bulan lalu yang akan dikecualikan dalam ESM menentukan ambang  $m$  untuk seri waktu bulanan yang disimulasikan.

Semua data harian yang terkait dengan bulan kering dikeluarkan dari perkiraan fungsi transfer. Keragaman data harian milik bulan-bulan kering ini tidak dimodifikasi. Untuk bulan-bulan basah yang tersisa koreksi bias berlangsung dalam dua tahap: (1) meningkatkan frekuensi hari-hari kering di mana diperlukan. Semua data harian yang terkait dengan bulan kering (*contoh:  $P_{ij}^{ESM} | (P_i^{ESM} \leq \in_m)$* ) dikeluarkan dari perkiraan fungsi *transfer*. (2) Menyesuaikan intensitas curah hujan untuk hari hujan. Hempel dkk, (2013) menggunakan pendekatan yang sama seperti yang diusulkan oleh Piani dkk, (2010).

#### a. Koreksi frekuensi hari kering

Koreksi frekuensi hari kering berasal dari bulan basah periode pengamatan. Dalam banyak kasus ada gerimis dalam jumlah besar dalam ESM, yaitu hari-hari dengan curah hujan rendah, sementara pengamatan menunjukkan jumlah hari-hari kering yang lebih besar (*contoh curah hujan nol*). Untuk memperbaiki perbedaan tersebut, Hempel dkk, (2013) menentukan jumlah hari

kering yang diamati,  $N_{hujan}$ , selama periode pengamatan dengan menghitung terjadinya  $P_{ij}^{WFD} < 1 \text{ mm hari}^{-1}$  dari data harian WFD (observasi) yang terkait dengan bulan basah. Nilai ambang  $1 \text{ mm hari}^{-1}$  sudah digunakan dalam penelitian sebelumnya dan terkait dengan kebisingan pengukuran. Jumlah hari yang sama (dimulai dengan yang memiliki nilai curah hujan terendah) diatur ke nol dalam data harian ESM dan dikeluarkan dari *dataset* yang digunakan untuk menghasilkan fungsi *transfer* untuk koreksi intensitas curah hujan. Dengan cara ini curah hujan rendah, atau gerimis, di ESM terpotong jika intensitas curah hujan dibawah ambang batas.

$$\begin{aligned}\epsilon_d = 0.5.P_{ij}^{GCM} |(P_i^{ESM} > \epsilon_m, P_{ij}^{ESM} \leq P_1^{ESM} [N_{dry}]) \\ + 0.5.P_{ij}^{ESM} |(P_i^{ESM} > \epsilon_m, P_{ij}^{ESM} > P_1^{ESM} [N_{dry}])\end{aligned}\quad (2.37)$$

Variabel  $P_i$  menunjukkan peringkat nilai curah hujan pada bulan-bulan basah. Karena nilai curah hujan lebih kecil dari  $\epsilon_d$  ditetapkan ke nol, frekuensi hari kering (yaitu tanpa curah hujan terukur) dapat ditingkatkan dalam data model. Jika ada lebih banyak hari dengan curah hujan nol dalam ESM daripada dalam *dataset* pengamatan  $N_{basah}$  dipilih sama dengan jumlah hari untuk menghitung ambang batas (persamaan 2.37), yaitu tidak ada hari kering tambahan yang diperkenalkan dalam kasus ini.

Pengecualian hari gerimis dapat mengubah rata-rata bulanan, yang harus dihindari jika *tren* jangka panjang harus dipertahankan. Normalisasi yang tepat dapat memastikan hal ini. Jika normalisasi identik untuk konstruksi dan aplikasi tidak dapat dipastikan dalam kasus apa pun (seperti dalam pendekatan yang diterapkan untuk dataset ISIMIP) ini membatasi kapasitas untuk menyesuaikan variabilitas harian, karena mengalikan data dengan faktor apa pun yang berbeda dari satu modifikasi dari lebar distribusi probabilitas. Jadi, dalam pendekatan yang diperluas, untuk setiap bulan Hempel dkk. (2013) mendistribusikan kembali jumlah curah hujan pada hari-hari kering secara seragam di antara hari-hari hujan. Hal ini dicapai dengan  $m$  data  $i$  konstanta aditif yang merupakan jumlah total curah hujan dari hari-hari kering (gerimis) dibagi dengan jumlah hari basah. Itu dihitung untuk

setiap tahun dan bulan secara terpisah. Redistribusi curah hujan mengarah pada nilai-nilai baru,

$$\hat{P}_{ij}^{data} \begin{cases} P_{ij}^{data} + m_i^{data} & \text{jika basah} \\ 0 & \text{jika kering} \end{cases} \quad (2.38)$$

rata-rata semua hari hujan di bulan tertentu  $\hat{P}_i^{WFD}$  dan  $\hat{P}_i^{ESM}$  digunakan untuk normalisasi.

$$\delta\hat{P}_{ij}^{data} = \frac{\hat{P}_{ij}^{data}}{\hat{P}_i^{data}} \quad (2.39)$$

### b. Koreksi intensitas curah hujan hari hujan

Koreksi intensitas curah hujan hari basah dengan memfungsikan fungsi *transfer*, jika ada lebih dari 80 hari basah dalam keseluruhan periode pengamatan dan rata-rata bulanan di atas  $0,01 \text{ mm hari}^{-1}$ . Nilai batas 80 diperoleh dari kajian sensitivitas yang dilakukan Water-MIP (Hempel dkk, 2013).

Secara umum fungsi *transfer*  $g(\delta\hat{P}^{ESM})$  diturunkan menggunakan regresi nonlinear pada *set* peringkat yang diperintahkan  $\delta\hat{P}^{WFD}$  dan  $\delta\hat{P}^{ESM}$ , yang merupakan himpunan hari basah yang dinormalisasi pada bulan basah selama periode referensi N tahun. Nilai curah hujan basah terendah pada periode itu,  $\delta\hat{P}_{\min}^{ESM}$ , adalah parameter dari fungsi transfer.

$$g(\delta\hat{P}^{ESM}) = \left[ a + b \cdot \left\{ \delta\hat{P}^{ESM} - \delta\hat{P}_{\min}^{ESM} \right\} \right] \times \left[ 1 - \exp \left\{ -\frac{\delta\hat{P}^{ESM} - \delta\hat{P}_{\min}^{ESM}}{\tau} \right\} \right] \quad (2.40)$$

Offset  $a$  dan kemiringan  $b$  dari bagian linier dari fungsi, serta konstanta peluruhan  $\tau$  dari bagian eksponensial harus disesuaikan. Dalam algoritma yang diperluas, regresi nonlinier ini diterapkan sangat baik. Hanya jika prosedur nonlinier (literasi menurut metode ekspansi-gradien) tidak menyatu untuk dua *set* nilai awal yang berbeda, ini merupakan fungsi transfer linier,

$$g(\delta\hat{P}^{ESM}) = [a + b \cdot \delta\hat{P}^{ESM}] \quad (2.41)$$

dengan *offsite* slope  $a$  dan  $b$  diterapkan. Dataset ISIMIP Hempel dkk, (2013) menggunakan seperangkat aturan seleksi yang berbeda untuk fungsi. Selain itu, frekuensi dan variabilitas curah hujan berada pada beberapa titik grid yang tidak

disesuaikan sama sekali, karena titik-titik yang tidak memadai dipilih untuk dimasukkan dalam *fit* karena *bug* dalam kode atau parameter yang dilengkapi terlalu ekstrim. Masalah-masalah tersebut telah dipecahkan dalam *versi* diperpanjang dari algoritma untuk meningkatkan koreksi variabilitas harian.

Dalam kedua versi algoritma, di mana ada kurang dari 80 hari basah dalam keseluruhan periode observasi, atau rata-rata bulanan jangka panjang dibawah  $0.01 \text{ mm hari}^{-1}$ , variabilitas harian curah hujan tidak disesuaikan untuk kekurangan informasi statistik. Dalam hal ini Hempel dkk, (2013) mempertimbangkan fungsi *transfer* linier dengan nol *offset*  $a = 0$  dan *threshold* unit  $b = 1$  (lihat persamaan 2.41).

### 2.7.3. Aplikasi dari Koreksi Bias

Dibagian berikut merupakan bagaimana nilai-nilai yang diturunkan selama periode pengamatan diterapkan untuk memperbaiki data simulasi di masa lalu, sekarang dan masa depan. Dalam menyesuaikan rata-rata bulanan dan variabilitas harian data, Hempel dkk, (2013) menggabungkan dua pendekatan yang dijelaskan dalam sub bab 2.7.1 dan 2.7.2.

#### 2.7.3.1. Temperatur

Menghitung nilai temperatur rata-rata harian residu dari ESM untuk seluruh periode aplikasi dengan cara yang sama seperti sebelumnya untuk periode pengamatan (persamaan 2.33). Fungsi transfer linier  $f$  (persamaan 2.35) kemudian diterapkan untuk menyesuaikan variabilitas harian. Dalam menghindari diskontinuitas pada transisi antara bulan, faktor bobot untuk sebelumnya (indeks  $m$ ), sekarang (indeks 0) dan bulan berikutnya (indeks  $p$ ).

$$d_m = 0,5 \cdot (|d| - d), \quad (2.42)$$

$$d_0 = 1 - |d|, \quad (2.43)$$

$$d_p = 0,5 \cdot (|d| + d) \quad (2.44)$$

Dievaluasi tergantung pada hari dalam bulan  $i_{hari}$  dan jumlah hari dalam bulan itu  $n_{hari}$ ,

$$d = \frac{i_{day} - 1}{n_{day} - 1} - 0,5 \quad (2.45)$$

untuk paruh pertama (kedua) *slope* bulan fungsi *transfer linier* dari bulan  $B_m$  ( $B_p$ ) sebelumnya (berikut) diperhitungkan. Jumlah *slope* yang tertimbang.

$$\bar{B} = d_m B_m + d_0 B + d_p B_p \quad (2.46)$$

Kemudian diterapkan pada nilai suhu rata-rata harian residual, yang mengarah pada nilai residual yang dikoreksi secara bias.

$$\Delta \tilde{T}_{ij}^{ESM} = \bar{B} \cdot \Delta T_{ij}^{ESM} \quad (2.47)$$

Bersama dengan persamaan ini koreksi dalam persamaan (2.28) dapat diperpanjang.

$$\tilde{T}_{ij}^{ESM} = C + T_i^{ESM} + \Delta \tilde{T}_{ij}^{ESM} \quad (2.48)$$

Hal berhasil mempertahankan perubahan suhu absolut jangka panjang dalam simulasi (ESM), sementara menyesuaikan variabilitas harian tentang rata-rata bulanan (jika  $\bar{B} = B$ ) Hempel dkk, (2013). Konstanta  $C$  muncul dari koreksi suhu rata-rata bulanan (persamaan 2.27) dan menjamin kesepakatan antara rata-rata bulanan jangka panjang dari data yang diamati dan yang disimulasikan. Nilai bulanan  $C$  diinterpolasi ke nilai harian,  $\bar{C}$ , menggunakan pendekatan pembobotan yang sama seperti untuk *slope*  $B$  (persamaan 2.46), sehingga mencegah lompatan dalam deret waktu pada transisi antara bulan. Untuk  $\bar{C} \approx C$  trennya, kecuali untuk penyimpangan yang sangat kecil, dipertahankan.

### 2.7.3.2. Curah Hujan

Dalam kasus curah hujan, interpolasi serupa (persamaan 2.46) dari faktor koreksi bulanan,  $C$  (persamaan 2.30), dengan nilai harian kurang tepat karena nilai yang diturunkan dapat sangat bervariasi dari bulan ke bulan (karena tingginya variabilitas pada skala waktu yang berbeda). Hal yang sama berlaku untuk parameter fungsi transfer ( $a$ ,  $b$  dan  $\tau$  dalam persamaan 2.40 dan 2.41).

Menggunakan ambang  $\epsilon_m$  dan  $\epsilon_d$  (persamaan 2.36 dan 2.37) yang ditentukan sebelumnya untuk periode pengamatan untuk membedakan hari kering dan bulan dari yang basah pada periode aplikasi.

Semua hari di bulan-bulan kering, Hempel dkk, (2013) hanya menerapkan faktor multiplikasi  $C$  untuk koreksi rata-rata jangka panjang lihat persamaan 2.30 dan 2.31). Pada bulan basah, frekuensi hari kering disesuaikan dengan mengatur semua nilai dibawah ambang hari kering  $\epsilon_d$  ke nol,

$$\hat{P}_{ij}^{ESM} = 0, \text{ jika } (P_{ij}^{ESM} \leq \epsilon_d) \text{ dan } (P_i^{ESM} > \epsilon_m) \quad (2.49)$$

dengan cara yang sama pada sub bab 2.7.2, didistribusikan kembali curah hujan total dari hari-hari kering ini secara seragam di antara hari-hari hujan di bulan itu (persamaan 2.38). Nilai curah hujan yang diperoleh dinormalisasi dengan rata-rata selama hari-hari basah (persamaan 2.39), dan fungsi transfer  $g$  (persamaan 2.40 dan 2.41) diterapkan pada nilai-nilai normal ini. Aplikasikan ke periode pengamatan (di mana fungsi transfer diturunkan) prosedur ini memastikan bahwa nilai curah hujan yang dikoreksi tidak negatif. Hal ini tidak selalu berlaku untuk semua periode waktu, karena nilai curah hujan terendah dalam data ESM yang tidak bias mungkin berada dibawah  $\delta\hat{P}_{\min}^{ESM}$  (meskipun pengecualian tersebut jarang terjadi). Nilai negatif yang timbul dari proses koreksi ditetapkan ke nol. Pemotongan seperti itu mengubah rata-rata bulanan. Agar menghindari perubahan curah hujan rata-rata bulanan ini, faktor koreksi digunakan untuk memastikan bahwa rata-rata hari hujan normal yang dikoreksi adalah kesatuan dalam setiap bulan dan tahun. Konservasi  $\hat{P}_i^{ESM}$  dipastikan, yaitu rata-rata selama hari-hari basah dalam sebulan setelah redistribusi gerimis tetapi sebelum normalisasi. Selain itu, penyesuaian variabilitas dipertahankan. Faktor koreksi dapat diterapkan karena rata-rata bulanan baru sudah dekat dengan persatuan oleh konstruksi, dan dengan demikian perkalian ini tidak secara signifikan mempengaruhi lebar distribusi probabilitas. Tidak dapat diasumsikan untuk redistribusi gerimis, oleh karena itu pendekatan aditif digunakan dalam kasus ini.

Koreksi dalam persamaan 2.31 dapat dijabarkan,

$$\tilde{P}_{i,j}^{ESM} = c \cdot \hat{P}_i^{ESM} \cdot \delta \tilde{P}_{i,j}^{ESM} \quad (2.50)$$

dengan penambahan kondisi hari kering dan bulan kering, redistribusi gerimis, dan normalisasi nilai yang diperbaiki, persamaan 2.50 mempertahankan perubahan curah hujan relatif dalam simulasi (ESM). Faktor koreksi  $C$  diambil dari koreksi rata-rata bulanan curah hujan dan memetakan rata-rata bulanan jangka panjang dari data yang disimulasikan ke data pengamatan. Selain itu, menerapkan persamaan 2.50 menyesuaikan frekuensi hari kering dan variabilitas tentang rata-rata. Batas atas untuk curah hujan ( $400 \text{ mm hari}^{-1}$ ).

## 2.8. Metode Evaluasi Skill

Penelitian ini menggunakan diagram Taylor untuk mengevaluasi *skill* pada masing-masing metode koreksi bias. Diagram Taylor merupakan diagram yang memiliki tiga alat ukur statistik, yaitu *centered Root Mean Square (RMS difference)*, standar deviasi, dan koefisien korelasi yang dikembangkan oleh Taylor pada tahun 2001. Tiga alat ukur statistik tersebut diperoleh dua variabel dan digambarkan dalam satu titik. Diagram Taylor biasanya digunakan dalam bidang klimatologi untuk mengetahui kecocokan antara data observasi dan data simulasi. Berikut merupakan rumus korelasi ( $r$ ) (persamaan 2.51), *centered RMS difference* (E) (persamaan 2.52), dan standar deviasi (SD) (persamaan 2.53) yang terdapat pada diagram Taylor,

$$r_{\hat{x}x} = \frac{\frac{1}{N} \sum_{i=1}^N (\hat{X}_i - \bar{\hat{X}})(X_i - \bar{X})}{SD_{\hat{x}} SD_x} \quad (2.51)$$

$$E = \sqrt{\frac{1}{N} \sum_{i=1}^N \left[ (\hat{X}_i - \bar{\hat{X}}) - (X_i - \bar{X}) \right]^2} \quad (2.52)$$

$$SD_{\hat{x}} = \sqrt{\frac{\sum_{i=1}^N (\hat{X}_i - \bar{\hat{X}})^2}{N}} \quad (2.53)$$

$$SD_x = \sqrt{\frac{\sum_{i=1}^N (X_i - \bar{X})^2}{N}} \quad (2.54)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (\hat{X}_i - X_i)^2}{N}}$$

Keterangan

$\hat{X}_i$  : nilai curah hujan/ temperatur maksimum yang telah terkoreksi ke-i.

$\bar{X}$  : rata-rata curah hujan/temperatur maksimum yang telah terkoreksi.

$X_i$  : nilai curah hujan/ temperatur maksimum observasi ke-i.

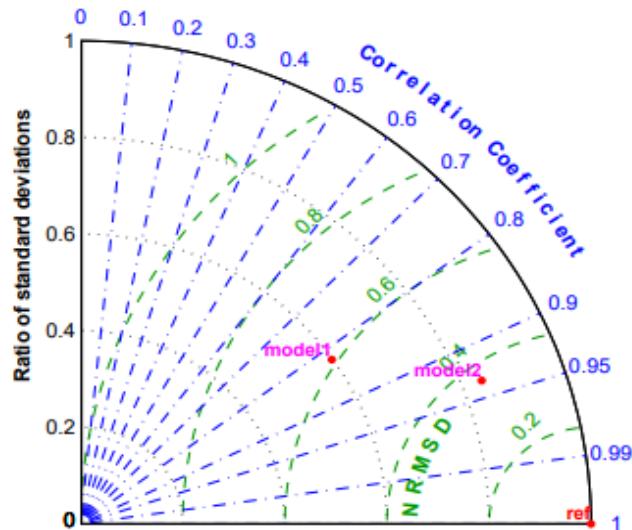
$\bar{X}$  : rata-rata curah hujan/temperatur maksimum observasi.

$SD_{\hat{X}}$  : standar deviasi curah hujan/temperatur maksimum yang telah terkoreksi.

$SD_x$  : standar deviasi curah hujan/temperatur maksimum observasi.

$N$  : banyaknya observasi (time) pada data yang telah terkoreksi dan data observasi.

RMSE : Root Mean Square Error (RMSE)



Gambar 2. 2 Diagram Taylor (Sumber: Taylor, 2001)

Berdasarkan Gambar 2.2 terdapat tiga macam garis yang menunjukkan nilai tiga ukuran statistik, dimana *centered RMS difference* ditunjukkan dengan garis putus-putus lengkung warna hijau, koefisien korelasi ditunjukkan dengan garis warna biru, sedangkan standar deviasi ditunjukkan dengan garis titik-titik warna abu-abu. Titik yang dilambangkan dengan “ref” adalah titik sempurna (observasi) dimana jika titik “model” mendekati titik “ref” maka bisa dikatakan bahwa “model” (simulasi) menyerupai observasi. Semakin dekat dengan titik “ref” maka nilai standar deviasi dan *centered RMS difference* semakin kecil serta koefisien korelasi semakin besar.

Pada penelitian ini juga akan di uji signifikansi nilai korelasi pertitik (grid) untuk seluruh metode dan model pada skenario *historical* dengan statistic uji *t* untuk mengetahui berapa persen pola ERA-Interim diikuti dengan baik oleh luaran ESM pada setiap grid (titik), adapun hipotesisnya sebagai berikut,

$H_0 : \rho = 0$  (Pola ERA-Interim tidak diikuti dengan baik oleh luaran ESM)

$H_1 : \rho \neq 0$  (Pola ERA-Interim diikuti dengan baik oleh luaran ESM)

Statistik uji:

$$t = \frac{r_{\hat{x}x}}{\sqrt{\frac{1 - r_{\hat{x}x}^2}{n - 2}}}$$

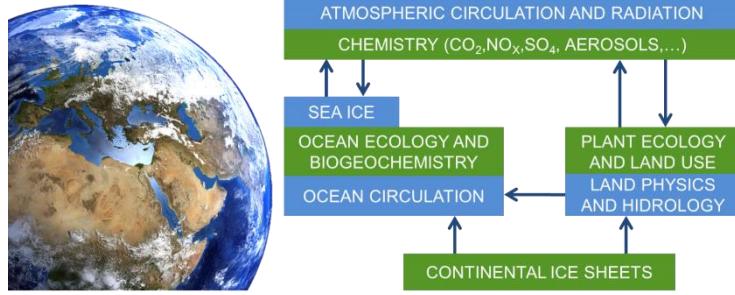
Kriteria pengujian:

Tolak  $H_0$ , jika  $|t_{\text{hitung}}| > t_{\alpha/2;n-2}$

## 2.9. Earth System Model

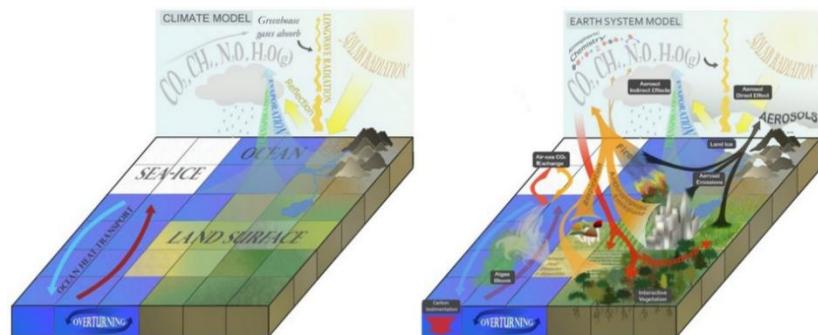
*Earth System Model* (ESM) berupaya mensimulasikan semua aspek yang relevan dari sistem Bumi. *Earth System Model* (ESM) termasuk proses fisik, kimia dan biologis, sehingga mencapai jauh melampaui pendahulunya yaitu *Global Climate Model* (GCM), yang hanya mewakili proses fisik atmosfer dan lautan. Faktanya dalam lapangan, sistem iklim didorong oleh lebih dari proses fisik yang telah dimodelkan secara konvensional (seperti angin, awan, permukaan tanah, lautan dan es). Konsentrasi gas rumah kaca dan aerosol tidak hanya dipengaruhi oleh emisi buatan manusia, karena ini terlibat dalam reaksi fisik dan interaksi

dengan komponen biologis dari sistem bumi, sangat terkait dengan sistem iklim. Adapun struktur dasar dari ESM disajikan pada Gambar 2.2.



Gambar 2. 3 Struktur dasar ESM: kotak biru mewakili proses yang termasuk dalam model iklim; kotak hijau mewakili komponen tambahan yang mungkin termasuk dalam ESM (Sumber: <https://www.climateurope.eu/earth-system-modeling-a-definition>).

*Earth System Models* (ESM) memiliki komponen atmosfer dan lautan dari GCM, untuk ESM menambahkan representasi dari siklus karbon global, vegetasi dinamis, kimia atmosfer, bio-geo-kimia laut dan bahkan lapisan es benua. Adapun perbedaan antara ESM dan GCM disajikan pada Gambar 2.3.



Gambar 2. 4 Fitur utama dari model iklim dan *earth system models*: *earth system models* mendapatkan kompleksitas dengan mempertimbangkan proses biologis dan kimia yang umpan balik ke dalam fisika iklim (Sumber: <https://www.climateurope.eu/earth-system-modeling-a-definition>)

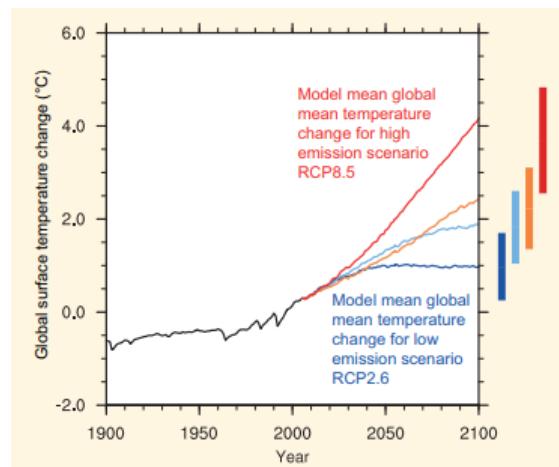
*Earth System Model* (ESM) dapat mensimulasikan bagaimana komponen berubah seiring waktu sebagai respons terhadap aktivitas antropogenik dan perubahan kondisi iklim. Oleh karena itu, perubahan iklim akan mempengaruhi konsentrasi gas rumah kaca dan aerosol yang pada gilirannya akan memberi umpan balik kepada iklim. Karenanya ESM mampu mewakili pengaruh manusia terhadap iklim secara lebih lengkap. *Earth System Model* (ESM) disusun oleh seperangkat persamaan yang menggambarkan sirkulasi atmosfer dan samudera dan termodinamika, tetapi juga proses biologis dan kimia yang memberi umpan balik kepada fisika iklim, semuanya diselesaikan untuk sejumlah lokasi di ruang angkasa yang membentuk kisi tiga dimensi di atas permukaan Bumi dan dibawah permukaan lautan.

Seperti GCM, ESM dikembangkan untuk simulasi, prediksi, dan pembuatan skenario iklim, serta digunakan untuk mempelajari variabilitas iklim dan mengkaji dampak perubahan iklim. Menurut IPCC (2007) skenario bukanlah metode untuk memprediksi masa mendatang tetapi untuk memahami ketidakpastian dan gambaran alternatif tentang iklim dimasa yang akan datang. IPCC telah menyeusun beberapa skenario iklim untuk mengetahui proyeksi iklim global dan regional tahun 2100 melalui skenario *Representative Concentration Pathway* (RCP) (Moss dkk, 2010). Skenario RCP didasarkan pada *Radiative Forcing* (RF) yang ditimbulkan oleh konsentrasi gas rumah kaca. Terdapat empat skenario RCP yaitu RCP 4.5, RCP 2.6, RCP 6.0, dan RCP 8.5 sebagaimana disajikan dalam Tabel 2.1.

Tabel 2. 1 Skenario RCP

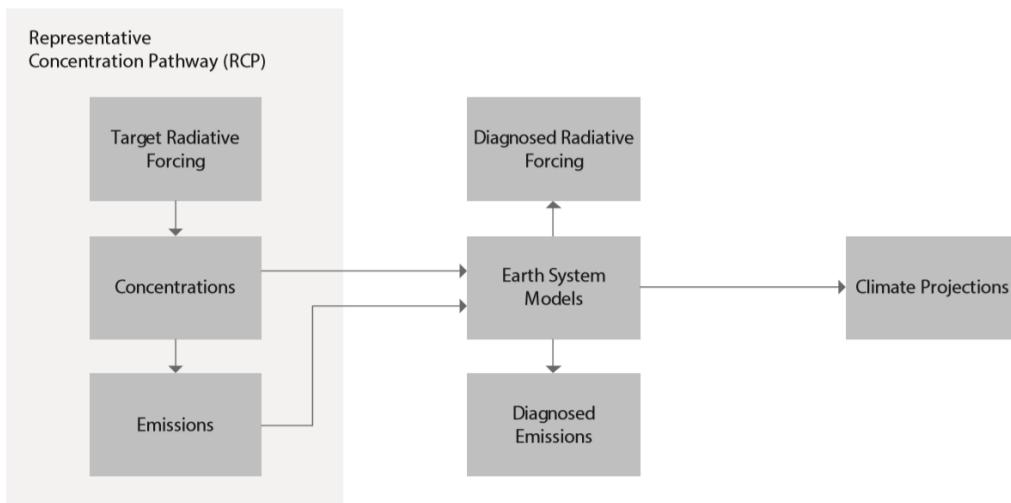
Skenario	Radiative Forcing (RF)	Konsentrasi (ppm)	Pathway
RCP 8.5	>8.5 W/m <sup>2</sup> pada 2100	Setara dengan CO <sub>2</sub> >1370 pada 2100	Meningkat
RCP 6.0	~6.0 W/m <sup>2</sup> Stabil setelah 2100	Setara dengan CO <sub>2</sub> ~850 stabil setelah 2100	Stabil tanpa melampaui
RCP 4.5	~4.5 W/m <sup>2</sup> Stabil setelah 2100	Setara dengan CO <sub>2</sub> ~650 stabil setelah 2100	Stabil tanpa melampaui
RCP 2.6	Mencapai ~3 W/m <sup>2</sup> sebelum 2100 dan kemudian turun	Mencapai ~490 setara dengan CO <sub>2</sub> sebelum 2100 dan kemudian turun	Mencapai nilai tertinggi kemudian menurun

Sumber: Moss dkk, 2010



Gambar 2. 5 Perubahan rata-rata temperatur global CMIP5 *historical* (1900-2005), RCP2.6 (biru tua), RCP 4.5 (biru muda), RCP6.0 (orange), dan RCP8.5 (merah)

Skenario pada Tabel 2.1 dibangun dari besaran emisi yang masih dapat dihasilkan agar kenaikan temperatur bumi tidak melebihi 2°C. Berikut merupakan gambaran alur dari pembentukan proyeksi iklim.



Gambar 2. 6 Alur *Climate Projection* (Sumber: <https://www.ipcc.ch/site/assets/uploads/2018/02>)

Berdasarkan Gambar 2.6 *Representative Concentration Pathway* (RCP) dimasukan ke dalam konsentrasi dan emisi gas rumah kaca menggunakan *Integrated Assessment Model* (IAMs). Ini kemudian digunakan sebagai input untuk *Earth System Models* (ESM) dinamis dalam simulasi yang didorong oleh

konsentrasi (majoritas percobaan proyeksi) atau didorong oleh emisi (hanya untuk skenario RCP8.5). Aerosol dan faktor *forcing* lainnya diimplementasikan dengan cara yang berbeda di setiap ESM. Proyeksi ESM masing-masing memiliki RF yang berpotensi berbeda, yang dapat dilihat sebagai output dari model dan yang mungkin tidak sesuai dengan tepat tingkat RF yang ditunjukkan oleh nomenklatur RCP. Demikian pula, untuk percobaan yang didorong konsentrasi, emisi yang konsisten dengan konsentrasi yang didiagnosis dari ESM mungkin berbeda dari yang ditentukan dalam RCP (didiagnosis dari IAM). Model yang berbeda menghasilkan respons yang berbeda bahkan di bawah RF yang sama. Ketidakpastian menyebar melalui rantai dan menghasilkan penyebaran proyeksi ESM. Penyebaran proyeksi ESM hanya salah satu cara menilai ketidakpastian dalam proyeksi. Metode alternatif, yang menggabungkan informasi dari model dan pengamatan sederhana maupun kompleks melalui model statistik atau penilaian dari ahli, juga dapat digunakan untuk mengukur ketidakpastian tersebut.

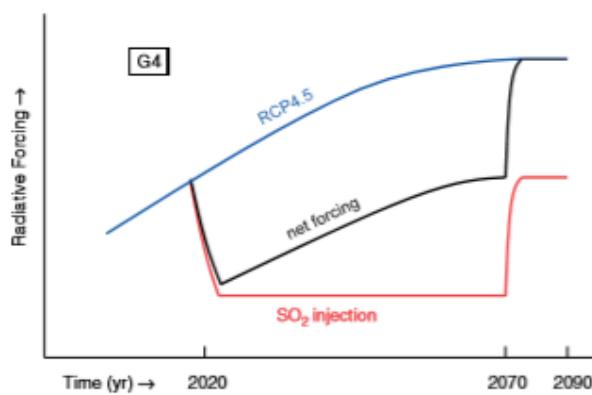
Selain RCP, skenario untuk proyeksi iklim dilakukan oleh Kravitz dkk, (2011) yang dikenal dengan *Geoengineering Model Intercomparison Project* (GeoMIP). Terdapat empat skenario yaitu G1, G2, G3, dan G4 yang relevan dengan strategi geoengineering dengan menyuntikkan aerosol sulfat stratosfer dalam upaya mengimbangi pemanasan yang ditimbulkan oleh efek rumah kaca. Berikut disajikan keterangan eksperimen pada Tabel 2.2.

Tabel 2. 2 Skenario GeoMIP

<b>Skenario</b>	<b>Keterangan</b>
G1	Melipatgandakan konsentrasi CO <sub>2</sub> (yang diukur dari tingkat pra-industri) sekaligus mengurangi konstanta matahari untuk melawan tekanan.
G2	Kombinasi dengan peningkatan 1% dalam konsentrasi CO <sub>2</sub> per tahun, secara bertahap mengurangi konstanta matahari untuk menyeimbangkan perubahan kekuatan radiasi
G3	Dalam kombinasi dengan RCP4.5, mulai tahun 2020, secara bertahap meningkatkan jumlah SO <sub>2</sub> atau aerosol sulfat yang disuntikkan, dengan tujuan menjaga suhu rata-rata global hampir konstan. Injeksi akan dilakukan pada satu titik di ekuator atau secara global seragam. Jumlah aktual injeksi per tahun dapat didasarkan pada Hansen et al. (2005) tetapi mungkin perlu disesuaikan untuk masing-masing model.
G4	Dalam kombinasi dengan pemakaian RCP4.5, mulai tahun 2020, injeksi harian jumlah konstan SO <sub>2</sub> pada tingkat 5 Tg SO <sub>2</sub> per tahun pada satu titik di Ekuator melalui stratosfer yang lebih rendah (ketinggian ~16–25 km) atau setara model tertentu. Suntikan akan berlanjut pada tingkat yang sama selama masa simulasi.

Sumber: Kravitz dkk, 2011

Data skenario yang digunakan dalam penelitian ini adalah skenario *historical*, RCP 4.5, dan skenario G4. Adapun contoh model dari skenario tersebut adalah *Beijing Normal University Earth System Model* (BNU-ESM), *Marine-Earth Science and Technology Earth System Model Chemistry* (MIROC-ESM-CHEM), dan *Marine-Earth Science and Technology Earth System Model* (MIROC-ESM). Berikut merupakan gambar rancangan skenario G4 yang dilakukan Kravits dkk, (2011).



Gambar 2. 7 Skenario injeksi SO<sub>2</sub> skenario G4 (sumber: Kravitz, dkk 2011)

## 2.10. Downscaling

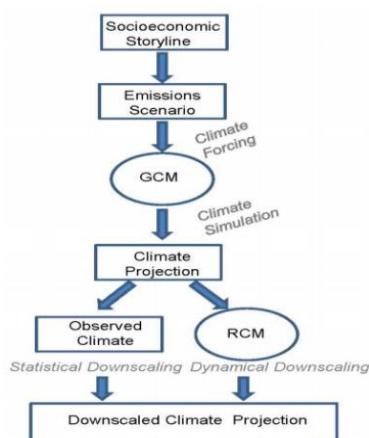
Luaran ESM memiliki resolusi yang rendah yang tidak dapat meresolusikan kejadian-kejadian atau efek-efek berskala *meso* atau lokal dari keberadaan heterogenitas topografi, vegetasi, serta komposisi tanah (Ratag, 2001). Untuk kawasan yang bertipe topografi relatif homogen dengan ketinggian yang tidak jauh berbeda, parameter-parameter skala kecil dari ESM mampu memprediksi variabilitas skala lokal. Perubahan iklim yang terjadi dalam satu grid kemungkinan besar akan berlaku secara merata pada wilayah yang homogen tersebut. Sedangkan apabila terdapat wilayah yang memiliki topografi yang relatif heterogen yang sangat dipengaruhi oleh iklim regional, sehingga perlu dilakukan pendekatan *downscaling*. *Downscaling* adalah pendekatan untuk menghasilkan model iklim

resolusi tinggi berdasarkan pada informasi skala besar baik dari data analisis ulang atau model iklim global (Tang dkk, 2016).

Model berskala lokal memiliki resolusi tinggi dengan ukuran grid lebih kecil dari pada grid dari ESM dapat memperhitungkan topografi lokal, vegetasi, dan jenis tanah, serta mentranslasikan hasil prediksi ESM pada skala lokal. Wilby dan Wigley (1997) menyatakan bahwa *downscaling* dibagi menjadi empat kategori yaitu, metode regresi, pendekatan berbasis pola cuaca, generator cuaca stokastik dan model area terbatas. Terdapat dua jenis pendekatan *downscaling* yaitu (1) *dynamical downscaling* (DS) dan (2) *statistical downscaling* (SD). *Dynamical downscaling* dilakukan dengan cara menetapkan ESM terserang dengan resolusi spasial yang lebih tinggi, sedangkan SD berdasarkan hubungan fungsional antara prediktor berskala besar dan variabel respon berskala kecil. Berikut ilustrasi teori *downscaling*.



Gambar 2. 8 Ilustrasi *downscaling* (sumber: Siwilia, 2013)



Gambar 2. 9 Ilustrasi Komponen Yang Terlibat dalam Pengembangan Proyeksi Iklim Global dan Regional (Sumber: Daniels, 2012)

## 2.11. Indeks Iklim Ekstrim

Indikasi dari dampak perubahan iklim salah satunya adalah terjadinya curah hujan yang tidak menentu, intensitas yang cenderung meningkat dan pergeseran awal serta panjang musim yang menyimpang atau ekstrim dibandingkan kondisi normalnya. Indeks iklim ekstrim yang digunakan pada umumnya berhubungan dengan curah hujan dan suhu udara (Nugroho dkk, 2019). Banyak penelitian menggunakan indeks iklim ekstrim dengan menggunakan standar *Expert Team on Climate Change Detection and Indices* (ETCCDI).

Tabel 2. 3 Indeks Ekstrim ETCCDI

<b>Indek</b>	<b>Definisi</b>	<b>Interval</b>	<b>Satuan</b>
PRCPTOT	Curah hujan tahunan	Tahunan	mm
R99p	Hari sangat basah (ekstrim)	Tahunan	mm
R95p	Hari sangat basah	Tahunan	mm
CWD	Hari hujan berturut-turut	Tahunan	Hari
CDD	Hari kering berturut-turut	Tahunan	Hari
R20mm	Jumlah hari-hari hujan yang sangat deras	Tahunan	Hari
R10mm	Jumlah hari-hari hujan lebat	Tahunan	Hari
SDII	Jumlah curah hujan tahunan dibagi jumlah hari hujan (hujan $\geq 1.0$ mm)	Tahunan	mm
RX5day	Jumlah curah hujan maksimal 5 hari	Bulanan	mm
RX1day	Jumlah curah hujan maksimal 1 hari	Bulanan	mm
DTR	Kisaran suhu diurnal	Bulanan	°C
CSDI	<i>Cold-spell duration</i>	Tahunan	Hari
WSDI	<i>Warm-spell duration</i>	Tahunan	Hari
TX90p	<i>Warm days</i>	Bulanan	Hari
TN90p	<i>Warm nights</i>	Bulanan	Hari
TX10p	<i>Cold days</i>	Bulanan	Hari
TN10p	<i>Cold nights</i>	Bulanan	Hari
TNN	Suhu minimum paling tinggi dalam satu bulan	Bulanan	°C
TXN	Suhu minimum paling rendah dalam satu bulan	Bulanan	°C
TNX	Suhu maksimum paling rendah dalam satu bulan		
TXX	Suhu maksimum paling tinggi dalam satu bulan	Bulanan	°C
GSL	<i>Growing-season length</i>	Tahunan	°C
TR	<i>Tropical nights</i>	Tahunan	Hari
ID	<i>Ice days</i>	Tahunan	Hari
SU	<i>Summer days</i>	Tahunan	Hari
FD	<i>Frost days</i>	Tahunan	hari

Sumber: Sobie dan Murdock, 2017

Pada penelitian ini akan di ambil dua indek untuk curah hujan dan temperatur maksimum, indeks ekstrim adalah RX1day, sedangkan untuk temperatur maksimum adalah TXx.

## **BAB 3**

### **METODOLOGI PENELITIAN**

#### **3.1. Sumber Data**

Data yang digunakan pada penelitian ini adalah data sekunder. Terdapat dua data yang digunakan dalam penelitian ini yaitu data reanalisis dan data skenario. Rincian data penelitian yang digunakan antara lain akan dipaparkan sebagai berikut.

1. Sumber data pertama diperoleh dari *Coupled Model Intercomparison Project* (CMIP5) dan *The Geoengineering Model Intercomparion Project* (GeoMIP) dengan website sebagai berikut: <https://esgf-node.ipsl.upmc.fr/search/cmip5-ipsl/>. berupa skenario G4, RCP4.5, dan *historical*.
2. Sumber data kedua yaitu data reanalisis yang diperoleh dari website *European Center for Medium-Range Weather Forecast* (ECMWF) ERA-Interim dengan website sebagai berikut: <https://apps.ecmwf.int/datasets/data/interim-full-daily/levtype=sfc>.

#### **3.2. Variabel Penelitian**

Variabel yang digunakan dalam penelitian ini sebagai berikut.

1. Variabel data luaran ESM skenario G4, RCP4.5, dan *historical* berupa data curah hujan dan temperatur maksimum, pada kordinat  $6,97^{\circ} - 12,55^{\circ} LS$  dan  $92,81^{\circ} - 143,43^{\circ} BT$ . Pemilihan variabel curah hujan dan temperatur maksimum berdasarkan penelitian Vimont dkk, (2009). Terdapat beberapa model di dalam masing-masing skenario dan setiap model memiliki resolusi yang berbeda berda diantaranya terdapat pada Tabel 3.1. Variabel curah hujan dan temperatur maksimum luaran ESM skenario G4, RCP4.5, dan *historical* bersekala global.

Tabel 3. 1 Model Luaran ESM

No	Skenario	Model	Variabel	Periode	Resolusi
1	G4	BNU-ESM	Curah hujan	1-01-2006 s.d 31-12-2100	2,8°×2,8°
			Tasmax	1-01-2006 s.d 31-12-2100	2,8°×2,8°
		MIROC-ESM-CHEM	Curah hujan	1-01-2006 s.d 31-12-2090	2,8°×2,8°
			Tasmax	1-01-2006 s.d 31-12-2090	2,8°×2,8°
	RCP4.5	MIROC-ESM	Curah hujan	1-01-2006 s.d 31-12-2090	2,8°×2,8°
			Tasmax	1-01-2006 s.d 31-12-2090	2,8°×2,8°
		BNU-ESM	Curah hujan	1-01-2006 s.d 31-12-2100	2,8°×2,8°
			Tasmax	1-01-2006 s.d 31-12-2100	2,8°×2,8°
2	RCP4.5	MIROC-ESM	Curah hujan	1-01-2006 s.d 31-12-2100	2,8°×2,8°
			Tasmax	1-01-2006 s.d 31-12-2100	2,8°×2,8°
		MIROC-ESM-CHEM	Curah hujan	1-01-2006 s.d 31-12-2100	2,8°×2,8°
			Tasmax	1-01-2006 s.d 31-12-2100	2,8°×2,8°
	Historical	BNU-ESM	Curah hujan	1-01-1950 s.d 31-12-2005	2,8°×2,8°
			Curah hujan	1-01-1850 s.d 31-12-2005	2,8°×2,8°
		MIROC-ESM-CHEM	Tasmax	1-01-1850 s.d 31-12-2005	2,8°×2,8°
			Curah hujan	1-01-1850 s.d 31-12-2005	2,8°×2,8°
3	Historical	MIROC-ESM	Tasmax	1-01-1850 s.d 31-12-2005	2,8°×2,8°

2. Variabel pada data reanalisis ERA-Interim ECMWF berupa data curah hujan dan temperatur maksimum harian di Indonesia pada koordinat  $6^{\circ} - 11^{\circ} LS$  dan  $95^{\circ} - 141,25^{\circ} BT$ . Data curah hujan dan temperatur maksimum dibagi menjadi beberapa data berdasarkan grid koordinat yang telah ditentukan, dimana ukuran grid yang digunakan adalah  $0,25^{\circ} \times 0,25^{\circ}$ . Variabel curah hujan dan temperatur maksimum ERA-Interim ECMWF sebagai proksi observasi bersekala lokal.

### 3.3. Struktur Data

Dalam memudahkan mengetahui pola data maka dibentuklah struktur data berdasarkan variabel yang digunakan, baik untuk variabel prediktor maupun variabel respon. Adapun struktur data untuk data skenario G4, RCP4.5, dan *historical* terdapat pada Tabel 3.2 dan Tabel 3.3.

Tabel 3. 2 Struktur Data Skenario *Historical* Model BNU-ESM

Periode	6,97° LS				4,18° LS				...° LS	-12,55° LS			
	92,81° BT	95,62° BT	...	143,43° BT	92,81° BT	95,62° BT	...	143,43° BT	...	92,81° BT	95,62° BT	...	143,43° BT
1 Jan 1980	X <sub>1,1,1</sub>	X <sub>1,1,2</sub>	...	X <sub>1,1,19</sub>	X <sub>1,2,1</sub>	X <sub>1,2,2</sub>	...	X <sub>1,2,19</sub>	...	X <sub>1,8,1</sub>	X <sub>1,8,2</sub>	...	X <sub>1,8,19</sub>
2 Jan 1980	X <sub>2,1,1</sub>	X <sub>2,1,2</sub>	...	X <sub>2,1,19</sub>	X <sub>2,2,1</sub>	X <sub>2,2,2</sub>	...	X <sub>2,2,19</sub>	...	X <sub>2,8,1</sub>	X <sub>2,8,2</sub>	...	X <sub>2,8,19</sub>
:	:	:	:	:	:	:	:	:	:	:	:	:	:
31 Des 2005	X <sub>9410,1,1</sub>	X <sub>9410,1,2</sub>	...	X <sub>9410,1,19</sub>	X <sub>9410,2,1</sub>	X <sub>9410,2,2</sub>	...	X <sub>9410,2,19</sub>	...	X <sub>9410,8,1</sub>	X <sub>9410,8,2</sub>	...	X <sub>9410,8,19</sub>

Keterangan.

- a. X<sub>a,b,c</sub> = X adalah data dari variabel prediktor (curah hujan/ temperatur maksimum) pada hari ke-i, koordinat lintang ke-j, dan koordinat bujur ke-k.
- b. Koordinat lintang dan bujur untuk setiap model dari skenario berbeda, keterangan koordinat lintang dan bujur setiap model skenario pada *table 3.1*

Berikut adalah struktur data untuk data reanalisis ERA-Interim ECMWF untuk curah hujan atau temperatur maksimum yang ditunjukkan seperti pada Tabel 3.3 sebagai berikut.

Tabel 3. 3 Struktur Data ECMWF

Periode	$5^{\circ} LS$				$5,25^{\circ} LS$				$\dots^{\circ} LS$	$-10^{\circ} LS$			
	$94^{\circ} BT$	$94,25^{\circ} BT$	$\dots$	$141^{\circ} BT$	$94^{\circ} BT$	$94,25^{\circ} BT$	$\dots$	$141^{\circ} BT$	$\dots$	$94^{\circ} BT$	$94,25^{\circ} BT$	$\dots$	$141^{\circ} BT$
1 Jan 1980	X <sub>1,1,1</sub>	X <sub>1,1,2</sub>	$\dots$	X <sub>1,1,189</sub>	X <sub>1,2,1</sub>	X <sub>1,2,2</sub>	$\dots$	X <sub>1,2,19</sub>	$\dots$	X <sub>1,61,1</sub>	X <sub>1,61,2</sub>	$\dots$	X <sub>1,8,189</sub>
2 Jan 1980	X <sub>2,1,1</sub>	X <sub>2,1,2</sub>	$\dots$	X <sub>2,1,189</sub>	X <sub>2,2,1</sub>	X <sub>2,2,2</sub>	$\dots$	X <sub>2,2,19</sub>	$\dots$	X <sub>2,61,1</sub>	X <sub>2,61,2</sub>	$\dots$	X <sub>2,8,189</sub>
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
31 Des 2005*	X <sub>9410,1,1</sub>	X <sub>9410,1,2</sub>	$\dots$	X <sub>9410,1,189</sub>	X <sub>9410,2,1</sub>	X <sub>9410,2,2</sub>	$\dots$	X <sub>9410,2,19</sub>	$\dots$	X <sub>9410,61,1</sub>	X <sub>9410,61,2</sub>	$\dots$	X <sub>9410,8,189</sub>

Keterangan.

X<sub>a,b,c</sub> = X adalah data dari variabel prediktor (curah hujan/ temperatur maksimum) pada hari ke-i, koordinat lintang ke-j, dan koordinat bujur ke-k.

\*) tanggal menyesuaikan periode skenario, apabila periode skenario melebihi periode 31 Desember 2018 maka data ECMWF yang terakhir adalah pada tanggal tersebut.

### **3.4. Tahapan Analisis**

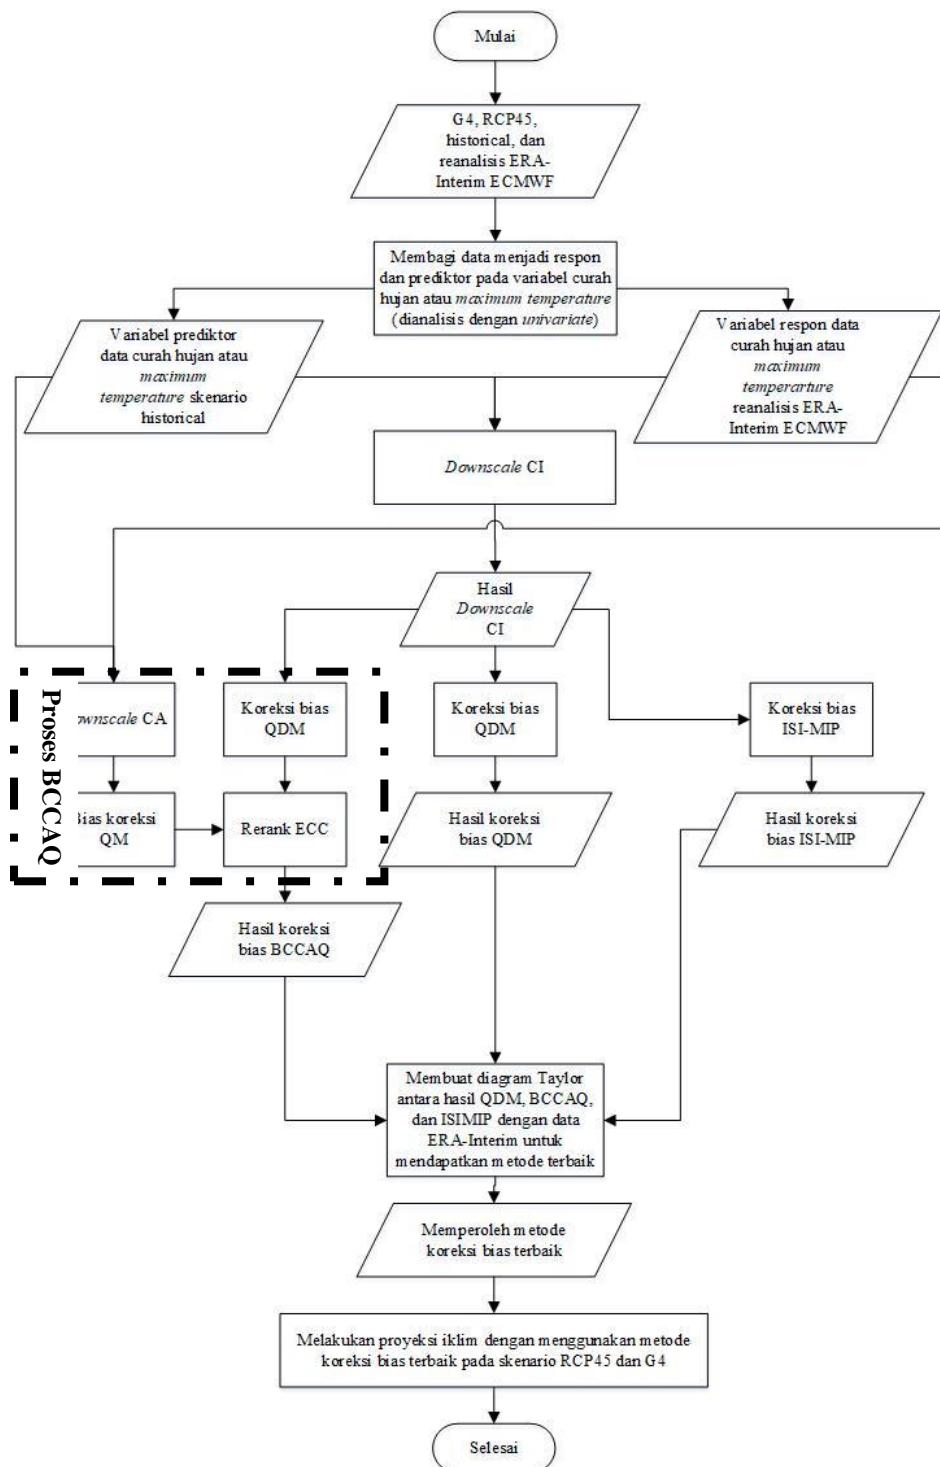
Tahapan analisis yang dilakukan untuk mencapai tujuan penelitian ini adalah sebagai berikut.

1. Melakukan eksplorasi data dengan plot data *time series* pada variabel curah hujan dan temperatur maksimum masing-masing model (BNU-ESM, MIROC-ESM, dan MIROC-ESM-CHEM) luaran skenario (G4, RCP4.5, *historical*) dan reanalisis ERA-Interim ECMWF untuk mengetahui karakteristik curah hujan dan temperatur maksimum di Indonesia.
2. Membagi data menjadi variabel curah hujan dan temperatur maksimum menjadi variabel respon (porsesi observasi berskala lokal) dan prediktor (proksi berskala global), dimana variabel respon adalah data reanalisis ERA-Interim ECMWF dan variabel prediktor adalah skenario *historical*.
3. Melakukan *downscaling* parsial atau *univariate* pada masing-masing variabel curah hujan dan temperatur maksimum menggunakan metode *climate imprint* (CI) pada setiap model dalam skenario *historical* terhadap data reanalisis ERA-Interim ECMWF.
4. Melakukan koreksi bias hasil *downscaling* CI dengan metode *Quantile Delta Mapping* (QDM).
  - a. Hasil *downscaling* CI dilakukan bias koreksi menggunakan metode QDM dengan menyamakan CDF secara empiris antara ERA-Interim ECMWF dengan skenario *historical*.
  - b. Menghitung korelasi dan RMSE data hasil koreksi bias QDM (data terkoreksi) setiap model pada skenario *historical* dengan data reanalisis ERA-Interim ECMWF.
  - c. Membentuk peta korelasi dan RMSE.
  - d. Uji signifikansi nilai korelasi per-titik (grid).
5. Melakukan koreksi bias hasil *downscaling* CI dengan metode *Bias Correction/Constructed Analogues with Quantile Mapping* (BCCAQ). Adapun langkahnya sebagai berikut.
  - a. Hasil *downscaling* CI dilakukan bias koreksi menggunakan metode QDM dengan menyamakan CDF secara empiris antara ERA-Interim ECMWF dengan skenario *historical*.

- b. Melakukan *downscaling* dengan metode *Constructed Analogues* (CA).
  - c. Melakukan bias koreksi QM pada hasil *downscaling* CA dengan menyamakan CDF secara empiris antara ERA-Interim ECMWF dengan skenario *historical*.
  - d. Menggabungkan output dari (a) dan (c) di setiap titik *grid* skala halus dan menyusun ulang dalam bulan tertentu sesuai dengan peringkat CA harian, yaitu, menggunakan bentuk *Empirical Copula Copuling*.
  - e. Mendapatkan curah hujan harian yang sudah terkoreksi bias.
  - f. Menghitung korelasi dan RMSE data hasil koreksi bias BCCAQ (data terkoreksi) setiap model pada skenario *historical* dengan data reanalisis ERA-Interim ECMWF.
  - g. Membentuk peta korelasi dan RMSE.
  - h. Uji signifikansi nilai korelasi per-titik (*grid*).
6. Melakukan koreksi bias hasil *downscaling* CI dengan metode *Inter-Sectoral Impact Model Intercomparison Project* (ISI-MIP) dengan langkah sebagai berikut.
- a. Koreksi bias untuk curah hujan.
    - i. Menghitung nilai koreksi ( $C$ ) rata-rata bulanan (persamaan 2.30).
    - ii. Menyesuaikan frekuensi hari basah, Menentukan nilai ambang batas untuk mengklasifikasi bulan kering atau bulan basah.
    - iii. Normalisasi curah hujan, dengan membagi setiap bulan dengan rata-rata (setiap tahun) (persamaan 2.34).
    - iv. Hasil normalisasi langkah curah hujan observasi dan curah hujan historis didekati dengan pendekatan eksponensial atau pendekatan linier (persamaan 2.40).
    - v. Mengalikan rata-rata bulan tertentu dengan nilai dari fungsi transfer (iv) untuk hari tertentu (persamaan 2.41).
  - b. Koreksi bias untuk temperatur maksimum,
    - i. Menghitung nilai konstan ( $C$ ) (persamaan 2.27).
    - ii. Menghitung variabilitas harian dari residual temperatur maksimum (persamaan 2.33).

- iii. Menerapkan fungsi transfer linier untuk menyesuaikan variabilitas harian (persamaan 2.35).
    - iv. Menghitung diskontinuitas (persamaan 2.42, 2.43, dan 2.44).
    - v. Menghitung jumlah *slope* tertimbang (persamaan 2.46).
    - vi. Menghitung nilai residual yang dikoreksi bias (persamaan 2.47).
    - vii. Mendapatkan nilai temperatur maksimum yang dikoreksi dengan cara memasukan nilai langkah (vi) terhadap persamaan 2.28.
  - c. Menghitung nilai korelasi dan RMSE data hasil koreksi bias ISI-MIP (data terkoreksi) setiap model pada skenario *historical* dengan data reanalisis ERA-Interim ECMWF.
  - d. Membentuk peta korelasi dan RMSE.
  - e. Uji signifikansi nilai korelasi per-titik (grid).
7. Membandingkan *skill* hasil metode koreksi bias QDM, BCCAQ, dan QDM menggunakan diagram Taylor (musiman dan non-musiman).
  8. Mendapatkan metode koreksi bias terbaik.
  9. Memproyeksikan iklim skenario RCP4.5 dan G4 menggunakan metode koreksi bias terbaik.

#### 4.5. Diagram Alir Penelitian



Gambar 3.1 Diagram Alir

## BAB 4

### ANALISIS DAN PEMBAHASAN

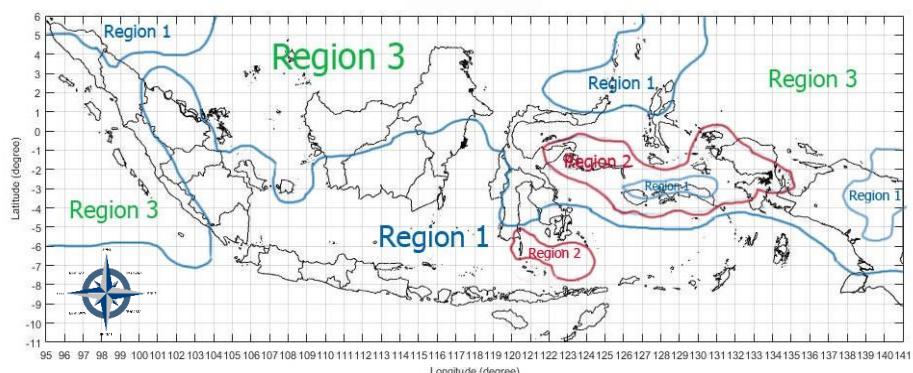
Pada bab ini akan dibahas hasil yang di peroleh dalam penelitian ini, mengenai koreksi bias dengan metode BCCAQ, QDM, dan ISIMIP. Kemampuan bias koreksi dan *downscaling* akan diverifikasi menggunakan diagram Taylor. Metode terbaik akan digunakan untuk proyeksi iklim dengan menggunakan skenario G4 dan RCP4.5.

#### 4.1. Statistika Deskriptif Data Curah Hujan dan Temperatur Maksimum

Statistika deskriptif merupakan gambaran umum dari karakteristik suatu data. Sebelum melakukan penyamaan grid antara data luaran ESM dengan data ERA-Interim ECMWF dengan *statistical downscaling* dan melakukan koreksi bias akan dianalisis secara deskriptif untuk mengetahui karakteristik data curah hujan dan temperatur maksimum di Indonesia. Analisis deskriptif yang dilakukan dalam penelitian ini diantaranya adalah *time series plot* serta peta curah hujan dan temperatur maksimum.

##### 4.1.1. Pembagian Zona

Zona iklim di Indonesia dibagi menjadi 3 region berdasarkan kedekatan dan karakteristik. Gambar 4.1 merupakan pembagian zona iklim yang ada di Indonesia.



Gambar 4. 1 Pembagian Zona Iklim di Indonesia

Region 1 merupakan region bertipe *monsoon* dimana wilayah yang berada pada region tersebut memiliki periode yang jelas antara periode musim kemarau dan musim hujan, tipe curah hujan pada region 1 adalah unimodal (satu puncak musim hujan DJF, dan JJA musim kemarau). Wilayah yang terdapat pada region 1 diantaranya pulau Jawa, Bali, sebagian pulau Sumatra bagian utara, dan sebagian besar region 1 adalah wilayah-wilayah Indonesia bagian selatan.

Region 2 merupakan region bertipe lokal (anti *monsoon*) yang merupakan kebalikan dari region 1. Tipe lokal dicirikan dengan curah hujan unimodal (satu puncak hujan namun berlawanan dengan region tipe 1. Wilayah yang termasuk dalam region 3 diantaranya adalah sebagian pulau Sumatra bagian barat, sebagian pulau Kalimantan bagian Utara, dan bagian timur laut Indonesia.

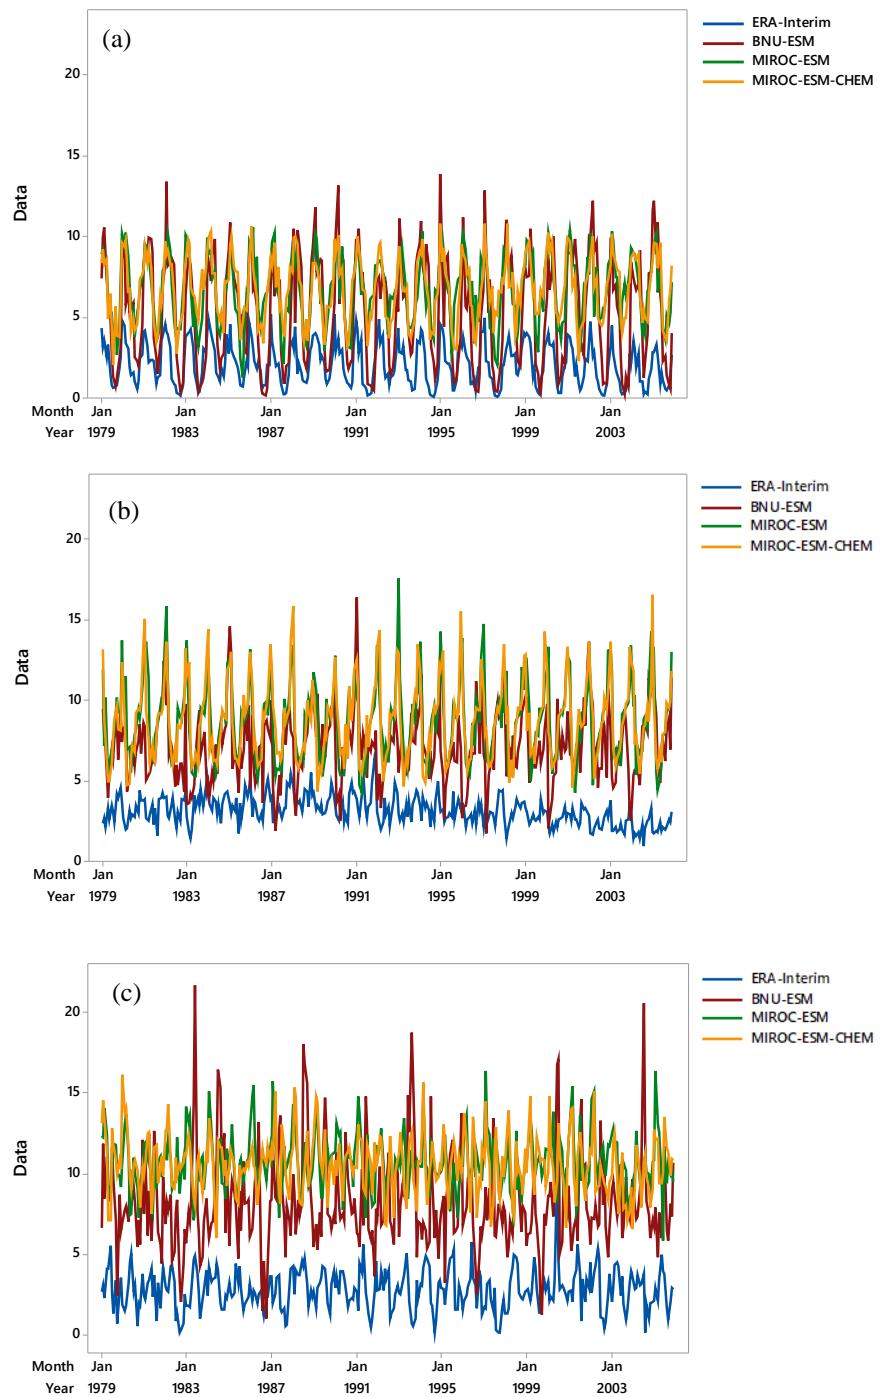
Region 3 merupakan region bertipe *equatorial* dimana wilayahnya memiliki distribusi hujan bimodal (dua puncak musim hujan *maksimal*) hampir sepanjang tahun masuk dalam kriteria musim hujan, biasanya terjadi pada bulan maret dan oktober atau saat terjadi ekinoks. Wilayah yang terdapat pada region 2 diantaranya adalah sedikit kepulauan di bagian selatan pulau Sulawesi, dan sebagian kepulauan Maluku.

#### **4.1.2. Plot Data Skenario *Historical* dan ERA-Interim ECMWF**

Plot data skenario *historical* dan ERA-Interim ECMWF bertujuan untuk melihat apakah terdapat kesamaan pola antara data skenario *historical* dengan ERA-Interim ECMWF pada setiap zona.

a. Curah Hujan

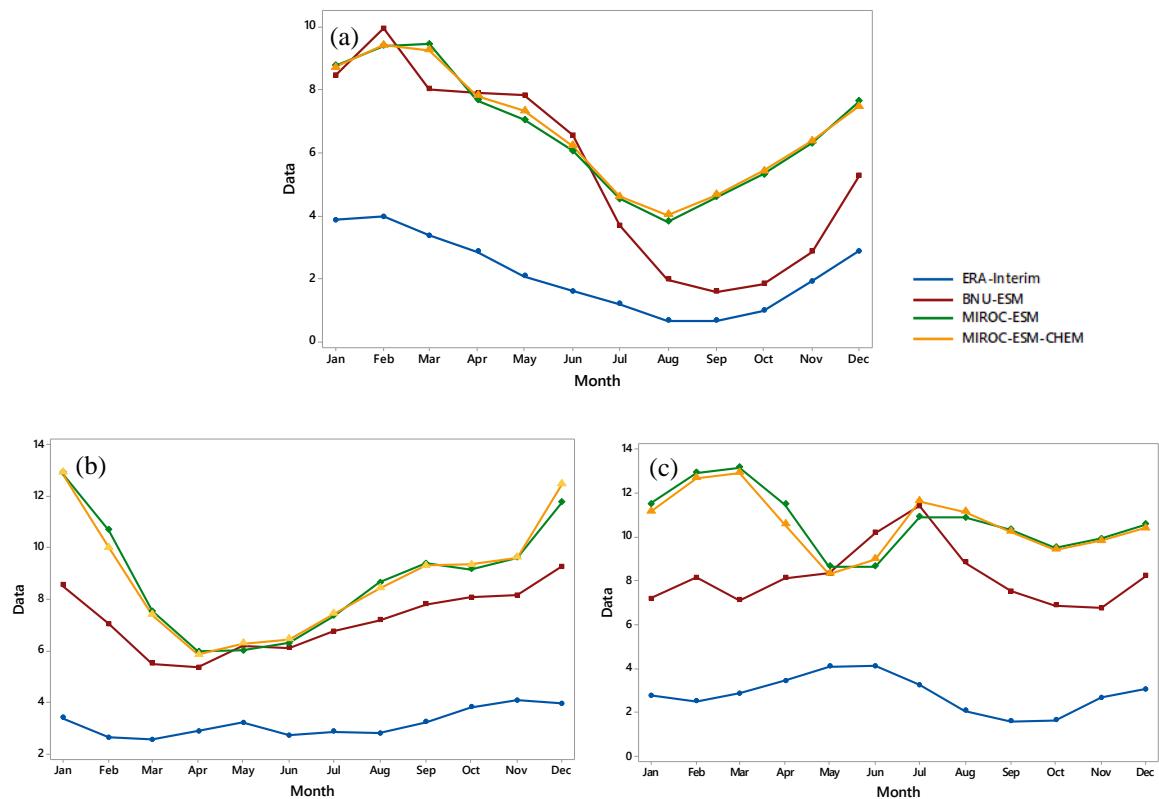
Gambar 4.2 merupakan *time series plot* bulanan yang didapatkan dari rata-rata harian tahun 1979-2005 skenario *historical* yang terdiri dari model BNU-ESM, MIROC-ESM, dan MIROC-ESM-CHEM. Gambar 4.3 merupakan rata-rata dari Gambar 4.2 dengan bulan yang sama untuk mengetahui pola curah hujan yang terjadi pada satu tahun, untuk setiap regionnya.



Gambar 4. 2 Time Series Plot Rata-rata Curah Hujan Bulanan ( $\text{mm}^2$ ) (a) Region 1 (b) Region 2 (c) Region 3

Berdasarkan Gambar 4.2 nilai curah hujan pada data ERA-Interim ECMWF berada dibawah dari curah hujan skenario *historical*, dengan rentan curah hujan ERA-interim ECMWF berada pada kisaran nilai 0-5  $\text{mm}^2$ , sedangkan

skenario *historical* berada pada rentan 1-12 mm<sup>2</sup>. Skenario *historical* model BNU-ESM sangat fluktuatif dibandingkan dengan model MIROC-ESM dan MIROC-ESM-CHEM, sedangkan model MIROC-ESM dan MIROC-ESM-CHEM memiliki pola yang selau sama disetiap periodenya. Region 1 memiliki kesamaan pola antara data ERA-Interim ECMWF dengan skenario *historical* yang sangat mirip dibandingkan dengan region 2 dan region 3. ERA-Interim ECMWF pada region 2 tidak memiliki curah hujan 0 untuk setiap bulannya. Curah hujan pada region 3 lebih tinggi dibandingkan dengan region 2 dan region 1, diakrenakan region 3 hampir setiap tahun musim hujan dan merupakan wilayah yang bertipe *equatorial*.



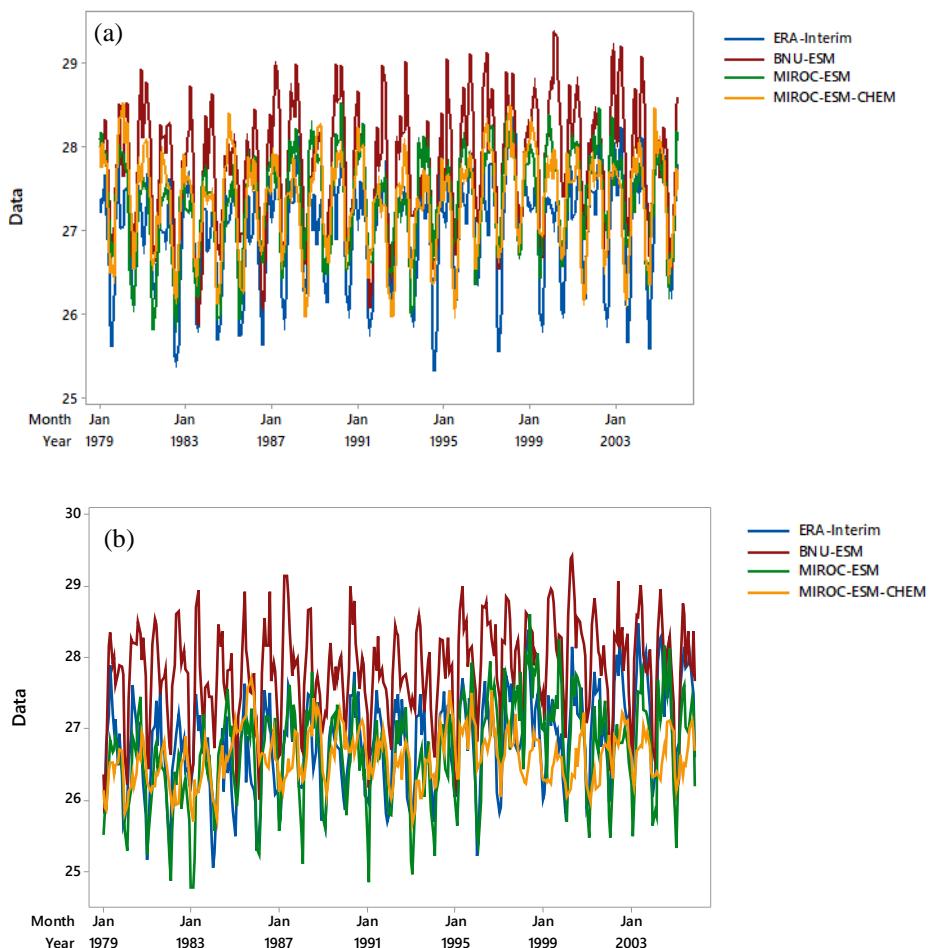
Gambar 4. 3 Time Series Plot Rata-rata Curah Hujan Perbulan (mm<sup>2</sup>) (a) Region 1 (b) Region 2 (c) Region 3

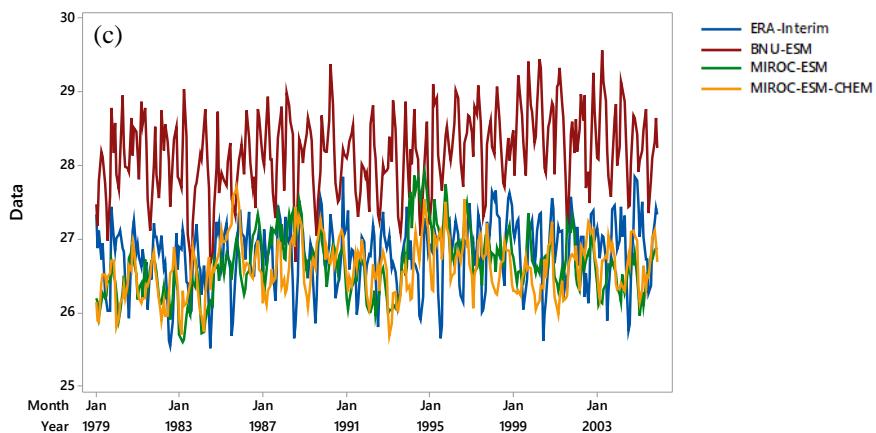
Berdasarkan Gambar 4.3 *time series plot* pada region 1 terdapat satu puncak curah hujan tertinggi yaitu  $\pm 10$  mm<sup>2</sup> di bulan Desember Januari dan Februari (DJF), setelah bulan Februari turun eksponensial. Intensitas curah hujan region 1 sedikit lebih rendah dibandingkan dengan region 2 dan region 3. Region 2

merupakan wilayah bertipe lokal atau anti *monsoon* di mana pola curah hujan berkebalikan dengan region 1, namun pada region 2 belum membentuk pola yang berkebalikan dengan region 1 dengan sempurna. Pada region 2 curah hujan naik pada mulai naik pada bulan Mei. Region 3 merupakan region bertipe *equatorial* dengan ciri-ciri terdapat dua puncak dalam satu tahun, namun yang menyerupai tipe *equatorial* pada region 3 hanya model MIROC-ESM dan MIROC-ESM-CHEM. Pada region 1, region 2, dan region 3 antara model MIROC-ESM dan MIROC-ESM-CHEM memiliki pola yang mirip, hal ini dikarenakan MIROC-ESM-CHEM merupakan model pengembangan dari model MIROC-ESM.

#### b. Temperatur Maksimum

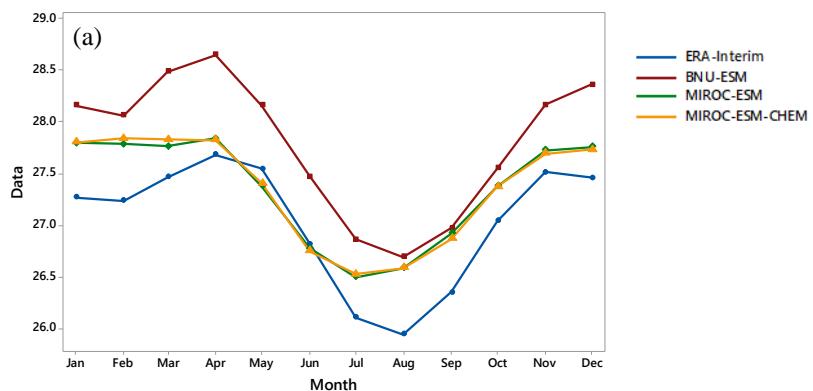
Berikut merupakan *time series plot* bulanan dan rata-rata bulanan temperatur maksimum ERA-Interim ECMWF dan skenario *historical*.

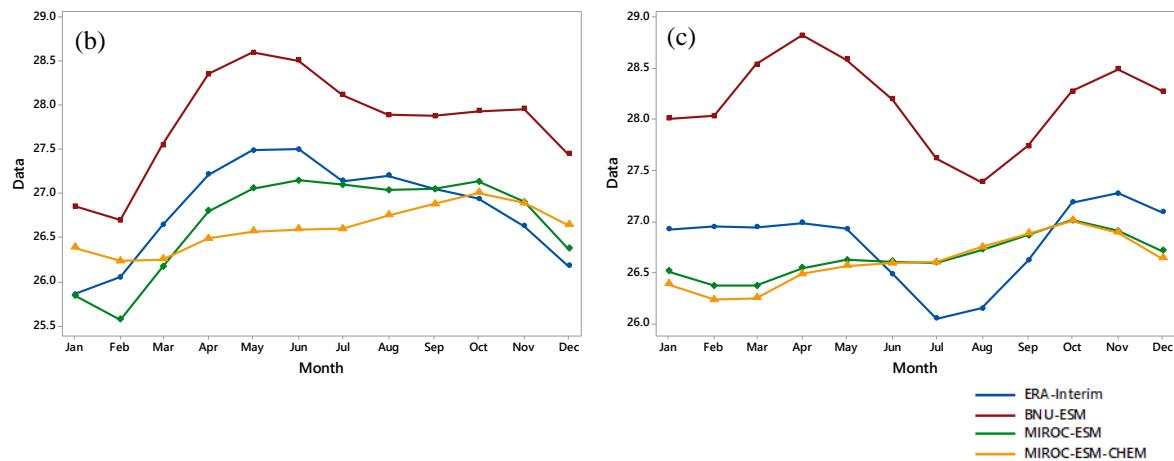




Gambar 4. 4 Time Series Plot Rata-rata Temperatur maksimum Bulanan ( $^{\circ}\text{C}$ ) (a) Region 1 (b) Region (2) (c) Region 3

Berdasarkan Gambar 4.4 terlihat bahwa rentan temperatur maksimum ERA-Interim ECMWF berada pada rentan  $25\text{-}28^{\circ}\text{C}$ , sedangkan skenario *historical* berada pada rentan  $27\text{-}29^{\circ}\text{C}$ . Model BNU-ESM memiliki temperatur maksimum tertinggi dibandingkan dengan model lainnya. Pola pada region 1 antara ERA-Interim ECMWF dengan skenario *historical* sangat mirip dibandingkan pada region 2 dan 3. Pada region 2 model MIROC-ESM memiliki temperatur lebih rendah dibandingkan dengan ERA-Interim ECMWF dan model yang lainnya. Model BNU-ESM pada region 3 memiliki rentan yang sangat jauh dengan model MIROC-ESM, MIROC-ESM-CHEM dan ERA-Interim ECMWF.





Gambar 4.5 *Time Series Plot* Rata-rata Temperatur maksimum Perbulan (°C) (a) Region 1 (b) Region 2 (c) Region 3

Berdasarkan Gambar 4.5 region 1 terjadi kenaikan temperatur pada bulan Maret April Mei, dan temperatur terendah pada bulan Agustus. Region 2 memiliki siklus yang terbalik dengan region 1 dimana sepanjang bulan Maret sampai November cenderung tinggi sedangkan pada bulan Desember sampai Februari cenderung rendah. Pola temperatur maksimum pada region 3 memiliki dua puncak dimana suhu maksimal terdapat pada bulan April dan November, namun tidak diikuti oleh model MIROC-ESM dan MIROC-ESM-CHEM.

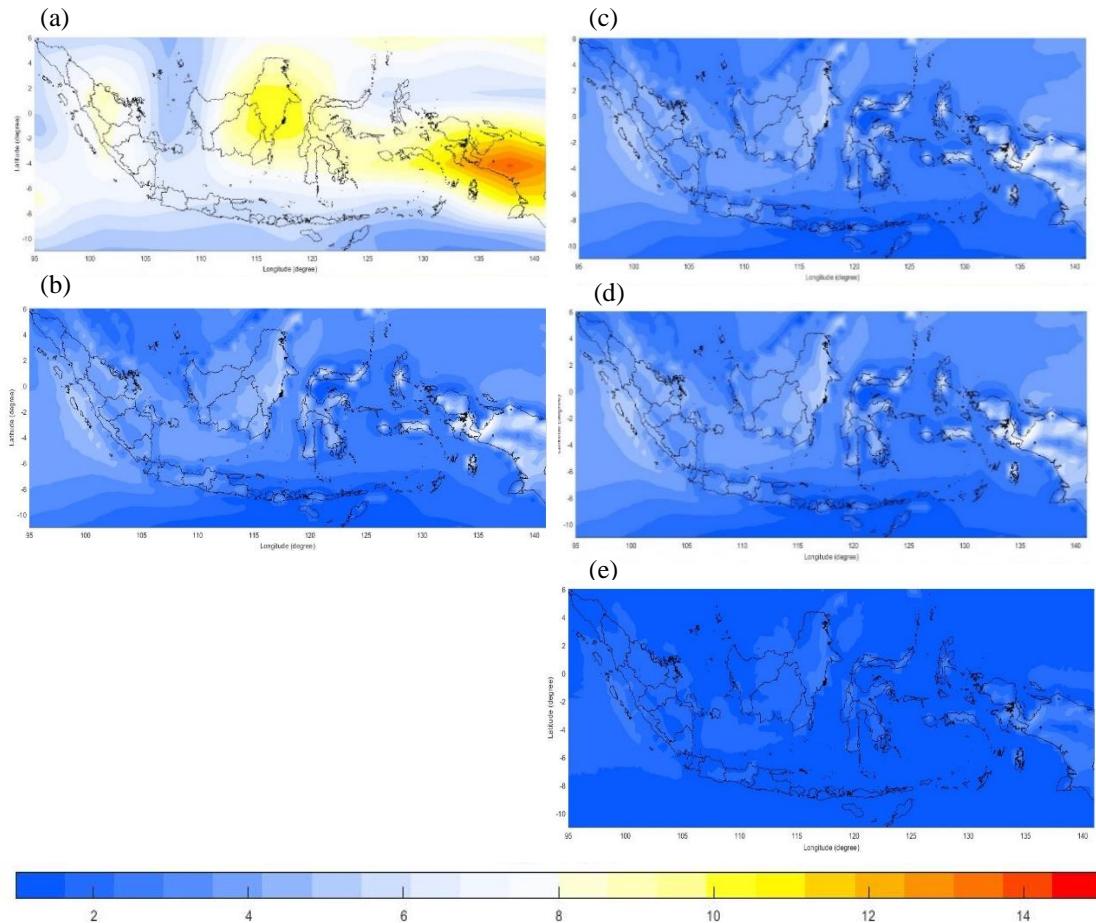
#### 4.1.3. Peta Sebelum dan Sesudah dilakukan Downscaling dan Bias Koreksi

Terdapat perbedaan sekala antara data skenario *historical* dengan Era-Interim ECMWF, maka diperlukan suatu metode penurunan skala (*downscale*), dalam penelitian ini dilakukan pada data skenario *historical* dengan menggunakan metode *climate imprint* (CI). Berikut merupakan peta sebelum dan sesudah downscale untuk curah hujan dan temperatur maksimum.

##### a. Curah Hujan

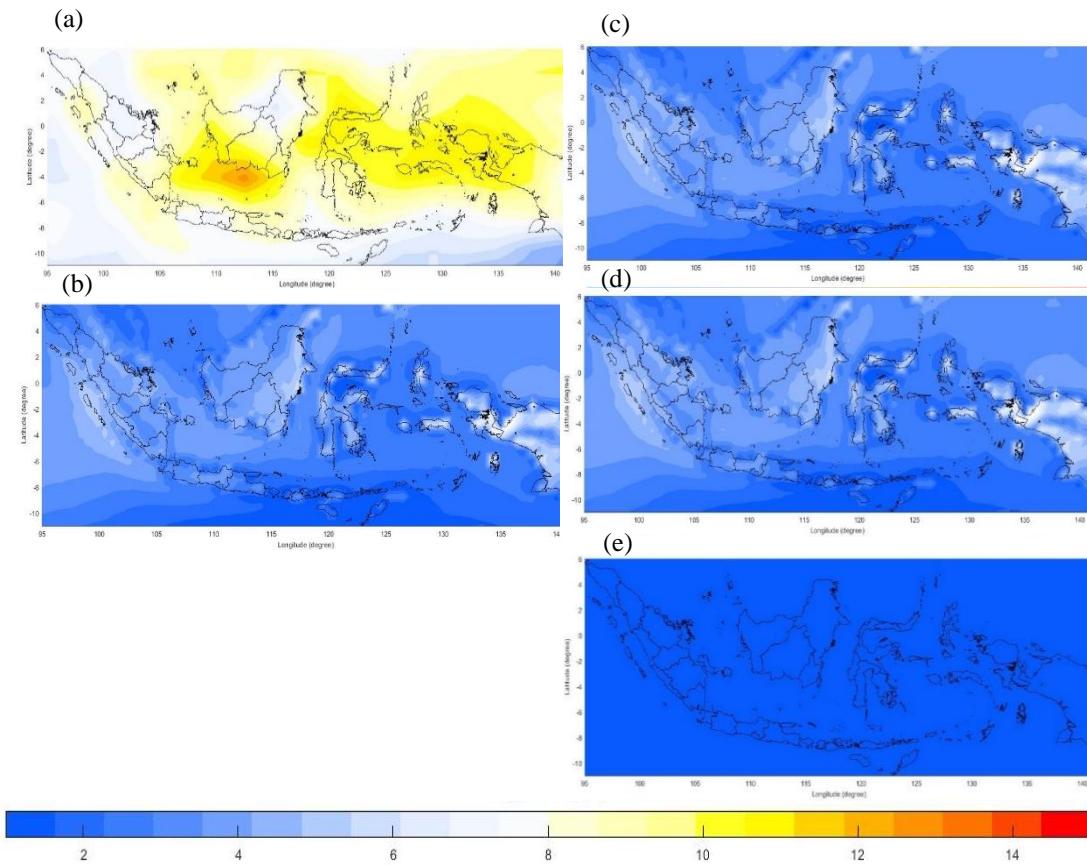
Gambar 4.6 (a) merupakan skenario *historical* model BNU-ESM dengan resolusi rendah (sebelum *downscale*) terlihat bahwa curah hujan tertinggi terdapat di wilayah pulau Papua, sebagian pulau Kalimantan dan Sulawesi yaitu lebih dari  $10 \text{ mm}^2$ . Gambar 4.6 (b) merupakan peta dari ERA-Interim ECMWF dengan intensitas curah hujan kurang dari  $8 \text{ mm}^2$ , nilai curah hujan skenario *historical*

model BNU-ESM lebih tinggi dibandingkan dengan nilai curah hujan ERA-Interim ECMWF.



Gambar 4. 6 Peta Curah Hujan Observasi ERA-Interim ECMWF, Skenario *Historical Model* BNU-ESM Sebelum dan Sesudah Koreksi Bias (a) Peta BNU-ESM Sebelum Koreksi Bias (b) Peta ERA-Interim ECMWF (c) Peta Sesudah Bias Koreksi Metode BCCAQ (d) Peta Sesudah Bias Koreksi Metode QDM, (e) Peta Sesudah Bias Koreksi Metode ISIMIP.

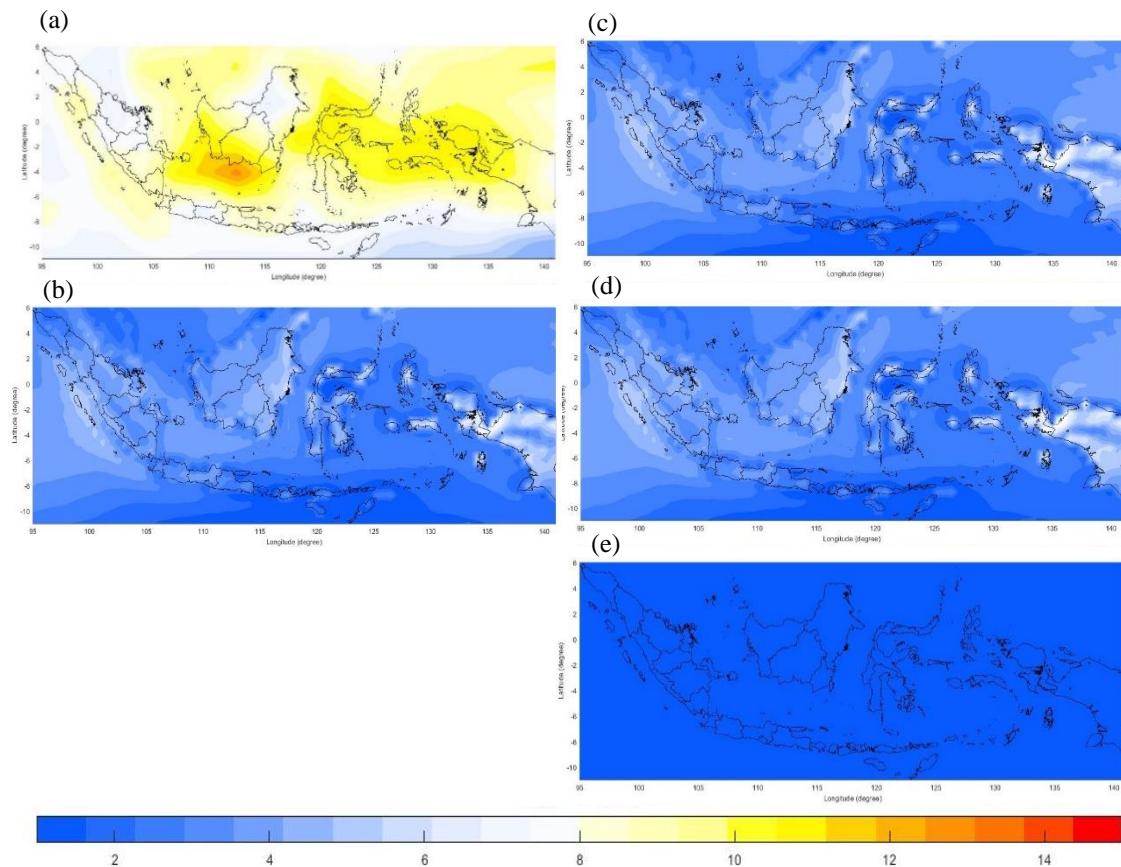
Hasil *downscale* dan bias koreksi terlihat mendekati nilai dari observasi (ERA-Interim ECMWF), bahkan pada metode ISIMIP memiliki intensitas curah hujan yang lebih rendah dibandingkan dengan ERA-Interim ECMWF yaitu kurang dari 3 mm<sup>2</sup>. Wilayah yang memiliki curah hujan tinggi sama seperti dengan sebelum *downscale* yaitu pulau Papua, sebagian pulau Kalimantan dan Sulawesi, namun intensitas curah hujannya berkurang. Curah hujan tertinggi terdapat pada region 3, karena pada region 3 terdapat dua puncak musim hujan. Berikut merupakan peta sebelum dan sesudah *downscale* dan bias koreksi pada model BNU-ESM.



Gambar 4. 7 Peta Curah Hujan Observasi ERA-Interim ECMWF, Skenario *Historical* Model MIROC-ESM Sebelum dan Sesudah Koreksi Bias (a) Peta BNU-ESM Sebelum Koreksi Bias (b) Peta ERA-Interim ECMWF (c) Peta Sesudah Bias Koreksi Metode BCCAQ (d) Peta Sesudah Bias Koreksi Metode QDM, (e) Peta Sesudah Bias Koreksi Metode ISIMIP.

Model MIROC-ESM sebelum *downscale* dan bias koreksi memiliki intensitas curah lebih tinggi dibandingkan model BNU-ESM berdasarkan Gambar 4.7 (a). Curah hujan tertinggi sebagian berada pada wilayah yang termasuk dalam region 3 dan region 2, sedangkan wilayah yang termasuk region 1 cenderung memiliki intensitas curah hujan yang rendah kurang dari  $8 \text{ mm}^2$ . Wilayah yang memiliki curah hujan tertinggi berada pada pulau Kalimantan bagian selatan, Sulawesi bagian utara, dan sebagian pulau Papua. Setelah dilakukan *downscale* dan koreksi bias, peta model MIROC-ESM menyerupai ERA-Interim ECMWF. Hasil *downscale* dan koreksi bias metode QDM dan BCCAQ memiliki curah yang sama pada setiap wilayahnya. Pada metode ISIMIP, intensitas curah hujan lebih rendah

dibandingkan dengan ERA-Interim ECMWF. Berikut merupakan peta sebelum dan sesudah dilakukan *downscale* dan bias koreksi untuk model MIROC-ESM-CHEM.

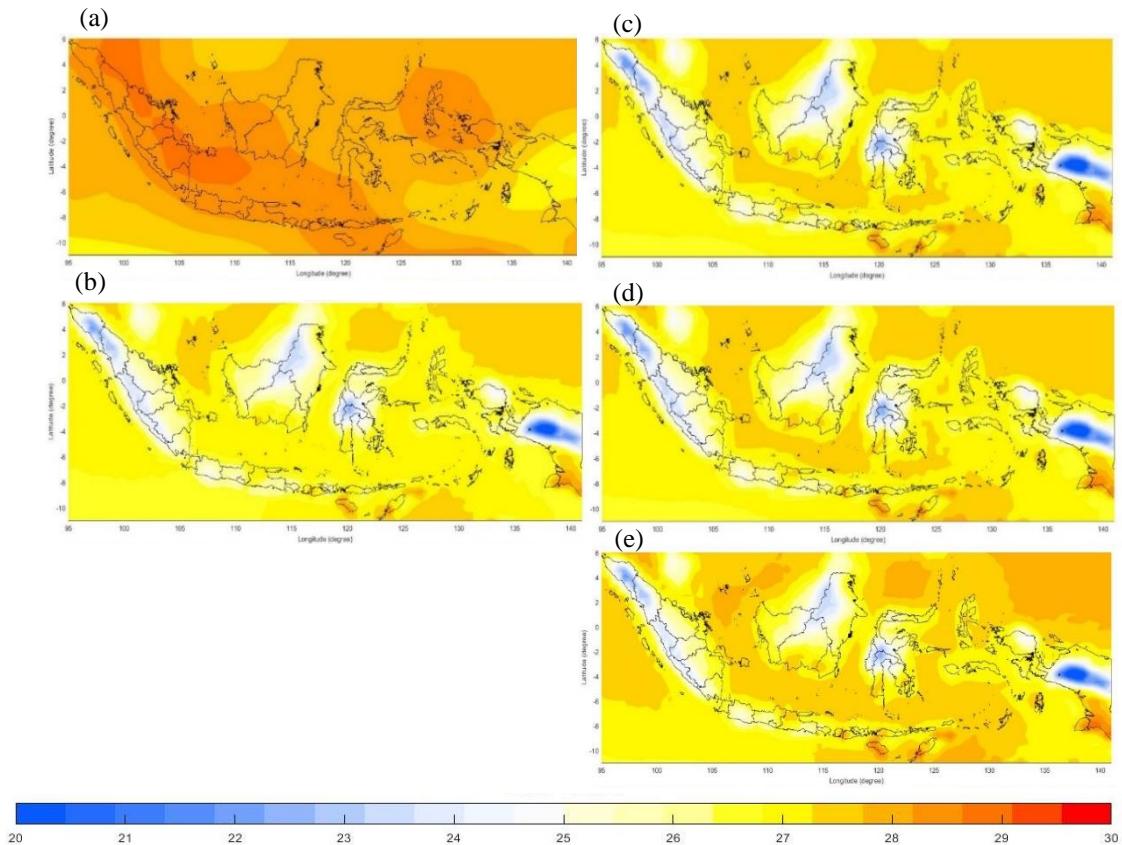


Gambar 4. 8 Peta Curah Hujan Observasi ERA-Interim ECMWF, Skenario *Historical* Model MIROC-ESM-CHEM Sebelum dan Sesudah Koreksi Bias (a) Peta BNU-ESM Sebelum Koreksi Bias (b) Peta ERA-Interim ECMWF (c) Peta Sesudah Bias Koreksi Metode BCCAQ (d) Peta Sesudah Bias Koreksi Metode QDM, (e) Peta Sesudah Bias Koreksi Metode ISIMIP.

Berdasarkan Gambar 4.8 terlihat bahwa peta model MIROC-ESM dan MIROC-ESM-CHEM sebelum *downscale* dan koreksi bias memiliki kemiripan. Intensitas curah hujan pada model MIROC-ESM-CHEM lebih tinggi dibandingkan dengan BNU-ESM. Metode BCCAQ dan QDM memiliki kemiripan dengan ERA-Interim ECMWF, namun pada metode ISIMIP memiliki intensitas curah hujan lebih rendah dibandingkan dengan metode QDM, BCCAQ, dan ERA-Interim ECMWF.

## b. Temperatur Maksimum

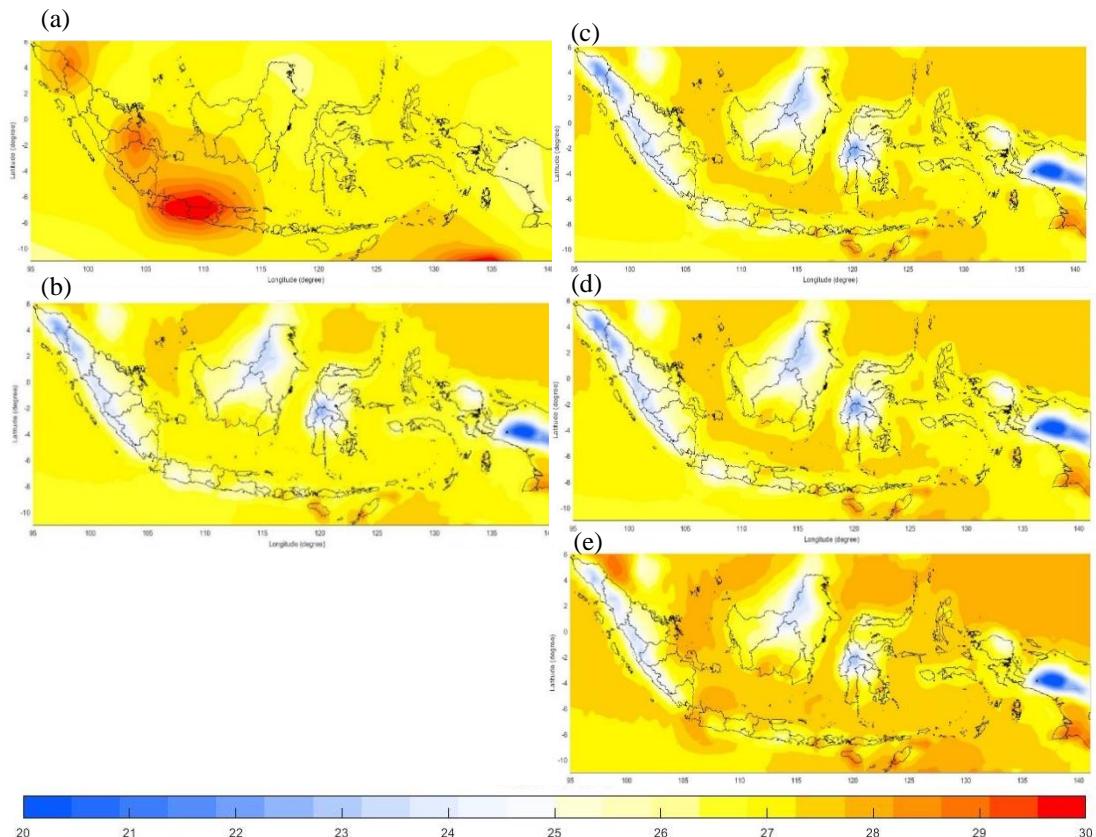
Berdasarkan Gambar 4.9 (a) temperatur maksimum tertinggi pada data skenario *historical* model BNU-ESM terdapat pada daerah kepulauan Maluku Utara, sebagian pulau Sumatra dengan rentang temperatur sebesar 27-29°C, sedangkan suhu terendah wilayah di Indonesia berada di pulau Papua.



Gambar 4. 9 Peta Temperatur Maksimum Observasi ERA-Interim ECMWF, Skenario *Historical* Model BNU-ESM Sebelum dan Sesudah Koreksi Bias (a) Peta BNU-ESM Sebelum Koreksi Bias (b) Peta ERA-Interim ECMWF (c) Peta Sesudah Bias Koreksi Metode BCCAQ (d) Peta Sesudah Bias Koreksi Metode QDM, (e) Peta Sesudah Bias Koreksi Metode ISIMIP.

Temperatur maksimum model BNU-ESM lebih tinggi dibandingkan dengan ERA-Interim ECMWF sebelum *downscale* dan koreksi bias. Pulau Sumatra dan pulau Jawa, dan pulau Ambon memiliki temperatur yang tinggi, sedangkan pulau Papua cenderung lebih dingin dengan temperatur maksimum berkisar 21°C. Setelah dilakukan *downscale* dan koreksi bias terdapat kemiripan peta antara temperatur maksimum ERA-Interim ECMWF, kemiripan sebagian besar terjadi pada wilayah daratan dan sedikit berbeda pada daerah laut. Temperatur

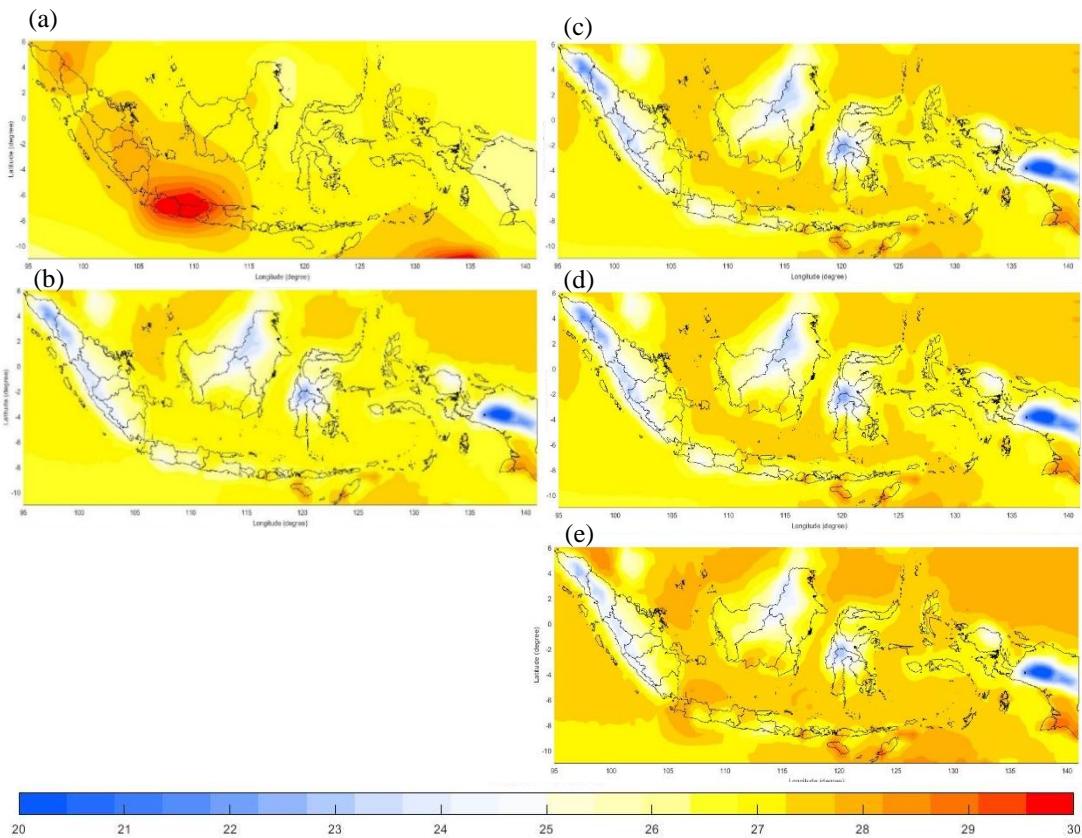
maksimum terendah setelah dilakukan *downscale* dan bias koreksi tedapat pada bagian tengah pulau Papua, pulau Sulawesi bagian tengah, pulau Kalimantan bagian utara, dan pulau Sumatra bagian utara. Temperatur maksimum tertinggi berada pada wilayah timur laut Indonesia yang termasuk dalam region 3. Berikut merupakan temperatur maksimum model MIROC-ESM.



Gambar 4. 10 Peta Temperatur Maksimum Observasi ERA-Interim ECMWF, Skenario *Historical* Model MIROC-ESM Sebelum dan Sesudah Koreksi Bias (a) Peta BNU-ESM Sebelum Koreksi Bias (b) Peta ERA-Interim ECMWF (c) Peta Sesudah Bias Koreksi Metode BCCAQ (d) Peta Sesudah Bias Koreksi Metode QDM, (e) Peta Sesudah Bias Koreksi Metode ISIMIP.

Berdasarkan Gambar 4.10 temperatur maksimum model MIROC-ESM memiliki sebaran yang cukup homogen di Indonesia. Temperatur maksimum model MIROC-ESM lebih rendah dibandingkan dengan temperatur maksimum BNU-ESM. Temperatur maksimum tertinggi sebelum dilakukan *downscale* dan koreksi bias terdapat pada pulau Jawa dan sebagian pulau Sumatra, sedangkan temperatur maksimum terendah berada pada di pulau Papua. Temperatur maksimum setelah

dilakukan *downscale* dan koreksi bias, memiliki kemiripan yang sama seperti ERA-Interim ECMWF. Model MIROC-ESM, MIROC-ESM-CHEM dan BNU-ESM memiliki kemiripan setelah dilakukan *downscale* dan bias koreksi. Gambar 4.11 merupakan peta dari MIROC-ESM-CHEM sebelum dan sesudah *downscale* dan koreksi bias. Hasil yang diperoleh tidak jauh berbeda dengan hasil MIROC-ESM, begitu juga dengan sebelum dilakukan downscale dan koreksi bias memiliki peta yang sama.



Gambar 4. 11 Peta Temperatur Maksimum Observasi ERA-Interim ECMWF, Skenario *Historical* Model MIROC-ESM-CHEM Sebelum dan Sesudah Koreksi Bias (a) Peta BNU-ESM Sebelum Koreksi Bias (b) Peta ERA-Interim ECMWF (c) Peta Sesudah Bias Koreksi Metode BCCAQ (d) Peta Sesudah Bias Koreksi Metode QDM, (e) Peta Sesudah Bias Koreksi Metode ISIMIP.

#### 4.2. Evaluasi Skill

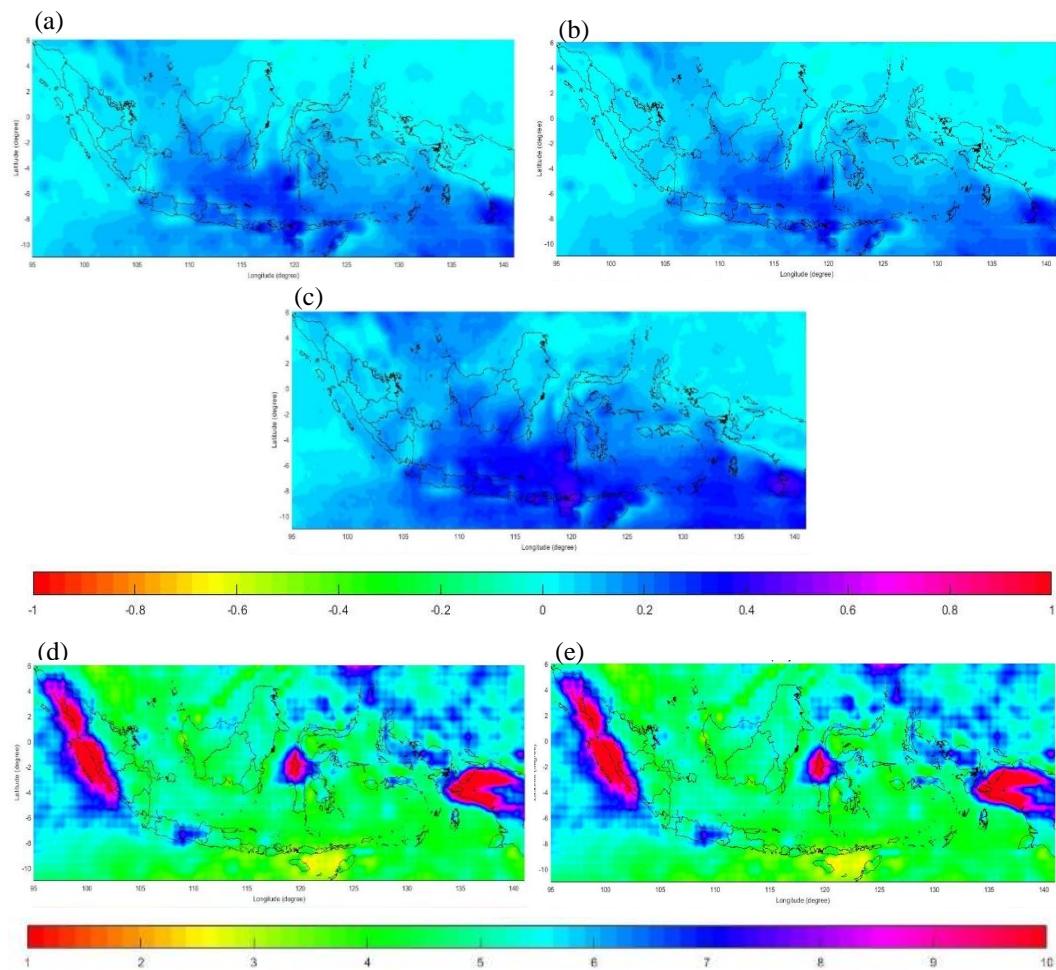
Evaluasi *Skill* bertujuan untuk mengetahui *skill* metode *downscale* dan bias koreksi dalam mereduksi bias sehingga mendekati data observasi (ERA-Interim ECMWF). Penelitian ini menggunakan peta korelasi dan RMSE serta diagram Taylor untuk mengetahui metode yang mempunyai *skill* terbaik.

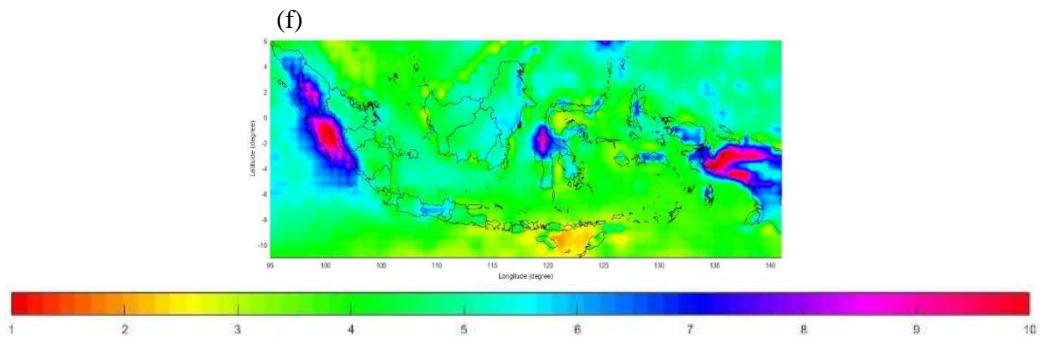
#### **4.2.1. Peta Korelasi dan Peta RMSE Curah Hujan dan Temperatur Maksimum**

Peta korelasi dan peta RMSE bertujuan untuk mengetahui wilayah mana saja yang memiliki korelasi kuat, dan bias yang kecil antara data luaran ESM yang telah di *downscale* dan koreksi bias menggunakan metode QDM, BCCAQ, dan ISIMIP dengan ERA-Interim ECMWF. Selain untuk mengetahui daerah mana yang memiliki korelasi kuat, peta korelasi juga menunjukkan sejauh mana luaran ESM mengikuti pola dari ERA-Interim ECMWF.

##### a. Curah Hujan

Peta korelasi pada Gambar 4.12 (a), (b), dan (c) berada pada rentang -1 sampai dengan +1 dengan gradasi warna biru tua, merah muda, dan merah sebelah kanan menunjukkan korelasi yang tinggi.

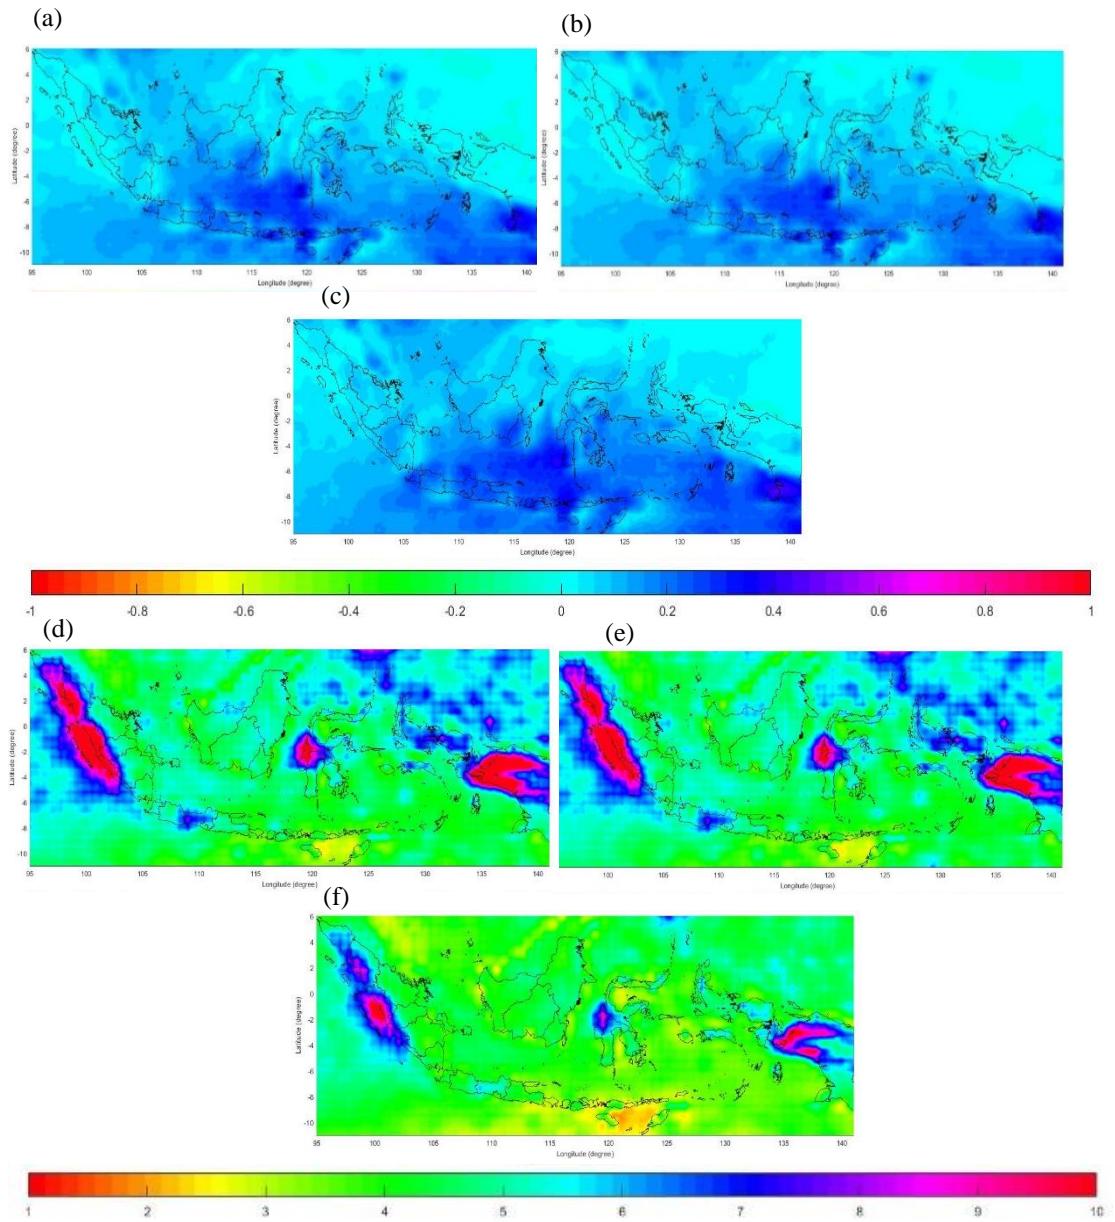




Gambar 4. 12 Peta Korelasi dan Peta RMSE Curah Hujan Model MIROC-ESM (a) Peta Korelasi BCCAQ (b) Peta Korelasi QDM (c) Peta Korelasi ISIMIP (d) Peta RMSE BCCAQ (e) Peta RMSE QDM (f) Peta RMSE ISIMIP.

Terlihat bahwa korelasi yang tertinggi antara luaran ESM model MIROC-ESM dan ERA-Interim ECMWF berada di Indonesia bagian selatan dengan nilai koefisien korelasi berada diantara 0,4, namun pada metode ISIMIP terdapat beberapa titik (grid) yang berwarna merah muda dengan kisaran nilai koefisien korelasi sebesar 0,5. Pada setiap metode nilai koefisien korelasi tertinggi terdapat pada region 1 dan sebagian region 2, sedangkan region 3 merupakan region yang memiliki nilai koefisien korelasi yang paling redah. Metode yang memiliki nilai koefisien korelasi tertinggi adalah metode ISIMIP, walaupun perbedaanya tidak signifikan pada peta.

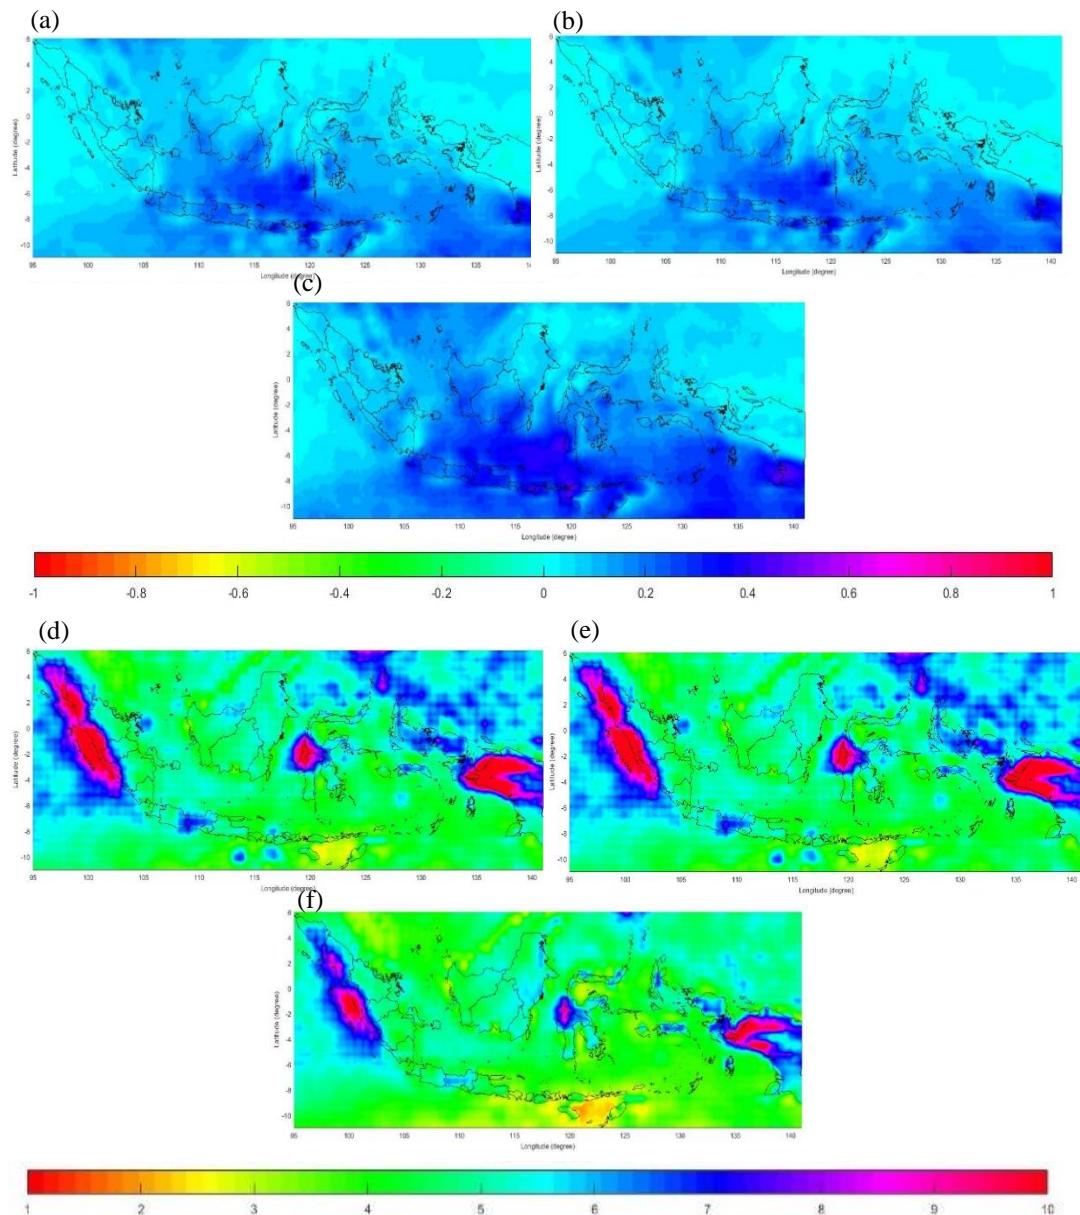
Gambar 4.12 (d), (e), dan (f) merupakan peta RMSE dengan rentang 1 sampai dengan 10, daerah yang bergradasi warna biru tua, merah muda, dan merah memiliki RMSE yang tinggi. Daerah yang memiliki RMSE cukup tinggi diantaranya adalah sebagian wilayah pulau Sumatra, pulau Sulawesi bagian tengah, dan pulau Papua dengan RMSE lebih dari 8. Terdapat perbedaan yang jelas antara RMSE metode QDM dan BCCAQ dengan metode ISMIP, terdapat penurunan nilai RMSE. Penurunan nilai RMSE yang terlihat signifikan terjadi pada wilayah Jawa Tengah dan wilayah timur laut Indonesia. Nilai RMSE terbesar terdapat pada region 3 dan terkecil pada region 1. Berikut merupakan peta korelasi dan RMSE untuk model BNU-ESM,



Gambar 4. 13 Peta Korelasi dan Peta RMSE Curah Hujan Model BNU-ESM (a) Peta Korelasi BCCAQ (b) Peta Korelasi QDM (c) Peta Korelasi ISIMIP (d) Peta RMSE BCCAQ (e) Peta RMSE QDM (f) Peta RMSE ISIMIP

Berdasarkan Gambar 4.13 (a) (b) (c), terlihat bahwa nilai koefisien korelasi dari model BNU-ESM sama antara ketiga metode tersebut, berbeda dengan model MIROC-ESM, yang terdapat sedikit perbedaan pada metode ISIMIP. Nilai koefisien korelasi tertinggi pada model BNU-ESM terdapat pada wilayah Indoensia bagian selatan atau region 1, sedangkan wilayah yang termasuk dalam region 3

merupakan region yang memiliki koefisien korelasi terendah. Terdapat perbedaan antara metode QDM, BCCAQ dan ISIMIP pada peta RMSE. Peta RMSE metode ISIMIP memiliki sebaran nilai yang lebih rendah dibandingkan dengan metode QDM dan BCCAQ. Perbedaan nilai tersebut sangat terlihat dibagian uatara pulau Papua dan sebagian pulau Sumatra. Peta korelasi dan RMSE untuk model MIROC-ESM-CHEM tidak jauh berbeda dengan model MIROC-ESM. Gambar 4.14 merupakan peta korelasi dan RMSE dari model MIROC-ESM-CHEM,



Gambar 4. 14 Peta Korelasi dan Peta RMSE Curah Hujan Model BNU-ESM (a) Peta Korelasi BCCAQ (b) Peta Korelasi QDM (c) Peta Korelasi ISIMIP (d) Peta RMSE BCCAQ (e) Peta RMSE QDM (f) Peta RMSE ISIMIP

Terdapat 12834 titik (grid) akan diuji signifikansi korelasi dimana jika nilai *absolute* koefisien korelasi  $|t_{\text{hitung}}| > t_{\alpha/2;n-2}$ , maka pola ERA-Interim ECMWF diikuti dengan baik oleh luaran ESM berikut rincian uji hubungannya,

Tabel 4. 1 Signifikansi Titik (Grid) Curah Hujan

Skenario	Metode	Nilai t tabel	Jumlah titik (grid) yang signifikan	Presentase (%)
BNU-ESM	BCCAQ	1,960204	10516	81,94%
	QDM		10521	81,98%
	ISIMIP		11698	91,15%
MIROC-ESM	BCCAQ	1,960204	10635	82,87%
	QDM		10650	82,98%
	ISIMIP		12315	95,95%
MIROC-ESM-CHEM	BCCAQ	1,960204	10925	85,13%
	QDM		10897	84,91%
	ISIMIP		12306	95,89%

Berdasarkan Tabel 4.1 presntasi titik (grid) yang signifikan berada pada taraf lebih dari 80%. Metode ISIMIP adalah metode yang memiliki presentase tertinggi jumlah titik (grid) yang signifikan dengan pretentase sebesar lebih dari 90%, dan skenario model MIROC-ESM-CHEM memiliki presentase tertinggi yaitu 95,89%. Berdasarkan Gambar 4.12, 4.13, dan 4.14 terlihat bahwa besar kecilnya nilai koefisien korelasi cenderung mengelompok sesuai region, maka akan diuji signifikansi korelasi berdasarkan region untuk setiap metode dan setiap modelnya. Terdapat 6646 titik (grid) region 1, 656 titik (grid) region 2, dan 5532 titik (grid) region 3.

Tabel 4. 2 Signifikansi Titik (Grid) Curah Hujan Per-region

Region	Skenario	Metode	Nilai t tabel	Jumlah titik (grid) yang signifikan	Presentase (%)
Region 1	BNU-ESM	BCCAQ	1,960204	6223	93,64%
		QDM		6269	94,33%
		ISIMIP		6427	96,70%
	MIROC-ESM	BCCAQ	1,960204	6137	92,34%
		QDM		6162	92,72%
		ISIMIP		6515	98,03%
	MIROC-ESM-CHEM	BCCAQ	1,960204	6323	95,12%
		QDM		6299	94,78%
		ISIMIP		6528	98,22%

Tabel 4.2 Signifikansi Titik (Grid) Curah Hujan Per-region (Lanjutan)

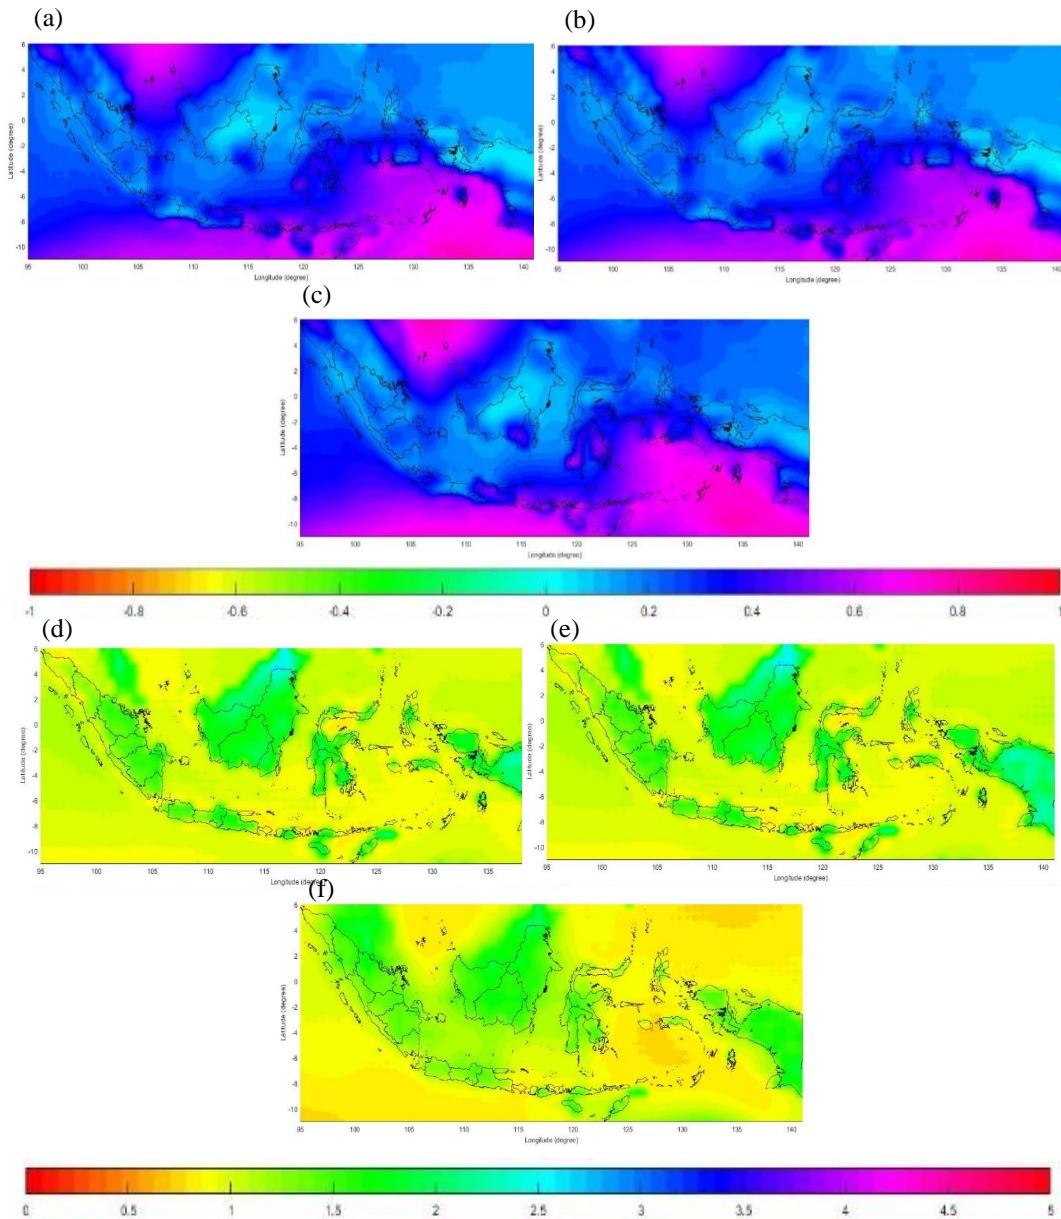
Region 2	BNU-ESM	BCCAQ	1,960204	603	91,92%
		QDM		598	91,16%
		ISIMIP		651	99,24%
	MIROC-ESM	BCCAQ	1,960204	592	90,24%
		QDM		587	89,48%
		ISIMIP		655	99,85%
	MIROC-ESM-CHEM	BCCAQ	1,960204	578	88,11%
		QDM		591	90,09%
		ISIMIP		651	99,24%
Region 3	BNU-ESM	BCCAQ	1,960204	3906	70,61%
		QDM		3654	66,05%
		ISIMIP		4620	83,51%
	MIROC-ESM	BCCAQ	1,960204	3888	70,28%
		QDM		3901	70,52%
		ISIMIP		5144	92,99%
	MIROC-ESM-CHEM	BCCAQ	1,960204	4024	72,74%
		QDM		4007	72,43%
		ISIMIP		5128	92,70%

Metode ISIMIP baik untuk curah hujan, hal ini dibuktikan dengan nilai signifikansi yang terdapat pada Tabel 4.2 di semua region dan semua model skenario *historical* memiliki presentase titik (grid) yang signifikansi di atas 80%. Model MIROC-ESM-CHEM dengan metode ISIMIP merupakan model yang memiliki presentase titik yang signifikansi tertinggi yaitu 98,22% pada region 1, sedangkan model MIROC-ESM dengan metode ISIMIP merupakan model yang memiliki presentase titik (grid) yang signifikan tertinggi yaitu 99,85% pada region 2, dan model MIROC-ESM-CHEM dengan metode ISIMIP merupakan model yang memiliki presntase tertinggi titik (grid) yang signifikan tertinggi yaitu 92,70% pada region 3.

#### b. Temperatur Maksimum

Berdasarkan Gambar 4.15 nilai koefisien korelasi temperatur maksimum wilayah Indonesia tertinggi terdapat pada wilayah Indonesia bagian selatan dan sedikit di wilayah utara. Wilayah tersebut merupakan wilayah region 1 (wilayah selatan) dan region 3 wilayah utara, dengan nilai koefisien korelasi berada pada rentan 0,6 sampai 0,7. Sebagian besar pulau-pulau di Indoensia memiliki nilai koefisien korelasi 0,4 sampai 0,5. Peta metode ISIMIP sedikit lebih baik dibandingkan dengan metode QDM dan BCCAQ, perbedaanya terlihat di bagian pulau Sulawesi bagian selatan, sedikit di pulau Jawa bagian timur, pulau

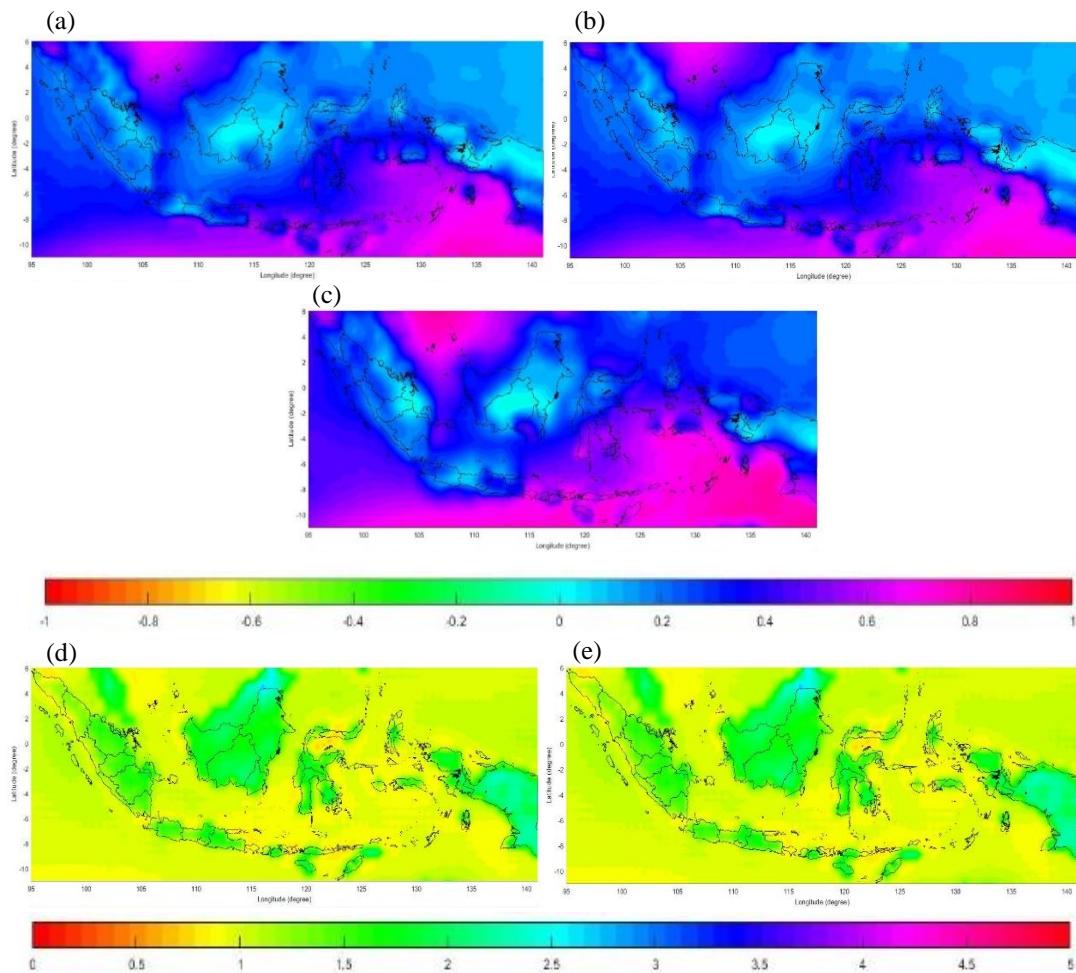
Kalimantan bagian selatan dan sepanjang garis pantai selatan pulau Papua, walaupun tidak signifikan berbeda.

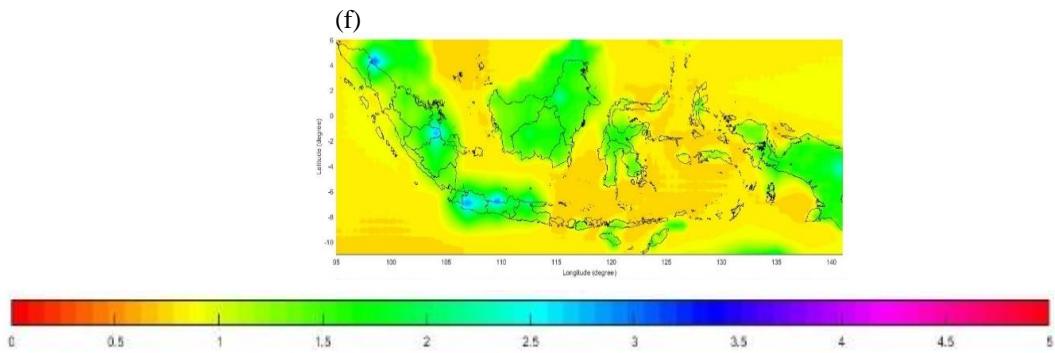


Gambar 4. 15 Peta Korelasi dan RMSE Temperatur Maksimum Model BNU-ESM (a) Peta Korelasi BCCAQ (b) Peta Korelasi QDM (c) Peta Korelasi ISIMIP (d) Peta RMSE BCCAQ (e) Peta Korelasi QDM (f) Peta RMSE ISIMIP.

Rentang nilai peta RMSE adalah 0 sampai dengan 5, dimana pulau-pulau di Indonesia sebagian besar memiliki nilai RMSE di sekitar 1-2 dengan warna gradasi hijau. Nilai RMSE terkecil berada pada wilayah laut Indonesia. Terdapat perbedaan

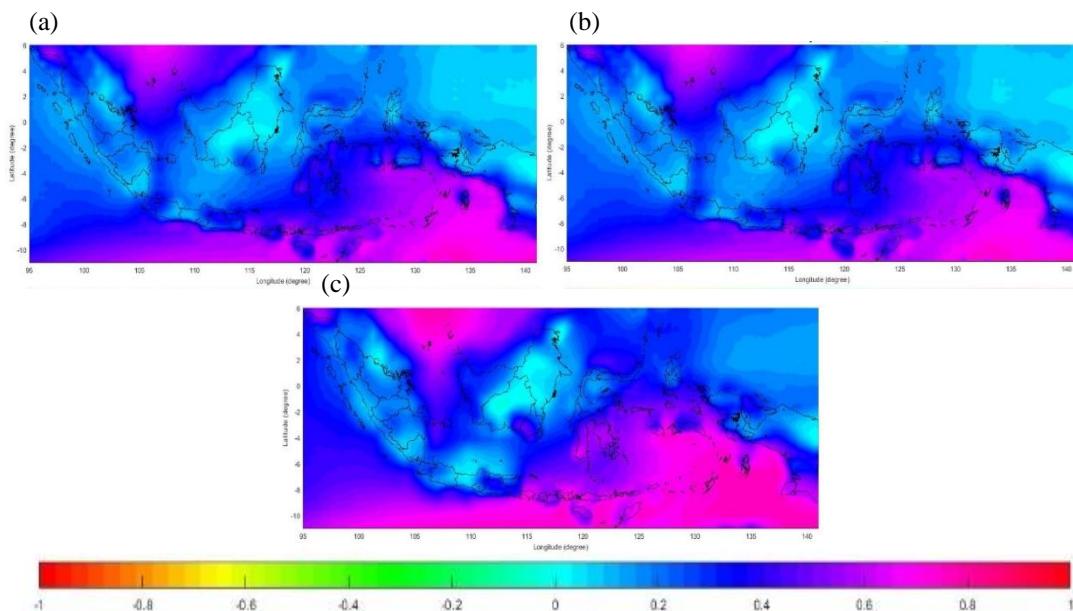
yang cukup signifikan pada peta metode QDM dan BCCAQ dengan peta ISIMIP, perbedaan tersebut terletak pada pulau Papua dan sebagian pulau Kalimantan bagian utara, dimana nilai RMSE dari peta metode ISIMIP pada wilayah itu lebih kecil dibandingkan dengan metode QDM dan BCCAQ. Sama seperti model BNU-ESM, terlihat pada Gambar 4.16 (a) (b) (c) model MIROC-ESM nilai korelasi tertingginya berada pada wilayah Indonesia bagian selatan dan sedikit di bagian utara. Pada model MIROC-ESM peta metode ISIMIP sedikit lebih bagus dibandingkan dengan metode QDM dan BCCAQ, perbedaan terlihat pada kepulauan Nusa Tenggara dan pulau Sulawesi bagian selatan. Peta metode ISIMIP model MIROC-ESM sedikit lebih bagus dibandingkan dengan model BNU-ESM.

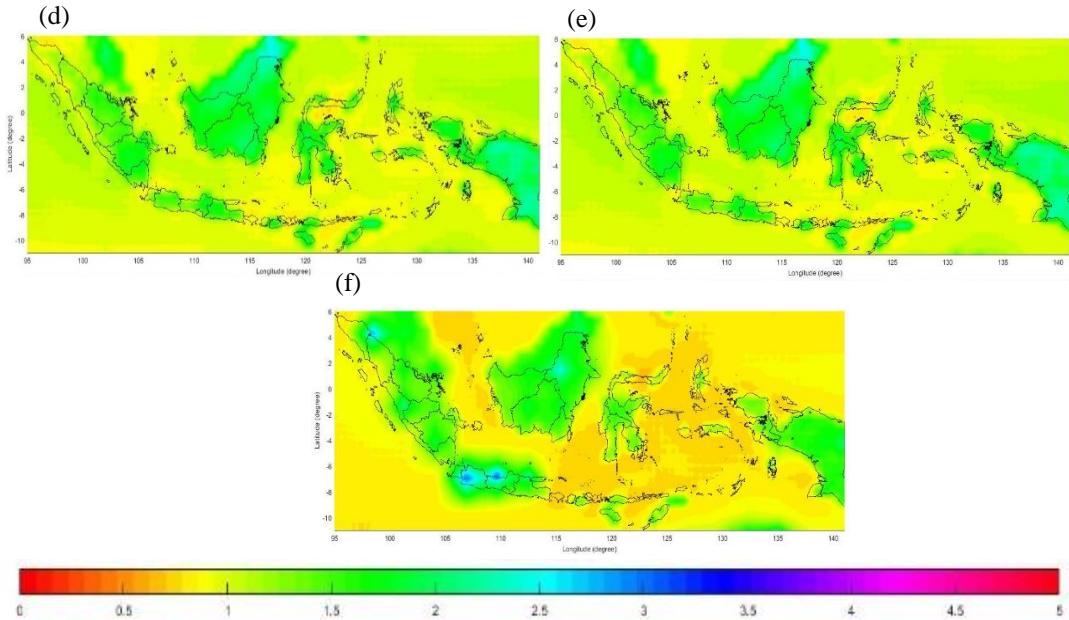




Gambar 4. 16 Peta Korelasi dan RMSE Temperatur Maksimum Model MIROC-ESM (a) Peta Korelasi BCCAQ (b) Peta Korelasi QDM (c) Peta Korelasi ISIMIP (d) Peta RMSE BCCAQ (e) Peta Korelasi QDM (f) Peta RMSE ISIMIP.

Berdasarkan Gambar 4.16 (c) (d) (e) terlihat bahwa metode QDM dan BCCAQ tidak jauh berbeda, nilai RMSE tertinggi terdapat pada pulau Papua bagian tengah dan pulau Kalimantan bagian utara. Peta metode ISIMIP terlihat memiliki nilai RMSE lebih kecil dibandingkan dengan metode QDM dan BCCAQ, hal terlebut di tunjukan dengan gradasi berwarna kuning mendekati merah pada bagian lautnya, namun terdapat beberapa titik yang sedikit tinggi dibagian pulau Sumatra dan Jawa. Peta korelasi dan RMSE untuk metode MIROC-ESM-CHEM tidak jauh berbeda dengan MIROC-ESM, dimana metode yang memiliki koefisien korelasi tertinggi dan nilai RMSE terendah adalah metode ISIMIP, Gambar 4.17 adalah peta korelasi dan RMSE untuk model MIROC-ESM-CHEM,





Gambar 4. 17 Peta Korelasi dan RMSE Temperatur Maksimum Model MIROC-ESM (a) Peta Korelasi BCCAQ (b) Peta Korelasi QDM (c) Peta Korelasi ISIMIP (d) Peta RMSE BCCAQ (e) Peta Korelasi QDM (f) Peta RMSE ISIMIP.

Berikut akan diuji signifikansi nilai korelasi pertitik (grid) dari variabel temperatur maksimum untuk seluruh model BNU-ESM, MIROC-ESM, dan MIROC-ESM-CHEM skenario *historical*.

Tabel 4. 3 Signifikansi Titik (Grid) Temperatur Maksimum

Skenario	Metode	Nilai t tabel	Jumlah titik (grid) yang signifikan	Presentase (%)
BNU-ESM	BCCAQ	1,960204	12834	100%
	QDM		12834	100%
	ISIMIP		12834	100%
MIROC-ESM	BCCAQ	1,960204	12793	99,68%
	QDM		12794	99,69%
	ISIMIP		12720	99,11%
MIROC-ESM-CHEM	BCCAQ	1,960204	12790	99,66%
	QDM		12774	99,52%
	ISIMIP		12737	99,24%

Berdasarkan Tabel 4.3 Model BNU-ESM memiliki presentasi titik (grid) yang signifikan 100% pada ketiga metode bias koreksi. Pada model MIROC-ESM metode QDM memiliki presentase lebih baik dibandingkan dengan metode lainnya,

sedangkan pada model MIROC-ESM-CHEM metode BCCAQ mengungguli metode QDM dan ISIMIP sebesar 99,66% titik (grid) yang signifikan. Namun secara garis besar presentase signifikansi titik (grid) pada masing-masing model mendekati 100%. Selanjutnya akan diuji signifikansi nilai korelasi per-region untuk masing-masing model skenario *historical*.

Tabel 4. 4 Signifikansi Titik (Grid) Temperatur Maksimum Per-region

Region	Skenario	Metode	Nilai t tabel	Jumlah titik (grid) yang signifikan	Presentase (%)
Region 1	BNU-ESM	BCCAQ	1,960204	6646	100%
		QDM		6645	100%
		ISIMIP		6646	100%
	MIROC-ESM	BCCAQ	1,960204	6613	99,50%
		QDM		6612	99,49%
		ISIMIP		6542	98,44%
	MIROC-ESM-CHEM	BCCAQ	1,960204	6613	99,50%
		QDM		6599	99,29%
		ISIMIP		6577	98,96%
Region 2	BNU-ESM	BCCAQ	1,960204	656	100%
		QDM		656	100%
		ISIMIP		656	100%
	MIROC-ESM	BCCAQ	1,960204	650	99,09%
		QDM		654	99,70%
		ISIMIP		656	100%
	MIROC-ESM-CHEM	BCCAQ	1,960204	656	100%
		QDM		656	100%
		ISIMIP		656	100%
Region 3	BNU-ESM	BCCAQ	1,960204	5532	100%
		QDM		5532	100%
		ISIMIP		5532	100%
	MIROC-ESM	BCCAQ	1,960204	5530	99,96%
		QDM		5528	99,93%
		ISIMIP		5526	99,89%
	MIROC-ESM-CHEM	BCCAQ	1,960204	5521	99,80%
		QDM		5519	99,77%
		ISIMIP		5506	99,53%

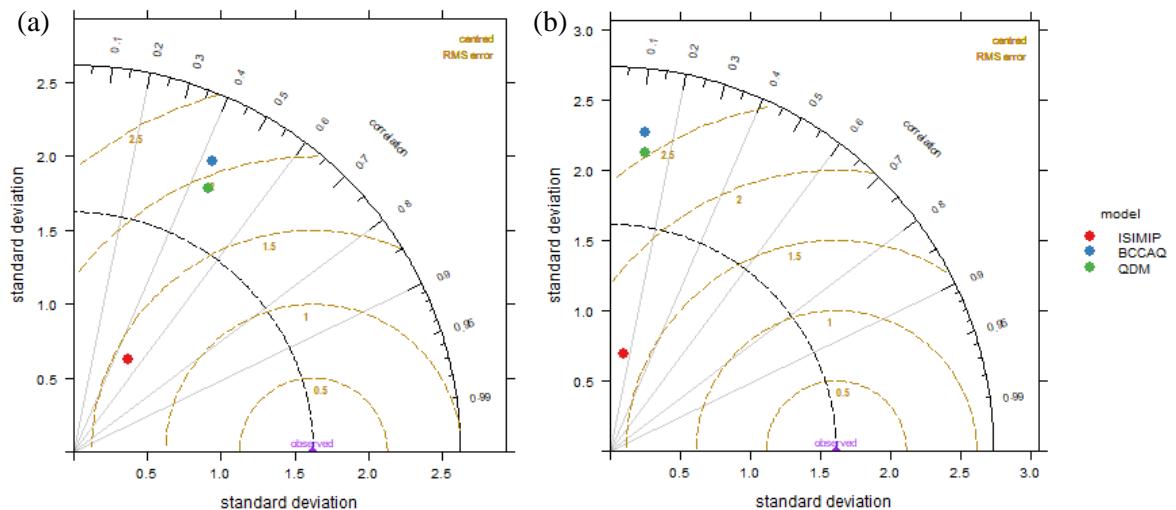
Berdasarkan Tabel 4.4 terlihat bahwa presentase titik (grid) yang signifikan berada pada rentan 98-100%. Pada region 2 model BNU-ESM dan MIROC-ESM-CHEM memiliki presentase titik (grid) yang signifikan sebesar 100% pada semua metode bias koreksi. Pada region 1 dan 3 model BNU-ESM memiliki presentase signifikansi titik (grid) pada semua metode mencapai 100%.

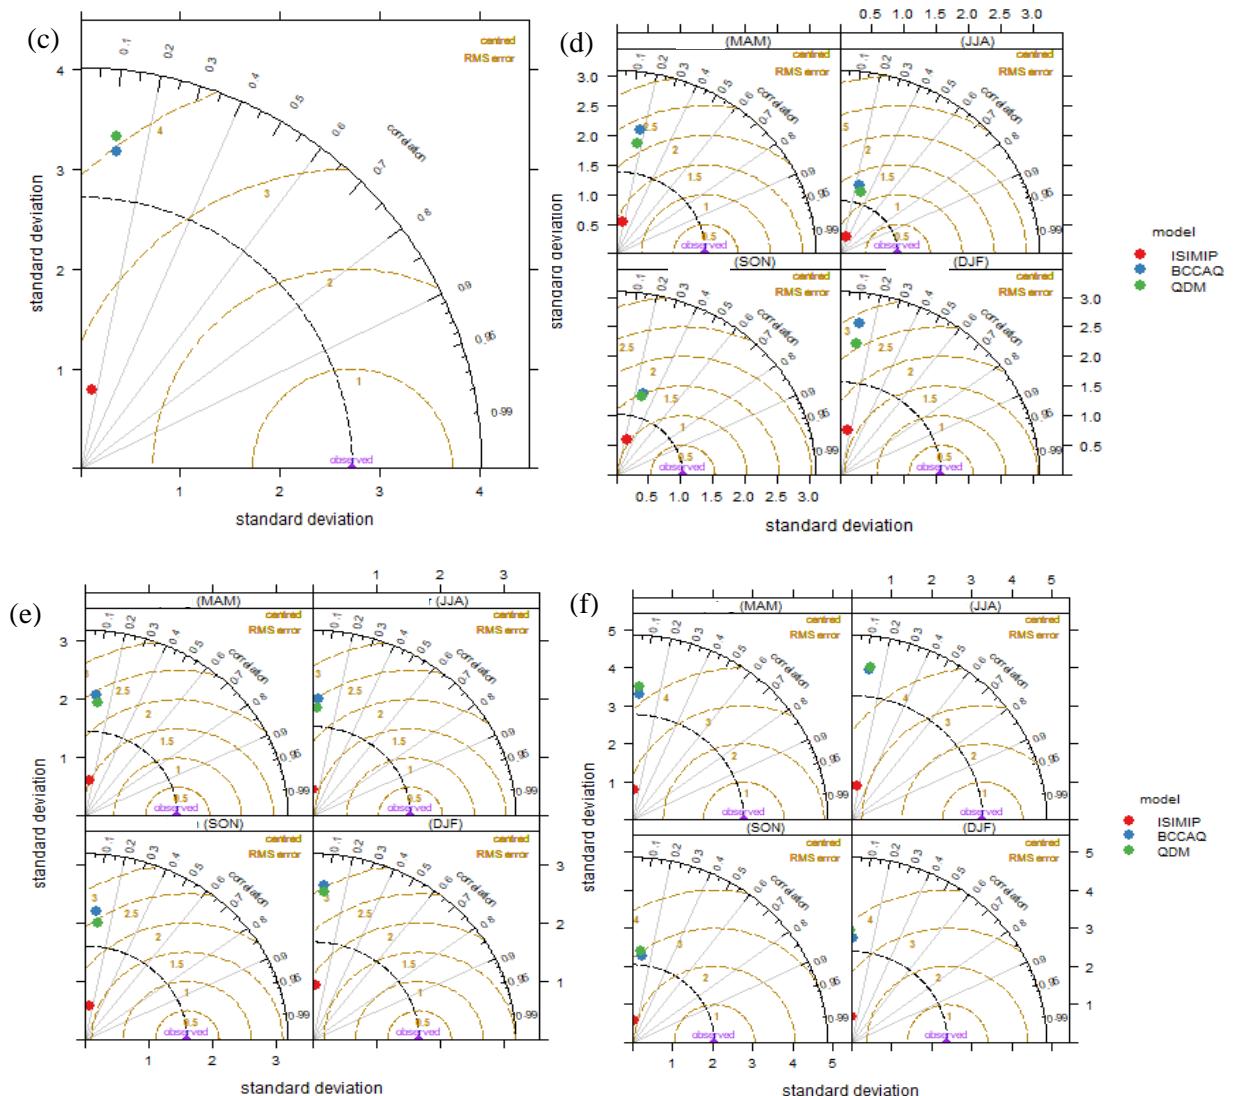
### 5.2.2. Taylor Diagram

Diagram Taylor merupakan suatu diagram yang terdapat tiga ukuran statistik yaitu korelasi, *centered RMS difference*, dan standar deviasi. Diagram Taylor dalam penelitian ini digunakan untuk mengetahui metode yang memiliki *skill* yang baik untuk melakukan bias koreksi, dimana metode yang terbaik adalah metode yang mendekati titik “observed”. Dalam penelitian ini akan dihitung Taylor diagram setiap region dan model pada skenario *historical*, baik musiman maupun non-musiam. Musiman dalam penelitian ini dibagi menjadi 4 periode yaitu periode peralihan Maret April Mei (MAM) September Oktober November (SON), periode hujan yaitu Desember Januari Februari (DJF), dan periode kemarau yaitu Juni Juli Agustus (JJA), pembagian periode musim di Indonesia menjadi 4 periode merujuk pada jurnal yang ditulis oleh Aldrian dan Susanto, (2003) dan Narulita, (2017).

#### a. Curah hujan

Gambar 4.18, Gambar 4.19, dan Gambar 4.20 merupakan Taylor diagram curah hujan dari tiga model skenario *historical* yaitu BNU-ESM, MIROC-ESM, dan, MIROC-ESM-CHEM untuk non-musiman dan musiman.

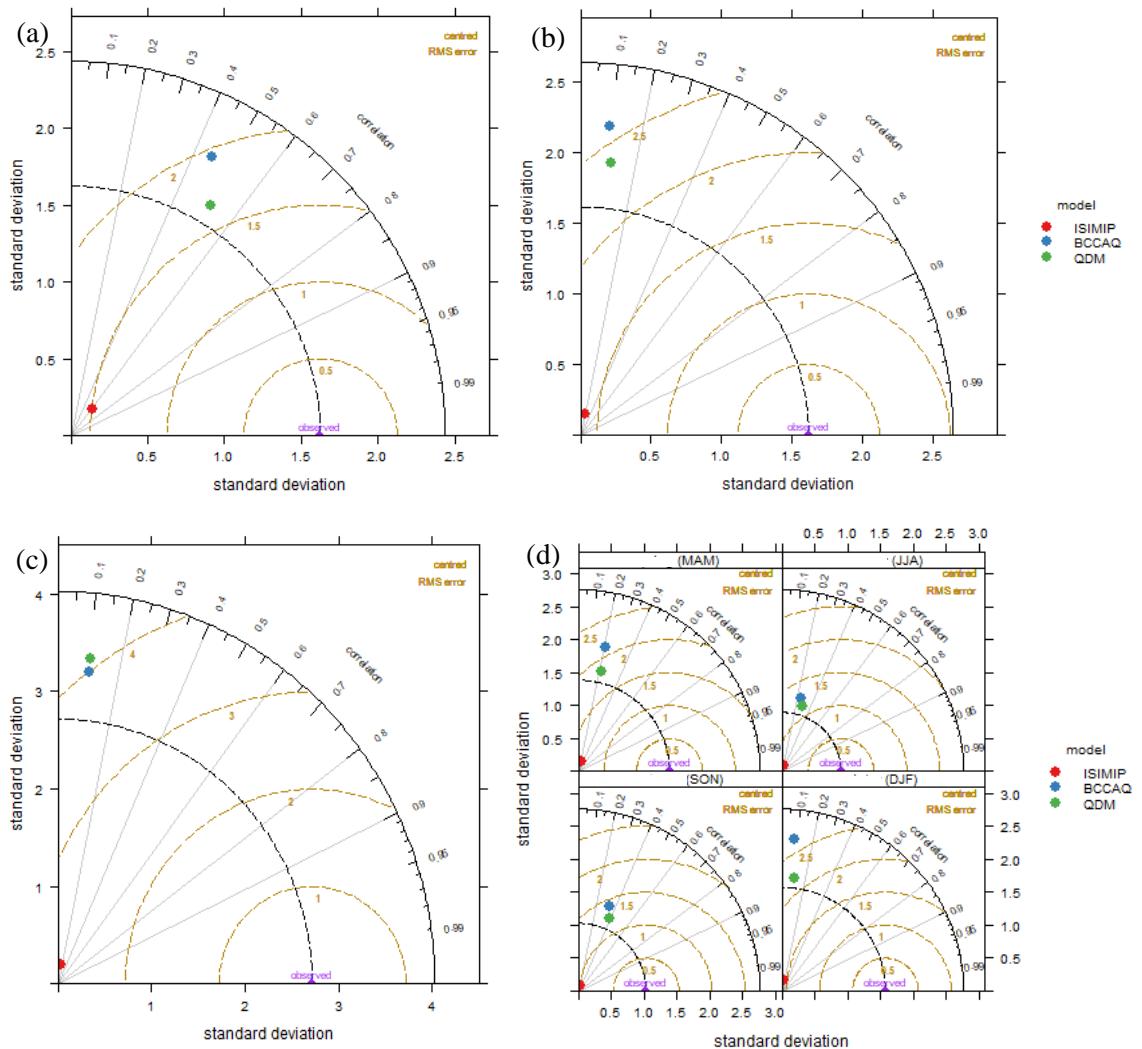


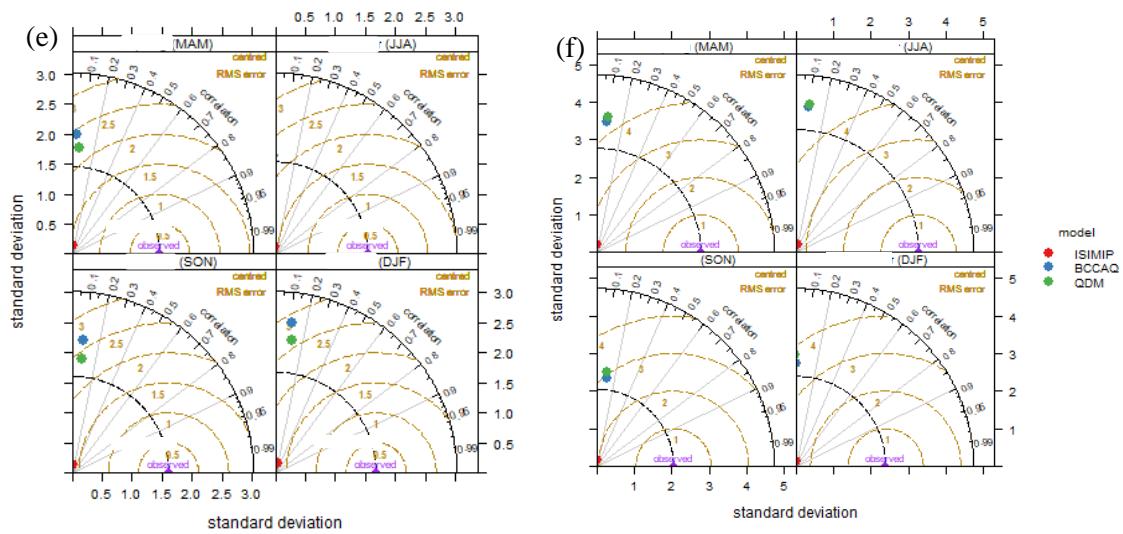


Gambar 4. 18 Diagram Taylor Curah Hujan Model BNU-ESM (a) Non-Musiman Region 1 (b) Non-Musiman Region 2 (c) Non-Musiman Region 3 (d) Musiman Region 1 (e) Musiman Region 2 (f) Musiman Region 3

Berdasarkan Gambar 4.18 titik yang mewakili metode ISIMIP cenderung lebih dekat dengan titik “observed” di semua region baik musiman dan non-musiman, hal ini menunjukan bahwa metode ISIMIP adalah metode yang mampu menyamakan model BNU-ESM dengan ERA-Interim ECMWF. Posisi titik dari metode QDM dan BCCAQ saling berdekatan artinya bahwa *skill* dari metode QDM dan BCCAQ tidak jauh berbeda, namun metode QDM sedikit lebih baik dibandingkan dengan metode BCCAQ. Region 1 non-musiman adalah region yang

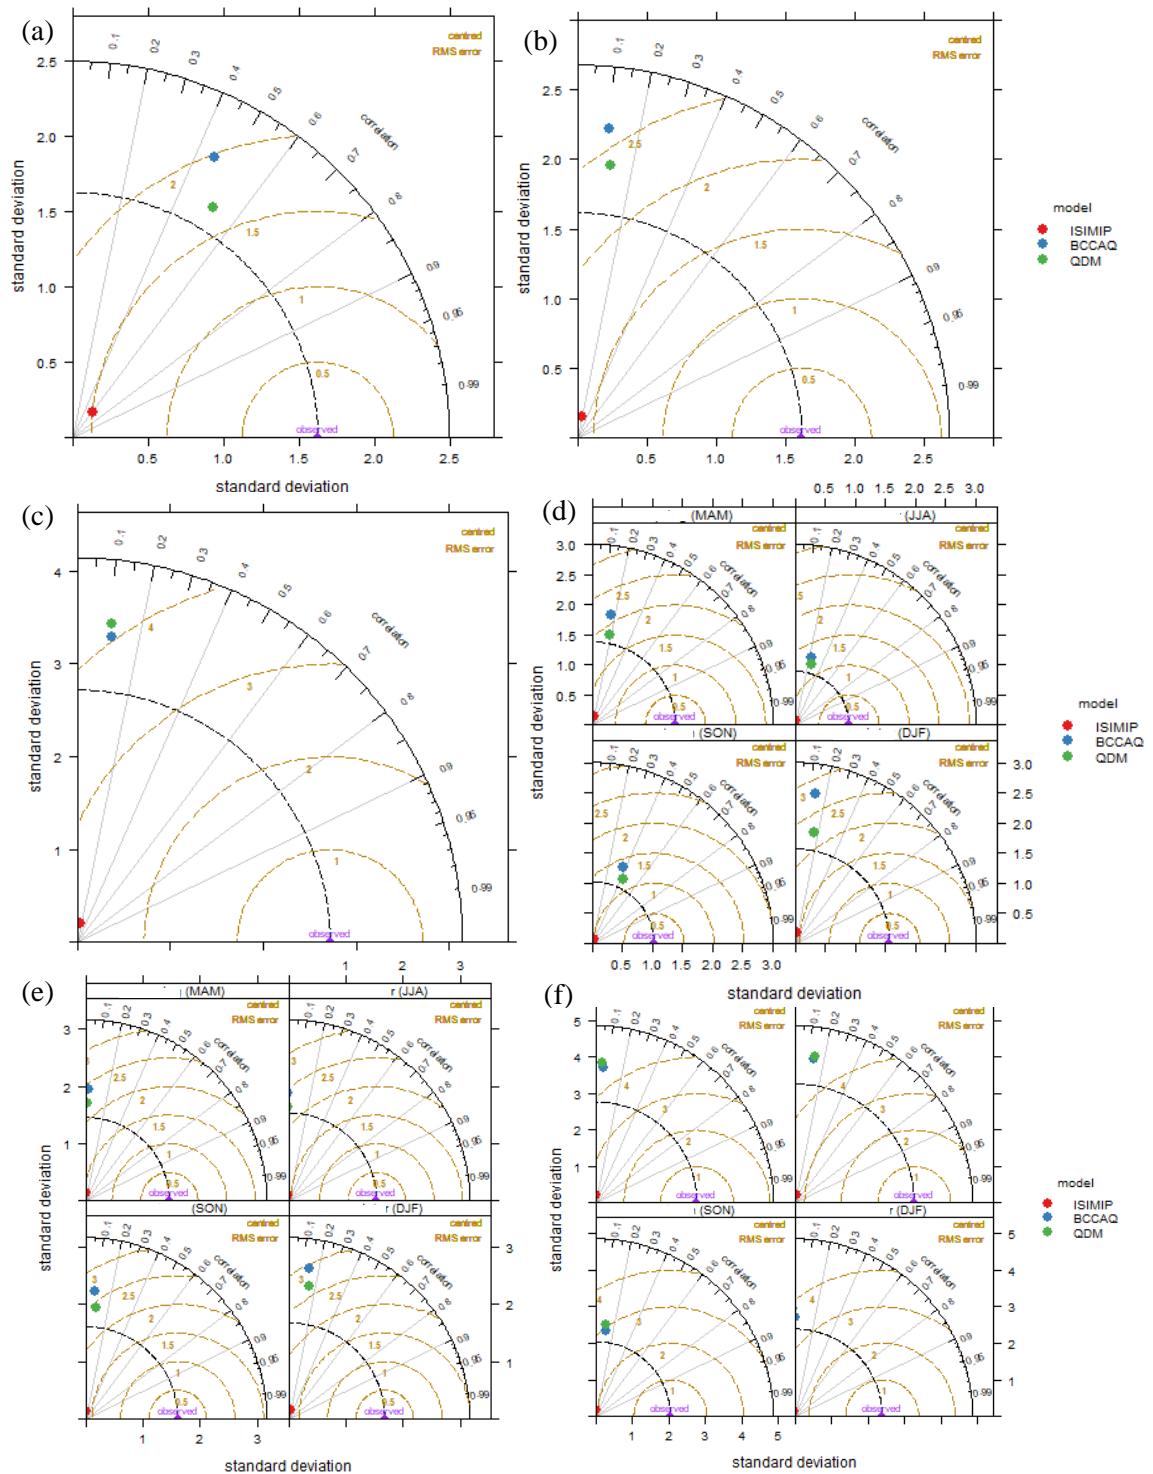
memiliki *skill* yang lebih baik dibandingkan dengan region 2 dan region 3, dimana region 1 memiliki koefisien korelasi di sekitar 0.58 dengan *centered RMS difference* sebesar 1,4 dan standar deviasi 0,7. *Skill* musiman curah hujan region 1 terbaik adalah periode SON diikuti dengan JJA, region 2 terbaik pada periode MMA dan SON, sedangkan pada region 3 padalah periode JJA dan SON. Musiman region 1 merupakan musiman region yang memiliki *skill* yang lebih baik dibandingkan dengan musiman region 2 dan musiman region 3. Diagram Taylor musiman dan non musiman pada region 2 dan region 3 memiliki koefisien korelasi dibawah 0.3.





Gambar 4. 19 Diagram Taylor Curah Hujan Model MIROC-ESM (a) Non-Musiman Region 1 (b) Non-Musiman Region 2 (c) Non-Musiman Region 3 (d) Musiman Region 1 (e) Musiman Region 2 (f) Musiman Region 3

Pada model MIROC-ESM metode ISIMIP juga memiliki *skill* yang lebih baik dibandingkan dengan metode QDM dan BCCAQ, sedangkan region 1 non-musiman merupakan region yang terbaik dibandingkan dengan region 2 dan region 3 dengan nilai koefisien korelasi sebesar 0,6, dengan *centered RMS difference* sebesar 1,5 dan standar deviasi 0,3. Diagram Taylor musiman menunjukkan bahwa pada periode SON dan JJA merupakan periode yang memiliki *skill* terbaik pada region 1, sedangkan pada musiman region 2 yang terbaik adalah periode SON dan DJF, dan pada region 3 yang terbaik adalah JJA dan SON. Berdasarkan Gambar 4.20 terlihat bahwa diagram Taylor untuk model MIROC-ESM-CHEM memiliki kisaran nilai yang sama dengan model MIROC-ESM. Kesamaan antara model MIROC-ESM-CHEM dengan model MIROC-ESM juga terdapat pada *skill* terbaik dalam hal metode, region, dan periode musiman setiap region.

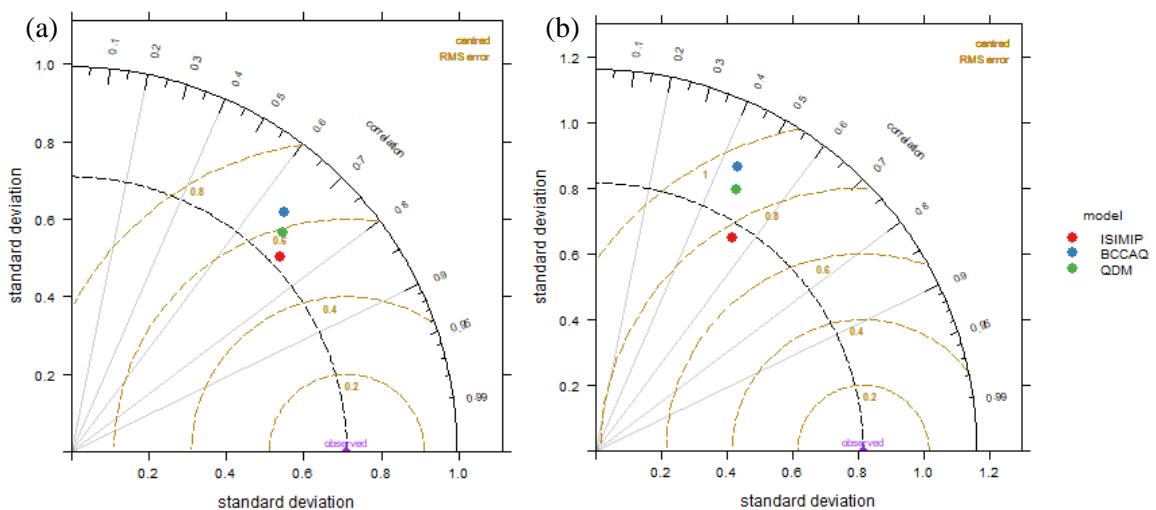


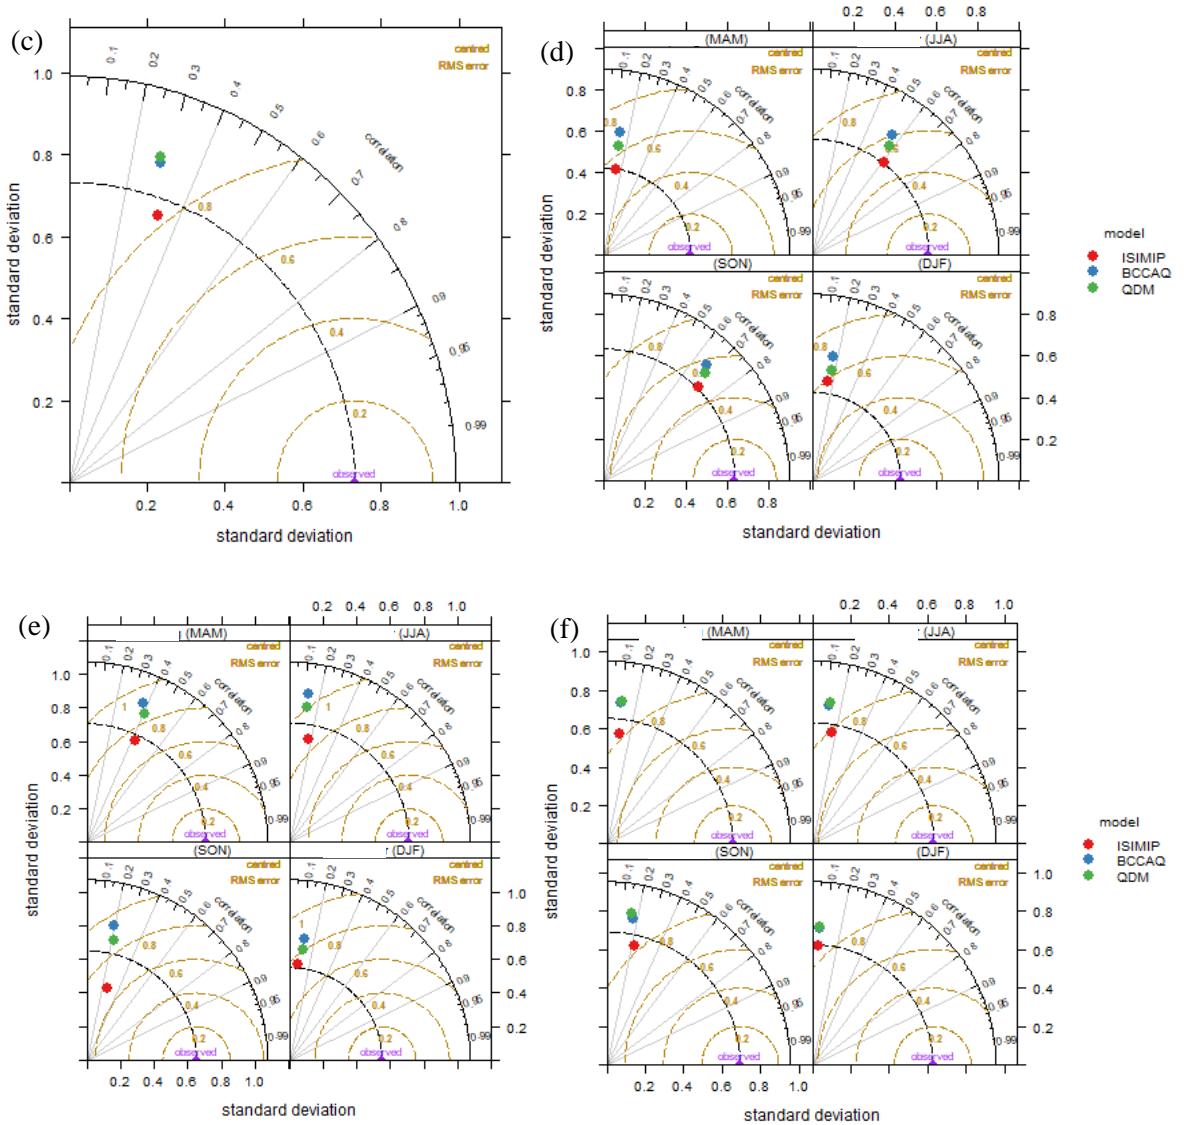
Gambar 4. 20 Diagram Taylor Curah Hujan Model MIROC-ESM-CHEM (a) Non-Musiman Region 1 (b) Non-Musiman Region 2 (c) Non-Musiman Region 3 (d) Musiman Region 1 (e) Musiman Region 2 (f) Musiman Region 3.

Berdasarkan hasil model BNU-ESM, MIROC-ESM, dan MIROC-ESM-CHEM baik musiman maupun non-musiman region 1 merupakan region dengan nilai koefisien korelasi tertinggi, *centered RMS difference* terendah, dan standar deviasi terendah, dikarenakan pola dari ketiga model skenario *historical* memiliki kemiripan yang baik dengan ERA-Interim ECMWF (lihat Gambar 4.2 (a)). Region 3 merupakan region dengan *skill* yang paling buruk untuk semua model pada skenario *historical*, hal ini dikarenakan variabilitas curah hujan yang terdapat pada region 3 cukup tinggi (lihat Gambar 4.2 (c)), selain itu juga dalam satu tahun terdapat dua puncak curah hujan tertinggi. Nilai koefisien korelasi tertinggi pada musim SON untuk semua model skenario *historical*, di mana musim SON adalah musim peralihan menuju musim *monsoon*, hal ini diperkuat oleh pernyataan penelitian sebelumnya oleh Narulita, (2017) bahwa korelasi pada musim SON lebih tinggi dibandingkan dengan musim hujan. Model MIROC-ESM dan MIROC-ESM-CHEM memiliki *skill* yang lebih baik dibandingkan dengan model BNU-ESM untuk variabel curah hujan.

#### b. Temperatur Maksimum

Berikut merupakan diagram Taylor untuk temperatur maksimum skenario *historical* model BNU-ESM, MIROC-ESM, dan MIROC-ESM-CHEM, untuk setiap region baik musiman dan non-musiman.

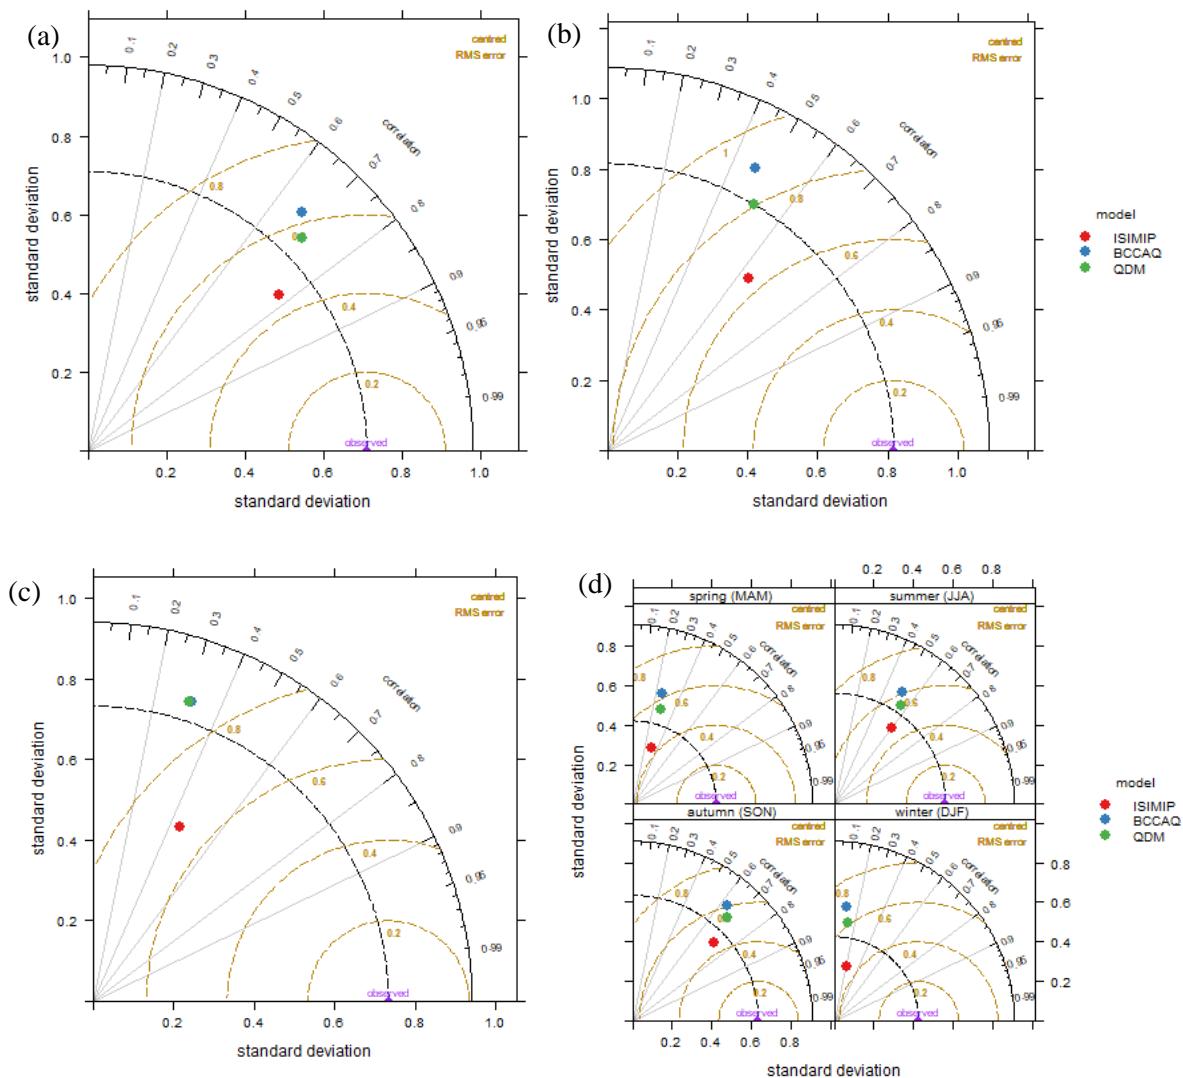


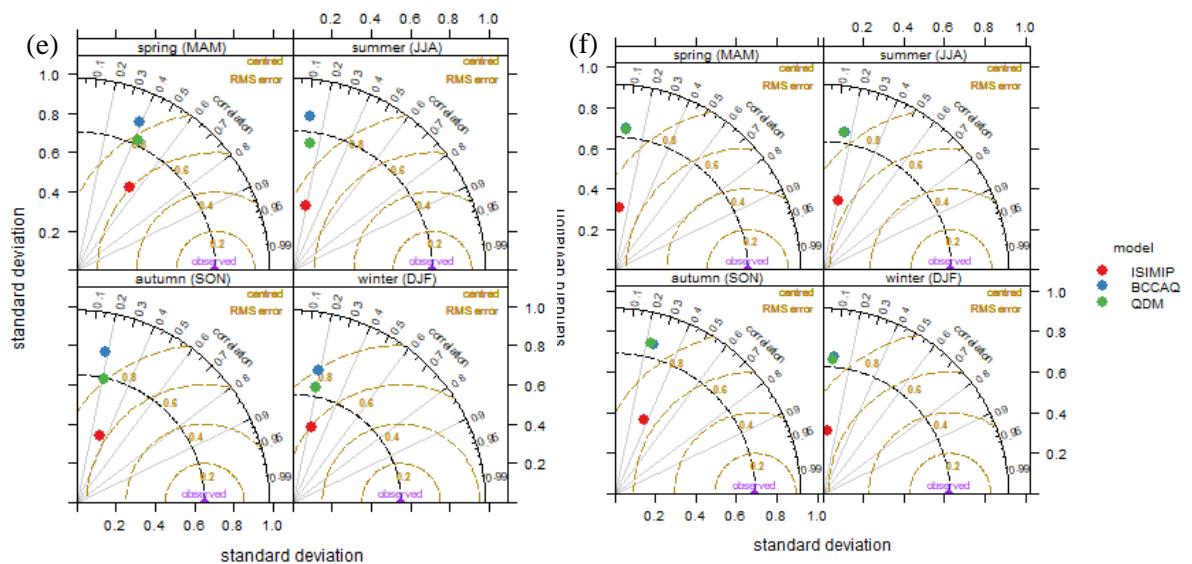


Gambar 4. 21 Diagram Taylor Temperatur Maksimum Model BNU-ESM (a) Non-Musiman Region 1 (b) Non-Musiman Region 2 (c) Non-Musiman Region 3 (d) Musiman Region 1 (e) Musiman Region 2 (f) Musiman Region 3

Berdasarkan Gambar 4.21 *skill* dari metode QDM, BCCAQ, dan ISIMIP tidak jauh berbeda baik musiman maupun non-musiman, hal ini ditunjukkan dengan saling berdekatannya tiga titik yang mewakili metode tersebut. Metode ISIMIP merupakan metode yang mampu membawa model BNU-ESM mendekati observasi (ERA-Interim ECMWF) dibandingkan dengan metode QDM dan BCCAQ, kedekatan tersebut ditunjukkan dengan nilai koefisiek korelasi sebesar 0,75, *centered*

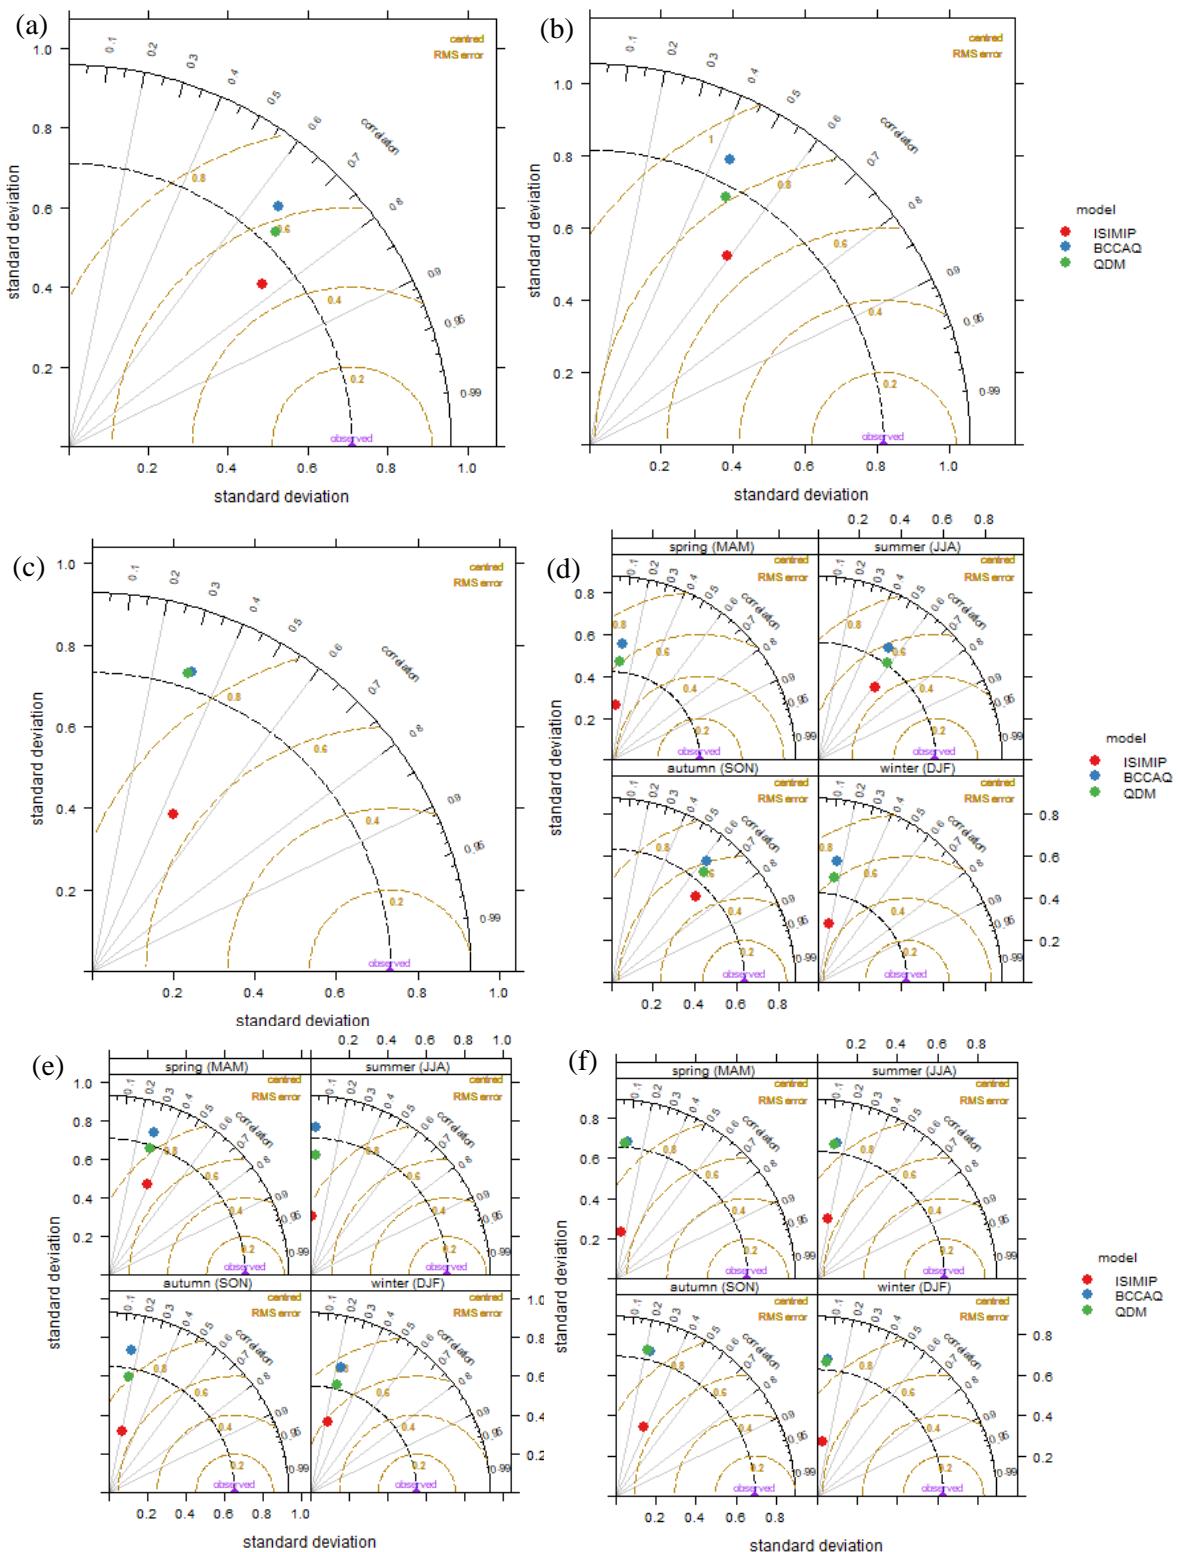
RMS *difference* sebesar 0,46 dan standar deviasi sebesar 0,71 pada region 1. Region 1 non-musiman merupakan region yang memiliki *skill* baik dibandingkan dengan region lainnya. Periode musim SON dan JJA merupakan periode yang memiliki *skill* terbaik pada region 1, sedangkan pada region 2 terdapat periode MMA dan SON, dan region 3 adalah periode JJA dan SON. Periode musiman pada region 1 merupakan periode musiman terbaik dibandingkan dengan periode musiman yang terdapat pada region 2 dan region 3.





Gambar 4. 22 Diagram Taylor Temperatur Maksimum Model MIROC-ESM (a) Non-Musiman Region 1 (b) Non-Musiman Region 2 (c) Non-Musiman Region 3 (d) Musiman Region 1 (e) Musiman Region 2 (f) Musiman Region 3.

Hasil yang diperoleh dari diagram Taylor pada model MIROC-ESM dengan BNU-ESM hamper sama, dimana metode ISIMIP mampu mengurangi bias yang terdapat pada model MIROC-ESM sehingga mendekati nilai dari observasi (ERA-Interim ECMWF). Terlihat pada Gambar 4.22 (a) region 1 non-musiman metode ISIMIP mempunyai koefisien korelasi sebesar hingga 0,79, dengan *centered RMS difference* sebesar 0,43, dan standar deviasi sebesar 0,61. Pada region 2 dan region 3 non-musiman metode ISIMIP mengalami penurunan *skill*. Pada periode musiman periode SON dan JJA merupakan periode yang memiliki *skill* paling bagus pada musiman region 1, sedangkan pada region 2 adalah periode MAM dan SON, dan region 3 adalah SON dan JJA. Model MIROC-ESM-CHEM nilai koefisien korelasi tertinggi sebesar 0,79 pada region 1, dengan nilai *centered RMS difference* 0,43, dan standar deviasi sebesar 0,61. Berdasarkan Gambar 4.23 terlihat bahwa model MIROC-ESM-CHEM nilai yang hampir sama dengan model MIROC-ESM baik musiman maupun non-musiman, sehingga kesimpulan yang diperoleh sama dengan model MIROC-ESM.



Gambar 4. 23 Diagram Taylor Temperatur Maksimum Model MIROC-ESM-CHEM (a) Non-Musiman Region 1 (b) Non-Musiman Region 2 (c) Non-Musiman Region 3 (d) Musiman Region 1 (e) Musiman Region 2 (f) Musiman Region 3.

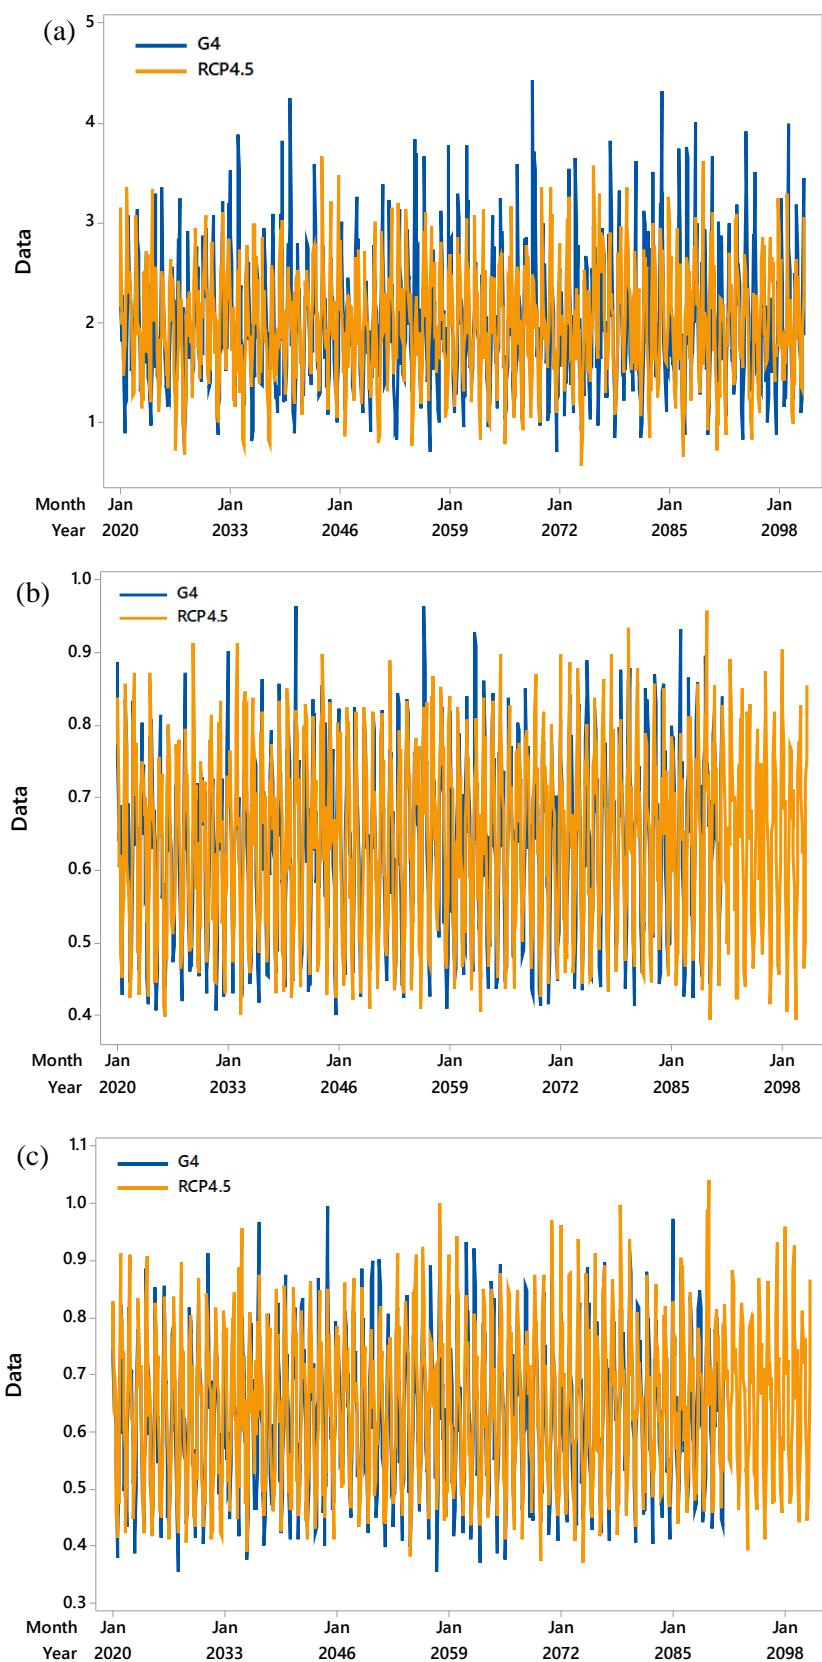
Berdasarkan hasil yang diperoleh dari model BNU-ESM, MIROC-ESM, dan MIROC-ESM-CHEM, metode ISIMIP memiliki *skill* yang baik disetiap region mengungguli metode QDM dan BCCAQ. Periode peralihan merupakan (SON dan MAM) periode yang memiliki *skill* lebih baik dibandingkan dengan periode lainnya. Model MIROC-ESM dan MIROC-ESM-CHEM lebih baik dibandingkan dengan model BNU-ESM dalam mendekati nilai observasi (ERA-Interim ECMWF). Region 1 merupakan region yang memiliki *skill* terbaik dibandingkan dengan region 2 dan 3 pada setiap model skenario *historical* diakrenakan pola antara model-model skenario *historical* pada region 1 sangat mirip dengan data ERA-Interim ECMWF (lihat Gambar. 4.3).

### 5.3. Proyeksi Iklim Skenario G4 dan RCP4.5

Metode ISIMIP merupakan metode terbaik dalam skenario *historical*, sehingga langkah selanjutnya adalah proyeksi iklim dengan menggunakan metode ISIMIP pada skenario G4 dan RCP4.5. Skenario G4 merupakan skenario yang dirancang oleh Kravitz, (dkk 2011) untuk menurunkan suhu bumi, skenario G4 merupakan modifikasi dari skenario RCP4.5. Skenario G4 dimulai tahun 2020 dan dilepas *treatment*-nya pada tahun 2070, sehingga pada tahun 2071 temperatur mulai kembali normal dan berangsur meningkat. Pada penelitian ini menggunakan dua indeks ekstrim yaitu Rx1day untuk curah hujan dan TXx untuk temperatur maksimum. Indeks Rx1day adalah jumlah maksimal curah hujan satu hari dalam 1 bulan ( $\text{mm}^2$ ). Indeks TXx adalah temperatur tertinggi dalam satu bulan ( $^{\circ}\text{C}$ ).

#### a. Curah hujan

Berikut merupakan *time series plot* dari indeks Rx1day untuk model BNU-ESM-MIROC-ESM, dan MIROC-ESM-CHEM.

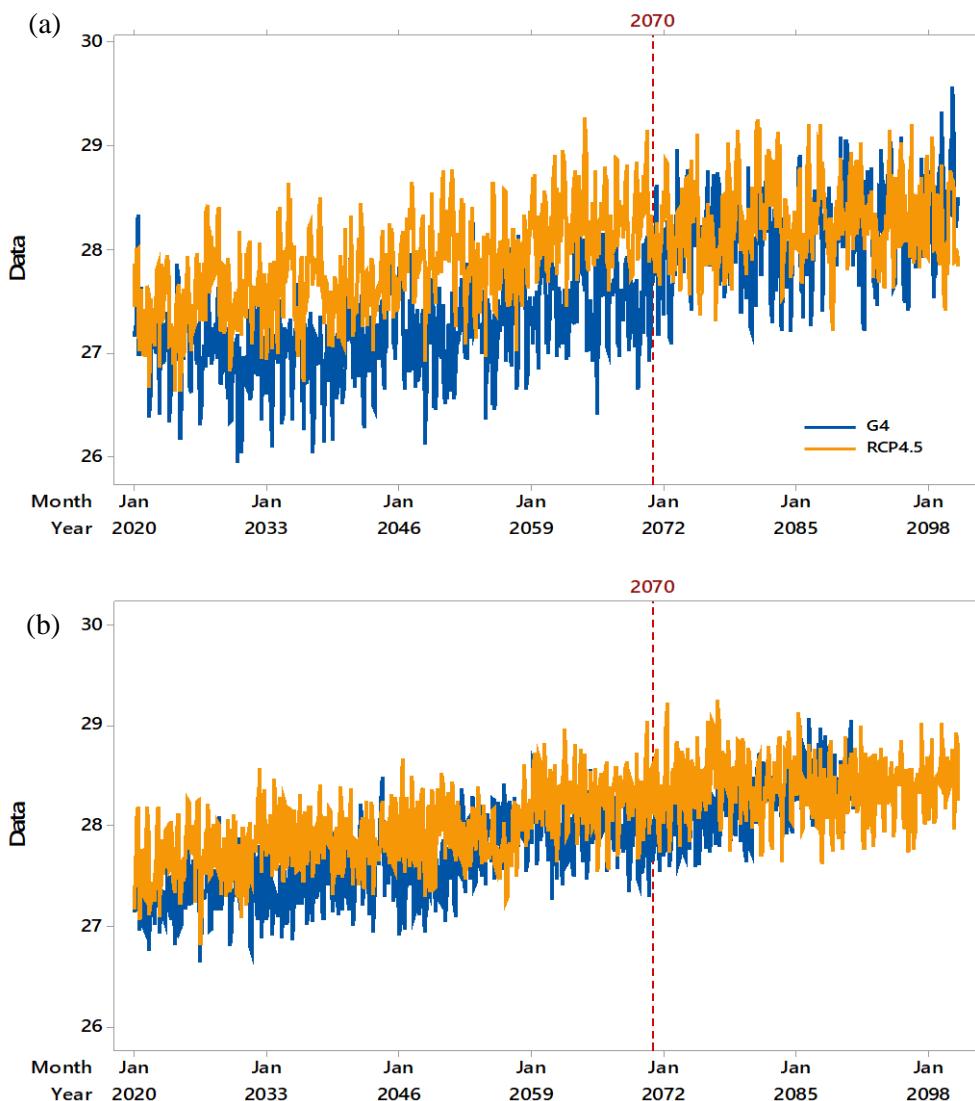


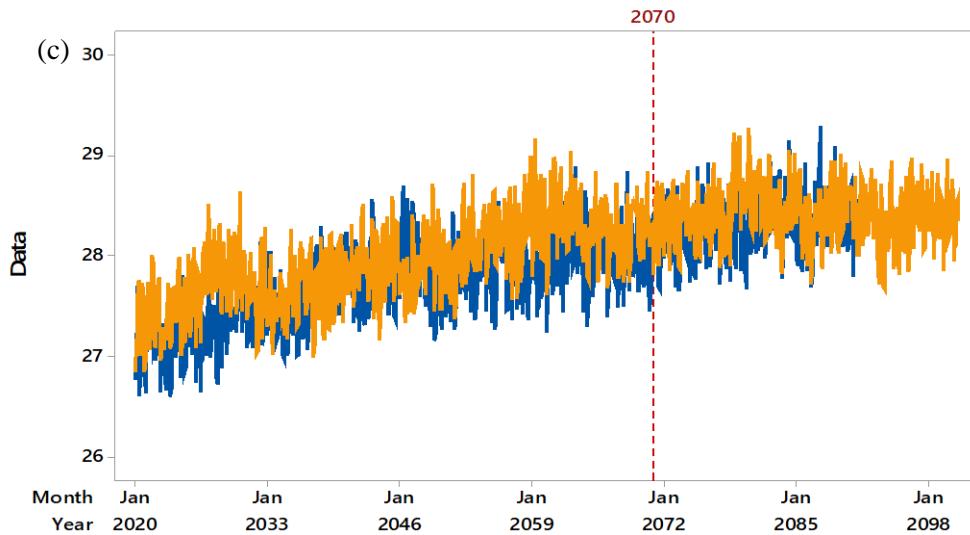
Gambar 4. 24 *Time Series Plot* Indeks Ekstrim Rx1day (a) BNU-ESM (b) MIROC-ESM (c) MIROC-ESM-CHEM

Berdasarkan Gambar 4.24 bahwa curah hujan pada model BNU-ESM, MIROC-ESM, dan MIROC-ESM-CHEM pada masing-masing skenario sangat fluktuatif. Pada model BNU-ESM intensitas curah hujan G4 lebih tinggi dibandingkan dengan RCP4.5, sedangkan pada model MIROC-ESM dan MIROC-ESM-CHEM lebih tinggi skenario RCP4.5. Skenario G4 merupakan skenario yang dirancang untuk menurunkan skenario kenaikan temperatur RCP4.5, penurunan temperatur sebanding dengan penurunan intensitas curah hujan, namun pada penelitian kali ini bahwa intensitas curah hujan dari skenario G4 tidak mengalami penurunan hal ini dikarenakan variabilitas dari curah hujan sangat kompleks.

#### b. Temperatur maksimum

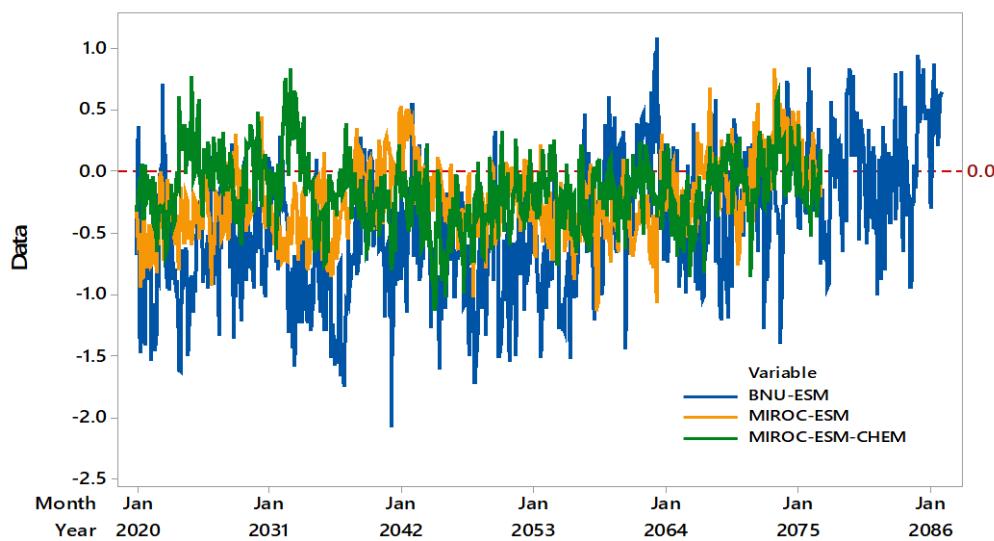
Berikut merupakan *time series plot* TXx temperatur maksimum G4 dan RCP4.5 pada model BNU-ESM, MIROC-ESM, dan MIROC-ESM-CHEM.





Gambar 4. 25 *Time Series Plot* Indeks Ekstrim TXx (a) BNU-ESM (b) MIROC-ESM (c) MIROC-ESM-CHEM

Berdasarkan Gambar 4.25 (a) terlihat bahwa suhu pada skenario G4 model BNU-ESM tahun 2020 berada dibawah dari skenario RCP4.5 model BNU-ESM, hal ini menandakan injeksi SO<sub>2</sub> mulai berkerja untuk menurunkan suhu bumi. Pada tahun 2050 injeksi SO<sub>2</sub> dihentikan, sehingga suhu pada tahun 2071 mulai naik, tetapi suhu pada skenario G4 model BNU-ESM masih dibawah dari skenario RCP4.5 di karenakan bahwa setelah tahun 2070 efek dari injeksi SO<sub>2</sub> masih. Pada skenario G4 model MIROC-ESM mengalami penurunan suhu sama seperti G4 model BNU-ESM namun tidak terlalu signifikan, bahkan terdapat beberapa bulan G4 model MIROC-ESM lebih tinggi dibandingkan dengan RCP4.5 model MIROC-ESM, namun sebagian besar cenderung dibawah dari RCP4.5. Skenario G4 model MIROC-ESM-CHEM tidak berjalan dengan baik, terlihat walaupun terdapat beberapa bulan temperatur lebih rendah dibandingkan RCP4.5 model MIROC-ESM-CHEM, namun sebagian besar sama. Gambar 4.26 merupakan *plot* penurunan suhu masing-masing model yang didapat dari TXx G4 dikurangi dengan TXx RCP4.5, untuk mengetahui seberapa besar penurunan suhu yang diakibatkan oleh injeksi SO<sub>2</sub> terhadap skenario RCP4.5 masing masing model.

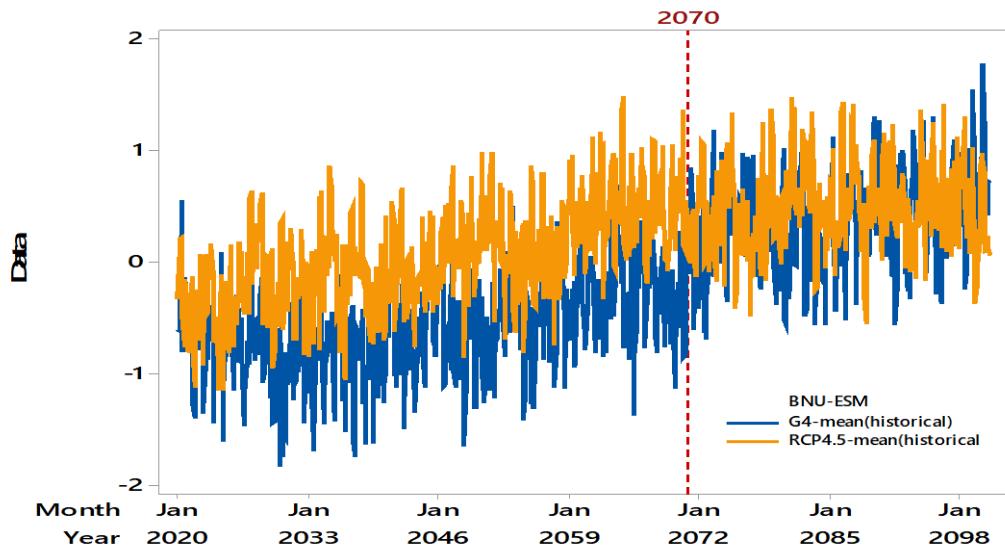


Gambar 4. 26 Time series Plot G4-RCP4.5 untuk Setiap Model Skenario G4 dan RCP4.5

Berdasarkan Gambar 4.26 model BNU-ESM adalah model yang memiliki performasi yang baik dalam menurunkan suhu, terlihat bahwa dari tahun 2024-2062 nilai dibawah 0 dengan penurunan terbesar pada tahun 2042 sebesar  $2^{\circ}\text{C}$ , rata-rata penurunan cuhu model BNU-ESM pada periode penyemprotan  $\text{SO}_2$  sebesar  $0.57^{\circ}\text{C}$ . Model MIROC-ESM mampu menurunkan suhu tetapi tidak begitu signifikan dimana terdapat beberapa bulan yang nilainya melebihi 0, artinya bahwa suhu pada skenario RCP4.5 model MIROC-ESM lebih rendah dibandingkan dengan G4 model MIROC-ESM, dengan rata-rata penurunan sepanjang masa penyemprotan  $\text{SO}_2$  sebesar  $0.27^{\circ}\text{C}$ . Model MIROC-ESM-CHEM tidak berbeda jauh dengan MIROC-ESM, hal tersebut ditunjukkan dengan plot antara MIROC-ESM dan MIROC-ESM-CHEM tidak terlalu berbeda.

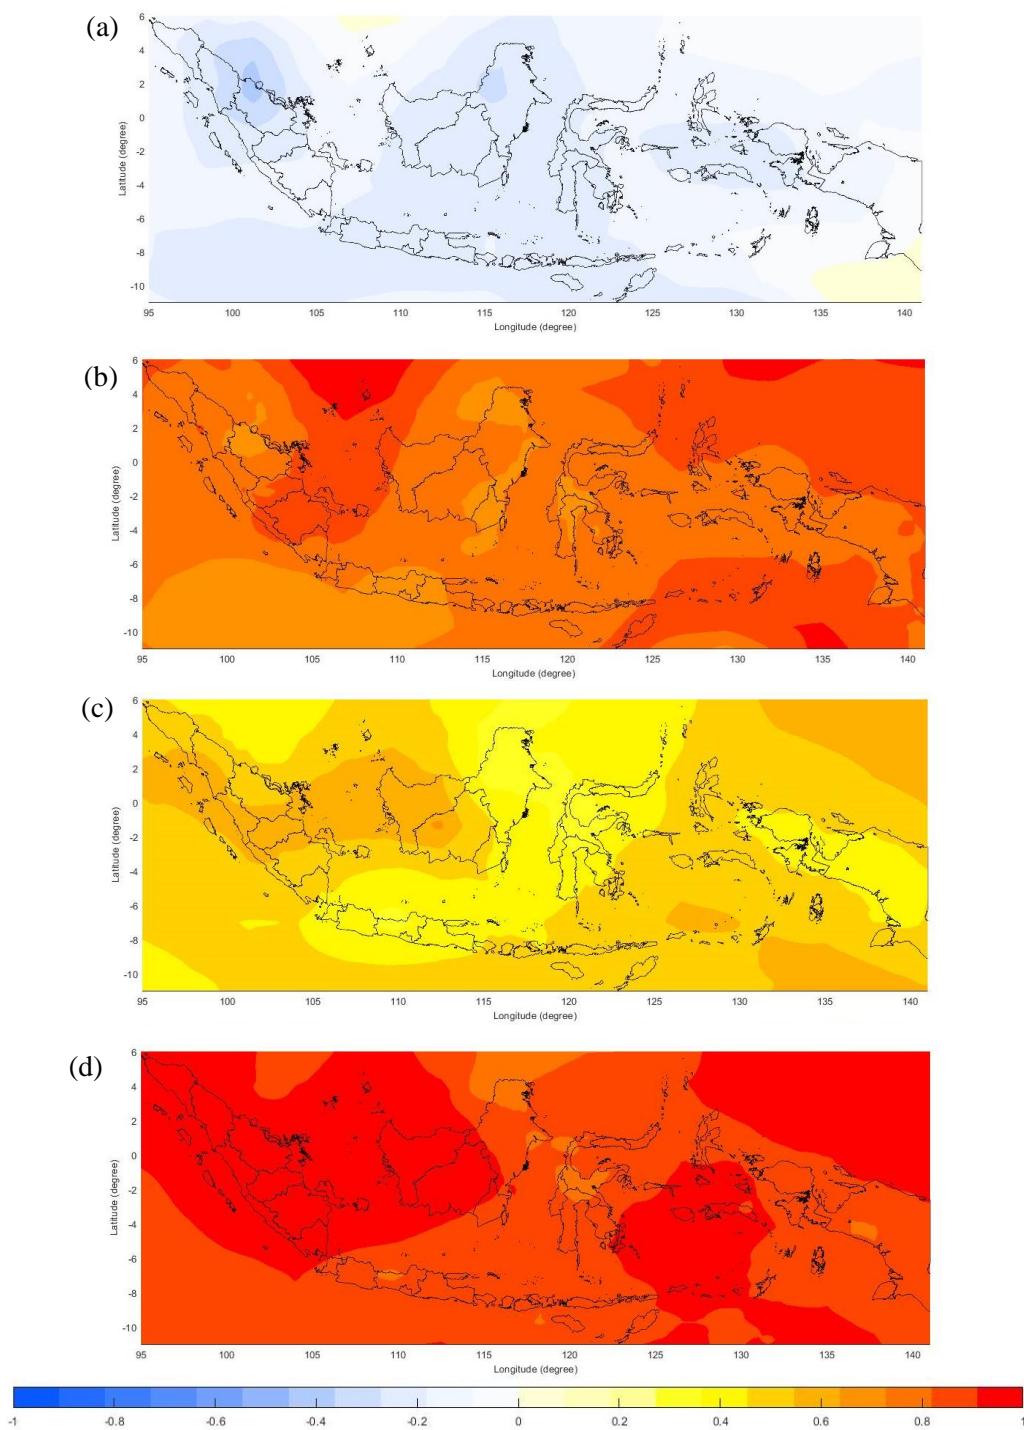
Skenario *historical* merupakan skenario historis dimana perlakuan atau efek perubahan iklim belum dimasukan dalam skenario. Skenario RCP4.5 adalah skenario kenaikan suhu, sedangkan skenario G4 adalah skenario untuk menurunkan kenaikan suhu yang dibuat oleh skenario RCP4.5. Skenario G4 model BNU-ESM terbukti efektif dalam menurunkan suhu, selanjutnya akan dilakukan analisis seberapa besar penurunan suhu pada skenario G4 model BNU-ESM terhadap suhu pada masa historis yang diwakili oleh skenario *historical* model BNU-ESM.

Skenario analisisnya adalah dengan mengurangi temperatur G4 model BNU-ESM dan RCP4.5 model BNU-ESM dengan rata-rata temperatur skenario *historical* model BNU-ESM. Gambar 4.27 merupakan *time series* plot untuk mengetahui penurunan suhu terhadap skenario *historical*.



Gambar 4. 27 *Time Series Plot* untuk Mengetahui Perubahan Skenario G4 dan RCP4.5 Terhadap Rata-Rata Skenario *Historical*.

Berdasarkan Gambar 4.27 terlihat bahwa temperatur G4 model BNU-ESM bernilai dibawah 0, artinya bahwa temperatur yang dimiliki oleh skenario G4 model BNU-ESM berada dibawah dari temperatur skenario *historical* BNU-ESM. Temperatur skenario RCP4.5 model BNU-ESM yang dikurangi skenario *historical* sangat fluktuatif, namun masih di atas dari skenario G4 model BNU-ESM, hal ini menunjukan bahwa injeksi SO<sub>2</sub> bekerja dengan baik. Setelah periode pelepasan berakhir yaitu tahun 2070 skenario G4 dan RCP4.5 model BNU-ESM memiliki nilai yang hampir sama. Langkah selanjutnya untuk mengetahui daerah mana saja yang mengalami penurunan akan diplotkan peta skenario G4 model BNU-ESM dikurangi dengan skenario *historical* BNU-ESM tahun 2020-2070 (masa injeksi SO<sub>2</sub>) dan tahun 2071-2100 (setelah masa injeksi).



Gambar 4. 28 Peta selisih temperatur antara G4 dan RCP4.5 dengan *historical* model BNU-ESM  
 (a) 2020-2070 skenario G4 (b) 2071-2100 skenario G4 (c) 2020:2070 skenario RCP4.5 (d) 2071-2100 skenario RCP4.5

Berdasarkan Gambar 4.28 (a) terlihat bahwa diseluruh wilayah Indonesia mengalami penurunan temperatur, ditunjukan bahwa gradasi warna sebagian besar berwarna putih menuju biru pada periode injeksi SO<sub>2</sub> (2020-2070), hal ini menunjukan bahwa pada periode tersebut suhu menyamai atau bahkan sedikit dibawah *historical*. Kenaikan suhu setelah masa transisi terlihat pada Gambar 4.28 (b) dimana gradasi warna wilayah Indonesia menuju merah. Pada skenario RCP4.5 periode 2020-2070 temperatur BNU-ESM belum menyamai rata-rata suhu *historical*, dan semakin meningkat pada tahun 2071-2100.

## **BAB 5**

### **KESIMPULAN DAN SARAN**

#### **5.1. Kesimpulan**

Beberapa hal yang dapat disimpulkan dalam analisis sebelumnya bahwa data luaran ESM terbukti memiliki resolusi yang rendah, hal ini ditunjukkan dengan peta antara luaran ESM dan ERA-Interim ECMWF (resolusi tinggi) sangat berbeda. Setelah dilakukan *downscale* dan koreksi bias terhadap luaran ESM, hasil yang diperoleh bahwa metode koreksi bias dan *downscale* mampu mengoreksi bias yang terdapat pada luaran ESM, hal ini ditunjukkan dengan kesamaan pola antara data ERA-Interim ECMWF dengan luaran ESM yang telah *didownscale* dan koreksi bias menggunakan metode QDM, BCCAQ, dan ISIMIP.

*Skill* metode koreksi bias QDM, BCCAQ dan ISIMIP dievaluasi oleh peta korelasi dan RMSE ditambah dengan diagram Taylor. Berdasarkan peta korelasi dan RMSE untuk curah hujan serta temperatur maksimum, metode ISIMIP lebih baik dibandingkan dengan metode QDM dan BCCAQ, walapun perbedaanya tidak terlalu signifikan. Terdapat lebih dari 70% titik (grid) yang korelasinya signifikan dari ketiga metode yang digunakan untuk variable curah hujan baik per region ataupun seluruh Indonesia. Terdapat lebih dari 90% titik (grid) yang korelasinya signifikan untuk variabel temperatur maksimum baik per region maupun seluruh Indonesia. Berdasarkan diagram Taylor metode ISIMIP memiliki peformasi lebih baik dibandingkan dengan metode QDM dan BCCAQ. Region 1 merupakan region dengan koefisien korelasi tertinggi, *centered RMS difference* terendah, dan standar deviasi terendah pada setiap model *historical*. Model MIROC-ESM dan MIROC-ESM-CHEM lebih baik dibandingkan dengan model BNU-ESM untuk curah hujan, sedangkan untuk variabel temperatur maksimum model BNU-ESM lebih baik dibandingkan dengan model MIROC-ESM, dan MIROC-ESM-CHEM.

Metode ISIMIP secara keseluruhan memiliki *skill* lebih baik dibandingkan metode QDM dan BCCAQ, sehingga metode ISIMIP akan digunakan untuk proyeksi iklim menggunakan skenario G4 dan RCP4.5. Proyeksi iklim dianalisis berdasarkan indeks ekstrim Rx1day untuk curah hujan dan TXx untuk temperatur

maksimum. Curah hujan pada skenario G4 dan RCP4.5 model BNU-ESM, MIROC-ESM, dan MIROC-ESM-CHEM sangat fluktuatif sampai tahun 2090. Temperatur maksimum skenario G4 mulai tahun 2020 cenderung lebih rendah dibandingkan dengan skenario RCP4.5, seketika naik pada tahun 2071 dikarenakan injeksi SO<sub>2</sub> dihentikan. Model BNU-ESM merupakan model yang mampu menurunkan suhu bumi dengan efektif dibandingkan dengan model MIROC-ESM dan MIROC-ESM-CHEM. Temperatur maksimum skenario G4 model BNU-ESM pada tahun 2020-2070 mampu menyamai temperatur maksimum skenario *historical* model BNU-ESM di seluruh wilayah Indonesia. Sedangkan skenario RCP4.5 model BNU-ESM masih lebih panas dibandingkan dengan skenario *historical* model BNU-ESM di seluruh wilayah Indonesia. Skenario G4 pada masa injeksi SO<sub>2</sub> (2020-2070) mampu menurunkan skenario kenaikan temperatur di bumi 0-2°C.

## 5.2. Saran

Hasil penelitian ini menunjukan bahwa peformasi dari metode QDM, BCCAQ, dan ISIMIP sudah cukup bagus untuk variabel temperatur maksimum, namun masih kurang bagus pada variabel curah hujan. Saran yang diberikan untuk penelitian selanjutnya yaitu mencoba metode lain selain metode koreksi bias QDM, BCCA, dan ISIMIP yang memiliki *skill* baik untuk curah hujan, khususnya daerah katulistiwa, saran lainnya adalah mengganti data resolusi tinggi (ERA-Interim ECMWF) dengan data lain, misalnya ERA-5 yang merupakan perbaikan dari ERA-Interim atau data Aphrodite.

## DAFTAR PUSTAKA

- Ahmed, K.Z., Wang, G., Sildar, S., Wilson, A.M., Allen, J.M., Horton, R., dan Anyah, R. (2013), “Statistical Downscaling and Bias Correction of Climate Model Outputs for Climate Change Impact Assessment in the U . S . Northeast.” ,*Global and Planetary Change*, Vol. 100, hal. 320–332.
- Aldrian, E dan Susanto, R.D. (2003), “Identification of Three Dominant Rainfall Regions within Indonesia and Their Relationship to Sea Surface Temperatur.”, *International Journal of Climatology* Vol. 23, No. 12, hal. 1435–52.
- Boe, J., Terray L., Habets, F., dan Martin, E.(2007), “Statistical and Dynamical Downscaling of the Seine Basin Climate for Hydro-Meteorological Studies”, *International Journal of Climatology*, Vol. 27, No. 12, hal. 1643–55.
- Cannon, A.J., Sobie, S.R., dan Murdock, T.Q. (2015), “Bias Correction of GCM Precipitation by Quantile Mapping : How Well Do Methods Preserve Changes in Quantiles and Extremes ?”, *Journal of Climate*, Vol. 28, hal 6938–59.
- Daniels, A.E., Morrison, J.F., Joyce, L.A., Crookston, N.L., Chen, S.C., dan McNally, S. G. (2012). *Climate projections FAQ*. General Technical Report. Fort Collins, CO, U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station: 1-32.
- Eentemeyer, R. K. dan Hunter,R. D. (2005), “Climatologically Aided Mapping of Daily Precipitation and Temperatur.”, *Journal of Applied Meteorology*, Vol. 44, hal. 1501–1510.
- Falcon, W.P., Naylor,R.L., Smith, W.l., Burke, M.B., dan McCullough, E.B. (2004), “Using Climate Models to Improve Indonesian Food Security.”, *Bulletin of Indonesian Economic Studies*, Vol. 40, No. 3, hal. 355–3577.
- Gusev, Y.M., Nasonova, O.N., Kovalev, E.E., dan Ayzel, G.V. (2018), “Impact of Possible Climate Changes on River Runoff under Different Natural Conditions.”, *Proc. IAHS*, Vol. 279, hal. 293–300.
- Hagemann, S., Chen, C., dan Hearter, J.O. (2011), “Impact of a Statistical Bias Correction on the Projected Hydrological Changes Obtained from Three GCMs and Two Hydrology Models.”, *Journal of Hydrometeorology*, Vol. 12, hal. 556–578.
- Harsa, H. (2017), *Pendugaan Parameter Distribusi Gamma Pada Quantile Mapping Menggunakan Self Organizing Map untuk Koreksi Bias Data Curah Hujan*, Tesis, Istitut Pertanian Bogor, Bogor.
- Hempel, S., Frieler, K., Waraszawski, L., Schewe, J., dan Piontek, F. (2013), “A Trend-Preserving Bias Correction – the ISI-MIP Approach.” , *Earth System Dynamics*, Vo. 4, No. 2, hal. 219–236.

- Hendon, Harry H. dan Brant, L. (2002), "A Composite Study of Onset of the Australian Summer Monsoon." *Journal of the Atmospheric Sciences*, Vol. 47, No No. 18, hal 2227–2240.
- Hidalgo, H. G., Dettinger, M. D., dan Cayan, D. R. (2008), "Downscaling with Constructed Analogues : Daily Precipitation and Temperatur Fields over the United States.", *California Energy Commission Report*,
- Huth, R dan Jan, K. (2000), "Constructing Site-Specific Climate Change Scenarios on a Monthly Scale Using Statistical Downscaling.", *Theoretical and Applied Climatology*, Vol. 66, No. 1–2, hal. 13–27.
- Jacob, D. (2001), "A Note to the Simulation of the Annual and Inter-Annual Variability of the Water Budget over the Baltic Sea Drainage Basin.", *Meteorology and Atmospheric Physics*, Vol. 73, hal. 61–73.
- Ji, D., Fang, S., Curry, C.L., Kashimura, H., Watanabe, S., Cole, J.N.S., Lenton, A., Muri, H., Kravitz, B., dan Moore, J.C. (2018). "Extreme temperatur and precipitation response to solar dimming and stratospheric aerosol geoengineering", *Atmospheric Chemistry and Physics*, Vol 18, No. 14, hal. 10133-10156.
- Jones, A.C., Hawcroft, M.K., Haywood, J.M., Jones, A., Guo, X., dan Moore, J.C. (2018). "Regional Climate Impacts of Stabilizing Global Warming at 1.5 K Using Solar Geoengineering", *Earth's Future*. Vol. 6, No. 2, hal. 230-251.
- Kravitz, B., Robock, A., Boucher, O., Schmidt, H., Taylor, K.E., Stenchikov, G., dan Schulz, M. (2011). "The Geoengineering Model Intercomparison Project (GeoMIP)", *Athmospheric Science*, Vol. 12, No. 2, hal. 162-167.
- Kristianda, F. dan Fithriasari, K. 2016. "Peramalan Curah Hujan di Wilayah Timur dengan Vector Autoregressive Neural Network", *Jurnal Sains dan Seni*, Vol. 5, No. 2, hal. 175-180.
- Lizumi, T., Takikawa, H., Hirabayashi, Y., Hanasaki, N., dan Nishimori, M. (2017), "Contributions of different bias-correction methods and reference meteorological forcing data sets to uncertainty in projected temperatur and precipitation extremes.", *Journal of Geophysical Research:Atmospheres*, Vol. 122, hal. 7800–7819.
- Lorenz, E.N. (1969), "Atmospheric Predictability as Revealed by Naturally Occurring Analogues.", *Journal of the Atmospheric Sciences*, Vol. 26, hal.636–646.
- Maraun, D. (2013), "Bias Correction, Quantile Mapping, and Downscaling : Revisiting the Inflation Issue.", *Journal of Climate*, Vol. 26, hal. 2137– 2143.
- Marquardt, D. W. (1963), "An Algorithm for Least-Squares Estimation of Nonlinear Parameters.", *Journal of The Society for Industrial and Apiled Mathematics*, Vol. 11, No. 2, hal. 431–441.

- Maurer,E.P., Hidalgo, H.G., Das, T., Dettinger, M.D., dan Cayan, D.R. (2010), "The Utility of Daily Large-Scale Climate Data in the Assessment of Climate Change Impacts on Daily Streamflow in California.", *Hydrology Earth System Sciences*, Vol. 14, hal. 1125–1138.
- Moss, R.D., Edmonds, J.A., Hibbard, K.A., Manning, M.R., Rose, S.K., van Vuuren, D.P., Carter, T.P., Emori, S., Kainuma, M., Kram, T., Meehl, G.A., Mitchell, J.F.B., Nakicenovic, N., Riahi, K., Smith, S.J., Stouffer, R.J., Thomson, A.M., Weyant, J.P., dan Wilbanks, T.J. (2010), "The next generation of scenarios for climate change research and assessment", *Nature*, Vol. 463, No. 7282, hal. 747-756.
- Narulita, I. (2017). "Pengaruh ENSO dan IOD pada Variabilitas Curah Hujan di DAS Cerukuk, Pulau Belitung", *Jurnal Tanah dan Iklim*, Vol. 41, No. 1, hal. 45-60.
- Naylor, R.L., Battisti, D.S., Vimont, D.J., Falcon, W.P., and Burke, M.B. (2007), "Assessing Risks of Climate Variability and Climate Change for Indonesian Rice Agriculture.", *Proceedings of the National Academy of Sciences*, Vol. 104, No. 19, hal. 7752–7757.
- Nugroho, S., Febriamansyah, R., Ekaputra, E.G., dan Gunawan, D. (2019)."Analisis Iklim Ekstrim untuk Deteksi Perubahan Iklim di Sumatra Barat", *Junral Ilmu Lingkungan*, Vol. 17, No. 1, hal. 7-14.
- Piani, C., Haerter , J. O., dan Coppola , E. (2010), "Statistical Bias Correction for Daily Precipitation in Regional Climate Models over Europe.", *Theor Appl Climatol*, Vol. 99, hal. 187–92.
- Pinson, P. (2012), "Adaptive Calibration of ( u , v ) -Wind Ensemble Forecasts 1274.", *Q. J. R. Meteorol. Soc.* Vol. 138, hal. 1273–1284.
- Qian, J. (2008), "Why Precipitation Is Mostly Concentrated over Islands in the Maritime Continent.", *Journal of the Atmospheric Sciences* Vol. 65, No. 4, hal. 1428–1441.
- Tang, J., Niu, X., Wang, S., Gao, H., Wang, X., dan Wu, J. (2016). "Statistical downscaling and dynamical downscalingof regional climate in China: Present climateevaluations and future climate projections". *Journal of Geophysical Reasearch: Atmospheres*. Vol. 121, No. 5, hal. 2110-2129
- Taylor, K.E., Stouffer, R.J., dan Meehl, G.A. (2012). "An overview of CMIP5 and the experiment design", *Bull Am Meteorol Soc*, Vol. 93, No. 4, hal. 485–498.
- Taylor, K.E. (2001). "Summarizing multiple aspects of model performance in a single diagram". *J. Geophys. Res.*, Vol. 106, hal. 7183-7192.
- Salath, Eric P., Mote, W., dan Wiley, M.W. (2007), "Review of Scenario Selection and Downscaling Methods for the Assessment of Climate Change Impacts on Hydrology in the United States Pacific Northwest.", *International Journal of Climatology*, Vol. 27, hal. 1611–21.

- Schefzik, R., Thorarinsdottir, T.L., dan Tilman, G. (2013), "Uncertainty Quantification in Complex Simulation Models Using Ensemble Copula Coupling.", *Statistical Science*, Vol. 28, No. 4, hal. 616–640.
- Siwilia, S., Taye, M.T., Quevauviller, P., dan Willems, P. (2013), "Climate Change Impact Investigation on Hydro-Meteorological Extremes on Zambia's Kabompo Catchment", *Acque Sotterraneo*, Vol. 4, No. 1, hal. 29-40.
- Sobie, S. R. dan Trevor Q. M. (2017). "High-Resolution Statistical Downscaling in Southwestern British Columbia.", *Journal of Climate*, Vol. 28, No. 17, hal. 1625–1641.
- van den Dool, H.M. (1994), "Searching for Analogues, How Long Must We Wait?", *TELLUS*, Vol. 46, hal. 314-324.
- van den Dool, H.M. (2003), "Performance dan Analysis of the Constructed Analogue Method Applied to U.S. Soil Moisture over 1981 – 2001.", *Journal of Geophysical Research*, Vol. 108, No. D16, hal. 1–16.
- Vimont, D.J., Battisti, D.S., dan Naylor, R.L. (2009), "Downscaling Indonesian Precipitation Using Large-scale Meteorological Fields", *International Journal of Climatology*, Vol 30, No. 11, hal. 1706-1722.
- Werner, A.T. dan Canon, A.J. (2016), "Hydrologic Extremes – an Intercomparison of Multiple Gridded Statistical Downscaling Methods.", *Hydrology and Earth System Sciences*, Vol 20, No. 4, hal 1483-1508.
- Wigena, A.H. (2006), *Pemodelan Statistical Downscaling Dengan Regresi Projection Pursuit Untuk Peramalan Curah Hujan Bulanan (Kasus Curah Hujan Bulanan Di Indramayu)*, Disertasi, Institut Pertanian Bogor, Bogor.
- Wilks, D.S. (2002), "Smoothing Forecast Ensembles with Truncated Probability Distributions.", *Q. J. R. Meteorol. Soc* Vol. 128, hal. 2821–2836.
- Wilks, D.S. (2015), "Multivariate Ensemble Model Output Statistics Using Empirical Copulas.", *Quarterly Journal of the Royal Meteorological Society*, Vol. 141 No. 688, hal. 945–52.
- Wood, A. W., Leung , L. R., Sridhar, V., dan Lettenmaier , D. P. (2004), "Hydrologic Implications of Dynamical and Statistical Approaches to Downscaling Climate Model Outputs.", *Climate Change*, Vol. 62, hal. 189–216.
- Zorita, E. (1995), "Stochastic Characterization of Regional Circulation Patterns for Climate Model Diagnosis and Estimation of Local Precipitation.", *Journal of Climate* Vol. 8, hal. 1023–1042.
- Zorita, E. dan Hans Von Storch. (1999). "The Analog Method as a Simple Statistical Downscaling Technique : Comparison with More Complicated Methods.", *Journal of Climate*, Vol. 12, hal 2474–2489.

## LAMPIRAN

### **Lampiran 1. Link Data Hasil *Downscaling* dan Bias Koreksi untuk Curah Hujan**

No	Hasil	Metode	Model	Link
1	<i>Historical</i>	BCCAQ	BNU-ESM	<a href="https://intip.in/9his">https://intip.in/9his</a>
			MIROC-ESM	<a href="https://intip.in/WzdR">https://intip.in/WzdR</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/bp2S">https://intip.in/bp2S</a>
		QDM	BNU-ESM	<a href="https://intip.in/6t5y">https://intip.in/6t5y</a>
			MIROC-ESM	<a href="https://intip.in/Ns5o">https://intip.in/Ns5o</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/S8Ju">https://intip.in/S8Ju</a>
		ISIMIP	BNU-ESM	<a href="https://intip.in/0JH4">https://intip.in/0JH4</a>
			MIROC-ESM	<a href="https://intip.in/fx9L">https://intip.in/fx9L</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/C400">https://intip.in/C400</a>
2	G4	ISIMIP	BNU-ESM	<a href="https://intip.in/RL22">https://intip.in/RL22</a>
			MIROC-ESM	<a href="https://intip.in/bR99">https://intip.in/bR99</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/rJi0">https://intip.in/rJi0</a>
3	RCP4.5	ISIMIP	BNU-ESM	<a href="https://intip.in/btrL">https://intip.in/btrL</a>
			MIROC-ESM	<a href="https://intip.in/nTBF">https://intip.in/nTBF</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/wHXD">https://intip.in/wHXD</a>
4	KORELASI	BCCAQ	BNU-ESM	<a href="https://intip.in/fdJz">https://intip.in/fdJz</a>
			MIROC-ESM	<a href="https://intip.in/iK28">https://intip.in/iK28</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/ijhM">https://intip.in/ijhM</a>
		QDM	BNU-ESM	<a href="https://intip.in/QOeE">https://intip.in/QOeE</a>
			MIROC-ESM	<a href="https://intip.in/X27A">https://intip.in/X27A</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/o7eT">https://intip.in/o7eT</a>
		ISIMIP	BNU-ESM	<a href="https://intip.in/xjGY">https://intip.in/xjGY</a>
			MIROC-ESM	<a href="https://intip.in/6chB">https://intip.in/6chB</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/wnQ4">https://intip.in/wnQ4</a>
5	RMSE	BCCAQ	BNU-ESM	<a href="https://intip.in/1M4r">https://intip.in/1M4r</a>
			MIROC-ESM	<a href="https://intip.in/NxBh">https://intip.in/NxBh</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/Jhm3">https://intip.in/Jhm3</a>
		QDM	BNU-ESM	<a href="https://intip.in/tGT8">https://intip.in/tGT8</a>
			MIROC-ESM	<a href="https://intip.in/YpMa">https://intip.in/YpMa</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/Z7Dk">https://intip.in/Z7Dk</a>
		ISIMIP	BNU-ESM	<a href="https://intip.in/L2Wb">https://intip.in/L2Wb</a>
			MIROC-ESM	<a href="https://intip.in/TO0t">https://intip.in/TO0t</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/RL22">https://intip.in/RL22</a>

**Lampiran 2.** Link Data Hasil *Downscaling* dan Bias Koreksi untuk Temperatur Maksimum

No	Hasil	Metode	Model	Link
1	<i>Historical</i>	BCCAQ	BNU-ESM	<a href="https://intip.in/SUWe">https://intip.in/SUWe</a>
			MIROC-ESM	<a href="https://intip.in/aatw">https://intip.in/aatw</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/36fz">https://intip.in/36fz</a>
		QDM	BNU-ESM	<a href="https://intip.in/cB9J">https://intip.in/cB9J</a>
			MIROC-ESM	<a href="https://intip.in/o5Tf">https://intip.in/o5Tf</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/Asnn">https://intip.in/Asnn</a>
		ISIMIP	BNU-ESM	<a href="https://intip.in/Nct4">https://intip.in/Nct4</a>
			MIROC-ESM	<a href="https://intip.in/Lo5d">https://intip.in/Lo5d</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/Yri1">https://intip.in/Yri1</a>
2	G4	ISIMIP	BNU-ESM	<a href="https://intip.in/XC86">https://intip.in/XC86</a>
			MIROC-ESM	<a href="https://intip.in/HKsw">https://intip.in/HKsw</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/tLNY">https://intip.in/tLNY</a>
3	RCP4.5	ISIMIP	BNU-ESM	<a href="https://intip.in/YzZH">https://intip.in/YzZH</a>
			MIROC-ESM	<a href="https://intip.in/ZFDi">https://intip.in/ZFDi</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/Oeey">https://intip.in/Oeey</a>
4	KORELASI	BCCAQ	BNU-ESM	<a href="https://intip.in/suy2">https://intip.in/suy2</a>
			MIROC-ESM	<a href="https://intip.in/Hano">https://intip.in/Hano</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/Jypq">https://intip.in/Jypq</a>
		QDM	BNU-ESM	<a href="https://intip.in/spQ6">https://intip.in/spQ6</a>
			MIROC-ESM	<a href="https://intip.in/Wio8">https://intip.in/Wio8</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/DDHR">https://intip.in/DDHR</a>
		ISIMIP	BNU-ESM	<a href="https://intip.in/8U85">https://intip.in/8U85</a>
			MIROC-ESM	<a href="https://intip.in/YoaE">https://intip.in/YoaE</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/U48s">https://intip.in/U48s</a>
5	RMSE	BCCAQ	BNU-ESM	<a href="https://intip.in/CcJb">https://intip.in/CcJb</a>
			MIROC-ESM	<a href="https://intip.in/0Aou">https://intip.in/0Aou</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/ej1U">https://intip.in/ej1U</a>
		QDM	BNU-ESM	<a href="https://intip.in/GDwc">https://intip.in/GDwc</a>
			MIROC-ESM	<a href="https://intip.in/wcuD">https://intip.in/wcuD</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/SCYa">https://intip.in/SCYa</a>
		ISIMIP	BNU-ESM	<a href="https://intip.in/FbOB">https://intip.in/FbOB</a>
			MIROC-ESM	<a href="https://intip.in/mJRS">https://intip.in/mJRS</a>
			MIROC-ESM-CHEM	<a href="https://intip.in/hN0Q">https://intip.in/hN0Q</a>

### Lampiran 3 Syntax Crop Data untuk Wilayah Indonesia

```
# -*- coding: utf-8 -*-

import numpy as np
from datetime import datetime
from netCDF4 import num2date, date2num
import glob
from netCDF4 import Dataset

variabel = 'pr'
model = 'MIROC-ESM'
exp = 'RCP45'

path = 'G:\\GEdata\\daily\\'+exp+'\\'+model+'\\'+variabel+'\\*r1i1p1*.nc' #isi lokasi data
dirs = glob.glob(str(path))

file = Dataset(dirs[0])

latbounds = [ -12 , 9 ] #Isi batas latitude
lonbounds = [ 93 , 145 ] #Isi batas longitude

##data logitude dan latitude
lats = file.variables['lat'][:]
lons = file.variables['lon'][:]

##indeks batas atas dan bawah latitude
latli = np.argmin( np.abs( lats - latbounds[0] ) )
latui = np.argmin( np.abs( lats - latbounds[1] ) )

##indeks batas atas dan bawah longitude
lonli = np.argmin( np.abs( lons - lonbounds[0] ) )
lonui = np.argmin( np.abs( lons - lonbounds[1] ) )

latitude = lats[latli:latui]
longitude = lons[lonli:lonui]

lbds = file.variables['lat_bnds'][:]
latbnds = lbds[latli:latui]

lnbds = file.variables['lon_bnds'][:]
lonbnds = lnbds[lonli:lonui]

tm = file.variables['time_bnds'][:]

##dd/mm/yyyy
time_comb = np.array(file.variables['time'][:])
```

### Lampiran 3. Syntax Crop Data untuk Wilayah Indonesia (Lanjutan)

```
##data
data_comb = np.array(file.variables['pr'][::], latli:latui , lonli:lonui ])*86400

#simpan data
x = dirs[0].split("\\")
name = x[4]

ncfile = Dataset('H:\\RCP45\\pr\\crop_pr_day_MIROC-ESM_rcp45_r1i1p1_20060101-
21001231.nc',mode='w',format='NETCDF4_CLASSIC')

##keterangan
lat_dim = ncf.createDimension('lat', len(latitude)) # latitude axis
lon_dim = ncf.createDimension('lon', len(longitude)) # longitude axis
nb2_dim = ncf.createDimension('bnds', 2)
time_dim = ncf.createDimension('time', None) #4 unlimited axis (can be appended to).
for dim in ncf.dimensions.items():
    print(dim)

##global atribut
ncfile.title ='MIROC-ESM model output prepared for GeoMIP RCP4.5 2020-2069 and 5Tg SO2
injection per yr'
ncfile.institution_id = 'MIROC'
ncfile.experiment_id = exp
ncfile.frequency = 'day'

#lat information
lat = ncf.createVariable('lat', np.float64, ('lat',))
lat.standard_name='latitude'
lat.long_name = 'latitude'
lat.units = 'degrees_north'
lat.axis='Y'
lat.bounds='lat_bnds'
lat_bnds=ncf.createVariable('lat_bnds', np.float64, ('lat','bnds'))

#lon information
lon = ncf.createVariable('lon', np.float64, ('lon',))
lon.standard_name='longitude'
lon.long_name='longitude'
lon.units = 'degrees_east'
lon.axis='X'
lon.bnds='lon_bnds'
lon_bnds=ncf.createVariable('lon_bnds', np.float64, ('lon','bnds'))

#time information
times = ncf.createVariable("time", "f8",("time",), chunksizes=(1,))
times.long_name = 'time'
times.units = 'days since 2006-1-1'
times.standard_name='time'
times.bounds='time_bnds'
times.calendar='gregorian'
```

### Lampiran 3. Syntax Crop Data untuk Wilayah Indonesia (Lanjutan)

```
times.long_name = 'time'
times.axis = 'T'
time_bnds=ncfile.createVariable('time_bnds', np.float64,('time','bnds'))
time_bnds.units='days since 2006-1-1'
time_bnds.calendar='gregorian'

#pr information
pr = ncf.createVariable('pr',np.float32,'time','lat','lon'),fill_value=1.0E20) # note: unlimited
dimension is leftmost
pr.standard_name = 'precipitation_flux' # this is a CF standard name
pr.long_name='Precipitation'
pr.units = 'kg m-2 s-1' # degrees Kelvin
pr.original_name = 'PRCP'
pr.original_units = 'kg/m**2/s'
pr.cell_methods = 'time: mean'
pr.cell_measures = 'area: areacella'
pr.history="2011-10-04T11:32:54z altered by CMOR: Treated scalar dimension: \height\."
pr.FillValue = "1.0E20f; // float"
pr.associated_files="baseURL: http://cmip-pcmdi.llnl.gov/GeoMIP/dataLocation gridspecFile:
gridspec_atmos_fx_MIROC-ESM_historical_r0i0p0.nc areacella: areacella_fx_MIROC-
ESM_historical_r0i0p0.nc"

#print(temp)
print("-- Some pre-defined attributes for variable temp:")
print("pr.dimensions:", pr.dimensions)
print("pr.shape:", pr.shape)
print("pr.dtype:", pr.dtype)
print("pr.ndim:", pr.ndim)

lat[:] = latitude
lon[:] = longitude
lat_bnds[:] = latbnds
lon_bnds[:]= lonbnds
time_bnds[:] = tm

pr[:,::,:] = data_comb # Appends data along unlimited dimension
times[:] = time_comb
times_arr = times[:]
print(type(times_arr),times_arr)

dates = []
for n in range (pr.shape[0]):
    # nasty fix for the fact that datetime.timedelta only works on 365 day calendar
    new_date = date2num(datetime(2006,1,1), units=times.units, calendar=times.calendar)+n*1
    dates.append(num2date(new_date, units=times.units, calendar=times.calendar))

times[:] = date2num(dates, units=times.units, calendar=times.calendar)

print('time values (in units %s): ' % times.units+'\n',times[:])
```

### Lampiran 3. Syntax Crop Data untuk Wilayah Indonesia (Lanjutan)

```
#print(times, times.units) # numeric values
# first print the Dataset object to see what we've got
print(ncfile)
# close the Dataset.
ncfile.close(); print('Dataset is closed!')
```

### Lampiran 4. Syntax Menggabungkan File NetCDF

```
import netCDF4
import numpy as np
import pandas as pd
from netCDF4 import Dataset
ncfile = netCDF4.Dataset('E:/ecmwf indonesia/tasmax
ecmwf/tahun/tasmax_ECMWF_d.nc',mode='w',format='NETCDF4_CLASSIC')
print(ncfile)
lat_dim = ncf.createDimension('lat', 69) # latitude axis
lon_dim = ncf.createDimension('lon', 186) # longitude axis
time_dim = ncf.createDimension('time', None) #4 unlimited axis (can be appended to).
for dim in ncf.dimensions.items():
    print(dim)
    ncf.title='Data ECMWF 0.25 Indonesia'
    print(ncf.title)
    ncf.subtitle="Temperatur maksimum"
    ncf.anything="nc file of Indonesia"
    print(ncf.subtitle)
    print(ncf)
    print(ncf.anything)
    lat = ncf.createVariable('lat', np.float64, ('lat',))
    lat.standard_name='latitude'
    lat.long_name = 'latitude'
    lat.units = 'degrees_north'
    lat.axis='Y'
    lon = ncf.createVariable('lon', np.float64, ('lon',))
    lon.standard_name='longitude'
    lon.long_name='longitude'
    lon.units = 'degrees_east'
    lon.axis='X'
    times = ncf.createVariable("time","f8",("time",), chunksizes=(1,))
    #time = ncf.createVariable('time', np.float64, ('time',))
    times.long_name = 'time'
    times.units = 'hours since 1900-01-01 00:00:00'
    times.standard_name='time'
    times.calendar='gregorian'
    times.long_name = 'time'
    tasmax = ncf.createVariable('tasmax',np.float32,('time','lat','lon'),fill_value=-32767) # note:
    #unlimited dimension is leftmost
    tasmax.standard_name = 'Temperatur maksimum'
    tasmax.long_name='Temperatur maksimum'
```

#### Lampiran 4. Syntax Menggabungkan File NetCDF (Lanjutan)

```
tasmax.units = 'K'  
#pr.cell_methods = "time: maksimal"  
#print(temp)  
print("-- Some pre-defined attributes for variable temp:")  
print("tasmax.dimensions:", tasmax.dimensions)  
print("tasmax.shape:", tasmax.shape)  
print("tasmax.dtype:", tasmax.dtype)  
print("tasmax.ndim:", tasmax.ndim)  
nlats = len(lat_dim); nlons = len(lon_dim); ntimes = 366  
#lat[:] = np.arange(68.12,70.21,0.083)  
#lon [:]= np.arange(-93.04,-90.96,0.083)  
#lat[:] = np.arange(68.12,70.21,0.083)  
#lon [:]= np.arange(-93.04,-90.96,0.083)  
  
tahun_1= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1979.nc','r')  
tahun_2= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1980.nc','r')  
tahun_3= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1981.nc','r')  
tahun_4= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1982.nc','r')  
tahun_5= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1983.nc','r')  
tahun_6= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1984.nc','r')  
tahun_7= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1985.nc','r')  
tahun_8= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1986.nc','r')  
tahun_9= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1987.nc','r')  
tahun_10= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1988.nc','r')  
tahun_11= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1989.nc','r')  
tahun_12= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1990.nc','r')  
tahun_13= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1991.nc','r')  
tahun_14= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1992.nc','r')  
tahun_15= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1993.nc','r')  
tahun_16= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1994.nc','r')  
tahun_17= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1995.nc','r')  
tahun_18= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1996.nc','r')  
tahun_19= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1997.nc','r')  
tahun_20= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1998.nc','r')  
tahun_21= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_1999.nc','r')  
tahun_22= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_2000.nc','r')  
tahun_23= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_2001.nc','r')  
tahun_24= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_2002.nc','r')  
tahun_25= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_2003.nc','r')  
tahun_26= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_2004.nc','r')  
tahun_27= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_2005.nc','r')  
tahun_28= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_2006.nc','r')  
tahun_29= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_2007.nc','r')  
tahun_30= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_2008.nc','r')  
tahun_31= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_2009.nc','r')  
tahun_32= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_2010.nc','r')  
tahun_33= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_2011.nc','r')  
tahun_34= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_2012.nc','r')  
tahun_35= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_2013.nc','r')
```

#### Lampiran 4. Syntax Menggabungkan file NetCDF (Lanjutan)

```
tahun_36= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_2014.nc','r')
tahun_37= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_2015.nc','r')
tahun_38= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_2016.nc','r')
tahun_39= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_2017.nc','r')
tahun_40= Dataset('E:\\ecmwf indonesia\\tasmax ecmwf\\tahun\\tahun_2018.nc','r')

a = np.array(tahun_1.variables['tasmax'])
b = np.array(tahun_2.variables['tasmax'])
c = np.array(tahun_3.variables['tasmax'])
d = np.array(tahun_4.variables['tasmax'])
e = np.array(tahun_5.variables['tasmax'])
f = np.array(tahun_6.variables['tasmax'])
g = np.array(tahun_7.variables['tasmax'])
h = np.array(tahun_8.variables['tasmax'])
i = np.array(tahun_9.variables['tasmax'])
j = np.array(tahun_10.variables['tasmax'])
k = np.array(tahun_11.variables['tasmax'])
l = np.array(tahun_12.variables['tasmax'])
m = np.array(tahun_13.variables['tasmax'])
n = np.array(tahun_14.variables['tasmax'])
o = np.array(tahun_15.variables['tasmax'])
p = np.array(tahun_16.variables['tasmax'])
q = np.array(tahun_17.variables['tasmax'])
r = np.array(tahun_18.variables['tasmax'])
s = np.array(tahun_19.variables['tasmax'])
t = np.array(tahun_20.variables['tasmax'])
u = np.array(tahun_21.variables['tasmax'])
v = np.array(tahun_22.variables['tasmax'])
w = np.array(tahun_23.variables['tasmax'])
x = np.array(tahun_24.variables['tasmax'])
y = np.array(tahun_25.variables['tasmax'])
z = np.array(tahun_26.variables['tasmax'])
aa = np.array(tahun_27.variables['tasmax'])
ab = np.array(tahun_28.variables['tasmax'])
ac = np.array(tahun_29.variables['tasmax'])
ad = np.array(tahun_30.variables['tasmax'])
ae = np.array(tahun_31.variables['tasmax'])
af = np.array(tahun_32.variables['tasmax'])
ag = np.array(tahun_33.variables['tasmax'])
ah = np.array(tahun_34.variables['tasmax'])
ai = np.array(tahun_35.variables['tasmax'])
aj = np.array(tahun_36.variables['tasmax'])
ak = np.array(tahun_37.variables['tasmax'])
al = np.array(tahun_38.variables['tasmax'])
am = np.array(tahun_39.variables['tasmax'])
an = np.array(tahun_40.variables['tasmax'])
```

#### Lampiran 4. Syntax Menggabungkan File NetCDF (Lanjutan)

```
data_arr=np.concatenate((a,b,c,d,e,f,g,h,i,j,k,l,m,n,o,p,q,r,s,t,u,v,w,x,y,z,aa,ab,ac,ad,ae,af,ag,ah,ai,a
j,ak,al,am,an))
lat[:] = sorted (tahun_1.variables['lat'][:])
lon [:]= tahun_1.variables['lon'][:]
#data_arr = np.random.uniform(low=-30,high=-31,size=(ntimes,nlats,nlons))
tasmax[:,::] = data_arr # Appends data along unlimited dimension
#print("-- Wrote data, temp.shape is now ", temp.shape)
#print("-- Min/Max values:", temp[:,::].min(), temp[:,::].max())
#data_slice = np.random.uniform(low=280,high=330,size=(nlats,nlons))
#temp[3,:,:] = data_slice
#print("-- Wrote more data, temp.shape is now ", temp.shape)
#print(time)
times_arr = times[:,]
print(type(times_arr),times_arr)
#import datetime as dt
#from netCDF4 import date2num,num2date
from datetime import datetime, timedelta
from netCDF4 import num2date, date2num
dates = [datetime(1979,1,1)+n*timedelta(hours=24) for n in range(tasmax.shape[0])]
times[:,] = date2num(dates,units=times.units,calendar=times.calendar)
#dates =
[dt.datetime(2014,10,1,0),dt.datetime(2014,10,2,0),dt.datetime(2014,10,3,0),dt.datetime(2014,10,4,0)]
print(dates)
times = date2num(dates, times.units)
#print(times, times.units) # numeric values
# first print the Dataset object to see what we've got
print(ncfile)
# close the Dataset.
ncfile.close(); print('Dataset is closed!')
```

#### Lampiran 5. Syntax Downscaling dan Koreksi Bias Menggunakan QDM dan BCCAQ

```
library(ClimDown)
#pr
memory.limit()
#memory.limit(size=56000)
#QDM
ci.file <- tempfile(fileext='.nc')
ClimDown::ci.netcdf.wrapper('D:/tesis/historical/historical-bnu-esm.nc', 'D:/tesis
/ECMWF/EMCWF_precip.nc', ci.file , 'pr')
out.nc <- tempfile(fileext='.nc')
options(
  calibration.start = as.POSIXct('1984-1-1', tz='GMT'),
  calibration.end=as.POSIXct('2004-12-31', tz='GMT'))
ClimDown::qdm.netcdf.wrapper('D:/tesis /ECMWF/EMCWF_precip.nc', ci.file, out.file =
"D:/tesis/historical/historical-bnu-esm_qdm.nc ", 'pr')
unlink(ci.file)
```

## Lampiran 5 Syntax Downscaling dan Koreksi Bias Menggunakan QDM dan BCCAQ (Lanjutan)

```
unlink(out.nc)
#BCCAQ
out.nc <- tempfile(fileext='.nc')
options(
  calibration.start = as.POSIXct('1990-1-1', tz='GMT'),
  calibration.end=as.POSIXct('2004-12-31', tz='GMT'))

ClimDown::bccaq.netcdf.wrapper('D:/tesis/historical/historical-bnu-esm.nc ', 'D:/tesis
/ECMWF/EMCWF_precip.nc ', out.file = "D:/tesis/historical/historical-bnu-esm_bccaq.nc ", 'pr')
unlink(out.nc)
```

## Lampiran 6. Syntax ISIMIP

```
clc
clear all

gcm = csvread('C:\Users\B\Decimals\Ecmwf\pr_day_BNU-ESM_historical_r1i1p1_19500101-
20051231_mm.csv');
obs = csvread('C:\Users\B\Decimals\Ecmwf\precip_ECMWF_flip_24.csv');

date_gcm = [datenum('01-Jan-1950'):datenum('31-Dec-2005')];
%merra noleap & 365days
date_gcm(month(date_gcm)==2 & day(date_gcm)==29) = [];
date_gcm=datenum(date_gcm);

date_obs = [datenum('01-Jan-1979'):datenum('31-Dec-2018')];
%merra noleap & 365days
no_leap =[datetime('01-Jan-1979'):datetime('31-Dec-2018')];
no_leap(month(no_leap)==2 & day(no_leap)==29) = [];
no_leap=datenum(no_leap);

[C,ia,ib] = intersect(date_obs,no_leap);
obs = obs(ia,:);
date_obs = no_leap;

obs_new = [date_obs,obs];

[C,ia,ib] = intersect(date_gcm,date_obs);
observ = obs_new(1:length(C),:);
missing = nan((length(date_gcm)-length(observ(:,1))),length(observ(1,:))-1);
observation = (observ(:,2:length(observ(1,:))));
```

## Lampiran 6. Syntax ISIMIP (Lanjutan)

```
fix = [missing;observation];
%%%%%isimip%%%%%isimip%%%%%isimip%%%%%isimip%%%%%
cd 'H:\MLToolbox_R2013\MeteoLab'
init

datesCTL=date_gcm;
obsDates=date_gcm;

SIM1=isimip(fix(:,1:2000),gcm(:,1:2000),gcm(:,1:2000),'datesobs','obsDates','datesfor','datesCTL','threshold',0.5,'variable','precipitation');
SIM2=isimip(fix(:,2001:4000),gcm(:,2001:4000),gcm(:,2001:4000),'datesobs','obsDates','datesfor','datesCTL','threshold',0.5,'variable','precipitation');
SIM3=isimip(fix(:,4001:6000),gcm(:,4001:6000),gcm(:,4001:6000),'datesobs','obsDates','datesfor','datesCTL','threshold',0.5,'variable','precipitation');
SIM4=isimip(fix(:,6001:8000),gcm(:,6001:8000),gcm(:,6001:8000),'datesobs','obsDates','datesfor','datesCTL','threshold',0.5,'variable','precipitation');
SIM5=isimip(fix(:,8001:10000),gcm(:,8001:10000),gcm(:,8001:10000),'datesobs','obsDates','datesfor','datesCTL','threshold',0.5,'variable','precipitation');
SIM6=isimip(fix(:,10001:12000),gcm(:,10001:12000),gcm(:,10001:12000),'datesobs','obsDates','datesfor','datesCTL','threshold',0.5,'variable','precipitation');
SIM7=isimip(fix(:,12001:12834),gcm(:,12001:12834),gcm(:,12001:12834),'datesobs','obsDates','datesfor','datesCTL','threshold',0.5,'variable','precipitation');

SIMprojCTL_isimip = [SIM1,SIM2,SIM3,SIM4,SIM5,SIM6,SIM7];
csvwrite('C:\Users\B\Decimals\Ecmwf\result_isimip\pr_day_BNU-ESM_historical_r1i1p1_19500101-20051231.csv',SIMprojCTL_isimip)

#untuk model yang lainnya hanya mengganti pada bagian periode data,
#sedangkan untuk temperatur hanya mengganti pada fungsi isimip dengan #'temparature'
```

## Lampiran 7. Syntax convert NetCDF ke excel (.csv)

```
memory.limit()
memory.limit(size=5600000000)
library(ncdf4)
setwd("I:\\ECMWF\\")
nc = nc_open("tasmax_ECMWF_degC_flip.nc")      #open ncdf dan read variables
lon = ncvar_get(nc,"lon")           # Lon lat dan time
lat = ncvar_get(nc,"lat")
time = ncvar_get(nc, "time")
```

### Lampiran 7. Syntax Convert NetCDF ke Excel (.csv) (Lanjutan)

```
dname = "tasmax" #nama variabel
var = ncvar_get(nc,dname)
lonlat = as.matrix(expand.grid(lat,lon))
a=data.frame()
for(i in 1:length(time))
{
  a=rbind(a,as.vector((var[,i])))
}

csvpath = "I:\\ECMWF\\\" #alamat simpan
csvname = "tasmax_ECMWF_degC_flip_2019_2.csv" #nama file outputnya
csvfile = paste(csvpath, csvname, sep="")
write.table(na.omit(a),csvfile, row.names=FALSE, sep=",", col.names = FALSE)
```

### Lampiran 8. Syntax Korelasi dan RMSE untuk Peta

```
#HITUNG KORELASI
bias=read.csv("H:/isimip/tasmax_MIROC-ESM-CHEM_ISIMIP.csv", header= F)
bias=bias[47117:56978,]
obs=read.csv("H:/ECMWF/tasmax_ECMWF_degC_flip.csv")
biasm=as.vector(bias)
obsm=as.vector(obs)

a=rbind()
for (i in 1:12834){

  a=rbind(a,cor.test(biasm[i],obsm[i])$estimate)
}
korlasi=a

csvpath = "H:\\\" #alamat simpan
csvname = "korelasi_tasmax_MIROC-ESM-CHEM_ISIMIP.csv" #nama file outputnya
csvfile = paste(csvpath, csvname, sep="")
write.table(na.omit(korlasi),csvfile, row.names=FALSE, sep=",")

#menghitung bias
library(Metrics)
d=rbind()
for (i in 1:12834){
  d=rbind(d,rmse(obs[,i],bias[,i]))
}
```

### Lampiran 8. Syntax Korelasi dan RMSE untuk peta

```
rmse=d
csvpathbiasall = "H:\\\" #alamat simpan
csvnamebiasall = "rmse_tasmax_MIROC-ESM-CHEM_ISIMIP.csv" #nama file outputnya
csvfilebiasall= paste(csvpathbiasall, csvnamebiasall, sep="")
write.table(na.omit(rmse),csvfilebiasall, row.names=FALSE, sep=",")
```

### Lampiran 9. Syntax Taylor Diagram

```
library(PCICt)
library(openair)
library(lubridate)
memory.limit()
memory.limit(size=56000000000)

#ecmwf filter

ecmwf = read.csv("I:/pr/precip_ECMWF_flip_24.csv",header = T)
ecmwf=ecmwf[-c(425,1886,3347,4808,6269,7730,9191,)]
data_ecmwf=ecmwf

#bccaq filter
#bccaq1 = read.csv("H:/pr/New_pr_day_MIROC-ESM_BCCAQ_baru_2.csv",header=F)
bccaq2= read.csv("I:/pr/pr_day__BNU-ESM_BCCAQ_flip.csv")

#bccaq3=bccaq1[-c(1),]
bccaq4=bccaq2[-c(1),]
data_bccaq = bccaq2

#qdm filter
#qdm1 = read.csv("H:/pr/New_pr_day_MIROC-ESM_QDM_baru_2.csv",header=F)
qdm2= read.csv("I:/pr/pr_day__BNU-ESM_QDM_flip.csv")
#qdm3=qdm1[-c(1),]
qdm4=qdm2[-c(1),]
data_qdm = qdm2

#isimip
isimip=read.csv("I:/tesis/PR_BNU-ESM_ISIMIP_4.csv", header=F)
#isimip2=read.csv("H:/tasmax_BNU-ESM_ISIMIP.csv", header=F)
data_isimip= isimip[10586:20440,]

w = rowMeans(data_ecmwf)
x= rowMeans(data_isimip)
y = rowMeans(data_bccaq)
z = rowMeans(data_qdm)

model1 = sample(c("ISIMIP"),length(y),replace = TRUE)
```

### Lampiran 9. Syntax Taylor Diagram (Lanjutan)

```
model2 = sample(c("BCCAQ"),length(y),replace = TRUE)
model3 = sample(c("QDM"),length(y),replace = TRUE)

mod1 = cbind.data.frame(w,x,model1)
colnames(mod1)=c("obs","mod","model")
mod2 = cbind.data.frame(w,y,model2)
colnames(mod2)=c("obs","mod","model")
mod3 = cbind.data.frame(w,z,model3)
colnames(mod3)=c("obs","mod","model")

mod.dat = rbind(mod1,mod2,mod3)

png(filename="I:/BNU-ESM_pr_tahun_threshold_1.png")
TaylorDiagram(mod.dat, obs = "obs", mod = "mod", group = "model")
dev.off()

#png(filename="E:/Decimals/taylordiagram/bnu-esm_tas_season.png")
#TaylorDiagram(mod.dat, obs = "obs", mod = "mod", group = "model", type = "season")
#dev.off()

#noleap date generate
cal <- "noleap"
origin = "1979-01-01"
seconds.per.day = 86400
ts.dat.days = 0:9854
origin.pcict = as.POSIXct(origin, cal)
ts.dat.pcict = origin.pcict + (ts.dat.days * seconds.per.day)

dateuse = data.frame(as.Date(as.character(ts.dat.pcict)))
month = data.frame(month(as.POSIXlt(ts.dat.pcict, format="%d/%m/%Y")))

mod4 = cbind.data.frame(dateuse,w,x,month,model1)
colnames(mod4)=c("date","obs","mod","month","model")
mod5 = cbind.data.frame(dateuse,w,y,month,model2)
colnames(mod5)=c("date","obs","mod","month","model")
mod6 = cbind.data.frame(dateuse,w,z,month,model3)
colnames(mod6)=c("date","obs","mod","month","model")

mod.dat = rbind(mod4,mod5,mod6)

png(filename="H:/BNU-ESM_pr_season.png")
TaylorDiagram(mod.dat, obs = "obs", mod = "mod", group = "model", type = "season")
dev.off()
```

## Lampiran 10. Syntax Fungsi *creat map* (Membuat Peta)

```
function [] = createMap(data01,xlon1,ylat1,variable)
figure1 = figure('Position',(get(0,'Screensize')));
F = getframe(figure1);
load('indobound.mat')

xlon    = 95:2.8/10:141.25;
ylat    = -11:2.8/10:6.9765;
[LON1,LAT1] = meshgrid(xlon1,ylat1);
[LON,LAT] = meshgrid(xlon,ylat);
outData = interp2(LON1,LAT1, data01, LON,LAT, 'linear');

%imagesc(outData);
pcolor(LON,LAT,outData); view([0 90]); shading flat;
grid on;

hold on;
plot(indobound(:,1),indobound(:,2),'color','black');
axis equal; axis([95 141 -11 6]);
xlabel('Longitude (degree)', 'fontsize',10); %label pada sumbu x
ylabel('Latitude (degree)', 'fontsize',10); %label pada sumbu y
%color = othercolor('BuOr_12',22);
color = othercolor('BuOrR_14',22);
colormap(color);
shading interp;

c = colorbar;

c.Location = 'southoutside';
ax = gca;
axpos = ax.Position;
c.Position(4) = 1*c.Position(4);
ax.Position = axpos;

variable = variable;
if variable == 0
    caxis([1 15]) %limit axis (upper lower)
else
    caxis([20 30]) %limit axis (upper lower)
end

drawnow;
end
```

### Lampiran 11. Syntax Fungsi IndonesianMap

```
function [] = IndonesianMap(latitude,longitude,data_selected,bias)

bias = bias;
map = [latitude;longitude;data_selected]';
r=zeros(length(unique(longitude)),1);
for i = unique(latitude)
    rr = map(map(:,1)==i,:);
    r = [r,rr(:,3)];
end
r=r(:,2:size(r,2));

% membuat map
createMap(r',unique(longitude),unique(latitude),bias)
end
```

### Lampiran 12. Syntax Fungsi Map

```
clc
clear all
data = csvread('D:\map_d\SEBELUM DOWNSCALE\TASMAX\maps_QDM_MIROC-
ESM_tasmax.csv');

%latlon = csvread('E:\Decimals\GeData\csv\BNU-ESM\pr\latlon_pr_day_BNU-
%ESM_historical_r1i1p1_19500101-20051231.csv');
%rata = mean(data-273.15);
%rata = mean(data*86400);

cd 'D:\map_d\geData'
IndonesianMap(data(:,1)',data(:,2)',data(:,3)',1);
```

### Lampiran 13. Surat Ijin Penggunaan Data

#### SURAT PERNYATAAN

Saya yang bertanda tangan dibawah ini, mahasiswa Departemen Statistika FMKSD ITS.

Nama : Fatkhurokhman Fauzi  
NRP : 06211750012006  
Program : Magister

Menyatakan bahwa data yang digunakan dalam Tesis ini merupakan data sekunder yang diambil dari publikasi lainnya yaitu:

Sumber:

1. <https://esgf-node.ipsl.upmc.fr/projects/esgf-ipsl/>
2. <https://apps.ecmwf.int>

Keterangan:

1. Data Skenario Historical model BNU-ESM tahun 1950-2005, model MIROC-ESM tahun 1850-2005, dan MIROC-ESM-CHEM tahun 1850-2005. Skenario G4 model BNU-ESM tahun 2006-2100, MIROC-ESM 2006-2090, dan model MIROC-ESM-CHEM tahun 2006-2090. Skenario RCP4.5 model BNU-ESM tahun 2006-2100, MIROC-ESM 2006-2100, dan model MIROC-ESM-CHEM tahun 2006-2100.
2. Data reanalysis ERA-Interim

Surat ini dibuat dengan sebenar-benarnya. Apabila ada pemalsuan data maka saya siap menerima sanksi dengan aturan yang berlaku.

Surabaya, 29 Januari 2020

Mahasiswa

  
Fatkhurokhman Fauzi

NRP. 06211750012006

Mengetahui

Pembimbing I



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

Pembimbing II



R. Mohamad Atok, M.Si., Ph.D.  
NIP: 19710915 199702 1 001

*(Halaman ini sengaja dikosongkan)*

## **BIODATA PENULIS**



Penulis bernama lengkap Fatkhurokhman Fauzi, lahir pada tanggal 20 Juli 1995 di Purbalingga. Penulis merupakan anak pertama dari tiga bersaudara dari Masturi dan Khuripah. Penulis telah menempuh pendidikan formal di TK Pertiwi Karanggedang (2000-2001). SD Negeri 1 Karanggedang (2001-2007). SMP Negeri 1 Bobotsari (2008-2010). SMA Negeri 1 Bobotsari (2011-2013). Diploma III Statistika Universitas Negeri Semarang (2014-2016). Pada tahun 2016 akhir penulis melanjutkan studi jenjang Sarjana di jurusan Statistika FMIPA Universitas Muhammadiyah Semarang, Kemudian kemudian pada tahun 2017 semester genap penulis melanjutkan studi pada program Magister Statistika FMKSD-ITS. Penulis menyadari masih banyak kesalahan dan kekurangan dalam laporan Tesis ini, bagi pembaca yang memiliki kritik, saran, dan ingin berdiskusi lebih lanjut tentang Tesis ini bisa menghubungi penulis melalui email fatkhurokhmanfauzi@gmail.com.