



TUGAS AKHIR – SS141501

**PERBANDINGAN BIAS KOREKSI *BAYESIAN*
MODEL AVERAGING DENGAN *ENSEMBLE MODEL*
OUTPUT STATISTICS PADA DATA *NUMERICAL*
WEATHER PREDICTION DALAM *MONITORING*
POLA KEKERINGAN DI PROVINSI NUSA
TENGGARA TIMUR**

**DIMAS RAHADIYUZA
NRP. 1313 100 122**

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

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017**



TUGAS AKHIR – SS141501

PERBANDINGAN BIAS KOREKSI *BAYESIAN MODEL AVERAGING* DENGAN *ENSEMBLE MODEL OUTPUT STATISTICS* PADA DATA *NUMERICAL WEATHER PREDICTION* DALAM *MONITORING* POLA KEKERINGAN DI PROVINSI NUSA TENGGARA TIMUR

**DIMAS RAHADIYUZA
NRP. 1313 100 122**

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

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017**



FINAL PROJECT – SS141501

**BIAS CORRECTION COMPARISON BETWEEN
BAYESIAN MODEL AVERAGING AND
ENSEMBLE MODEL OUTPUT STATISTICS IN
NUMERICAL WEATHER PREDICTION DATA TO
MONITORING DROUGHT PATTERN IN EAST
NUSA TENGGARA**

**DIMAS RAHADIYUZA
NRP. 1313 100 122**

**Supervisor
Dr. rer. pol. Heri Kuswanto, M.Si**

**UNDERGRADUATE PROGRAMME
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS AND NATURAL SCIENCES
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017**

LEMBAR PENGESAHAN

**PERBANDINGAN BIAS KOREKSI *BAYESIAN*
MODEL *AVERAGING* DENGAN *ENSEMBLE*
MODEL *OUTPUT STATISTICS* PADA DATA
NUMERICAL WEATHER PREDICTION DALAM
MONITORING POLA KEKERINGAN DI
PROVINSI NUSA TENGGARA TIMUR**

TUGAS AKHIR

Diajukan Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Sains
pada

Program Studi Sarjana Departemen Statistika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember

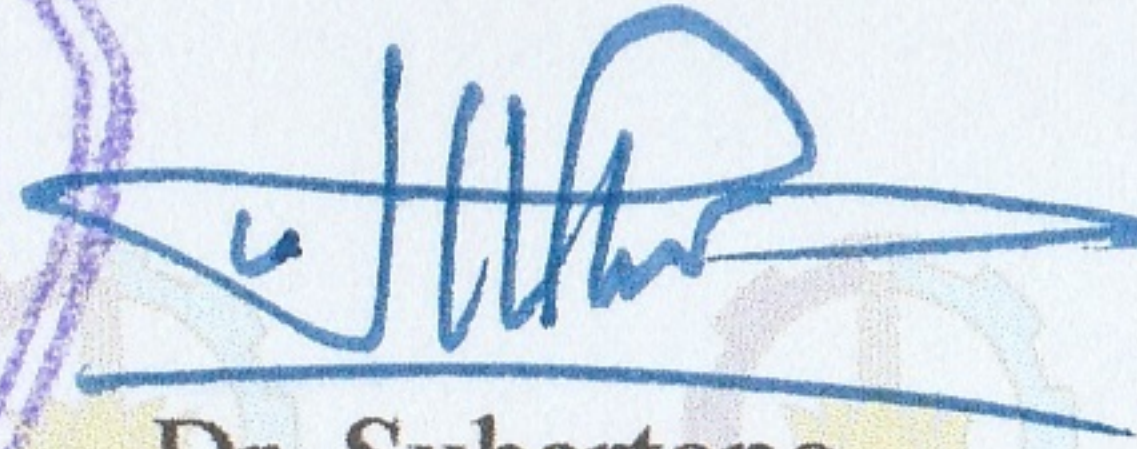
Oleh :

Dimas Rahadiyuza
NRP. 1313 100 122

Disetujui oleh Pembimbing:

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

Mengetahui,
Kepala Departemen


Dr. Suhartono

NIP. 19710929 199512 1 001

SURABAYA, JULI 2017

**PERBANDINGAN BIAS KOREKSI BAYESIAN
MODEL AVERAGING DENGAN ENSEMBLE MODEL
OUTPUT STATISTICS PADA DATA NUMERICAL
WEATHER PREDICTION DALAM MONITORING
POLA KEKERINGAN DI NUSA TENGGARA TIMUR**

Nama Mahasiswa : Dimas Rahadiyuza

NRP : 1313 100 122

Jurusan : Statistika

Dosen Pembimbing: Dr. rer. pol. Heri Kuswanto

Abstrak

Kekeringan adalah fenomena alam yang kerap menimbulkan dampak kerugian yang cukup besar. Provinsi Nusa Tenggara Timur adalah salah satu Provinsi di Indonesia dengan dampak kekeringan yang signifikan di Indonesia, dimana dampak yang paling terlihat dari kekeringan di provinsi ini mengakibatkan berkurangnya kebutuhan harian akan konsumsi air bersih dan gagalnya panen pada lebih dari 20 kabupaten . Untuk mendeteksi adanya kekeringan, dilakukan peramalan curah hujan secara berkala sebagai antisipasi akan datangnya bencana kekeringan. Dalam meramalkan curah hujan, banyak model yang digunakan dalam meramalkan pola kekeringan di suatu daerah. Akan tetapi sering kali model-model tersebut bias, sehingga menyebabkan kualitas peramalan yang kurang baik. Metode kalibrasi adalah metode yang tepat untuk melakukan penggabungan beberapa model peramalan sehingga dihasilkan satu output model yang lebih reliabel. Pada tahap kalibrasi akan dilakukan dua metode kalibrasi, yaitu menggunakan Bayesian Model Averaging dan Ensemble Model Output Statistics. Adapun dari kedua metode tersebut nantinya akan dilakukan pemilihan metode terbaik yang kemudian digunakan untuk meramalkan curah hujan sehingga dapat dilakukan pemetaan terkait antisipasi datangnya bencana kekeringan. Dari hasil kalibrasi, didapatkan kesimpulan bahwa peramalan terkalibrasi curah hujan di Provinsi Nusa Tenggara Timur menggunakan Bayesian Model Averaging terbukti menghasilkan kualitas peramalan yang lebih baik. Adapun dalam pemetaan pola kekeringan menggunakan model peramalan terkalibrasi, diketahui bahwa hasil pemetaan menggunakan lead time ke-1 tidak mendeteksi

adanya indikasi kekeringan, sementara pada pemetaan menggunakan lead ke-4 ditemukan indikasi kekeringan di setiap periode peramalan dengan puncak kekeringan terbesar terjadi pada April 2017.

Kata Kunci : Bayesian Model Averaging, Ensemble Model Output Statistics, Kalibrasi, Kekeringan, Nusa Tenggara Timur

BIAS CORRECTION COMPARISON BETWEEN BAYESIAN MODEL AVERAGING AND ENSEMBLE MODEL OUTPUT STATISTICS IN NUMERICAL WEATHER PREDICTION DATA TO MONITORING DROUGHT PATTERN IN EAST NUSA TENGGARA

Name : Dimas Rahadiyuza
NRP : 1313 100 122
Department : Statistics
Supervisor : Dr. rer. pol. Heri Kuswanto

Abstract

Drought is a natural phenomenon that frequently causes a lot of disadvantage in a big scale. East Nusa Tenggara is one of Province in Indonesia with most devastating damage caused by drought, where the most visible impact to be seen are in the lessening of daily needs for water and crop failure phenomenon in more than 20 districts along the province . To detect this phenomenon, rainfall forecasting is one of the obvious actions to anticipate drought. A lot of forecast models have been published to detect drought itself. However, the models tend to be biases, which caused the poor forecast quality. One of the methods offered to overcome it is by using ensemble forecast calibration. Bayesian Model Averaging and Ensemble Model Output Statistics is the method that will be used for calibrate forecast model ensembles. From the analysis, it is known that Bayesian Model Averaging has given a better quality of the forecast model ensembles. It is also known based on mapping process using the chosen calibration method, which is by using Bayesian Model Averaging at lead time 1, there are no sign which indicates drought phenomenon. However, when mapping process turns at lead time 4, it is known that drought phenomenon has been indicated in almost every period of mapping process. The peak of drought phenomenon happened based on mapping process in April 2017, where the entire region of East Nusa Tenggara experienced drought phenomenon in a large scale.

Keywords: Bayesian Model Averaging, Ensemble Model Output Statistics, Calibration, Drought, East Nusa Tenggara

(halaman ini sengaja dikosongkan)

KATA PENGANTAR

Puji syukur kehadirat Allah SWT, Tuhan Yang Maha Esa. Berkat rahmat dan ridho-Nya penulis dapat menyelesaikan laporan Tugas Akhir yang berjudul **“PERBANDINGAN BIAS KOREKSI BAYESIAN MODEL AVERAGING DENGAN ENSEMBLE MODEL OUTPUT STATISTICS PADA DATA NUMERICAL WEATHER PREDICTION DALAM MONITORING POLA KEKERINGAN DI PROVINSI NUSA TENGGARA TIMUR”** dengan lancar.

Keberhasilan penyusunan Tugas Akhir ini tidak lepas dari banyaknya bantuan dan dukungan yang diberikan dari berbagai pihak. Oleh karena itu, pada kesempatan ini penulis mengucapkan terima kasih kepada:

1. Dr. Suhartono selaku Kepala Departemen Statistika dan Dr. Sutikno, M.Si selaku Koordinator Program Studi S1 yang telah memberikan fasilitas untuk kelancaran penyelesaian Tugas Akhir.
2. Dr. rer. pol. Heri Kuswanto, M.Si selaku dosen pembimbing yang telah dengan sabar dan senantiasa memberikan bimbingan, saran, dan dukungan selama penyusunan Tugas Akhir.
3. Dr. Ir. Setiawan, M.S dan Dr. Suhartono selaku dosen penguji yang telah memberikan banyak bantuan dan saran demi kesempurnaan Tugas Akhir ini.
4. Dr. Dra. Ismaini Zain, M.Si selaku dosen wali yang telah memberikan nasehat dan *support* terhadap penulis dalam menyelesaikan Tugas Akhir ini.
5. Seluruh dosen Statistika ITS yang telah memberikan ilmu dan pengetahuan yang tak ternilai harganya, serta segenap karyawan Jurusan Statistika ITS.
6. Paulina Yuke Nusyawati dan Riza Purnama yaitu Ibu dan Ayah penulis yang selalu menjadi *long distance support system* dari penulis, serta senantiasa memberikan doa dan

bantuan dalam mempersiapkan apapun (material dan moral) selama penyusun dalam proses menyelesaikan Tugas Akhir.

7. Rr. Nadhila Ramadhini Ayuvinda selaku *close distance support system* yang senantiasa memberikan semangat, nasihat, dan mendoakan kelancaran penulis dalam menyelesaikan Tugas Akhir.
8. Dwi Putra Keza dan Rizky Tirta Nugraha, yaitu adik dari penulis yang selalu mendoakan dan memberikan penulis motivasi untuk segera menyelesaikan Tugas Akhir ini.
9. Mbak T. Dwi Ary dan Fachrunisah yang sudah bersedia meluangkan waktu untuk membantu dan berdiskusi mengenai topik dan metode Tugas Akhir ini.
10. Teman-teman seperjuangan, khususnya Juli, Win, Uni, Esis, Alicia, Iza, Aul, Delin, dan Aris yang selalu memberikan hiburan dan asupan semangat untuk penulis.
11. Teman-teman Sigma 24 yang selalu memberikan kehangatan dan kebersamaan untuk penulis.
12. Semua pihak yang telah memberikan bantuan hingga penyusunan laporan Tugas Akhir ini dapat terselesaikan yang namanya tidak dapat penulis sebutkan satu per satu.

Penulis menyadari bahwa Tugas Akhir ini masih belum sempurna, sehingga kritik dan saran sangat terbuka. Semoga hasil Tugas Akhir ini dapat bermanfaat bagi semua, khususnya pembaca dan untuk pengembangan penelitian selanjutnya. Amin.

Surabaya, Juli 2017

Penulis

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
COVER PAGE	iii
LEMBAR PENGESAHAN	v
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR GAMBAR	xvii
DAFTAR TABEL	xxi
DAFTAR LAMPIRAN	xxiii
BAB I PENDAHULUAN	
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah	6
1.3 Tujuan Penelitian.....	6
1.4 Manfaat Penelitian.....	7
1.5 Batasan Masalah.....	7
BAB II TINJAUAN PUSTAKA	
2.1 Kekeringan	9
2.1.1 Kekeringan Meteorologis.....	10
2.1.2 Kekeringan Hidrologis	10
2.1.3 Kekeringan Agrilultural	10
2.2 <i>Numerical Weather Prediction</i>	11
2.2.1 <i>Canadian Seasonal to Interannual Prediction</i> <i>System (CanSIPS)</i>	12
2.2.2 <i>Center for Ocean-Land-Atmosphere (COLA)</i>	13
2.2.3 <i>Geophysical Fluid Dynamic Laboratory</i> <i>(GFDL)</i>	14
2.3 Curah Hujan.....	14
2.4 <i>Standardized Precipitation Index</i>	15

2.5	<i>Ensemble Prediction System</i>	17
2.5.1	Metode Rata-Rata.....	18
2.5.2	Metode Penggabungan	18
2.6	Evaluasi Keباikan Model Peramalan.....	19
2.6.1	<i>Root Mean Square Error (RMSE)</i>	19
2.6.2	<i>Mean Percentage Error (MPE)</i>	20
2.6.3	<i>Rank Histogram</i>	20
2.7	<i>Bayesian Model Averaging</i>	22
2.8	<i>Expectation Maximization</i>	24
2.9	<i>Ensemble Model Output Statistic</i>	25
2.10	<i>Continous Rank Probability Score</i>	26

BAB III METODOLOGI PENELITIAN

3.1	Sumber Data	29
3.2	Variabel Penelitian.....	29
3.3	Struktur Data.....	30
3.4	Langkah Analisis	33

BAB IV ANALISIS DAN PEMBAHASAN

4.1	<i>Pre-processing</i> Data Curah Hujan Bulanan.....	35
4.2	Statistika Deskriptif Curah Hujan Rata-Rata Bulanan di Nusa Tenggara Timur.....	38
4.3	Evaluasi Model Peramalan Curah Hujan di Nusa Tenggara Timur	41
4.3.1	Evaluasi Model Peramalan Curah Hujan Lead-1 ..	42
4.3.2	Evaluasi Model Peramalan Curah Hujan Lead-4 ..	48
4.4	Kalibrasi Peramalan Curah Hujan Menggunakan <i>Bayesian Model Averaging-Expectation Maximization</i> ...	54
4.4.1	Kalibrasi Menggunakan BMA-EM pada Lead-1 ..	55
4.4.2	Kalibrasi Menggunakan BMA-EM pada Lead-4 ...	62
4.5	Kalibrasi Peramalan Curah Hujan Menggunakan <i>Ensemble Model Output Statistics</i>	64
4.5.1	Kalibrasi Menggunakan EMOS pada Lead-1	66
4.5.2	Kalibrasi Menggunakan EMOS pada Lead-4.....	68
4.6	Evaluasi Model Kalibrasi Peramalan.....	69

4.7 Pemetaan Kekeringan di Provinsi Nusa Tenggara Timur Berdasarkan Hasil Peramalan SPI	70
4.7.1 Pemetaan Kekeringan untuk <i>Lead</i> ke-1	72
4.7.2 Pemetaan Kekeringan untuk <i>Lead</i> ke-4	76
BAB V KESIMPULAN DAN SARAN	
5.1 Kesimpulan.....	83
5.2 Saran.....	84
DAFTAR PUSTAKA	85
LAMPIRAN.....	93
BIODATA PENULIS	

(halaman ini sengaja dikosongkan)

DAFTAR GAMBAR

	Halaman
Gambar 2.1	Tahapan dalam Metode Ensembl.....17
Gambar 2.2	Interpretasi Kriteria <i>Rank Histogram</i>21
Gambar 2.3	Ilustrasi CRPS27
Gambar 3.2	Diagram Alir Penelitian.....34
Gambar 4.1	Data Hasil Konversi format <i>.nc</i> ke Bentuk <i>.txt</i>36
Gambar 4.2	Hasil Penggabungan Data ECMWF dalam format <i>.csv</i>36
Gambar 4.3	Data Gabungan NMME dan ECMWF dalam Format <i>.csv</i>37
Gambar 4.4	Hasil Partisi Data untuk Kalibrasi Berdasarkan Koordinat38
Gambar 4.5	Peta Nusa Tenggara Timur Beserta Lokasi Spesifik yang Diinterpretasikan.....41
Gambar 4.6	<i>Tine Series Plot</i> Model Peramalan dan Observasi di Nusa Tenggara Timur pada Koordinat 8 ⁰ LS-118 ⁰ BT (<i>Lead</i> ke-1).....44
Gambar 4.7	<i>Tine Series Plot</i> Residual Model Peramalan Terhadap Observasi pada Koordinat 8 ⁰ LS- 118 ⁰ BT (<i>Lead</i> ke-1)44
Gambar 4.8	<i>Tine Series Plot</i> Model Peramalan dan Observasi di Nusa Tenggara Timur pada Koordinat Lainnya (<i>Lead</i> ke-1)45
Gambar 4.9	<i>Tine Series Plot</i> Residual Model Peramalan Terhadap Observasi pada Lainnya (<i>Lead</i> ke-1).....46
Gambar 4.10	<i>Rank Historam</i> Model Peramalan dan Observasi Curah Hujan di Nusa Tenggara Timur pada Koordinat 8 ⁰ LS-118 ⁰ BT (<i>Lead</i> ke-1).....47

Gambar 4.11	<i>Rank Histogram</i> Model Peramalan dan Observasi <i>lead</i> ke-1 pada Koordinat Lainnya ($8^0\text{LS}-119^0\text{BT}$).....	47
Gambar 4.12	<i>Tine Series Plot</i> Model Peramalan dan Observasi di Nusa Tenggara Timur pada Koordinat $10^0\text{LS}-118^0\text{BT}$ (<i>Lead</i> ke- 4)	50
Gambar 4.13	<i>Tine Series Plot</i> Residual Model Peramalan Terhadap Observasi pada Koordinat $8^0\text{LS}-118^0\text{BT}$ (<i>Lead</i> ke-4)	50
Gambar 4.14	<i>Tine Series Plot</i> Model Peramalan dan Observasi di Nusa Tenggara Timur pada Koordinat Lainnya (<i>Lead</i> ke-4)	51
Gambar 4.15	<i>Tine Series Plot</i> Residual Model Peramalan Terhadap Observasi pada Lainnya (<i>Lead</i> ke-4).....	52
Gambar 4.16	<i>Rank Historam</i> Model Peramalan dan Observasi Curah Hujan di Nusa Tenggara Timur pada Koordinat $10^0\text{LS}-118^0\text{BT}$ (<i>Lead</i> ke-4).....	52
Gambar 4.17	<i>Rank Histogram</i> Model Peramalan dan Observasi <i>lead</i> ke-4 pada Koordinat Lainnya ($8^0\text{LS}-125^0\text{BT}$).....	53
Gambar 4.18	Perhitungan μ_k untuk Masing-Masing Model Peramalan pada Koordinat $8^0\text{LS}-118^0\text{BT}$ Periode November 2016	56
Gambar 4.19	Perhitungan σ_k dan w_k untuk Masing-Masing Model Peramalan pada Koordinat $8^0\text{LS}-118^0\text{BT}$ Periode November 2016.....	57
Gambar 4.20	PDF curah hujan dengan metode BMA-EM untuk Periode November 2016 pada Koordinat $8^0\text{LS}-118^0$	59

Gambar 4.21	PDF curah hujan dengan metode BMA-EM untuk Periode November 2016 pada Koordinat lainnya (<i>Lead ke-1</i>).....	61
Gambar 4.22	PDF curah hujan dengan metode BMA-EM untuk Periode November 2016 pada Koordinat lainnya (<i>Lead ke-4</i>).....	63
Gambar 4.23	Ilustrasi Prosedur Regresi dalam Kalibrasi Peramalan menggunakan EMOS.....	66
Gambar 4.24	Hasil Pemetaan Kekeringan Periode Januari 2017 (<i>Lead ke-1</i>).....	72
Gambar 4.25	Hasil Pemetaan Kekeringan Periode Februari 2017 (<i>Lead ke-1</i>).....	73
Gambar 4.26	Hasil Pemetaan Kekeringan Periode Maret 2017 (<i>Lead ke-1</i>).....	73
Gambar 4.27	Hasil Pemetaan Kekeringan Periode April 2017 (<i>Lead ke-1</i>).....	74
Gambar 4.28	Hasil Pemetaan Kekeringan Periode Mei 2017 (<i>Lead ke-1</i>).....	75
Gambar 4.29	Hasil Pemetaan Kekeringan Periode Januari 2017 (<i>Lead ke-4</i>).....	77
Gambar 4.30	Hasil Pemetaan Kekeringan Periode Februari 2017 (<i>Lead ke-4</i>).....	78
Gambar 4.31	Hasil Pemetaan Kekeringan Periode Maret 2017 (<i>Lead ke-4</i>).....	78
Gambar 4.32	Hasil Pemetaan Kekeringan Periode April 2017 (<i>Lead ke-4</i>).....	79
Gambar 4.33	Hasil Pemetaan Kekeringan Periode Mei 2017 (<i>Lead ke-4</i>).....	80

(halaman ini sengaja dikosongkan)

DAFTAR TABEL

	Halaman
Tabel 2.1	Model NWP yang Digunakan.....12
Tabel 2.2	Nilai Kategori Kekeringan Berdasarkan SPI16
Tabel 3.1	Model Peramalan yang Digunakan dalam Kalibrasi.....30
Tabel 3.2	Struktur Data NMME31
Tabel 3.2	Struktur Data ECMWF32
Tabel 4.1	Daftar Keterangan Kode Koordinat ke Dalam Bentuk Koordinat Lintang-Bujur yang Sebenarnya.....37
Tabel 4.2	Analisis Deskriptif Data Curah Hujan di NTT Secara Umum.....39
Tabel 4.3	Analisis Deskriptif Data Curah Hujan di NTT Secara Spesifik40
Tabel 4.4	Perbandingan Jumlah Bias, RMSE, dan MPE Model Peramalan pada Koordinat 8 ⁰ LS-118 ⁰ BT (<i>Lead</i> ke-1)42
Tabel 4.5	Perbandingan Jumlah Bias, RMSE, dan MPE Model Peramalan pada Koordinat Lainnya (<i>Lead</i> ke-1)43
Tabel 4.6	Perbandingan Jumlah Bias, RMSE, dan MPE Model Peramalan pada Koordinat 10 ⁰ LS-118 ⁰ BT (<i>Lead</i> ke-4)48
Tabel 4.7	Perbandingan Jumlah Bias, RMSE, dan MPE Model Peramalan pada Koordinat Lainnya (<i>Lead</i> ke-4)49
Tabel 4.8	Parameter BMA untuk Periode November 2016 pada Koordinat 8 ⁰ LS-118 ⁰ LS (<i>Lead</i> ke-1).....60
Tabel 4.9	Parameter BMA untuk Periode November 2016 pada Koordinat 10 ⁰ LS-118 ⁰ LS (<i>Lead</i> ke-4).....62

Tabel 4.10	Parameter Distribusi EMOS untuk Periode November 2016 pada Koordinat 8 ⁰ LS-118 ⁰ LS (<i>Lead</i> ke-1).....	67
Tabel 4.11	Parameter Distribusi EMOS untuk Periode November 2016 pada Koordinat 10 ⁰ LS-118 ⁰ LS (<i>Lead</i> ke-4).....	68
Tabel 4.12	Nilai CRPS <i>mean</i> dari Kalibrasi Peramalan Menggunakan BMA-EM dan EMOS	69
Tabel 4.13	Kategori Kekeringan Berdasarkan SPI	71
Tabel 4.14	Pengkategorian Kekeringan Berdasarkan Spektrum Warna Pin	71
Tabel 4.15	Klasifikasi Kekeringan di Wilayah NTT pada <i>Lead</i> ke-1	76
Tabel 4.16	Klasifikasi Kekeringan di Wilayah NTT pada <i>lead</i> ke-4.....	81

DAFTAR LAMPIRAN

	Halaman
Lampiran 1 Data Observasi dan Data Peramalan Curah Hujan Bulanan di Nusa Tenggara Timur	93
Lampiran 2 <i>Syntax</i> Merubah Data ECMWF Menjadi Format <i>.txt</i>	97
Lampiran 3 <i>Syntax</i> R Merubah Penggabungan Data per Koordinat menjadi Satu <i>File</i>	98
Lampiran 4 <i>Syntax Looping</i> Untuk Separasi Data per Koordinat.....	98
Lampiran 5 <i>Syntax</i> R Kalibrasi dengan Metode BMA-EM.....	99
Lampiran 6 Plot Kurva Distribusi BMA.....	103
Lampiran 7 <i>Syntax</i> R Kalibrasi dengan Metode EMOS	104
Lampiran 8 Data Hasil Kalibrasi Peramalan Menggunakan BMA-EM	106
Lampiran 9 <i>Syntax</i> NCL untuk Pemetaan Pola Kekeringan	111
Lampiran 10 Hasil Pemetaan Menggunakan NCL	112
Lampiran 11 Surat Pernyataan.....	116

(halaman ini sengaja dikosongkan)

BAB I

PENDAHULUAN

1.1. Latar Belakang

Bencana kekeringan di Indonesia merupakan persoalan yang memiliki dampak yang cukup signifikan. Sebagai negara agraris, kekeringan mengakibatkan turunnya produksi tanaman yang berdampak kepada menurunnya kondisi pangan nasional serta menyebabkan goyahnya stabilisasi perekonomian. Kekeringan dapat diartikan sebagai pengurangan persediaan air atau kelembaban yang bersifat sementara secara signifikan di bawah normal atau volume yang diharapkan untuk jangka waktu tertentu (Raharjo & Dwi, 2010). Kekeringan dapat menjadi bencana alam apabila mulai menyebabkan suatu wilayah kehilangan sumber pendapatan akibat gangguan ekosistem yang ditimbulkannya. Tidak seperti bencana meteorologi lainnya seperti banjir, tornado, atau angin topan, kekeringan adalah fenomena alam yang dapat muncul tanpa peringatan dan berlangsung hingga berbulan-bulan (Sheffield & Wood, 2011). Dampak kekeringan yang panjang dapat menimbulkan kerusakan yang signifikan. Namun demikian, suatu kekeringan yang singkat tetapi intensif dapat juga mengakibatkan efek yang tidak jauh berbeda.

Terjadinya bencana alam turut dipengaruhi oleh kondisi geografis (Singer, Endreny, & Glassman, 1991). Dengan letak geografis diantara dua benua dan dua samudra, serta terletak di sekitar garis khatulistiwa menjadikan Indonesia berada di belahan bumi dengan iklim muson tropis yang sangat sensitif terhadap anomali iklim *El-Nino*. Posisi geografis Indonesia merupakan salah satu faktor klimatologis penyebab kekeringan di Indonesia. Badan Nasional Penanggulangan Bencana melalui CNN (2015) menyatakan bahwa Indonesia mengalami ancaman bencana kekeringan diakibatkan oleh imbas badai El Nino di wilayah Asia Pasifik. BNPB juga menambahkan bahwa dampak kekeringan paling terlihat pada delapan provinsi di Indonesia di Pulau Jawa, Bali, dan Nusa Tenggara. Kekeringan yang terjadi

menimbulkan krisis air di sepanjang pulau. Imbas krisis air ini kemudian turut mempengaruhi sektor pertanian dimana hampir 21 ribu hektare lahan pertanian di sepanjang Pulau Jawa, Bali, dan Nusa Tenggara mengalami kering kerontang.

Diperlukan sejumlah upaya penanganan terkait mengatasi bencana kekeringan di Indonesia, salah satunya adalah provinsi Nusa Tenggara Timur yang turut mengalami dampak signifikan. Upaya terkini yang dapat dilakukan adalah melakukan peramalan terkait potensi datangnya kembali bencana kekeringan. Peramalan bencana kekeringan dilakukan dengan tujuan untuk memberikan peringatan dini terkait datangnya bencana kekeringan yang melanda Provinsi Nusa Tenggara Timur. Beberapa indikator telah dikembangkan dalam upaya monitoring bencana kekeringan. Namun demikian, Badan Meteorologi Internasional telah menetapkan keputusan bahwa *Standardized Precipitation Index* (SPI) adalah indikator umum yang digunakan dalam monitorisasi kekeringan (Hayes, Svoboda, Wall, & Widhalm, 2011). Nilai *Standardized Precipitation Index* diperoleh melalui hasil konversi data curah hujan pada suatu daerah tertentu dan periode tertentu (Gutmann, 1998). Sebagai satuan standar internasional yang diterapkan dalam monitoring kekeringan, *Standardized Precipitation Index* (SPI) juga turut digunakan dalam *Numerical Weather Prediction* (NWP) sebagai ukuran dalam memetakan kekeringan secara global termasuk Provinsi Nusa Tenggara Timur di Indonesia. Data NWP hasil pengukuran curah hujan diperoleh melalui perhitungan satelit (Shofiyati *et al.*, 2014). Di dalam pengukuran menggunakan NWP terdapat beberapa model peramalan terhadap curah hujan berdasarkan *lead time* dan periode waktu tertentu (Yucel *et al.*, 2015). Output dari beberapa model peramalan yang dihasilkan nantinya diharapkan dapat memberikan pemaparan terkait model prediksi kekeringan yang reliabel, dimana teknik ini disebut *ensemble prediction system* (EPS).

Teknik *ensemble prediction system* (EPS) adalah teknik peramalan yang dihasilkan dari gabungan beberapa model output,

dimana hasil peramalan yang dihasilkan cenderung bersifat probabilistik. Ide dari peramalan ensembel adalah mengurangi ketidakpastian model yang diturunkan dari beberapa faktor tertentu seperti spesifikasi model, aturan alam, kondisi awal, dan lain sebagainya (Zhu, 2005). Teknik peramalan ensembel telah diaplikasikan oleh banyak departemen penelitian di negara maju seperti *National Centers for Environmental Prediction* (NCEP) di Amerika Serikat, *European Centre for Medium Range Weather Forecast* (ECMWF) di negara-negara Eropa, Met-Office di Britania Raya dan Irlandia Utara, *Environment Canada* di Kanada, *Japanese Meteorological Agency* di Jepang, *Bureau Meteorology* di Australia, *Korean Meteorological Administration* di Korea Selatan, dan masih banyak lagi. Dalam penerapannya, teknik peramalan ensembel terbukti lebih reliabel dibandingkan menggunakan teknik peramalan deterministik (Kuswanto & Sari, 2013).

Peramalan ensembel secara umum diperoleh dari kondisi awal, kondisi batas, dan parameter dari satu hingga beberapa model peramalan (Buizza *et al.*, 2007). Akan tetapi, seringkali peramalan menggunakan EPS tidak terkalibrasi dengan baik, dimana nilai pengamatan cenderung jauh dari interval prediksi EPS (Gneiting & Raftery, 2005). Pernyataan tersebut terbukti pada penelitian yang dilakukan oleh Leutbecher dan Palmer (2008), dimana didapatkan hasil bahwa pendekatan *ensemble prediction system* (EPS) tidak berhasil dalam melakukan perhitungan *error*. Penelitian mengenai evaluasi terhadap penggunaan metode *ensemble prediction system* (EPS) juga dilakukan oleh Candille (2009). Penelitian ini mengkalibrasi hasil observasi yang dari dua model yang berbeda: *Canadian Meteorological Centre* (CMC) dan *National Centers for Environmental Prediction* (NCEP). Dari penelitian tersebut, didapatkan hasil bahwa model yang didapatkan dari NCEP bersifat *undispersive* dan model yang didapatkan dari CMC bersifat mendekati *dispersive* secara sempurna. Dikarenakan hasil kalibrasi menunjukkan perbedaan yang begitu signifikan antara

kedua model, maka dapat disimpulkan bahwa metode ESP seringkali hanya merepresentasikan sedikit dari banyak model yang dilibatkan.

Berdasarkan dua penelitian yang telah dilakukan sebelumnya, dapat diketahui bahwa kondisi tersebut sebagian dikarenakan oleh tidak diperhitungkannya semua penyebab bias dan sebagian dikarenakan adanya perbedaan antara skala temporal dan skala spasial pada variabel yang diprediksi dan skala yang dibutuhkan. Oleh sebab itu, dibutuhkan penanganan lebih lanjut (*post-processing*) dalam menghasilkan model peramalan ensemble yang reliabel. Beberapa metode telah dikemukakan untuk memproses model ensemble secara lebih lanjut dalam menghasilkan peramalan kekeringan, di antaranya adalah *Bayesian Model Averaging* (BMA). Istilah BMA mengacu kepada metode *post-processing* secara statistik untuk meminimalisir bias dan menghasilkan estimasi model peramalan dari ensemble dengan merata-ratakan distribusi probabilitas dari semua model yang mungkin terbentuk (Raftery *et al.*, 2005). Tujuannya adalah untuk menghasilkan satu model terbaik dari kombinasi beberapa model sehingga estimasi model baru yang terbentuk lebih baik dan mampu merepresentasikan seluruh model yang terlibat (Montgomery & Nyhan, 2010).

Selain *Bayesian Model Averaging* (BMA), pendekatan *post-processing* lain yang dapat dilakukan adalah *Ensemble Model Output Statistics* (EMOS). Metode EMOS pertama kali diperkenalkan oleh Gneiting *et al.* (2005), dimana teknik ini mentransformasi model peramalan ensemble yang masih mentah menjadi fungsi pdf yang bersifat prediktif dan secara bersamaan mengoreksi bias dan kesalahan dispersi. Kedua metode, baik BMA ataupun EMOS memiliki kesamaan dalam estimasi parameter, yaitu *Maximum Likelihood Estimation* (MLE). Perbedaan antara keduanya adalah model BMA menggunakan gabungan distribusi dari setiap model yang terlibat, sedangkan model EMOS berdasarkan model regresi linier berganda (Marrocu & Chessa, 2008).

Penelitian ini bertujuan untuk mengkalibrasikan beberapa model hasil peramalan curah hujan dengan hasil output bias koreksi dari data hasil pengamatan curah hujan secara *real time* melalui satelit dengan data hasil pengamatan curah hujan secara *real time* berdasarkan observasi lapangan. Melalui hasil kalibrasi ini akan dibentuk satu model peramalan yang reliabel dan dapat merepresentasikan seluruh model yang digunakan dalam meramalkan kekeringan di Provinsi Nusa Tenggara Timur, dimana nilai curah hujan ini diukur dari perpaduan lintang bujur (*grid*) sepanjang wilayah Provinsi Nusa Tenggara Timur. Dari satu model yang terbentuk, akan dilakukan *forecast* curah hujan untuk beberapa periode ke depan yang kemudian nilai peramalan curah hujan tersebut akan dikonversikan ke dalam bentuk satuan *Standard Precipitation Index* (SPI). Selain itu, dalam penelitian ini akan dilakukan perbandingan akurasi antara metode ensemble menggunakan *Bayesian Model Averaging* dengan pendekatan *Expectation Maximization* (BMA-EM) dan *Ensemble Model Output Statistics* (EMOS).

Penelitian sebelumnya terkait perbandingan antara metode *Bayesian Model Averaging* (BMA) dan *Ensemble Model Output Statistics* (EMOS) pernah dilakukan oleh Prokosch (2013), dimana dilakukan perbandingan antara kedua metode tersebut untuk mengetahui manakah metode *post-processing* yang lebih akurat dalam meramalkan suhu cuaca di Provinsi Trondheim, Norwegia. Dari penelitian yang dilakukan didapatkan hasil bahwa model peramalan ensemble yang dihasilkan melalui metode EMOS memberikan skor yang lebih baik dibandingkan dengan model peramalan ensemble yang dihasilkan melalui metode BMA. Penelitian sebelumnya yang serupa juga pernah dilakukan oleh Baran *et al.* (2013), dimana dalam penelitian tersebut dilakukan perbandingan antara metode BMA dan EMOS dalam mengkalibrasikan model peramalan ensemble dari suhu cuaca dan kecepatan angin di Hungaria. Adapun dari penelitian tersebut didapatkan kesimpulan bahwa kedua metode menghasilkan probabilitas dan *point forecast* yang lebih baik dibandingkan

dengan metode ensemble secara umum. Dalam penelitian tersebut juga didapatkan kesimpulan bahwa kalibrasi menggunakan BMA menghasilkan model peramalan ensemble yang sedikit lebih baik dibandingkan dengan menggunakan metode EMOS.

1.2. Permasalahan Penelitian

Berdasarkan uraian dari latar belakang di atas maka terdapat beberapa permasalahan yang dapat ditelusuri dalam penelitian ini. Permasalahan pertama adalah untuk mengetahui bagaimana peramalan curah hujan untuk monitoring kekeringan yang terjadi di Provinsi Nusa Tenggara Timur menggunakan *Bayesian Model Averaging-Expectation Maximization* (BMA-EM) dan *Ensemble Model Output Statistics* (EMOS) Kemudian, permasalahan lain yang ditelusuri adalah mengenai seberapa besar kebaikan hasil model akurasi peramalan curah hujan untuk monitoring kekeringan di Provinsi Nusa Tenggara Timur menggunakan metode BMA-EM dan EMOS. Selain itu, dalam penelitian ini juga akan dilakukan analisis perbandingan antara hasil ketepatan peramalan antara metode BMA-EM dan metode EMOS terhadap peramalan curah hujan di Provinsi Nusa Tenggara Timur sehingga dapat ditentukan metode terbaik antara kedua metode peramalan ensemble tersebut.

1.3. Tujuan Penelitian

Berdasarkan latar belakang dan rumusan masalah di atas maka tujuan yang ingin diperoleh dalam penelitian ini adalah sebagai berikut.

1. Memodelkan peramalan curah hujan untuk monitoring kekeringan yang terjadi di Provinsi Nusa Tenggara Timur menggunakan BMA-EM dan EMOS.
2. Mengetahui akurasi dari model ensemble peramalan curah hujan di Provinsi Nusa Tenggara Timur yang telah didapatkan menggunakan metode BMA-EM dan EMOS.

3. Membandingkan hasil ketepatan model peramalan ensembel antara metode BMA-EM dengan metode EMOS terhadap peramalan curah hujan di Nusa Tenggara Timur.

1.4. Manfaat Penelitian

Manfaat yang dapat digunakan dari hasil penelitian ini adalah memberikan rekomendasi kepada pemerintah pusat ataupun daerah, khususnya Pemerintah Daerah Provinsi Nusa Tenggara Timur dalam melakukan upaya antisipasi terhadap bencana kekeringan di berdasarkan hasil peramalan curah hujan dan pemetaan *Standardized Precipitation Index* yang diperoleh.

1.5. Batasan Masalah

Terdapat dua batasan masalah yang digunakan dalam penelitian ini antara lain adalah sebagai berikut.

1. Monitoring kekeringan berdasarkan tinjauan hasil peramalan dari satu indikator saja, yaitu terhadap hasil peramalan curah hujan yang selanjutnya dikonversikan ke dalam satuan *Standardized Precipitation Index* (SPI).
2. Dikarenakan keterbatasan data, peramalan curah hujan hanya dilakukan untuk jangka waktu satu bulan sampai lima bulan ke depan.
3. Pemetaan kekeringan di Nusa Tenggara Timur hanya dibatasi untuk pemetaan terhadap wilayah daratan.

(halaman ini sengaja dikosongkan)

BAB II

TINJAUAN PUSTAKA

2.1. Kekeringan

Kekeringan secara umum didefinisikan oleh UN-ISDR (2009) sebagai suatu keadaan kurangnya curah hujan dalam suatu periode waktu tertentu yang menyebabkan minimnya air untuk berbagai kegiatan, kelompok, atau sektor lingkungan. Wilhite (2011) menyatakan bahwa kekeringan berbeda dari bencana alam lainnya pada 4 hal, yaitu:

- 1) Karena kekeringan merayap, berakumulasi secara lambat, maka awal dan akhir terjadinya sulit ditentukan.
- 2) Tidak adanya definisi yang tepat membuat kerancuan apakah telah terjadi kekeringan, dan jika terjadi bagaimana tingkat keparahannya. Contohnya, batas untuk menyatakan kekeringan pada umumnya tidak terkait langsung dengan dampak spesifik pada sektor ekonomi.
- 3) Dampak kekeringan adalah non-struktural, tidak seperti banjir, tanah longsor dan badai yang menimbulkan kerusakan struktur secara nyata. Dampaknya menyebar lebih luas, tidak terlokalisir seperti bencana alam lainnya.
- 4) Terdapat berbagai jenis kekeringan, dengan parameter yang berbeda.

Wilhite (2011) juga menambahkan, untuk membedakan berbagai tingkat kekeringan, pada dasarnya terdapat 3 faktor yang menentukan, yaitu intensitas, durasi, dan luas yang terkena dampak. Intensitas menyatakan derajat kekurangan hujan atau dampak lainnya yang biasa dinyatakan dengan penyimpangan dari indikator iklim atau indeks dari kondisi normal. Sebagaimana bencana alam lainnya, kekeringan juga memiliki komponen alami dan komponen masyarakat. Resiko kekeringan merupakan hasil perkalian antara daerah yang terkena kekeringan dengan kerawanan masyarakat terhadap kekeringan. Adapun SAARC (2010) menjelaskan bahwa berdasarkan parameternya, kekeringan terbagi menjadi tiga di antara lain sebagai berikut.

2.1.1. Kekeringan Meteorologis

Kekeringan meteorologis berkaitan dengan tingkat curah hujan di bawah normal dalam satu musim. Kekeringan meteorologis biasanya didefinisikan sebagai kurangnya curah hujan selama periode waktu yang telah ditentukan. Ambang batas yang dipilih, seperti 50% dari curah hujan normal selama jangka waktu enam bulan akan bervariasi menurut lokasi sesuai dengan kebutuhan pengguna atau aplikasi. Data yang diperlukan untuk menilai kekeringan meteorologi adalah informasi curah hujan harian, suhu, kelembaban, kecepatan dan tekanan angin serta penguapan.

2.1.2. Kekeringan Hidrologis

Kekeringan hidrologis didefinisikan sebagai kekurangan air pada permukaan dan persediaan air bawah permukaan di berbagai titik dalam periode tertentu. Pada kekeringan hidrologis, tidak ada hubungan langsung antara jumlah curah hujan dengan status air permukaan dan persediaan air bawah permukaan karena komponen sistem hidrologi digunakan untuk beberapa tujuan, seperti irigasi, rekreasi, pariwisata, pengendalian banjir, transportasi, produksi listrik tenaga air, air pasokan dalam negeri, perlindungan spesies terancam punah, dan manajemen lingkungan, ekosistem, dan pelestarian.

2.1.3. Kekeringan Agrikultural

Kekeringan pertanian didefinisikan sebagai kurangnya ketersediaan air tanah untuk mendukung pertumbuhan tanaman dan makanan ternak dari curah hujan normal selama beberapa periode waktu tertentu. Hubungan antara curah hujan dan infiltrasi air hujan ke dalam tanah seringkali tidak berlangsung. Tingkat infiltrasi bervariasi tergantung pada kondisi kelembaban, kemiringan, jenis tanah, dan intensitas dari peristiwa presipitasi. Sebagai contoh, beberapa tanah memiliki kapasitas menyimpan air lebih tinggi, yang membuat mereka kurang rentan terhadap kekeringan.

2.2. *Numerical Weather Prediction (NWP)*

Numerical Weather Prediction (NWP) adalah sebuah prosedur yang menggunakan model matematis dari pola atmosfer dan hidrosfer dalam memprediksi kondisi cuaca atau iklim secara global atau suatu wilayah tertentu. Istilah NWP muncul pada awal tahun 1920, dimana proses ini dilakukan untuk menghasilkan peramalan pola atmosfer pada dua titik di Eropa Tengah (Lynch, 2008). Pengaplikasian NWP digunakan di berbagai lembaga penelitian meteorologi dan geofisika di seluruh dunia, baik secara global maupun regional (Chen *et al.*, 2013). Dalam penelitian ini, data NWP yang digunakan adalah data NWP berdasarkan model *North-American Multi Model Ensemble (NMME)*. *North-American Multi Model Ensemble (NMME)* dirancang atas usulan beberapa lembaga penelitian di Amerika Utara; diantaranya *National Oceanic and Atmospheric Administration (NOAA)*, *National Science Foundation (NF)*, *United States Department of Energy (DOED)*, dan *National Aeronautics and Space Administration (NASA)*.

Terdapat dua tahapan utama dalam rancangan *NMME*. Tahap 1 memfokuskan dalam merubah skala waktu musiman dan tahunan menjadi dalam bentuk skala waktu bulanan, kemudian tahap kedua adalah medefinisikan parameter peramalan ulang yang paling tepat. Peramalan dalam *NMME* dilakukan pada setiap pertengahan bulan. Kirtman *et al.* (2014) menjelaskan bahwa pendekatan multi-model menggunakan *NMME* telah terbukti memberikan hasil peramalan yang lebih akurat dibandingkan dengan menggunakan peramalan model tunggal. Dataset *NMME* telah secara luas digunakan pada penelitian-penelitian sebelumnya untuk memverifikasi hasil peramalan dari rata-rata curah hujan bulanan (Wang, 2014), temperatur wilayah pada ketinggian 2 m di atas permukaan laut (Becker *et al.*, 2015), suhu permukaan laut (Barnston *et al.*, 2015), curah hujan musiman (Ma *et al.*, 2015), dan kekeringan musiman (Yuan *et al.*, 2013). Adapun terdapat lima model NWP yang digunakan dalam penelitian ini, dimana kelima model tersebut merupakan

ekspansi dari tiga model inti yang telah dikembangkan sebelumnya. Rincian dari model-model peramalan yang digunakan ditampilkan pada Tabel 2.1.

Tabel 2.1 Model NWP yang Digunakan

Model NWP	Asal Model	Anggota Ensemble
CMC1-CanCM3	<i>Canadian Seasonal to Interannual Prediction System (CanSIPS)</i>	1-10
CMC2-CanCM4		1-10
COLA-RSMAS-CCSM3	<i>Center for Ocean-Land-Atmosphere (COLA)</i>	1-6
COLA-RSMAS-CCSM4		1-10
GFDL-CM2p1-aer04	<i>Geophysical Fluid Dynamic Laboratory (GFDL)</i>	1-10

Masing-masing model model NWP memiliki *lead time* yang sama, yaitu bervariasi dari 1 bulan sampai dengan 12 bulan. Penelitian ini akan mengkalibrasikan kelima model NWP tersebut pada *lead* ke-1 dan *lead* ke-4. Adapun detail dan penjelasan mengenai kelima model NWP akan dipaparkan per sebagai berikut.

2.2.1. Canadian Seasonal to Interannual Prediction System (CanSIPS)

Sistem *Canadian Seasonal to Interannual Prediction System (CanSIPS)* mulai dioperasikan di Pusat Meteorologi Kanada sejak tahun 2011, dimana sistem ini menggantikan sistem *Canadian Meteorological Centre (CanCM)* yang telah dikembangkan sejak awal tahun 1990 (Merryfield *et al.*, 2013). CanSIPS merupakan sistem peramalan dua model dengan melanjutkan penggunaan dari dua model CanCM sebelumnya, yaitu CanCM3 dan CanCM4. Berbeda dengan sistem CanCM yang menggunakan enam anggota ensemble, CanSIPS melakukan penambahan menjadi sepuluh anggota ensemble pada masing-masing model yang digunakan. Penambahan anggota ensemble ini dilakukan dengan tujuan menghasilkan performa yang lebih baik dalam menghasilkan peramalan pola atmosfer (Kharin *et al.*, 2009). Kedua model peramalan memiliki persamaan nilai dalam

penggunaan resolusi *grid* (pemetaan horizontal), tetapi berbeda dalam pemetaan vertikal. Model CanCM3 yang terlebih dahulu dikembangkan menggunakan 31 tingkatan vertikal yang bekisar dari ketinggian permukaan laut sampai dengan ketinggian troposfer, sementara itu model CanCM4 menggunakan 35 tingkatan vertikal dengan interval ketinggian yang sama, (McFarlane *et al.*, 2008). Namun demikian dalam dataset NMME nilai peramalan telah disamakan ke dalam ketinggian yang sama, yaitu 2m di atas permukaan laut (Kirtman *et al.*, 2014).

Pengujian performa antara kedua model peramalan telah dilakukan berdasarkan tiga aspek, yaitu (i) tren terhadap temperatur global, (ii) rata-rata siklus musiman, dan (iii) variabilitas iklim dalam skala waktu yang relevan dengan peramalan jangka panjang. Adapun data peramalan yang dilakukan uji performansi berkisar dari tahun 1982 sampai dengan 2010. Dari hasil uji performansi, didapatkan hasil bahwa model CanCM3 lebih akurat dalam meramalkan temperatur global, sementara model CanCM4 lebih akurat dalam meramalkan variabilitas iklim dan rata-rata siklus musiman seperti kecepatan angin, curah hujan, dan tekanan udara (Merryfield *et al.*, 2013).

2.2.2. Center for Ocean Land-Atmosphere (COLA)

Center for Ocean-Land-Atmosphere Model atau lebih dikenal sebagai model COLA seperti yang dikemukakan oleh Barnston *et al.* (2015) adalah model peramalan yang dikembangkan oleh lembaga penelitian meteorologi Universitas Miami yang terafiliasi dengan *National Center for Atmospheric Research* (NCAR) milik Amerika Serikat. Model COLA telah mengalami beberapa pengembangan, dimana model COLA-RSMAS-CCSM3 dan COLA-RSMAS-CCSM4 adalah model yang paling sering digunakan (Kirtman *et al.*, 2014). Model COLA generasi ketiga, COLA-RSMAS-CCSM3 menggunakan pemetaan horizontal dengan resolusi *grid* sebesar $1,4^0$ dan pemetaan vertikal sebanyak 26 tingkatan (Kirtman & Min, 2009). Model ini dirancang untuk menghasilkan peramalan pola

atmosfer yang realistis dengan simulasi yang sederhana dan dapat berlangsung lama (Collins *et al.*, 2006). Namun demikian, model CCSM3 masih memiliki kekurangan yang fatal dalam kualitas peramalan pada wilayah tropis. Dengan demikian, model CCSM4 dikembangkan dengan mengecilkan resolusi horizontal menjadi 1^0 (Gent *et al.*, 2011). Hasil pengembangan model COLA-RSMAS-CCSM4 menghasilkan hasil peramalan yang lebih realistis, khususnya pada peramalan pola atmosfer di wilayah tropis (Lawrence *et al.*, 2012).

2.2.3. Geophysical Fluid Dynamic Laboratory (GFDL)

Geophysical Fluid Dynamic Laboratory (GFDL) model adalah model atmosferik yang dikembangkan oleh *National Oceanic Atmospheric Administration* (NOAA). Model ini dikembangkan dengan tujuan memfasilitasi deteksi dan prediksi variabilitas iklim dalam jangka waktu musiman hingga multi dekade (Delworth *et al.*, 2006). Adapun model yang digunakan dalam penelitian ini, yaitu model GFDL-CM2p1-aer04 adalah model yang dikembangkan berdasarkan asimilasi data antara model peramalan GFDL sebelumnya dengan nilai observasi *real time* dari beberapa lembaga meteorologi lainnya pada 24 tingkat pemetaan vertikal. Adapun pada pemetaan horizontal, resolusi yang digunakan sebesar 2^0 pada koordinat lintang dan $2,5^0$ pada koordinat bujur (Milly and Shmakin, 2002). Hasil asimilasi dari model peramalan ini terbukti menghasilkan peramalan yang stabil dan realistis dalam periode yang lama, terlepas dari besarnya resolusi *grid* horizontal yang digunakan (Zhang *et al.*, 2007).

2.3. Curah Hujan

Dalam meteorologi istilah curah hujan ditujukan kepada hasil pengembunan uap air di atmosfer yang jatuh ke permukaan bumi (Sosrodarsono, 1985). Curah hujan dipertimbangkan sebagai pembawa sinyal kekeringan, dan tingkat debit sunga serta air tanah sebagai indikator terjadinya kekeringan (Changnon, 1987). Curah hujan merupakan salah satu parameter atmosfer yang sulit diprediksi. Hal ini dikarenakan curah hujan memiliki

keragaman yang tinggi baik secara spasial maupun temporal. Data curah hujan pada dasarnya memiliki dimensi matriks yang cukup besar dan sulit untuk dianalisis. Oleh karena itu, dibutuhkan cara yang tepat untuk menganalisis data curah hujan agar diperoleh informasi yang bermanfaat (Lestari, 2016).

2.4. *Standardized Precipitation Index (SPI)*

Standardized Precipitation Index (SPI) dapat diartikan sebagai satuan indeks yang digunakan untuk menentukan penyimpangan curah hujan terhadap kondisi normal dalam satu periode tertentu (bulanan, tiga bulanan, enam bulanan, tahunan, dan seterusnya). Dalam penggunaannya, disebutkan bahwa apabila curah hujan yang turun mengecil dari batasan tertentu, maka akan berakibat pada berkurangnya debit aliran dan kandungan air tanah sehingga terjadi peristiwa kekeringan. Indeks SPI lebih diunggulkan untuk monitoring kekeringan apabila dibandingkan dengan indeks *simple precipitation rate* dan *Palmer Drought Severity Index (PSDI)* yang semula lebih sering digunakan. Hal ini dikarenakan SPI memiliki beberapa karakteristik yang merupakan perbaikan dari kedua indeks tersebut, diantaranya adalah kemudahan dan fleksibilitas temporal yang memungkinkan untuk diaplikasikan pada semua rentang waktu (Hayes *et al.*, 1996). Secara sederhana, persamaan SPI dapat ditentukan dengan menggunakan persamaan sebagai berikut (McKee *et al.*, 1993).

$$SPI_i = \frac{X_i - \mu}{\sigma} \quad (2.1)$$

dimana,

SPI_i = SPI pada periode bulan ke- i

X_i = Curah hujan pada periode bulan ke- i

μ = Rata-rata curah hujan bulanan

σ = Simpangan baku curah hujan bulanan.

Adapun simpangan baku untuk curah hujan bulanan diperoleh melalui persamaan berikut.

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1}} \quad (2.2)$$

dimana,

σ = Simpangan baku curah hujan bulanan

X_i = Curah hujan pada periode bulan ke- i

\bar{X} = Rata-rata curah hujan bulanan

n = Jumlah bulan

Definisi kekeringan dapat ditentukan setiap periode waktu tertentu. Peristiwa kekeringan dikatakan terjadi apabila nilai SPI mencapai nilai -1 atau kurang. Mengenai penjelasan lebih lanjut terhadap pengkategorian nilai SPI secara keseluruhan dapat dijelaskan pada Tabel 2.2 sebagai berikut (McKee *et al.*, 1993).

Tabel 2.2 Kategori Kekeringan Berdasarkan SPI

Nilai SPI	Kategori Kekeringan
≥ 2	Sangat Basah
1,49 : 1,99	Basah
1 : 1,49	Agak Basah
-0,99 : 0,99	Normal
-1 : -1,49	Agak Kering
-1,99 : -1,5	Kering
≤ -2	Kekeringan Besar

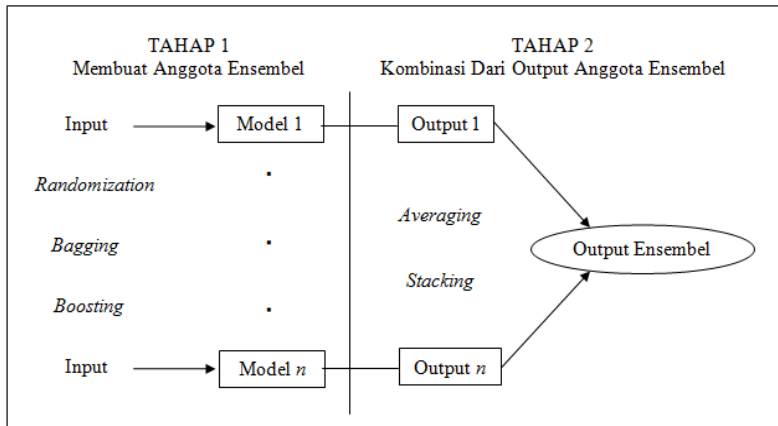
Peristiwa kekeringan mencakup periode waktu tertentu. Dari durasi waktu tersebut, puncak kekeringan dapat ditentukan dari nilai SPI. Pengukuran terhadap tingkat kekeringan dapat ditentukan menggunakan persamaan berikut (McKee *et al.*, 1993).

$$DM = - \left(\sum_{i=1}^n SPI_i \right) \quad (2.3)$$

dimana i dimulai sejak bulan pertama kekeringan dan terus berlanjut hingga bulan akhir kekeringan n (McKee *et al.*, 1993).

2.5. Ensemble Prediction System (EPS)

Peramalan ensemble adalah suatu teknik peramalan dengan menggunakan kombinasi dari output beberapa metode peramalan sebagai nilai dari suatu ramalan dengan tujuan memperbaiki ketegaran dan reliabilitas dari suatu teknik peramalan secara signifikan (Zaier *et al.*, 2010). Secara umum, konstruksi dari model ensemble memerlukan dua tahapan utama (Sharkey, 1999). Tahap pertama adalah membuat anggota ensemble secara individu, kemudian tahap kedua adalah mendapatkan kombinasi yang tepat dari output masing-masing anggota ensemble untuk menghasilkan suatu output baru. Kedua tahapan digambarkan sebagaimana pada Gambar 2.1.



Gambar 2.1. Tahapan dalam Metode Ensemble

Beberapa pendekatan telah dikembangkan untuk membangkitkan anggota-anggota ensemble dan secara umum terbagi menjadi dua golongan utama, yaitu sebagai berikut.

1. Golongan randomisasi, dimana prosedurnya adalah dengan membuat suatu himpunan model dari berbagai variasi model peramalan dengan menjaga data *training* tidak berubah (Shu & Burn, 2004).
2. Golongan *resampling*, dimana prosedur yang dilakukan adalah dengan merubah suatu himpunan dari data *training* (Breiman, 1996).

Zaier *et al.* (2010) menjelaskan bahwa terdapat dua metode yang paling dominan digunakan untuk mengkombinasikan output-output yang berbeda dari anggota ensemble, yaitu metode rata-rata (*averaging*) dan metode penggabungan (*stacking*).

2.5.1. Metode Rata-Rata (*Averaging*)

Pada metode *averaging*, output dari ensemble didapatkan dengan menghitung rata-rata dari output-output model anggota ensemble. Apabila K adalah jumlah dari anggota-anggota model individu dalam suatu ensemble, maka nilai peramalannya dapat dituliskan dalam persamaan berikut.

$$y_t = \frac{1}{N} \sum_{k=1}^K Z_{k,t} + e_t \quad (2.4)$$

dimana $Z_{k,t}$ merupakan nilai prediksi dari metode ke- k dan pengamatan ke- t . Penerapan dari pendekatan rata-rata menunjukkan hasil yang efektif dalam memperbaiki kualitas model peramalan tunggal, dimana metode ini cenderung mengurangi nilai indeks RMSE peramalan model tersebut (Murphy, 1988).

2.5.2. Metode Penggabungan (*Stacking*)

Ide dari metode *stacking* adalah dengan mengkombinasikan model level lebih tinggi dan model lebih rendah untuk mencapai akurasi prediksi yang lebih besar. Nilai peramalan ensemble dari

kombinasi *stacking* dapat dihitung menggunakan persamaan berikut.

$$y_t = \frac{1}{N} \sum_{k=1}^K Z_{k,t} + e_t \quad (2.5)$$

dimana $Z_{k,t}$ merupakan nilai prediksi dari metode ke- k pengamatan ke- t , dan C_k adalah suatu konstanta yang diestimasi dengan cara meminimumkan fungsi G . Adapun fungsi G memiliki persamaan matematis sebagai berikut.

$$G = \sum_{t=1}^n \left[y_t - \sum_{k=1}^K C_k Z_{k,t} \right]^2 \quad (2.6)$$

dimana syarat $\sum_{k=1}^K C_k = 1$ dan $0 \leq C_k \leq 1$. Suatu fungsi G yang diminimalisasi berdasarkan Breimann (1996) mampu memperbaiki kemampuan generalisasi dari suatu model.

2.6. Evaluasi Kebaikan Model Peramalan

Dalam mengidentifikasi apakah model yang telah diperoleh cukup baik dalam meramalkan suatu pengamatan, perlu dilakukan evaluasi kebaikan model yang digunakan. Pada penelitian ini, evaluasi kebaikan model peramalan dapat dilakukan dengan beberapa cara yaitu sebagai berikut.

2.6.1. Root Mean Square Error (RMSE)

Evaluasi kebaikan model peramalan yang paling umum digunakan adalah *Root Mean Square Error*. RMSE adalah nilai akar dari rata-rata kuadrat bias peramalan. Adapun bias peramalan dapat diartikan sebagai selisih antara nilai prediksi dengan nilai pengamatan sebenarnya. Rumusan RMSE dapat diformulasikan sebagai berikut (Wei, 2006).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - \hat{x}_i)^2}{n}} \quad (2.7)$$

dimana:

x_i : Nilai observasi pada periode *training* ke- i

\hat{x}_i : Nilai peramalan pada periode *training* ke- i

n : Banyaknya peramalan pada periode *training*

RMSE sangat dipengaruhi oleh *outlier*, sehingga dapat mempengaruhi akurasi kebaikan peramalan.

2.6.2. Mean Percentage Error (MPE)

Mean Percentage Error (MPE) merupakan suatu ukuran dalam mengetahui bias dari peramalan (Wei, 2006). Sebuah peramalan dikatakan bias ketika nilai MPE $\neq 0$. Sebaliknya, suatu peramalan dikatakan tidak bias apabila MPE bernilai 0. Adapun rumusan dari MPE dapat dituliskan sebagai berikut.


$$MPE = \left(\frac{1}{n} \sum_{i=1}^n \frac{x_i - \hat{x}_i}{x_i} \right) 100\% \quad (2.8)$$

Dimana x_i adalah nilai observasi pada periode *training* ke- i , \hat{x}_i adalah nilai peramalan pada periode *training* ke- i , dan n adalah banyaknya peramalan pada periode *training*. Pengujian kebaikan model menggunakan MPE hanya dapat dilakukan pada data yang tidak terdapat nilai nol (Wei, 2006)

2.6.3. Rank Histogram

Rank Histogram atau diagram Talagrand merupakan sebuah metode untuk mengevaluasi kebaikan peramalan ensemble, dimana evaluasi kebaikan peramalan ensemble ditinjau berdasarkan pola persebaran peramalannya. Adapun prosedur pembuatan *rank histogram* adalah dengan mengurutkan anggota ensemble sebanyak n dari nilai terendah ke tertinggi, kemudian

menentukan letak pengamatan sebenarnya pada anggota ensemble (Toth *et al.*, 2002). Kriteria *rank histogram* yang baik adalah membentuk garis lurus, dimana setiap anggota ensemble memiliki frekuensi yang sama. Berikut adalah garis besar interpretasi dari *rank histogram* (Hamill, 2001).



Gambar 2.2. Interpretasi Kriteria *Rank Histogram*

Untuk lebih memperjelas mengenai cara pembuatan *rank histogram*, Houtekamer (2000) menjelaskan langkah-langkah yang harus dilakukan sebagai berikut.

- 1) Urutkan nilai peramalan dari yang terkecil hingga yang terbesar. Misalkan diketahui nilai peramalan dari 5 model peramalan antara lain sebagai berikut: {0.25, 1.49, 4.2, 0.7, 2.17}.
- 2) Tentukan nilai bar berdasarkan nilai peramalan yang telah diurutkan pada langkah sebelumnya. Terdapat enam bar yang terbentuk dengan keterangan sebagai berikut.
 - Bar 1 : Bernilai di bawah 0,25
 - Bar 2 : Bernilai di antara 0,25 dan 0,7
 - Bar 3 : Bernilai di antara 0,7 dan 1,49
 - Bar 4 : Bernilai di antara 1,49 dan 2,17
 - Bar 5 : Bernilai di antara 2,17 dan 4,2
 - Bar 6 : Bernilai di atas 4,2

- 3) Tempatkan nilai observasi pada bin yang tepat. Idealnya, nilai observasi yang besar ditempatkan pada lokasi yang tersebar rata.
- 4) Buat histogram dengan data yang baru, dimana histogram berdistribusi uniform. Dengan kata lain, setiap bar sewajarnya merepresentasikan skenario yang sama seperti histogram sebelumnya (Houtemaker, 2000).

2.7. *Bayesian Model Averaging (BMA)*

Istilah *Bayesian Model Averaging* pertama kali digagas oleh Raftery *et al.* pada tahun 2005, dimana ide dari penggunaan metode ini adalah mengkalibrasikan seluruh model ensemble menjadi satu persamaan yang merepresentasikan semua model ensemble yang terlibat. Adapun pengkalibrasian model dilakukan dengan alasan peramalan ensemble cenderung memiliki sifat *undispersive* (terpusat pada suatu titik tertentu dengan varians rendah) atau *overdispersive* (varians tinggi), dimana hal ini dapat menyebabkan hasil peramalan yang dihasilkan menjadi bias. Mekanisme dari *Bayesian Model Averaging* secara umum adalah memberikan bobot yang tepat terhadap peramalan ensemble, dimana bobot yang diberikan berdasarkan pada kemampuan prediksi dari masing-masing model ensemble yang terlibat. Apabila diketahui $f = f_1, f_2, \dots, f_K$ adalah prediksi ensemble yang didapatkan dari K model yang berbeda, maka setiap peramalan ensemble dari f_k , ($k= 1,2,\dots,K$) berkaitan dengan suatu pdf bersyarat $g_k (y|f_k)$ yang dapat diartikan sebagai pdf bersyarat dari y pada f_k , dimana y adalah peramalan ensemble yang terkalibrasi dan f_k adalah peramalan terbaik dalam ensemble. Secara matematis, model prediksi menggunakan *Bayesian Model Averaging* untuk peramalan *ensemble* dapat dinyatakan dalam persamaan berikut (Raftery *et al.*, 2005).

$$p(y | f_1, f_2, \dots, f_K) = \sum_{k=1}^K w_k g_k (y | f_k) \quad (2.9)$$

dengan w_k menunjukkan probabilitas posterior bahwa peramalan ke- k adalah peramalan terbaik yang selalu positif dan jika

dijumlahkan akan bernilai sama dengan satu. w_k dapat dilihat sebagai bobot yang mencerminkan kemampuan prediksi atau kontribusi dari masing-masing model selama periode *training* (Vrugt *et al.*, 2008). Persamaan pdf dari *Bayesian Model Averaging* bersifat kondisional tergantung dari masing-masing modelnya. *Bayesian Model Averaging* mempunyai sifat optimalitas dalam bentuk interval dan penggunaannya telah menunjukkan kinerja yang baik dalam berbagai simulasi dan situasi *real* (Raftery & Zheng, 2003). Dalam penelitian ini, variabel yang diteliti adalah curah hujan dimana telah dijelaskan oleh Slougher *et al.* (2007) bahwa komponen fungsi pdf dari curah hujan dalam *Bayesian Model Averaging* berdistribusi gamma. Komponen pdf gamma terhadap curah hujan dijelaskan menggunakan persamaan berikut.

$$g_k(y | f_k) = \frac{1}{\beta_k^{\alpha_k} \Gamma(\alpha_k)} y^{\alpha_k - 1} \exp\left(\frac{-y}{\beta_k}\right) \quad (2.10)$$

dimana parameter distribusi gamma bergantung dari anggota peramalan ensemble, f_k , yang dijelaskan dalam hubungan sebagai berikut.

$$\mu_k = b_0 + b_1 f_k \quad (2.11)$$

dan

$$\sigma_k = c_0 + c_1 f_k \quad (2.12)$$

dimana $\mu_k = \alpha_k \beta_k$ adalah *mean* atau rata-rata dari distribusi, dan $\sigma_k = \sqrt{\alpha_k} \beta_k$ adalah standar deviasi (Slougher *et al.*, 2010). Dalam penelitian ini ditetapkan parameter standar deviasi konstan untuk semua anggota ensemble. Hal ini menyebabkan berkurangnya jumlah parameter yang diestimasi serta mengurangi resiko *overfitting*.

2.8. *Expectation Maximization (EM)*

Algoritma EM adalah suatu prosedur iteratif dari estimasi maksimum likelihood pada data yang hilang atau tidak lengkap, dimana data yang hilang tidak harus data aktual (Dempster *et al.*, 1977). Dalam penerapannya pada metode *Bayesian Model Averaging*, digunakan suatu kuantitas $h_{k,t}$ yang tidak teramati dan akan mempunyai nilai sama dengan 1 apabila anggota ensemble k merupakan peramalan terbaik pada waktu ke- t dan bernilai 0 apabila sebaliknya. Untuk tahapan awal, perlu dilakukan penentuan nilai awal dari bobot dan varians untuk di kemudian algoritma EM dapat berjalan secara iteratif antara *expectation* dan *maximization* hingga diperoleh kondisi yang konvergen. Pada saat langkah *expectation*, nilai $h_{k,t}$ diestimasi kembali dengan diberikan nilai bobot dan varians terbaru sesuai dengan persamaan sebagai berikut.

$$h_{k,t}^{(j)} = \frac{w_k g(y_t | f_{k,t}, \sigma^{(j-1)})}{\sum_{l=1}^K w_l g(y_t | f_{l,t}, \sigma^{(j-1)})} \quad (2.13)$$

dengan j merupakan jumlah iterasi dan $g(y_t | f_{k,t}, \sigma^{(j-1)})$ adalah pdf bersyarat dari anggota k yang berpusat pada y_t . Pada step *maximization*, nilai bobot dan varians diperbarui menggunakan estimasi dari $h_{k,t}$ seperti pada persamaan berikut.

$$w_k^{(j)} = \frac{1}{n} \sum_{t=1}^n h_{k,t}^{(j)} \quad (2.14)$$

dan

$$\sigma^{2(j)} = \frac{1}{n} \sum_{t=1}^n \sum_{k=1}^K h_{k,t}^{(j)} (y_t - f_t)^2 \quad (2.15)$$

dimana n adalah jumlah observasi dalam *training* set. Dalam iterasi antara *expectation* dan *maximization*, algoritma EM

memperbarui nilai w_k dan σ^2 . Iterasi dihentikan apabila nilai yang dihasilkan sudah konvergen dengan toleransi yang sangat kecil (Vrugt *et al.*, 2008).

2.9. Ensemble Model Output Statistics (EMOS)

Istilah *Ensemble Model Output Statistics* (EMOS) pertama kali diperkenalkan oleh Gneiting *et al.* (2004), dimana metode ini adalah pengembangan dari metode *Model Output Statistics* yang dikembangkan oleh Glahn & Lowry (1972). Prosedur *post-processing* menggunakan EMOS dilakukan dengan cara mengkonversi model ensemble baku dengan probabilitas diskrit menjadi model ensemble dengan probabilitas interval dalam bentuk pdf. Apabila diketahui $f = (f_1, f_2, \dots, f_K)$ adalah vektor dari K model ensemble, maka model prediksi EMOS dapat dituliskan dalam persamaan sebagai berikut.

$$p(y | f_k) \sim g(m, \sigma) \quad (2.16)$$

dimana $g(m, \sigma)$ adalah fungsi densitas parametrik dengan m dan σ masing-masing adalah parameter *shape* dan *scale* yang tergantung pada indikator model ensemble baku yang digunakan. Sama seperti metode sebelumnya, indikator yang digunakan dalam peramalan untuk dilakukan monitoring kekeringan adalah curah hujan. Sehingga komponen fungsi pdf yang digunakan berdistribusi Gamma. Dengan demikian, komponen pdf gamma terhadap curah hujan dapat dijelaskan dengan menggunakan persamaan berikut.

$$p(y | f_k) = \frac{1}{\beta_k^{\alpha_k} \Gamma(\alpha_k)} y^{\alpha_k - 1} \exp\left(\frac{-y}{\beta_k}\right) \quad (2.17)$$

Dari persamaan (2.15), maka parameter distribusi gamma bergantung dari anggota peramalan ensemble f_k , yang dijelaskan dalam hubungan seperti berikut.

$$\mu = a + b_1 f_1 + \dots + b_k f_k \quad (2.18)$$

dan

$$\sigma^2 = c + dS^2 \quad (2.19)$$

Dimana a dan b_1, \dots, b_k adalah parameter regresi, $c+d$ adalah parameter distribusi, dan S^2 adalah varians dari data peramalan *ensemble* (Gneiting *et al.*, 2004). Kemudian $\mu_k = \alpha_k \beta_k$ adalah *mean* dari distribusi, dan $\sigma_k = \sqrt{\alpha_k} \beta_k$ adalah standar deviasi (Sloughter *et al.*, 2010).

2.10. *Continous Ranked Probability Score (CRPS)*

Hasil peramalan dari kalibrasi ensemble berupa taksiran interval dalam bentuk pdf. Kondisi ini mengakibatkan evaluasi model kebaikan tidak dapat dilakukan dengan prosedur pada umumnya seperti tinjauan melalui MSE dan MAPE. Untuk itu, evaluasi kebaikan model yang dilakukan adalah dengan menggunakan prosedur CRPS. *Continous Rank Probability Score* berkaitan dengan probabilitas rank yang membandingkan distribusi hasil peramalan dengan pengamatan yang keduanya direpresentasikan dalam bentuk cdf. Adapun persamaan matematis dari prosedur CRPS adalah sebagai berikut (Hersbach, 2000).

$$CRPS = \frac{1}{n^f} \sum_{i=1}^n \int_{x=-\infty}^{\infty} (F_i^f(x) - F_i^0(x))^2 dx \quad (2.20)$$


dengan,

$F_i^f(x)$: cdf dari hasil peramalan ke- i

$F_i^0(x)$: cdf dari pengamatan asli ke- i

n^f : jumlah peramalan.

Ilustrasi dari CRPS dapat dilihat pada Gambar 2.3 berikut (Pena, 2011).



Gambar 2.3 Ilustrasi CRPS

Gambar 2.3 menunjukkan CDF dari suatu peramalan, daerah antara peramalan dan pengamatan digambarkan oleh persegi panjang yang dibentuk oleh dua fungsi. Terdapat beberapa kelebihan dalam menggunakan CRPS sebagai evaluasi kebaikan pada hasil peramalan. Beberapa diantaranya yaitu mudah untuk ditafsirkan, peka terhadap seluruh nilai parameter yang diuji, serta ketajaman CRPS menyebar pada setiap hasil ramalan. Hasil dari CRPS berupa suatu nilai dimana peramalan dapat dikatakan baik apabila nilai CRPS yang dihasilkan sangat kecil atau mendekati nilai nol (Hersbach, 2000).

(halaman ini sengaja dikosongkan)

BAB III

METODOLOGI PENELITIAN

3.1. Sumber Data

Terdapat dua sumber data yang digunakan dalam penelitian ini, dimana sumber data terbagi menjadi data observasi lapangan dan berdasarkan perhitungan satelit. Mengenai rincian data penelitian yang digunakan antara lain akan dipaparkan sebagai berikut.

1. Sumber data pertama diperoleh dari *website* resmi *North-American Multi Model Ensemble* (NMME). Data NMME berupa data hasil peramalan satelit secara global berdasarkan letak koordinat dan dibatasi hanya untuk koordinat Provinsi Nusa Tenggara Timur.
2. Sumber data kedua diperoleh dari *website* resmi *European Centre for Medium-Range Weather Forecast* (ECMWF). Data yang diperoleh berupa data observasi satelit secara global dimana pengukuran yang dilakukan berdasarkan letak koordinat yang dibatasi hanya untuk koordinat Provinsi Nusa Tenggara Timur.

3.2. Variabel Penelitian

Variabel yang digunakan dalam penelitian “Perbandingan Bias Koreksi *Bayesian Model Averaging-Expectation Maximization* (BMA-EM) dengan *Ensemble Model Output Statistics* (EMOS) pada Data *Numerical Weather Prediction* dalam Monitoring Pola Kekeringan di Provinsi Nusa Tenggara Timur” antara lain sebagai berikut.

1. Untuk data NMME, variabel penelitian berupa data spasial peramalan curah hujan bulanan melalui observasi satelit di Provinsi Nusa Tenggara Timur pada koordinat 8^0 - 12^0 LS dan 118^0 - 125^0 BT. Terdapat lima model data peramalan satelit yang akan dikalibrasikan, diantaranya ditampilkan di Tabel 3.1 pada halaman berikutnya antara lain sebagai berikut.

Tabel 3.1 Model Peramalan yang Digunakan Dalam Kalibrasi

No	Model Peramalan
1	Model 1 (NMME CMC1-CanCM3)
2	Model 2 (NMME CMC2-CanCM4)
3	Model 3 (NMME COLA-RSMAS-CCSM3)
4	Model 4 (NMME COLA-RSMAS-CCSM4)
5	Model 5 (NMME GFDL-CM2p1-aer04)

Pada data NMME, data peramalan curah hujan diukur berdasarkan peramalan jumlah keseluruhan curah hujan dalam satu bulan (*Total Precipitation*), dimana penentuan *total precipitation* secara bulanan dilakukan di setiap pertengahan bulan. Data peramalan curah hujan setiap bulan terbagi atas beberapa data berdasarkan *grid* koordinat yang telah ditentukan, dimana ukuran *grid* yang digunakan adalah 1x1.

2. Untuk data ECMWF, variabel penelitian berupa data spasial hasil pengukuran satelit secara *real time* terhadap curah hujan bulanan di Provinsi Nusa Tenggara Timur pada koordinat 8^0 - 12^0 LS dan 118^0 - 125^0 BT. Pada data ECMWF pengukuran curah hujan bulanan dilakukan di setiap akhir bulan, dimana nilai curah hujan bulanan ditentukan berdasarkan jumlah keseluruhan curah hujan per satu bulan (*Total Precipitation*). Data curah hujan bulanan terbagi atas beberapa data berdasarkan *grid* koordinat yang telah ditentukan, dimana ukuran *grid* yang digunakan adalah 1x1.

3.3. Struktur Data

Dalam memudahkan mengetahui pola data maka dibentuklah struktur data berdasarkan variabel yang digunakan, baik untuk variabel prediktor (peramalan curah hujan) maupun variabel respon (hasil observasi curah hujan secara *real time*).

Adapun struktur data untuk data NMME (data peramalan curah hujan ditunjukkan pada Tabel 3.2 berikut.

Tabel 3.2 Struktur Data NMME

No	Periode	Derajat Lintang	Derajat Bujur				
				1	2	...	5
1	16 Jan 2011	8 ⁰ LS	118 ⁰ BT	X _{1,1}	X _{2,1}	...	X _{5,1}
2	16 Jan 2011	9 ⁰ LS	118 ⁰ BT	X _{1,2}	X _{2,2}	...	X _{5,2}
⋮							
39	16 Jan 2011	11 ⁰ S	125 ⁰ BT	X _{1,39}	X _{2,39}	...	X _{5,39}
40	16 Jan 2011	12 ⁰ S	125 ⁰ BT	X _{1,40}	X _{2,40}	...	X _{5,40}
41	15 Feb 2011	8 ⁰ LS	118 ⁰ BT	X _{1,41}	X _{2,41}	...	X _{5,41}
42	15 Feb 2011	9 ⁰ LS	118 ⁰ BT	X _{1,42}	X _{2,42}	...	X _{5,42}
⋮							
79	15 Feb 2011	11 ⁰ LS	125 ⁰ BT	X _{1,79}	X _{2,79}	...	X _{5,79}
80	15 Feb 2011	12 ⁰ LS	125 ⁰ BT	X _{1,80}	X _{2,80}	...	X _{5,80}
⋮							
2841	16 Des 2016	11 ⁰ LS	125 ⁰ BT	X _{1,2841}	X _{2,2841}	...	X _{5,2841}
2842	16 Des 2016	12 ⁰ LS	125 ⁰ BT	X _{1,2842}	X _{2,2842}	...	X _{5,2842}
⋮							
2879	16 Des 2016	11 ⁰ LS	125 ⁰ BT	X _{1,2879}	X _{2,2879}	...	X _{5,2879}
2880	16 Des 2016	12 ⁰ LS	125 ⁰ BT	X _{1,2880}	X _{2,2880}	...	X _{5,2880}

Keterangan:

Model 1: NMME CMC1-CanCM3

Model 2: NMME CMC2-CanCM4

Model 3: NMME COLA-RSMAS-CCSM3

Model 4: NMME COLA-RSMAS-CCSM4

Model 5: NMME GFDL-CM2p1-aer04

Berikutnya adalah struktur data untuk data ECMWF, yaitu data hasil observasi curah hujan bulanan (*Total Precipitation*) secara *real time* yang ditunjukkan seperti pada Tabel 3.3 sebagai berikut.

Tabel 3.3 Struktur Data ECMWF

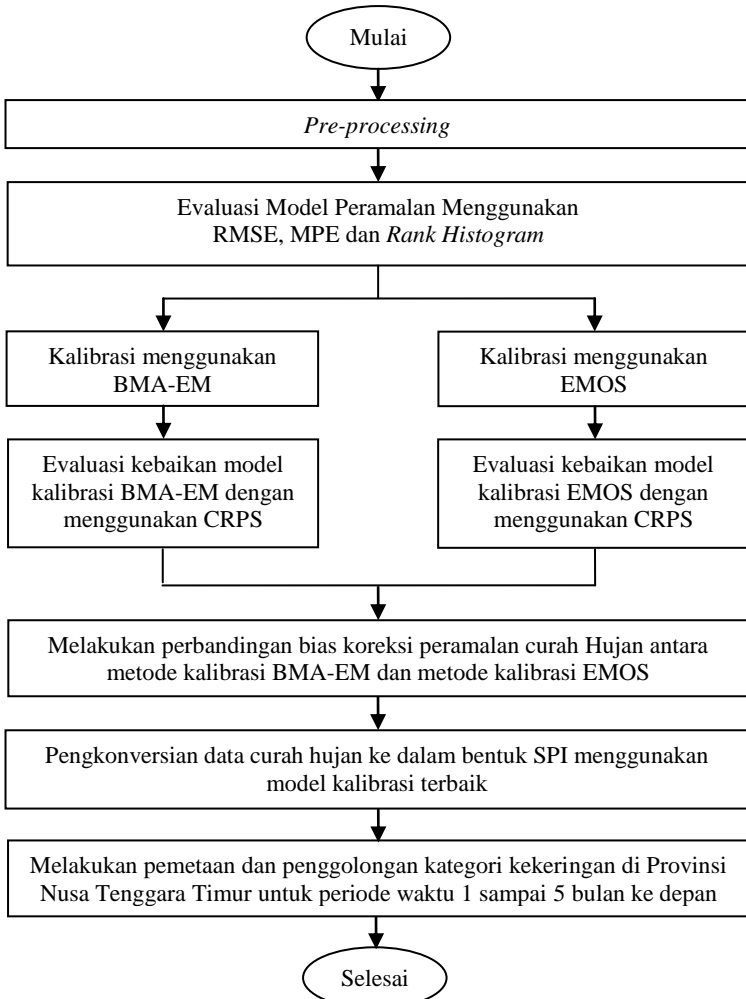
No	Periode	Derajat Lintang	Derajat Bujur	Curah Hujan
1	31 Jan 2011	8 ⁰ LS	118 ⁰ BT	Y ₁
2	31 Jan 2011	9 ⁰ LS	118 ⁰ BT	Y ₂
⋮				
5	31 Jan 2011	12 ⁰ LS	118 ⁰ BT	Y ₈
6	31 Jan 2011	8 ⁰ LS	119 ⁰ BT	Y ₉
⋮				
39	31 Jan 2011	11 ⁰ S	125 ⁰ BT	Y ₃₉
40	31 Jan 2011	12 ⁰ S	125 ⁰ BT	Y ₄₀
41	28 Feb 2011	8 ⁰ LS	119 ⁰ BT	Y ₄₁
42	28 Feb 2011	9 ⁰ LS	118 ⁰ BT	Y ₄₂
⋮				
45	15 Feb 2011	12 ⁰ LS	118 ⁰ BT	Y ₄₈
46	15 Feb 2011	8 ⁰ LS	119 ⁰ BT	Y ₄₉
⋮				
79	15 Feb 2011	11 ⁰ LS	125 ⁰ BT	Y ₈₀
80	15 Feb 2011	12 ⁰ LS	125 ⁰ BT	Y ₈₀
⋮				
2779	31 Des 2016	11 ⁰ S	125 ⁰ BT	Y ₂₇₇₉
2880	31 Des 2016	12 ⁰ S	125 ⁰ BT	Y ₂₈₈₀

3.4. Langkah Analisis

Langkah analisis yang akan dilakukan dalam penelitian ini diantaranya adalah sebagai berikut.

1. Evaluasi model peramalan pada data NMME terhadap data observasi menggunakan *time series plot* dan *rank histogram*.
2. Kalibrasi seluruh model peramalan pada data NMME dengan data hasil *pre-process* menggunakan metode *Bayesian Model Averaging* dengan pendekatan *Expectation Maximization* (BMA-EM).
3. Evaluasi kebaikan model hasil kalibrasi BMA-EM menggunakan *Continous Rank Probability Score* (CRPS).
4. Kalibrasi seluruh model peramalan pada data NMME dengan data hasil *pre-process* menggunakan metode *Ensemble Model Output Statistics* (EMOS).
5. Evaluasi kebaikan model hasil kalibrasi EMOS menggunakan CRPS.
6. Melakukan perbandingan *error* antara hasil peramalan curah hujan menggunakan kalibrasi BMA-EM dan hasil peramalan curah hujan menggunakan kalibrasi EMOS. Dari hasil perbandingan ini akan didapatkan metode kalibrasi terbaik.
7. Setelah didapatkan metode kalibrasi yang tepat, selanjutnya melakukan konversi data peramalan curah hujan ke dalam bentuk *Standardized Precipitation Index* (SPI).
8. Memetakan SPI berdasarkan *grid* yang diperoleh dan mengkategorikan jenis kekeringan dalam jangka waktu satu bulan sampai lima bulan ke depan di Nusa Tenggara Timur.

Berdasarkan langkah analisis yang telah dijelaskan sebelumnya, dapat digambarkan bentuk diagram alir penelitian pada halaman selanjutnya sebagai berikut.



Gambar 3.2. Diagram Alir Penelitian

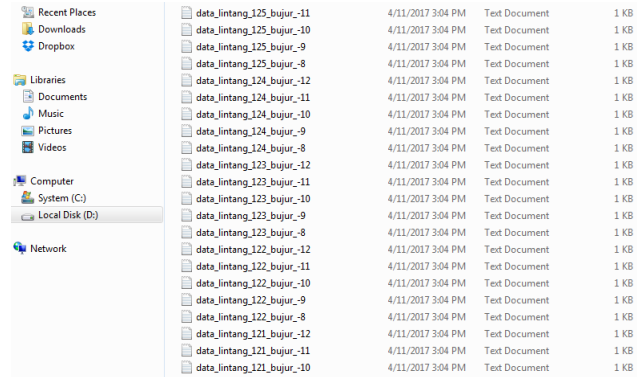
BAB IV

ANALISIS DAN PEMBAHASAN

Pada bab berikut akan dilakukan analisis data dan pembahasan terkait hasil pengolahan data. Sesuai dengan yang telah dijelaskan di permasalahan penelitian pada Bab I sebelumnya, output dari analisis dan pembahasan yang akan dilakukan berupa hasil kalibrasi beberapa model hasil peramalan satelit curah hujan terhadap data hasil pengamatan curah hujan secara *real time*. Melalui hasil kalibrasi ini akan dibentuk satu model peramalan yang lebih reliabel yang kemudian digunakan untuk meramalkan curah hujan sehingga dapat dilakukan monitoring terhadap bencana kekeringan.

4.1. Pre-Processing Data Curah Hujan Bulanan

Sebelum dilakukan analisis data, terlebih dahulu dilakukan *pre-processing* terhadap data yang akan digunakan, yaitu data curah hujan bulanan. Pada proses *pre-processing* dalam analisis ini dibagi menjadi dua bagian, yaitu *pre-processing* untuk penggabungan data dan *pre-preprocessing* untuk kalibrasi data. *Pre-processing* yang pertama adalah *pre-processing* untuk penggabungan data dari dua sumber yang berbeda. Terdapat dua sumber data yang digunakan yaitu data NMME sebagai data peramalan satelit dan data ECMWF sebagai data observasi *surface* secara *real time*. Tahapan pertama dalam *pre-processing* adalah mengubah format data ECMWF yang masih dalam bentuk format *.nc* ke dalam bentuk *.txt*. Proses konversi dilakukan dengan menggunakan *script* yang tertera pada Lampiran 2. Hasil konversi data ke dalam format *.txt* menghasilkan jumlah *file* sebanyak 40 *file*, dimana masing-masing *file* memiliki informasi data secara *time series* dari hasil observasi *surface* secara *real time* terhadap curah hujan pada masing-masing koordinat. Adapun Gambar 4.1 berikut menampilkan 40 *file* hasil konversi berdasarkan koordinat yang digunakan.



Gambar 4.1. Data Hasil Konversi format *.nc* ke Bentuk *.txt*

Setelah didapatkan format data *.txt* seperti pada Gambar 4.1 di atas, tahapan selanjutnya adalah melakukan penggabungan data ke dalam bentuk format *.csv*. menggunakan *script* yang tertera pada Lampiran 3. Hasil dari penggabungan data tersebut berupa data matriks berukuran 40x72, dimana 40 merupakan jumlah koordinat yang digunakan dalam analisis dan 72 merupakan jumlah periode bulan yang digunakan dalam analisis yaitu dari Januari 2011 sampai dengan Desember 2012. Gambaran mengenai matriks data secara lebih jelas dapat ditunjukkan pada Gambar 4.2 berikut.

	A	B	C	D	E	F	G	H	I	J	K	L	M	
1	V1		1	2	3	4	5	6	7	8	9	10	11	12
2	12011	0.01226	0.013158	0.011326	0.008755	0.008937	0.012244	0.013455	0.012046	0.007849	0.008919	0.009363	0.013232	
3	22011	0.010071	0.012049	0.011771	0.006919	0.006855	0.010523	0.012743	0.013078	0.007188	0.007921	0.008824	0.012511	
4	32011	0.007521	0.007308	0.005717	0.007135	0.006697	0.0075	0.007466	0.006401	0.007188	0.006428	0.008348	0.007339	
5	42011	0.006972	0.006616	0.005714	0.006828	0.006506	0.00637	0.006912	0.005766	0.006398	0.005451	0.007887	0.006857	
6	52011	0.002307	0.003072	0.00401	0.00315	0.002386	0.001807	0.002631	0.003587	0.002277	0.001424	0.002827	0.002503	
7	62011	0.000415	0.000378	0.000251	0.000469	0.000331	0.000145	0.000296	0.000221	0.000394	5.95E-05	0.000216	0.000295	
8	72011	0.000478	0.000074	0.000513	0.000776	0.000308	0.000268	0.000493	0.00042	0.000787	5.03E-05	0.000477	0.000665	
9	82011	7.47E-05	0.000137	9.92E-05	0.000156	4.77E-19	4.77E-19	0.00013	8.89E-05	0.000256	4.77E-19	4.77E-19	0.000123	
10	92011	0.000135	4.77E-19	4.77E-19	0.000201	0.000203	7.64E-05	5.33E-05	4.77E-19	0.000577	4.77E-19	9.34E-05	5.36E-05	
11	102011	0.001349	0.001189	0.000687	0.001594	0.000914	0.001015	0.000962	0.000789	0.001646	0.000606	0.001466	0.000967	
12	112011	0.003849	0.004466	0.003573	0.002649	0.002983	0.003735	0.003551	0.003293	0.002739	0.003058	0.002271	0.003597	
13	122011	0.006237	0.006508	0.00494	0.007321	0.005742	0.00551	0.005666	0.004517	0.007354	0.005019	0.005275	0.004948	
14	12012	0.013478	0.015725	0.014728	0.009679	0.01064	0.012703	0.018209	0.016153	0.009614	0.01011	0.011592	0.013734	
15	22012	0.008395	0.007143	0.005398	0.005901	0.007871	0.008333	0.007184	0.006156	0.006862	0.007384	0.007949	0.006968	
16	32012	0.009594	0.009366	0.008901	0.011569	0.009944	0.008872	0.008943	0.008313	0.010719	0.010702	0.007311	0.007789	
17	42012	0.00385	0.004144	0.00508	0.00317	0.003861	0.003713	0.004284	0.005408	0.003885	0.003993	0.003822	0.004662	
18	52012	0.004151	0.003365	0.001596	0.004417	0.0036	0.002772	0.003124	0.001759	0.004552	0.002172	0.00314	0.00308	
19	62012	0.000212	0.00033	0.000326	0.000693	0.000202	0.000104	0.000355	0.000266	0.000935	4.77E-19	0.000208	0.000398	
20	72012	0.000528	0.000391	0.000174	0.000955	0.000656	0.000351	0.000474	0.000193	0.000952	0.000157	0.000209	0.000414	
21	82012	4.77E-19	4.77E-19	4.77E-19	0.000185	4.77E-19	4.77E-19	4.77E-19	4.77E-19	0.00017	4.77E-19	4.77E-19	4.77E-19	
22	92012	0.000126	5.64E-05	5.32E-05	0.000131	9.14E-05	0.00031	9.59E-05	5.42E-05	0.000253	0.000215	4.77E-19	0.000216	
23	102012	0.001187	0.000929	0.000835	0.000869	0.000806	0.000823	0.000598	0.000651	0.001455	0.000696	0.000264	0.000391	

Gambar 4.2. Hasil Penggabungan Data ECMWF dalam Format *.csv*

Tahapan ketiga adalah mengubah format data matriks ECMWF ke dalam bentuk format NMME. Perubahan format dilakukan dengan cara mengkonversikan keterangan angka urutan koordinat ke dalam bentuk kombinasi lintang bujur sebenarnya. Adapun Tabel 4.1 menjelaskan mengenai keterangan urutan koordinat ke dalam bentuk koordinat lintang bujur yang sebenarnya.

Tabel 4.1 Daftar Keterangan Kode Koordinat ke Dalam Bentuk Koordinat Lintang-Bujur yang Sebenarnya

Kode Koordinat	Keterangan Koordinat Sebenarnya
1	8 ⁰ LS-118 ⁰ BT
2	8 ⁰ LS-119 ⁰ BT
3	8 ⁰ LS-120 ⁰ BT
⋮	⋮
39	8 ⁰ LS-120 ⁰ BT
40	8 ⁰ LS-125 ⁰ BT

Susunan koordinat ke-1 sampai dengan koordinat ke-40 diurutkan secara vertikal untuk satu periode pertama, kemudian susunan tersebut dilakukan perulangan dibawahnya pada periode kedua, hingga seterusnya sampai dengan periode terakhir, yaitu bulan ke-72 atau Desember 2016. Gambar 4.3 adalah struktur data excel dari data ECWF yang sudah disatukan dengan data NMME dalam bentuk .csv.

	A	B	C	D	E	F	G	H	I
1	Longitude	Latitude	Period	Obs	M111	M211	M311	M411	M511
2	118E	8S	Jan-11	8.75548	12.34924	14.11391	7.879169	10.21303	9.474804
3	118E	9S	Jan-11	8.93692	11.93754	13.4469	8.936979	12.85257	10.76259
4	118E	10S	Jan-11	12.2598	11.65674	12.59587	8.627231	16.04089	11.1179
5	118E	11S	Jan-11	13.1581	11.80664	11.13743	8.337238	17.3063	11.36831
6	118E	12S	Jan-11	11.3256	11.95698	9.679864	8.245447	16.05336	11.06062
7	119E	8S	Jan-11	7.84884	11.87922	12.7259	7.812271	10.78151	9.656169
8	119E	9S	Jan-11	8.91886	11.80491	12.98639	8.341893	12.58054	10.84789
9	119E	10S	Jan-11	12.2442	11.86669	12.88185	8.203115	15.79953	11.18424
10	119E	11S	Jan-11	13.4554	12.37386	11.57894	8.084979	17.2448	11.42437
11	119E	12S	Jan-11	12.0458	12.88103	10.27559	8.139449	16.16665	11.48935
12	120E	8S	Jan-11	8.78271	11.45111	11.01561	7.650017	11.79711	10.00635
13	120E	9S	Jan-11	7.68935	11.69994	12.37209	7.649024	12.49285	11.1632
14	120E	10S	Jan-11	9.3626	12.09306	13.15919	7.452871	15.37903	11.46613
15	120E	11S	Jan-11	13.232	12.95835	12.07055	7.364385	16.8273	11.673
16	120E	12S	Jan-11	12.4037	13.82408	10.98105	7.541158	16.43903	11.97461
17	121E	8S	Jan-11	7.04501	11.06447	9.481145	7.42527	13.25643	10.35653
18	121E	9S	Jan-11	6.18005	11.62823	11.81438	7.175201	12.86417	11.47851
19	121E	10S	Jan-11	7.00389	12.34448	13.40198	6.55777	15.6251	11.74802

Gambar 4.3. Data Gabungan NMME dan ECMWF dalam Format .csv

Susunan data pada Gambar 4.3 tersebut nantinya yang akan dilakukan untuk evaluasi peramalan beserta kalibrasi model peramalannya. Selanjutnya akan dijelaskan *pre-processing* untuk kalibrasi data peramalan. Pada tahapan ini, komponen data yang telah menjadi satu akan dipartisi sesuai koordinatnya. Hal ini mengingat bahwa kalibrasi model peramalan akan dilakukan pada masing-masing koordinat. Prosedur pemisahan data berdasarkan koordinat dilakukan menggunakan *script* seperti yang tertera pada Lampiran 7. Berikut adalah ilustrasi dari hasil pemisahan data berdasarkan koordinat.

Name	Date modified	Type	Size
databma1	5/29/2017 10:14 PM	Microsoft Office E...	5 KB
databma2	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma3	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma4	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma5	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma6	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma7	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma8	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma9	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma10	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma11	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma12	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma13	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma14	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma15	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma16	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma17	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma18	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma19	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma20	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma21	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma22	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma23	5/16/2017 11:50 AM	Microsoft Office E...	6 KB
databma24	5/16/2017 11:50 AM	Microsoft Office E...	6 KB

Gambar 4.4. Hasil Partisi Data untuk Kalibrasi Berdasarkan Koordinat

Setelah dilakukan partisi seperti pada Gambar 4.4 di atas, maka data sudah siap untuk dilakukan kalibrasi model peramalan menggunakan kedua metode kalibrasi, yaitu menggunakan *Bayesian Model Averaging-Expectation Maximization* (BMA-EM) dan *Ensemble Model Output Statistics* (EMOS).

4.2. Statistika Deskriptif Data Curah Hujan Rata-Rata Bulanan di Nusa Tenggara Timur

Sebelum dilakukan evaluasi model peramalan beserta metode kalibrasinya, terlebih dahulu data akan dianalisis secara

deskriptif untuk mengetahui karakteristik data curah hujan di Provinsi Nusa Tenggara Timur. Interpretasi secara deskriptif yang dilakukan dibagi menjadi dua bagian, yaitu interpretasi deskriptif secara umum dan interpretasi deskriptif secara spesifik. Adapun interpretasi mengenai data curah hujan di Provinsi Nusa Tenggara Timur secara umum dapat dipaparkan secara singkat melalui Tabel 4.2 berikut.

Tabel 4.2 Analisis Deskriptif Data Curah Hujan di NTT Secara Umum

No	Kategori	Periode	Koordinat	Curah Hujan (mm)
1	Curah Hujan Rata-Rata Bulanan Terbesar	Januari 2013	8 ⁰ LS dan 120 ⁰ BT	12,7171 mm/hari
2	Curah Hujan Rata-Rata Bulanan Terkecil	Juni – September 2011	Seluruh Wilayah NTT	0,00016 mm/hari
		Juni – November 2012		
		Agustus – September 2013		
		Agustus – November 2014		
		Juni – November 2015		

Curah hujan rata-rata bulanan di Provinsi Nusa Tenggara Timur terdiri dari 40 ragam titik lintang-bujur. Dari observasi yang dilakukan antara Januari 2011 sampai dengan Desember 2016, diketahui bahwa curah rata-rata bulanan terbesar terjadi pada bulan Januari 2013, pada koordinat 8⁰LS dan 119⁰BT dengan curah hujan sebesar 12,7171 mm/hari, dimana lokasi ini terletak di sebelah barat laut Pulau Flores, yaitu di sepanjang pesisir Labuan Bajo (Wilayah A). Sementara itu, untuk curah hujan bulanan terkecil terjadi pada bulan Juni 2011 sampai September 2011, Juni 2012 sampai November 2012, Agustus 2013 sampai September 2013, Agustus 2014 sampai November 2014, dan Juni 2015 sampai November 2015. Dimana pada periode tersebut, di

sepanjang wilayah koordinat Nusa Tenggara Timur hanya terjadi curah hujan sebesar 0,00016 mm/hari.

Tabel 4.3 Analisis Deskriptif Data Curah Hujan di NTT Secara Spesifik

Tinjauan Lokasi			
No	Kategori	Koordinat	Curah Hujan(mm)
1	Lokasi dengan rata-rata curah hujan terbesar (Sepanjang Periode)	8 ⁰ LS dan 120 ⁰ BT	4,4594 mm/hari
2	Lokasi dengan rata-rata curah hujan terkecil (Sepanjang Periode)	9 ⁰ LS dan 124 ⁰ BT	2,9064 mm/hari
Tinjauan Periode			
No	Kategori	Periode	Curah Hujan(mm)
1	Periode Terbasah (Seluruh Wilayah NTT)	Januari 2013	10,5155 mm/hari
2	Periode Terbasah (Seluruh Wilayah NTT)	September 2014	0,1475 mm/hari

Selanjutnya adalah analisis deskriptif curah hujan di seluruh wilayah Nusa Tenggara Timur berdasarkan dua tinjauan kategori. Berdasarkan tinjauan lokasi, tercatat bahwa lokasi dengan rata-rata curah hujan terbesar sepanjang periode terletak pada koordinat 8⁰LS dan 120⁰BT dengan curah hujan sebesar 4,4594 mm/hari. Adapun titik ini terletak di sebelah barat laut Pulau Flores, yaitu di sepanjang pesisir Labuan Bajo (Wilayah B). Sedangkan untuk lokasi dengan rata-rata curah hujan terkecil sepanjang periode terletak pada koordinat 9⁰LS dan 124⁰BT dengan rata-rata curah hujan bulanan sebesar 2,9064 mm/hari, dimana titik ini terletak di wilayah pesisir utara Pulau Timor, tepatnya Kota Atambua (Wilayah C). Sementara itu berdasarkan tinjauan periode, tercatat bahwa periode terbasah terjadi pada bulan Januari 2013, dimana rata-rata curah hujan untuk seluruh wilayah NTT pada periode tersebut sebesar 10,5155 mm/hari. Kemudian, periode terkering terjadi pada bulan September 2014, dimana rata-rata curah hujan untuk seluruh wilayah NTT pada periode tersebut sebesar 0,1475 mm/hari. Untuk memperjelas interpretasi mengenai wilayah-wilayah yang dijelaskan secara

deskriptif tersebut, berikut akan ditampilkan peta dari Provinsi Nusa Tenggara Timur pada Gambar 4.5



Keterangan: Wilayah A → Daerah dengan rata-rata curah hujan terbesar
 Wilayah B → Daerah terbasah sepanjang periode
 Wilayah C → Daerah terkering sepanjang periode

Gambar 4.5 Peta Nusa Tenggara Timur Beserta Lokasi Spesifik yang Diinterpretasikan

4.3. Evaluasi Model Peramalan Curah Hujan di Nusa Tenggara Timur

Dalam penelitian ini, terdapat lima model peramalan yang akan digunakan dalam proses kalibrasi. Akan tetapi, kelima model peramalan yang digunakan harus terlebih dahulu dievaluasi untuk mengetahui apakah model peramalan secara individu telah dapat memberikan hasil peramalan yang reliabel atau tidak. Peramalan dari lima model berbeda ini dilakukan dengan dua *lead time*, yaitu menggunakan *lead time* ke-1 dan *lead time* ke-4. Adapun tujuan digunakan dua *lead time* ini adalah untuk mengidentifikasi apakah peramalan dengan jangka yang lebih panjang (*lead* ke-4) masih dapat memberikan hasil peramalan yang cukup baik atau tidak. Evaluasi model peramalan dilakukan menggunakan *Root Mean Square Error* (RMSE), *Mean Percentage Error* (MPE), dan *rank histogram*. Penggunaan nilai RMSE adalah untuk mengetahui kebaikan suatu model peramalan

terhadap nilai observasi dan MPE digunakan untuk mengetahui seberapa besar bias peramalan terhadap nilai observasi. Adapun bias peramalan beserta nilai observasi akan ditampilkan melalui *time series plot*. Sementara itu, evaluasi menggunakan *rank histogram* digunakan untuk mengetahui pola karakteristik model peramalan ensemble terhadap data observasi.

4.3.1. Evaluasi Model Peramalan Curah Hujan untuk Lead ke-1

Seperti yang telah dijelaskan sebelumnya, evaluasi model peramalan curah hujan untuk 1 tahap ke depan dilakukan melalui tinjauan RMSE, MPE, dan *rank histogram*. Berikut akan ditampilkan terlebih dahulu tabel perbandingan jumlah bias, RMSE, dan MPE dari model peramalan pada koordinat 8⁰LS-118⁰BT di *lead* ke-1.

Tabel 4.4 Perbandingan Jumlah Bias, RMSE, dan MPE Model Peramalan pada Koordinat 8⁰LS-118⁰BT (*Lead* ke-1)

Kriteria	Model 1	Model 2	Model 3	Model 4	Model 5
Jumlah Bias Positif	61	53	63	57	47
Jumlah Bias Negatif	11	19	9	15	25
RMSE	2,109	2,644	4,469	3,604	3,468
MPE	-1,093	-0,799	-2,765	-1,775	-0,787


Dari Tabel 4.4, diketahui bahwa model peramalan pada koordinat 8⁰LS-118⁰BT di *lead* ke-1 memiliki jumlah bias positif yang lebih banyak untuk semua model peramalan. Dari segi kebaikan model berdasarkan RMSE, diperoleh nilai terkecil sebesar 2,109 pada model 1. Sementara itu dari tinjauan MPE diperoleh nilai MPE terkecil pada model 5 sebesar -0,787. Kemudian peringkat kedua diikuti oleh model 2 dengan nilai MPE -0,799. Dengan kata lain, dapat dikatakan bahwa model 5 mempunyai persentase bias terkecil terhadap observasi dibandingkan 4 model peramalan lainnya. Selain melakukan tinjauan perbandingan jumlah bias, RMSE, dan MPE pada koordinat 8⁰LS-118⁰BT, analisis yang sama juga dilakukan pada koordinat lainnya di Provinsi Nusa Tenggara Timur sebagaimana ditampilkan pada Tabel 4.5 berikut.

Tabel 4.5 Perbandingan Jumlah Bias, RMSE, dan MPE Model Peramalan pada Koordinat Lainnya (*Lead* ke-1)

Kriteria	Model 1	Model 2	Model 3	Model 4	Model 5
Jumlah Bias Positif	56	48	62	53	44
Jumlah Bias Negatif	16	24	10	19	28
RMSE	2,073	2,345	4,230	3,609	3,452
MPE	-0,820	-0,537	-2,169	-1,392	-0,680


Tabel 4.5 menampilkan perbandingan jumlah bias, RMSE, dan MPE model peramalan *lead* ke-1 di koordinat lain, tepatnya pada pada koordinat 8⁰LS-119⁰BT. Dari Tabel 4.5, diketahui bahwa kelima model memiliki jumlah bias positif yang lebih banyak.. Berdasarkan RMSE, diperoleh nilai terkecil sebesar 2,073 pada model 1. Hal ini serupa pada koordinat sebelumnya dimana nilai RMSE terkecil diperoleh pada model yang sama. Sementara itu dari tinjauan MPE diperoleh nilai MPE terkecil pada model 2 sebesar -0,537. Kemudian peringkat kedua diikuti oleh model 5 dengan nilai MPE -0,68. Dengan demikian, setelah ditinjau menggunakan dua titik koordinat tersebut dapat disimpulkan bahwa bias peramalan terkecil pada *lead* ke-1 didominasi baik oleh model 2 dan model 5.

Setelah dilakukan evaluasi kebaikan model menggunakan aspek RMSE dan MPE, selanjutnya adalah interpretasi secara visual menggunakan pendekatan *time series plot* dan *rank histogram*. Seperti yang telah dijelaskan sebelumnya, dalam evaluasi model ini *time series plot* akan dibagi menjadi dua. Pertama adalah *time series plot* nilai observasi dengan nilai peramalan dan berikutnya adalah *time series plot* dari nilai residual setiap model peramalan terhadap observasi. Adapun *time series plot* untuk mengetahui keterpautan antara setiap model peramalan dengan nilai observasi, sementara itu *rank histogram* digunakan untuk mengetahui bagaimana pola model peramalan ensemble terhadap data observasi. Gambar 4.6 pada halaman berikutnya menunjukkan *time series plot* nilai peramalan pada koordinat 8⁰LS-118⁰BT di *lead* ke-1 untuk masing-masing model apabila dibandingkan terhadap nilai observasi.




Gambar 4.6. *Time Series Plot Model Peramalan dan Observasi di Nusa Tenggara Timur pada Koordinat 8°LS-118°BT (Lead ke-1)*

Dari Gambar 4.6, terlihat bahwa hasil peramalan yang dihasilkan setiap model peramalan untuk *lead* ke-1 masih jauh dari nilai observasi. Untuk lebih memperjelas seberapa jauh nilai peramalan dengan observasi, maka ditampilkan *time series plot* dari residual setiap model peramalan sebagaimana berikut.




Gambar 4.7. *Time Series Plot Residual Model Peramalan Terhadap Observasi pada Koordinat 8°LS-118°BT (Lead ke-1)*

Gambar 4.7 pada halaman sebelumnya menunjukkan *time series plot* residual model peramalan dengan observasi pada koordinat $8^{\circ}\text{LS}-118^{\circ}\text{BT}$ di *Lead* ke-1. Dari Gambar 4.7, terlihat bahwa sebagian besar residual pada setiap model jatuh pada nilai dibawah nol. Dengan kata lain, hasil peramalan yang dihasilkan cenderung memiliki nilai yang melebihi observasi atau bias yang dihasilkan positif. Selain mengamati model peramalan dan observasi pada koordinat $8^{\circ}\text{LS}-118^{\circ}\text{BT}$, dilakukan pengamatan nilai observasi dan model peramalan beserta residualnya pada titik koordinat di Provinsi Nusa Tenggara yang lain seperti yang ditampilkan pada Gambar 4.8 berikut.



Gambar 4.8. *Time Series Plot* Model Peramalan dan Observasi di Nusa Tenggara Timur pada Koordinat Lainnya (*Lead* ke-1)


Gambar 4.8 menunjukkan *time series plot* dari nilai hasil observasi lapangan dan lima model peramalan berbeda yang digunakan pada salah satu koordinat lain di Nusa Tenggara Timur. Dari Gambar 4.8, terlihat bahwa kondisi yang tidak jauh berbeda juga terlihat pada beberapa titik koordinat lainnya, dimana nilai peramalan masih jauh dari hasil observasi. Beberapa peramalan juga memiliki nilai *outlier*, dimana nilai *outlier* yang paling jelas terlihat terdapat pada model 4 di bulan ke-36 atau Desember 2013 dan pada model 5 di bulan ke-62. Untuk memahami secara lebih jelas seberapa besar bias peramalan yang dihasilkan, maka ditampilkan Gambar 4.9 sebagai berikut.



Gambar 4.9. *Time Series Plot* Residual Model Peramalan Terhadap Observasi pada Koordinat Lainnya (*Lead* ke-1)


Gambar 4.9 menunjukkan *time series plot* residual model peramalan dengan observasi pada koordinat lainnya di *Lead* ke-1. Sama seperti pada koordinat sebelumnya, dari Gambar 4.9 terlihat bahwa sebagian besar residual pada setiap model jatuh pada nilai dibawah nol. Dengan kata lain, hasil peramalan yang dihasilkan cenderung memiliki nilai yang melebihi observasi atau bias yang dihasilkan positif.

Evaluasi model peramalan curah hujan terhadap observasi curah hujan selanjutnya adalah berdasarkan tinjauan *rank histogram*. Adapun tujuan dari dilakukannya evaluasi menggunakan *rank histogram* adalah untuk mengetahui pola karakteristik model peramalan ensemble terhadap nilai observasi curah hujan. Suatu model peramalan ensemble akan dikatakan telah tersebar secara merata (*dispersive*) apabila bar dari *rank histogram* yang dihasilkan telah seimbang atau memiliki frekuensi bar yang sama. Beberapa kriteria lainnya yang dapat diimpulkan dari *rank histogram* diantaranya adalah *over dispersive*, *under dispersive*, bias positif, dan bias negatif. Berikut adalah *rank histogram* model peramalan terhadap data observasi untuk *lead* ke-1.



Gambar 4.10. Rank Histogram Model Peramalan dan Observasi Curah Hujan di Nusa Tenggara Timur pada Koordinat $8^{\circ}\text{LS}-118^{\circ}\text{BT}$ (Lead ke-1)

Gambar 4.10 di atas menunjukkan *rank histogram* dari model peramalan ensemble terhadap data observasi curah hujan di Nusa Tenggara Timur pada koordinat $8^{\circ}\text{LS}-118^{\circ}\text{BT}$. Terlihat bahwa pola histogram menunjukkan pola *trend* yang menurun, atau dalam arti lain data peramalan ensemble memiliki bias positif. Beberapa pengamatan karakteristik model peramalan ensemble menggunakan *rank histogram* terhadap titik koordinat lainnya juga ditampilkan sebagaimana pada Gambar 4.11.



Gambar 4.11. Rank Histogram Model Peramalan dan Observasi lead ke-1 pada Koordinat Lainnya ($8^{\circ}\text{LS}-119^{\circ}\text{BT}$)

Dapat dilihat dari Gambar 4.11 pada halaman sebelumnya bahwa *rank histogram* di salah titik koordinat lain membentuk pola *histogram* yang sama, dimana terbentuk *trend* menurun pada *rank histogram*. Hal ini menandakan data peramalan ensemble dengan bias positif juga terjadi di koordinat lainnya.

4.3.2. Evaluasi Model Peramalan Curah Hujan untuk Lead ke-4

Evaluasi model peramalan curah hujan untuk *lead* ke-4 menggunakan cara yang sama dengan evaluasi model peramalan untuk *lead* ke-1, dimana evaluasi dilakukan melalui tinjauan RMSE, MPE, dan *rank histogram*. Berikut akan ditampilkan terlebih dahulu tabel perbandingan jumlah bias, RMSE, dan MPE dari model peramalan pada koordinat $10^0\text{LS}-118^0\text{BT}$.

Tabel 4.6 Perbandingan Jumlah Bias, RMSE, dan MPE Model Peramalan pada Koordinat $10^0\text{LS}-118^0\text{BT}$ (*Lead* ke-4)

Kriteria	Model 1	Model 2	Model 3	Model 4	Model 5
Jumlah Bias Positif	32	40	44	38	42
Jumlah Bias Negatif	40	32	28	34	30
RMSE	3,947	4,145	6,434	6,708	5,489
MPE	-4,383	-6,049	-11,745	-9,444	-6,549


Dari Tabel 4.6, diketahui bahwa model peramalan pada koordinat $10^0\text{LS}-118^0\text{BT}$ di *lead* ke-4 memiliki jumlah bias negative yang lebih banyak pada model peramalan 1 dan bias positif yang lebih banyak pada model peramalan lainnya. Berdasarkan tinjauan RMSE, diperoleh nilai terkecil sebesar 3,947 pada model 1. Sementara itu dari tinjauan MPE diperoleh nilai MPE terkecil pada model 1 sebesar -4,383. Kemudian peringkat kedua diikuti oleh model 2 dengan nilai MPE -6,049. Dengan kata lain, dapat dikatakan bahwa model 1 mempunyai persentase bias terkecil terhadap observasi dibandingkan 4 model peramalan lainnya. Selain melakukan tinjauan perbandingan jumlah bias, RMSE, dan MPE pada koordinat $10^0\text{LS}-118^0\text{BT}$, analisis yang sama juga dilakukan pada koordinat lainnya di Provinsi Nusa Tenggara Timur sebagaimana ditampilkan pada Tabel 4.7 berikut.

Tabel 4.7 Perbandingan Jumlah Bias, RMSE, dan MPE Model Peramalan pada Koordinat Lainnya (*Lead* ke-4)

Kriteria	Model 1	Model 2	Model 3	Model 4	Model 5
Jumlah Bias Positif	31	40	44	34	42
Jumlah Bias Negatif	41	32	28	38	30
RMSE	4,516	4,316	6,333	6,888	5,553
MPE	-7,061	-7,008	-11,914	-10,453	-9,177


Tabel 4.7 menampilkan perbandingan jumlah bias, RMSE, dan MPE model peramalan *lead* ke-1 di koordinat lain, tepatnya pada pada koordinat $8^{\circ}\text{LS}-125^{\circ}\text{BT}$. Dari Tabel 4.7, diketahui bahwa model 2,3, dan 5 memiliki jumlah bias positif yang lebih banyak. Sementara itu model 1 dan model 5 memiliki jumlah bias negative yang lebih banyak. Berdasarkan RMSE, diperoleh nilai terkecil sebesar 4,316 pada model 2. Hal ini serupa pada koordinat sebelumnya dimana nilai RMSE terkecil diperoleh pada model yang sama. Sementara itu dari tinjauan MPE diperoleh nilai MPE terkecil pada model 2 sebesar -7,008. Kemudian peringkat kedua diikuti oleh model 1 dengan nilai MPE -7,061. Dengan demikian, setelah ditinjau menggunakan dua titik koordinat tersebut dapat disimpulkan bahwa bias peramalan terkecil pada *lead* 4 didominasi baik oleh model 1 dan model 2.

Setelah dilakukan evaluasi kebaikan model menggunakan aspek RMSE dan MPE, selanjutnya adalah interpretasi secara visual menggunakan pendekatan *time series plot* dan *rank histogram*. Adapun evaluasi model secara visual pada *lead time* ke-4 masih menggunakan prosedur yang serupa, dimana evaluasi model ini *time series plot* akan dibagi menjadi dua. Pertama adalah *time series plot* nilai observasi dengan nilai peramalan dan berikutnya adalah *time series plot* dari nilai residual setiap model peramalan terhadap observasi. Setelah evaluasi menggunakan *time series plot* selesai, selanjutnya adalah evaluasi menggunakan *rank histogram*. Gambar 4.12 pada halaman berikutnya menunjukkan *time series plot* nilai peramalan pada koordinat $8^{\circ}\text{LS}-118^{\circ}\text{BT}$ di *lead* ke-1 untuk masing-masing model apabila dibandingkan terhadap nilai observasi.




Gambar 4.12. *Time Series Plot Model Peramalan dan Observasi di Nusa Tenggara Timur pada Koordinat 10⁰LS-118⁰BT (Lead ke-4)*

Gambar 4.12 menampilkan *time series plot* dari lima model peramalan curah hujan beserta dengan data observasi curah hujan secara *real time* pada letak koordinat 10⁰LS-118⁰BT. Dari Gambar 4.12 terlihat bahwa hasil peramalan yang dihasilkan setiap model peramalan untuk *lead* ke-4 terpaut jauh dari nilai observasi. Berikut juga dilakukan pengamatan *time series plot* dari residual setiap model peramalan sebagai berikut.




Gambar 4.13. *Time Series Plot Residual Model Peramalan Terhadap Observasi pada Koordinat 10⁰LS-118⁰BT (Lead ke-4)*

Gambar 4.13 pada menunjukkan *time series plot* residual model peramalan dengan observasi pada koordinat $10^{\circ}\text{LS}-118^{\circ}\text{BT}$ di *Lead* ke-4. Dari Gambar 4.13, terlihat bahwa sebagian besar residual pada setiap model merata di atas nilai nol dan di bawah nilai nol. Selain mengamati model peramalan dan observasi pada koordinat $10^{\circ}\text{LS}-118^{\circ}\text{BT}$, dilakukan pengamatan nilai observasi dan model peramalan beserta residualnya pada titik koordinat di Provinsi Nusa Tenggara yang lain seperti yang ditampilkan pada Gambar 4.14 berikut.




Gambar 4.14. *Time Series Plot* Model Peramalan dan Observasi pada di Nusa Tenggara Timur pada Koordinat Lainnya (*Lead* ke-4)

Gambar 4.14 menunjukkan *time series plot* dari nilai hasil observasi lapangan dan lima model peramalan berbeda di Nusa Tenggara Timur pada salah satu titik koordinat yang lain. Dari Gambar 4.14, terlihat bahwa pola peramalan *lead* ke-4 terlihat lebih tidak beraturan dibandingkan pola peramalan *lead* ke-1. Hal ini turut membuktikan bahwa semakin panjang *lead time* maka akan semakin besar tingkat ketidakpastian yang dihasilkan. Untuk memahami secara lebih jelas seberapa besar bias peramalan yang dihasilkan, maka ditampilkan Gambar 4.15 sebagai berikut.




Gambar 4.15. *Time Series Plot* Residual Model Peramalan Terhadap Observasi pada Koordinat Lainnya (*Lead ke-4*)

Gambar 4.15 menunjukkan *time series plot* residual model peramalan dengan observasi pada koordinat lainnya di *Lead ke-4*. Dari Gambar 4.15 terlihat bahwa residual pada setiap model jatuh merata pada nilai diatas nol dan dibawah nol. Dengan kata lain, hasil peramalan yang dihasilkan memiliki jumlah yang sama banyak antara nilai peramalan yang melebihi observasi dan nilai peramalan yang kurang dari observasi. Selanjutnya adalah evaluasi model peramalan curah hujan terhadap observasi curah hujan berdasarkan tinjauan *rank histogram* terhadap data observasi untuk *lead ke-4* sebagai berikut.



Gambar 4.16. *Rank Histogram* Model Peramalan dan Observasi Curah Hujan di Nusa Tenggara Timur pada Koordinat $10^0\text{LS}-118^0\text{BT}$ (*Lead ke-4*)

Gambar 4.16 pada halaman sebelumnya adalah *rank histogram* dari model peramalan ensemble terhadap data observasi curah hujan di Nusa Tenggara Timur pada koordinat $10^{\circ}\text{LS}-118^{\circ}\text{BT}$ untuk *lead* ke-4. Berbeda dengan *lead* sebelumnya, *rank histogram* pada *lead* ke-4 memiliki jumlah bias positif dan negative yang lebih berimbang dibandingkan *lead* 1. Namun demikian, pola yang terbentuk pada *lead* 4 bersifat *undispersive*. Hal ini dapat dilihat dari semakin menuju ke tengah bar, semakin kecil frekuensi dari *bar* tersebut. Selain mengamati *rank histogram* pada koordinat $10^{\circ}\text{LS}-118^{\circ}\text{BT}$, dilakukan pengamatan karakteristik model peramalan ensemble pada data observasi menggunakan *rank histogram* terhadap titik koordinat lainnya sebagaimana ditampilkan dalam Gambar 4.17 berikut.



Gambar 4.17. *Rank Histogram* Model Peramalan dan Observasi *lead* ke-4 pada koordinat lainnya ($8^{\circ}\text{LS}-125^{\circ}\text{BT}$)

Gambar 4.17 di atas menunjukkan *rank histogram* model peramalan dan observasi untuk *lead* ke-4 pada salah satu koordinat lain di Nusa Tenggara Timur. Pada Gambar 4.17, terlihat bahwa *rank histogram* memiliki pola *undispersive* sama seperti yang digambarkan pada koordinat sebelumnya. Pola yang bersifat *undispersive* menandakan bahwa model peramalan ensemble masih memberikan hasil yang kurang baik, dimana peramalan dengan *lead* yang lebih besar menghasilkan kesalahan peramalan yang lebih besar juga.

4.4. Kalibrasi Peramalan Curah Hujan dengan *Bayesian Model Averaging-Expectation Maximization*

Dikarenakan evaluasi model peramalan ensemble yang sudah dilakukan menunjukkan hasil dengan bias positif untuk *lead* ke-1 dan *undispersive* untuk *lead* ke-4, dengan demikian maka peramalan ensemble perlu dikalibrasi untuk menghasilkan peramalan yang lebih baik. Adapun metode kalibrasi yang digunakan adalah *Bayesian Model Averaging* dengan pendekatan *Expectation Maximization*. Dalam BMA-EM, hasil peramalan kalibrasi bergantung dengan ukuran m (*window training*) yang digunakan (Raftery *et al.*, 2005). Dengan demikian, dari 40 titik koordinat yang akan dikalibrasi akan digunakan dua nilai m , yaitu 12 dan 24. Dari kedua m tersebut nantinya akan dibandingkan ukuran m berapakah yang memberikan hasil kalibrasi peramalan yang optimal. Adapun langkah-langkah kalibrasi menggunakan BMA-EM dapat dijelaskan melalui prosedur sebagai berikut.

1. Menentukan ukuran *window time* yang digunakan, yaitu (m sebesar 12 dan 24). Adapun *window time* adalah jumlah data yang digunakan untuk mengestimasi parameter BMA-EM, yaitu μ_k , σ_k , dan w_k .
2. Melakukan prosedur analisis regresi $\hat{Y} = b_0 + b_1X$ terhadap peramalan ensemble (variabel prediktor) terhadap nilai observasi (variabel respon) dengan jumlah data sebanyak m -data sebelum periode peramalan yang dikalibrasi. Dari hasil regresi nantinya akan didapatkan koefisien b_0 dan b_1 . Nilai tersebut digunakan untuk menghilangkan bias dari peramalan ensemble sehingga nilai μ dapat mendekati nilai observasi.
3. Mendapatkan nilai koreksi bias melalui rumusan $\mu_k = b_0 + b_1f_k$, dimana f_k adalah hasil peramalan ensemble untuk tiap model.
4. Nilai σ_k dan w_k diperoleh dari iterasi berulang menggunakan EM. Langkah pertama dalam pendekatan ini

adalah dengan menentukan nilai awal c_0 , c_1 , dan w_k . Setelah nilai-nilai tersebut didapatkan, maka dapat diperoleh standar deviasi untuk masing-masing model melalui rumusan $\sigma_k = c_0 + c_1 f_k$.

- Setelah nilai σ_k dan w_k diperoleh, selanjutnya adalah melakukan iterasi berulang dengan memasukkan kembali nilai σ_k dan w_k ke dalam persamaan berikut

$$h_{kt}^{(j)} = \frac{w_k g(y_t | f_{kt}, \sigma_k^{(j-1)})}{\sum_{l=1}^K w_l g(y_t | f_{lt}, \sigma_l^{(j-1)})}$$

- Iterasi dilakukan sampai akhirnya berhenti dalam keadaan apabila nilai dari $l(w_1, \dots, w_k, \sigma_1^2, \dots, \sigma_k^2 | f_1, \dots, f_k, y)$ telah bernilai konvergen, sehingga diperoleh nilai σ_k dan w_k .
- Dikarenakan peramalan ensembel untuk data curah hujan mengikuti distribusi gamma, maka parameter gamma (α_k, β_k) dapat diperoleh melalui rumus berikut

$$\alpha_k = \frac{\mu_k^2}{\sigma_k^2}; \beta_k = \frac{\sigma_k^2}{\mu_k} \text{ a .}$$

- Dari rumusan pada langkah sebelumnya, maka dapat diperoleh model prediksi BMA beserta nilai μ -terkalibrasi dan σ^2 -terkalibrasi.
- Terakhir adalah mendapatkan nilai interval dari peramalan terkalibrasi, dimana nilai tersebut dapat dirumuskan dengan rumusan $\mu_y \pm Z_{(\alpha/2)} \sigma_y^2$, dimana nilai y adalah peramalan terkalibrasi dan $Z_{(\alpha/2)} = 1,96$ ($\alpha = 0,05$).

4.4.1. Kalibrasi Peramalan Curah Hujan Menggunakan BMA-EM untuk *Lead* ke-1

Prosedur Kalibrasi peramalan curah hujan dengan BMA-EM dilakukan pada dua *lead time* yang berbeda, yaitu *lead* ke-1

dan *lead* ke-4. Kalibrasi pertama dilakukan pada data peramalan curah hujan *lead* ke-1. Adapun ilustrasi mengenai kalibrasi peramalan ensemble menggunakan BMA-EM dijelaskan melalui gambar berikut.

Bulan	Obs	Lead 1				
		M1	M2	M3	M4	M5
⋮	⋮	⋮	⋮	⋮	⋮	⋮
Nov-15	1,3295	1,80	0,67	6,03	3,70	0,78
Des-15	6,4485	4,32	3,46	8,71	4,86	8,09
Jan-16	5,2720	5,75	11,36	14,39	3,01	12,34
Feb-16	10,0317	11,68	13,32	10,54	12,90	21,35
Mar-16	8,0884	9,63	6,43	8,15	8,19	11,02
Apr-16	3,5863	9,25	7,09	13,61	3,97	3,23
Mei-16	3,4543	8,47	6,00	9,16	8,44	1,47
Jun-16	3,2579	6,30	4,19	5,26	10,74	4,17
Jul-16	3,4076	4,31	3,23	4,02	3,76	6,46
Aug-16	1,1100	1,87	2,32	2,08	3,66	3,09
Sep-16	1,0431	2,06	0,86	7,61	2,25	7,19
Oct-16	4,7169	6,13	3,44	10,24	8,10	1,99
Nov-16	2,6054	7,47	3,80	11,32	6,56	4,28
		f_1	f_2	f_3	f_4	f_5

$m = 12$, yaitu banyak data yang digunakan dalam estimasi parameter μ_k , σ_k , w_k .

Gambar 4.18. Perhitungan μ_k untuk Masing-Masing Model Peramalan pada Koordinat $8^{\circ}\text{LS}-118^{\circ}\text{BT}$ Periode November 2016

Gambar 4.18 di atas merupakan ilustrasi dari prosedur kalibrasi peramalan pada periode November 2016 untuk koordinat $8^{\circ}\text{LS}-118^{\circ}\text{BT}$. Dengan dilakukan proses regresi antara model peramalan dengan observasi dari m -data, maka akan diperoleh koefisien regresi $b_0 = 1,5604$ dan $b_1 = 0,4248$. Selanjutnya dilakukan penentuan nilai koreksi bias dengan rumusan $\mu_k = b_0 + b_1 f_k$, dimana f_k adalah hasil peramalan ensemble untuk tiap model di koordinat $8^{\circ}\text{LS}-118^{\circ}\text{BT}$ pada periode November 2016. Dari perhitungan bias koreksi, diperoleh nilai $\mu_1 = 4,7376$, $\mu_2 = 3,1787$, $\mu_3 = 6,3694$, $\mu_4 = 4,3455$, dan $\mu_5 = 3,3805$.

Berikutnya adalah mendapatkan nilai c_0 , c_1 , dan w_k menggunakan pendekatan EM. Dari ketiga nilai tersebut nantinya dapat diperoleh nilai σ_k untuk masing-masing model melalui rumusan $\sigma_k = c_0 + c_1 f_k$. Kemudian, nilai σ_k dan w_k dimasukkan ke dalam rumusan variabel laten dengan $k = 1, 2, 3, 4, 5$; $t = 1, 2, 3, \dots, 12$; dan j adalah banyaknya jumlah iterasi yang dilakukan.

Tanggal	Lead 1				
	M1	M2	M3	M4	M5
Des-15	$\hat{h}_{1,1}$	$\hat{h}_{2,1}$	$\hat{h}_{3,1}$	$\hat{h}_{4,1}$	$\hat{h}_{5,1}$
Jan-16	$\hat{h}_{1,2}$	$\hat{h}_{2,2}$	$\hat{h}_{3,2}$	$\hat{h}_{4,2}$	$\hat{h}_{5,2}$
Feb-16	$\hat{h}_{1,3}$	$\hat{h}_{2,3}$	$\hat{h}_{3,3}$	$\hat{h}_{4,3}$	$\hat{h}_{5,3}$
Mar-16	\vdots	\vdots	\vdots	\vdots	\vdots
Apr-16					
Mei-16					
Jun-16					
Jul-16					
Aug-16					
Sep-16					
Oct-16					
Nov-16	\vdots	\vdots	\vdots	\vdots	\vdots
Dec-16	$\hat{h}_{1,10}$	$\hat{h}_{2,10}$	$\hat{h}_{3,10}$	$\hat{h}_{4,3}$	$\hat{h}_{5,3}$

$$w_k^{(j)} = \frac{1}{n} \sum_{t=1}^n \hat{h}_{kt}^{(j)}$$

$$\sigma^{2(j)} = \frac{1}{n} \sum_{t=1}^n \sum_{k=1}^K \hat{h}_{kt}^{(j)} (y_t - f_t)^2$$

Gambar 4.19 Perhitungan σ_k dan w_k untuk Masing-Masing Model Peramalan pada Koordinat $8^0\text{LS}-118^0\text{BT}$ Periode November 2016

Gambar 4.19 menampilkan ilustrasi mengenai perhitungan nilai σ_k dan w_k untuk masing-masing model peramalan. Terlihat bahwa pada Gambar 4.19 kedua nilai σ_k dan w_k kembali dimasukkan dalam persamaan $\hat{h}_{kt}^{(j)}$ untuk menghasilkan nilai σ_k dan w_k untuk iterasi berikutnya hingga konvergen.

Dari perhitungan didapatkan koefisien $c_0 = 1,2393$ dan $c_1 = 1,8422 \cdot 10^{-15}$. Kemudian dengan rumusan $\sigma_k = c_0 + c_1$ maka diperoleh nilai σ_1 sampai dengan σ_5 sebesar 1,2393. Nilai ini sama dikarenakan oleh kecilnya koefisien c_1 . Selain itu, juga diperoleh bobot untuk masing-masing model diantaranya $w_1 = 0,062$, $w_2 = 0,4126$, $w_3 = 2,0380 \cdot 10^{-17}$, $w_4 = 3,840 \cdot 10^{-15}$, dan $w_5 = 0,5245$. Semakin besar nilai bobot maka akan semakin besar kontribusi model tersebut terhadap hasil peramalan kalibrasi. Dari nilai bobot yang didapatkan menggunakan $m = 12$, diketahui bahwa pada November 2016 untuk titik koordinat $8^0\text{LS}-118^0\text{BT}$, model 5 memiliki kontribusi terbesar dalam hasil peramalan kalibrasi.


Peramalan ensemble untuk curah hujan mengikuti distribusi gamma (Slougher *et al.*, 2007). Dengan demikian, nilai parameter gamma dapat diestimasi melalui nilai μ_k^2 dan σ_k^2 yang sudah diperoleh. Dari perhitungan, didapatkan nilai $\alpha_1 = 14,6142$, $\beta_1 = 0,3242$; $\alpha_2 = 6,5792$, $\beta_2 = 0,4831$; $\alpha_3 = 26,4157$, $\beta_3 = 0,2411$; $\alpha_4 = 12,2953$, $\beta_4 = 0,3534$; dan $\alpha_5 = 7,4410$, $\beta_5 = 0,4543$.

Prosedur dengan langkah yang sama juga dilakukan terhadap *window time* = 24. Dari hasil analisis pada *window time* = 24, diperoleh koefisien regresi $b_0 = 0,8277$ dan $b_1 = 0,5464$. Sehingga diperoleh nilai $\mu_1 = 4,9139$, $\mu_2 = 2,9091$, $\mu_3 = 7,0127$, $\mu_4 = 4,4096$, dan $\mu_5 = 3,1686$. Kemudian, didapatkan nilai $c_0 = 0,9055$ dan $c_1 = 0,071$, sehingga diperoleh nilai $\sigma_1 = 1,4365$, $\sigma_2 = 1,176$, $\sigma_3 = 1,709$, $\sigma_4 = 1,371$, dan $\sigma_5 = 1,21$. Untuk nilai bobot pada masing-masing model, diperoleh nilai $w_1 = 0,2432$, $w_2 = 0,4125$, $w_3 = 4,5163 \cdot 10^{-28}$, $w_4 = 5,9545 \cdot 10^{-6}$, dan $w_5 = 0,3442$. Dari nilai bobot yang didapatkan menggunakan $m = 24$, diketahui bahwa model 2 memiliki kontribusi terbesar dalam hasil peramalan kalibrasi.

Setelah didapatkan nilai μ_k dan σ_k , maka dapat diperoleh nilai parameter gamma untuk masing-masing model peramalan.

Dari perhitungan, didapatkan nilai $\alpha_1 = 11,7014$, $\beta_1 = 0,4199$; $\alpha_2 = 6,1194$, $\beta_2 = 0,4754$; $\alpha_3 = 7,0127$, $\beta_3 = 0,4166$; $\alpha_4 = 10,3453$, $\beta_4 = 0,4262$; dan $\alpha_5 = 6,8608$, $\beta_5 = 0,4618$.

Dengan diperoleh nilai bias, bobot, maupun parameter gamma untuk masing-masing *window time* maka dapat diperoleh pdf hasil peramalan pada periode November 2016 di titik koordinat $8^0\text{LS}-118^0\text{BT}$ (*lead* ke-1) untuk masing-masing m , baik untuk $m = 12$ maupun $m = 24$ yang digunakan sebagaimana berikut.



Gambar 4.20. PDF curah hujan dengan metode BMA-EM untuk Periode November 2016 pada Koordinat $8^0\text{LS}-118^0$, dimana (a) menggunakan $m = 12$ dan (b) menggunakan $m = 24$.


Gambar 4.20 menampilkan hasil peramalan menggunakan BMA-EM untuk periode November 2016 menggunakan 2 nilai *window time* (m) yang berbeda. Adapun garis vertikal berwarna jingga menandakan data observasi dan garis vertikal hitam merupakan selang kepercayaan 95% dari hasil peramalan terkalibrasi. Pada Gambar 4.20, dapat dilihat bahwa hasil peramalan menggunakan BMA-EM pada kedua nilai m telah berada di dalam selang kepercayaan 95% dari hasil peramalan terkalibrasi. Terdapat selisih yang tipis dalam penempatan kurva distribusi terhadap garis observasi antar kedua *window time* yang

digunakan. Hal ini menandakan bahwa ukuran m yang digunakan dapat turut mempengaruhi hasil peramalan terkalibrasi. Adapun pemaparan dari nilai parameter distribusi untuk masing-masing m pada *lead time* ke-1 dapat dilihat pada Tabel 4.8 berikut.

Tabel 4.8. Parameter BMA untuk Periode November 2016 pada Koordinat $8^0\text{LS}-118^0\text{LS}$ (*Lead* ke-1)

Parameter	$m = 12$	$m = 24$	
μ	M1	4,7375	4,914
	M2	3,1787	2,9090
	M3	6,3694	7,0126
	M4	4,3454	4,401
	M5	3,3805	3,1685
w	M1	0,062	0,2432
	M2	0,4125	0,4125
	M3	$2,0383 \cdot 10^{-17}$	$4,516 \cdot 10^{-28}$
	M4	$3,8340 \cdot 10^{-15}$	$5,954 \cdot 10^{-6}$
	M5	0,5245	0,3442
μ -terkalibrasi	3,3813	3,486	
σ^2 -terkalibrasi	0,6968	0,7827	
batas bawah	2,0156	1,9518	
batas atas	4,7470	5,0203	

Berdasarkan Tabel 4.8 di atas, diketahui bahwa hasil peramalan kalibrasi terbaik untuk periode November 2016 pada letak koordinat $8^0\text{LS}-118^0\text{LS}$ adalah dengan menggunakan $m = 12$. Hal ini dikarenakan hasil peramalan terkalibrasi yang didapatkan memiliki bias yang lebih kecil atau mendekati observasi (yaitu 2,6054). Kondisi ini juga didukung dengan interval peramalan yang tidak terlalu lebar. Sehingga lebih dapat menangkap nilai observasi secara lebih akurat. Selanjutnya akan disajikan hasil peramalan optimum menggunakan BMA-EM untuk koordinat lainnya pada *lead* ke-1.



Gambar 4.21. PDF curah hujan dengan metode BMA-EM untuk Periode November 2016 pada Koordinat lainnya (*Lead* ke-1)

Berdasarkan Gambar 4.21 pada halaman sebelumnya, dapat dilihat bahwa hanya sebagian kecil observasi yang berada diluar

batas selang kepercayaan 95% dari hasil peramalan menggunakan BMA-EM pada *lead* ke-1. Selain itu, interval peramalan yang didapatkan juga tidak lebar, sehingga presisi nilai peramalan yang didapatkan lebih baik. Dengan kata lain, dapat dikatakan bahwa peramalan dengan metode BMA-EM terbukti akurat dalam meramalkan data curah hujan di provinsi Nusa Tenggara Timur.


4.4.2. Kalibrasi Peramalan Curah Hujan Menggunakan BMA-EM untuk *Lead* ke-4

Prosedur Kalibrasi peramalan curah hujan dengan BMA-EM kedua dilakukan pada data peramalan curah hujan *lead* ke-4. Adapun langkah-langkah yang dilakukan untuk kalibrasi peramalan ensemble menggunakan BMA-EM pada *lead* ke-4 sama seperti langkah yang dilakukan pada kalibrasi peramalan untuk *lead* ke-1, dimana ukuran m yang digunakan sama yaitu 12 dan 24. Berikut pemaparan dari nilai parameter distribusi untuk masing-masing m pada *lead time* ke-4 di salah satu titik koordinat di Nusa Tenggara Timur, yaitu $10^0\text{LS}-118^0\text{BT}$.


Tabel 4.9. Parameter BMA untuk Periode November 2016 pada Koordinat $10^0\text{LS}-118^0\text{LS}$ (*Lead* ke-4)

Parameter	$m = 12$	$m = 24$	
μ	M1	3,1580	3,0558
	M2	3,1003	3,0154
	M3	3,1193	3,0286
	M4	3,4535	3,2627
	M5	2,8786	2,8601
w	M1	$3,1259 \cdot 10^{-14}$	$5,7883 \cdot 10^{-11}$
	M2	$5,5951 \cdot 10^{-12}$	$1,0008 \cdot 10^{-12}$
	M3	0,4568	1
	M4	0,3315	$3,4921 \cdot 10^{-6}$
	M5	0,2115	$1,5155 \cdot 10^{-8}$
μ -terkalibrasi	3,1792	3,0286	
σ^2 -terkalibrasi	0,9803	1,9727	
batas bawah	1,2578	0	
batas atas	5,1006	6,8951	

Berdasarkan Tabel 4.9 pada halaman sebelumnya, diketahui bahwa hasil peramalan kalibrasi terbaik untuk periode November 2016 pada letak koordinat $10^0\text{LS}-118^0\text{LS}$ adalah dengan menggunakan $m = 12$. Hal ini dikarenakan hasil peramalan terkalibrasi yang didapatkan memiliki bias yang lebih kecil atau mendekati observasi (yaitu 3,36). Selain itu, interval peramalan yang dihasilkan menggunakan $m = 12$ tidak terlalu lebar. Dengan demikian nilai observasi yang diperoleh lebih akurat. Berikut adalah hasil peramalan optimum menggunakan BMA-EM untuk koordinat lainnya pada *lead* ke-4.



Gambar 4.22(a). PDF curah hujan dengan metode BMA-EM untuk Periode November 2016 pada Koordinat lainnya (*lead* ke-4)



Gambar 4.22(b). PDF curah hujan dengan metode BMA-EM untuk Periode November 2016 pada Koordinat lainnya (*lead* ke-4)

Berdasarkan Gambar 4.22(a) dan 4.22(b), dapat dilihat bahwa hanya sebagian kecil observasi yang berada diluar batas selang kepercayaan 95% dari hasil peramalan menggunakan BMA-EM pada *lead* ke-4. Sama seperti *lead time* sebelumnya, hampir seluruh koordinat pada kalibrasi BMA-EM dengan *lead* ke-4 yang ditampilkan pada Gambar mampu menghasilkan nilai peramalan yang lebih baik. Dari segi presisi, interval peramalan yang didapatkan juga tidak lebar, nilai peramalan yang didapatkan mampu diperkirakan secara spesifik. Dengan kata lain, dapat dikatakan bahwa kalibrasi model peramalan dengan metode BMA-EM, baik menggunakan *lead* ke-1 dan *lead* ke-4 terbukti akurat dalam meramalkan data curah hujan di provinsi Nusa Tenggara Timur.

4.5. Kalibrasi Peramalan Curah Hujan dengan *Ensemble Model Output Statistics*

Metode kalibrasi kedua yang digunakan dalam penelitian ini adalah *Ensemble Model Output Statistics* (EMOS). Adapun model EMOS dapat dinyatakan sebagai distribusi tunggal, dimana parameternya bergantung pada jumlah model ensemble yang akan dikalibrasi dengan persamaan sebagai berikut.

$$p(y | f_1, \dots, f_k) \sim g(y | a + b_1 f_1 + \dots + b_k f_k, c + ds^2)$$

Adapun langkah-langkah dalam melakukan kalibrasi menggunakan EMOS diantaranya dijelaskan sebagai berikut.

1. Menentukan ukuran *window time* yang digunakan, yaitu ($m = 12$ dan 24). a , b_1 , ..., b_k , c , dan d .
2. Melakukan prosedur regresi $Y = b_0 + b_1X$ terhadap peramalan ensemble (variabel prediktor) terhadap nilai observasi (variabel respon) dengan jumlah data sebanyak m -data sebelum periode peramalan yang dikalibrasi. Dari hasil regresi nantinya akan didapatkan koefisien parameter a , b_1 , ..., b_k , c , dan d
3. Melalui rumusan $\mu = a + b_1f_1 + b_2f_2 + b_3f_3 + b_4f_4 + b_5f_5$, maka akan didapatkan nilai koreksi bias, dimana f_k adalah hasil peramalan ensemble untuk tiap model, maka didapatkan nilai koreksi bias ($k = 1$ berlaku untuk model 1, dst).
4. Nilai σ^2 didapatkan dari $\sigma^2 = c + dS^2$. Dengan demikian, varians terkalibrasi berkorelasi secara linier dengan varians ensemble.
5. Peramalan ensemble untuk data curah hujan mengikuti distribusi gamma, dengan demikian parameter gamma (α_k, β_k) dapat diperoleh melalui rumus berikut

$$\alpha_k = \frac{\mu_k^2}{\sigma_k^2} \text{ dan } \beta_k = \frac{\sigma_k^2}{\mu_k}.$$

6. Setelah didapatkan parameter distribusi, maka selanjutnya dapat dilakukan penyusunan model prediksi EMOS untuk peramalan terkalibrasi dengan persamaan $p(y | f_k) \sim g(m, \sigma)$, dimana m dan σ masing-masing adalah parameter *shape* dan *scale* yang tergantung pada indikator model ensemble baku yang digunakan.
7. Terakhir adalah mendapatkan nilai interval dari peramalan terkalibrasi, dimana nilai tersebut dapat dirumuskan dengan

rumusan $\mu_y \pm Z_{(\alpha/2)}\sigma_y^2$, dimana nilai y adalah peramalan terkalibrasi dan $Z_{(\alpha/2)} = 1,96$ ($\alpha = 0,05$).

Untuk mempermudah gambaran mengenai prosedur kalibrasi, berikut akan ditampilkan ilustrasi mengenai kalibrasi peramalan ensemble menggunakan EMOS sebagaiberikut.

Tanggal	Obs	Lead 1				
		M1	M2	M3	M4	M5
⋮	⋮	⋮	⋮	⋮	⋮	⋮
Nov-15	1,3295	1,80	0,67	6,03	3,70	0,78
Des-15	6,4485	4,32	3,46	8,71	4,86	8,09
Jan-16	5,2720	5,75	11,36	14,39	3,01	12,34
Feb-16	10,0317	11,68	13,32	10,54	12,90	21,35
Mar-16	8,0884	9,63	6,43	8,15	8,19	11,02
Apr-16	3,5863	9,25	7,09	13,61	3,97	3,23
Mei-16	3,4543	8,47	6,00	9,16	8,44	1,47
Jun-16	3,2579	6,30	4,19	5,26	10,74	4,17
Jul-16	3,4076	4,31	3,23	4,02	3,76	6,46
Aug-16	1,1100	1,87	2,32	2,08	3,66	3,09
Sep-16	1,0431	2,06	0,86	7,61	2,25	7,19
Oct-16	4,7169	6,13	3,44	10,24	8,10	1,99
Nov-16	2,6054	7,47	3,80	11,32	6,56	4,28
		f_1	f_2	f_3	f_4	f_5

$m = 12$, yaitu banyak data yang digunakan dalam estimasi parameter distribusi

Gambar 4.23. Ilustrasi Prosedur Regresi dalam Kalibrasi Peramalan menggunakan EMOS

Dari Gambar 4.23, tampak terlihat bahwa tidak banyak perbedaan yang dilakukan antara prosedur kalibrasi EMOS dengan BMA-EM, hal ini terlihat dari pola prosedur regresi antara kedua metode yang sama. Hal yang menjadi pembeda antara EMOS dengan BMA-EM adalah parameter distribusi yang ditaksir, yaitu $a, b_1, \dots, b_k, c,$ dan d .

4.5.1. Kalibrasi Peramalan Curah Hujan Menggunakan EMOS untuk *Lead* ke-1

Prosedur kalibrasi peramalan curah hujan dengan EMOS pertama dilakukan pada data peramalan curah hujan *lead* ke-1. Sesuai dengan prosedur yang telah dilakukan sebelumnya,

langkah pertama yang dilakukan adalah dengan menentukan nilai parameter a , b_1 , b_2 , b_3 , b_4 , b_5 , c , dan d agar dapat dilakukan perhitungan nilai μ dan σ^2 . Berikut akan ditampilkan Tabel parameter EMOS beserta nilai *mean* dan standar deviasi untuk peramalan pada *lead time* ke-1 periode November 2016 di koordinat $8^0\text{LS}-118^0\text{LS}$ (*lead ke-1*).

Tabel 4.10. Parameter Distribusi EMOS untuk Periode November 2016 pada Koordinat $8^0\text{LS}-118^0\text{LS}$ (*Lead ke-1*)

Parameter	$m = 12$	$m = 24$
a	-0,0514	-0,2921
b_1	0,2806	0,2342
b_2	$2,296 \cdot 10^{-12}$	0,3698
b_3	0,0569	0,0593
b_4	0,1478	$6,788 \cdot 10^{-17}$
b_5	0,2467	0,1229
μ -terkalibrasi	4,2539	4,0659
c	1,1605	0,6441
d	$1,964 \cdot 10^{-13}$	0,1148
σ^2 -terkalibrasi	1,16	0,9892
batas bawah	1,9794	2,1270
batas atas	6,5284	6,0047

Berdasarkan Tabel 4.10 di atas, diketahui bahwa besar kontribusi model peramalan akan berbeda apabila *window time* yang digunakan tidak sama. Terlihat bahwa pada $m = 12$, kontribusi terbesar dimiliki oleh model ke-1, namun pada $m = 24$, kontribusi terbesar dimiliki oleh model ke-2. Untuk penentuan m , kalibrasi terbaik untuk periode November 2016 pada letak koordinat $8^0\text{LS}-118^0\text{LS}$ adalah dengan menggunakan $m = 24$. Hal ini dikarenakan hasil peramalan terkalibrasi yang didapatkan memiliki bias yang lebih kecil atau mendekati observasi (yaitu 2,6054). Kondisi ini juga didukung dengan interval peramalan yang lebih sempit, sehingga lebih dapat menangkap nilai observasi secara lebih akurat.

4.5.2. Kalibrasi Peramalan Curah Hujan Menggunakan EMOS untuk *Lead* ke-4

Selanjutnya adalah prosedur kalibrasi peramalan curah hujan dengan EMOS yang dilakukan pada data peramalan curah hujan *lead* ke-4. Sama seperti prosedur yang diterapkan pada data *lead* ke-1, langkah pertama yang dilakukan adalah dengan menentukan nilai parameter a , b_1 , b_2 , b_3 , b_4 , b_5 , c , dan d agar dapat dilakukan perhitungan nilai μ dan σ^2 . Berikut akan ditampilkan Tabel parameter EMOS beserta nilai *mean* dan standar deviasi untuk peramalan pada *lead time* ke-1 periode November 2016 di koordinat $10^0\text{LS}-118^0\text{LS}$ (*lead* ke-4)

Tabel 4.11. Parameter Distribusi EMOS untuk Periode November 2016 pada Koordinat $10^0\text{LS}-118^0\text{LS}$ (*Lead* ke-4)

Parameter	$m = 12$	$m = 24$
a	2,8260	2,097
b_1	0,1914	0,2655
b_2	$6,165 \cdot 10^{-11}$	0,0597
b_3	$2,654 \cdot 10^{-10}$	$4,737 \cdot 10^{-14}$
b_4	$7,766 \cdot 10^{-10}$	$1,998 \cdot 10^{-12}$
b_5	$1,805 \cdot 10^{-10}$	$1,716 \cdot 10^{-12}$
μ -terkalibrasi	4,7029	5,3115
c	4,3579	7,86998
d	$5,580 \cdot 10^{-9}$	$7,411 \cdot 10^{-13}$
σ^2 -terkalibrasi	4,36	7,87
batas bawah	0	0
batas atas	13,2445	20,7367

Berdasarkan Tabel 4.11 di atas, terlihat bahwa pada $m = 12$ maupun $m = 24$ kontribusi terbesar dimiliki oleh model ke-1, Akan tetapi, untuk penentuan m , kalibrasi terbaik untuk periode November 2016 pada letak koordinat $10^0\text{LS}-118^0\text{LS}$ adalah dengan menggunakan $m = 12$, dimana bias yang diperoleh lebih kecil atau mendekati observasi (yaitu 3,3360). Interval peramalan yang didapatkan juga lebih sempit, sehingga lebih dapat menangkap nilai observasi secara lebih akurat. Dikarenakan hasil kalibrasi peramalan antara kedua metode kalibrasi, baik BMA-EM maupun EMOS telah dilakukan, analisis selanjutnya adalah

analisis evaluasi kebaikan model melalui tinjauan nilai *Continuous Rank Probability Score* (CRPS).

4.6. Evaluasi Kebaikan Model Kalibrasi Peramalan

Analisis berikutnya akan membahas mengenai perbandingan antara hasil peramalan ensemble antara dua metode kalibrasi yang sudah dilakukan. Adapun tujuan dilakukan evaluasi kebaikan model adalah untuk mengetahui metode kalibrasi mana yang dapat memberikan hasil peramalan yang lebih baik (keakuratan dan kepadatan). Indikator evaluasi yang digunakan adalah menggunakan *Continuous Rank Probability Score* (CRPS). Ide dari evaluasi menggunakan CRPS adalah dengan membandingkan distribusi antara hasil peramalan dari kedua metode kalibrasi yang direpresentasikan dalam bentuk fungsi distribusi kumulatif (CDF). Tidak hanya mengevaluasi hasil peramalan, CRPS juga akan mengevaluasi *window time* yang digunakan. Nilai peramalan CRPS dihitung secara bulanan, dimana rata-rata CRPS dari kedua metode kalibrasi ditampilkan pada Tabel 4.12 berikut.

Tabel 4.12. Nilai CRPS *mean* dari Kalibrasi Peramalan Menggunakan BMA-EM dan EMOS

Koordinat	Lead Time	<i>m</i> = 12		<i>m</i> = 24	
		BMA-EM	EMOS	BMA-EM	EMOS
8 ⁰ LS-118 ⁰ BT	1	1,1423	2,386	1,0884	2,387
	4	2,0864	4,675	2,0827	4,5837
9 ⁰ LS-118 ⁰ BT	1	0,9599	2,281	1,0069	2,299
	4	1,8184	4,518	1,9366	4,4190
10 ⁰ LS-118 ⁰ BT	1	1,0439	2,067	1,0353	2,1111
	4	1,9366	4,344	2,0737	4,2762
⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮
11 ⁰ LS-125 ⁰ BT	1	0,8998	2,1354	0,9028	2,2161
	4	1,4761	4,699	1,3907	4,6504
12 ⁰ LS-125 ⁰ BT	1	0,9962	1,4206	1,0126	1,457
	4	1,4206	4,478	1,4572	4,6407

Berdasarkan Tabel 4.12 pada halaman sebelumnya, dapat diketahui bahwa nilai CRPS untuk metode menggunakan BMA-EM pada setiap nilai m memiliki nilai CRPS yang lebih kecil dibandingkan dengan nilai CRPS untuk EMOS. Hal ini menandakan bahwa hasil peramalan menggunakan metode BMA-EM akan cenderung memiliki reliabilitas dan kepadatan yang lebih baik dibandingkan dengan metode EMOS. Dikarenakan reliabilitas dan kepadatan yang lebih baik tersebut, peramalan yang dihasilkan cenderung lebih mendekati nilai observasi *real* dibandingkan peramalan dengan menggunakan EMOS. Untuk nilai m , peramalan terbaik untuk *lead* ke-1 adalah dengan menggunakan nilai m sebesar 12. Hal ini dikarenakan BMA-EM dengan nilai m tersebut akan menghasilkan nilai CRPS yang terkecil dibandingkan nilai m lainnya. Sementara itu, untuk *lead* ke-4, peramalan terbaik akan muncul apabila menggunakan nilai m sebesar 24.

4.7. Pemetaan Kekeringan di Provinsi Nusa Tenggara Timur Berdasarkan Hasil Peramalan *Standardized Precipitation Index* (SPI)

Dalam mendeteksi bencana kekeringan di Nusa Tenggara Timur, satuan *Standardized Precipitation Index* (SPI) turun merupakan salah satu faktor yang dapat digunakan untuk melakukan prediksi tersebut. Untuk itu, diperlukan pemetaan untuk memberikan gambaran kondisi wilayah Nusa Tenggara Timur yang memberikan pengaruh signifikan terhadap bencana kekeringan berdasarkan tinjauan SPI. Adapun nilai SPI yang didapatkan untuk pemetaan ini didapatkan dari hasil standarisasi nilai curah hujan hasil peramalan terkalibrasi menggunakan metode terbaik. Berdasarkan analisis pemilihan metode kalibrasi terbaik yang telah dilakukan sebelumnya, didapatkan hasil bahwa kalibrasi model peramalan terbaik terhadap peramalan curah hujan di NTT adalah menggunakan *Bayesian Model Averaging-Expectation Maximization* (BMA-EM) dengan nilai *window time* senilai 12 untuk *lead* ke-1 dan 24 untuk *lead* ke-4. Adapun pemetaan kekeringan akan dilakukan mulai Periode Januari 2017

sampai dengan Mei 2017 dengan menggunakan dua jenis *lead time*. Berikut akan ditampilkan nilai skala SPI yang digunakan untuk memetakan kekeringan di NTT.

Tabel 4.13 Kategori Kekeringan Berdasarkan SPI

Nilai SPI	Kategori Kekeringan
≥ 2	Sangat Basah
1,49 : 1,99	Basah
1 : 1,49	Agak Basah
-0,99 : 0,99	Normal
-1 : -1,49	Agak Kering
-1,99 : -1,5	Kering
≤ -2	Kekeringan Besar

Berdasarkan Tabel 4.13, dapat diketahui bahwa daerah dapat dikategorikan mengalami kekeringan apabila nilai SPI yang didapatkan sebesar ≤ -1 . Namun demikian, dalam penelitian ini akan dilakukan pembatasan dimana pemetaan berdasarkan skala kekeringan berdasarkan SPI yang terdapat di wilayah daratan NTT. Untuk mempermudah pemahaman mengenai interpretasi, dalam penelitian ini pengkategorian kekeringan akan ditandai dengan sebuah pin, dimana setiap warna pin memberikan ulasan kategori kekeringan yang berbeda-beda sebagaimana ditampilkan pada Tabel 4.14 berikut.

Tabel 4.14 Pengkategorian Kekeringan Berdasarkan Spektrum Warna Pin

Warna Pin	Kategori Kekeringan
Biru Gelap	Sangat Basah
Biru	Basah
Hijau	Agak Basah
Abu-Abu	Normal
Kuning	Agak Kering
Merah	Kering
Merah Gelap	Kekeringan besar

4.7.1. Pemetaan Kekeringan di Provinsi Nusa Tenggara Timur Untuk *Lead Ke-1*

Pemetaan kekeringan di Nusa Tenggara Timur terlebih dahulu akan dilakukan untuk hasil peramalan curah hujan pada *lead time* ke-1, dimana terdapat lima periode pemetaan yang dilakukan. Gambaran mengenai pemetaan ini dikhususkan hanya untuk koordinat Nusa Tenggara Timur saja dan dibatasi hanya pada wilayah daratan. Berikut akan ditampilkan mengenai hasil pemetaan kekeringan di Nusa Tenggara Timur berdasarkan tinjauan *Standardized Precipitation Index* (SPI) dimulai dari periode Januari 2017 sampai dengan Mei 2017 pada *lead ke-1*.



Gambar 4.24. Hasil Pemetaan Kekeringan Periode Januari 2017 (*Lead ke-1*)

Gambar 4.24 menunjukkan hasil pemetaan kekeringan di Provinsi Nusa Tenggara Timur berdasarkan tinjauan nilai SPI pada *lead time* ke-1. Dari hasil pemetaan untuk periode Januari 2017, tidak ditemukan adanya indikasi kekeringan di wilayah NTT. Hal ini dapat dilihat dari dua jenis spektrum warna yang terlihat pada peta. Pada Gambar 4.24 juga dapat diketahui bahwa Provinsi Nusa Tenggara Timur pada periode Januari 2017 berada dalam kondisi normal di sebagian besar Pulau Sumba dan Flores. Sementara itu, di Pulau Timor mengalami kondisi basah ringan. Hal ini dapat diketahui dari spektrum pin warna hijau yang terdapat di sekitar Pulau tersebut.



Gambar 4.25. Hasil Pemetaan Kekeringan Periode Februari 2017 (*Lead ke-1*)

Sama seperti bulan sebelumnya, dari hasil pemetaan tidak ditemukan adanya indikasi kekeringan di wilayah NTT. Hal ini dapat dikarenakan oleh musim di Indonesia pada bulan Februari adalah musim hujan, sehingga bencana kekeringan memiliki peluang yang kecil untuk terdeteksi. Terlihat pada Gambar 4.25, bahwa pada Februari 2017 terdapat tiga skala cuaca basah, dimana skala basah tertinggi terdapat pada wilayah Pulau Timor, tepatnya di Kota Kupang dengan skala sangat basah. Pulau Flores didominasi oleh kondisi basah menengah. Hanya di Labuan Bajo dan Rapet mengalami kondisi basah ringan. Sementara itu, di Pulau Sumba mengalami kondisi yang paling kering, dimana kondisi basah ringan berada di sebelah Timur pulau dan kondisi normal berada di sebelah Barat pulau.



Gambar 4.26. Hasil Pemetaan Kekeringan Periode Maret 2017 (*Lead ke-1*)

Berikutnya adalah pemetaan kekeringan di Provinsi Nusa Tenggara Timur untuk periode Maret 2017. Pada bulan ini, terlihat pada Gambar 4.26 bahwa masih belum ditemukan adanya indikasi kekeringan di wilayah daratan NTT. Namun demikian, dapat dilihat bahwa skala cuaca basah yang terjadi di bulan Maret sudah lebih kering dibandingkan pada bulan sebelumnya, mengingat bahwa bulan Maret adalah bulan terakhir terjadinya musim hujan di wilayah Indonesia, termasuk NTT. Kondisi cuaca dengan skala basah masih sepenuhnya terdeteksi di wilayah Pulau Timor, dimana kondisi basah menengah terjadi di Kabupaten Kefamenanu dan kondisi basah ringan terjadi di Kabupaten Atambua dan Kota Kupang.



Gambar 4.27. Hasil Pemetaan Kekeringan Periode April 2017 (*Lead ke-1*)

Pemetaan kekeringan di Provinsi Nusa Tenggara Timur berlanjut untuk periode April 2017. Memasuki bulan April, Indonesia telah memasuki periode musim kemarau. Hal ini didukung oleh pemetaan pada Gambar 4.27, dimana kondisi cuaca di bulan ini lebih kering dari bulan-bulan sebelumnya. Namun demikian, kondisi terkering yang dapat dideteksi pada periode ini adalah kondisi normal, dimana cuaca ini terjadi hampir di seluruh wilayah NTT. Kondisi cuaca dengan skala basah ringan hanya terdeteksi di wilayah Pulau Timor, tepatnya di Kabupaten Kefamenanu.



Gambar 4.28. Hasil Pemetaan Kekeringan Periode Mei 2017 (*Lead ke-1*)

Pada Gambar 4.28, terlihat Pemetaan kekeringan di Provinsi Nusa Tenggara Timur pada *lead ke-1* memasuki akhir periode yaitu bulan Mei 2017. Dari Gambar 4.28 juga dapat terlihat bahwa terjadi kondisi anomali dalam pemetaan kekeringan bulan Mei, dimana cuaca kembali menuju ke kondisi basah. Hal ini dapat terlihat pada kondisi cuaca di tiga pulau utama di NTT, dimana seluruh wilayah NTT mengalami dari kondisi basah ringan sampai basah menengah. Adapun cuaca basah menengah terdeteksi pada daerah Barat di ketiga pulau secara bersamaan dan menjadi basah ringan pada sisi Timur dari ketiga pulau, baik Pulau Flores, Pulau Sumba, ataupun Pulau Timor.

Berdasarkan hasil pemetaan kekeringan yang telah dilakukan untuk lima periode pada *lead ke-1*, yaitu bulan Januari 2017 sampai dengan Mei 2017, dapat diketahui bahwa selama lima periode pengamatan tidak dideteksi satupun wilayah dengan kondisi kekeringan. Adapun kondisi terkering yang terpetakan adalah kondisi normal. Untuk memperjelas mengenai rincian klasifikasi pemetaan kekeringan di wilayah NTT selama lima periode pengamatan pada *lead time ke-1*, maka dapat dilakukan perbandingan kondisi cuaca di tiga pulau besar pada wilayah NTT selama periode Januari 2017 sampai dengan Mei 2017 sebagai berikut.

Tabel 4.15. Klasifikasi Kekeringan di Wilayah NTT pada *Lead* ke-1

Periode	Pulau	Hasil Pemetaan Skala Kekeringan
Januari 2017	Pulau Flores	Normal
	Pulau Sumba	Normal
	Pulau Timor	Basah Ringan
Februari 2017	Pulau Flores	Basah Menengah
	Pulau Sumba	Normal
	Pulau Timor	Basah Menengah
Maret 2017	Pulau Flores	Normal
	Pulau Sumba	Normal
	Pulau Timor	Basah Ringan
April 2017	Pulau Flores	Normal
	Pulau Sumba	Normal
	Pulau Timor	Normal
Mei 2017	Pulau Flores	Basah Ringan
	Pulau Sumba	Basah Ringan
	Pulau Timor	Basah Ringan

Dari hasil rangkuman mengenai klasifikasi kekeringan berdasarkan skala SPI sepanjang Periode Januari 2017 sampai dengan Mei 2017 pada Tabel 4.15, dapat diketahui bahwa tidak terjadi kekeringan di Provinsi Nusa Tenggara Timur. Adapun kondisi yang paling mendekati kering hanya terjadi pada bulan April 2017 dan kondisi terbasah terjadi pada Februari dan Mei 2017. Dari tiga pulau besar yang diamati, dapat diketahui bahwa Pulau dengan kondisi terkering sepanjang periode pemetaan adalah Pulau Sumba, diikuti oleh Pulau Flores dan kemudian terakhir diikuti oleh Pulau Timor.

4.7.2. Pemetaan Kekeringan di Provinsi Nusa Tenggara Timur Untuk *Lead* Ke-4

Selanjutnya akan dilakukan pemetaan kekeringan di Nusa Tenggara Timur untuk hasil peramalan curah hujan pada *lead*

time ke-4. Sama seperti analisis sebelumnya pada *lead time* ke-1, terdapat lima periode pemetaan yang dilakukan. Gambaran mengenai pemetaan dikhususkan hanya untuk koordinat Nusa Tenggara Timur saja dan dibatasi hanya pada wilayah daratan. Berikut akan ditampilkan mengenai hasil pemetaan kekeringan di Nusa Tenggara Timur berdasarkan tinjauan *Standardized Precipitation Index* (SPI) dimulai dari periode Januari 2017 sampai dengan Mei 2017 pada *lead* ke-4.



Gambar 4.29. Hasil Pemetaan Kekeringan Periode Januari 2017 (*Lead* ke-4)

Gambar 4.29 menunjukkan hasil pemetaan kekeringan di Provinsi Nusa Tenggara Timur berdasarkan tinjauan nilai SPI untuk *lead time* ke-4. Dari hasil pemetaan untuk periode Januari 2017, ditemukan adanya indikasi kekeringan di sepanjang wilayah wilayah NTT. Adapun skala kekeringan yang terdeteksi diantaranya adalah skala kekeringan ringan pada seluruh wilayah daratan di Pulau Flores. Kemudian kekeringan menengah terdeteksi pada seluruh wilayah daratan di Pulau Sumba. Pada Pulau Sumba, hanya terdapat satu wilayah yang mengalami kekeringan ringan yaitu pada wilayah Kabupaten Tapil. Sementara itu, pada Pulau Timor diketahui bahwa tidak ditemukan indikasi terjadinya kekeringan, dimana di seluruh wilayah Pulau ini mengalami kondisi cuaca normal.



Gambar 4.30. Hasil Pemetaan Kekeringan Periode Februari 2017 (*Lead ke-4*)

Selanjutnya adalah pemetaan kekeringan di Provinsi Nusa Tenggara Timur untuk periode Februari 2017. Dari hasil pemetaan, hanya ditemukan adanya indikasi kekeringan di Pulau Timor. Pada periode ini skala kekeringan pada Pulau Timor yang terdeteksi diantaranya kekeringan menengah di Kota Kupang dan kekeringan ringan di Kabupaten Atambua. Pada Pulau Flores, dimulai dari wilayah Utara kondisi cuaca adalah basah menengah. Menuju arah Timur, dimulai dari Kabupaten Ruteng sampai dengan Kabupaten Maumere cuaca berubah ke kondisi menengah ringan hingga kondisi normal pada Kabupaten Nobo. Pada Pulau Timor, kondisi cuaca bervariasi dimulai dari sisi Barat dengan kondisi normal hingga kondisi basah ringan semakin ke Timur.



Gambar 4.31. Hasil Pemetaan Kekeringan Periode Maret 2017 (*Lead ke-4*)

Berikutnya adalah pemetaan kekeringan di Provinsi Nusa Tenggara Timur untuk periode Maret 2017. Pada bulan Maret, bencana kekeringan semakin terdeteksi secara signifikan di seluruh wilayah NTT. Dapat dilihat pada Gambar 4.31 bahwa kekeringan menengah terdeteksi pada seluruh wilayah di Pulau Sumba dan Pulau Timor. Sementara itu, pada Pulau Flores wilayah kekeringan terbagi menjadi dua, yaitu wilayah dengan kekeringan menengah di sisi Barat Pulau dan wilayah dengan kekeringan ringan di sisi Timur Pulau.



Gambar 4.32. Hasil Pemetaan Kekeringan Periode April 2017 (*Lead ke-4*)

Berikutnya pemetaan kekeringan di Provinsi Nusa Tenggara Timur untuk periode April 2017. Dari hasil pemetaan Pada periode April 2017 terlihat bahwa bencana kekeringan yang melanda Nusa Tenggara Timur berada pada puncaknya, dimana seluruh wilayah NTT terkategori mengalami kekeringan besar. Hal ini dapat dilihat dari spektrum pin warna merah gelap yang ditampilkan pada Gambar 4.32 di atas. Adapun hanya terdapat satu wilayah yang terindikasi mengalami kekeringan dengan skala yang lebih ringan, yaitu di Kota Kupang dengan skala kekeringan menengah. Hal ini bisa jadi dikarenakan oleh masuknya Indonesia ke periode awal musim kemarau di bulan April.



Gambar 4.33. Hasil Pemetaan Kekeringan Periode Mei 2017 (*Lead ke-4*)

Gambar 4.33 di atas adalah hasil pemetaan kekeringan di Provinsi Nusa Tenggara Timur pada periode terakhir, yaitu Mei 2017. Dari Gambar 4.29, dapat terlihat situasi kekeringan telah mereda memasuki bulan Mei 2017. Hal ini dapat terlihat pada perubahan kategori kondisi cuaca di seluruh wilayah NTT dari kekeringan besar pada bulan April menjadi kekeringan menengah. Kondisi ini persisi sama seperti pada pemetaan bulan Mei 2017 pada *lead-1*, dimana terjadi kondisi meredanya skala kekeringan pada Bulan April 2017 menuju bulan Mei 2017.

Sama seperti pada *lead time* sebelumnya, dari hasil pemetaan kekeringan yang telah dilakukan untuk lima periode pada *lead ke-4* yaitu bulan Januari 2017 sampai dengan Mei 2017, maka dapat dilakukan perbandingan kondisi cuaca di tiga pulau besar di wilayah NTT seperti pada Tabel 4.16.

Tabel 4.16 Klasifikasi Kekeringan di Wilayah NTT *lead* ke-4

Periode	Pulau	Hasil Pemetaan Skala Kekeringan
Januari 2017	Pulau Flores	Kekeringan Ringan
	Pulau Sumba	Kekeringan Menengah
	Pulau Timor	Normal
Februari 2017	Pulau Flores	Basah Ringan
	Pulau Sumba	Normal
	Pulau Timor	Kekeringan Ringan
Maret 2017	Pulau Flores	Kekeringan Menengah
	Pulau Sumba	Kekeringan Menengah
	Pulau Timor	Kekeringan Menengah
April 2017	Pulau Flores	Kekeringan Besar
	Pulau Sumba	Kekeringan Besar
	Pulau Timor	Kekeringan Besar
Mei 2017	Pulau Flores	Kekeringan Menengah
	Pulau Sumba	Kekeringan Menengah
	Pulau Timor	Kekeringan Menengah

Dari hasil rangkuman mengenai klasifikasi kekeringan berdasarkan skala SPI sepanjang periode Januari 2017 sampai dengan Mei 2017 pada sebagaimana dipaparkan pada Tabel 4.16, dapat diketahui bahwa bencana kekeringan kerap terjadi sepanjang periode. Adapun peristiwa pemetaan yang terkategori basah hanya terjadi di satu periode, yaitu hanya di Pulau Flores pada bulan Februari 2017. Dapat diketahui juga bahwa pola kekeringan yang terjadi di Nusa Tenggara Timur pada periode Januari 2017 sampai dengan Mei pada *lead* ke-4 cenderung homogen pada masing-masing pulau. Dari Tabel 4.16 juga diketahui bahwa pulau di NTT yang mengalami kecenderungan untuk terjadi kekeringan paling besar adalah masih sama seperti pada *lead time* sebelumnya, yaitu Pulau Sumba. Sementara itu Pulau Timor dengan Pulau Flores memiliki kecenderungan yang sama besar untuk mengalami peristiwa kekeringan.

(halaman ini sengaja dikosongkan)

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan analisis yang telah dilakukan, maka dapat ditarik kesimpulan sebagai berikut.

1. Peramalan dengan menggunakan metode BMA-EM memberikan hasil yang optimum pada nilai *window time* yang berbeda untuk setiap *lead time* ($m = 12$ untuk *lead* ke-1 dan $m = 24$ untuk *lead* ke-4), dimana hasil kalibrasi ini terbukti memampatkan interval nilai peramalan sehingga lebih padat dan berpeluang lebih besar dalam mendekati nilai observasi.
2. Peramalan dengan menggunakan metode EMOS memberikan hasil yang optimum pada nilai *window time* yang sama untuk kedua *lead time*, dimana nilai m optimum adalah dengan menggunakan nilai $m = 24$ untuk hampir setiap koordinat yang diramalkan. Interval peramalan yang dihasilkan menggunakan metode EMOS cenderung lebih lebar dibandingkan dengan menggunakan metode BMA-EM.
3. Dari hasil perhitungan menggunakan nilai CRPS (*Continuous Rank Probability Score*), dapat diketahui bahwa metode kalibrasi menggunakan peramalan BMA-EM menghasilkan kualitas peramalan yang lebih baik dibandingkan dengan metode EMOS. Hal ini dapat dilihat dari nilai CRPS yang dihasilkan untuk metode BMA-EM yang lebih kecil.
4. Dari hasil pemetaan yang dilakukan berdasarkan tinjauan *Standardized Precipitation Index* (SPI), terjadi perbedaan kecenderungan antara pemetaan kekeringan untuk *lead time* ke-1 dengan pemetaan kekeringan untuk *lead time* ke-4. Sementara itu hasil pemetaan dengan menggunakan *lead time* ke-4 menunjukkan hasil kecenderungan terhadap terjadinya kekeringan dan homogen pada sepanjang wilayah Nusa Tenggara Timur dibandingkan dengan pemetaan menggunakan *lead* ke-1.

5. Dari hasil pengkategorian tiga pulau besar di Provinsi Nusa Tenggara Timur, diketahui bahwa Pulau Sumba memiliki potensi mengalami bencana kekeringan dibandingkan dua pulau besar lainnya, yaitu Pulau Flores dan Pulau Timor.

5.2 Saran

Dari hasil analisis dan pembahasan yang sudah dilakukan, saran yang dapat diberikan untuk perkembangan penelitian ke depan diantaranya adalah dengan melakukan penambahan opsi *window time*. Hal ini mengingat bahwa hasil akurasi peramalan memiliki ketergantungan yang cukup besar terhadap pemilihan nilai m . Dengan semakin banyak opsi *window time* yang digunakan, maka dapat diketahui kira-kira *window time* manakah yang mampu menghasilkan kualitas peramalan yang lebih baik. Selain itu, perlu dilakukan analisis lebih mendalam lagi terhadap pencarian nilai interval, salah satunya dengan mempertimbangkan bentuk distribusi *mixture*.

DAFTAR PUSTAKA

- Baran, S., Horanyi, A., & Nemoda, D. (2013). Comparison of BMA and EMOS Statistical Calibration Methods for Temperature and Wind Speed Ensemble Weather Prediction. *Hungarian Meteorological Service*, 22, 273-282. Retrieved from <https://arxiv.org/abs/1312.3763>
- Barnston, A. G., Tippett, M. K., van den Dool, H., & Unger, D. A. (2015). Toward an Improved Multimodel ENSO Prediction. *Journal of Applied Meteorology and Climatology*, 56(8), 1579-1595. doi: 10.1175/JAMC-D-14-0188.1
- Becker, E. J., van den Dool, H., Zhang, Q., & Chen, L. C. (2015). Forecasting Temperature Extremes with the North-American Multi Model Ensemble. *Science and Technology Infusion Climate Bulletin*.
- Breiman, L. (1996). Stacked Regression. *Machine Learning*, 24, 49-64. doi: 10.1023/A:1018046112532
- Buizza, R., & Coauthors (2007). The New ECMWF VAREPS (Variable Resolution Ensemble Prediction System). *Quarterly Journal of The Royal Meteorological Society*, 133, 681-695. doi: 10.1002/qj.75
- Candille, G. (2009). The Multiensemble Approach: The NAEFS Example. *Monthly Weather Review*, 138, 1655-1665. doi: 10.1175/2008MWR2682.1
- Changnon, S. A. (1987). Droughts in Illinois: Their Physical and Social Dimensions. *III. State Water Survey*, 369. doi: 10.1111/j.1752-1688.1989.tb05663.x
- Chen, N., Qian, Z., Nabney, I. T., & Meng, X. (2013). Wind Power Forecast Using Gaussian Processes and Numerical Weather Prediction. *IEEE Transactions on Power Systems*, 29(2), 656-665. doi: 10.1109/TPWRS.2013.2282366

- CNN. (2015). *Kekeringan Landa Delapan Provinsi di Indonesia*. Retrieved December 30, 2016, from <http://www.cnnindonesia.com/nasional/20150728095930-20-68525/kekeringan-landa-delapan-provinsi-di-indonesia/>
- CNN. (2017). *Jokowi Minta Anak Buahnya Tekan Angka Kemiskinan di NTT*. Retrieved January 20, 2017, from <http://www.cnnindonesia.com/nasional/20170216211459-20-194115/jokowi-minta-anak-buahnya-tekan-angka-kemiskinan-di-ntt/>
- Collins, W. D., & Coauthors. (2014). The Community Climate System Model Version 3 (CCSM3). *Journal of Climate*, 19, 2122-2143. doi: 10.1175/JCLI3761.1
- Dempster, A. P., Laird, N. M., & Rubin, D. B. (1977). Maximum Likelihood for Incomplete Data via the EM Algorithm. *Journal of The Royal Statistical Society*, 39(1), 1-38. Retrieved from <http://www.jstor.org/stable/2984875>
- Gent, P. R., & Coauthors. (2011). The Community Climate System Model Version 4. *Journal of Climate System Model Version 4*, 24, 4973-4991. doi: 10.1175/2011JCLI4083.1
- Glahn, H. R., & Lowry, D. A. (1972). The Use of Model Output Statistics (MOS) in Objective Weather Forecasting. *Journal of Applied Meteorology*, 11(8), 1203-1211. doi: 10.1175/1520-0450(1972)011<1203:TUOMOS>2.0.CO;2
- Gneiting, T., Raftery, A. E., Westveld III, A. H., & Goldman, T. (2005). Calibrated Probabilistic Forecasting Using Ensemble Model Output Statistics and Minimum CRPS Estimation. *Monthly Weather Review*, 135(5), 1098-1118. doi: 10.1175/MWR2904.1
- Gneiting, T., Raftery, A. E. (2005). Weather Forecasting With Ensemble Methods. *Science*, 310, 248-249. doi: 10.1126/science.1115255

- Gutmann, N. B. (1998). Comparing The Palmer Drought Index and The Standardized Precipitation Index. *JAWRA Journal of The American Water Resources Association*, 34(1), 113-121. doi: 10.1111/j.1752-1688.1998.tb05964.x
- Hamill, T. (2001). Interpretation of Rank Histograms for Verifying Ensemble Forecasts. *Monthly Weather Review*, 129, 550-560. doi: 10.1175/1520-0493(2001)129<0550-IORHFV>2.0.CO;2
- Hayes, M., Svoboda, M., Wall, N., & Widhalm, M. (2011). The Lincoln Declaration on Drought Indices: Universal Meteorological Drought Index Recommended. *Bulletin of American Meteorological Society*, 92, 485-8. doi: 10.1175/2010BAMS3103.1
- Hersbach, H. (2000). Decomposition of the Continuous Ranked Probability Score for Ensemble Prediction Systems. *Weather and Forecasting*, 15, 559-570. doi: 10.1175/1520-0434(2000)015<0559:DOTCRP>2.0.CO;2
- Houtekamer, P. (2000). *Ensemble Forecasts*. Retrieved 6/24/2017 from: http://collaboration.cmc.ec.gc.ca/cmc/cmoe/product_guide/docs/lib/ens_en.pdf
- Kharin, V. V., & Coauthors. (2009). Skill Assessment of Seasonal Hindcasts from the Canadian Historical Forecast Project, *Atmos-Ocean*, 47, 204-203. doi: 10.3137/AO1101.2009
- Kirtman, B. P., & and Coauthors. (2014). The North American Multi Model Ensemble (NMME); Phase-1, Seasonal-to-Interannual Prediction; Phase-2, Toward Developing Intraseasonal Prediction. *Bulletin of American Meteorological Society*, 95(4), 585-601. doi: 10.1175/BAMS-D-12-00050.1
- Kirtman, B. P., & Min, D. (2009). Multimodel Ensemble ENSO Prediction with CCSM and CFS. *Monthly Weather Review*, 137, 2908, 2930. doi: 10.1175/2009MWR2672.1

- Kuswanto, H., & Sari, M. R. (2013). Bayesian Model Averaging With Markov Chain Monte Carlo for Calibrating Temperature Forecast From Combination of Time Series Model. *Journal of Mathematics and Statistics*, 9(4), 349-356. doi: 10.3844/jmssp.2013.349.356
- Lawrence, D. M., & Coauthors. The CCSM4 Land Simulation, 1850-2005: Assessment of Surface Climate and New Capabilities. *Journal of Climate*, 25, 2240-2260. doi: 10.1175/JCLI-D-11-00103.1
- Lestari, I. L. (2016). Analisis Empirical Orthogonal Function (EOF) Berbasis Singular Value Decomposition (SVD) Pada Data Curah Hujan Indonesia. *IPB Journal of Mathematics and Natural Science*. Retrieved from <http://repository.ipb.ac.id/handle/123456789/80495>
- Leutbecher, M., & Palmer, T. N. (2008). Ensemble Forecasting. *Journal of Computational Physics*, 227, 3515-3539. doi: 10.1016/j.jcp.2007.02.014
- Lynch, P. (2008). The Origins of Computer Weather Prediction and Climate Modeling. *Journal Of Computational Physics*, 227(7), 3431-3444. doi: 10.1016/j.jcp.2007.02.034
- Ma, F., & Coauthors (2015). Evaluating the Skill of NMME Seasonal Precipitation Ensemble Predictions for 17 Hydroclimatic Regions in Continental China. *International Journal of Climatology*, 36(1), 132-144. doi: 10.1002/joc.4333
- Marrocu, M., & Chessa, P. A. (2008). A Multi-Model / Multi-Analysis Limited Area Ensemble: Calibration Issues. *Meteorological Applications*, 15(1), 171-179. doi: 10.1002/met.48
- Milly, P. C. D., & Shmakin, A. B. (2002). Global Modeling of Land, Water, and Energy Balances. Part I: The Land Dynamics Model. *Journal of Hydrometeorology*, 19, 643-674. doi: 10.1175/1525-7541(2002)003<0283GMOLWA>2.0.CO;2

- McFarlane, N. A., & Coauthors. (2008). The CCCma Third Generation Atmospheric General Circulation Model and Its Extension Into the Middle Atmosphere. *Atmospheric Chemistry and Physics*, 8, 7055-7074. doi: 10.5194/acp-8-7055-2008
- McKee, T. B., Doesken, N. J., & Klesit, J. (1993). The Relationship of Drought Frequency and Duration to Time Scales. *American Meteorological Society*, 179-184. Retrieved from http://clima1.cptec.inpe.br/~rclima1/pdf/paper_spi.pdf
- Merryfield, W. J., & Coauthors (2013). The Canadian Seasonal to Interannual Prediction System. Part I: Models and Initialization. *Monthly Weather Review*, 141, 2910-2945. doi: 10.1175/MWR-D-12-00216.1
- Montgomery, J.M., & Nyhan, B. (2010). Bayesian Model Averaging: Theoretical Developments and Practical Applications. *Political Analysis*, 18(2), 245-270. doi: <https://doi.org/10.1093/pan/mpq001>
- Murphy, J. M. (1988). The Impact of Ensemble Forecast on Predictability. *Quarterly Journal of The Royal Meteorological Society*, 114(480), 463-493. doi: 10.1002/qj.49711448010
- Pena, M. (2011). *Ensemble Forecasts and Their Verification*, Ensemble Group at EMC, Guest Class.
- Prokosch, J. (2013). *Bivariate Bayesian Model Averaging and Ensemble Model Output Statistics With a Case Study of Ensemble Temperature Forecast in Trondheim*. Trondheim: Norwegian University of Science and Technology.
- Raftery, A. E., Gneiting, T., Balabdaoui, F., & Polakowski, M. (2005). Using Bayesian Model Averaging to Calibrate Forecast Ensembles. *Monthly Weather Review*, 113, 1155-1174. doi: 10.1175/MWR2906.1

- Raftery, A. E., & Zheng, Y. (2003). Performance of Bayesian Model Averaging. *Journal of American Statistical Association*, 98, 931-938. doi: 10.1198/0162145030000891
- Raharjo & Dwi, P. (2010). Teknik Pengindraan Jauh dan Sistem Informasi Geografis untuk Identifikasi Potensi Kekeringan Kabupaten Kebumen. *Jurnal Makara Teknologi*, 14(2), 97-105.
- SAARC. (2010). *SAARC Workshop on Drought Risk Management in South Asia*. SAARC Disaster Management Centre, New Delhi in collaboration with Afghanistan National Disaster Management Authority.
- Sharkey, A. J. C. (1999). *Combining Artificial Neural Nets: Ensembl and Modular Multi-Net Systems*. New York: Springer-Verlag.
- Sheffield, J., & Wood E. F. (2011). *Drought Pass Problems and Future Scenarios*. New Jersey: Routledge.
- Shofiyati, R., Darmawan, S., & Takeuchi, W. (2014). Seasonal Analysis of Precipitation, Drought, and Vegetation Index in Indonesian Paddy Field Based on Remote Sensing Data. *IOP Conference Series: Earth and Environmental Science*, 20(1).
- Shu, C., & Burn, D. H. (2004). Artificial Neural Network Ensembles and Their Application in Pooled Flood Frequency Analysis. *Water Resource Research*, 40, 9. doi: 10.1029/2003WR002816
- Singer, E., Endreny, P., & Glassman, M. B. (1991). Media Coverage of Disasters: Effect of Geographic Location. *Journalism Quarterly*, 68(1-2), 48-58. doi: 10.1177/107769909106800106
- Slughter, J. M., Gneiting, T., & Raftery, A. E. (2010). Probabilistic Wind Speed Forecasting Using Ensembles and Bayesian Model Averaging. *Journal of the American Statistical Association*, 105(489), 25-35. doi: 10.1198/jasa.2009.ap08615

- Sloughter, J. M., Gneiting, T., Raftery, A. E., & Fraley, C. (2007). Probabilistic Quantitative Precipitation Forecasting Using Bayesian Model Averaging. *Monthly Weather Review*, 135, 3209-3220. doi: 10.1175/MWR3441.1
- Sosrodarsono, S. (1985). *Hidrologi*. Jakarta: PT Pradnya Paramita.
- Toth, Z., Talagrand, O., Candille, G., & Zhu, Y. (2002). Probability and Ensemble Forecasts. *Environmental Forecast Verification: A Practitioner's Guide in Atmospheric Science*, 137-164.
- UN-ISDR. (2009). *Drought Risk Reduction Framework and Practices*. United Nations International Strategy for Disaster Reduction.
- Vrugt, J. A., Diks, C. G., & Clark, M. P. (2008). Ensemble Bayesian Model Averaging Using Markov Chain Monte Carlo Sampling. *Environmental Fluid Mechanics*, 8(5-6), 579-595. doi: 10.1007/s10652-008-9106-3
- Wang, H. (2014). Evaluation of Monthly Precipitation Forecasting Skill of the North-American Multi Model Ensemble in the Summer Season. *Hydrological Processes*, 28(15), 4472-4486. doi: 10.1002/hyp.9957
- Wei, W. W. S. (2006). *Time Series Analysis Univariate and Multivariate Methods*. New York: Pearson Education, Inc.
- Wilhite, D. A. (2011). Quantification of Agricultural Drought for Effective Drought Mitigation and Preparedness: Key Issues and Challenges. *Drought Mitigation Center Faculty Publications*. Retrieved from <http://digital-commons.unl.edu/droughtfacpub/82/>
- Yuan, X., & Wood, E. F. (2013). Multimodel Seasonal Forecasting of Global Drought Onset. *Geophysical Research Letters*, 40(18), 4900-4905. doi: 10.1002/grl.50949

- Yucel, I., Onen, A., Yilmaz, K. K., & Gochis, D. J. (2015). Calibration and Evaluation of A Flood Forecasting System: Utility of Numerical Weather Prediction Model, Data Assimilation and Satellite-Based Rainfall. *Journal of Hydrology*, 523, 49-66. doi: 10.1016/j.jhydrol.2015.01.042
- Zaier, I., Shu, C., Ouarda, T. B. M. J., Seidou, O., & Chebana, F. (2010). Estimation of The Ice Thickness on Lakes Using Artificial Neural Network Ensembles. *Journal of Hydrology*, 383, 330-340. doi: 10.1016/j.jhydrol.2010.01.006
- Zhang, S., & Harrison, M. J., Rosati, A., & Wittenberg, A. (2006). System Design and Evaluation of Coupled Ensemble Data Assimilation for Global Oceanic Climate Studies. *Monthly Weather Review*, 135, 3541-3564. doi: 10.1175/MWR3466.1
- Zhu, Y. (2005). Ensemble Forecast: A New Approach To Uncertainty and Predictability. *Advanced Atmospheric Science*, 22, 781-788. doi: 10.1007/BF02918678

LAMPIRAN

Lampiran 1. Data Observasi dan Data Peramalan Curah Hujan Bulanan di NTT (Nusa Tenggara Timur)

a.) Lead ke-1

Period	Long.	Lat.	M1	M2	M3	M4	M5	Obs
January 2011	118	-12	11.96	9.68	8.25	16.05	11.06	11.33
	119	-12	12.88	10.28	8.14	16.17	11.49	12.05
	120	-12	13.82	10.98	7.54	16.44	11.97	12.40
	121	-12	14.78	11.66	6.49	17.51	12.46	12.36
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	122	-8	11.30	10.59	7.51	13.60	10.69	7.07
	123	-8	11.54	11.69	8.29	13.96	11.03	8.65
	124	-8	11.84	12.43	9.40	14.61	11.28	8.23
	125	-8	12.33	12.06	10.37	14.92	11.32	7.97
February 2011	118	-12	9.50	12.25	10.81	6.49	10.18	11.77
	119	-12	9.81	13.12	11.07	6.72	10.27	13.08
	120	-12	10.09	14.18	11.30	6.53	10.01	14.00
	121	-12	10.37	15.15	11.42	6.46	9.75	13.99
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	122	-8	9.99	9.55	9.02	12.02	6.43	6.56
	123	-8	10.75	11.00	9.72	12.04	6.35	8.63
	124	-8	11.37	12.10	10.49	12.46	6.35	8.25
	125	-8	11.61	12.13	10.88	12.91	6.58	7.29

Lampiran 1(a). Lanjutan

Period	Long.	Lat.	M1	M2	M3	M4	M5	Obs
March 2011	118	-12	6.87	4.37	6.46	5.04	7.10	5.72
	119	-12	6.96	4.74	6.44	4.90	7.73	6.40
	120	-12	7.00	5.26	6.68	4.75	8.80	6.78
	121	-12	7.05	5.74	7.17	5.55	9.87	7.13
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	122	-8	6.31	5.96	6.39	7.13	11.73	8.85
	123	-8	6.52	6.81	6.26	7.42	11.70	9.29
	124	-8	6.68	7.63	6.28	8.86	11.76	7.67
	125	-8	6.68	8.35	6.40	9.80	12.07	6.70
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	
December 2016	118	-12	9.12	4.63	12.73	5.79	12.56	9.36
	119	-12	9.54	5.67	13.32	6.84	11.93	8.43
	120	-12	9.93	6.82	13.58	5.95	10.48	6.79
	121	-12	10.27	7.85	13.54	5.23	9.02	6.40
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	122	-8	11.74	8.97	10.10	8.54	14.64	7.97
	123	-8	11.82	8.64	10.97	9.19	16.14	7.59
	124	-8	11.80	8.39	12.09	11.25	17.01	6.38
	125	-8	11.50	8.34	12.83	13.86	15.95	6.64

b.) Lead ke-4

Period	Long.	Lat.	M1	M2	M3	M4	M5	Obs
January 2011	118	-12	6.91	7.78	2.34	0.11	6.91	11.33
	119	-12	6.11	8.12	2.52	0.10	6.11	12.05
	120	-12	5.30	8.61	2.70	0.10	5.30	12.40
	121	-12	4.52	9.03	2.76	0.10	4.52	12.36
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	122	-8	9.46	10.28	9.75	0.52	13.49	7.07
	123	-8	9.42	10.82	7.94	0.42	14.51	8.65
	124	-8	9.85	11.28	6.55	0.35	15.42	8.23
	125	-8	11.68	11.51	5.73	0.42	15.99	7.97
	February 2011	118	-12	3.61	3.15	0.87	0.11	2.64
119		-12	3.36	3.09	1.08	0.08	2.15	13.08
120		-12	3.07	3.09	1.05	0.07	1.67	14.00
121		-12	2.78	3.09	0.74	0.05	1.19	13.99
⋮		⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮		⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮		⋮	⋮	⋮	⋮	⋮	⋮	⋮
122		-8	9.78	7.68	4.11	0.37	9.89	6.56
123		-8	10.21	7.50	3.21	0.25	9.71	8.63
124		-8	10.45	7.50	2.21	0.20	9.62	8.25
125		-8	10.16	8.06	1.53	0.24	9.81	7.29

Lampiran 1(b). Lanjutan

Period	Long.	Lat.	M1	M2	M3	M4	M5	Obs
March 2011	118	-12	0.68	2.02	1.97	0.11	1.91	5.72
	119	-12	0.57	1.75	2.30	0.09	1.61	6.40
	120	-12	0.46	1.44	2.50	0.08	1.28	6.78
	121	-12	0.35	1.15	2.49	0.09	0.96	7.13
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	122	-8	2.83	5.84	1.50	0.47	4.54	8.85
	123	-8	3.04	6.02	1.45	0.42	4.25	9.29
	124	-8	3.18	6.15	1.51	0.33	4.02	7.67
	125	-8	3.15	6.08	1.55	0.37	3.94	6.70
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	
December 2016	118	-12	7.68	13.22	1.15	2.62	16.93	9.36
	119	-12	8.22	13.36	1.15	2.72	18.55	8.43
	120	-12	8.86	13.56	1.12	3.11	19.19	6.79
	121	-12	9.49	13.63	1.02	3.01	19.82	6.40
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	122	-8	8.56	7.16	2.17	4.44	8.56	7.97
	123	-8	8.73	7.58	1.56	3.96	8.73	7.59
	124	-8	8.99	7.91	1.08	3.50	8.99	6.38
	125	-8	9.53	7.96	0.83	3.84	9.53	6.64

Lampiran 2. Syntax Merubah Data ECMWF Menjadi Format Text. (format *.nc* → *.txt*)

```
'c'
'set t 1 last'
awallintang=-12
akhirlintang=-8
bedalintang=1
awalbujur=118
akhirbujur=125
bedabujur=1
iterlintang=((akhirlintang-awallintang)/bedalintang)+1
iterbujur=((akhirbujur-awalbujur)/bedabujur)+1

j=1
say 'titik lintang yang akan digunakan'
while(j<=iterlintang)
lintang.j=awallintang+((j-1)*bedalintang)
say lintang.j
j=j+1
endwhile

k=1
say 'titik bujur yang akan digunakan'
while(k<=iterbujur)
bujur.k = awalbujur+((k-1)*bedabujur)
say bujur.k
k=k+1
endwhile

l=1
while(l<=iterlintang)
say 'lintang ke ' l
'c'
i=1
while(i<=iterbujur)
'set lat 'lintang.l
'set lon 'bujur.i
'fprintf tp D:\Data\data_lintang_'bujur.i'_bujur_'lintang.l'.txt %g 1'
i=i+1
endwhile
l=l+1
endwhile
```

Lampiran 3. Syntax R Merubah Penggabungan Data per Koordinat menjadi Satu File (format *.txt* → *.csv*)

```

setwd("d:/TA/data1/SSTtxt")
filelist = list.files(pattern = ".*.txt", full.names=TRUE)
myfunction <- function(x)
{
  data <- readLines(x)
  split_content = strsplit(data, split = " ")
  data2 <- unlist(split_content)
  data3 <- as.numeric(data2)
}
#datalist = lapply(filelist, function(x)readLines(x))
datalist = lapply(filelist, myfunction)
datafr = do.call("rbind", datalist)
datafr=t(datafr)
tgl=read.table('d:/TA/syntax/tgl1.txt')
datafr1=cbind(tgl,datafr)

write.table(datafr1,"d:/TA/data1/SSTexcel/allsst.csv",sep="," ,row.names=
FALSE)
write.table(filelist,"d:/TA/data1/SSTexcel/listsst.csv",sep="," ,col.names=T
RUE,row.names=FALSE)

#all -> hasil data gabungan #list -> keterangan koordinat

```

Lampiran 4. Syntax Looping Untuk Separasi Data per Koordinat

```

rhl6 <- read.csv("databmal1.csv")
coord=rhl6[,1:3]
obs=rhl6[,4]
rhl6=rhl6[,-c(1:4)]
rhl6=cbind(rhl6,obs,coord)
rhl6$Longitude=as.factor(rhl6$Longitude)
long.level=levels(rhl6$Longitude)
rhl6$Latitude=as.factor(rhl6$Latitude)
lat.level=levels(rhl6$Latitude)
n.long.level=length(long.level)
n.lat.level=length(lat.level)
id=c(1:n.lat.level)

```


Lampiran 4. Lanjutan

```

rhl6.long=NULL
databma=NULL
for(i in 1:length(long.level))
{
  long.id=which(rhl6$Longitude==long.level[i])
  rhl6.long[[i]]=rhl6[long.id,]
  rhl6.lat=NULL
  for(j in 1:length(lat.level))
  {
    lat.id=which(rhl6.long[[i]]$Latitude==lat.level[j])
    rhl6.lat[[j]]=rhl6.long[[i]][lat.id,]
  }

  for(j in 1:n.lat.level)
  {
    id.level=n.lat.level*(i-1)+id[j]
    databma[[id.level]]=rhl6.lat[[j]]
    rownames(databma[[id.level]])=c(1:nrow(databma[[id.level]]))
  }
}

library(stringr)
for(i in 1:length(databma))
{
  file=paste("D:/Lead7/databma",i,".csv")
  file=str_replace_all(file," ","")
  write.csv(databma[[i]],file)
}

```

Lampiran 5. Syntax R Kalibrasi dengan Metode BMA-EM

```

rhl6 <- read.csv("D:/Lead1/databma1.csv")

CRPS_EM <-function(data,date,m)
{
  start <- which(data$Period==date)
  dates <- toString(data$Period[start])

  Nmodel <- 5
  coldata <- ncol(data)

```

Lampiran 5. Lanjutan

```
data1 <- data[,2:6]
Y <- data[,coldata-3]
end <- length(data1)

##### PREPARING DATA FOR ESTIMATING LIKELIHOOD #####

StartT <- (start-m)
EndT <- start-1
Xcal <- data1[EndT+1,1:Nmodel]

Xcal <- as.matrix(Xcal)
Ycal <- Y[EndT+1]

Ycal <- as.numeric(Ycal)

memberLabels <- c("M1L6", "M2L6", "M3L6", "M4L6", "M5L6")

exGroups <- c(M1L6=1, M2L6=2, M3L6=3, M4L6=4, M5L6=5)

rhl6Data <- ensembleData(forecast=data[,2:6],
  dates=data$Period,
  observations=data$Obs,
  longitude=data$Longitude,
  latitude=data$Latitude,
  forecastHour=24,
  initializationTime="00",
  exchangeable=exGroups)

rhl6BMAfit <-
ensembleBMAgamma(rhl6Data,dates,controlBMAgamma(startupSpeed=1
),trainingDays=m)

weight <- rhl6BMAfit$weights

w1 <- weight[1]
w2 <- weight[2]
w3 <- weight[3]
w4 <- weight[4]
w5 <- weight[5]
```

Lampiran 5. Lanjutan

```

a <- rhl6BMAfit$biasCoefs
a1 <- a[1]
a2 <- a[2]

b <- rhl6BMAfit$varCoefs
b1 <- a[3]
b2 <- a[4]

mean <-
(a1+a2*Xcal[,1])*w1+(a1+a2*Xcal[,2])*w2+(a1+a2*Xcal[,3])*w3+(a1+a2*X
cal[,4])*w4+(a1+a2*Xcal[,5])*w5

mean <- as.numeric(mean)

ms = (mean-Ycal)^2

ori <- crps(rhl6BMAfit,rhl6Data)[1]
hier <- crps(rhl6BMAfit,rhl6Data)[2]

list (ori=ori, hier=hier, ms=ms, a=a, b=b, weight=weight)

}

CRPSmean <-function(data, awal, akhir, m)
{

miss <- which(!complete.cases(data[,2:7]))
jum <- length(miss)

if (jum==0){data <- data}
else if (jum!=0){data<-data[-miss,]}

start <- which(data$Period==awal)
end <- which(data$Period==akhir)
print (start)
print (end)

range <-end-start+1
print(range)

```

Lampiran 5. Lanjutan

```
CRPS_akhir0 <- matrix(nrow=3, ncol=1)
CRPS_akhir <- matrix(nrow=3, ncol=range)
bias <- matrix(nrow=2, ncol=1)
biaskoreksi <- matrix(nrow=2, ncol=range)
var <- matrix(nrow=2, ncol=1)
var_coef <- matrix(nrow=2, ncol=range)
bobot <- matrix(nrow=5, ncol=1)
bobotkumpulan <- matrix(nrow=5, ncol=range)
bobotakhir <- matrix(nrow=5, ncol=range)

for (ii in start:end)
{

tanggal <- data$Period[ii]

CRPS_akhir1 <- CRPS_EM(data, tanggal, m)
CRPS_akhir0[1] <- CRPS_akhir1$ori
CRPS_akhir0[2] <- CRPS_akhir1$hier
CRPS_akhir0[3] <- CRPS_akhir1$ms
bias <- CRPS_akhir1$a
var <- CRPS_akhir1$b
bobot <- CRPS_akhir1$w

jjj <- ii - (start - 1)
hoho <- as.vector(CRPS_akhir0)
hehe <- as.vector(bias)
haha <- as.vector(var)
hihi <- as.vector(bobot)

CRPS_akhir[,jjj] <- hoho
biaskoreksi[,jjj] <- hehe
var_coef[,jjj] <- haha
bobotkumpulan[,jjj] <- hihi

}
```

Lampiran 5. Lanjutan

```

CRPS_akhir <- CRPS_akhir
print(CRPS_akhir)
biaskoreksi <- biaskoreksi
print(biaskoreksi)
var_coef <- var_coef
print(var_coef)
bobotakhir <- bobotkumpulan
print(bobotakhir)

mean_ori = mean(CRPS_akhir[1,],na.rm=TRUE)
mean_hier= mean(CRPS_akhir[2,],na.rm=TRUE)
mse = mean(CRPS_akhir[3,],na.rm=TRUE)
bias0rata = mean(biaskoreksi[1,], na.rm=TRUE)
bias1rata = mean(biaskoreksi[2,], na.rm=TRUE)
var0rata= mean(var_coef[1,], na.rm=TRUE)
var1rata= mean(var_coef[2,], na.rm=TRUE)
bobotrata1 = mean(bobotkumpulan[1,], na.rm=TRUE)
bobotrata2 = mean(bobotkumpulan[2,], na.rm=TRUE)
bobotrata3 = mean(bobotkumpulan[3,], na.rm=TRUE)
bobotrata4 = mean(bobotkumpulan[4,], na.rm=TRUE)
bobotrata5 = mean(bobotkumpulan[5,], na.rm=TRUE)

list(mean_ori=mean_ori, mean_hier=mean_hier, mse=mse,
bias0rata=bias0rata, bias1rata=bias1rata, var0rata=var0rata,
var1rata=var1rata, bobotrata1=bobotrata1, bobotrata2=bobotrata2,
bobotrata3=bobotrata3, bobotrata4=bobotrata4, bobotrata5=bobotrata5)
}

```

Lampiran 6. Plot Kurva Distribusi BMA

```

start <- which(rhl6$Period==start)
dates <- toString(rhl6$Period[start])

Nmodel <- 5
coldata <- ncol(rhl6)

```

Lampiran 6. Lanjutan

```

data1 <- rh16[,2:6]
Y <- rh16[,coldata-3]
end <- length(data1)

StartT <- (start)
Xcal <- data1[start,1:Nmodel]

Xcal <- as.matrix(Xcal)
Ycal <- Y[start]

Ycal <- as.numeric(Ycal)

memberLabels <- c("M1L6","M2L6","M3L6","M4L6", "M5L6")

exGroups <- c(M1L6=1, M2L6=2, M3L6=3, M4L6=4, M5L6=5)

rh16Data <- ensembleData(forecast=rh16[,2:6],
dates=rh16$Period,
observations=rh16$obs,
longitude=rh16$Longitude,
latitude=rh16$Latitude,
forecastHour=24,
initializationTime="00",
exchangeable=exGroups)

rh16BMAfit <-
ensembleBMAgamma(rh16Data,dates,controlBMAgamma(startupSpeed=1
),trainingDays=m)

```

Lampiran 7. Syntax R Kalibrasi dengan Metode EMOS

```

start <- which(rh16$Period==start)
end <- which(rh16$Period==end)
dates <- toString(rh16$Period[start])

Nmodel <- 5
coldata <- ncol(rh16)

```

Lampiran 7. Lanjutan

```
data1 <- rh16[,2:6]
Y <- rh16[,coldata-1]

StartT <- (start-m)
EndT <- start-1
EndTT <- EndT+1
Xcal <-data1[EndTT,(1:5)]

Xcal <- as.matrix(Xcal)
Ycal <- Y[EndT+1]

Ycal <- as.numeric(Ycal)

memberLabels <- c("M1L1","M2L1","M3L1","M4L1","M5L1")

exGroups <- c(M1L6=1, M2L6=2, M3L6=3, M4L6=4, M5L6=5)

rh16Data <- ensembleData(forecast=rh16[,2:6],
dates=rh16$Period,
observations=rh16$obs,
forecastHour=24,
initializationTime="00",
exchangeable=exGroups)

rh16TestFit <- ensembleMOS(rh16Data, trainingDays=m, model="normal")

a <- rh16TestFit$a
b <- rh16TestFit$b
c <- rh16TestFit$c
d <- rh16TestFit$d

mean(a)
mean(b)
mean(c)
mean(d)
```

Lampiran 8. Data Hasil Kalibrasi Peramalan Menggunakan BMA-EM

a.) *Lead ke-1*

Period	Long.	Lat.	M1	M2	M3	M4	M5	Obs
January 2017	118	-12	6.05	5.48	12.73	2.12	5.65	5.54
	119	-12	6.45	6.81	13.32	2.60	6.02	6.79
	120	-12	6.87	8.25	13.58	3.07	6.63	7.01
	121	-12	7.30	9.64	13.54	3.41	7.25	7.93
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	122	-8	9.99	8.67	10.10	9.60	10.49	9.84
	123	-8	10.01	9.67	10.97	11.10	10.37	10.28
	124	-8	10.09	10.55	12.09	12.12	10.43	10.72
	125	-8	10.37	11.06	12.83	11.55	11.03	11.05
	February 2017	118	-12	5.26	6.35	10.34	9.74	7.30
119		-12	6.01	7.21	11.47	9.13	7.99	7.31
120		-12	6.78	8.18	12.58	8.11	8.86	7.90
121		-12	7.53	9.11	13.53	8.58	9.74	8.53
⋮		⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮		⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮		⋮	⋮	⋮	⋮	⋮	⋮	⋮
122		-8	9.98	10.17	11.07	9.63	10.12	10.33
123		-8	10.77	11.61	12.43	10.23	10.52	11.27
124		-8	11.47	12.63	13.69	11.47	10.92	11.87
125		-8	11.95	12.38	13.71	12.45	11.34	12.18

Lampiran 8(a). Lanjutan

Period	Long.	Lat.	M1	M2	M3	M4	M5	Obs
March 2017	118	-12	4.85	5.95	11.55	8.21	7.00	6.50
	119	-12	5.09	6.79	12.46	8.73	8.34	7.00
	120	-12	5.36	7.75	12.84	9.03	11.19	7.93
	121	-12	5.63	8.66	12.48	9.68	14.04	8.10
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	122	-8	7.21	8.52	6.74	7.86	9.07	7.82
	123	-8	7.92	10.09	6.87	8.47	10.04	8.98
	124	-8	8.60	11.36	6.95	9.47	11.21	9.58
	125	-8	9.19	11.77	6.88	9.73	12.96	9.95
	April 2017	118	-12	4.33	1.82	4.00	8.54	1.90
119		-12	4.37	1.76	3.89	7.98	1.94	2.87
120		-12	4.35	1.69	3.84	7.67	1.81	3.39
121		-12	4.33	1.64	3.82	7.00	1.68	3.40
⋮		⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮		⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮		⋮	⋮	⋮	⋮	⋮	⋮	⋮
122		-8	7.43	3.36	6.42	6.88	1.95	5.02
123		-8	8.04	3.98	6.71	6.95	1.65	5.00
124		-8	8.52	4.51	7.61	7.34	1.69	6.45
125		-8	8.60	4.77	9.22	7.63	2.77	6.99

Lampiran 8(a). Lanjutan

Period	Long.	Lat.	M1	M2	M3	M4	M5	Obs
May 2017	118	-12	1.01	4.02	7.00	2.07	13.17	6.60
	119	-12	0.93	3.73	6.07	1.87	11.97	4.93
	120	-12	0.84	3.55	5.17	1.72	9.94	4.10
	121	-12	0.76	3.36	4.33	1.53	7.92	2.68
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	122	-8	7.14	8.45	12.37	9.95	12.35	10.14
	123	-8	6.70	8.81	12.57	9.38	11.61	9.82
	124	-8	6.29	9.17	12.75	8.88	11.36	8.55
	125	-8	5.91	9.56	12.52	9.65	12.57	8.96

b.) Lead ke-4

Period	Long.	Lat.	M1	M2	M3	M4	M5	Obs
January 2017	118	-12	2.28	5.88	6.15	3.20	2.79	3.83
	119	-12	2.08	5.44	6.78	3.43	3.06	5.04
	120	-12	1.95	4.97	7.12	4.65	3.59	5.29
	121	-12	1.82	4.54	7.02	6.65	4.11	6.26
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	122	-8	3.76	6.51	5.90	2.90	3.40	4.12
	123	-8	3.67	6.74	6.62	3.81	3.68	5.04
	124	-8	3.65	6.96	8.19	5.01	4.11	5.91
	125	-8	3.83	7.15	9.69	6.16	4.97	7.35

Lampiran 8(b). Lanjutan

Period	Long.	Lat.	M1	M2	M3	M4	M5	Obs
February 2017	118	-12	1.06	2.55	3.89	2.96	6.90	3.10
	119	-12	1.07	2.16	3.79	2.93	6.96	3.20
	120	-12	1.09	1.79	3.81	2.67	5.92	3.04
	121	-12	1.11	1.43	3.88	1.97	4.89	2.73
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	122	-8	5.69	9.29	13.38	7.58	12.29	8.78
	123	-8	6.04	9.12	12.84	6.08	12.26	8.68
	124	-8	6.32	9.10	12.86	5.08	12.11	8.15
	125	-8	6.42	9.50	13.42	5.04	11.61	10.18
March 2017	118	-12	1.12	0.25	0.90	1.02	0.57	0.86
	119	-12	0.98	0.22	0.99	0.74	0.51	0.86
	120	-12	0.83	0.19	0.98	0.53	0.48	0.76
	121	-12	0.69	0.17	0.85	0.35	0.44	0.57
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	122	-8	4.61	3.76	1.21	3.81	3.24	3.38
	123	-8	4.50	4.21	1.04	3.93	3.74	3.13
	124	-8	4.43	4.56	0.85	3.68	4.19	2.79
	125	-8	4.50	4.57	0.74	3.70	4.47	2.52

Lampiran 8(b). Lanjutan

Period	Long.	Lat.	M1	M2	M3	M4	M5	Obs
April 2017	118	-12	0.45	0.27	0.83	0.12	0.28	0.19
	119	-12	0.38	0.22	0.85	0.12	0.20	0.52
	120	-12	0.32	0.17	0.90	0.10	0.14	0.47
	121	-12	0.26	0.12	0.94	0.09	0.09	0.42
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	122	-8	1.96	2.70	0.63	0.72	0.32	1.13
	123	-8	1.88	2.52	0.51	0.63	0.38	0.89
	124	-8	1.77	2.27	0.45	0.53	0.47	0.74
	125	-8	1.58	1.85	0.52	0.54	0.60	0.70
	May 2017	118	-12	0.35	0.09	0.18	0.40	0.17
119		-12	0.38	0.07	0.13	0.30	0.16	0.21
120		-12	0.43	0.06	0.09	0.21	0.16	0.19
121		-12	0.46	0.04	0.07	0.16	0.15	0.15
⋮		⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮		⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮		⋮	⋮	⋮	⋮	⋮	⋮	⋮
122		-8	0.57	0.54	0.33	0.41	1.99	0.44
123		-8	0.54	0.43	0.29	0.29	2.06	0.37
124		-8	0.51	0.34	0.26	0.24	2.14	0.30
125		-8	0.50	0.27	0.27	0.36	2.27	0.60

Lampiran 9. Syntax NCL untuk Pemetaan Pola Kekeringan

```

begin;

---Read data off CSV file
filename = "periode.csv"

lines = asciiread(filename,-1,"float")

lon1d = lines(0::4)
lat1d = lines(1::4)
data1d = lines(2::4)
data2d = lines(3::4)

ndata = dimsizes(data1d)

wks = gsn_open_wks("pdf","SPI Periode")
gsn_define_colormap(wks,"gui_default")

Ires=True
Ires@gsnDraw= False
Ires@gsnFrame = False
Ires@cnMonoLineDashPattern = False
Ires@cnLineColor = "NavyBlue"
Ires@sfXArray = lon1d ; Contouring 1D data
Ires@sfYArray = lat1d ; requires these resources

res = True
res@gsnDraw= False
res@gsnFrame = False
res@gsnMaximize = True ; Make plot larger.
res@gsnAddCyclic = False ; Don't add longitude cyclic point
res@sfXArray = lon1d ; Contouring 1D data
res@sfYArray = lat1d ; requires these resources

res@mpMinLatF = min(lat1d)
res@mpMaxLatF = max(lat1d)
res@mpMinLonF = min(lon1d)
res@mpMaxLonF = max(lon1d)

```

Lampiran 9. Lanjutan

```

res@cnLevelSelectionMode = "ExplicitLevels"
res@cnLevels             = (/ -2, -1.5, -1, 0, 1, 1.5, 2 /)
res@cnFillOn            = True
res@cnFillColors        =
(/ "red4", "red", "yellow", "white", "white", "green", "blue", "blue4" /)
res@cnLinesOn           = False ; don't draw contour lines

res@lbLabelStrings      = (/ "-2", "-1.5", "-1", "0", "1", "1.5", "2" /)


res@tiMainString        = "SPI Periode"

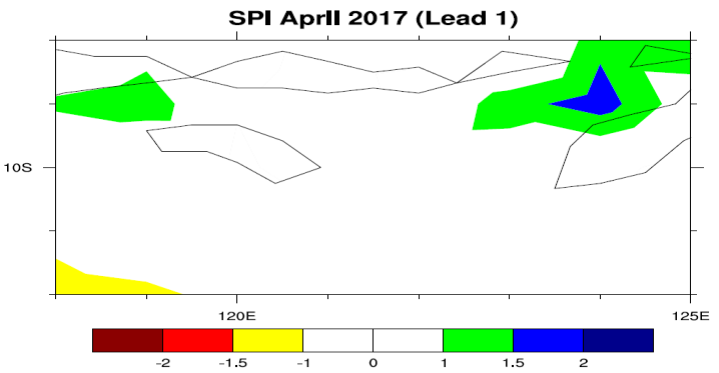


plot = gsn_csm_contour_map(wks, data1d, res)


```

Lampiran 10. Hasil Pemetaan Menggunakan NCL



a.) Lead ke-1

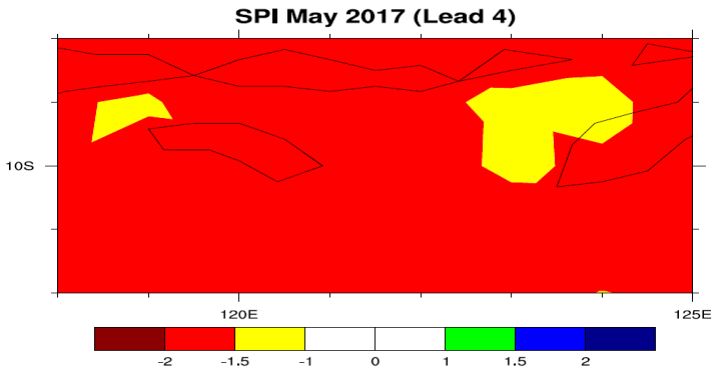








b.) Lead ke-4





Lampiran 11. Surat Pernyataan

SURAT PERNYATAAN

Saya yang bertanda tangan di bawah ini, mahasiswa Departemen Statistika FMIPA ITS.

Nama : Dimas Rahadiyuza
NRP : 1313 100 122

Menyatakan bahwa data yang saya gunakan dalam Tugas Akhir / ~~Thesis~~ ini merupakan data sekunder yang diambil dari ~~penelitian / buku / Tugas Akhir / Thesis /~~ publikasi lainnya, yaitu.

Sumber:

1. *North American Multi Model Ensemble (NMME)* pada *website* <https://iridl.ldeo.columbia.edu/SOURCES/.Models/.NMME/>
2. *European Centre of Medium-Range Weather Forecast (ECMWF)* pada *website* https://www.ecmwf.int/datasets/_data/interim

Keterangan: Data Tahun 2011-2016

Demikian surat pernyataan ini saya buat dengan sebenar-benarnya. Apabila terdapat pemalsuan data maka saya siap menerima sanksi sesuai aturan yang berlaku.

Mengetahui,
Pembimbing Tugas Akhir

Surabaya, 1 Juni 2017

(Dr. rer. pol. Heri Kuswanto, M.Si)
NIP. 19830326 200312 1 004

Dimas Rahadiyuza
NRP. 1313 100 122

BIODATA PENULIS



Penulis memiliki nama lengkap Dimas Rahadiyuza. Penulis dilahirkan dari pasangan Bapak Riza Purnama dan Ibu Paulina Yuke Nusyawati di Negeri Laskar Pelangi, Belitung pada tanggal 10 Agustus 1995. Kendati dilahirkan di sana, Penulis menghabiskan masa kecil hingga masa remajanya di Kota Tangerang Selatan, Banten. Penulis memulai masa studi di usia 4 tahun di TK Dalian, kemudian SD Permata Bunda. Memasuki bangku SMP, penulis mulai bersekolah di sekolah negeri tepatnya di SMP Negeri 4 Kota Tangerang Selatan. Setelah tamat SMP, penulis menempuh pendidikan SMA di SMA Negeri 2 Kota Tangerang Selatan. Pada masa SMA, penulis cukup aktif dalam kegiatan ekstrakurikuler basket dan program *cultural exchange* yang diadakan oleh Bina Antar Budaya (AFS). Hingga akhirnya pada tahun 2013 penulis melanjutkan pendidikan di jenjang perguruan tinggi di jurusan Statistika ITS dengan NRP 1313100122. Selama 4 tahun berkuliah di jurusan Statistika ITS, penulis sempat aktif di dua Unit Kegiatan Mahasiswa, antara lain adalah UKM Bola Basket ITS dan Paduan Suara Mahasiswa ITS. Di lingkup jurusan, penulis juga turut berorganisasi di HIMASTA ITS 2015/2016 tepatnya di Departemen Dalam Negeri. Segala kritik dan saran serta diskusi lebih lanjut mengenai Tugas Akhir ini akan sanga diterima oleh penulis, dimana pesan pesan tersebut dapat dikirimkan melalui suratel elektronik (*e-mail*) ke dimasrahadiyuza@gmail.com atau nomor telepon 081381388619.