

TUGAS AKHIR - SS141501

ENSEMBLE MODEL OUTPUT STATISTICS UNTUK PREDIKSI SUHU DAN KELEMBABAN JANGKA PENDEK TERKALIBRASI

**DESI ERLIANA SARI
NRP 062114 4000 0079**

**Dosen Pembimbing
Dr. Sutikno, S.Si, M.Si**

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2018**



TUGAS AKHIR - SS141501

ENSEMBLE MODEL OUTPUT STATISTICS UNTUK PREDIKSI SUHU DAN KELEMBABAN JANGKA PENDEK TERKALIBRASI

**DESI ERLIANA SARI
NRP 062114 4000 0079**

**Dosen Pembimbing
Dr. Sutikno, S.Si, M.Si**

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2018**

(Halaman ini sengaja dikosongkan)



FINAL PROJECT - SS141501

CALIBRATED PREDICTION OF SHORT-TERM TEMPERATURE AND HUMIDITY USING ENSEMBLE MODEL OUTPUT STATISTICS

DESI ERLIANA SARI
SN 062114 4000 0079

Supervisor
Dr. Sutikno, S.Si, M.Si

UNDERGRADUATE PROGRAMME
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS, COMPUTING, AND DATA SCIENCE
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2018

(Halaman ini sengaja dikosongkan)

LEMBAR PENGESAHAN

ENSEMBLE MODEL OUTPUT STATISTICS UNTUK PREDIKSI SUHU DAN KELEMBABAN JANGKA PENDEK TERKALIBRASI

TUGAS AKHIR

Diajukan Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Sains
pada

Program Studi Sarjana Departemen Statistika
Fakultas Matematika, Komputasi, dan Sains Data
Institut Teknologi Sepuluh Nopember

Oleh :
Desi Erliana Sari
NRP. 062114 4000 0079

Disetujui oleh Pembimbing:
Dr. Sutikno, S.Si, M.Si
NIP. 19710313 199702 1 001

Mengetahui,
Kepala Departemen

Dr. Suhartono

SURABAYA, JULI 2018

ENSEMBLE MODEL OUTPUT STATISTICS UNTUK PREDIKSI SUHU DAN KELEMBABAN JANGKA PENDEK TERKALIBRASI

Nama Mahasiswa : Desi Erliana Sari
NRP : 062114 4000 0079
Departemen : Statistika-FMKSD-ITS
Dosen Pembimbing : Dr. Sutikno, S.Si, M.Si

ABSTRAK

Informasi tentang prediksi cuaca yang cepat dan tepat menjadi suatu hal yang penting karena mempengaruhi berbagai bidang kehidupan. Upaya BMKG dalam memberikan informasi mengenai kondisi cuaca di Indonesia yaitu dengan mengembangkan Numerical Weather Prediction (NWP). Dengan memanfaatkan data luaran NWP dilakukan penelitian untuk prediksi cuaca jangka pendek dengan melakukan ensemble menggunakan luaran Model Output Statistics (MOS). MOS dapat didekati menggunakan metode PCR, PLSR, stepwise regression, dan ridge regression. Namun hasil ensemble sering kali bersifat underdispersi sehingga dibutuhkan kalibrasi ensemble dengan menggunakan metode Ensemble Model Output Statistics (EMOS). Kebaikan model dievaluasi dengan menggunakan Root Mean Square Error (RMSE), Continuous Ranked Probability Score (CRPS), dan rank histogram. Hasil penelitian pada kedua stasiun pengamatan menunjukkan bahwa model MOS terbaik berdasarkan nilai RMSE yaitu model regresi stepwise dan PLSR. Untuk prediksi terkalibrasi berdasarkan nilai CRPS yang diperoleh, model EMOS lebih terkalibrasi dibandingkan dengan raw ensemble dalam memprediksi temperatur dan kelembaban.

Kata Kunci : Ensemble Model Output Statistics, Kalibrasi, Model Output Statistics, Numerical Weather Prediction.

(Halaman ini sengaja dikosongkan)

CALIBRATED PREDICTION OF SHORT-TERM TEMPERATURE AND HUMIDITY USING ENSEMBLE MODEL OUTPUT STATISTICS

Name : Desi Erliana Sari
Student Number : 062114 4000 0079
Department : Statistics
Supervisor : Dr. Sutikno, S.Si, M.Si

ABSTRACT

Information of fast and precise weather prediction is important due to its affects on many areas of life. BMKG had has an efforts in providing information about weather conditions in Indonesia by developing Numerical Weather Prediction (NWP). By utilizing NWP's output, this research conducted to predict short-term weather using ensemble Model Output Statistic (MOS). MOS can be approximated by PCR, PLSR, stepwise regression, and ridge regression methods. However, the ensemble result is often underdispersion, so it needs an ensemble calibration using the Ensemble Model Output Statistics (EMOS) method. This model goodness is evaluated by using Root Mean Square Error (RMSE), Continuous Probability Score (CRPS), and verification rank histogram. The results of the research on both stations showed that the best MOS model based on the RMSE value is a stepwise regression and PLSR. For calibrated predictions based on CRPS values obtained, EMOS models are more calibrated than the raw ensembles in predicting temperature and humidity.

Keyword : Ensemble Model Output Statistics, Calibrated, Model Output Statistic, Numerical Weather Prediciton.

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Puji syukur atas kehadiran Allah SWT, yang telah memberikan rahmat, hidayah serta karunia-NYA sehingga penulis dapat menyelesaikan tugas akhir yang berjudul "**Ensemble Model Output Statistics Untuk Prediksi Suhu dan Kelembaban Jangka Pendek Terkalibrasi**". Tugas akhir ini disusun sebagai syarat untuk menyelesaikan Program Strata-1 di Departemen Statistika, Fakultas Matematika Komputasi dan Sains Data, Institut Teknologi Sepuluh Nopember, Surabaya.

Terselesaikannya penyusunan tugas akhir ini tidak lepas dari partisipasi berbagai pihak yang telah banyak membantu. Oleh karena itu, penulis mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Orang tua penulis yang selalu memberikan doa, dukungan, motivasi, dan kasih sayang.
2. Bapak Dr. Sutikno, S.Si, M.Si selaku Ketua Program Studi S1 dan dosen pembimbing yang mengawal proses berjalannya tugas akhir Mahasiswa S1 dengan bimbingan serta fasilitas yang diberikan.
3. Bapak Dr. Purhadi, M.Sc dan Ibu Dr. Santi Wulan Purnami, S.Si., M.Si selaku dosen pengaji yang telah memberikan saran membangun untuk kesempurnanya tugas akhir ini .
4. Bapak Dr. Suhartono, selaku Ketua Jurusan Statistika ITS yang telah memberikan fasilitas dalam kelancaran tugas akhir ini.
5. Seluruh dosen pengajar di departemen Statistika ITS yang telah memberikan ilmu yang bermanfaat, serta segenap staf dan karyawan di jurusan Statistika ITS atas seluuh bantuan, bimbingan, dan dukungan yang diberikan dalam penyusunan tugas akhir.
6. Teman-teman Statistika ITS, Respect khususnya M. Lukman Hakim, Dedi Setiawan, Carianto Sihombing, Larasati Dewinta, Dwita Bening, Anisa Nur F., AVE, ITS REA REO, dan 9km.

7. Semua pihak yang telah membantu penulis yang tidak dapat disebutkan satu persatu.

Penulis menyadari bahwa tugas akhir ini masih terdapat kekurangan, oleh karena itu kritik dan saran yang bersifat membangun sangat diharapkan. Semoga tugas akhir ini dapat memberikan manfaat baik bagi penulis, pembaca, dan semua pihak.

Surabaya, Juli 2017

Penulis

DAFTAR ISI

HALAMAN JUDUL.....	i
TITLE PAGE.....	iii
LEMBAR PENGESAHAN.....	Error! Bookmark not defined.
ABSTRAK	vi
ABSTRACT	viii
KATA PENGANTAR	x
DAFTAR ISI.....	xii
DAFTAR TABEL.....	xiv
DAFTAR GAMBAR	xvi
DAFTAR LAMPIRAN	xviii

BAB I PENDAHULUAN

1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	4
1.3 Tujuan Penelitian.....	5
1.4 Manfaat Penelitian	5
1.5 Batasan Masalah	5

BAB II TINJAUAN PUSTAKA

2.1 <i>Numerical Weather Predictions</i>	7
2.2 <i>Principal Component Analysis</i>	8
2.3 <i>Model Output Statistics</i>	10
2.3.1 <i>Principal Component Regression</i>	11
2.3.2 <i>Principal Least Square Regression</i>	12
2.3.3 <i>Stepwise Regression</i>	15
2.3.4 <i>Ridge Regression</i>	16
2.4 <i>Ensemble Prediction System</i>	17
2.5 <i>Ensemble Model Output Statistics</i>	18
2.6 Evaluasi Kebaikan Model.....	19
2.6.1 <i>Continuous Ranked Probability Score</i>	19
2.6.2 <i>Residual Mean Square Error</i>	20
2.6.3 <i>Rank Histogram</i>	21
2.7 Suhu dan Kelembaban	21

BAB III METODOLOGI PENELITIAN	
3.1 Sumber Data	23
3.2 Variabel Penelitian.....	23
3.3 Langkah Analisis Data	27
BAB IV ANALISIS DAN PEMBAHASAN	
4.1 Pembentukan Model Prediksi Anggota <i>Ensemble</i>	31
4.1.1 Deskripsi Temperatur Maksimum, Temperatur Minimum, dan Kelembaban di Lokasi Penelitian	31
4.1.2 <i>Pre-processing</i> Data.....	32
4.1.3 Pemodelan Prediksi dengan PCR.....	34
4.1.4 Pemodelan Prediksi dengan PLSR	37
4.1.5 Pemodelan Prediksi dengan <i>Stepwise Regression</i>	40
4.1.6 Pemodelan Prediksi dengan <i>Ridge Regression</i>	42
4.2 Pemodelan <i>Ensemble Model Output Statistics</i>	52
4.2.1 Penentuan Panjang Periode Training Optimal... <td>52</td>	52
4.2.2 Kalibrasi Prediksi Ensemble menggunakan EMOS	55
4.2.3 Taksiran Interval PDF Prediksi Terkalibrasi	59
4.3 Evaluasi Kebaikan Model	62
BAB V KESIMPULAN DAN SARAN	
5.1 Kesimpulan	65
5.2 Saran	66
DAFTAR PUSTAKA	67
LAMPIRAN.....	71

DAFTAR TABEL

Tabel 3.1	Variabel Respon Penelitian	23
Tabel 3.2	Variabel Prediktor Penelitian	23
Tabel 3.3	Struktur Data Penelitian	26
Tabel 4.1	Statistika Deskriptif Data Observasi Temperatur Maksimum, Temperatur Minimum, dan Kelembaban pada Stasiun Hasanuddin dan Pattimura	31
Tabel 4.2	Banyak PC Parameter NWP di Stasiun Hasanuddin dan Pattimura	33
Tabel 4.3	Kumulatif Varians Tmaks, Tmin, dan RH Stasiun Hasanuddin	34
Tabel 4.4	Model Prediksi PCR Tmaks, Tmin, dan RH Stasiun Hasanuddin.....	35
Tabel 4.5	Kumulatif Varians Tmaks, Tmin, dan RH Stasiun Pattimura.....	36
Tabel 4.6	Model Prediksi PCR Tmaks, Tmin, dan RH Stasiun Pattimura	36
Tabel 4.7	RMSEP Tmaks, Tmin, dan RH Stasiun Hasanuddin	37
Tabel 4.8	Model Prediksi PLSR Tmaks, Tmin, dan RH Stasiun Hasanuddin.....	38
Tabel 4.9	RMSE Tmaks, Tmin, dan RH Stasiun Pattimura ...	39
Tabel 4.10	Model Prediksi PLSR Tmaks, Tmin, dan RH Stasiun Pattimura	39
Tabel 4.11	Nilai AIC Tmaks, Tmin, dan RH Stasiun Hasanuddin	40
Tabel 4.12	Model Prediksi Stepwise Regression Tmaks, Tmin, dan RH Stasiun Hasanuddin	41
Tabel 4.13	Nilai AIC Tmaks, Tmin, dan RH Stasiun Pattimura	41
Tabel 4.14	Model Prediksi Stepwise Regression Tmaks, Tmin, dan RH Stasiun Pattimura.....	42
Tabel 4.15	Nilai Konstanta λ Optimum Tmaks, Tmin, dan RH Stasiun Hasanuddin dan Pattimura	45

Tabel 4.16	Model Prediksi Stepwise Regression Tmaks, Tmin, dan RH Stasiun Hasanuddin	45
Tabel 4.17	Model Prediksi Stepwise Regression Tmaks, Tmin, dan RH Stasiun Pattimura.....	46
Tabel 4.18	Koefisien Parameter EMOS Tmaks Stasiun Hasanuddin	56
Tabel 4.19	Koefisien Parameter EMOS Tmin Stasiun Hasanuddin	56
Tabel 4.20	Koefisien Parameter EMOS RH Stasiun Hasanuddin	56
Tabel 4.21	Koefisien Parameter EMOS Tmaks Stasiun Pattimura.....	57
Tabel 4.22	Koefisien Parameter EMOS Tmin Stasiun Pattimura.....	57
Tabel 4.23	Koefisien Parameter EMOS RH Stasiun Pattimura.....	57
Tabel 4.24	<i>Mean</i> dan Varians Terkalibrasi Tmaks, Tmin, dan RH Stasiun Hasanuddin	58
Tabel 4.25	<i>Mean</i> dan Varians Terkalibrasi Tmaks, Tmin, dan RH Stasiun Pattimura.....	59
Tabel 4.26	Nilai RMSE PCR,PLSR, Regresi Stepwise, Regresi Ridge, dan EMOS pada Tmaks, Tmin, dan RH.....	62
Tabel 4.27	Nilai CRPS <i>Raw Ensemble</i> dan EMOS pada Tmaks, Tmin, dan RH.....	63

DAFTAR GAMBAR

Gambar 2.1	Ilustrasi <i>Continous Ranked Probability Score</i> ...	20
Gambar 2.2	Pola <i>Verification Rank Histogram</i>	21
Gambar 3.1	Pengukuran NWP dalam Grid 3 x 3	24
Gambar 3.2	Diagram Alir Analisis Data.....	30
Gambar 4.1	Pola Data Observasi Temperatur Maksimum, Temperatur Minimum, dan Kelembaban pada Stasiun Hasanuddin dan Pattimura.....	31
Gambar 4.2	Konvergensi Koefisien Regresi Ridge Stasiun Meteorologi Hasanuddin (a) Tmaks, (b) Tmin, (c) RH	43
Gambar 4.3	Konvergensi Koefisien Regresi Ridge Stasiun Pattimura.....	44
Gambar 4.4	Perbandingan Data Observasi dengan Hasil Prediksi MOS Tmaks dan Tmin Stasiun Hasanuddin (a)PCR, (b)PLSR, (c)Stepwise, dan (d) Ridge	48
Gambar 4.5	Perbandingan Data Observasi dengan Hasil Prediksi MOS RH Stasiun Hasanuddin (a)PCR, (b)PLSR, (c)Stepwise, dan (d)Ridge	50
Gambar 4.6	Verifikasi Rank Histogram Hasil Prediksi MOS Stasiun Hasanuddin (a)Tmaks, (b)Tmin, dan (c)RH	51
Gambar 4.7	Perbandingan Panjang Periode Training Tmaks Stasiun Hasanuddin (a) CRPS dan (b) RMSE..	53
Gambar 4.8	Perbandingan Panjang Periode Training Tmin Stasiun Hasanuddin (a) CRPS dan (b) RMSE..	53
Gambar 4.9	Perbandingan Panjang Periode Training RH Stasiun Hasanuddin (a) CRPS dan (b) RMSE..	53
Gambar 4.10	Perbandingan Panjang Periode Training Tmaks Stasiun Pattimura (a) CRPS dan (b) RMSE ..	54
Gambar 4.11	Perbandingan Panjang Periode Training Tmin Stasiun Pattimura (a) CRPS dan (b) RMSE ..	54
Gambar 4.12	Perbandingan Panjang Periode Training RH Stasiun Pattimura	55

Gambar 4.13 Taksiran Interval Prediksi Teralibrasi di Stasiun Hasanuddin Tanggal 23 Maret 2015 (a)Tmaks, (b)Tmin, dan (c)RH	60
Gambar 4.14 Taksiran Interval Prediksi Teralibrasi di Stasiun Pattimura Tanggal 23 Maret 2015 (a)Tmaks, (b)Tmin, dan (c)RH	62

DAFTAR LAMPIRAN

Lampiran 1.	Data Observasi (Variabel Respon) Tmaks, Tmin, RH di Stasiun Hasanuddin dan Pattimura	71
Lampiran 2.	Data NWP model WRF-EMS Stasiun Hasanuddin	72
Lampiran 3.	Data NWP model WRF-EMS Stasiun Paattimura	73
Lampiran 4.	Nilai Prediksi Temperatur Maksimum <i>Model Output Statistics</i> di Stasiun Hasanuddin.....	74
Lampiran 5.	Nilai Prediksi Temperatur Minimum <i>Model Output Statistics</i> di Stasiun Hasanuddin.....	75
Lampiran 6.	Nilai Prediksi Kelembaban <i>Model Output Statistics</i> di Stasiun Hasanuddin.....	76
Lampiran 7.	Nilai Prediksi Temperatur Maksimum <i>Model Output Statistics</i> di Stasiun Pattimura	77
Lampiran 8.	Nilai Prediksi Temperatur Minimum <i>Model Output Statistics</i> di Stasiun Pattimura	78
Lampiran 9.	Nilai Prediksi Kelembaban <i>Model Output Statistics</i> di Stasiun Pattimura	79
Lampiran 10.	Ilustrasi Penggunaan <i>Training (m)</i> 10 Hari	80
Lampiran 11.	Nilai CRPS Temperatur Maksimum, Temperatur Minimum, dan Kelembaban di Stasiun Hasanuddin dan Pattimura.....	80
Lampiran 12.	Nilai RMSE Temperatur Maksimum, Temperatur Minimum, dan Kelembaban di Stasiun Hasanuddin dan Pattimura.....	81
Lampiran 13.	Taksiran Interval Temperatur Maksimum, Temperatur Minimum, dan Kelembaban di Stasiun Hasanuddin.....	81
Lampiran 14.	Taksiran Interval Temperatur Maksimum, Temperatur Minimum, dan Kelembaban di Stasiun Pattimura	82
Lampiran 15.	Program Reduksi Dimensi menggunakan PCA.83	
Lampiran 16.	Program Pemodelan MOS dengan Metode Pendekatan PCR.....	84

Lampiran 17. Program Pemodelan MOS dengan Metode Pendekatan PLSR	86
Lampiran 18. Program Pemodelan MOS dengan Metode Pendekatan Stepwise Regression	88
Lampiran 19. Program Pemodelan MOS dengan Metode Pendekatan Ridge Regression	90
Lampiran 20. Program Pemodelan EMOS	94
Lampiran 21. Program Taksiran Interval PDF Prediksi Terkalibrasi	98
Lampiran 22. Surat Pernyataan Penggunaan Data.....	100

BAB I

PENDAHULUAN

1.1 Latar Belakang

Indonesia merupakan negara *maritime-continent* berdasarkan letak geografis Indonesia yang berada diantara samudera Pasifik dan samudera Hindia. Selain itu, letak astronomi Indonesia berada pada 6° LU- 11° LS dan 95° BT- 141° BT, dimana posisi garis lintas tersebut menyebabkan Indonesia beriklim tropis dan adanya pembagian waktu yang disebabkan oleh posisi garis bujur. Berdasarkan letak astronomi dan letak geografis, memungkinkan Indonesia mempunyai karakteristik cuaca yang beragam. Informasi tentang prediksi cuaca yang cepat dan tepat menjadi suatu hal yang penting karena mempengaruhi berbagai bidang kehidupan, salah satunya bidang transportasi udara. Aktivitas penerbangan sangat bergantung pada keadaan cuaca. Salah satu unsur cuaca seperti suhu dan tekanan udara penting bagi operasi penerbangan, yang berpengaruh pada saat *take off* atau *landing* pesawat. Suhu dan tekanan udara disuatu tempat selalu berubah bersama dengan perubahan waktu. Dengan mengetahui informasi mengenai unsur cuaca tersebut, maka gangguan dapat diantisipasi sehingga penerbangan pesawat dapat terhindar dari kecelakaan. Oleh karena itu dibutuhkan suatu metode yang efektif dalam prediksi cuaca, khususnya prediksi cuaca jangka pendek.

Lembaga pemerintah yang berperan penting dalam prediksi cuaca adalah Badan Meteorologi Klimatologi dan Geofisika (BMKG). Salah satu misi BMKG yaitu menyediakan data, informasi dan jasa meteorologi, klimatologi, kualitas udara dan geofisika yang handal dan terpercaya. Secara rutin kondisi cuaca yang terjadi di Indonesia dipantau oleh BMKG, seperti BMKG kabupaten Mimika, Papua. Demi menjaga keselamatan disetiap penerbangan, pihak BMKG selalu memberikan laporan keadaan cuaca kepada menara komunikasi penerbangan. Peran BMKG dalam sebuah perjalanan penerbangan adalah memberikan laporan Metar

atau laporan cuaca secara rutin yang diberikan kepada pilot pesawat terbang tiap 30 menit sampai dengan 1 jam dan laporan terkait dengan tekanan udara yang berada di landasan. Dalam laporan Metar didukung oleh Radar yang menunjukkan bagian mana yang sedang mengalami cuaca buruk atau keberadaan awan yang mengandung petir. Sedangkan laporan terkait dengan tekanan udara yang berada di landasan dilakukan agar pilot dapat memperkirakan berapa kecepatan pesawat disaat melakukan pendaratan di landasan (Guritno, 2018).

Upaya BMKG dalam memberikan informasi mengenai kondisi cuaca di Indonesia yaitu dengan mengembangkan *Numerical Weather Prediction* (NWP). NWP merupakan model cuaca numerik yang dikeluarkan oleh beberapa institusi seperti Japan Meteorological Agency (JMA), National Oceanic and Atmospheric Administration (NOAA), ECMWF. NWP menggunakan model matematika atmosfer dan laut untuk memprediksi cuaca berdasarkan kondisi cuaca saat ini, namun luaran prediksi cuaca model numerik belum bisa mengeluarkan parameter cuaca dan lokasi secara spesifik (Haryoko, 2014). Selain itu, model NWP besifat bias, deterministik, dan tidak bisa secara penuh menjelaskan proses stokastik cuaca (Wilks, 2006). Untuk mengurangi nilai *error* dan meningkatkan akurasi hasil prediksi model NWP, dilakukan *statistical post-processing* dengan menggunakan metode *model output statistics* (MOS).

MOS merupakan teknik pendekatan obyektif berbasis regresi yang menunjukkan hubungan antara hasil observasi cuaca sebagai variabel respon dan parameter NWP sebagai variabel prediktor. Karakteristik MOS yaitu sampel prediktor yang digunakan berupa data jangka pendek yang dihasilkan oleh model numerik dan dapat mencakup prediktor yang banyak. Pemodelan MOS dapat dilakukan pendekatan menggunakan beberapa metode. Pemodelan MOS pernah dilakukan Safitri (2012) dalam meramalkan suhu minimum, suhu maksimum, dan kelembaban dengan pendekatan *Projection Pursuit Regression* (PPR), disimpulkan bahwa model MOS dapat memperbaiki model NWP mencapai 86%. Pemodelan MOS

menggunakan *Statistically Inspired Modification of Partial* (SIMPLS) pada 3 stasiun meteorologi di Indonesia menghasilkan nilai %IM untuk prediksi T_{\max} , T_{\min} , dan RH berkisar antara 26% sampai 92% dan model SIMPLS dapat mengkoreksi bias model NWP (Kurniasari, 2017). Selain itu, Narendra (2017) melakukan pendekatan MOS dengan metode *Partial Least Square Regression* (PLSR), *Principal Component Regression* (PCR), dan Regresi Ridge. Disimpulkan bahwa metode PLSR yang terbaik.

Dalam pemodelan MOS sering dijumpai adanya kasus multikolinieritas antar grid akibat pengukuran grid yang cukup luas (skala global) pada data NWP, maupun pada data NWP sebagai variabel prediktor. Multikolinieritas antar grid dapat diatasi dengan melakukan reduksi dimensi, dengan memetakan set data dari dimensi semula ke dimensi baru yang mewakili karakteristik data. Metode yang sering digunakan dalam reduksi dimensi yaitu *Principal Component Analysis* (PCA). Anuravega (2013) melakukan *post-processing* prediksi unsur cuaca dengan MOS yaitu membandingkan reduksi dimensi antara *Independent Component Analysis* (ICA) dan *Principal Component Analysis* (PCA), disimpulkan bahwa RMSE MOS dengan reduksi PCA lebih kecil dibandingkan RMSE MOS ICA. Untuk mengatasi multikolinieritas pada data NWP sebagai variabel prediktor dapat dilakukan dengan pemrosesan *ensemble* yaitu menggabung beberapa model prediksi tunggal yang diverifikasi dalam waktu yang bersamaan. Namun, hasil prediksi *ensemble* sering bersifat *underdispersive* dan bias (Raftery, Gneiting, Balabdaoui, & Polakowski, 2005), yang berarti bahwa nilai prediksi cuaca cenderung terpusat pada suatu interval dengan varians yang rendah, sehingga dibutuhkan proses kalibrasi. Salah satu metode kalibrasi prediksi *ensemble* yang dapat mengoreksi bias serta *underdispersive* adalah *Ensemble Model Output Statistics* (EMOS).

Kalibrasi EMOS untuk prediksi cuaca jangka pendek pernah dilakukan oleh Narendra (2017), disimpulkan bahwa prediksi EMOS terkalibrasi lebih baik daripada NWP dan *raw ensemble* dengan diperoleh nilai prediksi deterministik EMOS memiliki

RMSE hingga 87% lebih rendah dibanding RMSE NWP. Hal yang sama dilakukan oleh Fachrunisah (2017) dengan mengkalibrasikan metode PCR, *Stepwise Regression* dan SIMPLS. Disimpulkan bahwa model *stepwise regression* memiliki kontribusi paling besar dalam model kalibrasi EMOS dibanding-kan dengan SIMPLS dan *principal component regression*. Model EMOS juga baik dalam memprediksi temperatur dan kelembaban udara jika dibandingkan dengan prediksi NWP. Teknik EMOS juga pernah diterapkan dalam memprediksi tekanan permukaan laut dan suhu permukaan di Pacific Northwest Amerika Utara pada musim semi 2000, dengan menggunakan *mesoscale ensemble* dari University of Washington. Bila dibandingkan dengan *ensemble* koreksi bias, prediksi EMOS dengan gaya deterministik tekanan permukaan laut memiliki *root mean square error* 9% lebih kecil dan *mean absolute error* 7% lebih kecil. Maka, PDF prediksi EMOS lebih teliti dan lebih baik dikalibrasi daripada *raw ensemble* atau *ensemble* koreksi bias (Gneiting, et al., 2005). Oleh karena itu, prediksi cuaca untuk suhu dan temperatur dapat menggunakan metode EMOS.

Penelitian ini membahas tentang EMOS untuk prediksi cuaca jangka pendek, dimana unsur cuaca yang diprediksi yaitu suhu dan kelembaban. Reduksi dimensi data NWP menggunakan PCA dan pemodelan *ensemble* berupa output MOS dengan menggunakan PCR, PLSR, *stepwise regression*, dan *ridge regression*. Pemilihan metode MOS didasarkan oleh penelitian Narendra (2017) dan Fachrunisah (2017), dimana keempat metode tersebut dapat menunjukkan hasil yang relatif baik dan dapat mengatasi adanya kasus multikolinieritas. Kebaikan model dievaluasi dengan menggunakan *Root Mean Square Error* (RMSE), *Continuous Ranked Probability Score* (CRPS), dan rank histogram. Hasil penelitian ini diharapkan dapat memberikan hasil prediksi cuaca jangka pendek yang tepat dan mendapat informasi yang akurat.

1.2 Rumusan Masalah

Pentingnya prediksi cuaca jangka pendek khususnya bagi transportasi udara, dimana aktivitas penerbangan seperti *take off* dan *landing* pesawat bergantung pada keadaan cuaca. Penelitian ini

menggunakan metode MOS dengan beberapa pendekatan metode yaitu PCR, PLSR, *stepwise regression*, dan *ridge regression*, dalam prediksi temperatur maksimum, minimum, dan kelembaban. Selanjutnya, dilakukan prediksi *ensemble* dengan menggunakan keempat hasil prediksi MOS yang kemudian dikalibrasi dengan menggunakan EMOS pendekatan distribusi normal. Setelah itu, pemilihan model prediksi terbaik dilakukan dengan evaluasi nilai RMSE, CRPS, dan rank histogram.

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah, tujuan penelitian adalah sebagai berikut.

1. Mendapatkan prediksi temperatur maksimum, temperatur minimum dan kelembaban menggunakan MOS dengan pendekatan metode PCR, PLSR, *stepwise regression*, dan *ridge regression*.
2. Mendapatkan hasil kalibrasi temperatur maksimum, temperatur minimum dan kelembaban menggunakan EMOS.
3. Memperoleh model prediksi temperatur maksimum, temperatur minimum dan kelembaban terbaik.

1.4 Manfaat Penelitian

Manfaat penelitian yang diperoleh yaitu mengetahui peran Statistika dalam prediksi cuaca salah satunya yaitu penggunaan EMOS dalam memprediksi temperatur maksimum, temperatur minimum, dan kelembaban jangka pendek. Serta manfaat bagi BMKG yaitu mendapatkan model yang memberikan prediksi yang akurat, sehingga metode yang digunakan dapat menjadi alternatif dalam prediksi cuaca jangka pendek, khususnya temperatur maksimum, temperatur minimum, dan kelembaban.

1.5 Batasan Masalah

Ruang lingkup penelitian dibatasi pada 2 stasiun pengamatan dengan menggunakan 4 anggota *ensemble* yang diperoleh melalui PCR, PLSR, *stepwise regression*, dan *ridge regression*. Dalam mereduksi dimensi parameter NWP digunakan metode

PCA. Distribusi data yang digunakan dalam analisis adalah distribusi normal.

BAB II

TINJAUAN PUSTAKA

2.1 Numerical Weather Predictions

NWP pertama kali dicetuskan pada tahun 1904 oleh Vilhelm Bjerknes yang mendiskusikan pemecahan masalah prediksi cuaca dengan menerapkan hukum fisika (Shuman, 1989). NWP merupakan sekumpulan kode komputer yang merepresentasikan secara numerik persamaan-persamaan atmosfer. NWP digunakan untuk memprediksi kondisi atau status atmosfer yang akan datang dengan menggunakan kemampuan komputer yang tinggi (Idowu & Rautenbach, 2008).

Menurut Raible, Bischof, Flaedrich, & Kirk (1998) dalam Kurniasari (2017) secara umum model-model NWP sudah cukup baik dalam melakukan peramalan jangka pendek. NWP dicatat pada grid (kombinasi lintang-bujur) tertentu dengan deskripsi sebagai berikut :

1. NWP diukur pada level tekanan tertentu, yaitu 1000 mb, 950 mb, 925 mb, 900 mb, 850 mb, 800 mb, 700 mb, 600 mb, 500 mb, 400 mb, 350 mb, 300 mb dan 200mb dan dapat diukur dengan level ketinggian permukaan, 2 meter, dan 10 meter di atas permukaan laut.
2. Ramalan NWP dilakukan dengan waktu tertentu, misal 3 atau 6 jam sekali.
3. NWP memiliki resolusi grid lintang bujur $0,5^\circ \times 0,5^\circ$ ($55,5 \times 55,5$) km^2 hingga $1^\circ \times 1^\circ$ (111×111) km^2 . NWP diukur pada grid yang luas dengan ukuran lintang-bujur tertentu.

Hasil prediksi NWP dengan skala besar akan bersifat homogen pada daerah grid tersebut, sehingga kondisi cuaca skala kecil atau lokal menjadi kurang terwakili (*representative*) dengan benar. Model NWP adalah deterministik dan tidak bisa secara penuh menjelaskan proses stokastik cuaca. Namun, informasi NWP yang digunakan bersamaan dengan metode statistik memungkinkan untuk mengkuantifikasi dan menjelaskan ketidakpastian

dengan menghubungkannya dengan kondisi prediksi yang berbeda atau prediksi probabilistik (Wilks, 2006).

Salah satu model aplikasi yang terintegrasi dengan NWP adalah model *Weather Research and Forecasting Environmental Modeling System* (WRF-EMS). *National Oceanic and Atmospheric Administration* (NOAA) bekerjasama dengan *National Weather Service* (NWS), *Forecast Decision Training Branch* (FDTB) dan *Science Operations Officer and Training Resource Center* (SOO/STCR) mengembangkan model WRF-EMS untuk keperluan prediksi cuaca. Model WRF-EMS dinilai sebagai model yang lengkap dan merupakan *state-of-the science* dari produk NWP serta merupakan gabungan dari dua model dinamis yang umum digunakan di dunia pemodelan yaitu Advanced Research WRF (ARW) dan non-Hydrostatic Mesoscale Model (NMM). Semua fitur-fitur yang terdapat pada kedua *binary* tersebut terdapat dalam model WRF EMS dan sudah disederhanakan dari mulai proses instalasi, konfigurasi dan eksekusinya, hal tersebut bertujuan agar penggunaan model ini dapat dengan mudah dilakukan (Rozumalski, 2010).

2.2 Principal Component Analysis

Pengukuran grid yang cukup luas (skala global) pada data NWP menghasilkan prediksi bersifat homogen pada daerah grid tersebut, sehingga menyebabkan adanya kasus multikolinieritas. Multikolinieritas data luaran NWP dapat diatasi dengan melakukan reduksi dimensi menggunakan metode PCA.

PCA adalah metode statistika yang dapat digunakan untuk menjelaskan struktur varians-kovarians sekumpulan variabel melalui beberapa variabel baru yang saling bebas. Variabel baru yang terbentuk merupakan kombinasi linier variabel asal. Selanjutnya variabel baru ini dinamakan komponen utama (PC). PCA digunakan untuk mereduksi dimensi data dengan cara mentransformasi variabel-variabel asli yang berkorelasi menjadi satu set variabel baru yang tidak berkorelasi, dengan tetap mempertahankan sebanyak mungkin keragaman yang dapat dijelaskan.

Apabila terdapat parameter NWP sebanyak p , maka vektor random $\mathbf{x} = [x_1, x_2, \dots, x_p]^T$ mempunyai matriks varians-kovarians Σ dengan akar ciri (*eigenvalue*) berturut-turut yaitu $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$, sehingga kombinasi linier utama dapat dituliskan sebagai berikut.

$$\begin{aligned} \text{PC}_1 &= \mathbf{e}_1^T \mathbf{x} = e_{11}x_1 + e_{21}x_2 + \dots + e_{p1}x_p \\ \text{PC}_2 &= \mathbf{e}_2^T \mathbf{x} = e_{12}x_1 + e_{22}x_2 + \dots + e_{p2}x_p \\ &\vdots \\ &\vdots \\ \text{PC}_p &= \mathbf{e}_p^T \mathbf{x} = e_{1p}x_1 + e_{2p}x_2 + \dots + e_{pp}x_p \end{aligned} \quad (2.1)$$

keterangan :

PC_1 = PC ke-1, yang mempunyai varians terbesar pertama

PC_2 = PC ke-2, yang mempunyai varians terbesar kedua

PC_p = PC ke- p , yang mempunyai varians terbesar ke- p

x_1 = variabel asal ke-1

x_2 = variabel asal ke-2

x_p = variabel asal ke- p

e_1 = *eigenvector* PC ke-1

e_2 = *eigenvector* PC ke-2

e_p = *eigenvector* PC ke- p

Dari persamaan (2.1) diperoleh model PC ke- i secara umum yang ditunjukkan pada persamaan (2.2), selain itu diperoleh varians dan kovarian pada persamaan (2.3) dan (2.4).

$$\text{PC}_i = \mathbf{e}_i^T \mathbf{x} \quad (2.2)$$

$$\text{var}(\text{PC}_i) = \mathbf{e}_i^T \Sigma \mathbf{e}_i = \lambda_i \quad (2.3)$$

$$\text{cov}(\text{PC}_i, \text{PC}_m) = \mathbf{e}_i^T \Sigma \mathbf{e}_m = 0 \quad (2.4)$$

dengan $i = 1, 2, \dots, p$, $i \neq m$. PC yang terbentuk tidak berkorelasi dan memiliki varians yang sama dengan *eigenvalue* dari matriks varians-kovarians Σ , sehingga total varians dapat dihitung menggunakan persamaan (2.5).

$$\begin{aligned}\sum_{i=1}^k \text{var}(x_i) &= \sigma_{11} + \sigma_{22} + \dots + \sigma_{pp} \\ \sum_{i=1}^k \text{var}(\text{PC}_i) &= \lambda_1 + \lambda_2 + \dots + \lambda_p\end{aligned}\quad (2.5)$$

Persentase total varians yang dapat diterangkan oleh PC ke-*i* dapat dihitung dengan persamaan (2.6).

$$\text{Proporsi total varians PC ke-}i = \frac{\lambda_i}{\lambda_1 + \lambda_2 + \dots + \lambda_p} \quad (2.6)$$

Beberapa kriteria yang dapat digunakan sebagai acuan penentuan jumlah PC yang akan diambil sebagai berikut :

1. Melihat *scree plot*. Apabila garis yang terbentuk mengalami *range* yang cukup besar maka PC sejumlah garis tersebut.
2. Banyaknya PC dipilih berdasarkan banyaknya *eigenvalue* yang lebih besar dari satu (bila PC diperoleh dari matriks korelasi).

Sebaiknya jumlah PC yang dipilih adalah yang mampu memberikan kumulatif persentase varians sebesar 80% - 90% (Johnson & Wichern, 2010).

2.3 Model Output Statistics

Model Output Statistics (MOS) merupakan salah satu metode yang dapat digunakan dalam memprediksi parameter cuaca yang tidak dapat secara langsung dihasilkan dari sebuah model numerik. MOS adalah teknik peramalan cuaca obyektif yang terdiri dari penentuan hubungan statistik cuaca sebenarnya dengan model numerik. (Glahn & Lowry, 1972). MOS merupakan model yang meghubungkan antara variabel respon yaitu hasil observasi stasiun cuaca dengan variabel prediktor yaitu parameter NWP, seperti temperatur, angin dan sebagainya pada berbagai grid dan level (Haryoko, 2014). Pemodelan MOS dapat dilakukan pendekatan menggunakan beberapa metode yaitu *Partial Least Square Regression* (PLSR), *Principal Component Regression* (PCR), *Stepwise Regression*, dan *Ridge Regression*.

2.3.1 Principal Component Regression

Principal Component Regression (PCR) merupakan teknik analisis yang mengkombinasikan antara analisis regresi dengan *Principal Component Analysis* (PCA). Analisis Regresi digunakan untuk mengetahui hubungan antara variabel dependen dan variabel independen, sedangkan PCA bertujuan menyederhanakan variabel yang diamati dengan mereduksi dimensinya. Hal ini dilakukan dengan menghilangkan korelasi antar variabel melalui transformasi variabel asal ke variabel baru, sehingga didapatkan variabel baru yang tidak berkorelasi dengan tetap mempertahankan sebanyak mungkin keragaman yang dapat dijelaskan (Johnson & Wichern, 2010).

Pembentukan regresi komponen utama melalui analisis komponen utama dapat menggunakan komponen utama yang dibentuk berdasarkan matriks kovariansi jika semua variabel yang diamati memiliki satuan pengukuran yang sama. Sedangkan matriks korelasi data yang telah distandarisasi (bentuk baku Z) digunakan jika variabel yang diamati tidak memiliki satuan pengukuran yang sama. Analisis regresi komponen utama merupakan analisis regresi variabel dependen terhadap komponen-komponen utama yang tidak saling berkorelasi, regresi komponen utama dapat dinyatakan sebagai berikut :

$$Y = \omega_0 + \omega_1 K_1 + \omega_2 K_2 + \dots + \omega_m K_m + \varepsilon \quad (2.7)$$

keterangan :

Y = variabel respon

K = komponen utama

ω = parameter regresi komponen utama

K_1, K_2, \dots, K_m menunjukkan komponen utama yang dilibatkan dalam regresi komponen utama, dengan besaran m yang lebih kecil daripada banyaknya variabel prediktor sejumlah p . Komponen utama merupakan kombinasi linear variabel baku Z , sehingga:

$$\begin{aligned} K_1 &= \alpha_{11}Z_1 + \alpha_{21}Z_2 + \dots + \alpha_{p1}Z_p \\ K_2 &= \alpha_{12}Z_1 + \alpha_{22}Z_2 + \dots + \alpha_{p2}Z_p \\ &\vdots \\ K_m &= \alpha_{1m}Z_1 + \alpha_{2m}Z_2 + \dots + \alpha_{pm}Z_p \end{aligned} \quad (2.8)$$

Apabila persamaan (2.8) disubstitusikan pada persamaan (2.7), maka akan diperoleh persamaan regresi komponen utama yang ditunjukkan pada persamaan (2.9).

$$\begin{aligned} Y = & \omega_0 + (\omega_1 \alpha_{11} + \omega_2 \alpha_{12} + \dots + \omega_m \alpha_{1m}) Z_1 \\ & + (\omega_1 \alpha_{21} + \omega_2 \alpha_{22} + \dots + \omega_m \alpha_{2m}) Z_2 \\ & + \dots + (\omega_1 \alpha_{p1} + \omega_2 \alpha_{p2} + \dots + \omega_m \alpha_{pm}) Z_p + \varepsilon \end{aligned} \quad (2.9)$$

dari persamaan (2.9) diperoleh persamaan regresi dengan komponen utama sebagai berikut.

$$Y = b_0 + b_1 Z_1 + b_2 Z_2 + \dots + b_p Z_p + \varepsilon \quad (2.10)$$

dengan,

$$b_0 = \omega_0$$

$$b_1 = \omega_1 \alpha_{11} + \omega_2 \alpha_{12} + \dots + \omega_m \alpha_{1m}$$

$$b_2 = \omega_1 \alpha_{21} + \omega_2 \alpha_{22} + \dots + \omega_m \alpha_{2m}$$

:

$$b_p = \omega_1 \alpha_{p1} + \omega_2 \alpha_{p2} + \dots + \omega_m \alpha_{pm}$$

Karena data awal merupakan data standarisasi, maka perlu dilakukan transformasi. Hal ini dilakukan agar Y kembali pada satuan semula yaitu dengan mengalikan Y terhadap standar deviasinya, lalu dijumlahkan dengan rata-ratanya.

Adapun algoritma *Principal Component Regression* (PCR) sebagai berikut:

1. Menghitung *eigen value* dan *eigen vector* dari matriks korelasi atau kovarians.
2. Terdapat p komponen utama yang orthogonal dan tidak berkorelasi.
3. Dipilih komponen yang *eigen value* > 1 atau yang mampu menerangkan keragaman cukup tinggi (80%-90%).
4. Regresi variabel dependen dengan komponen-komponen utama yang terpilih (Johnson & Wichern, 2010).

2.3.2 Principal Least Square Regression

PLS merupakan teknik prediktif yang dapat menangani banyak variabel independen, sekalipun terjadi multikolinieritas

diantara variabel-variabel tersebut. PLS bersifat robust, artinya parameter model tidak banyak berubah ketika sampel baru diambil dari total populasi (Geladi & Kowalski, 1986). *Partial Least Square Regression* (PLSR) merupakan metode berbasis regresi yang menghubungkan dua matriks data X dan Y. Untuk meregresikan variabel respon y dengan variabel prediktor x_1, x_2, \dots, x_p , metode PLS mencari komponen-komponen baru yang berperan sebagai variabel bebas untuk mengestimasi parameter regresi. Pada prinsipnya PLS memodelkan hubungan antara X dan Y berdasarkan variabel laten (Wold, S., Sjostrom, M. & Eriksson, L., 2001).

PLS dalam menghitung komponen utama pada variabel dependen dan independen dilakukan secara bersama melalui proses iterasi. Pada setiap iterasinya varians pada X dan Y saling mempengaruhi, struktur varians Y mempengaruhi kombinasi linier X dan sebaliknya (Wigena & Aunuddin, 1998). Metode PLS diawali dengan standarisasi data variabel X dan variabel Y (persamaan (2.11)) dengan tujuan menghasilkan pembobot yang memiliki satuan yang sama antar variabel. Apabila sebanyak q variabel respon (Y_1, Y_2, \dots, Y_q) diprediksi dengan p variabel prediktor (X_1, X_2, \dots, X_p) dengan sampel sebanyak n pengamatan, maka pasangan datanya dapat ditulis sebagai berikut: (x_i^T, y_i^T) dengan $i=1, 2, \dots, n$.

$$\begin{aligned} x_{iu}^* &= \frac{x_{iu} - \bar{x}_u}{s_u} \\ y_{ir}^* &= \frac{y_{ir} - \bar{y}_r}{s_r} \end{aligned} \quad (2.11)$$

dengan,

$$\begin{aligned} \bar{x}_u &= \frac{1}{n} \sum_{i=1}^n x_{iu}; s_u = \sqrt{\frac{\sum_{i=1}^n (x_{iu} - \bar{x}_u)^2}{n-1}} \\ \bar{y}_r &= \frac{1}{n} \sum_{i=1}^n y_{ir}; s_r = \sqrt{\frac{\sum_{i=1}^n (y_{ir} - \bar{y}_r)^2}{n-1}} \end{aligned} \quad (2.12)$$

keterangan :

x_{iu}^* = observasi ke- i yang distandarisasi untuk variabel prediktor ke- u , $u = 1, 2, \dots, p$

y_{ir}^* = observasi ke- i yang distandarisasi untuk variabel respon ke- r , $r = 1, 2, \dots, q$

Kemudian $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{ip})^T$ dikumpulkan dalam matriks

$\mathbf{X}(n \times p)$ dan matriks $\mathbf{Y}(n \times q)$ yang berisikan $\mathbf{y}_i = (y_{i1}, y_{i2}, \dots, y_{ir})^T$ sebagai berikut :

$$\mathbf{X} = \begin{bmatrix} \mathbf{x}_1^T \\ \vdots \\ \mathbf{x}_n^T \end{bmatrix}; \mathbf{Y} = \begin{bmatrix} \mathbf{y}_1^T \\ \vdots \\ \mathbf{y}_n^T \end{bmatrix} \quad (2.13)$$

keterangan :

\mathbf{x}_1 = variabel prediktor ke-1

\mathbf{x}_n = variabel prediktor ke-n

\mathbf{y}_1 = variabel respon ke-1

\mathbf{y}_n = variabel respon ke-n

Apabila terjadi kondisi $n < p$, maka metode regresi yang umum digunakan seperti *Ordinary Least Square* (OLS) tidak dapat digunakan karena akan menghasilkan matriks kovarian ($\mathbf{X}^T \mathbf{X}$) yang singular. Namun metode PLS mampu mengatasi kasus kondisi $n < p$. Dalam PLS, reduksi dimensi dan pemodelan regresi dilakukan secara simultan. Regresi PLS didasarkan pada dekomposisi komponen laten yang ditunjukkan pada persamaan (2.14).

$$\begin{aligned} \mathbf{X} &= \mathbf{T}\mathbf{P}^T + \mathbf{E} \\ \mathbf{Y} &= \mathbf{T}\mathbf{Q}^T + \mathbf{F} \end{aligned} \quad (2.14)$$

keterangan :

\mathbf{T} = matriks komponen laten (*scores matrices*) untuk n pengamatan yang berukuran $n \times c$

\mathbf{P} = matriks koefisien (*loading matrices*) variabel X yang berukuran $p \times c$

\mathbf{Q} = matriks koefisien (*loading matrices*) variabel Y yang berukuran $q \times c$

\mathbf{E} dan \mathbf{F} = matriks residual

PLS merupakan metode yang membentuk matriks komponen laten \mathbf{T} sebagai transformasi linier \mathbf{X} . Hal tersebut dapat ditunjukan pada persamaan (2.15).

$$\mathbf{T} = \mathbf{X}\mathbf{W} \quad (2.15)$$

\mathbf{W} adalah matriks pembobot yang berukuran $p \times c$. Dengan c adalah banyaknya komponen laten. Selanjutnya \mathbf{W} dan \mathbf{T} dinotasikan sebagai berikut :

$$\begin{aligned} W &= [\mathbf{w}_1 \quad \mathbf{w}_2 \quad \cdots \quad \mathbf{w}_j] \\ T &= [\mathbf{t}_1 \quad \mathbf{t}_2 \quad \cdots \quad \mathbf{t}_j] \end{aligned}$$

dengan,

$$\mathbf{w}_j = \begin{bmatrix} w_{1j} \\ \vdots \\ w_{pj} \end{bmatrix}; \mathbf{t}_j = \begin{bmatrix} t_{1j} \\ \vdots \\ t_{nj} \end{bmatrix} \text{ untuk } j = 1, 2, \dots, c \quad (2.16)$$

Komponen laten digunakan untuk melakukan prediksi terhadap \mathbf{Y} , menggantikan variabel asalnya yaitu \mathbf{X} .

Dari persamaan 2.14 dan 2.15 dapat diperoleh model regresi berganda sebagai berikut,

$$\begin{aligned} \mathbf{Y} &= \mathbf{X}\mathbf{W}\mathbf{Q}^T + \mathbf{F} \\ \mathbf{Y} &= \mathbf{X}\mathbf{B} + \mathbf{F} \end{aligned} \quad (2.17)$$

dengan \mathbf{B} adalah matriks koefisien regresi (Wold, et al., 2001).

Algoritma terperinci untuk menghitung regresi PLS dapat diperoleh dari literatur (Sijmen, 1993), koefisien regresi kemudian dapat digunakan untuk mengidentifikasi variabel yang relevan.

2.3.3 Stepwise Regression

Stepwise regression merupakan salah satu metode yang digunakan untuk mendapatkan persamaan regresi terbaik dengan melakukan reduksi variabel prediktor dalam analisis regresi berganda yang dapat dilakukan dengan menggabungkan metode *forward selection* dan *backward elimination*.

Forward selection merupakan salah satu metode pemilihan model terbaik dengan memasukkan variabel bebas secara berulang-ulang. Metode ini dimulai dari nol peubah (*intercept*), kemudian satu persatu variabel prediktor dimasukkan hingga diperoleh nilai kriteria yang optimum. Kebalikan dari *forward*

selection, backward elimination dalam menentukan variabel yang memiliki kriteria optimum dilakukan dengan mengeluarkan satu per satu variabel prediktor.

Pemilihan model dalam *stepwise regression* menggunakan nilai *Akaike's Information Criterion* (AIC) yang dapat menjelaskan kecocokan model dengan data yang ada (*in-sample forecasting*) dan nilai yang terjadi di masa mendatang (*out-sample forecasting*).

Menurut Widarjono (2007) dalam Fathurahman (2010) metode AIC didasarkan pada metode *Maximum Likelihood Estimation* (MLE), dengan perhitungan menggunakan persamaan (2.18).

$$AIC = -2 \ln(\hat{L}) + 2k \quad (2.18)$$

k adalah jumlah parameter dalam model dan L adalah nilai maksimal dari *likelihood function* untuk estimasi model. Model regresi terbaik adalah model yang memiliki nilai AIC terkecil.

2.3.4 Ridge Regression

Regresi ridge merupakan suatu metode untuk mengatasi multikolinieritas yang mengakibatkan matriks $\mathbf{X}^T \mathbf{X}$ bersifat hampir singular. Keadaan tersebut dapat menyebabkan estimasi β menjadi tidak efisien (varians yang besar). Misalkan \mathbf{Z} merupakan matriks yang memuat variabel prediktor yang sudah distandarisasi. Pendugaan parameter regresi ridge menggunakan metode kuadrat terkecil dengan menambahkan sebuah ketetapan bias λ pada nilai diagonal matriks $\mathbf{Z}^T \mathbf{Z}$. Bilangan λ mencerminkan besarnya bias pada penduga regresi ridge, sehingga penduga regresi ridge dari r elemen $\beta_z = (\beta_{1z}, \beta_{2z}, \dots, \beta_{rz})^T$ adalah r elemen $\mathbf{b}_z(\lambda) = \{b_{1z}(\lambda), b_{2z}(\lambda), \dots, b_{rz}(\lambda)\}^T$ yang dituliskan pada persamaan (2.19).

$$\hat{\mathbf{b}}_z(\lambda) = (\mathbf{Z}^T \mathbf{Z} + \lambda \mathbf{I})^{-1} \mathbf{Z}^T \mathbf{Y} \quad (2.19)$$

Konstanta $\lambda = 0$ maka estimator $b_z(\lambda)$ akan bernilai sama dengan nilai dugaan OLS. Jika λ dinaikan, maka nilai mutlak dugaan menjadi semakin kecil menuju nol untuk λ menuju tak hingga. Kriteria pemilihan tetapan bias yaitu dengan memilih

tetapan bias yang menghasilkan bias relatif kecil dan menghasilkan koefisien yang relatif stabil. (Hoerl & Kennard, 2010)

2.4 Ensemble Prediction System

Menurut Demeritt (2007) model yang diperoleh dari sistem prediksi tunggal seringkali menghasilkan akurasi model yang rendah, sehingga dibutuhkan metode yang menghasilkan prediksi yang bersifat probabilistik, salah satunya dengan mengembangkan *Ensemble Prediction System* (EPS). EPS adalah sistem prediksi cuaca numerik (NWP) yang memungkinkan untuk memprakirakan ketidakpastian dalam prediksi cuaca. Model prediksi *ensemble* dibentuk dengan mengkombinasikan beberapa sistem prediksi tunggal. Model EPS diperkenalkan pertama kali oleh *European Center for Medium-Range Weather Forecast* (ECMWF) di Eropa dan *National Centers for Environmental Prediction* (NCEP) di Amerika Serikat pada tahun 1992 (Froude, 2010).

Kebanyakan studi dalam prediksi cuaca atau iklim menghasilkan performa akurasi model yang lebih baik daripada model sistem prediksi tunggal. Ada tiga cara untuk melakukan konstruksi model system prediksi *ensemble* (Viney, Croke, Breuer, Bormann, Bronstert, Frede, Graff, Hubrechts, Huisman, Jakeman, Kite, Lanini, Leavesley, Lettenmaier, Lindstrom, Seibert, Sivapalan, & Willems, 2005), yaitu :

1. Menggunakan nilai rerata kasar (*raw mean*) atau lebih lazim disebut sebagai *ensemble mean*.
2. Mengadopsi nilai median harian dari semua *ensemble members*.
3. Menggunakan multi variabel linear regresi dalam periode kalibrasi dan mengaplikasikan selama masa validasi.

Raftery, et al. (2005) menyatakan bahwa salah satu karakteristik peramalan *ensemble* adalah sering kali bersifat bias dan *underdispersive*. *Underdispersive* berartikan bahwa hasil peramalan yang dihasilkan cenderung terpusat pada suatu titik tertentu dengan nilai varians yang relatif rendah, sehingga dibutuh-

kan metode *post-processing* dan kalibrasi yang bertujuan untuk memperbaiki prediksi *ensemble*.

2.5 Ensemble Model Output Statistics

Ensemble Model Output Statistics (EMOS) merupakan metode *post-processing* untuk menangani hasil peramalan *ensemble* yang bias dan *underdispersive*. EMOS diperkenalkan pertama kali oleh Gneiting, T., Raftery, A. E., Westveld, A. H. & Goldman, T., (2005). EMOS merupakan pengembangan metode MOS yaitu dengan menggabungkan atau mengkombinasikan model MOS. Peramalan *ensemble* berukuran m dinotasikan sebagai x_1, x_2, \dots, x_m merupakan anggota *ensemble* yang didapatkan dari peramalan tunggal untuk ukuran univariat Y . Anggota *ensemble* atau *raw ensemble* digunakan sebagai variabel prediktor pada regresi linier berganda, sehingga didapatkan persamaan (2.20).

$$Y = a + b_1 x_1 + \dots + b_m x_m + \varepsilon \quad (2.20)$$

a, b_1, \dots, b_m merupakan koefisien regresi dan ε adalah *error* dengan varians σ^2 dan *mean* 0. Gneiting (2005) mengusulkan pendekatan untuk meningkatkan kinerja prediktif *ensemble*, dengan mengasumsikan *error* berdistribusi normal yaitu $\varepsilon \sim N(0, \sigma^2)$, maka akan mengarah pada distribusi Y dengan m *ensemble member*.

$$Y|x_1, \dots, x_m \sim N(a + \sum_{k=1}^m b_k x_k, \sigma^2) \quad (2.21)$$

Distribusi bersyarat ini memungkinkan untuk mendapatkan estimasi PDF dan CDF dari persamaan 2.20. Gneiting, et al., (2005) dalam Narendra (2017) mengusulkan model varians dari *error* sebagai fungsi linier penyebaran (*spread*) *ensemble*:

$Var(\varepsilon) = c + dS^2$, dengan $S^2 = \frac{1}{m} \sum_{k=1}^m (x_k - \bar{x})^2$ merupakan *variанс ensemble*, dan $\bar{x} = \frac{1}{m} \sum_{k=1}^m x_k$, serta c dan d merupakan koefisien non-negatif, sehingga diperoleh distribusi prediktif Y ditunjukkan pada persamaan (2.22).

$$Y|x_1, \dots, x_m \sim N(a + \sum_{k=1}^m b_k x_k, c + dS^2) \quad (2.22)$$

Mean prediktif model EMOS merupakan rata-rata bobot koreksi bias *ensemble member* dan memberikan prediksi deterministik. Koefisien a, b_1, \dots, b_m merupakan korelasi antara *ensemble member*. Koefisien c dan d mencerminkan penyebaran *ensemble* dan kinerja dari peramalan *mean ensemble*, semakin besar nilai d menunjukkan hubungan *spread-error* lebih jelas, sehingga d akan kecil jika *spread* dan *error* independen.

2.6 Evaluasi Kebaikan Model

Evaluasi kebaikan model digunakan untuk mengetahui model optimum dalam prediksi dengan mengevaluasi nilai *error* prediksi dan ketajaman prediksi terhadap observasi. Keakuratan hasil prediksi dapat dievaluasi menggunakan RMSE, CRPS, dan rank histogram.

2.6.1 Continuous Ranked Probability Score

Keakuratan hasil peramalan kalibrasi *ensemble* yang bersifat probabilistik dapat dievaluasi menggunakan CRPS dengan membandingkan distribusi hasil peramalan dan observasi menggunakan fungsi distribusi kumulatif (CDF).

$$crps(F, y) = \int_{-\infty}^{\infty} [F(t) - H(t-y)]^2 dt \quad (2.23)$$

dengan,

$$H(t-y) = \begin{cases} 0, & t < y \\ 1, & \text{lainnya} \end{cases}$$

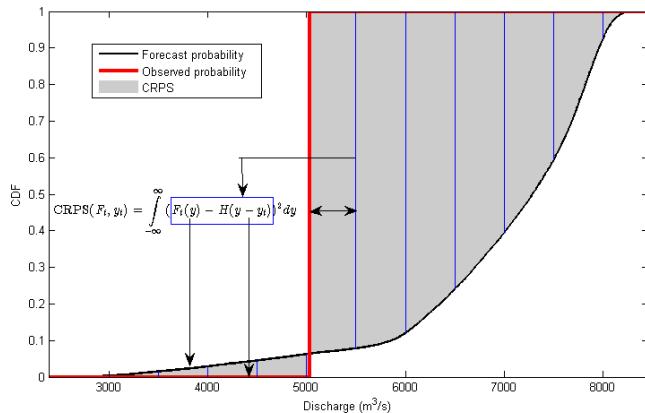
yang dikenal dengan fungsi *Heaviside*, y merupakan nilai observasi, t merupakan periode waktu yang digunakan, dan F merupakan CDF distribusi normal (μ, σ^2) dengan pengulangan integrasi parsial dari (2.23) menunjukkan bahwa,

$$crps[N(\mu, \sigma^2), y] = \sigma \left\{ \frac{y-\mu}{\sigma} \left[2\Phi\left(\frac{y-\mu}{\sigma}\right) - 1 \right] + 2\varphi\left(\frac{y-\mu}{\sigma}\right) - \frac{1}{\sqrt{\pi}} \right\} \quad (2.24)$$

dimana $\varphi\left(\frac{y-\mu}{\sigma}\right)$ dan $\Phi\left(\frac{y-\mu}{\sigma}\right)$ merupakan PDF dan CDF distribusi normal dengan *mean* 0 dan varians 1 dievaluasi pada kesalahan

prediksi yang dinormalkan, $\left(\frac{y - \mu}{\sigma}\right)$. Secara visual ditunjukkan oleh

Gambar 2.1 (Robertson, et al., 2013)



Gambar 2.1 Ilustrasi *Continuous Ranked Probability Score*

Model dikatakan baik dan *reliable* dalam melakukan peramalan jika memiliki nilai CRPS yang kecil, dalam hal ini mendekati 0 (Hersbach, 2000).

2.6.2 Residual Mean Square Error

RMSE merupakan akar rata-rata kuadrat dari selisih nilai prediksi dan nilai observasi. Adanya *outlier* dapat mempengaruhi nilai RMSE yang dapat mempengaruhi akurasi kebaikan prediksi. Dengan RMSE dapat diketahui ukuran kesalahan prediksi. Kebaikan model prediksi memiliki nilai RMSE yang kecil. Secara univariat, RMSE diformulakan pada persamaan (2.25).

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.25)$$

dengan,

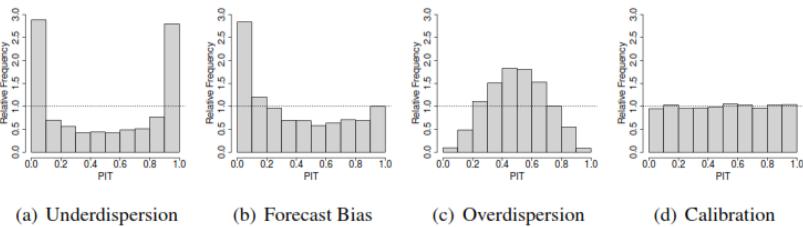
y_t = observasi pada waktu ke- t

\hat{y}_t = prediksi pada waktu ke- t

n = banyaknya observasi

2.6.3 Verification Rank Histogram

Prediksi *ensemble* dapat dievaluasi menggunakan rank histogram. Rank histogram menunjukkan persebaran prediksi *ensemble* dengan melihat pola yang terbentuk. Dengan melihat pola yang terbentuk seperti pada Gambar 2.2 (Moller, 2014), rank histogram akan membentuk garis lurus yang menunjukkan bahwa prediksi *ensemble* telah terkalibrasi dengan baik. Pola rank histogram membentuk pola huruf U, menunjukkan bahwa sebaran prediksi bersifat *underdispersive*, sedangkan sebaran prediksi bersifat *overdispersive* jika pola rank histogram yang terbentuk yaitu mengumpul ditengah.



Gambar 2.2 Pola Verification Rank Histogram

2.7 Suhu dan Kelembaban

Cuaca merupakan kondisi udara yang terjadi disuatu daerah atau wilayah dalam periode waktu tertentu. Perbedaan cuaca yang berubah-ubah disuatu wilayah disebabkan oleh adanya perbedaan suhu dan kelembaban. Suhu merupakan salah satu unsur cuaca yang menyatakan suatu ukuran panas, dingin, dan hangatnya suatu benda. Beberapa faktor penyebab perbedaan suhu adalah sebagai berikut,

- Sudut datang sinar matahari
- Lama waktu peninjoran
- Ketinggian tempat
- Keadaan permukaan bumi.

Menurut Arpan, Kirono, & Sudjarwadi, (2004) kelembaban udara menyatakan banyaknya uap air dalam udara. Jumlah uap air

dalam udara merupakan sebagian kecil dari seluruh atmosfer, yaitu bervariasi dari 0% sampai 5% dari jumlah massa udara. Penyebab pentingnya variabilitas kandungan uap air dalam udara baik berdasarkan tempat maupun waktu yaitu,

- a. Besarnya jumlah uap air dalam udara merupakan indikator kapasitas potensial atmosfer tentang terjadinya hujan.
- b. Uap air mempunyai sifat menyerap radiasi bumi sehingga uap air menentukan kecepatan kehilangan panas dari bumi dan dengan sendirinya juga ikut mengatur suhu.
- c. Semakin besar jumlah uap air dalam udara, semakin besar pula energy potensial yang latent tersedia dalam atmosfer dan merupakan sumber atau asal terjadinya hujan.

Kapasitas udara menyatakan jumlah uap air yang dapat dikandung oleh udara pada suatu suhu. Besar kecilnya kapasitas udara bergantung pada suhu. Semakin tinggi suhu maka semakin besar kapasitas udara, dan sebaliknya. Jika kapasitas udara dapat dicapai berarti udara itu jenuh dengan uap air. Suhu udara yang bertepatan dengan jenuhnya udara disebut titik embun, saat itulah kondensasi dapat terjadi.

BAB III

METODOLOGI PENELITIAN

3.1 Sumber Data

Data yang digunakan yaitu data sekunder bersumber dari Badan Meteorologi, Klimatologi dan Geofisika Jakarta. Data tersebut terdiri atas data observasi temperatur maksimum, minimum dan kelembaban udara serta data luaran NWP model *Weather Research and Forecasting Environmental Modelling System* (WRF-EMS) dengan periode data 2 Januari 2015 hingga 10 Desember 2016. Lokasi yang digunakan yaitu stasiun meteorologi Pattimura dan stasiun meteorologi Hasanuddin.

3.2 Variabel Penelitian

Variabel penelitian yang digunakan terdiri atas variabel respon berupa data observasi yang ditampilkan pada Tabel 3.1,

Tabel 3.1 Variabel Respon Penelitian

No	Variabel	Keterangan	Satuan
1	Y1	Temperatur Maksimum (Tmaks)	Celcius
2	Y2	Temperatur Minimum (Tmin)	Celcius
3	Y3	Kelembaban Rata-rata (RH)	%

dan variabel prediktor berupa data *output* NWP model WRF-EMS disajikan pada Tabel 3.2.

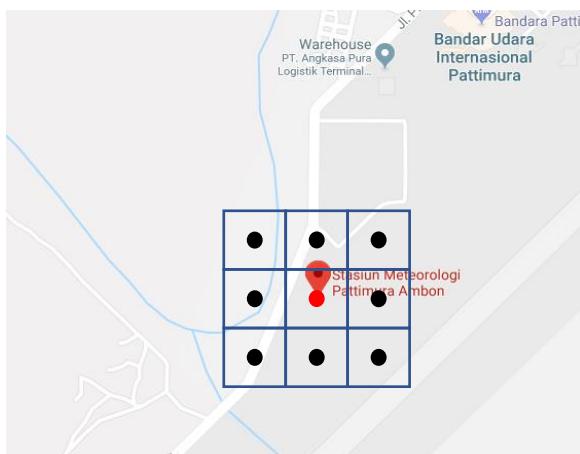
Tabel 3.2 Variabel Prediktor Penelitian

No	Variabel	Keterangan	Satuan
1	X1	dew2m	celcius
2	X2	hi_cloud	%
3	X3	hujan_total	mm/jam
4	X4	low_cloud	%
5	X5	mid_cloud	%

Tabel 3.2 (lanjutan) Variabel Prediktor Penelitian

No	Variabel	Keterangan	Satuan
6	X6	mslp	%
7	X7	rhum2m	%
8	X8	shum2m	kg/kg
9	X9	sur_press	mb
10	X10	sur_vis	m
11	X11	temp2m	celcius
12	X12	tot_cloud	%
13	X13	uwind10m	m./s
14	X14	vwind10m	m/s
15	X15	wind_gust	m/s

Variabel prediktor yang digunakan yaitu parameter NWP model WRF-EMS sebanyak 15 parameter yang ditunjukkan oleh Tabel 3.2 Masing-masing parameter diukur pada Sembilan grid (3×3) pengukuran yang terdekat dari lokasi stasiun pengamatan seperti yang ditunjukkan oleh Gambar 3.1.

**Gambar 3.1 Pengukuran NWP dalam Grid 3 x 3**

Grid yang paling dekat dengan lokasi pengamatan ditunjukkan oleh titik berwarna merah, sedangkan kombinasi dari grid di sekitar lokasi pengamatan ditunjukkan oleh titik berwarna hitam.

Definisi operasional dari variabel prediktor yang digunakan pada penelitian dijelaskan sebagai berikut.

1. Hujan Total (hujan_total) adalah jumlah setiap produk dari kondensasi uap air di atmosfer yang jatuh karena grafitasi.
2. *Dew point* 2m (dew2m) adalah pengukuran titik embun yang dilakukan pada ketinggian 2 meter.
3. *Wind gust* (wind_gust) adalah angin yang berkaitan dengan banya guntur arah dan kecepatannya dapat berubah dengan cepat pada waktu terik matahari. Perubahan kecepatannya dapat besar dan dalam waktu yang singkat. Sesaat sesudah terjadi perubahan angin tersebut, biasanya diikuti keadaan lengang atau tak ada angin.
4. *High cloud* (hi_cloud) adalah awan yang letaknya pada ketinggian lebih dari 3 km tetapi tidak sama disetiap wilayah.
5. *Low cloud* (low_cloud) adalah awan yang terletak pada paras rendah kurang dari 2 km.
6. *Middle cloud* (mid_cloud) adalah awan yang terletak pada paras antara 2 dan 8 km tetapi tidak sama disetiap wilayah
7. *Total cloud* (tot_cloud) adalah persentase jumlah awan tanpa memperhatikan letak awan disetiap wilayah.
8. *Mean sea level pressure* (mslp) adalah suhu rata-rata di atas permukaan laut.
9. *Surface pressure* (sur_press) adalah tekanan permukaan diukur berdasarkan tekanan gaya pada permukaan dengan luas tertentu. Tekanan udara berkurang dengan bertambahnya ketinggian.
10. *Relative humidity* 2m (rhum2m) adalah nilai perbandingan antara tekanan uap air ada pada saat pengukuran dan besarnya tekanan uap air maksimum yang dapat dicapai pada suhu dan tekanan udara pada saat itu yang di ukur pada 2 meter di atas permukaan laut.

11. *Specific humidity* 2m (shum2m) adalah perbandingan antara massa uap air dan massa udara dalam tiap satuan volume udara yang diukur pada 2 meter di atas permukaan laut.
12. Temperatur 2m (temp2m) adalah derajat panas dan dingin udara di atmosfer yang diukur pada ketinggian 2 meter di atas permukaan.
13. *U wind* 10m (uwind10m) adalah konvensi angin dari arah barat ke timur yang diukur pada ketinggian 10 meter di atas permukaan laut.
14. *V wind* 10m (vwind10m) adalah konvensi angin dari arah selatan ke utara yang diukur pada ketinggian 10 meter di atas permukaan laut (Fachrunisah, 2017).

Struktur data setiap variabel respon pada masing-masing stasiun pengamatan disajikan pada Tabel 3.3.

Tabel 3.3 Struktur Data Penelitian

Stasiun	Variabel Respon Y _i	Variabel Prediktor						
		dew2m		...	wind_gust			
		dew2m (1)	...		wind_gust (1)	...	wind_gust (9)	
Hasanuddin	Y ₁	22.56	...	24.71	...	6.93	...	8.69
	Y ₂	22.36	...	24.77	...	8.37	...	10.27
	Y ₃	22.35	...	24.71	...	6.55	...	8.17
	Y ₄	22.53	...	24.64	...	7.85	...	9.03
	Y ₅	22.26	...	24.64	...	7.70	...	9.87
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	Y ₃₄₈	22.20	...	24.15	...	2.10	...	2.43
	Y ₃₄₉	22.04	...	24.12	...	3.01	...	2.94
	Y ₃₅₀	22.03	...	24.00	...	1.86	...	1.85
	Y ₃₅₁	20.94	...	24.03	...	3.30	...	3.74
Pattimura	Y ₁	23.92	...	24.65	...	7.10	...	8.01
	Y ₂	23.92	...	24.84	...	7.18	...	9.64
	Y ₃	24.18	...	25.04	...	9.65	...	11.00
	Y ₄	24.09	...	24.83	...	9.11	...	9.58
	Y ₅	23.91	...	24.58	...	8.68	...	8.75
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	Y ₃₅₀	23.59	...	24.22	...	2.93	...	1.92
	Y ₃₅₁	23.91	...	24.18	...	3.25	...	2.94
	Y ₃₅₂	24.37	...	25.28	...	4.39	...	4.08
	Y ₃₅₃	23.59	...	24.02	...	2.13	...	1.93

keterangan :

- i* = banyak data pada stasiun pengamatan
 - 1. Stasiun Hasanuddin dengan $n = 1, 2, 3, \dots, 351$
 - 2. Stasiun Pattimura dengan $n = 1, 2, 3, \dots, 353$

3.3 Langkah Analisis Data

Berikut langkah – langkah yang dilakukan untuk mencapai tujuan penelitian. Dalam mencapai tujuan penelitian pertama yaitu mendapatkan prediksi temperatur maksimum, temperatur minimum dan kelembaban menggunakan MOS dengan pendekatan metode PCR, PLSR, *stepwise regression*, dan *ridge regression* digunakan langkah analisis sebagai berikut,

1. Melakukan *pre-processing* data.
 - a. Menyetarakan jumlah data NWP dengan data observasi cuaca berdasarkan waktu pengukuran.
 - b. Apabila terdapat *missing value* pada data observasi, maka dilakukan imputasi dengan nilai rata-rata pada 1 hari sebelum dan sesudahnya.
2. Melakukan deskripsi data temperatur maksimum, temperatur minimum, dan kelembaban di stasiun Hasanuddin dan Pattimura.
3. Melakukan standarisasi data *output* NWP (X) dan data observasi (Y). Standarisasi dilakukan dengan mengurangi nilai setiap pengamatan dengan rata-rata, setelah itu dibagi dengan standart deviasinya, menggunakan persamaan (2.11).
4. Melakukan reduksi dimensi *output* NWP menggunakan PCA dengan langkah sebagai berikut :
 - a. Menghitung matriks varians kovarians.
 - b. Menghitung nilai *eigenvalue* dan *eigenvector* dari matriks kovarians.
 - c. Membentuk variabel baru dari PC yang memiliki nilai *eigen* lebih dari 1.
5. Melakukan pemodelan MOS dengan menggunakan metode PCR, PLSR, *stepwise Regression*, dan *ridge regression*.

Tahapan dalam pemodelan MOS dengan pendekatan PCR adalah sebagai berikut :

- a. Menentukan komponen optimum yang digunakan dengan menggunakan *cross validation*. Dimana jumlah komponen optimum dipilih berdasarkan nilai kumulatif varian sebesar 80%.
- b. Meregresikan komponen optimum yang terpilih dengan masing-masing variabel respon yaitu T_{maks} , T_{min} , dan RH yang telah distandarisasi.

Tahapan pemodelan MOS dengan pendekatan PLSR adalah sebagai berikut :

- a. Mendefinisikan vektor **u** (vector inisial Y-scores)
- b. Membentuk matriks pembobot inisial **W**
- c. Membentuk matriks skor **T**
- d. Membentuk matriks *loading* **Q** (matriks Y-loading)
- e. Membentuk Y-scores yang diperbarui **U***
- f. Membentuk pembobot prediktor yang diperbarui **W***
- g. Membentuk X-scores yang diperbarui **T***
- h. Menguji konvergensi vektor X-scores
- i. Menghitung koefisien regresi **B**
- j. Membentuk model regresi PLS

Tahapan pemodelan MOS dengan pendekatan *stepwise regression* sebagai berikut :

- a. Meregresikan variabel respon dan variabel prediktor secara univariat
- b. Menghitung nilai AIC dengan semua variabel prediktor terlibat ke dalam model.
- c. Menghilangkan satu per satu variabel prediktor dari model dan menghitung nilai AIC menggunakan persamaan (2.21), hingga diperoleh nilai AIC yang terbaik.
- d. Membuat model regresi antara variabel prediktor yang telah dipilih berdasarkan nilai AIC terbaik dengan masing-masing variabel respon.

Tahapan pemodelan MOS dengan pendekatan *ridge regression* sebagai berikut :

- a. Menentukan nilai konstanta λ optimum
- b. Melakukan estimasi β dengan persamaan (2.22)
- c. Melakukan prediksi cuaca dengan model regresi ridge
6. Menghitung nilai prediksi untuk setiap model MOS yang digunakan sebagai *ensemble member*.

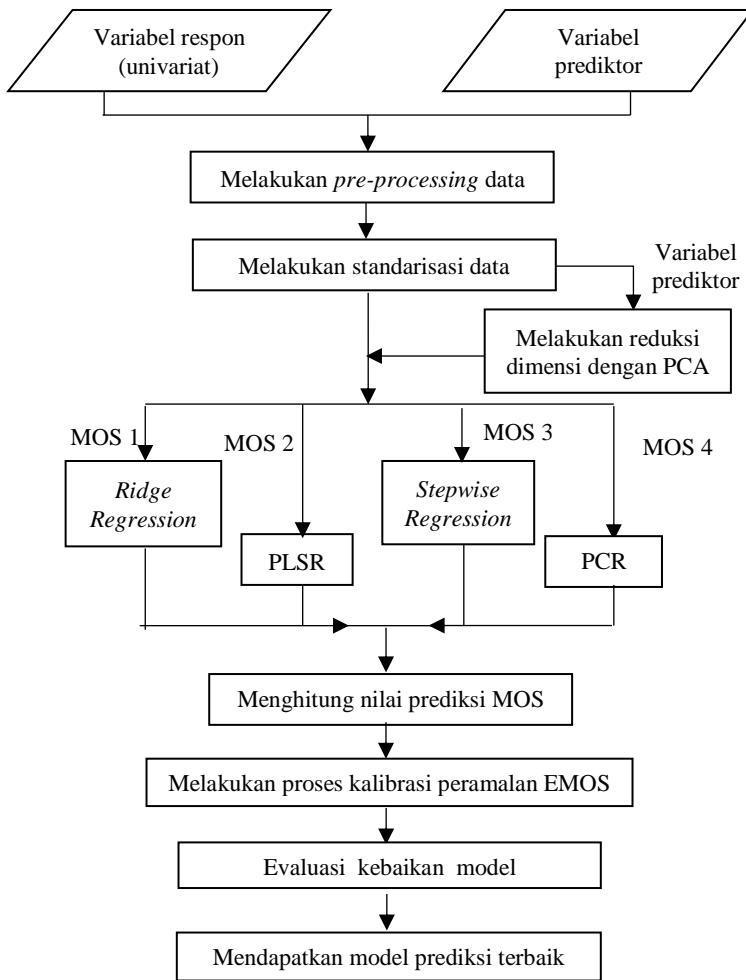
Langkah analisis yang digunakan untuk mencapai tujuan penelitian kedua yaitu mendapatkan hasil kalibrasi temperatur maksimum, temperatur minimum dan kelembaban menggunakan EMOS sebagai berikut,

7. Melakukan pemodelan EMOS dengan langkah-langkah sebagai berikut.
 - a. Menetapkan jumlah *training window* yang optimal.
 - b. Meregresikan prediksi *ensemble* dengan pengamatan sebenarnya untuk data *training window* yang ditetapkan.
 - c. Melakukan kalibrasi untuk memperoleh parameter kalibrasi, yaitu parameter *mean* dan parameter varians.
 - d. Mendapatkan taksiran interval prediksi *ensemble* terkalibrasi.

Untuk mencapai tujuan penelitian ketiga yaitu memperoleh model prediksi temperatur maksimum, temperatur minimum dan kelembaban terbaik digunakan langkah analisis sebagai berikut,

8. Melakukan evaluasi kebaikan prediksi terkalibrasi dengan menghitung nilai RMSE, CRPS, rank histogram.
9. Menarik kesimpulan

Berdasarkan langkah analisis, diagram alir penelitian pada setiap stasiun yang menganalisis variabel respon dan variabel prediktor secara univariat ditunjukkan pada Gambar 3.2.



Gambar 3.2 Diagram Alir Analisis Data

BAB IV

ANALISIS DAN PEMBAHASAN

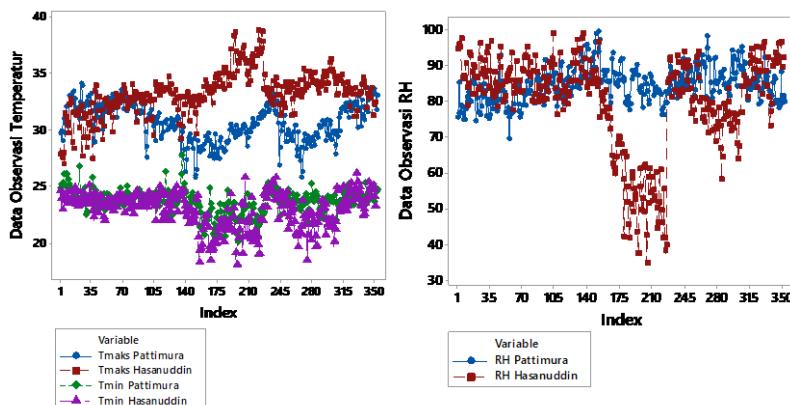
Analisis dan pembahasan penelitian terdiri atas uraian mengenai pembentukan model prediksi anggota *ensemble* dengan metode MOS, Pembentukan model prediksi *ensemble* terkalibrasi menggunakan metode EMOS, dan pemilihan model prediksi terbaik berdasarkan akurasi model prediksi.

4.1 Pembentukan Model Prediksi Anggota *Ensemble*

Sub bab ini membahas pembentukan model prediksi untuk mendapatkan anggota *ensemble* menggunakan metode PCR, PLSR, *stepwise regression*, dan *ridge regression*. Sebelum pembedahan, terlebih dahulu dilakukan deskripsi dan *pre-processing* data untuk kedua stasiun pengamatan.

4.1.1 Deskripsi Temperatur Maksimum, Temperatur Minimum, dan Kelembaban di Lokasi Penelitian

Karakteristik dan pola data observasi temperatur maksimum, temperatur minimum, dan kelembaban untuk kedua stasiun meteorologi ditampilkan pada Gambar 4.1 dan Tabel 4.1.



Gambar 4.1 Pola Data Observasi Temperatur Maksimum, Temperatur Minimum, dan Kelembaban pada Stasiun Hasanuddin dan Pattimura.

Gambar 4.1 menunjukkan bahwa rata-rata temperatur maksimum dan temperatur minimum untuk kedua stasiun pengamatan berbanding terbalik. Rata-rata temperatur maksimum stasiun meteorologi Hasanuddin lebih besar daripada stasiun meteorologi Pattimura dengan nilai maksimumnya yaitu 38,8. Sedangkan temperatur minimum meteorologi Hasanuddin lebih kecil daripada stasiun meteorologi Pattimura dengan nilai minimum 18 (Tabel 4.1).

Untuk variabel kelembaban, rata-rata kelembaban stasiun meteorologi Pattimura lebih besar daripada stasiun meteorologi Hasanuddin, dengan nilai maksimum dan minimum masing-masing yaitu 99,704 dan 69,412. Rata-rata temperatur/suhu (t) normal Indonesia yaitu berada di sekitar $25^{\circ} < T < 36^{\circ}$, sedangkan rata-rata kelembaban udara Indonesia berada di sekitar 55 - 100 %. Jika dilihat nilai modus unsur cuaca, suhu dan kelembaban di kedua stasiun pengamatan masih tergolong normal.

Tabel 4.1 Statistika Deskriptif Data Observasi Temperatur Maksimum, Temperatur Minimum, dan Kelembaban pada Stasiun Hasanuddin dan Pattimura

Variabel	Minimum	Maksimum	Modus	N Modus
Tmaks Hasanuddin (°C)	26,900	38,800	33,2 33,3	13 13
Tmaks Pattimura (°C)	25,700	34,100	29	12
Tmin Hasanuddin (°C)	18,000	26,100	23,8	17
Tmin Pattimura (°C)	20,100	27,700	24,2	23
RH Hasanuddin (%)	34,642	98,981	86,65 88,379	2 2
RH Pattimura (%)	69,412	99,704	78,208	2
			81,329	2
			81,566	2
			82,508	2
			82,579	2

4.1.2 Pre-processing Data

Pengukuran grid pada data NWP menghasilkan prediksi bersifat homogen pada daerah grid tersebut dan menyebabkan adanya

multikolinieritas. Sehingga dibutuhkan *pre-processing* data pada parameter NWP dengan melakukan reduksi dimensi menggunakan PCA. Selain mengatasi multikolinieritas, PCA juga bertujuan mereduksi hubungan spasial antar grid ke dalam beberapa komponen utama. Dengan menggunakan program pada Lampiran 15, diperoleh hasil PC yang memiliki *eigen value* yang lebih dari satu dan nilai kumulatif varians minimal 80% seperti pada Tabel 4.2.

Tabel 4.2 Banyak PC Parameter NWP di Stasiun Hasanuddin dan Pattimura

Parameter	Hasanuddin			Parameter	Pattimura		
	Jum PC	Eigen Value	Kum varians		Jum PC	Eigen Value	Kum varians
dew2m	1	8,636	96,0%	dew2m	1	8,695	96,6%
hi cloud	1	8,269	91,9%	hi cloud	1	8,211	91,2%
hujan total	1	7,277	80,9%	hujan total	1	7,387	82,1%
		4,351	48,3%				
low cloud	3	1,660	66,8%	low cloud	1	7,659	85,1%
		1,274	80,9%				
mid cloud	1	8,262	91,8%	mid cloud	1	8,392	93,2%
mslp	1	8,891	98,8%	mslp	1	8,965	99,6%
rhum2m	1	8,159	90,7%	rhum2m	1	7,999	88,9%
shum2m	1	8,621	95,8%	shum2m	1	8,698	96,6%
sur press	1	8,930	99,2%	sur press	1	8,979	99,8%
sur vis	2	6,976	77,5%	sur vis	2	7,256	80,6%
		1,053	89,2%			1,064	92,4%
temp2m	2	5,363	59,6%	temp2m	1	8,053	89,5%
		3,235	95,5%				
tot cloud	1	8,409	93,4%	tot cloud	1	8,430	93,7%
uwind 10m	1	8,642	96,0%	uwind 10m	1	8,944	99,4%
vwind 10m	1	8,296	92,2%	vwind 10m	1	8,948	99,4%
wind gust	2	7,337	81,5%	wind gust	1	8,803	97,8%
		1,029	93,0%				

Hasil PCA untuk stasiun meteorologi Hasanuddin yaitu menghasilkan 20 komponen utama, dan dihasilkan 16 komponen utama pada stasiun meteorologi Pattimura. Komponen utama dari tiap stasiun tersebut dijadikan sebagai variabel prediktor dalam pembentukan model prediksi anggota *ensemble*.

4.1.3 Pemodelan Prediksi dengan PCR

Pembangunan model suhu dan kelembaban dengan PCR dilakukan dengan menggunakan respon univariat masing-masing stasiun meteorologi. Sebelum pemodelan PCR dilakukan, terlebih dahulu ditetapkan jumlah komponen optimal. Pemilihan komponen tersebut didasarkan pada kumulatif varians dengan nilai minimal 80%. Dengan menggunakan program pada Lampiran 16, diperoleh jumlah komponen terpilih untuk stasiun Hasanuddin yaitu 7 komponen dengan nilai kumulatif varians sebesar 81,42% seperti pada Tabel 4.3.

Tabel 4.3 Kumulatif Varians Tmaks, Tmin, dan RH Stasiun Hasanuddin

Banyak Komponen	% Kumulatif Varians	Banyak Komponen	% Kumulatif Varians
1	35,66	11	94,69
2	48,65	12	96,27
3	57,87	13	87,76
4	65,46	14	98,97
5	71,11	15	99,67
6	76,36	16	99,93
7	81,42*	17	99,98
8	85,98	18	100
9	89,58	19	100
10	92,72	20	100
<hr/>		Tmaks	Tmin
<hr/>		67,24	55,16
<hr/>		RH	76,02

Ket : *komponen dengan kumulatif varians >80%

Hasil tersebut berlaku untuk semua variabel respon, dikarenakan ketiga unsur cuaca menghasilkan kumulatif varians yang sama. Pemodelan PCR dengan menggunakan 7 komponen tersebut dapat menjelaskan keragaman temperatur maksimum sebesar 67,24%, temperatur minimum sebesar 55,16%, serta RH sebesar 76,02%. Sedangkan keragaman lainnya dijelaskan oleh parameter lain selain 15 parameter yang telah disebutkan pada Tabel 3.2.

Komponen optimal stasiun meteorologi Hasanuddin tersebut diregresikan dengan masing-masing variabel respon sehingga didapatkan persamaan regresi yang ditampilkan pada Tabel 4.4.

Tabel 4.4 Model Prediksi PCR Tmaks, Tmin, dan RH Stasiun Hasanuddin

$\hat{y}_{T_{max}} = 0,0796dew2m + 0,0113hi_cloud + 0,0507hujan_total$ $+ 0,0263low_cloud_1 + 0,0052low_cloud_2$ $+ 0,1072low_cloud_3 + 0,0524mid_cloud - 0,0681mslp$ $+ 0,1548rhum2m + 0,0796shum2m - 0,0732sur_press$ $+ 0,0270sur_vis_1 - 0,0144sur_vis_2 + 0,1029temp2m_1$ $- 0,1686temp2m_2 + 0,0342tot_cloud + 0,1477uwind10m$ $- 0,1043vwind10m + 0,0363wind_gust_1 + 0,1672wind_gust_2$
$\hat{y}_{T_{min}} = -0,1459dew2m - 0,0244hi_cloud - 0,0172hujan_total$ $+ 0,0075low_cloud_1 - 0,0112low_cloud_2$ $- 0,0237low_cloud_3 - 0,0259mid_cloud + 0,0265mslp$ $- 0,0835rhum2m - 0,1458shum2m + 0,0273sur_press$ $- 0,0060sur_vis_1 + 0,0082sur_vis_2 - 0,0643temp2m_1$ $- 0,1776temp2m_2 - 0,0268tot_cloud - 0,0678uwind10m$ $+ 0,0806vwind10m + 0,1960wind_gust_1$ $+ 0,0995wind_gust_2 + 0,1672wind_gust_2$
$\hat{y}_{RH} = -0,1632dew2m + 0,0129hi_cloud - 0,0125hujan_total$ $- 0,0724low_cloud_1 - 0,0273low_cloud_2$ $- 0,0648low_cloud_3 - 0,0183mid_cloud + 0,1276mslp$ $- 0,1271rhum2m - 0,1632shum2m + 0,1315sur_press$ $- 0,0168sur_vis_1 - 0,0021sur_vis_2 - 0,1116temp2m_1$ $- 0,0676temp2m_2 - 0,0054tot_cloud - 0,0572uwind10m$ $+ 0,0323vwind10m + 0,0977wind_gust_1 - 0,0169wind_gust_2$

Sedangkan jumlah komponen terpilih untuk stasiun meteorologi Pattimura yaitu 5 komponen dengan kumulatif varians se-

besar 80,84% seperti pada Tabel 4.5. Pemodelan menggunakan 5 komponen tersebut dapat menjelaskan keragaman temperatur maksimum sebesar 66,25%, temperatur minimum sebesar 46,75%, serta RH sebesar 39,9%. Sedangkan keragaman lainnya dijelaskan oleh parameter lain selain 15 parameter yang telah disebutkan pada Tabel 3.2.

Tabel 4.5 Kumulatif Varians Tmaks, Tmin, dan RH Stasiun Pattimura

Banyak Komponen	% Kumulatif Varians	Banyak Komponen	% Kumulatif Varians
1	36,23	9	96,1
2	54,84	10	97,7
3	67,94	11	99,01
4	75,23	12	99,75
5	80,84*	13	99,94
6	85,92	14	100
7	89,94	15	100
8	93,26	16	100
<i>% Variance Explained</i>		Tmaks	Tmin
		66,25	46,75
			RH
			39,9

Ket : *komponen dengan kumulatif varians >80%

Selanjutnya dilakukan pemodelan PCR yaitu meregresikan komponen optimum dengan variabel respon secara univariat dan didapatkan persamaan regresi yang ditampilkan pada Tabel 4.6.

Tabel 4.6 Model Prediksi PCR Tmaks, Tmin, dan RH Stasiun Pattimura

$$\hat{y}_{T_{maks}} = -0,0520 \text{ dew2m} + 0,0623 \text{ hi_cloud} - 0,0554 \text{ hujan_total} \\ + 0,1046 \text{ low_cloud} - 0,000016 \text{ mid_cloud} - 0,0672 \text{ mslp} \\ + 0,2173 \text{ rhum2m} - 0,045 \text{ shum2m} - 0,0618 \text{ sur_press} \\ - 0,0519 \text{ sur_vis_1} - 0,0219 \text{ sur_vis_2} - 0,2137 \text{ temp2m} \\ + 0,0480 \text{ tot_cloud} - 0,1442 \text{ uwind10m} + 0,1535 \text{ vwind10m} \\ + 0,3207 \text{ wind_gust}$$

$\hat{y}_{T_{\min}} = -0,1538 \text{ dew2m} - 0,0238 \text{ hi_cloud} - 0,00012 \text{ hujan_total}$ + 0,0767 low_cloud - 0,00026 mid_cloud + 0,1386 mslp + 0,0368 rhum2m - 0,1556 shum2m + 0,1350 sur_press - 0,0531 sur_vis_1 - 0,0279 sur_vis_2 - 0,1224 temp2m - 0,0033 tot_cloud - 0,0344 uwind10m + 0,0557 vwind10m + 0,0319 wind_gust
$\hat{y}_{RH} = -0,1362 \text{ dew2m} + 0,0413 \text{ hi_cloud} - 0,0271 \text{ hujan_total}$ - 0,0928 low_cloud - 0,0289 mid_cloud + 0,0253 mslp - 0,2317 rhum2m - 0,1361 shum2m + 0,04 sur_press + 0,1097 sur_vis_1 + 0,0061 sur_vis_2 + 0,0652 temp2m - 0,0043 tot_cloud + 0,1702 uwind10m - 0,1584 vwind10m - 0,0706 wind_gust

4.1.4 Pemodelan Prediksi dengan PLSR

Dalam Pemodelan dengan PLSR, terlebih dahulu dilakukan penentuan jumlah komponen optimum untuk setiap modelnya yang didasarkan nilai RMSEP terkecil. Dengan menggunakan program pada Lampiran 17 didapatkan nilai RMSEP temperatur maksimum, temperatur minimum, dan kelembaban stasiun Hasanuddin ditunjukkan pada Tabel 4.7.

Tabel 4.7 RMSEP Tmaks, Tmin, dan RH Stasiun Hasanuddin

Banyak Komp	Tmaks	Tmin	RH	Banyak Komp	Tmaks	Tmin	RH
1	0,639	0,782	0,611	11	0,553	0,681	0,457
2	0,579	0,734	0,506	12	0,550*	0,684	0,460
3	0,569	0,715	0,506	13	0,552	0,691	0,466
4	0,571	0,702	0,506	14	0,556	0,667	0,460
5	0,569	0,704	0,503	15	0,559	0,671	0,464
6	0,566	0,693	0,507	16	0,557	0,672	0,460
7	0,560	0,680	0,511	17	0,556	0,668	0,450
8	0,554	0,683	0,467	18	0,552	0,662	0,451
9	0,552	0,686	0,464	19	0,553	0,646*	0,439*
10	0,553	0,689	0,459	20	0,555	0,648	0,440

Ket : * nilai RMSEP terkecil

Berdasarkan nilai RMSEP terkecil pada Tabel 4.7, diperoleh jumlah komponen optimal pada stasiun meteorologi Hasanuddin yaitu 12 komponen untuk temperatur maksimum dan 19 komponen

untuk temperatur minimum dan kelembaban. Selanjutnya meregresikan komponen yang telah terpilih dengan variabel respon secara univariat. Sehingga didapatkan persamaan regresi untuk stasiun meteorologi Hasanuddin yang ditampilkan pada Tabel 4.8.

Tabel 4.8 Model Prediksi PLSR Tmaks, Tmin, dan RH Stasiun Hasanuddin

$\hat{y}_{T_{\text{maks}}} = 0,3019 \text{ dew2m} + 0,0104 \text{ hi_cloud} - 0,0949 \text{ hujan_total}$ $+ 0,0592 \text{ low_cloud_1} + 0,0044 \text{ low_cloud_2}$ $- 0,0075 \text{ low_cloud_3} + 0,0783 \text{ mid_cloud} + 0,0160 \text{ mslp}$ $+ 0,0901 \text{ rhum2m} - 0,1231 \text{ shum2m} - 0,0830 \text{ sur_press}$ $+ 0,0722 \text{ sur_vis_1} + 0,0406 \text{ sur_vis_2} + 0,3047 \text{ temp2m_1}$ $- 0,1707 \text{ temp2m_2} + 0,0421 \text{ tot_cloud} + 0,5653 \text{ uwind10m}$ $+ 0,1549 \text{ vwind10m} + 0,1844 \text{ wind_gust_1}$ $- 0,0172 \text{ wind_gust_2}$
$\hat{y}_{T_{\text{min}}} = 2,9411 \text{ dew2m} + 0,0913 \text{ hi_cloud} + 0,0785 \text{ hujan_total}$ $+ 0,0776 \text{ low_cloud_1} + 0,0589 \text{ low_cloud_2}$ $- 0,0096 \text{ low_cloud_3} - 0,1541 \text{ mid_cloud} - 1,1122 \text{ mslp}$ $+ 0,5866 \text{ rhum2m} - 4,0861 \text{ shum2m} + 1,0277 \text{ sur_press}$ $- 0,0178 \text{ sur_vis_1} + 0,0229 \text{ sur_vis_2} + 0,0775 \text{ temp2m_1}$ $+ 0,0093 \text{ temp2m_2} - 0,0828 \text{ tot_cloud} - 0,2596 \text{ uwind10m}$ $+ 0,0010 \text{ vwind10m} + 0,0392 \text{ wind_gust_1}$ $+ 0,1087 \text{ wind_gust_2}$
$\hat{y}_{RH} = -3,1471 \text{ dew2m} + 0,0659 \text{ hi_cloud} + 0,0425 \text{ hujan_total}$ $+ 0,0033 \text{ low_cloud_1} + 0,02 \text{ low_cloud_2}$ $- 0,0076 \text{ low_cloud_3} + 0,0092 \text{ mid_cloud} - 0,2908 \text{ mslp}$ $+ 0,7101 \text{ rhum2m} + 2,0122 \text{ shum2m} + 0,446 \text{ sur_press}$ $+ 0,0124 \text{ sur_vis_1} - 0,0172 \text{ sur_vis_2} - 0,1983 \text{ temp2m_1}$ $+ 0,2486 \text{ temp2m_2} - 0,1441 \text{ tot_cloud} - 0,3194 \text{ uwind10m}$ $- 0,1337 \text{ vwind10m} + 0,0948 \text{ wind_gust_1}$ $+ 0,0045 \text{ wind_gust_2}$

Sedangkan nilai RMSEP temperatur maksimum, temperatur minimum, dan kelembaban pada stasiun Pattimura ditampilkan pada Tabel 4.9. Jumlah komponen optimal stasiun meteorologi Pattimura untuk temperatur maksimum, temperatur minimum, dan kelembaban masing-masing yaitu, 13, 14, dan 15 komponen. Kom-

ponen optimal yang terpilih digunakan sebagai variabel prediktor pada pemodelan regresi yang dilakukan secara univariat.

Tabel 4.9 RMSEP Tmaks, Tmin, dan RH Stasiun Pattimura

Banyak Komp	Tmaks	Tmin	RH	Banyak Komp	Tmaks	Tmin	RH
1	0,6966	0,7588	0,7812	9	0,5702	0,6771	0,7178
2	0,6061	0,7228	0,7449	10	0,5697	0,6755	0,7129
3	0,5840	0,7206	0,7296	11	0,5682	0,6742	0,7140
4	0,5777	0,7082	0,7232	12	0,5683	0,6759	0,7144
5	0,5757	0,7150	0,7310	13	0,5651*	0,6729	0,7142
6	0,5726	0,7127	0,7361	14	0,5666	0,6715*	0,7135
7	0,5715	0,710	0,7328	15	0,5653	0,6764	0,7113*
8	0,5742	0,6907	0,7280	16	0,5722	0,6752	0,7669

Ket : * nilai RMSEP terkecil

Diperoleh persamaan regresi PLS temperatur maksimum, temperatur minimum, dan kelembaban stasiun Pattimura yang ditampilkan pada Tabel 4.10.

Tabel 4.10 Model Prediksi PLSR Tmaks, Tmin, dan RH Stasiun Pattimura

$\hat{y}_{T_{maks}} = 0,108 \text{ dew2m} + 0,063 \text{ hi_cloud} - 0,13 \text{ hujan_total} - 0,1194 \text{ low_cloud} + 0,027 \text{ mid_cloud} + 0,5054 \text{ mslp} - 0,006 \text{ rhum2m} - 0,133 \text{ shum2m} - 0,7305 \text{ sur_press} - 0,2608 \text{ sur_vis_1} - 0,106 \text{ sur_vis_2} - 0,4592 \text{ temp2m} + 0,0596 \text{ tot_cloud} - 0,148 \text{ uwind10m} + 0,242 \text{ vwind10m} + 0,2878 \text{ wind_gust}$
$\hat{y}_{T_{min}} = -0,418 \text{ dew2m} + 0,132 \text{ hi_cloud} + 0,169 \text{ hujan_total} + 0,075 \text{ low_cloud} - 0,18 \text{ mid_cloud} - 0,884 \text{ mslp} + 0,6959 \text{ rhum2m} - 0,4160 \text{ shum2m} + 1,046 \text{ sur_press} + 0,0958 \text{ sur_vis_1} + 0,055 \text{ sur_vis_2} + 0,4536 \text{ temp2m} - 0,0601 \text{ tot_cloud} + 0,044 \text{ uwind10m} + 0,1528 \text{ vwind10m} - 0,1232 \text{ wind_gust}$
$\hat{y}_{RH} = -2,346 \text{ dew2m} + 0,135 \text{ hi_cloud} + 0,032 \text{ hujan_total} + 0,1244 \text{ low_cloud} - 0,02511 \text{ mid_cloud} - 0,9549 \text{ mslp} - 0,0499 \text{ rhum2m} + 2,2464 \text{ shum2m} + 1,3809 \text{ sur_press} + 0,1297 \text{ sur_vis_1} + 0,0538 \text{ sur_vis_2} + 0,2925 \text{ temp2m} - 0,2518 \text{ tot_cloud} + 0,3845 \text{ uwind10m} - 0,2267 \text{ vwind10m} + 0,0861 \text{ wind_gust}$

4.1.5 Pemodelan Prediksi dengan *Stepwise Regression*

Stepwise regression merupakan salah satu metode pendekatan dalam pembentukan model MOS, dengan memodelkan variabel prediktor berdasarkan model terbaik pada masing-masing variabel respon. Model terbaik diperoleh dengan menyeleksi variabel prediktor yang mengkombinasikan metode *forward selection* dan *backward elimination*. Pemilihan metode terbaik didasarkan pada model yang memiliki nilai AIC terkecil. Dengan menggunakan program pada Lampiran 18, didapatkan nilai AIC untuk ketiga unsur cuaca pada stasiun Hasanuddin ditunjukkan pada Tabel 4.11.

Tabel 4.11 Nilai AIC Tmaks, Tmin, dan RH Stasiun Hasanuddin

Banyak Komp.	Tmaks	Tmin	RH
20	-435,75	-305,14	-591,73
19	-437,74	-307,14	-593,73
18	-439,72	-309,14	-595,73
17	-441,63	-311,13	-597,63
16	-443,42	-313,08	-599,56
15	-445,3	-315,02	-601,07
14	-447,1	-316,67	-602,1
13	-449	-318,17	-603,16
12	-449,78	-318,26*	-604,15
11	-450,11*		-606,01
10			-606,37*

Ket : * nilai AIC terkecil

Jumlah variabel prediktor yang digunakan dalam pembentukan model terbaik untuk temperatur maksimum, temperatur minimum, dan kelembaban pada stasiun Hasanuddin berturut-turut yaitu 11, 12, dan 10 variabel. Variabel prediktor tersebut diregresikan dengan variabel respon secara univariat dan diperoleh persamaan regresi untuk stasiun Hasanuddin yang ditampilkan pada Tabel 4.12.

Tabel 4.12 Model Prediksi *Stepwise Regression* Tmaks, Tmin, dan RH Stasiun Hasanuddin

$\hat{y}_{T_{maks}} = 2,1961 \text{ dew2m} + 0,067 \text{ low_cloud_1} + 0,0993 \text{ mid_cloud}$ - 2,0135 shum2m - 0,1047 sur_press + 0,1015 sur_vis_1 + 0,3093 temp2m_1 - 0,1787 temp2m_2 + 0,5612 uwind10m + 0,1263 vwind10m + 0,15423 wind_gust_1
$\hat{y}_{T_{min}} = 2,923 \text{ dew2m} + 1,7969 \text{ hi_cloud} + 0,0937 \text{ hujan_total}$ + 0,2689 low_cloud_1 + 1,2358 mid_cloud - 1,1782 mslp + 0,6089 rhum2m - 4,0445 shum2m + 1,0992 sur_press - 2,8849 tot_cloud - 0,3053 uwind10m + 0,1263 wind_gust_2
$\hat{y}_{RH} = -3,1358 \text{ dew2m} + 0,6384 \text{ rhum2m} + 2,0529 \text{ shum2m}$ + 0,1,522 sur_press - 0,2035 temp2m_1 + 0,2,388 temp2m_2 - 0,0692 tot_cloud - 0,2738 uwind10m - 0,1296 vwind10m + 0,1145 wind_gust_1

Sedangkan nilai AIC untuk temperatur maksimum, temperatur minimum, dan kelembaban pada stasiun Pattimura ditunjukkan pada Tabel 4.13.

Tabel 4.13 Nilai AIC Tmaks, Tmin, dan RH Stasiun Pattimura

Jum. Var	Tmaks	Tmin	RH
16	-404,56	-274,99	-245,24
15	-406,5	-276,93	-247,13
14	-408,35	-278,64	-248,96
13	-410,13*	-279,94*	-250,7
12			-250,95*

Ket : * nilai AIC terkecil

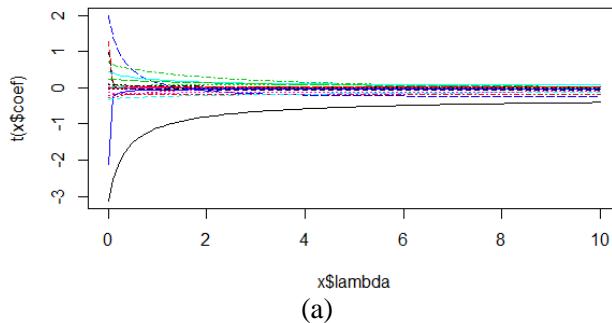
Untuk variabel respon temperatur maksimum, temperatur minimum, dan kelembaban didapatkan model terbaik dengan menggunakan variabel prediktor berturut-turut yaitu 13, 13, dan 12 variabel dalam pemodelan regresi stepwise, maka diperoleh persamaan regresi untuk stasiun Pattimura ditampilkan pada Tabel 4.14.

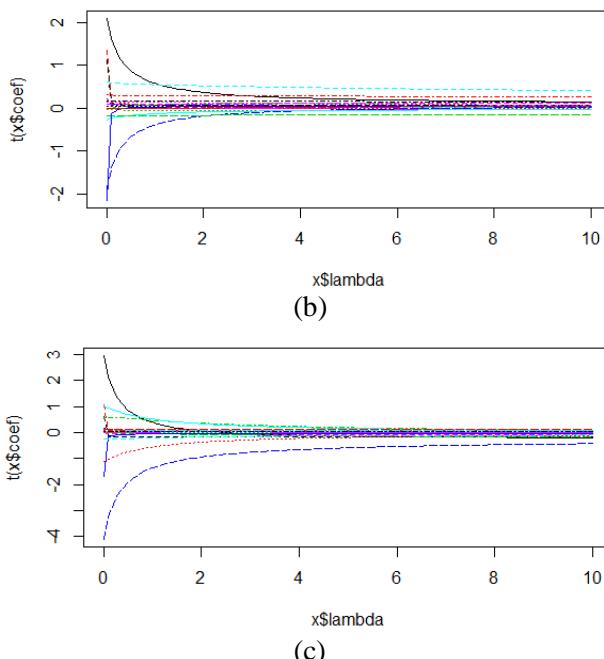
Tabel 4.14 Model Prediksi *Stepwise Regression* Tmaks, Tmin, dan RH Stasiun Pattimura

$\hat{y}_{T_{max}} = 1,553 \text{ dew2m} - 0,1338 \text{ hujan_total} - 0,1169 \text{ low_cloud}$ $+ 0,4607 \text{ mslp} - 1,6233 \text{ shum2m} - 0,7471 \text{ sur_press}$ $- 0,2471 \text{ sur_vis_1} - 0,1076 \text{ sur_vis_2} - 0,4443 \text{ temp2m}$ $+ 0,1549 \text{ tot_cloud} - 0,1944 \text{ uwind10m} + 0,2058 \text{ vwind10m}$ $+ 0,296 \text{ wind_gust}$
$\hat{y}_{T_{min}} = 0,3276 \text{ hi_cloud} + 0,1756 \text{ hujan_total} + 0,1262 \text{ low_cloud}$ $- 0,9345 \text{ mslp} + 0,6892 \text{ rhum2m} - 0,8444 \text{ shum2m}$ $+ 1,076 \text{ sur_press} + 0,09561 \text{ sur_vis_1} + 0,05603 \text{ sur_vis_2}$ $+ 0,4495 \text{ temp2m} - 0,4123 \text{ tot_cloud} + 0,1238 \text{ vwind10m}$ $- 0,125 \text{ wind_gust}$
$\hat{y}_{RH} = - 2,523 \text{ dew2m} + 0,1472 \text{ hi_cloud} + 0,1033 \text{ low_cloud}$ $- 0,8986 \text{ mslp} + 2,3862 \text{ shum2m} + 1,3262 \text{ sur_press}$ $+ 0,117 \text{ sur_vis_1} + 0,3462 \text{ temp2m} - 0,2814 \text{ tot_cloud}$ $+ 0,3971 \text{ uwind10m} - 0,2334 \text{ vwind10m} + 0,0955 \text{ wind_gust}$

4.1.6 Pemodelan Prediksi dengan *Ridge Regression*

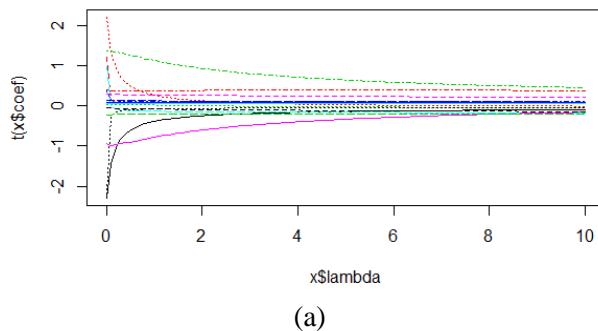
Pemodelan *ridge regression* dilakukan dengan menggunakan konstanta λ . Beberapa cara yang dilakukan dalam penentuan nilai λ , salah satunya yaitu dengan menggunakan plot *ridge trace* yang didasarkan pada konvergensi koefisien regresi ridge. Penentuan nilai λ menggunakan plot *ridge trace* masing-masing variabel respon untuk stasiun Hasanuddin ditunjukkan oleh Gambar 4.2.

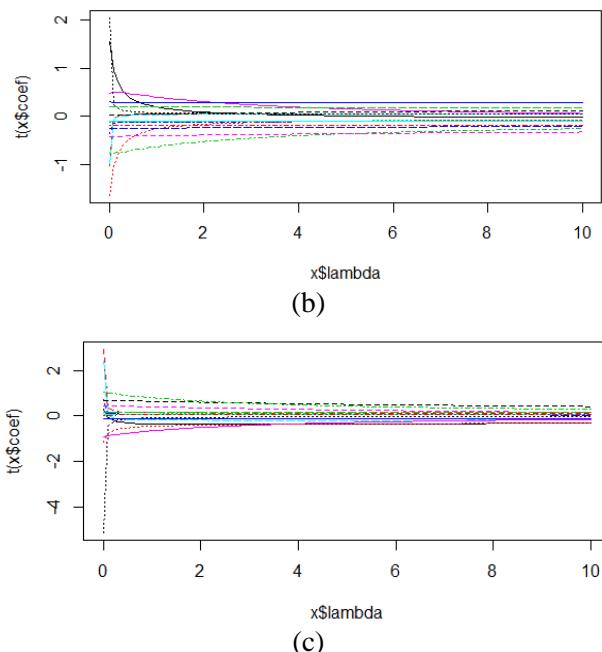




Gambar 4.2 Konvergensi Koefisien Regresi Ridge Stasiun Meteorologi Hasanuddin (a) Tmaks, (b) Tmin, (c) RH

Untuk plot *ridge* trace stasiun Pattimura masing-masing variabel respon ditunjukkan oleh Gambar 4.3.





Gambar 4.3 Konvergensi Koefisien Regresi Ridge Stasiun Pattimura
 (a) Tmaks, (b) Tmin, (c) RH

Berdasarkan Gambar 4.2 dan Gambar 4.3 penentuan nilai konstanta λ juga subjektif, plot temperatur maksimum, menunjukkan garis hitam paling bawah menyebabkan konstanta λ tidak kovergen hingga melebihi 10. Sehingga pemilihan nilai konstanta λ menggunakan *Generalize Cross Validation* (GCV) yang didasarkan pada nilai minimum GCV. Dengan menggunakan program pada Lampiran 19, didapatkan nilai konstanta λ optimum temperatur maksimum, tempe-ratur minimum, dan kelembaban untuk kedua stasiun meteorologi ditunjukkan oleh Tabel 4.15.

Dengan nilai konstanta λ pada Tabel 4.15, dilakukan pemodelan regresi ridge untuk masing-masing variabel respon pada setiap stasiun meteorologi.

Tabel 4.15 Nilai Konstanta λ Optimum Tmaks, Tmin, dan RH Stasiun Hasanuddin dan Pattimura

Variabel Respon	Nilai λ	
	Hasanuddin	Pattimura
Tmaks	0,09	0,18
Tmin	0,05	0,61
RH	0,04	0,18

Diperoleh persamaan regresi temperatur maksimum, temperatur minimum, dan kelembaban untuk stasiun meteorologi Hasanuddin seperti pada Tabel 4.16.

Tabel 4.16 Model Prediksi *Ridge Regression* Tmaks, Tmin, dan RH Stasiun Hasanuddin

$\hat{y}_{T_{maks}} = 1,649 \text{ dew2m} + 0,131 \text{ hi_cloud} - 0,036 \text{ hujan_total} + 0,079 \text{ low_cloud_1} - 0,001 \text{ low_cloud_2} - 0,008 \text{ low_cloud_3} + 0,147 \text{ mid_cloud} + 0,146 \text{ mslp} - 0,005 \text{ rhum2m} - 1,445 \text{ shum2m} - 0,241 \text{ sur_press} + 0,091 \text{ sur_vis_1} + 0,040 \text{ sur_vis_2} + 0,304 \text{ temp2m_1} - 0,182 \text{ temp2m_2} - 0,153 \text{ tot_cloud} + 0,589 \text{ uwind10m} + 0,139 \text{ vwind10m} + 0,172 \text{ wind_gust_1} - 0,012 \text{ wind_gust_2}$
$\hat{y}_{T_{\min}} = -0,160 \text{ dew2m} + 0,068 \text{ hi_cloud} - 0,014 \text{ hujan_total} + 0,026 \text{ low_cloud_1} + 0,073 \text{ low_cloud_2} - 0,020 \text{ low_cloud_3} - 0,177 \text{ mid_cloud} - 0,159 \text{ mslp} + 0,160 \text{ rhum2m} - 0,534 \text{ shum2m} + 0,137 \text{ sur_press} - 0,071 \text{ sur_vis_1} + 0,0392 \text{ sur_vis_2} + 0,038 \text{ temp2m_1} - 0,140 \text{ temp2m_2} - 0,049 \text{ tot_cloud} - 0,121 \text{ uwind10m} + 0,054 \text{ vwind10m} + 0,042 \text{ wind_gust_1} + 0,122 \text{ wind_gust_2}$
$\hat{y}_{RH} = -0,525 \text{ dew2m} + 0,004 \text{ hi_cloud} + 0,080 \text{ hujan_total} - 0,016 \text{ low_cloud_1} + 0,022 \text{ low_cloud_2} + 0,0114 \text{ low_cloud_3} - 0,051 \text{ mid_cloud} + 0,014 \text{ mslp} + 0,114 \text{ rhum2m} - 0,214 \text{ shum2m} + 0,010 \text{ sur_press} - 0,028 \text{ sur_vis_1} - 0,010 \text{ sur_vis_2} - 0,187 \text{ temp2m_1} + 0,075 \text{ temp2m_2} - 0,034 \text{ tot_cloud} - 0,160 \text{ uwind10m} - 0,118 \text{ vwind10m} + 0,026 \text{ wind_gust_1} + 0,031 \text{ wind_gust_2}$

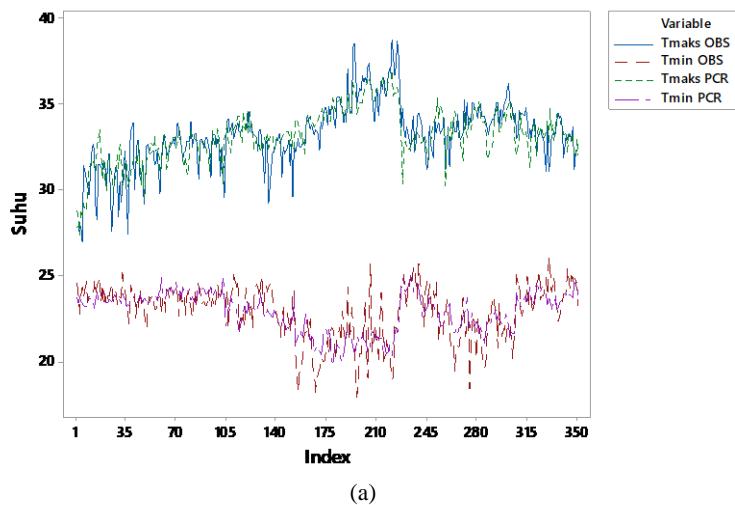
Sedangkan persamaan regresi temperatur maksimum, temperatur minimum, dan kelembaban untuk stasiun meteorologi Pattimura ditampilkan pada Tabel 4.17.

Tabel 4.17 Model Prediksi *Ridge Regression* Tmaks, Tmin, dan RH Stasiun Pattimura

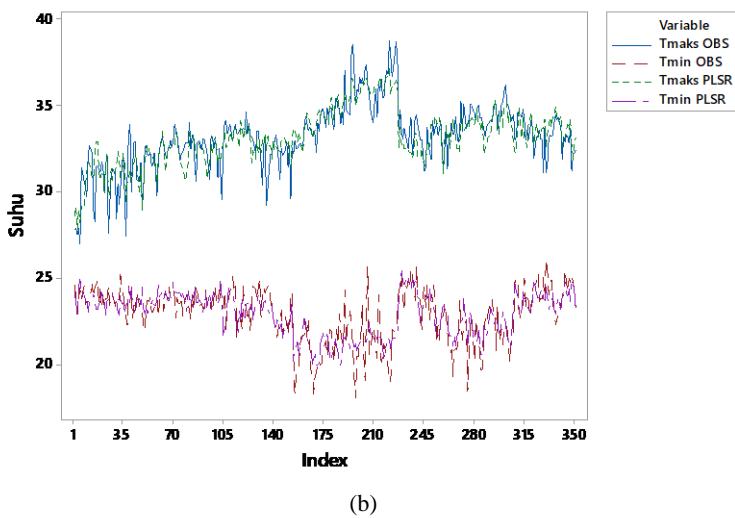
$\hat{y}_{T_{\text{maks}}} = 0,708 \text{ dew2m} + 0,004 \text{ hi_cloud} - 0,133 \text{ hujan_total} - 0,127 \text{ low_cloud} - 0,021 \text{ mid_cloud} + 0,499 \text{ mslp} + 0,030 \text{ rhum2m} - 0,781 \text{ shum2m} - 0,752 \text{ sur_press} - 0,251 \text{ sur_vis_1} - 0,107 \text{ sur_vis_2} - 0,416 \text{ temp2m} + 0,161 \text{ tot_cloud} - 0,185 \text{ uwind10m} + 0,294 \text{ vwind10m} + 0,199 \text{ wind_gust}$
$\hat{y}_{T_{\text{min}}} = -0,319 \text{ dew2m} + 0,161 \text{ hi_cloud} + 0,151 \text{ hujan_total} + 0,083 \text{ low_cloud} - 0,160 \text{ mid_cloud} - 0,727 \text{ mslp} + 0,663 \text{ rhum2m} - 0,495 \text{ shum2m} + 0,879 \text{ sur_press} + 0,087 \text{ sur_vis_1} + 0,053 \text{ sur_vis_2} + 0,421 \text{ temp2m} - 0,106 \text{ tot_cloud} + 0,049 \text{ uwind10m} + 0,157 \text{ vwind10m} - 0,123 \text{ wind_gust}$
$\hat{y}_{RH} = -1,111 \text{ dew2m} + 0,102 \text{ hi_cloud} + 0,036 \text{ hujan_total} + 0,123 \text{ low_cloud} - 0,072 \text{ mid_cloud} - 0,972 \text{ mslp} - 0,063 \text{ rhum2m} + 0,992 \text{ shum2m} + 1,345 \text{ sur_press} + 0,129 \text{ sur_vis_1} + 0,055 \text{ sur_vis_2} + 0,282 \text{ temp2m} - 0,178 \text{ tot_cloud} + 0,375 \text{ uwind10m} - 0,220 \text{ vwind10m} + 0,088 \text{ wind_gust}$

Model prediksi *ensemble member* masih dalam bentuk PC, sehingga respon dugaan model regresi harus dikembalikan ke bentuk awal dengan mengalikan dengan standar deviasi, kemudian menjumlahkan dengan rata-rata dari observasi. Nilai prediksi temperatur maksimum, temperatur minimum, dan kelembaban model regresi dari masing-masing *ensemble member* untuk stasiun Hasanuddin diberikan pada Lampiran 4,5,6. Sedangkan Nilai prediksi untuk stasiun Pattimura diberikan pada Lampiran 7,8,9.

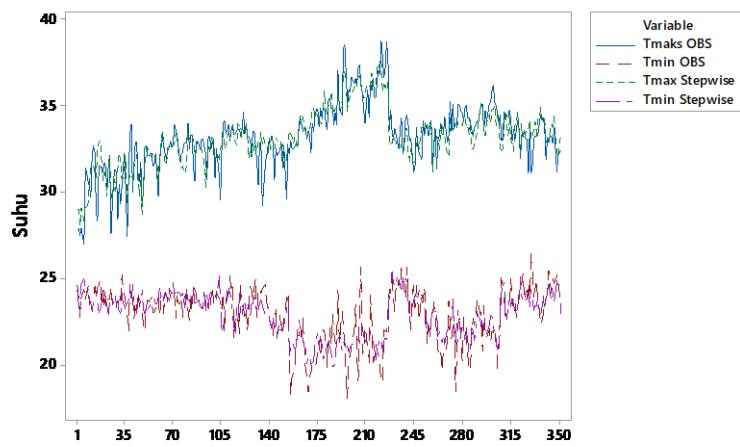
Hasil prediksi MOS yang diperoleh dibandingkan dengan data observasi untuk melihat pola data prediksi. Pola data yang diilustrasikan merupakan perbandingan antara data observasi dengan hasil prediksi MOS temperatur maksimum, temperatur minimum, serta kelembaban pada stasiun meteorologi Hasanuddin (Gambar 4.4 dan 4.5).



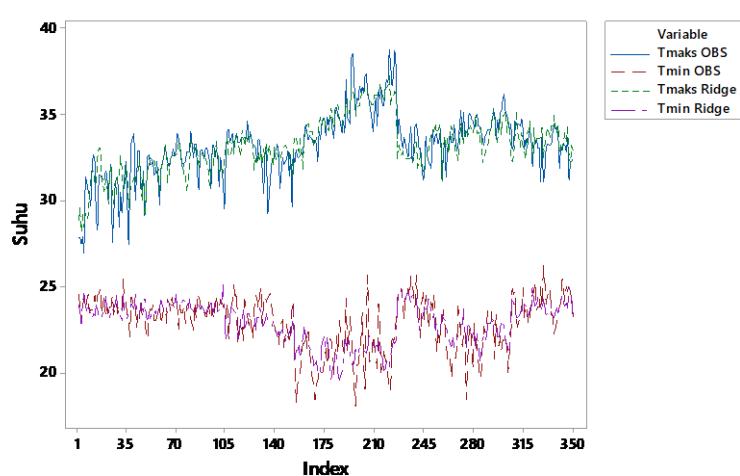
(a)



(b)

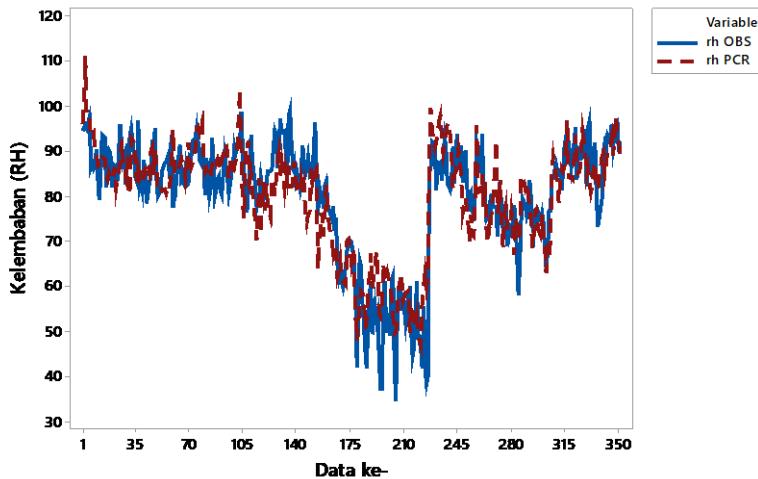


(c)

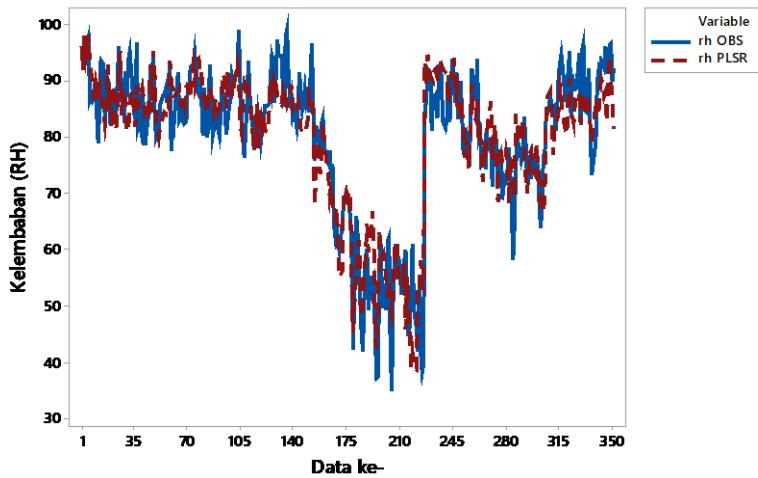


(d)

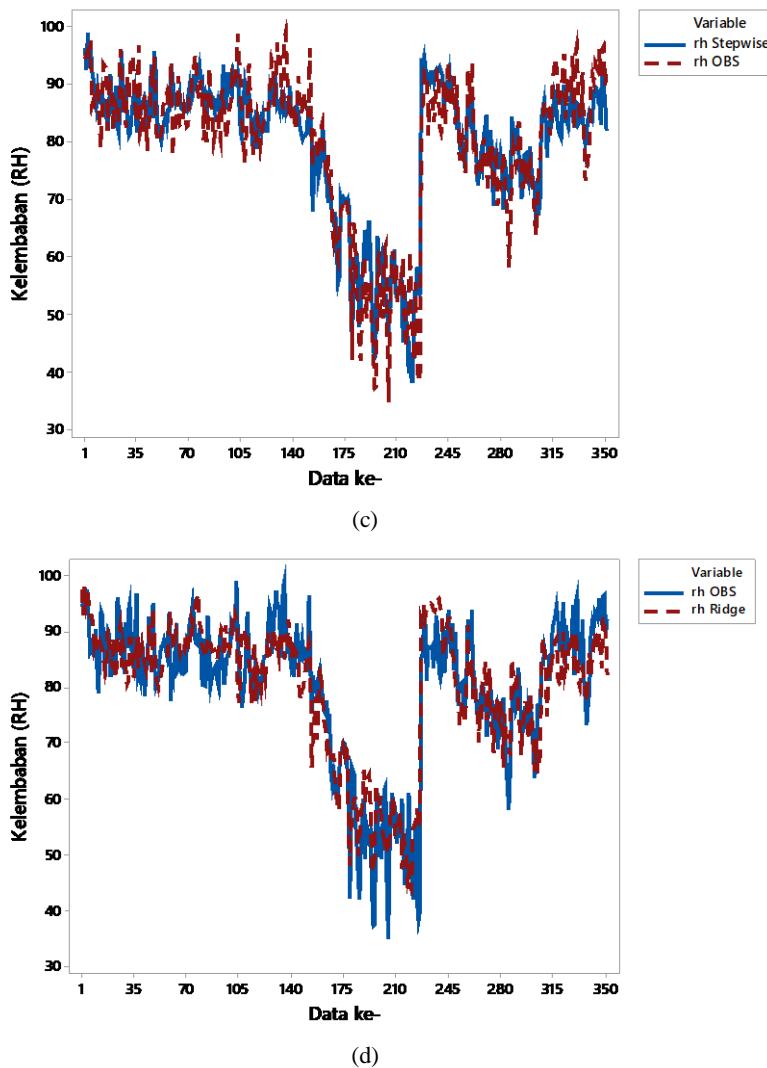
Gambar 4.4 Perbandingan Data Observasi dengan Hasil Prediksi MOS Tmaks dan Tmin Stasiun Hasanuddin (a)PCR, (b)PLSR, (c)Stepwise, dan (d) Ridge



(a)

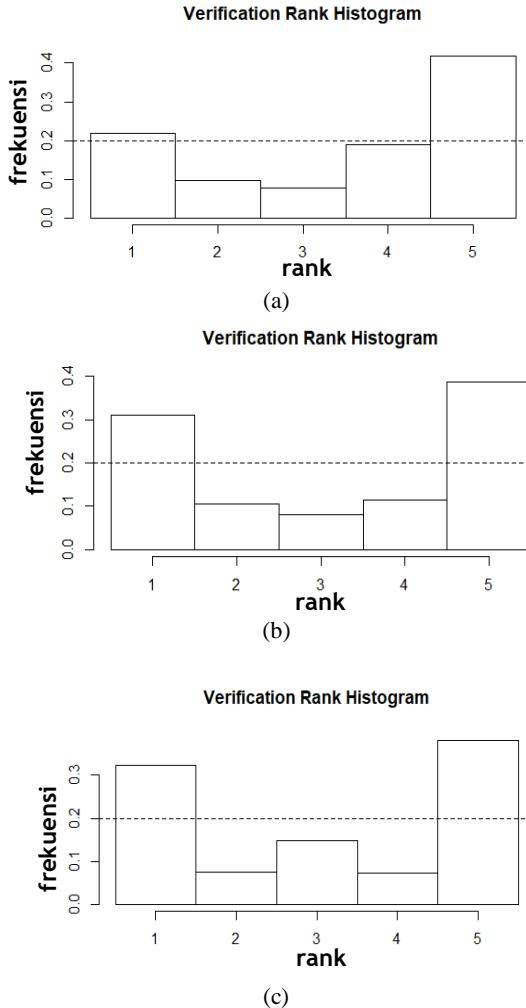


(b)



Gambar 4.5 Perbandingan Data Observasi dengan Hasil Prediksi MOS RH Stasiun Hasanuddin (a)PCR, (b)PLSR, (c)Stepwise, dan (d)Ridge

Berdasarkan Gambar 4.4 dan 4.5, dapat dilihat bahwa pola data hasil prediksi setiap *ensemble member* mampu menangkap pola data observasi, namun masih menghasilkan bias yang cukup besar.



Gambar 4.6 Verifikasi Rank Histogram Hasil Prediksi MOS Stasiun Hasanuddin (a)T_{maks}, (b)T_{min}, dan (c)RH

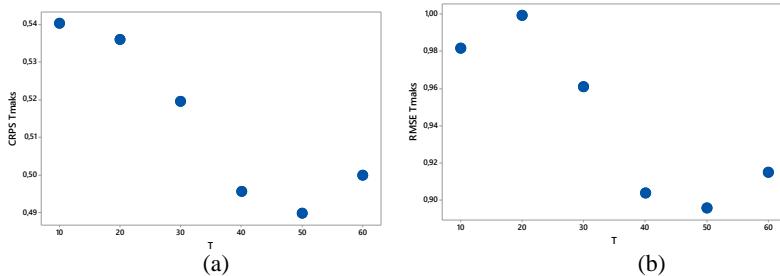
Pengukuran kalibrasi untuk sistem prediksi *ensemble* dapat dilihat dari hasil *verifikasi rank histogram* untuk prediksi *ensemble* temperatur maksimum, temperatur minimum, dan kelembaban di stasiun Pattimura (Gambar 4.6) menunjukkan bahwa VRH tidak uniform dan cenderung berbentuk U. Hal ini mengindikasikan adanya underdispersi. Oleh karena itu, dilakukan sistem prediksi *ensemble* dari keempat model MOS dengan menggunakan metode prediksi *ensemble* terkalibrasi yang dapat mengoreksi bias dan *underdispersive* yaitu *Ensemble Model Output Statistics* (EMOS).

4.2 Pemodelan *Ensemble Model Output Statistics*

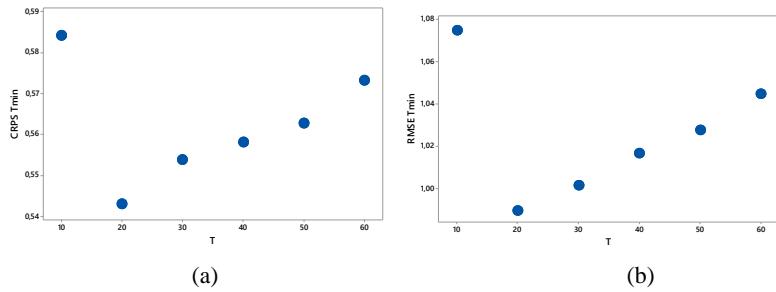
Hasil prediksi EMOS berupa taksiran interval yang diperoleh dari distribusi prediktif. Dalam penelitian ini, pemodelan EMOS menggunakan pendekatan distribusi normal. EMOS menghasilkan prediksi dengan model yang berbeda setiap harinya, dikarenakan EMOS menghasilkan model dengan periode geser. Oleh karena itu, model yang dihasilkan pada hari *testing* tertentu tidak bisa digunakan untuk hari testing lainnya. Langkah pertama pemodelan EMOS yaitu menentukan panjang *training* optimal yang digunakan untuk mengestimasi koefisien regresi dan parameter varians EMOS. Ilustrasi penggunaan *training* (m) yaitu 10 hari ditampilkan pada Lampiran 10. Penggunaan *training* 10 dalam pemodelan EMOS artinya yaitu 10 observasi pertama (m_1) digunakan untuk memodelkan satu hari setelahnya dan mengestimasi parameter distribusinya ($f_{i,j}$), begitupun untuk hari selanjutnya.

4.2.1 Penentuan Panjang Periode Training Optimal

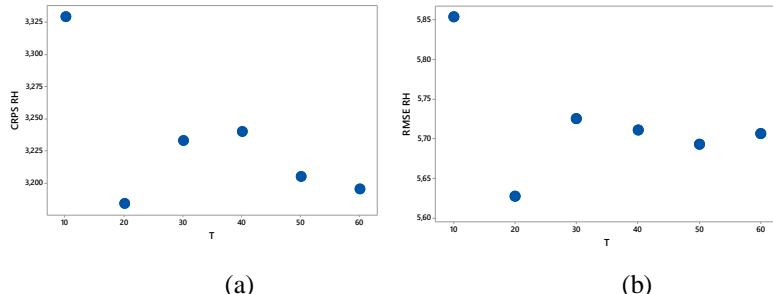
Pemodelan EMOS dalam penelitian ini akan mempertimbangkan beberapa panjang *training* (m) yaitu 10, 20, 30, 40, 50, 60 hari. Pemilihan panjang periode *training* optimal didasarkan pada kriteria nilai RMSE yaitu memilih nilai terkecil dan CRPS yaitu memilih nilai terkecil hingga mendekati 0 yang ditampilkan pada Lampiran 11 dan Lampiran 12. Perbandingan panjang periode *training* temperatur maksimum, temperatur minimum, dan kelembaban stasiun meteorologi Hasanuddin (Gambar 4.7, 4.8, dan 4.9) sebagai berikut.



Gambar 4.7 Perbandingan Panjang Periode Training Tmaks Stasiun Hasanuddin (a) CRPS dan (b) RMSE

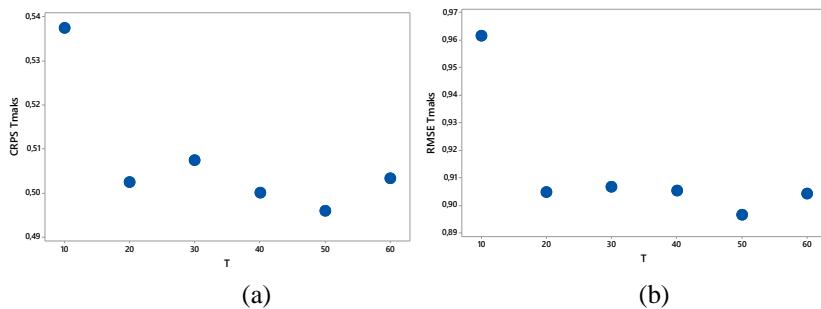


Gambar 4.8 Perbandingan Panjang Periode Training Tmin Stasiun Hasanuddin (a) CRPS dan (b) RMSE

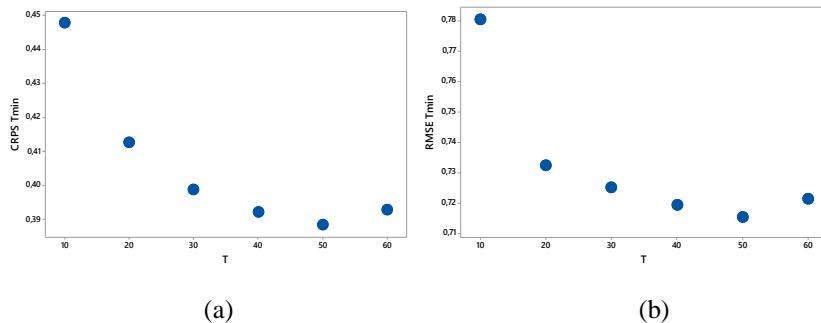


Gambar 4.9 Perbandingan Panjang Periode Training RH Stasiun Hasanuddin (a) CRPS dan (b) RMSE

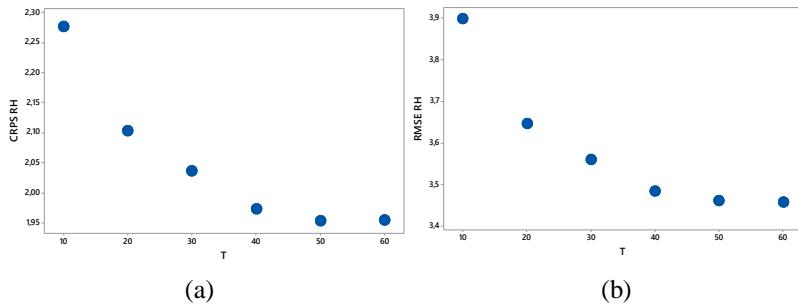
Dari perbandingan tersebut didapatkan panjang periode *training* optimal untuk temperatur maksimum, temperatur minimum, dan kelembaban pada stasiun meteorologi Hasanuddin berturut-turut yaitu 40, 20, dan 20 hari. Karena data pengamatan yang digunakan pada stasiun meteorologi Hasanuddin yaitu 351 hari, maka data *testing* untuk temperatur maksimum adalah 311 hari. Sedangkan data *testing* untuk temperatur minimum dan kelembaban yaitu 331 hari. Perbandingan panjang periode *training* temperatur maksimum, temperatur minimum, dan kelembaban stasiun meteorologi Pattimura (Gambar 4.10, 4.11, dan 4.12) adalah sebagai berikut.



Gambar 4.10 Perbandingan Panjang Periode Training Tmaks Stasiun Pattimura
(a) CRPS dan (b) RMSE



Gambar 4.11 Perbandingan Panjang Periode Training Tmin Stasiun Pattimura
(a) CRPS dan (b) RMSE



Gambar 4.12 Perbandingan Panjang Periode Training RH Stasiun Pattimura
 (a) CRPS dan (b) RMSE

Panjang periode *training* optimal untuk temperatur maksimum yaitu 20 hari, dikarenakan Gambar 4.8 menunjukkan bahwa terjadi penurunan yang sangat tajam dari *training* 10 ke *training* 20. Hal tersebut menunjukkan bahwa *training* 20 lebih baik digunakan dalam pemodelan EMOS karena akan menghasilkan prediksi dengan bias yang kecil. Sedangkan *training* 30 hingga 60 memiliki selisih yang kecil. Sedangkan untuk temperatur minimum dan kelembaban didapatkan panjang periode *training* optimal 40 hari. Data pengamatan pada stasiun meteorologi Pattimura yaitu 353 hari, maka data *testing* untuk temperatur maksimum adalah 333 hari. Sedangkan data *testing* untuk temperatur minimum dan kelembaban yaitu 313 hari.

4.2.2 Kalibrasi Prediksi Ensemble menggunakan EMOS

Telah dijelaskan pada sub bab 2.5 bahwa model EMOS di dasarkan pada regresi linier berganda yaitu meregresikan hasil prediksi MOS sebagai *ensemble member* dengan nilai observasi secara univariat. Pemodelan EMOS dengan menggunakan *training* optimal pada tiap variabel respon di masing-masing stasiun pengamatan didapatkan koefisien parameter (a , b_1 , b_2 , b_3 , b_4) dan koefisien varians (c dan d) untuk tiap harinya.

Dengan menggunakan program pada Lampiran 20, diperoleh koefisien parameter stasiun Hasanuddin pada masing-masing variabel respon yang ditampilkan pada Tabel 4.18,4.19, dan 4.20.

Tabel 4.18 Koefisien Parameter EMOS Tmaks Stasiun Hasanuddin

Testing ke-	a	b1	b2	b3	b4	c	d
1	5.8515	4,93E-08	0,6222	0,1773	4,86E-08	2,3609	4,58E-05
2	7,2331	6,44E-10	0,3884	0,3670	9,44E-11	2,3246	2,95E-08
3	8,7489	2,61E-11	0,5395	0,1687	1,52E-09	2,2366	2,65E-06
4	10,749	4,12E-10	0,3033	0,3431	2,00E-11	2,2818	3,83E-06
.
.
309	7,3315	1,22E-08	0,7635	0,0080	0,00125	0,3246	2,32334
310	5,9217	3,99E-05	0,7528	0,0199	0,04136	0,2496	2,86566
311	4,9813	0,00032	0,8378	0,0002	0,0022	0,2593	2,28377

Tabel 4.19 Koefisien Parameter EMOS Tmin Stasiun Hasanuddin

Testing ke-	a	b1	b2	b3	b4	c	d
1	16,987	3,56E-11	1,82E-10	1,24E-08	0,29667	0,3074	1,24E-07
2	18,300	9,15E-10	1,73E-09	3,04E-08	0,23943	0,2794	1,81E-06
3	18,252	7,55E-08	1,72E-06	0,00011	0,23995	0,3158	5,54E-07
4	23,286	1,56E-09	5,30E-06	0,02867	0,00004	0,2725	2,13E-07
.
.
329	-5,132	7,70E-09	0,06670	1,16545	0,00260	0,6574	0,07326
330	-3,244	1,64E-08	2,22E-05	1,15440	6,09E-15	0,6609	0,71134
331	-0,290	2,92E-07	0,30230	0,72312	2,72E-06	0,5675	0,00056

Tabel 4.20 Koefisien Parameter EMOS RH Stasiun Hasanuddin

Testing ke-	a	b1	b2	b3	b4	c	d
1	19,304	0,13849	4,85E-10	0,49903	0,138	15,940	7,64E-10
2	28,473	0,18222	1,44E-08	0,35955	0,132	17,283	4,78E-11
3	28,619	0,12142	2,65E-09	0,25504	0,292	16,416	1,47E-08
4	25,871	0,22378	1,51E-08	0,39210	0,085	16,394	8,40E-09
.
.
329	-24,144	2,99E-08	1,48E-07	0,02104	1,303	9,953	2,8428
330	-16,409	1,56E-06	6,48E-10	0,00045	1,239	15,639	0,2880
331	-13,455	4,44E-08	2,13E-07	3,31E-05	1,202	17,255	0,3549

Sedangkan koefisien parameter pada stasiun meteorologi Pattimura (Tabel 4.18,4.19, dan 4.20) adalah sebagai berikut.

Tabel 4.21 Koefisien Parameter EMOS Tmaks Stasiun Pattimura

Testing ke-	a	b1	b2	b3	b4	c	d
1	-15,197	1,4839	5,65E-10	1,22E-06	6,36E-10	1,1694	1,15E-05
2	-15,714	1,5041	1,63E-06	7,69E-07	5,31E-05	1,0109	3,50E-05
3	-13,505	1,2893	0,02245	0,12173	1,37E-08	0,9595	5,18E-05
4	-10,943	0,7376	0,00026	0,61428	4,16E-08	0,7683	0,00088
.
.
331	7,090	0,1491	1,72E-05	0,64331	5,46E-10	0,7138	0,08262
332	6,947	0,4408	5,93E-06	0,26168	7,88E-10	0,6764	1,41E-16
333	6,963	0,7995	1,25E-10	5,30E-11	7,26E-10	0,6331	0,00612

Tabel 4.22 Koefisien Parameter EMOS Tmin Stasiun Pattimura

Testing ke-	a	b1	b2	b3	b4	c	d
1	-1,553	1,56E-10	4,03E-05	0,0396	1,03448	0,3543	4,4212
2	-3,716	1,30E-12	0,00100	0,0427	1,11963	0,3697	3,8070
3	-4,669	1,33E-08	0,02942	0,0884	1,08395	0,4008	3,2608
4	-5,406	1,52E-10	4,68E-06	0,0022	1,23023	0,4091	3,3858
.
.
311	5,296	0,6495	0,12611	0,0019	7,81E-11	0,2469	0,5411
312	4,434	0,6983	0,11498	0,0001	6,25E-09	0,2591	0,4179
313	7,638	0,6157	0,06572	0,0003	6,42E-11	0,2405	0,2611

Tabel 4.23 Koefisien Parameter EMOS RH Stasiun Pattimura

Testing ke-	a	b1	b2	b3	b4	c	d
1	19,157	1,69E-09	6,25E-08	0,7576	9,91E-08	7,6777	1,96645
2	19,171	5,35E-12	2,88E-07	0,7586	6,64E-06	6,7353	2,18250
3	23,220	3,04E-07	0,00067	0,7101	2,30E-06	7,9899	1,68340
4	16,311	4,91E-11	3,99E-10	0,7966	6,89E-10	8,7191	2,22E-08
.
.
311	10,694	0,14753	0,03830	0,6764	1,32E-06	6,8473	0,47765
312	12,200	0,22102	5,54E-05	0,6223	5,33E-06	7,3270	0,52099
313	13,528	0,16821	0,00260	0,6554	1,61E-05	7,7414	0,01271

Dengan koefisien parameter tersebut didapatkan model distribusi prediktif dari Y berdasarkan persamaan (2.25). Misal model prediktif di hari ke-313 untuk variabel kelembaban (RH) pada stasiun meteorologi Pattimura , maka model pada persamaan (4.1).

$$Y(x_1, x_2, x_3, x_4) \sim N(13,528 + 0,1682x_1 + 0,0026x_2 + 0,6554x_3 + 0,000016x_4, 7,7414 + 0,0127S^2) \quad (4.1)$$

Setelah didapatkan koefisien parameter, maka dapat dihitung nilai parameter terkalibrasi yaitu *mean* dan varians terkalibrasi setiap variabel respon. *Mean* dan varians terkalibrasi untuk temperatur maksimum, temperatur minimum, dan kelembaban pada stasiun meteorologi Hasanuddin ditampilkan pada Tabel 4.24.

Tabel 4.24 *Mean* dan Varians Terkalibrasi Tmaks, Tmin, dan RH Stasiun Hasanuddin

No	Tmaks		No	Tmin		No	RH	
	Mean	Varians		Mean	Varians		Mean	Varians
1	30,386	2,361	1	24,038	0,307	1	83,452	15,940
2	30,982	2,325	2	23,953	0,279	2	88,283	17,283
3	31,239	2,237	3	23,785	0,316	3	83,533	16,416
4	31,521	2,282	4	23,963	0,273	4	83,516	16,394
5	31,088	2,189	5	23,966	0,271	5	88,015	14,904
.
.
.
309	32,091	0,345	329	25,193	0,658	329	96,638	55,299
310	32,805	0,268	330	24,661	0,735	330	93,618	22,607
311	32,833	2,086	331	23,240	0,568	331	85,199	28,061

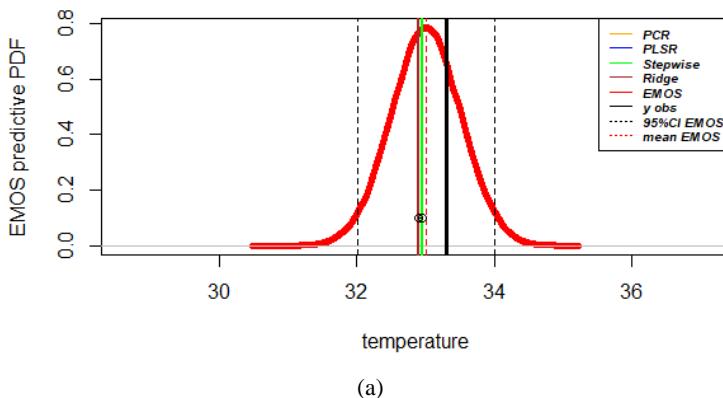
Sedangkan *mean* dan varians terkalibrasi untuk temperatur maksimum, temperatur minimum, dan kelembaban pada stasiun meteorologi Pattimura ditampilkan pada Tabel 4.25. Nilai *mean* terkalibrasi merupakan nilai prediksi EMOS (\hat{Y}_{EMOS}), sehingga *mean* pada Tabel 4.24 dan Tabel 4.25 merupakan nilai prediksi untuk temperatur maksimum, temperatur minimum, dan kelembaban masing-masing stasiun pengamatan.

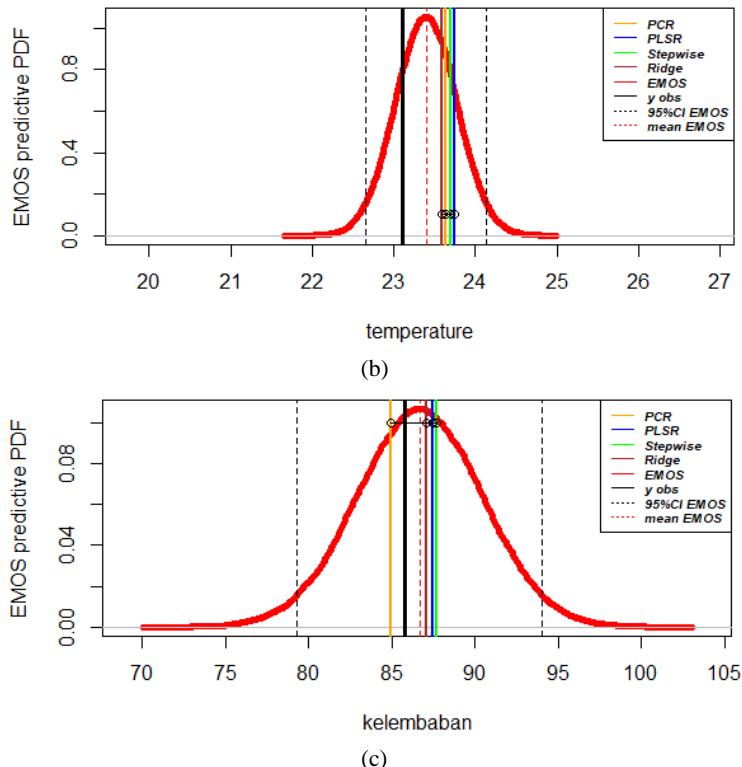
Tabel 4.25 Mean dan Varians Terkalibrasi Tmaks, Tmin, dan RH Stasiun Pattimura

No	Tmaks		No	Tmin		No	RH	
	Mean	Varians		Mean	Varians		Mean	Varians
1	31,257	1,169	1	23,625	0,434	1	79,909	7,849
2	31,730	1,011	2	23,955	0,445	2	78,835	6,802
3	32,412	0,960	3	24,730	0,965	3	79,790	8,393
4	32,799	0,768	4	24,121	0,487	4	81,274	8,719
5	32,837	0,895	5	24,497	0,372	5	81,531	9,358
.
.
.
331	31,861	0,726	311	24,291	0,292	311	85,093	10,086
332	29,270	0,635	312	24,569	0,339	312	83,035	10,427
333	33,061	0,633	313	24,197	0,281	313	81,705	7,780

4.2.3 Taksiran Interval PDF Prediksi Terkalibrasi

Taksiran interval masing-masing variabel respon yaitu nilai batas atas (*upper*) dan batas bawah (*lower*) untuk stasiun ditampilkan pada Lampiran 13, sedangkan stasiun Pattimura ditampilkan pada Lampiran 14. Penaksiran interval terkalibrasi pada tanggal 23 Maret 2015 dilakukan dengan selang kepercayaan 5% menggunakan program pada Lampiran 21. Sehingga diperoleh taksiran interval PDF untuk temperatur maksimum, temperatur minimum, dan kelembaban di stasiun Hasanuddin (Gambar 4.13).





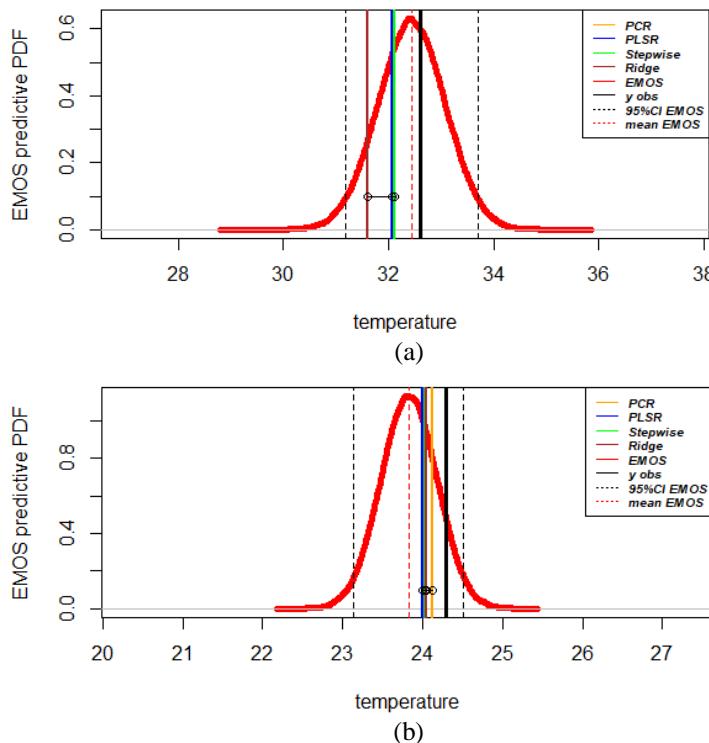
Gambar 4.13 Taksiran Interval Prediksi Teralibrasi di Stasiun Hasanuddin Tanggal 23 Maret 2015 (a)Tmaks, (b)Tmin, dan (c)RH

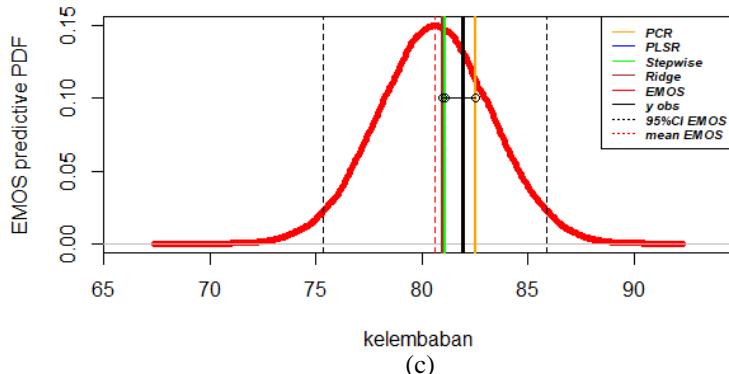
Hasil prediksi PCR, PLSR, regresi stepwise, dan regresi ridge berturut-turut digambarkan oleh garis vertikal berwarna orange, biru, hijau, dan coklat. Kurva merah dan garis putus-putus vertikal merah menunjukkan hasil prediksi EMOS, dan garis vertikal berwarna hitam merupakan data observasi. Sedangkan garis putus-putus merupakan *lower* dan *upper*, serta lingkaran yang terhubung dengan garis merupakan range *ensemble member*.

Terlihat bahwa nilai observasi dan *ensemble member* temperatur maksimum, temperatur minimum, dan kelembaban berada dalam selang kepercayaan 95% EMOS yang mengindikasikan

bahwa EMOS menghasilkan interval yang reliabel, khususnya pada tanggal 23 Maret 2015. Pada temperatur maksimum, temperatur maksimum, hasil prediksi EMOS mampu memperbaiki hasil prediksi keempat *ensemble member*, terlihat dari garis merah yang mendekati nilai observasi. Sedangkan pada kelembaban, prediksi *ensemble member* lebih baik daripada prediksi EMOS.

Taksiran interval prediksi terkalibrasi untuk temperatur maksimum, temperatur minimum, dan kelembaban di stasiun meteorologi Pattimura ditunjukkan pada Gambar 4.14. Sama halnya dengan PDF stasiun meteorologi Hasanuddin, kurva PDF nilai observasi dan *ensemble member* masing-masing variabel respon pada stasiun meteorologi Pattimura berada dalam interval selang kepercayaan 95% EMOS.





Gambar 4.14 Taksiran Interval Prediksi Teralibrasi di Stasiun Pattimura Tanggal 23 Maret 2015 (a)Tmaks, (b)Tmin, dan (c)RH

Hasil prediksi pada temperatur maksimum menunjukkan bahwa prediksi EMOS dapat memperbaiki prediksi *ensemble member*. Sedangkan hasil prediksi temperatur minimum dan kelembaban *ensemble member* menunjukkan hasil prediksi terbaik daripada prediksi EMOS karena garis *ensemble member* yang mendekati nilai observasi.

4.3 Evaluasi Kebaikan Model

Kebaikan model prediksi dapat dievaluasi menggunakan RMSE untuk mengoreksi bias dan CRPS untuk mengevaluasi kalibrasi prediksi. Nilai RMSE EMOS dan masing-masing *ensemble member* berdasarkan kriteria RMSE pada kedua stasiun pengamatan ditampilkan pada Tabel 4.26.

Tabel 4.26 Nilai RMSE PCR, PLSR, Regresi Stepwise, Regresi Ridge, dan EMOS pada Tmaks, Tmin, dan RH

Stasiun	Evaluasi	Tmaks	Tmin	RH
Hasanuddin	RMSE_NWP	11,3636	1,593638	16,65187
	RMSE_PCR	0,995739	1,059019	6,77872
	RMSE_PLSR	0,877335	0,965167*	5,646498
	RMSE_Stepwise	0,868236*	0,967989	5,696879
	RMSE_Ridge	0,875586	1,004364	5,904804
	RMSE_EMOS	0,903792	0,989364	5,628171*

Keterangan : *Hasil prediksi dengan RMSE terkecil

Tabel 4,27 (lanjutan) Nilai RMSE PCR,PLSR, Regresi Stepwise, Regresi Ridge, dan EMOS pada Tmaks, Tmin, dan RH

Stasiun	Evaluasi	Tmaks	Tmin	RH
Pattimura	RMSE_NWP	2,245851	5,191878	5,763283
	RMSE_PCR	0,973324	0,778078	3,866496
	RMSE_PLSR	0,893003	0,692131*	3,396057*
	RMSE_Stepwise	0,889084*	0,692404	3,404981
	RMSE_Ridge	0,960271	0,729728	3,413133
	RMSE_EMOS	0,904680	0,719194	3,483266

Keterangan : *Hasil prediksi dengan RMSE terkecil

Didapatkan bahwa prediksi *ensemble member* menghasilkan nilai bias terkecil dalam memprediksi temperatur maksimum dan minimum pada kedua stasiun pengamatan. Dalam prediksi kelembaban nilai bias terkecil pada stasiun Hasanuddin diperoleh dari prediksi EMOS, sedangkan pada stasiun Pattimura diperoleh dari prediksi *ensemble member* yaitu PLSR. Sehingga, disimpulkan bahwa prediksi dengan bias terkecil yaitu menggunakan *ensemble member*.

Dari perbandingan RMSE dapat dikatakan bahwa EMOS belum cukup signifikan dalam meningkatkan akurasi prediksi cuaca. Untuk koreksi prediksi terkalibrasi didapatkan nilai CRPS temperatur maksimum, temperatur minimum, dan kelembaban pada masing-masing stasiun pengamatan ditampilkan pada Tabel 4.27.

Tabel 4,28 Nilai CRPS *Raw Ensemble* dan EMOS pada Tmaks, Tmin, dan RH

Stasiun	Variabel Respon	CRPS	
		Raw Ensemble	EMOS
Hasanuddin	Tmaks	0,6090	0,5023
	Tmin	0,4726	0,3919
	RH	2,4980	1,9718
Pattimura	Tmaks	0,5922	0,4955
	Tmin	0,6725	0,5430
	RH	4,0330	3,1840

Perbandingan nilai CRPS antara *raw ensemble* dan EMOS di kedua stasiun pengamatan menghasilkan nilai CRPS lebih kecil daripada *raw ensemble*, sehingga dapat disimpulkan bahwa EMOS lebih terkalibrasi dengan baik dari pada *raw ensemble*.

(Halaman ini sengaja dikosongkan)

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil analisis dan pembahasan pada Bab 4 yaitu memprediksi temperatur maksimum, minimum dan kelembaban udara menggunakan EMOS diperoleh kesimpulan sebagai berikut.

1. Model prediksi anggota *ensemble* didapatkan menggunakan metode PCR, PLSR, regresi stepwise, dan regresi ridge, sehingga diperoleh hasil prediksi untuk temperatur maksimum, temperatur minimum dan kelembaban kedua stasiun pengamatan. Hasil prediksi anggota *ensemble* pada stasiun Hasanuddin dan Pattimura dibandingkan dengan data observasi dan diperoleh pola data hasil prediksi setiap *ensemble member* mampu menangkap pola data observasi, namun masih menghasilkan bias yang cukup besar.
2. Pemodelan temperatur maksimum, temperatur minimum dan kelembaban menggunakan EMOS pada stasiun Hasanuddin menggunakan panjang periode *training* berturut-turut yaitu 40, 20, dan 20 periode, sementara pada stasiun Pattimura menggunakan panjang periode *training* berturut-turut sebesar 20,20, dan 40 periode. Sehingga diperoleh model prediksi temperatur maksimum, temperatur minimum, dan kelembaban untuk setiap harinya dengan nilai parameter yang berbeda-beda. Dengan parameter EMOS diperoleh PDF temperatur maksimum, temperatur minimum dan kelembaban pada periode 23 Maret 2015 yang menunjukkan bahwa EMOS dapat memperbaiki hasil prediksi *ensemble member*. PDF stasiun Pattimura menunjukkan bahwa EMOS dapat memperbaiki hasil prediksi *ensemble member* untuk temperatur maksimum. Sedangkan untuk temperatur minimum dan kelembaban, *ensemble member* menunjukkan hasil prediksi terbaik daripada prediksi EMOS.

3. Kebaikan model prediksi jika dilihat dari nilai RMSE, dapat dikatakan bahwa EMOS belum cukup signifikan dalam meningkatkan akurasi prediksi cuaca dibandingkan hasil prediksi model MOS terutama PLSR dan regresi stepwise. Jika dibandingkan dengan prediksi NWP, hasil prediksi EMOS lebih baik dan mampu mengatasi hasil prediksi yang bias. Berdasarkan nilai CRPS antara *raw ensemble* dan EMOS di kedua stasiun pengamatan menghasilkan nilai CRPS lebih kecil daripada *raw ensemble*, sehingga dapat disimpulkan bahwa EMOS lebih terkalibrasi dengan baik dari pada *raw ensemble*.

5.2 Saran

Saran yang dapat diberikan bagi Badan Meteorologi Klimatologi dan Geofisika adalah penggunaan pendekatan statistik, salah satunya yaitu metode EMOS dalam memprediksi cuaca jangka pendek khususnya temperatur maksimum, temperatur minimum, dan kelembaban. Serta, saran bagi penelitian selanjutnya yaitu menambah periode waktu yang lengkap dalam memodelkan *ensemble* MOS untuk meminimalkan potensi prediksi yang kurang akurat.

DAFTAR PUSTAKA

- Anuravega, A., 2013. *Post Processing Peramalan Unsur Cuaca dengan Model Output Statistics (MOS) : Studi Perbandingan Antara Reduksi Dimensi Independent Component Analysis (ICA) dan Principal Component Analysis*, Surabaya: Tugas Akhir, Departemen Statistika, Institut Teknologi Sepuluh Nopember.
- Arpan, F., Kirono, D. G. & Sudjarwadi, 2004. Kajian Meteorologis Hubungan antara Hujan Harian dan Unsur-Unsur Cuaca. *Majalah Geografi Indonesia*, 18(2), pp. 69-79.
- Davis, J. T., 2004. *Bias Removal and Model Consensus Forecast of Maximum and Minimum Temperatures Using the Graphical Forecast Editor*, Tucson, Arizona: National Weather Service Office .
- Demeritt, D. et al., 2007. Ensemble Predictions and Perceptions of Risk, Uncertainly, and Error in Flood Forecasting. *Environmental Hazards*, Volume 7, pp. 115-127.
- Dewi, M. K., 2017. BMKG. [Online] Available at: <http://www.bmkg.go.id/berita/?p=bmkg-himbau-masyarakat-siaga-cuaca-ekstrim-3-hari-ke-depan&lang=ID&s=detil> [Diakses pada 5 Februari 2018].
- Draper, N. & Smith, H., 1992. *Applied Regression Analysis (Analisis Regresi Terapan)*. (Penerjemah : Bambang Sumantri). 2nd ed. Jakarta: PT. Gramedia Pustaka Utama.
- Fachrunisah, 2017. *Kalibrasi Prediksi Suhu dan Kelembapan Jangka Pendek menggunakan Ensemble Model Output Statistics*, Surabaya: Tugas Akhir, Departemen Statistika, Institut Teknologi Sepuluh Nopember.
- Fathurahman, M., 2010. Pemilihan Model Regresi Terbaik menggunakan Akaike's Information Criterion. *Eksponensial*, 1(2), pp. 26-33.

- Froude, L. S., 2010. TIGGE : Comparison of the Prediction of Northern Hemisphere Extratropical Cyclones by Different Ensemble Prediction Systems. *Weather and Forecast*, Volume 25, pp. 819-836.
- Geladi, P. & Kowalski, B. R., 1986. Partial Least-Squares Regression : A Tutorial. *Analytica Chimica Acta*, Volume 185, pp. 1-17.
- Glahn, H. R. & Lowry, D. A., 1972. The Use of Model Output Statistics (MOS) in Objective Weather Forecasting. *J. Appl. Meteor*, Volume 11, pp. 1203-1211.
- Gneiting, T., Raftery, A. E., Westveld, A. H. & Goldman, T., 2005. Calibrated Probabilistic Forecasting Using Ensemble Model Output Statistics and Minimum CRPS Estimation. *Monthly Weather Review*, Volume 133, pp. 1098-1118.
- Guritno, R., 2018. *Jaga Keselamatan Penerbangan, BMKG Selalu Laporkan Keadaan Cuaca*. [Online] Available at: <https://www.harianpapuanews.com.metro-mimika/jaga-keselamatan-penerbangan-bmkg-selalu-laporkan-keadaan-cuaca/> [Diakses pada 4 Maret 2018].
- Haryoko, U., 2014. *Model Prakiraan Cuaca Harian Memanfaatkan Luaran NWP dan Data Pengamatan Stasiun Cuaca*, Bogor: Sekolah Pascasarjana Institut Pertanian Bogor .
- Hersbach, H., 2000. Decomposition of the Continuous Ranked Probability Score for Ensemble Prediction Systems. *Weather and Forecasting*, 15(5), pp. 559-570.
- Hoerl, A. E. & Kennard, R. W., 2010. Ridge Regression : Biased Estimation for Nonorthogonal Problems. *American Statistical Association*, 12(1), pp. 55-67.
- Idowu, O. S. & Rautenbach, C. d., 2008. Model Output Statistics to improve severe storms prediction over Western Sahel. *Atmos. Res*, p. 7.

- Johnson, R. A. & Wichern, D. W., 2010. *Applied Multivariate Statistical Analysis*. 6th ed. New Jersey: Prentice Hall.
- Kurniasari, V. O., 2017. *Model Output Statistics untuk Prakiraan Cuaca Jangka Pendek menggunakan Statistically Inspired Modification of Partial Least Square*, Surabaya: Tugas Akhir, Departemen Statistika, Institut Teknologi Sepuluh Nopember.
- Moller, A., 2014. *Multivariate and Spatial Ensemble Postprocessing Methods*, Jerman: Dissertation. Heidelberg University.
- Narendra, R. D., 2017. *Ensemble Model Output Statistics untuk Prakiraan Cuaca Jangka Pendek*, Surabaya: Tesis. Departemen Statistika. Institut Teknologi Sepuluh Nopember.
- Raftery, A. E., Gneiting, T., Balabdaoui, F. & Polakowski, M., 2005. Using Bayesian Model Averaging to Calibrate Forecast Ensembles. *Monthly Weather Review. AMS*, Volume 133, pp. 1155-1174.
- Raible, C. C., Bischof, G., Flaedrich, K. & Kirk, E., 1998. *Statistical Single-Station Short-Term Forecasting of Temperature and Probability of Precipitation : Area Interpolation and NWP Combination*, Germany: Meteorologisches Institute, Universitat Hamburg.
- Rozumalski, R. A., 2010. *A Nearly Complete Guide to The WRF EMS Version 3*. Boulder: NOAA/NWS National SOO Science and Training Resource Coordinator Forecast Decision Training Branch .
- Safitri, R., 2012. *Model Output Statistics dengan Projection Pursuit Regression untuk Meramalkan Suhu amainimum, Suhu Maksimum, dan Kelembapan*, Surabaya: Tugas Akhir, Departemen Statistika, Institut Teknologi Sepuluh Nopember.
- Shuman, F. G., 1989. History of Numerical Weather Prediction at the National Meteorological Center. *Weather and Forecasting*, Volume 4, pp. 286-296.

- Sijmen, d. J., 1993. SIMPLS: an alternative approach to partial least squares regression. *Chemometrics and Intelligent Laboratory Systems*, pp. 251-263.
- Viney, N. R. et al., 2005. Ensemble Modelling of the Hydrological Impacts of Land Use Change. *German Science Foundation & Collaborative Research Centre*, pp. 2967-2973.
- Widarjono, A., 2007. *Ekonometrika : Teori dan Aplikasi untuk Ekonomi dan Bisnis*. Yogyakarta: Ekonisia Fakultas Ekonomi Universitas Islam Indonesia.
- Wigena, A. H. & Aunuddin, 1998. Metode PLS untuk Mengatasi Kolinearitas dalam Kalibrasi Ganda. *Forum Statistika dan Komputasi*, Volume 3, pp. 17-19.
- Wilks, D. S., 2006. *Statistical Methods in the Atmospheric Sciences*. 2nd ed. Boston: Elsevier.
- Wold, S., Sjostrom, M. & Eriksson, L., 2001. PLS-regression: a basic tool of chemometrics. *Chemometrics and Intelligent Laboratory Systems*, Volume 58, pp. 109-130.

LAMPIRAN

Lampiran 1. Data Observasi (Variabel Respon) Tmaks, Tmin, RH di Stasiun Hasanuddin dan Pattimura

No	Tanggal	Hasanuddin			Pattimura		
		Tmaks	Tmin	RH	Tmaks	Tmin	RH
1	02/01/2015	27.8	24.6	94.5	29.7	24.8	75.4
2	03/01/2015	27.9	23.9	95.2	29.9	25.2	76.6
3	04/01/2015	27.5	22.9	95.8	29	25.3	85.2
4	05/01/2015	27.9	23.9	95.2	30.9	24.2	76.7
5	06/01/2015	26.9	24.3	97.6	30.9	26	78.7
6	07/01/2015	31.4	23.7	86.4	29.7	25	78.5
7	08/01/2015	31.1	24.2	87.4	32	26	75.0
8	09/01/2015	30.6	24.5	86.2	30.6	26	78.3
9	10/01/2015	30.3	23.5	86.7	30.2	25.6	74.7
10	11/01/2015	29.7	23.6	90.5	30.6	25	77.8
11	12/01/2015	32.2	23.6	84.0	33	25.2	81.3
12	13/01/2015	32.7	23.8	78.9	32.8	24.6	79.7
13	14/01/2015	32.3	24.5	84.8	32.9	24	82.6
14	15/01/2015	28.9	23.9	93.6	33.3	24.1	80.3
15	16/01/2015	28.3	24.5	92.8	33.4	24.1	79.9
16	17/01/2015	31.5	24.6	81.9	31.4	24.8	85.7
17	18/01/2015	31.5	24.9	88.3	32.7	23.7	85.3
:	:	:	:	:	:	:	:
346	19/11/2016	32.8	25	96.2	33.5	25.2	78.9
347	20/11/2016	33.7	24.7	91.1	33.3	24.9	88.1
348	21/11/2016	31.2	25.1	96.2	33.6	23.6	79.7
349	22/11/2016	32.2	24.7	96.7	33.1	24.7	81.3
350	23/11/2016	32.3	24.1	89.7	31.7	24.5	81.5
351	10/12/2016	32.4	23.2	92.3	33	24.7	79.7

Lampiran 2. Data NWP model WRF-EMS Stasiun Hasanuddin

No	Tanggal	Dew2m (1)	...	Dew2m (9)	...	Wind_gust(1)	...	Wind_gust(9)
1	02/01/2015	22.6	...	24.7	...	6.93	...	8.69
2	03/01/2015	22.4	...	24.8	...	8.37	...	10.27
3	04/01/2015	22.3	...	24.7	...	6.55	...	8.17
4	05/01/2015	22.5	...	24.6	...	7.85	...	9.03
5	06/01/2015	22.3	...	24.6	...	7.70	...	9.87
6	07/01/2015	22.1	...	24.5	...	7.24	...	9.47
7	08/01/2015	22.3	...	24.7	...	7.62	...	10.25
8	09/01/2015	22.3	...	24.6	...	8.53	...	10.81
9	10/01/2015	21.9	...	24.6	...	6.75	...	8.97
10	11/01/2015	21.8	...	24.1	...	3.39	...	4.63
11	12/01/2015	21.4	...	24.2	...	2.99	...	4.56
12	13/01/2015	21.7	...	24.0	...	3.62	...	4.02
13	14/01/2015	21.6	...	24.1	...	4.93	...	6.01
14	15/01/2015	21.4	...	24.3	...	5.46	...	6.93
15	16/01/2015	21.6	...	24.2	...	2.98	...	2.74
16	17/01/2015	21.1	...	23.7	...	2.66	...	2.27
17	18/01/2015	20.7	...	24.0	...	2.60	...	2.83
:	:	:	:	:	:	:	:	:
343	13/11/2016	22.2	...	24.4	...	2.64	...	4.10
344	17/11/2016	21.2	...	24.8	...	3.57	...	5.91
345	18/11/2016	20.8	...	24.8	...	4.04	...	5.57
346	19/11/2016	21.2	...	25.2	...	3.73	...	6.51
347	20/11/2016	20.4	...	24.8	...	4.23	...	5.97
348	21/11/2016	22.2	...	24.1	...	2.10	...	2.43
349	22/11/2016	22.0	...	24.1	...	3.01	...	2.94
350	23/11/2016	22.0	...	24.0	...	1.86	...	1.85
351	10/12/2016	20.9	...	24.0	...	3.30	...	3.74

Lampiran 3. Data NWP model WRF-EMS Stasiun Paattimura

No	Tanggal	Dew2m (1)	...	Dew2m (9)	...	Wind_gust(1)	...	Wind_gust(9)
1	02/01/2015	23.9	...	24.7	...	7.10	...	8.01
2	03/01/2015	23.9	...	24.8	...	7.18	...	9.64
3	04/01/2015	24.2	...	25.0	...	9.65	...	11.00
4	05/01/2015	24.1	...	24.8	...	9.11	...	9.58
5	06/01/2015	23.9	...	24.6	...	8.68	...	8.75
6	07/01/2015	23.8	...	24.6	...	9.99	...	9.27
7	08/01/2015	23.8	...	24.6	...	10.20	...	10.44
8	09/01/2015	24.1	...	24.8	...	9.95	...	10.97
9	10/01/2015	23.9	...	24.5	...	9.84	...	8.85
10	11/01/2015	24.0	...	24.4	...	9.08	...	7.16
11	12/01/2015	23.8	...	24.2	...	6.52	...	6.12
12	13/01/2015	23.6	...	23.9	...	4.86	...	3.55
13	14/01/2015	24.1	...	24.3	...	6.46	...	4.46
14	15/01/2015	24.0	...	24.4	...	6.29	...	4.65
15	16/01/2015	23.9	...	24.5	...	4.49	...	3.67
16	17/01/2015	23.9	...	24.1	...	2.14	...	1.84
17	18/01/2015	23.9	...	24.0	...	2.63	...	2.76
:	:	:	⋮	⋮	⋮	⋮	⋮	⋮
343	13/11/2016	23.9	...	24.1	...	1.65	...	1.67
344	17/11/2016	24.1	...	25.0	...	4.80	...	4.50
345	18/11/2016	24.2	...	25.1	...	4.30	...	3.65
346	19/11/2016	23.8	...	24.4	...	4.39	...	4.05
347	20/11/2016	23.8	...	23.9	...	3.25	...	3.13
348	21/11/2016	23.6	...	24.2	...	2.93	...	1.92
349	22/11/2016	23.9	...	24.2	...	2.85	...	2.94
350	23/11/2016	24.4	...	25.3	...	3.83	...	4.08
351	10/12/2016	23.6	...	24.0	...	2.13	...	1.93

Lampiran 4. Nilai Prediksi Temperatur Maksimum *Model Output Statistics* di Stasiun Hasanuddin

vdate	PCR	PLSR	Stepwise	Ridge	Obs
20150102	28.8	28.6	29.0	28.8	27.8
20150103	28.4	29.1	29.0	29.4	27.9
20150104	27.3	27.8	28.0	28.2	27.5
20150105	28.9	29.0	29.1	29.0	27.9
20150106	28.5	28.3	28.4	28.5	26.9
20150107	29.2	29.1	29.2	29.2	31.4
20150108	28.8	29.0	29.1	28.9	31.1
20150109	28.8	29.2	29.3	29.1	30.6
20150110	29.9	30.4	30.5	30.3	30.3
20150111	31.2	31.2	31.4	31.2	29.7
20150112	31.8	31.8	31.9	31.8	32.2
20150113	31.8	31.6	31.6	31.7	32.7
20150114	31.3	30.8	30.9	31.0	32.3
20150115	31.1	30.7	30.9	30.9	28.9
20150116	32.5	32.4	32.5	32.5	28.3
20150117	33.1	32.9	32.9	33.1	31.5
20150118	33.3	32.9	33.0	33.1	31.5
20150119	32.2	31.2	31.8	31.3	31.3
20150120	30.7	30.7	30.8	30.5	31.2
20150121	31.7	31.1	31.2	31.2	31.7
:	:	:	:	:	:
20151202	33.8	34.4	34.3	34.3	33.3
20151203	34.4	34.4	34.3	34.3	34.0
20151204	34.4	34.9	34.8	34.9	34.5
20151205	34.3	34.4	34.3	34.3	34.2
20151206	33.8	34.1	34.1	33.9	34.3
20151207	33.8	34.4	34.2	34.3	33.7
20151208	33.2	32.7	32.9	32.9	31.9
20151209	33.3	33.0	33.0	33.1	33.2
20151210	32.4	33.0	33.0	32.9	32.9
20151211	33.2	33.5	33.5	33.4	33.3
20151212	33.3	34.0	33.9	34.0	33.2
20151213	33.0	33.6	33.8	33.6	32.8
20151214	33.3	34.3	34.3	34.1	33.7
20151215	32.0	32.7	32.5	32.6	31.2
20151216	32.0	32.0	32.1	32.1	32.2
20151217	33.0	33.0	33.0	33.1	32.3
20151218	32.1	33.1	33.2	32.9	32.4

Lampiran 5. Nilai Prediksi Temperatur Minimum *Model Output Statistics* di Stasiun Hasanuddin

vdate	PCR	PLSR	Stepwise	Ridge	Obs
20150102	23.7	24.2	24.3	23.9	24.6
20150103	23.4	23.6	23.5	23.6	23.9
20150104	23.7	22.9	22.9	22.8	22.9
20150105	23.5	24.5	24.6	24.1	23.9
20150106	23.4	24.9	24.9	24.6	24.3
20150107	23.3	24.2	24.3	23.9	23.7
20150108	23.1	23.9	24.1	23.6	24.2
20150109	23.2	24.2	24.4	23.9	24.5
20150110	23.2	23.7	23.7	23.5	23.5
20150111	23.8	23.6	23.6	23.4	23.6
20150112	23.6	23.0	23.1	23.2	23.6
20150113	23.5	23.6	23.5	23.4	23.8
20150114	23.2	23.7	23.8	23.3	24.5
20150115	23.6	24.0	24.1	23.8	23.9
20150116	24.0	23.7	23.5	23.6	24.5
20150117	23.6	23.1	23.0	23.3	24.6
20150118	23.8	23.2	23.1	23.4	24.9
20150119	23.7	23.5	23.6	23.3	23.4
20150120	23.8	23.6	23.7	23.7	24.5
20150121	24.1	24.3	24.3	24.3	23.2
:	:	:	:	:	:
20151202	23.7	24.0	23.9	24.0	23.3
20151203	23.1	23.2	23.1	23.3	23.2
20151204	23.1	22.9	22.9	23.1	22.3
20151205	23.4	23.4	23.3	23.5	22.5
20151206	23.5	23.9	23.8	23.7	22.9
20151207	23.7	23.2	23.1	23.5	23.5
20151208	24.0	23.9	23.8	23.7	23.9
20151209	23.8	24.2	24.2	24.1	24.0
20151210	24.1	24.7	24.6	24.5	25.4
20151211	23.9	24.1	24.0	24.0	24.7
20151212	23.9	23.9	23.8	23.9	24.2
20151213	23.8	24.3	24.2	24.0	25.0
20151214	23.7	23.7	23.6	23.8	24.7
20151215	24.6	24.9	24.8	25.0	25.1
20151216	24.5	24.6	24.6	24.7	24.7
20151217	24.6	24.2	24.2	24.3	24.1
20151218	23.8	23.0	22.9	23.3	23.2

Lampiran 6. Nilai Prediksi Kelembaban *Model Output Statistics* di Stasiun Hasanuddin

vdate	PCR	PLSR	Stepwise	Ridge	Obs
20150102	96.1	96.0	96.3	97.5	94.5
20150103	100.6	92.0	92.6	93.0	95.2
20150104	111.1	98.1	99.0	98.1	95.8
20150105	97.0	94.4	94.0	95.3	95.2
20150106	96.8	98.2	96.8	97.8	97.6
20150107	93.4	92.9	92.2	93.0	86.4
20150108	93.3	91.2	90.8	92.8	87.4
20150109	94.0	89.9	88.8	91.8	86.2
20150110	90.2	86.6	86.4	87.8	86.7
20150111	89.5	88.9	89.3	89.4	90.5
20150112	86.6	86.2	87.1	86.6	84.0
20150113	87.0	86.7	86.8	87.2	78.9
20150114	86.9	89.3	88.6	88.2	84.8
20150115	88.6	87.5	86.7	87.6	93.6
20150116	88.2	84.5	84.8	86.7	92.8
20150117	84.2	82.0	82.2	82.5	81.9
20150118	83.7	84.8	85.4	83.9	88.3
20150119	85.3	93.0	91.7	90.4	90.2
20150120	84.2	85.2	85.9	87.3	89.6
20150121	83.7	87.0	86.2	87.4	81.8
:	:	:	:	:	:
20151202	87.5	84.2	84.2	83.6	92.1
20151203	82.3	82.2	82.4	81.0	81.3
20151204	81.4	79.2	79.3	77.3	73.3
20151205	86.1	83.9	84.0	82.7	77.2
20151206	88.5	85.3	85.4	86.2	79.2
20151207	89.5	84.2	84.7	82.3	89.8
20151208	84.5	84.1	84.1	85.6	91.7
20151209	86.4	88.4	87.5	87.7	90.5
20151210	91.0	90.2	89.4	89.9	93.6
20151211	91.3	89.4	89.3	88.8	93.1
20151212	91.5	87.2	87.4	86.6	92.4
20151213	92.8	88.1	88.4	89.6	96.2
20151214	88.8	82.5	83.0	83.4	91.1
20151215	97.5	94.3	92.9	92.7	96.2
20151216	94.3	89.7	89.2	91.2	96.7
20151217	93.4	87.4	87.4	88.8	89.7
20151218	88.2	81.4	81.8	82.1	92.3

Lampiran 7. Nilai Prediksi Temperatur Maksimum *Model Output Statistics* di Stasiun Pattimura

vdate	PCR	PLSR	Stepwise	Ridge	Obs
20150102	31.4	31.8	31.7	31.8	29.7
20150103	31.0	31.4	31.4	31.6	29.9
20150104	30.6	31.1	31.1	31.6	29.0
20150105	30.8	31.2	31.2	31.6	30.9
20150106	31.0	31.2	31.2	31.5	30.9
20150107	30.5	30.6	30.6	31.3	29.7
20150108	31.0	31.3	31.2	31.8	32.0
20150109	30.7	31.1	31.1	31.7	30.6
20150110	31.1	31.4	31.5	32.0	30.2
20150111	31.2	31.5	31.6	31.8	30.6
20150112	31.5	31.7	31.7	31.7	33.0
20150113	32.0	32.0	32.0	31.7	32.8
20150114	32.0	32.2	32.2	32.1	32.9
20150115	31.4	31.5	31.5	31.5	33.3
20150116	31.3	31.2	31.2	31.0	33.4
20150117	31.7	31.4	31.3	30.8	31.4
20150118	32.0	32.0	31.9	31.4	32.7
20150119	32.2	32.3	32.2	31.6	31.6
20150120	32.2	32.1	32.1	31.8	31.6
20150121	31.6	31.5	31.6	31.4	31.6
:	:	:	:	:	:
20151202	31.3	31.0	31.0	31.2	31.2
20151203	31.4	31.4	31.3	31.3	30.8
20151204	31.5	31.5	31.5	31.4	32.0
20151205	31.5	31.5	31.5	31.4	31.8
20151206	31.8	31.7	31.7	31.6	32.0
20151207	31.6	31.5	31.4	31.4	31.5
20151208	32.4	32.7	32.9	32.4	32.6
20151209	33.2	33.5	33.4	32.7	32.8
20151210	33.5	33.7	33.7	32.9	33.6
20151211	32.4	32.7	32.7	32.3	33.4
20151212	31.6	31.7	31.8	31.3	33.1
20151213	31.4	31.3	31.2	31.0	33.5
20151214	32.6	32.8	32.7	32.1	33.3
20151215	32.1	32.1	32.1	31.3	33.6
20151216	31.5	31.2	31.2	30.8	33.1
20151217	31.5	31.9	32.2	31.5	31.7
20151218	32.6	32.5	32.5	31.9	33.0

Lampiran 8. Nilai Prediksi Temperatur Minimum *Model Output Statistics* di Stasiun Pattimura

vdate	PCR	PLSR	Stepwise	Ridge	Obs
20150102	24.7	24.9	24.8	24.9	24.8
20150103	24.9	24.8	24.8	24.9	25.2
20150104	25.1	25.2	25.2	25.2	25.3
20150105	25.0	24.9	24.9	25.0	24.2
20150106	24.9	25.1	25.1	25.1	26.0
20150107	24.8	25.1	25.1	24.9	25.0
20150108	24.7	25.3	25.3	25.1	26.0
20150109	24.8	25.0	25.1	25.1	26.0
20150110	24.6	24.7	24.8	24.7	25.6
20150111	24.5	24.6	24.6	24.6	25.0
20150112	24.2	24.1	24.2	24.3	25.2
20150113	24.2	24.1	24.1	24.0	24.6
20150114	24.4	24.3	24.4	24.4	24.0
20150115	24.2	24.4	24.4	24.2	24.1
20150116	24.1	24.3	24.3	24.1	24.1
20150117	24.0	24.2	24.2	23.9	24.8
20150118	24.0	23.9	23.9	23.8	23.7
20150119	23.8	23.7	23.7	23.8	24.1
20150120	23.2	23.3	23.3	23.1	23.6
20150121	23.3	23.3	23.4	23.2	23.8
:	:	:	:	:	:
20151204	24.4	24.5	24.5	24.3	23.7
20151205	24.0	23.7	23.7	23.9	23.2
20151206	24.6	24.5	24.5	24.5	23.8
20151207	24.7	24.9	24.9	24.8	25.3
20151208	24.5	24.8	24.7	24.6	24.1
20151209	24.8	24.8	24.7	24.7	23.6
20151210	24.4	24.1	24.2	24.3	23.9
20151211	24.1	23.9	23.9	24.0	24.0
20151212	24.3	24.0	24.0	24.2	24.3
20151213	24.9	24.8	24.8	24.9	24.9
20151214	24.9	24.6	24.6	24.7	25.0
20151215	24.5	24.4	24.3	24.3	25.2
20151216	24.6	23.9	23.9	24.3	24.9
20151217	24.6	23.8	23.8	24.3	23.6
20151218	24.5	24.1	24.2	24.1	24.7
20151219	24.8	24.3	24.3	24.5	24.5
20151220	24.3	23.9	23.9	24.0	24.7

Lampiran 9. Nilai Prediksi Kelembaban *Model Output Statistics* di Stasiun Pattimura

vdate	PCR	PLSR	Stepwise	Ridge	Obs
20150102	82.0	80.1	80.0	80.4	75.4
20150103	82.3	79.8	79.6	80.0	76.6
20150104	82.7	78.2	77.9	78.6	85.2
20150105	81.9	78.3	78.1	78.5	76.7
20150106	81.7	80.0	79.8	80.2	78.7
20150107	80.7	78.9	78.7	78.9	78.5
20150108	81.4	78.2	77.9	78.4	75.0
20150109	82.2	77.7	77.5	78.0	78.3
20150110	80.6	76.3	76.2	76.3	74.7
20150111	81.4	78.6	78.6	78.8	77.8
20150112	81.7	79.9	79.8	80.1	81.3
20150113	80.4	80.5	80.4	80.4	79.7
20150114	82.0	80.0	80.0	80.1	82.6
20150115	83.0	80.7	80.7	80.8	80.3
20150116	83.9	83.7	83.7	83.8	79.9
20150117	83.6	86.9	87.0	87.0	85.7
20150118	82.1	84.1	84.3	84.0	85.3
20150119	82.0	83.8	84.1	83.9	85.7
20150120	79.7	80.0	80.1	79.6	84.9
20150121	80.8	80.4	80.4	80.1	82.1
:	:	:	:	:	:
20151204	83.5	84.6	84.6	84.4	82.6
20151205	81.8	82.3	82.4	82.1	78.8
20151206	85.5	85.3	85.1	85.5	81.5
20151207	85.6	85.5	85.4	85.8	85.2
20151208	84.0	84.9	84.8	84.9	86.9
20151209	82.6	84.8	84.8	84.6	86.2
20151210	83.3	79.9	79.9	80.2	80.3
20151211	80.3	79.6	79.7	79.5	79.5
20151212	80.3	79.4	79.4	79.4	80.2
20151213	83.6	82.5	82.5	82.9	78.2
20151214	85.7	85.3	85.3	85.8	79.0
20151215	84.1	86.1	86.1	86.0	78.9
20151216	81.2	83.3	83.2	83.2	88.1
20151217	83.6	86.4	86.1	86.7	79.7
20151218	83.7	86.9	86.8	86.9	81.3
20151219	86.2	83.2	83.2	84.3	81.5
20151220	80.8	83.0	82.9	82.7	79.7

Lampiran 10. Ilustrasi Penggunaan *Training (m)* 10 Hari

No	Tanggal	Obs	PCR	PLSR	Stepwise	Ridge	
1	02/01/15	27.8	28.81	28.62	28.96	28.84	
2	03/01/15	27.9	28.42	29.14	28.96	29.43	
3	04/01/15	27.5	27.34	27.83	28.03	28.17	
4	05/01/15	27.9	28.86	28.98	29.06	29.02	
5	06/01/15	26.9	28.54	28.25	28.35	28.50	
6	07/01/15	31.4	29.17	29.12	29.18	29.20	
7	08/01/15	31.1	28.78	28.98	29.14	28.92	
8	09/01/15	30.6	28.82	29.18	29.34	29.14	
9	10/01/15	30.3	29.93	30.40	30.52	30.25	
10	11/01/15	29.7	31.24	31.21	31.37	31.23	
11	12/01/15	32.2	31.76	31.76	31.86	31.77	$f_{1,j}$
12	13/01/15	32.7	31.83	31.64	31.64	31.70	$f_{2,j}$

Lampiran 11. Nilai CRPS Temperatur Maksimum, Temperatur Minimum, dan Kelembaban di Stasiun Hasanuddin dan Pattimura

Panjang Training	Hasanuddin			Pattimura		
	Tmaks	Tmin	RH	Tmaks	Tmin	RH
10	0.540	0.584	3.329	0.537	0.448	2.277
20	0.536	0.543	3.184	0.502	0.412	2.103
30	0.519	0.554	3.233	0.507	0.399	2.036
40	0.496	0.558	3.240	0.500	0.392	1.972
50	0.490	0.563	3.205	0.496	0.388	1.952
60	0.500	0.573	3.195	0.503	0.393	1.953

Lampiran 12. Nilai RMSE Temperatur Maksimum, Temperatur Minimum, dan Kelembaban di Stasiun Hasanuddin dan Pattimura

Panjang Training	Hasanuddin			Pattimura		
	Tmaks	Tmin	RH	Tmaks	Tmin	RH
10	0.982	1.075	5.853	0.961	0.780	3.898
20	0.999	0.989	5.627	0.905	0.732	3.646
30	0.961	1.001	5.725	0.906	0.725	3.559
40	0.904	1.017	5.711	0.905	0.719	3.483
50	0.896	1.028	5.692	0.896	0.715	3.459
60	0.915	1.045	5.706	0.904	0.721	3.456

Lampiran 13. Taksiran Interval Temperatur Maksimum, Temperatur Minimum, dan Kelembaban di Stasiun Hasanuddin

<i>vdate</i>	Tmaks		Tmin		RH			
	<i>Lower</i>	<i>Upper</i>	<i>Lower</i>	<i>Upper</i>	<i>Lower</i>	<i>Upper</i>		
20150211	27.37	33.40	20150122	22.95	25.12	20150122	75.62	91.27
20150212	27.99	33.97	20150123	22.92	24.99	20150123	80.14	96.43
20150213	28.31	34.17	20150124	22.68	24.89	20150124	75.59	91.47
20150214	28.56	34.48	20150125	22.94	24.99	20150125	75.59	91.47
20150215	28.19	33.99	20150126	22.95	24.99	20150126	80.44	95.58
20150216	27.75	33.12	20150127	22.91	25.04	20150127	83.09	98.31
20150217	28.34	33.61	20150128	22.89	25.02	20150128	78.61	93.46
:	:	:	:	:	:	:	:	:
20151210	31.60	34.69	20151210	22.52	27.14	20151210	86.83	104.02
20151211	32.22	34.71	20151211	22.57	26.14	20151211	85.83	101.70
20151212	32.24	35.19	20151212	22.51	25.67	20151212	79.81	101.26
20151213	31.98	35.03	20151213	22.72	26.26	20151213	84.21	103.37
20151214	32.08	35.50	20151214	22.28	25.53	20151214	73.85	95.79
20151215	31.47	34.15	20151215	24.61	27.76	20151215	91.99	109.82
20151216	30.96	33.22	20151216	23.60	26.78	20151216	87.60	105.68
20151217	31.81	33.80	20151217	23.05	26.28	20151217	85.39	101.84
20151218	30.87	33.77	20151218	21.76	24.72	20151218	76.41	93.98

Lampiran 14. Taksiran Interval Temperatur Maksimum, Temperatur Minimum, dan Kelembaban di Stasiun Pattimura

Tmaks			Tmin			RH		
vdate	Lower	Upper	vdate	Lower	Upper	vdate	Lower	Upper
20150122	29.14	33.38	20150211	22.42	24.83	20150211	74.46	85.36
20150123	29.76	33.70	20150212	22.73	25.18	20150212	73.74	83.93
20150124	30.49	34.33	20150213	23.29	26.17	20150213	74.21	85.37
20150125	31.08	34.52	20150214	22.84	25.41	20150214	75.49	87.06
20150126	30.98	34.69	20150215	23.33	25.67	20150215	75.54	87.53
20150127	29.98	33.87	20150216	23.27	25.87	20150216	75.44	87.46
20150128	31.28	35.15	20150217	22.56	25.46	20150217	78.25	90.45
:	:	:	:	:	:	:	:	:
20151212	31.56	34.04	20151212	23.05	25.04	20151212	72.97	82.84
20151213	31.36	33.93	20151213	23.59	25.50	20151213	77.16	86.74
20151214	30.86	33.52	20151214	23.63	25.57	20151214	80.29	89.49
20151215	30.41	33.26	20151215	23.31	25.27	20151215	80.65	89.97
20151216	31.27	34.40	20151216	23.39	25.33	20151216	77.23	87.17
20151217	30.93	34.04	20151217	23.50	25.47	20151217	79.90	90.65
20151218	30.20	33.52	20151218	23.29	25.29	20151218	79.65	90.54
20151219	27.71	30.83	20151219	23.53	25.60	20151219	77.46	88.61
20151220	31.50	34.62	20151220	23.22	25.18	20151220	76.25	87.16

Lampiran 15. Program Reduksi Dimensi menggunakan PCA

```
pca_pat<-read.csv("F:/KULIAH/SEMESTER 8/TA/DATA  
TA/HASANUDDIN/Variabel Grid/dew2m.csv",header=T, sep = ";")  
pca=scale(pca_pat)  
write.csv(pca,"F:/KULIAH/SEMESTER 8/TA/DATA  
TA/HASANUDDIN/Hasil PCA/standardize_dew2m.csv")  
kovarian<-cov(pca)  
write.csv(kovarian,"F:/KULIAH/SEMESTER 8/TA/DATA  
TA/HASANUDDIN/Hasil PCA/kovarian_dew2m.csv")  
eigenvalue<-eigen(kovarian)$value  
fit_pca<-princomp(pca,cor=FALSE)  
fit_pca  
sdev<-fit_pca$sdev  
sumvar<-sum(eigenvalue)  
p<-ncol(pca)  
var <- matrix(c(0),p,1)  
cumvar <- matrix(c(0),p,1)  
for(i in 1:p){  
  var[i] <- eigenvalue[i]/sumvar  
  if (i == 1) {cumvar[i] <- var[i]}  
  else  
    cumvar[i] <- var[i] + cumvar[i-1]  
}  
write.csv(cbind(eigenvalue,sdev,var,cumvar),"F:/KULIAH/SEMESTER  
R 8/TA/DATA TA/HASANUDDIN/Hasil  
PCA/eigenvalue_dew2m.csv")  
loadings<-loadings(fit_pca)  
write.csv(cbind(loadings),"F:/KULIAH/SEMESTER 8/TA/DATA  
TA/HASANUDDIN/Hasil PCA/koefisien_dew2m.csv")  
score<-fit_pca$scores  
write.csv(cbind(score),"F:/KULIAH/SEMESTER 8/TA/DATA  
TA/HASANUDDIN/Hasil PCA/score_dew2m.csv")
```

Lampiran 16. Program Pemodelan MOS dengan Metode Pendekatan PCR

```

library(pls)
library(plsdepot)
library(MASS)
pca<-read.csv("F:/KULIAH/SEMESTER 8/TA/DATA
TA/HASANUDDIN/DATA ENSEMBLE.csv",header=T,sep = ";")
stdr<-scale(pca[,1:23])
x=stdr[,1:20]
y1=stdr[,21]
y2=stdr[,22]
y3=stdr[,23]
tr=cbind(x,y1,y2,y3)

#PCR
#mencari komponen optimal Tmaks PCR#
#berdasarkan kumulatif varians minimal 80%#
pcr.tmaks<-mvr(y1~dew2m+hi_cloud+hujan_total+low_cloud_1+
low_cloud_2+low_cloud_3+mid_cloud+mslp+rhum2m+shum2m+sur
_press+sur_vis_1+sur_vis_2+temp2m_1+temp2m_2+tot_cloud+uwin
d10m+vwind10m+wind_gust_1+wind_gust_2,data=as.data.frame(tr),n
comp=20,method=pls.options()$pcr)
summary(crossval(pcr.tmaks))

#mencari komponen optimal Tmin PCR#
#berdasarkan kumulatif varians minimal 80%#
pcr.tmin<-mvr(y2~dew2m+hi_cloud+hujan_total+low_cloud_1+
low_cloud_2+low_cloud_3+mid_cloud+mslp+rhum2m+shum2m+sur
_press+sur_vis_1+sur_vis_2+temp2m_1+temp2m_2+tot_cloud+uwin
d10m+vwind10m+wind_gust_1+wind_gust_2,data=as.data.frame(tr),n
comp=20,method=pls.options()$pcr)
summary(crossval(pcr.tmin))

#mencari komponen optimal RH PCR#
#berdasarkan kumulatif varians minimal 80%#
pcr.rh<-mvr(y3~dew2m+hi_cloud+hujan_total+low_cloud_1+
low_cloud_2+low_cloud_3+mid_cloud+mslp+rhum2m+shum2m+su
r_press+sur_vis_1+sur_vis_2+temp2m_1+temp2m_2+tot_cloud+uwin
d10m+vwind10m+wind_gust_1+wind_gust_2,data=as.data.frame(tr),n
comp=20,method=pls.options()$pcr)
summary(crossval(pcr.rh))

```

```

#prediksi MOS dengan menggunakan komponen optimal
#MOS PCR Tmaks
tmax.tr1=pcr(y1~dew2m+hi_cloud+hujan_total+low_cloud_1+low_cl
oud_2+low_cloud_3+mid_cloud+mslp+rhum2m+shum2m+sur_press
+sur_vis_1+sur_vis_2+temp2m_1+temp2m_2+tot_cloud+uwind10m+
vwind10m+wind_gust_1+wind_gust_2,7,data=as.data.frame(tr))
tmax.tr1.fit=tmax.tr1$fitted.values[,7]

#MOS PCR Tmin
tmin.tr1=pcr(y2~dew2m+hi_cloud+hujan_total+low_cloud_1+low_cl
oud_2+low_cloud_3+mid_cloud+mslp+rhum2m+shum2m+sur_press
+sur_vis_1+sur_vis_2+temp2m_1+temp2m_2+tot_cloud+uwind10m+
vwind10m+wind_gust_1+wind_gust_2,7, data=as.data.frame(tr))
tmin.tr1.fit=tmin.tr1$fitted.values[,7]

#MOS PCR RH
rh.tr1=pcr(y3~dew2m+hi_cloud+hujan_total+low_cloud_1+low_clou
d_2+low_cloud_3+mid_cloud+mslp+rhum2m+shum2m+sur_press+su
r_vis_1+sur_vis_2+temp2m_1+temp2m_2+tot_cloud+uwind10m+vwi
nd10m+wind_gust_1+wind_gust_2,7, data=as.data.frame(tr))
rh.tr1.fit=rh.tr1$fitted.values[,7]

obs<-read.csv("F:/KULIAH/SEMESTER 8/TA/DATA
TA/HASANUDDIN/DATA OBSERVASI
HASANUDDIN.csv",header=T,sep =";")
c=vector(mode="numeric",length=2)
d=vector(mode="numeric",length=2)
for (i in 1:3){
  c[i]=mean(obs[,i])
  d[i]=sd(obs[,i])
}
PCR.Tmaks=(tmax.tr1.fit*d[1])+c[1]
PCR.Tmin=(tmin.tr1.fit*d[2])+c[2]
PCR.RH=(rh.tr1.fit*d[3])+c[3]

hasilPCR=cbind(PCR.Tmaks,PCR.Tmin,PCR.RH)
write.csv(hasilPCR,"F:/KULIAH/SEMESTER 8/TA/DATA TA/Hasil
MOS HASANUDDIN/HASIL PCR HASANUDDIN.csv")

#Persamaan regresi PCR untuk 7 komponen optimal
tmax.tr1$coefficients
tmin.tr1$coefficients
rh.tr1$coefficients

```

Lampiran 17. Program Pemodelan MOS dengan Metode Pendekatan PLSR

```

library(pls)
library(plsdepot)
library(MASS)
pca<-read.csv("F:/KULIAH/SEMESTER 8/TA/DATA
TA/HASANUDDIN/DATA ENSEMBLE.csv",header=T,sep = ";")
tran<-scale(pca[,1:23])
x=tran[,1:20]
y1=tran[,21]
y2=tran[,22]
y3=tran[,23]
tr=cbind(x,y1,y2,y3)

#PLSR1
#mencari komponen optimal Tmaks PLSR#
#RMSE terendah#
plsr.tmaks<-mvr(y1~dew2m+hi_cloud+hujan_total+low_cloud_1
+low_cloud_2+low_cloud_3+mid_cloud+mslp+rhum2m+shum2m+su
r_press+sur_vis_1+sur_vis_2+temp2m_1+temp2m_2+tot_cloud+uwin
d10m+vvwind10m+wind_gust_1+wind_gust_2,data=as.data.frame(tr),n
comp=20,method=pls.options()$plsr)
summary(crossval(plsr.tmaks))

#mencari komponen optimal Tmin PLSR#
#RMSE terendah#
plsr.tmin<-mvr(y2~dew2m+hi_cloud+hujan_total+low_cloud_1
+low_cloud_2+low_cloud_3+mid_cloud+mslp+rhum2m+shum2m+su
r_press+sur_vis_1+sur_vis_2+temp2m_1+temp2m_2+tot_cloud+uwin
d10m+vvwind10m+wind_gust_1+wind_gust_2,data=as.data.frame(tr),n
comp=20,method=pls.options()$plsr)
summary(crossval(plsr.tmin))

#mencari komponen optimal RH PLSR#
#RMSE terendah#
plsr.rh<-mvr(y3~dew2m+hi_cloud+hujan_total+low_cloud_1
+low_cloud_2+low_cloud_3+mid_cloud+mslp+rhum2m+shum2m+su
r_press+sur_vis_1+sur_vis_2+temp2m_1+temp2m_2+tot_cloud+uwin
d10m+vvwind10m+wind_gust_1+wind_gust_2,data=as.data.frame(tr),n
comp=20,method=pls.options()$plsr)
summary(crossval(plsr.rh))

```

```
#PREDIKSI MOS menggunakan komponen optimal
#MOS PLSR Tmaks
tmax.tr2=plsreg1(x,y1,comps=12)
Ytr1.hat=as.matrix(x)%*%(tmax.tr2$std.coefs)
write.csv(Ytr1.hat,"F:/TA/Ytr1.hat PLSR HASANUDDIN.csv")
#MOS PLSR Tmin
tmin.tr2=plsreg1(x,y2,comps=19)
Ytr2.hat=as.matrix(x)%*%(tmin.tr2$std.coefs)
#MOS PLSR RH
rh.tr2=plsreg1(x,y3,comps=19)
Ytr3.hat=as.matrix(x)%*%(rh.tr2$std.coefs)

obs<-read.csv("F:/KULIAH/SEMESTER 8/TA/DATA
TA/HASANUDDIN/DATA OBSERVASI
HASANUDDIN.csv",header=T,sep = ";")
a=vector(mode="numeric",length=1)
b=vector(mode="numeric",length=1)
for (i in 1:3){
  a[i]=mean(obs[,i])
  b[i]=sd(obs[,i])
}
PLS1.Tmax=(Ytr1.hat*b[1])+a[1]
PLS1.Tmin=(Ytr2.hat*b[2])+a[2]
PLS1.RH=(Ytr3.hat*b[3])+a[3]

hasilPLS=cbind(PLS1.Tmax,PLS1.Tmin,PLS1.RH)
write.csv(hasilPLS,"F:/KULIAH/SEMESTER 8/TA/DATA TA/Hasil
MOS HASANUDDIN/HASIL PLSR HASANUDDIN.csv")

#Persamaan regresi PLSR menggunakan komponen optimal
tmax.tr2$std.coefs
tmin.tr2$std.coefs
rh.tr2$std.coefs
```

Lampiran 18. Program Pemodelan MOS dengan Metode Pendekatan *Stepwise Regression*

```

library(pls)
library(plsdepot)
library(MASS)
pca<-read.csv("F:/KULIAH/SEMESTER 8/TA/DATA
TA/HASANUDDIN/DATA ENSEMBLE.csv",header=T,sep =";")
tran<-scale(pca[,1:23])
x=tran[,1:20]
y1=tran[,21]
y2=tran[,22]
y3=tran[,23]
tr=cbind(x,y1,y2,y3)

#STEPWISE
#mencari komponen optimum Tmaks Stepwise#
#AIC TERKECIL#
stepwise_tmaks<-lm(y1~dew2m+hi_cloud+hujan_total+low_cloud_1
+low_cloud_2+low_cloud_3+mid_cloud+mslp+rhum2m+shum2m+su
r_press+sur_vis_1+sur_vis_2+temp2m_1+temp2m_2+tot_cloud+uwin
d10m+vwind10m+wind_gust_1+wind_gust_2,data=as.data.frame(tr))
stepAIC(stepwise_tmaks,direction="both")

#mencari komponen optimum Tmin Stepwise#
#AIC TERKECIL#
stepwise_tmin<-lm(y2~dew2m+hi_cloud+hujan_total+low_cloud_1
+low_cloud_2+low_cloud_3+mid_cloud+mslp+rhum2m+shum2m+su
r_press+sur_vis_1+sur_vis_2+temp2m_1+temp2m_2+tot_cloud+uwin
d10m+vwind10m+wind_gust_1+wind_gust_2,data=as.data.frame(tr))
stepAIC(stepwise_tmin,direction="both")

#mencari komponen optimum RH Stepwise#
#AIC TERKECIL#
stepwise_RH<-lm(y3~dew2m+hi_cloud+hujan_total+low_cloud_1
+low_cloud_2+low_cloud_3+mid_cloud+mslp+rhum2m+shum2m+su
r_press+sur_vis_1+sur_vis_2+temp2m_1+temp2m_2+tot_cloud+uwin
d10m+vwind10m+wind_gust_1+wind_gust_2,data=as.data.frame(tr))
stepAIC(stepwise_RH,direction="both")

```

```

#MOS stepwise Tmaks
lm.step.tmax<-lm(y1 ~ dew2m + low_cloud_1 + mid_cloud +
shum2m + sur_press + sur_vis_1 + temp2m_1 + temp2m_2 +
uwind10m + vwind10m + wind_gust_1, data = as.data.frame(tr))
lm.step.tmax.fit=lm.step.tmax$fitted.values

#MOS stepwise Tmin
lm.step.tmin<-lm(y2 ~ dew2m + hi_cloud + hujan_total +
low_cloud_1 +mid_cloud + mslp + rhum2m + shum2m + sur_press +
tot_cloud + uwind10m + wind_gust_2, data = as.data.frame(tr))
lm.step.tmin.fit=lm.step.tmin$fitted.values

#MOS stepwise RH
lm.step.rh<-lm(y3 ~ dew2m + rhum2m + shum2m + sur_press +
temp2m_1 + temp2m_2 + tot_cloud + uwind10m + vwind10m +
wind_gust_1, data = as.data.frame(tr))
lm.step.rh.fit=lm.step.rh$fitted.values

obs<-read.csv("F:/KULIAH/SEMESTER 8/TA/DATA
TA/HASANUDDIN/DATA OBSERVASI
HASANUDDIN.csv",header=T,sep = ";")
a=vector(mode="numeric",length=1)
b=vector(mode="numeric",length=1)
for (i in 1:3){
  a[i]=mean(obs[,i])
  b[i]=sd(obs[,i])}
STEP.Tmax=(lm.step.tmax.fit*b[1])+a[1]
STEP.Tmin=(lm.step.tmin.fit*b[2])+a[2]
STEP.RH=(lm.step.rh.fit*b[3])+a[3]

hasilSTEP=cbind(STEP.Tmax,STEP.Tmin,STEP.RH)
write.csv(hasilSTEP,"F:/KULIAH/SEMESTER 8/TA/DATA
TA/Hasil MOS HASANUDDIN/HASIL STEPWISE
HASANUDDIN.csv")

#Persamaan regresi stepwise
lm.step.tmax$coefficients
lm.step.tmin$coefficients
lm.step.rh$coefficients

```

Lampiran 19. Program Pemodelan MOS dengan Metode Pendekatan *Ridge Regression*

```

library(pls)
library(plsdepot)
library(MASS)
pca<-read.csv("F:/KULIAH/SEMESTER 8/TA/DATA
TA/HASANUDDIN/DATA ENSEMBLE.csv",header=T,sep = ";")
tran<-scale(pca[,1:23])
x=tran[,1:20]
y1=tran[,21]
y2=tran[,22]
y3=tran[,23]
tr=cbind(x,y1,y2,y3)

#RIDGE
#mencari penalti optimal Tmaks Ridge#
ridge.tmaks<-
lm.ridge(y1~dew2m+hi_cloud+hujan_total+low_cloud_1
+low_cloud_2+low_cloud_3+mid_cloud+mslp+rhum2m+shum2m+su
r_press+sur_vis_1+sur_vis_2+temp2m_1+temp2m_2+tot_cloud+uwin
d10m+vwind10m+wind_gust_1+wind_gust_2,data=as.data.frame(tr),l
ambda=seq(0,10,.01))
plot(ridge.tmaks)
select(ridge.tmaks)
lambda1=which.min(ridge.tmaks$GCV) #this is the optimal tuning
parameter lambda

#mencari penalti optimal Tmin Ridge#
ridge.tmin<-lm.ridge(y2~dew2m+hi_cloud+hujan_total+low_cloud_1
+low_cloud_2+low_cloud_3+mid_cloud+mslp+rhum2m+shum2m+su
r_press+sur_vis_1+sur_vis_2+temp2m_1+temp2m_2+tot_cloud+uwin
d10m+vwind10m+wind_gust_1+wind_gust_2,data=as.data.frame(tr),l
ambda=seq(0,10,.01))
plot(ridge.tmin)
lambda2=which.min(ridge.tmin$GCV) #this is the optimal tuning
parameter lambda

```

```

#mencari penalti optimal RH Ridge#
ridge.rh<-lm.ridge(y3~dew2m+hi_cloud+hujan_total+low_cloud_1
+low_cloud_2+low_cloud_3+mid_cloud+mslp+rhum2m+shum2m+su
r_press+sur_vis_1+sur_vis_2+temp2m_1+temp2m_2+tot_cloud+uwin
d10m+vwind10m+wind_gust_1+wind_gust_2,data=as.data.frame(tr),l
ambda=seq(0,10,.01))
plot(ridge.rh)
lambda3=which.min(ridge.rh$GCV) #this is the optimal tuning
parameter lambda

#MOS RIDGE Tmaks
ridge.tmaks<-
lm.ridge(y1~dew2m+hi_cloud+hujan_total+low_cloud_1
+low_cloud_2+low_cloud_3+mid_cloud+mslp+rhum2m+shum2m+su
r_press+sur_vis_1+sur_vis_2+temp2m_1+temp2m_2+tot_cloud+uwin
d10m+vwind10m+wind_gust_1+wind_gust_2,data=as.data.frame(tr),l
ambda=as.numeric(names(lambda1)))

ridge.tmaks.hat<-coef(ridge.tmaks)[2]*tr[,1] +
coef(ridge.tmaks)[3]*tr[,2] + coef(ridge.tmaks)[4]*tr[,3] +
coef(ridge.tmaks)[5]*tr[,4] + coef(ridge.tmaks)[6]*tr[,5] +
coef(ridge.tmaks)[7]*tr[,6] + coef(ridge.tmaks)[8]*tr[,7] +
coef(ridge.tmaks)[9]*tr[,8] + coef(ridge.tmaks)[10]*tr[,9] +
coef(ridge.tmaks)[11]*tr[,10]+ coef(ridge.tmaks)[12]*tr[,11]
+coef(ridge.tmaks)[13]*tr[,12]+coef(ridge.tmaks)[14]*tr[,13] +
coef(ridge.tmaks)[15]*tr[,14]+coef(ridge.tmaks)[16]*tr[,15]
+coef(ridge.tmaks)[17]*tr[,16]+ coef(ridge.tmaks)[18]*tr[,17]
+coef(ridge.tmaks)[19]*tr[,18]+coef(ridge.tmaks)[20]*tr[,19] +
coef(ridge.tmaks)[21]*tr[,20]

#MOS RIDGE Tmin
ridge.tmin<-
lm.ridge(y2~dew2m+hi_cloud+hujan_total+low_cloud_1+low_cloud_
2+low_cloud_3+mid_cloud+mslp+rhum2m+shum2m+sur_press+sur_
vis_1+sur_vis_2+temp2m_1+temp2m_2+tot_cloud+uwind10m+vwin
d10m+wind_gust_1+wind_gust_2,data=as.data.frame(tr),lambda=as.n
umeric(lambda2))

```

```

ridge.tmin.hat<-coef(ridge.tmin)[2]*tr[,1] +
coef(ridge.tmaks)[3]*tr[,2] + coef(ridge.tmaks)[4]*tr[,3] +
coef(ridge.tmaks)[5]*tr[,4]+ coef(ridge.tmaks)[6]*tr[,5] +
coef(ridge.tmaks)[7]*tr[,6] + coef(ridge.tmaks)[8]*tr[,7] +
coef(ridge.tmaks)[9]*tr[,8] + coef(ridge.tmaks)[10]*tr[,9] +
coef(ridge.tmaks)[11]*tr[,10]+ coef(ridge.tmaks)[12]*tr[,11] +
+coef(ridge.tmaks)[13]*tr[,12]+coef(ridge.tmaks)[14]*tr[,13] +
coef(ridge.tmaks)[15]*tr[,14]+coef(ridge.tmaks)[16]*tr[,15] +
+coef(ridge.tmaks)[17]*tr[,16]+ coef(ridge.tmaks)[18]*tr[,17] +
+coef(ridge.tmaks)[19]*tr[,18]+coef(ridge.tmaks)[20]*tr[,19] +
coef(ridge.tmaks)[21]*tr[,20]

#MOS RIDGE RH
ridge.rh<-
lm.ridge(y3~dew2m+hi_cloud+hujan_total+low_cloud_1+low_cloud_2+
low_cloud_3+mid_cloud+mslp+rhum2m+shum2m+sur_press+sur_vis_1+
sur_vis_2+temp2m_1+temp2m_2+tot_cloud+uwind10m+vwin
d10m+wind_gust_1+wind_gust_2,data=as.data.frame(tr),lambda=as.numeric(lambda3))
ridge.rh.hat<-coef(ridge.rh)[2]*tr[,1] +
coef(ridge.tmaks)[3]*tr[,2] + coef(ridge.tmaks)[4]*tr[,3] +
coef(ridge.tmaks)[5]*tr[,4]+ coef(ridge.tmaks)[6]*tr[,5] +
coef(ridge.tmaks)[7]*tr[,6] + coef(ridge.tmaks)[8]*tr[,7] +
coef(ridge.tmaks)[9]*tr[,8] + coef(ridge.tmaks)[10]*tr[,9] +
coef(ridge.tmaks)[11]*tr[,10]+ coef(ridge.tmaks)[12]*tr[,11] +
+coef(ridge.tmaks)[13]*tr[,12]+coef(ridge.tmaks)[14]*tr[,13] +
coef(ridge.tmaks)[15]*tr[,14]+coef(ridge.tmaks)[16]*tr[,15] +
+coef(ridge.tmaks)[17]*tr[,16]+ coef(ridge.tmaks)[18]*tr[,17] +
+coef(ridge.tmaks)[19]*tr[,18]+coef(ridge.tmaks)[20]*tr[,19] +
coef(ridge.tmaks)[21]*tr[,20]

obs<-read.csv("F:/KULIAH/SEMESTER 8/TA/DATA TA/
HASANUDDIN/DATA OBSERVASI
HASANUDDIN.csv",header=T,sep = ";")
a=vector(mode="numeric",length=1)
b=vector(mode="numeric",length=1)
for (i in 1:3){
a[i]=mean(obs[,i])
b[i]=sd(obs[,i])}
RIDGE.Tmax=(ridge.tmaks.hat*b[1])+a[1]
RIDGE.Tmin=(ridge.tmin.hat*b[2])+a[2]
RIDGE.RH=(ridge.rh.hat*b[3])+a[3]

```

```
hasilRIDGE=cbind(RIDGE.Tmax,RIDGE.Tmin,RIDGE.RH)
write.csv(hasilRIDGE,"F:/KULIAH/SEMESTER 8/TA/DATA TA
/Hasil MOS HASANUDDIN/HASIL RIDGE HASANUDDIN.csv")

#Persamaan regresi Ridge
ridge.tmaks$coef
ridge.tmin$coef
ridge.rh$coef
```

Lampiran 20. Program Pemodelan EMOS

```
#-----#EMOS dengan n=351 hari dan training=40#-----
library(ensembleMOS)
ensMOStest=read.csv("F:/KULIAH/SEMESTER 8/TA/DATA
TA/INPUT EMOS/Tmaks Hasanuddin.csv",sep=";",header=T)
data=ensMOStest
T=40
n=4
tgl=data$vdate
start=which(data$vdate==tgl)
jmlh=length(start)
jmlh
test=jmlh-T
test
data1=data[,1:4]
y1=data[,5]
x=matrix(c(0),test,n)
y=vector(mode="numeric",length=test)
x=as.matrix(data1[(T+1):jmlh,])
y=y1[(T+1):jmlh]
variabel=cbind(x,y)
write.csv(variabel,"F:/KULIAH/SEMESTER 8/TA/DATA
TA/OUTPUT EMOS/HAS TMAKS/variabel Tmaks Hasanuddin T
40.csv")

#data ensemble member
emosdata=ensembleData(forecasts=data1,dates=data[,"vdate"],
observations=y1,forecastHour = 24,initializationTime="00")

#Prediksi EMOS dengan lead time
emosfit=ensembleMOS(emosdata,model="normal",trainingDays=T)

#nilai intercept regresi EMOS
intercept=as.vector(emosfit$a)
Intercept1=intercept[-312]
write.csv(Intercept1,"F:/KULIAH/SEMESTER 8/TA/DATA
TA/OUTPUT EMOS/HAS TMAKS/intercept Tmaks Hasanuddin T
40.csv")
```

```
nilai koefisien regresi EMOS
koeff=emosfit$B
koef=as.matrix(koeff)
write.csv(koef,"F:/KULIAH/SEMESTER 8/TA/DATA TA/OUTPUT
EMOS/HAS TMAKS/koefisien Tmaks Hasanuddin T 40.csv")
k1=vector(mode="numeric",length=test)
k2=vector(mode="numeric",length=test)
k3=vector(mode="numeric",length=test)
k4=vector(mode="numeric",length=test)
i=1
for (j in 1:test){
  k1[j]=koeff[i]
  k2[j]=koeff[i+1]
  k3[j]=koeff[i+2]
  k4[j]=koeff[i+3]
  i=i+4
}
koefisien=cbind(k1,k2,k3,k4)
write.csv(koefisien,"F:/KULIAH/SEMESTER 8/TA/DATA
TA/OUTPUT EMOS/HAS TMAKS/parameter Tmaks Hasanuddin T
40.csv")

#Rata-rata prediksi EMOS
mean_emos=as.vector(Intercept1+(k1*(x[,1]))+(k2*(x[,2]))+(k3*(x[,3]
))+ (k4*(x[,4])))
mean_ens=as.vector(((x[,1]+x[,2]+x[,3]+x[,4]))/n)
write.csv(mean_emos,"F:/KULIAH/SEMESTER 8/TA/DATA
TA/OUTPUT EMOS/HAS TMAKS/mean emos Tmaks Hasanuddin T
40.csv")
write.csv(mean_ens,"F:/KULIAH/SEMESTER 8/TA/DATA
TA/OUTPUT EMOS/HAS TMAKS/mean ens Tmaks Hasanuddin T
40.csv")

#Varians prediksi EMOS
c1=as.vector(emosfit$c)
d1=as.vector(emosfit$d)
c=c1[-312]
d=d1[-312]
parameter_var=cbind(c1,d1)
```

```

write.csv(parameter_var,"F:/KULIAH/SEMESTER 8/TA/DATA
TA/OUTPUT EMOS/HAS TMAKS/parameter varian EMOS Tmaks
Hasanuddin T 40.csv")
obs=y1
var_ens=as.vector((((x[,1]-mean_ens)^2)+((x[,2]-
mean_ens)^2)+((x[,3]-mean_ens)^2)+((x[,4]-mean_ens)^2))/n)
var_emos=c+(d*var_ens)
write.csv(var_ens,"F:/KULIAH/SEMESTER 8/TA/DATA
TA/OUTPUT EMOS/HAS TMAKS/var ens Tmaks Hasanuddin T
40.csv")
write.csv(var_emos,"F:/KULIAH/SEMESTER 8/TA/DATA
TA/OUTPUT EMOS/HAS TMAKS/var emos Tmaks Hasanuddin T
40.csv")
parValues <- pars(emosfit,emosdata)
write.csv(parValues,"F:/KULIAH/SEMESTER 8/TA/DATA
TA/OUTPUT EMOS/HAS TMAKS/parValues Tmaks Hasanuddin T
40.csv")

#Kriteria model terbaik
#CRPS
nilai_CRPS=crps(emosfit,emosdata)
write.csv(nilai_CRPS,"F:/KULIAH/SEMESTER 8/TA/DATA
TA/OUTPUT EMOS/HAS TMAKS=nilai CRPS Tmaks Hasanuddin T
40.csv")
mean_CRPS=CRPS(emosfit,emosdata)

#RMSE
resi_PCR=vector(length=test)
resi_PLSR=vector(length=test)
resi_Stepwise=vector(length=test)
resi_Ridge=vector(length=test)
resi_EMOS=vector(length=test)
for (i in 1:test){
  resi_PCR[i]=(y[i]-x[i,1])^2
  res1=as.vector(resi_PCR)
  resi_PLSR[i]=(y[i]-x[i,2])^2
  res2=as.vector(resi_PLSR)
  resi_Stepwise[i]=(y[i]-x[i,3])^2
  res3=as.vector(resi_Stepwise)
  resi_Ridge[i]=(y[i]-x[i,4])^2
  res4=as.vector(resi_Ridge)
  resi_EMOS[i]=(y[i]-mean_emos[i])^2
  res5=as.vector(resi_EMOS)
}

```

```
RMSE_PCR=sqrt(sum(res1)/test)
RMSE_PLSR=sqrt(sum(res2)/test)
RMSE_Stepwise=sqrt(sum(res3)/test)
RMSE_Ridge=sqrt(sum(res4)/test)
RMSE_EMOS=sqrt(sum(res5)/test)
RMSE=list(RMSE_PCR=RMSE_PCR,RMSE_PLSR=RMSE_PLSR,
RMSE_Stepwise=RMSE_Stepwise,
RMSE_Ridge=RMSE_Ridge,RMSE_EMOS=RMSE_EMOS)
write.csv(RMSE,"F:/KULIAH/SEMESTER 8/TA/DATA
TA/OUTPUT EMOS/HAS TMAKS/nilai RMSE Tmaks Hasanuddin
T 40.csv")
```

Lampiran 21. Program Taksiran Interval PDF Prediksi Terkalibrasi

```
#COVERAGE DAN RANK HISTOGRAM
forecast=read.csv("F:/KULIAH/SEMESTER 8/TA/DATA TA/INPUT EMOS/COV PDF RANK HAS/PDF Tmaks Hasanuddin T 40.CSV",sep=";",header=T)
tgl=forecast$vdate
start=which(forecast$vdate==tgl)
jmlh=length(start)
jmlh
x=forecast[,1:4]
fore_PCR=forecast[,1]
fore_PLSR=forecast[,2]
fore_STEPWISE=forecast[,3]
fore RIDGE=forecast[,4]
y=forecast[,5]
mean_emos=forecast[,6]
var_emos=forecast[,7]
var_ens=forecast[,8]
forecast[43,]

#Cek missing value
is.na(fore_PCR)
is.na(fore_PLSR)
is.na(fore_STEPWISE)
is.na(fore_RIDGE)
is.na(var_ens)

#Plot PDF
s=100000
s1=rnorm(s,fore_PCR[43],var_ens[43])
s2=rnorm(s,fore_PLSR[43],var_ens[43])
s3=rnorm(s,fore_STEPWISE[43],var_ens[43])
s4=rnorm(s,fore_RIDGE[43],var_ens[43])
d1=density(s1)
d2=density(s2)
d3=density(s3)
d4=density(s4)
mix=rnorm(s,mean_emos[43],sqrt(var_emos[43]))
dmix=density(mix)
min=min(mix,mix-2)
max=max(mix,mix+2)
```

```
#Nilai Interval PDF
lower=mean_emos[43]-1.96*sqrt(var_emos[43])
lower
upper=mean_emos[43]+1.96*sqrt(var_emos[43])
upper
y[43]

#Plot PDF
plot(dmix,xlim=c(min,max),xlab="temperature",ylab="EMOS
predictive PDF",main="",col="red",lwd=5)
abline(v=x[43,1],col="orange",lwd=2)
abline(v=x[43,2],col="blue",lwd=2)
abline(v=x[43,3],col="green",lwd=2)
abline(v=x[43,4],col="brown",lwd=2)
abline(v=y[43],col="black",lwd=3)
abline(v=mean_emos[43],col="red",lty=2)
abline(v=lower,col="black",lty=2)
abline(v=upper,col="black",lty=2)
lines(x=c(x[43,1],x[43,2],x[43,3],x[43,4]),y=c(0.1,0.1,0.1,0.1),col="bl
ack",type="o",xlab="",ylab="",main="")
ind=c("orange","blue","green","brown","red","black","black")
legend("topright",legend=c("PCR","PLSR","Stepwise","Ridge","EMO
S","y.,""95%CI EMOS"),lty=c(1,1,1,1,1,3),col=c(ind),ncol=1,
text.font=4,cex=0.6)
```

Lampiran 22. Surat Pernyataan Penggunaan Data

SURAT PERNYATAAN

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

Nama : Desi Erliana Sari

NRP : 062114 4000 0079

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

Sumber : Data Penelitian Sutikno dengan Judul “Pengembangan Model Output Statistik Dengan Pendekatan Linear dan Non-Linear Dalam Antisipasi Bencana Hidrometeorologi”

Keterangan : 1. Data temperatur maksimum, temperatur minimum dan kelembaban udara harian pada Stasiun Meteorologi Hasanuddin dan Pattimura periode 2 Januari 2015 – 10 Desember 2016.
2. Output data NWP WRF-EMS periode 2 Januari 2015 – 10 Desember 2016.

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

Mengetahui,
Pembimbing Tugas Akhir

Dr. Sutikno, S.Si, M.Si
NIP. 19710313 199702 1 001

Surabaya,
Mahasiswa

Desi Erliana Sari
NRP.062114 4000 0079

BIODATA PENULIS



Desi Erliana Sari lahir pada 20 Desember 1995 di Banyuwangi. Penulis merupakan anak kedua dari dua bersaudara. Penulis telah menempuh pendidikan formal di TK AL-Bukhori Genteng (2000-2002), SD Negeri 2 Kaligondo (2002-2008), SMP Negeri 2 Genteng (2008-2011), dan SMA Negeri 1 Genteng (2011-2014). Penulis melanjutkan studi jenjang S1 di jurusan Statistika Institut Teknologi Sepuluh Nopember Surabaya.

Beberapa organisasi yang pernah diikuti penulis adalah sebagai staf Hubungan Luar HIMASTA-ITS 2015/2016, Sekdep Hubungan Luar HIMASTA-ITS 2016/2017,. Pengalaman kepanitian maupun kegiatan yang telah Penulis jalani adalah Bendahara *Statistics in Sharing* 2016, Bendahara HIMASTA-ITS *Build the Network* 2016, *Public Relation PRS* 2016, *Leadership Organization Training* 2016, Surveyor MPM, serta kerja praktek di BMKG (2017). Dari pengalaman tersebut, penulis belajar membagi waktu, bertanggung jawab, menghargai orang lain, serta mengabdi dan memberikan yang terbaik. Bagi pembaca yang memiliki saran, kritik, atau ingin berdiskusi dengan penulis terkait konten materi Tugas Akhir, dapat menghubungi email penulis yang tertera sebagai berikut.
email:desierliananasari@gmail.com