TUGAS AKHIR – SS141501

MULTIVARIATE ADAPTIVE REGRESSION SPLINE UNTUK PRAKIRAAN CUACA JANGKA PENDEK DENGAN PRA-PEMROSESAN *INDEPENDENT COMPONENT ANALYSIS*

BINTI FATMAWATI
NRP 1315 105 049

Dosen Pembimbing
Dr. Sutikno, S.Si., M.Si.
Shofi Andari, S.Stat., M.Si.

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

TUGAS AKHIR – SS141501

MULTIVARIATE ADAPTIVE REGRESSION SPLINE UNTUK PRAKIRAAN CUACA JANGKA PENDEK DENGAN PRA-PEMROSESAN *INDEPENDENT COMPONENT ANALYSIS*

BINTI FATMWATI
NRP 1315 105 049

Dosen Pembimbing
Dr. Sutikno, S.Si., M.Si.
Shofi Andari, S.Si., M.Si.

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

FINAL PROJECT – SS141501

MULTIVARIATE ADAPTIVE REGRESSION SPLINE FOR SHORT-TERM WEATHER PREDICTING WITH INDEPENDENT COMPONENT ANALYSIS PRE-PROCESSING

BINTI FATMAWATI
NRP 1315 105 049

Supervisors
Dr. Sutikno, S.Si., M.Si.
Shofi Andari, S.Si., M.Si.

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

LEMBAR PENGESAHAN

MULTIVARIATE ADAPTIVE REGRESSION SPLINE* UNTUK PRAKIRAAN CUACA JANGKA PENDEK DENGAN PRA-PEMROSESAN *INDEPENDENT COMPONENT ANALYSIS

TUGAS AKHIR
Diajukan untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Sains
pada
Program Studi Sarjana Departemen Statistika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember

Oleh :
Binti Fatmawati
NRP. 1315 105 049

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

Shofi Andari, S.Stat., M.Si. ( )
NIP. 19871207 201404 2 001

Mengetahui,
Kepala Departemen

Dr. Suhartono
NIP. 19710929 199512 1 001

KEMENTERIAN RISET, TEKNOLOGI, DAN PENDIDIKAN TINGGI
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
DEPARTEMEN STATISTIKA

SURABAYA, JULI 2017

MULTIVARIATE ADAPTIVE REGRESSION SPLINE* UNTUK PRAKIRAAN CUACA JANGKA PENDEK DENGAN PRA-PEMROSESAN *INDEPENDENT COMPONENT ANALYSIS

Nama Mahasiswa : Binti Fatmawati
NRP : 1315 105 049
Departemen : Statistika
Dosen Pembimbing 1 : Dr. Sutikno, S.Si., M.Si.
Dosen Pembimbing 2 : Shofi Andari, S.Stat., M.Si.

Abstrak

Informasi tentang prakiraan cuaca yang cepat dan tepat menjadi suatu hal yang penting. Informasi cuaca menjadi bagian yang tidak dapat dipisahkan dari aktifitas manusia dan mempengaruhi berbagai bidang kehidupan. Prakiraaan cuaca selama ini dengan acuan data sebelumnya dan melihat prospek yang akan datang dengan memanfaatkan data komponen cuaca Numerical Weather Prediction (NWP). Namun NWP menghasilkan ramalan yang bias terutama untuk lokasi dengan topografi berbukit dan vegetasi yang kompleks. Oleh karena itu, perlu dilakukan pra-pemrosesan secara statistik (statistical post processing) untuk mengoptimalkan pemanfaatan output NWP dengan menggunakan Model Output Statistics (MOS). Data yang digunakan meliputi observasi cuaca permukaan dan data model NWP di Stasiun Soekarno Hatta dan Juanda. Data permukaan selanjutnya digunakan sebagai variabel respon yaitu maksimum, suhu minimum, dan kelembapan rata-rata harian serta data NWP model WRF-EMS sebagai variabel prediktor. Tahap awal dilakukan reduksi dimensi pengukuran untuk masing-masing variabel NWP dengan Independent Component Analysis (ICA) dan metode regresi yang digunakan adalah Multivariate Adaptive Regression Spline (MARS).

Hasil reduksi di stasiun pengamatan masing-masing menjadi 20 dan 21 komponen. Kemudian hasil reduksi tersebut digunakan untuk pemodelan MARS. Hasil validasi model MARS dengan kriteria RMSEP menunjukkan bahwa variabel Tmaks di stasiun Soekarno Hatta dan Juanda berkriteria buru. Kriteria RMSEP variabel Tmin di Stasiun Soekarno Hatta dan Juanda berkriteria sedang. Pemodelan MARS untuk variabel respon RH pada stasiun Soekarno Hatta berkriteria baik dan Juanda memiliki kriteria buruk. Nilai Percentage Improval (%IM) untuk prediksi Tmaks berkisar antara 23,66%-86,10% yang artinya model MARS dapat mengkoreksi bias NWP sebesar 23,66% sampai 86,10%.

Kata Kunci : Cuaca, ICA, NWP, MARS

(Halaman ini sengaja dikosongkan)

MULTIVARIATE ADAPTIVE REGRESSION SPLINE FOR SHORT-TERM WEATHER PREDICTING WITH INDEPENDENT COMPONENT ANALYSIS PRE-PROCESSING

Student's Name : Binti Fatmawati
Student's ID : 1315 105 049
Department : Statistics
Supervisor 1 : Dr. Sutikno, S.Si., M.Si.
Supervisor 2 : Shofi Andari, S.Stat., M.Si.

Abstract

Information about responsive and right weather prediction is an important issue. Weather information can be dependent from human activity and influence more life aspects. Weather prediction currently refers to the previous data and considering the future prospect utilizing Numerical Weather Prediction (NWP) of data components. However, NWP results biased forecasts especially for the locations with hills topography and complex vegetation. Thus, pre-processing statistically is needed (statistical post processing) in order to optimize the NWP output utilization through the use of Model Output Statistics (MOS). The data that will be used covers surface weather observation and model data NWP in Soekarno Hatta and Juanda Station. Then, the surface data is used as the respond variable that is maximum, minimum temperature, and daily average humidity and NWP data WRF-EMS model as prediction variable.

The first step is reduction dimension measurements for each NWP Variable by using Independet Component Analysis (ICA) and regression method used is Multivariate Adaptive Regression Spline (MARS). The reduction result in observation stations , each of them become 20 and 21 components. The reduction result then is used for MARS modeling. The result of MARS model validation with RMSEP criteria shows that the Tmax variable in Soekarno Hatta and Juanda Stations has bad criteria. The criteria of RMSEP variable Tmin in Soekarno Hatta and Juanda Stations are medium criteria. MARS for RH respond variable of Soekarno Hatta Station has good criteria while Juanda Station has bad criteria. The percentage of improvement score (%IM) is to predict Tmaks ranged from 23,66% - 86,10% that means MARS model is able to correct the biased NWP from 23,66% to 86,10%.

Keywords : Weather, ICA, NWP, MARS

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Puji syukur kepada Allah SWT yang telah melimpahkan karunia dan rahmat-Nya sehingga Tugas Akhir dengan judul "***MULTIVARITE ADAPTIVE REGRESSION SPLINE*** **UNTUK PRAKIRAAN CUACA JANGKA PENDEK DENGAN PRA-PEMROSESAN *INDEPENDENT COMPONENT ANALYSIS*"** dapat terselesaikan. Penulis menyadari bahwa dalam pelaksanaan penyelesaian Tugas Akhir ini tidak terlepas dari bantuan dan dukungan dari berbagai pihak. Oleh karena itu, pada kesempatan ini penulis manyampaikan terimakasih kepada beberapa pihak yang telah membantu dalam penyusunan laporan Tugas Akhir yaitu sebagai berikut.

1. Dr. Sutikno, S.Si., M.Si. selaku dosen pembimbing yang telah memberikan pengarahan, bimbingan, dan saran serta semangat kepada Penulis dalam menyelesaikan Tugas Akhir.
2. Shofi Andari, S.Stat., M.Si. selaku dosen co-pembimbing yang juga senantiasa membimbing dan memberikan arahan hingga terselesaikannya Laporan Tugas Akhir ini.
3. Dr. Bambang Widjanarko Otok., M.Si. dan Dr. rer pol Heri Kuswanto, S.Si., M.Si. selaku penguji yang telah memberikan kritik dan saran demi kesempuraan Tugas Akhir ini.
4. Dr. Suhartono selaku Ketua Jurusan Statistika FMIPA ITS.
5. Seluruh dosen dan karyawan di lingkungan Jurusan Statistika ITS yang telah memberikan banyak ilmu, pengalaman, dan bantuan kepada penulis.
6. Orang tua tercinta, Bapak Moh. Ghafur dan Ibu Umi Nurhayati yang telah melahirkan saya serta adik-adik tercinta Yusril, Muhtar, dan Owi karena mereka semualah motivasi terbesar dalam menyelesaikan laporan Tugas Akhir.
7. Nur yang selalu setia menemani tugas-tugas selama kuliah, Silvi, Ros, Widya, Fasha dan seluruh teman-teman Lintas

Jalur Statistika FMIPA ITS angkatan 2015 yang senantiasa memberikan semangat dan doa sehingga laporan ini dapat terselesaikan.

8. Serta semua pihak yang telah membantu dalam pelaksanaan maupun pembuatan laporan tugas akhir.

Tiada gading yang tak retak. Penulis menyadari bahwa laporan ini tidak luput dari kekurangan, maka kritik dan saran sangat kami harapkan demi perbaikan di masa mendatang. Semoga tulisan ini dapat memberikan manfaat bagi semua pihak.

Surabaya, Juli 2017

Penulis

DAFTAR ISI

Halaman

HALAMAN JUDUL.. i
LEMBAR PENGESAHAN.. iii
ABSTRAK.. v
ABSTRACT vii
KATA PENGANTAR ix
DAFTAR ISI xi
DAFTAR GAMBAR xiii
DAFTAR TABEL.. xv
DAFTAR LAMPIRAN xvii
BAB I PENDAHULUAN
1.1 Latar Belakang 1
1.2 Rumusan Masalah 4
1.3 Tujuan 5
1.4 Manfaat Penelitian... 5
1.5 Batasan Masalah 6
BAB II TINJAUAN PUSTAKA
2.1 Distribusi Normal Multivariat.................................... 7
2.2 *Independent Component Analysis* 8
2.3 *Multivariate Adaptive Regression Spline* 11
2.4 *Numerical Weather Prediction*.................................... 15
2.5 *Model Output Statictics* 17
2.6 Validasi Model 19
2.7 Ukuran Pengoreksi Bias 20
2.7 Suhu dan Kelembapan... 20
BAB III METODOLOGI PENELITIAN
3.1 Sumber Data... 23
3.2 Variabel Penelitian 24
3.3 Struktur Data 27
3.4 Langkah Analisis Data 27
BAB IV ANALISIS DAN PEMBAHASAN
4.1 Karakterisitik Variabel Respon 31
4.2 Uji Distribusi Normal Multivariat............................... 32

4.3 Pemodelan Suhu dan Kelembapan 33
4.3.1 Reduksi Dimensi ICA 33
4.3.2 Pemodelan Suhu dan Kelembapan dengan MARS 35
4.4 Validasi Model MARS 40
4.5 Perbandingan Keakuratan Hasil Prediksi NWP dengan Model MOS 42
BAB V KESIMPULAN DAN SARAN
5.1 Kesimpulan 45
5.2 Saran 45
DAFTAR PUSTAKA 47
LAMPIRAN 51
BIODATA PENULIS 81

DAFTAR GAMBAR

Halaman

Gambar 3.1 Lokasi Stasiun Pengamatan 23
Gambar 3.2 Pengukuran NWP Model WRF EMS dalam grid 3x3 26
Gambar 3.1 Langkah Analisis Data....................................... 29

(Halaman ini sengaja dikosongkan)

DAFTAR TABEL

Halaman

Tabel 2.1 Kriteria Nilai RMSEP... 19
Tabel 3.1 Parameter NWP WRF EMS 24
Tabel 3.2 Struktur Data Penelitian.. 27
Tabel 4.1 Rata-rata dan Standar Deviasi Variabel Respon.... 31
Tabel 4.2 Nilai Eigen dan Varians Kumulatif Variabel Hujan Total dan Dew Point 2m di Stasiun Soekarno Hatta 33
Tabel 4.3 Jumlah Kompoenen Independen Variabel NWP di Stasiun Soekarno Hatta.. 34
Tabel 4.4 Jumlah Kompoenen Independen Variabel NWP di Stasiun Juanda.. 35
Tabel 4.5 Kombinasi Model MARS terbaik di Stasiun Soekarno Hatta.. 36
Tabel 4.6 Nilai R^2 Model MARS di Stasiun Pengamatan...... 40
Tabel 4.7 Nilai Prediksi Tmkas, Tmin, dan RH di Stasiun Soekarno Hatta 41
Tabel 4.8 Kriteria RMSEP di Stasiun Pengamatan 41
Tabel 4.9 Nilai $RMSEP_{NWP}$, $RMSEP_{MOS}$, dan %IM............. 42

(Halaman ini sengaja dikosongkan)

DAFTAR LAMPIRAN

Halaman

Lampiran 1 Data Observasi Stasiun Soekarno Hatta 51
Lampiran 2 Data Observasi Stasiun Juanda 52
Lampiran 3 Data NWP Model WRF-EMS di Stasiun Soekarno Hatta 53
Lampiran 4 Data NWP Model WRF-EMS di Stasiun Juanda.. 55
Lampiran 5 Rata-rata dan Standar Deviasi Variabel Respon di Stasiun Soekarno Hatta 57
Lampiran 6 Rata-rata dan Standar Deviasi Variabel Respon di Stasiun Juanda.. 57
Lampiran 7 Syntax Uji Distribusi Normal Multivariat.......... 57
Lampiran 8 Syntax ICA... 58
Lampiran 9 Hasil Uji Normal Multivariat Variabel Prediktor Stasiun Soekarno Hatta 59
Lampiran 10 Hasil Uji Normal Multivariat Variabel Prediktor Stasiun Juanda 60
Lampiran 11 Jumlah Komponen Independen Variabel NWP di Stasiun Soekarno Hatta 61
Lampiran 12 Jumlah Komponen Independen Variabel NWP di Stasiun Juanda................................... 61
Lampiran 13 Kombinasi Basis Fungsi (BF), Maksimum Interaksi (MI), Minimum Observasi (MO), dan Nilai *Penalty* Pemodelan Tmaks Stasiun Soekarno Hatta 62
Lampiran 14 Kombinasi Basis Fungsi (BF), Maksimum Interaksi (MI), Minimum Observasi (MO), dan Nilai *Penalty* Pemodelan Tmin Stasiun Soekarno Hatta 64
Lampiran 15 Kombinasi Basis Fungsi (BF), Maksimum Interaksi (MI), Minimum Observasi (MO), dan Nilai *Penalty* Pemodelan RH Stasiun Soekarno Hatta 66

Lampiran 16 Kombinasi Basis Fungsi (BF), Maksimum Interaksi (MI), Minimum Observasi (MO), dan Nilai *Penalty* Pemodelan Tmaks Stasiun Juanda 68
Lampiran 17 Kombinasi Basis Fungsi (BF), Maksimum Interaksi (MI), Minimum Observasi (MO), dan Nilai *Penalty* Pemodelan Tmin Stasiun Juanda 70
Lampiran 18 Kombinasi Basis Fungsi (BF), Maksimum Interaksi (MI), Minimum Observasi (MO), dan Nilai *Penalty* Pemodelan RH Stasiun Juanda 70
Lampiran 19 Model MARS Stasiun Soekarno Hatta 74
Lampiran 20 Model MARS Stasiun Juanda 76
Lampiran 21 Nilai Prediksi Tmaks, Tmin, dan RH di Stasiun Soekarno Hatta 78
Lampiran 22 Nilai Prediksi Tmaks, Tmin, dan RH di Stasiun Juanda 78
Lampiran 23 Legalitas Data 79

BAB I
PENDAHULUAN

1.1 Latar Belakang

Informasi cuaca jangka pendek sangat dibutuhkan untuk mengetahui kondisi cuaca hari esok. Informasi cuaca jangka pendek yang penting diantaranya: suhu dan kelembapan. Saat ini pengguna informasi cuaca jangka pendek menuntut untuk dapat memperoleh informasi cuaca jangka pendek secara cepat dan tepat. Mengacu pada kondisi tersebut, perlu dikembangkan prakiraan cuaca jangka pendek yang cepat dan tepat secara operasional (Arfianto, 2006).

Prediksi cuaca saat ini umumnya sudah terkomputerisasi, dimana komputer dapat menghitung interaksi *non-linear* yang rumit antara angin, suhu, kelembapan, dan curah hujan pada ribuan lokasi dan ketinggian di seluruh dunia. Komputer mampu mengeplotkan, menganalisis data, dan melakukan prediksi kondisi cuaca yang akan terjadi dengan menggunakan persamaan gerak atmosfer secara matematik atau dikenal dengan *Numerical Weather Prediction* (NWP) (Stull, 2000). Informasi tentang prakiraan cuaca yang cepat dan tepat menjadi suatu hal yang penting karena cuaca menjadi bagian yang tidak dapat dipisahkan dari aktifitas manusia. Informasi ini mempengaruhi berbagai bidang kehidupan, seperti penentuan masa tanam (pertanian) dan kelayakan keberangkatan pesawat udara maupun kapal laut (transportasi) sehingga kecelakaan akibat cuaca buruk dapat dihindari. Oleh karena itu diperlukan kemampuan dan metode yang efektif dalam prakiraan cuaca, khususnya prakiraan cuaca jangka pendek.

Sejak tahun 2004, BMKG telah melakukan penelitian untuk prakiraan cuaca jangka pendek dengan memanfaatkan data komponen cuaca NWP. Namun NWP menghasilkan ramalan yang bias terutama untuk lokasi dengan topografi berbukit dan vegetasi yang kompleks. *Forcing* lokal NWP lebih dominan

sehingga memberikan informasi cuaca yang bersifat homogen. Akibatnya jika model NWP digunakan untuk meramal cuaca lokal (dimensi rendah) akan menghasilkan ramalan cuaca yang bias (Wilks, 2006). Oleh karena itu, perlu dilakukan pemrosesan secara statistik (*statistical post processing*) untuk mengoptimalkan pemanfaatan *output* NWP dalam meminimalisir bias pada ramalan. Salah satu upaya untuk mengoptimalkan pemanfaatan *output* model NWP adalah dengan menggunakan *Model Output Statistics* (MOS) (Clark, Hay, & Whitaker, 2001). MOS merupakan model yang menghubungkan antara variabel respon (hasil observasi cuaca) dengan variabel prediktor (parameter NWP) dengan model berbasis regresi (Nichols, 2008-2009). MOS menentukan hubungan statistik antara variabel respon model NWP pada beberapa proyeksi waktu (Glahn & Lowry, 1972).

Data NWP diambil dalam 9 grid pengukuran di setiap lokasi untuk masing-masing variabel, sehingga perlu dilakukan pereduksian variabel di setiap lokasi untuk masing-masing variabel. Reduksi dimensi merupakan salah satu hal yang harus diperhatikan dalam penyusunan MOS. Reduksi dimensi yang sering digunakan dalam pemodelan MOS adalah *Principal Component Analysis* (PCA). Saat ini, terdapat suatu metode reduksi dimensi yang tengah dikembangkan, yaitu *Independent Component Analysis* (ICA). ICA merupakan salah satu metode reduksi yang bertujuan untuk representasi linier dari data *nongaussian* sehingga komponen-komponennya independen secara statistik (Hyvarinen & Oja, 2000). Permasalahan lain dalam MOS adalah pemilihan metode yang sesuai terkait dengan pemodelan variabel independen (*output* NWP) terhadap variabel dependen yang diteliti.

Dalam menjelaskan pola hubungan antara variabel dependen dan variabel independen dapat digunakan kurva regresi. Pendekatan kurva regresi yang sering digunakan adalah pendekatan regresi parametrik, dimana diasumsikan bentuk kurva regresi diketahui berdasarkan teori yang dapat memberikan informasi hubungan (Drapper & Smith, 1992). Pemodelan dengan

menggunakan metode regresi linier membutuhkan asumsi yang sangat ketat, diantaranya: kurva regresi yang harus diketahui, kenormalan sisaan, dan kehomogenan ragam sisaan. Namun sering kali data iklim dan cuaca melanggar asumsi terutama bentuk kurva regresinya tidak diketahui (Sutikno, 2002). Oleh karena itu, penanganan terhadap data cuaca dilakukan dengan metode nonparametrik karena metode tersebut tidak ketat akan asumsi. Pemodelan menggunakan MOS dengan respon suhu minimum, suhu maksimum, dan kelembapan telah dilakukan oleh Setiawan (2015) menggunakan *Multivariate Adaptive Regression Spline* (MARS). Penelitian tersebut menyimpulkan bahwa bahwa prediksi model MARS lebih akurat daripada model NWP. Penelitian lain tentang MOS dengan respon kejadian hujan telah dilakukan oleh Priastuti (2013) menggunakan regresi logistik ordinal. Penelitian tersebut menyimpulkan bahwa model MOS dengan regresi logistik ordinal menghasilkan ketepatan yang cukup baik untuk klasifikasi kejadian hujan. Permasalahan dalam MOS yaitu terkait fungsi hubungan dan metode reduksi variabelnya. Oleh karena itu diperlukan beberapa metode untuk mengatasi permasalahan dalam MOS, sehingga diharapkan akan mendapatkan model dengan bias yang kecil. Metode non-parametrik tidak bergantung pada asumsi tertentu sehingga memberikan fleksibilitas yang lebih besar dalam menganalisa data, tetapi tetap mempunyai tingkat akurasi yang tinggi dan mudah dalam penggunaannya. Pendekatan nonparametrik juga dapat menghasilkan prediksi variabel respon yang akurat karena dapat mengurangi efek outlier pada model (Budiantara, Suryadi, Otok, & Guritno, 2006).

Multivariate Adaptive Regression Spline (MARS) adalah pendekatan untuk regresi multivariat nonparametrik yang diperkenalkan oleh Friedman (1991). MARS merupakan metode yang tidak bergantung pada asumsi bentuk kurva tertentu, sehingga memberikan fleksibilitas yang lebih besar dalam penggunaannya. Kelebihan lain metode MARS adalah tidak dipengaruhi oleh jumlah data yang hilang. Hal ini dikarenakan

MARS secara otomatis menciptakan suatu indikator nilai yang hilang untuk setiap variabel dengan nilai yang hilang. MARS juga dirancang untuk dapat menangkap order interaksi yang lebih tinggi atau untuk pemodelan data berdimensi tinggi (Friedman, 1991). Secara umum, iklim dan curah hujan adalah fenomena alam yang bersifat nonlinier karena terdapat perilaku pada periode tertentu sehingga tidak dapat diprediksi secara pasti. MARS dapat digunakan untuk mengatasi masalah nonlinier pada data iklim yang berupa data kontinu, yaitu dengan beberapa fungsi basis *splines* (Priambudi, 2006). Penelitian oleh Setiawan (2015) tentang MARS dengan pra-pemrosesan PCA menunjukkan bahwa nilai RMSEP model MOS menggunakan metode MARS lebih kecil daripada RMSEP model NWP untuk semua unsur cuaca (T_{MAKS}, $T_{MIN,}$ dan RH). Studi perbandingan reduksi dimensi pada *post-processing* peramalan unsur cuaca antara PCA dan ICA juga telah dilakukan oleh Anuravega (2013) yang menunjukkan bahwa secara keseluruhan MOS ICA menghasilkan presisi rendah dan akurasi tinggi, sedangkan MOS PCA memiliki presisi tinggi dan akurasi rendah.

Penelitian ini membahas pemodelan MOS dengan MARS. Sebelum dilakukan pemodelan dengan MARS, terlebih dahulu dilakukan pengujian distribusi normal multivariat dan pra-pemrosesan data yaitu reduksi dimensi variabel dengan ICA. Selanjutnya hasil pemodelan MARS melalui pra-pemrosesan ICA dibandingkan dengan hasil model NWP sehingga diperoleh akurasi hasil prediksi suhu maksimum (Tmaks), suhu minimum (Tmin), dan kelembapan (RH) dengan metode MARS.

1.2 Rumusan Masalah

Hasil prakiraan NWP dengan resolusi tinggi disuatu tempat seringkali menghasilkan bias yang besar terutama untuk wilayah dengan topografi dan tutupan vegetasi yang kompleks. Data NWP diambil dalam 9 grid pengukuran di setiap lokasi untuk masing-masing variabel, sehingga perlu dilakukan pereduksian variabel di setiap lokasi untuk masing-masing variabel. ICA merupakan

salah satu metode reduksi yang bertujuan untuk representasi linier dari data *nongaussian* sehingga komponen-komponennya independen secara statistik.

Salah satu metode yang digunakan dalam prediksi parameter cuaca yang tidak dapat diamati secara langsung oleh NWP adalah dengan pemodelan MOS. MOS merupakan model yang menghubungkan antara variabel respon (hasil observasi cuaca) dengan variabel prediktor (parameter NWP) dengan model berbasis regresi. Karena data cuaca seringkali melanggar asumsi terutama bentuk kurva regresinya tidak diketahui, maka dilakukan metode nonparametrik. MARS merupakan metode pendekatan regresi nonparamterik yang dapat mengatasi masalah nonlinier pada data iklim yang berupa data kontinu. Berdasarkan uraian tersebut, maka dalam penelitian ini akan dianalisis mengenai pemodelan prediksi cuaca dengan MARS melalui pra-pemrosesan ICA. Kemudian penghitungan akurasi hasil prediksi cuaca dengan metode MARS serta kebaikan hasil prediksi model NWP dan prediksi model MARS dengan kriteria %IM (*Percentage Improval*).

1.3 Tujuan

Tujuan penelitian ini adalah untuk mendapatkan model prediksi cuaca dengan MARS melalui pra-pemrosesan ICA, untuk mengetahui akurasi hasil prediksi cuaca dengan metode MARS, dan untuk mengetahui kebaikan hasil prediksi model NWP dan prediksi model MARS dengan kriteria %IM.

1.4 Manfaat

Manfaat dalam penelitian ini adalah sebagai berikut.

1. Bagi BMKG, diharapkan dapat dijadikan sebagai bahan acuan dalam memodelkan prakiraan cuaca jangka pendek, khususnya bidang transportasi udara dan laut. Prakiraan yang akurat, antisipasi resiko bencana karena faktor cuaca akan berkurang (terhindar).

2. Bagi ilmu pengetahuan, dapat menambah wawasan aplikasi ilmu statistika di bidang meteorologi tentang MOS dengan metode MARS melalui tahap pra-pemrosesan ICA.

1.5 Batasan Masalah

Pada penelitian ini dilakukan di dua lokasi stasiun pengamatan yaitu Soekarno Hatta dan Juanda. Data NWP yang digunakan adalah hasil model aplikasi *Weather Reasearch and Forecasting-Environment Modelling System* (WRF-EMS). Periode data yang digunakan dimulai dari 1 Januari 2015 sampai 31 Desember 2016.

BAB II
TINJAUAN PUSTAKA

2.1 Distribusi Normal Multivariat

Distribusi normal multivariat adalah perluasan dari distribusi normal univariat sebagai aplikasi pada variabel-variabel yang mempunyai hubungan. Dalam analisis multivariat, asumsi normal multivariat diperlukan karena untuk memastikan data pengamatannya mengikuti distribusi normal agar statistik inferensia dapat digunakan dalam menganalisis data tersebut.

Misalkan $\mathbf{x}^T = (\mathbf{x}_1, \mathbf{x}_2, \cdots, \mathbf{x}_m)$ adalah vektor yang mengikuti distribusi normal multivariat dari pengamatan terhadap p variabel maka didapat fungsi padatan peluang untuk vektor $\mathbf{x}^T$ dengan bentuk :

$$f_x(\mathbf{x}) = (2\pi)^{-\frac{1}{2}p} |v_0|^{-\frac{1}{2}} \exp\left\{-\frac{1}{2}(\mathbf{x}-\bar{\mathbf{x}})' v_0^{-1} (\mathbf{x}-\bar{\mathbf{x}})\right\} \qquad (2.1)$$

dimana $\bar{\mathbf{x}} = E(\mathbf{x}_i)$, untuk $i = 1,2,\ldots,m$ dan v_0 adalah matriks varians kovarians dari $\mathbf{x}_1,\mathbf{x}_2,\ldots,\mathbf{x}_m$ dengan elemen-elemen diagonal σ_{ii} adalah $\sigma_{11}, \sigma_{22}, \ldots, \sigma_{mm}$ yang merupakan varians dari $\mathbf{x}_1,\mathbf{x}_2,\ldots,\mathbf{x}_m$ dan elemen-elemen nondiagonal σ_{ij} yang merupakan kovarians dari $\mathbf{x}_1,\mathbf{x}_2,\ldots,\mathbf{x}_m$ dan mengikuti persamaan $\sigma_{ij} = \rho_{ij}(\sigma_{ii}\sigma_{jj})^{1/2}$.

Untuk mengetahui kenormalan data, salah satu pengujian yang dilakukan adalah uji Saphiro-Wilk untuk normal multivariat. Prosedur pengujiannya adalah sebagai berikut.

Hipotesis

H_0 : Data berdistribusi normal multivariat

H_1 : Data tidak berdistribusi normal multivariat

Statistik Uji

Misal $\mathbf{c}^T = (\mathbf{c}_1, \mathbf{c}_2, \ldots, \mathbf{c}_m)$ adalah vektor dari nilai ekspektasi normal standar dan $\mathbf{V} = (\mathbf{V}_{ij})$ adalah matriks kovarians berukuran mxm.

$E(\mathbf{x}_i)=\mathbf{c}_i$ dengan $i=1,2,\ldots,m$; $\mathrm{cov}(x_i,x_j)=v_{ij}(i,j=1,\ldots m)$ dimana $x_1<x_2<\ldots<x_m$ adalah sampel random dari distribusi normal standar $N(0,1)$. Misal $y^{'}=(y_1,\ldots,y_m)$ adalah sampel random dimana kenormalan dengan uji MVW menggunakan order $y_{(1)}<y_{(2)}<\ldots<y_{(m)}$. Nilai MVW diperoleh sebagai berikut.

$$MVW=\frac{\left[\sum_{i=1}^{m}b_i y_{(i)}\right]^2}{\sum_{i=1}^{m}(y_i-\bar{y})^2} \tag{2.2}$$

dengan $b^T=(b_1,\ldots,b_m)=c^T v^{-1}\left[(c^{'}v^{-1})(v^{-1}c)\right]^{-1/2}$

Kriteria penolakan H_0 adalah nilai signifikansi (*p-value*) lebih besar dari taraf signifikansi α (Royston, 1982).

2.2 *Independent Component Analysis*

Pada beberapa disiplin ilmu, permasalahan utama adalah menemukan representasi yang tepat dari data multivariat. Untuk beberapa alasan komputasi dan kesederhanaan konsep, seringkali representasi diperoleh dari tranformasi linear menggunakan data asli. Dengan kata lain, setiap komponen dari representasi adalah sebuah kombinasi linear dari variabel aslinya. Terdapat beberapa metode transformasi linier yang telah diketahui meliputi *Principal Component Analysis* (PCA), analisis faktor, dan *projection pursuit* (Hyvarinen & Oja, 2000). ICA merupakan salah satu metode reduksi yang bertujuan untuk representasi linier dari data *non-gaussian* sehingga komponen-komponennya independen secara statistik.

Menurut Jutten dan Herault (1991); Comon (1994) dalam Hyvarinen (2000), untuk menetapkan ICA dengan teliti dapat menggunakan model statistika "variabel laten". Misal sebanyak n dimensi $x_1,x_2,\ldots,x_n$ dari n komponen independen, maka persamaan umumnya sebagai berikut.

$$x_j = a_{j1}s_1 + a_{j2}s_2 + \ldots + a_{jn}s_n, \text{ untuk semua } j \quad (2.3)$$

dalam notasi vektor matriks, vektor random pengamatan $\mathbf{x} = [x_1, x_2, \ldots, x_n]^T$, yang n elemen-elemennya merupakan gabungan dari elemen independen n dari vektor random $[s_1, s_2, \ldots, s_n]^T$. Maka diberikan notasi matriks berikut.

$$\mathbf{x} = \mathbf{A}\mathbf{s} \quad (2.4)$$

dimana vektor $\mathbf{x}$ adalah kombinasi linier dari komponen independen *non-gaussian*, vektor $\mathbf{s}$ mengandung komponen independen dan $\mathbf{A}$ mewakili matriks linier gabungan (*mixing matrix*) mxm.

Model ICA adalah model generatif yang menggambarkan bagaimana data pengamatan dihasilkan dengan prosses penggabungan (*mixing*) komponen s_i (Hyvarinen, 2000). Komponen-komponen independen adalah variabel laten, artinya komponen tersebut tidak dapat diamati secara langsung. Matriks $\mathbf{A}$ diasumsikan tidak diketahui. Semua yang diamati adalah vektor random $\mathbf{x}$, dan peneliti harus mengestimasi $\mathbf{A}$ dan $\mathbf{s}$.

Penggunaaan ICA membutuhkan asumsi yang sangat sederhana, yaitu komponen $\mathbf{s}$ adalah independen secara statistik. Komponen independen memiliki asumsi berdistribusi *non-Gaussian*. Setelah mengestimasi matriks $\mathbf{A}$, dapat dihitung matriks *unmixing* $\mathbf{W}$ (invers dari $\mathbf{A}$) sehingga persamaan ICA adalah sebagai berikut.

$$\mathbf{s} = \mathbf{W}\mathbf{x} \quad (2.5)$$

Adapun tahap *pre-processing* ICA adalah sebagai berikut.

1. *Centering*

Pre-pocessing yang utama dan penting adalah pemusatan $\mathbf{x}$, misalnya pengurangan vektor rata-rata $\mathbf{m} = E\{\mathbf{x}\}$ sehingga untuk membuat $\mathbf{x}$ memiliki rata-rata nol. Jika rata-rata nol, maka dapat dihitung nilai ekspektasi sebagaimana pada persamaan 2.4. Setelah mengestimasi matriks $\mathbf{A}$ dengan pemusatan data, estimasi dapat dilengkapi dengan menambahkan vektor rata-rata

dari $\mathbf{s}$ menuju estimasi pemusatan $\mathbf{s}$. Rata-rata vektor $\mathbf{s}$ diberikan oleh $\mathbf{A}^{-1}\mathbf{m}$, dimana $\mathbf{m}$ adalah pengurangan dari rata-rata pada proses *preprosessing*.

2. *Whitening*

Proses *whitening* ini dilakukan pada variabel yang diamati. Sebelum diaplikasikan algoritma ICA (setelah proses *centering*), dilakukan transformasi. Diawali dari observasi vektor $\mathbf{x}$ yang linier sehingga diperoleh vektor $\tilde{\mathbf{x}}$ yang telah di *whitening*. Misalnya komponen yang tidak berkorelasi dan variansnya memiliki satuan yang sama sehingga matriks covarians dari $\tilde{\mathbf{x}}$ adalah matriks identitas ($E\{\tilde{\mathbf{x}}\tilde{\mathbf{x}}^T\} = \mathrm{I}$).

Salah satu metode *whitening* yang sering dilakukan adalah menggunakan *eigen-value decomposition* (EVD) dari matriks kovarians $E\{\tilde{\mathbf{x}}\tilde{\mathbf{x}}^T\} = \mathbf{EDE}^T$, dimana E adalah matriks ortogonal dari vektor eigen $E\{\tilde{\mathbf{x}}\tilde{\mathbf{x}}^T\}$ dan $\mathbf{D} = diag(d_1, \ldots, d_n)$. $E\{\tilde{\mathbf{x}}\tilde{\mathbf{x}}^T\}$ dapat diestimasi dari standarisasi sampel $\mathbf{x}(1), \ldots, \mathbf{x}(T)$. Proses *whitening* dapat diselesaikan dengan persamaan berikut.

$$\tilde{\mathbf{x}} = \mathbf{ED}^{-1/2}\mathbf{E}^T\mathbf{x} \tag{2.6}$$

dimana matriks $\mathbf{D}^{-1/2} = diag(d_1^{-1/2}, \ldots, d_n^{-1/2})$ sehingga mudah dalam pengecekan persamaan $E\{\tilde{\mathbf{x}}\tilde{\mathbf{x}}^T\} = \mathrm{I}$. Transformasi *whitening* matriks gabungan (*mixing*) menjadi persamaan 2.7.

$$\tilde{\mathbf{x}} = \mathbf{ED}^{-1/2}\mathbf{E}^T\mathbf{As} = \tilde{\mathbf{A}}\mathbf{s} \tag{2.7}$$

Proses FastICA tergantung pada skema iterasi titik yang ditentukan untuk menemukan *non-gausanity* maksimum dari $\mathbf{w}^T\mathbf{x}$ Berikut ini algoritma dari FastICA.

a. Memilih sebuah *initial vector* $\mathbf{w}$.
b. Membentuk $\mathbf{w}^+ = E\{\mathbf{x}g(\mathbf{w}^T\mathbf{x})\} - E\{g'(\mathbf{w}^T\mathbf{x})\}\mathbf{w}$
c. Membentuk $\mathbf{w} = \mathbf{w}^+ / \|\mathbf{w}^+\|$
d. Jika $\mathbf{w}$ tidak konvergen kembali ke langkah 2.

2.3 *Multivariate Adaptive Regression Spline*

Mulitivariate Adaptive Regression Spline (MARS) adalah pendekatan untuk regresi multivariat nonparamterik yang dilakukan untuk mengatasi permasalahan dimensi yang tinggi dan diskontiunitas pada data, sehingga menghasilkan prediksi variabel respon yang akurat (Friedman, 1991). Metode MARS tidak memerlukan asumsi tentang hubungan fungsional yang mendasar antara variabel respon dan prediktor. Selain itu, MARS merupakan pengembangan dari pendekatan *Recursive Partition Regression* (RPR) yang masih memiliki kelemahan dimana model yang dihasilkan tidak kontinu pada titik *knot*.

Nash dan Brandford (2001) menyatakan bahwa ada beberapa hal yang perlu diperhatikan dalam membangun model MARS, yaitu :

1. *Knot*, yaitu akhir sebuah garis regresi (*region*) dan awal sebuah garis (*region*) yang lain. Di setiap titik *knot* diharapkan adanya kontinuitas dan fungsi basis satu region dengan region lainnya.
2. *Basic Function*, yaitu suatu fungsi yang digunakan untuk menjelaskan hubungan antara variabel respon dan variabel prediktor, atau dapat diartikan sebagai sekumpulan fungsi yang digunakan untuk mempresentasikan infromasi yang terdiri atas satu atau lebih variabel termasuk interaksi antar variabel. Suatu fungsi basis adalah jarak antar knot yang berurutan (Cherkassky & Mulier, 1998).

Friedman (1991) menyarankan bahwa untuk jumlah maksimum basis fungsi (BF) adalah 2 sampai 4 kali jumlah variabel prediktor. Jumlah interaksi maksimum (MI) yaitu 1, 2, atau 3 dengan pertimbangan jika lebih dari 3 akan mendapatkan model yang sangat kompleks. Untuk jarak minimum antar *knot* atau observasi minimum (MO) antar *knot* sebanyak 5, 10, dan 20 (Sutikno, 2008).

Model umum persamaan MARS dirumuskan dalam persamaan 2.8.

$$\hat{f}(x) = a_0 + \sum_{m=1}^{M} a_m \prod_{k=1}^{K_m} [s_{km}.(x_{v(k,m)} - t_{km})]_+ . \qquad (2.8)$$

dengan :

a_0 = parameter fungsi basis induk

a_m = paramater dari fungsi basis ke-m

M = maksimum fungsi basis (*nonconstant* fungsi basis)

K_m = derajat interaksi

s_{km} = nilainya ± 1 jika data berada di sebelah kanan titik knot atau di kiri titik *knot*

$x_{v(k,m)}$ = variabel prediktor

t_{km} = nilai *knot* dari variabel prediktor $x_{v(k,m)}$

Berdasarkan persamaan (2.8) model MARS dapat dituliskan sebagai berikut.

$$\hat{f}(\mathbf{x}) = a_0 + \sum_{m=1}^{M} a_m B_m(\mathbf{x}) \qquad (2.9)$$

dengan $B_m(x) = \prod_{k=1}^{K_m} [s_{km}(x_{v(k,m)} - t_{km})]$.

Dalam bentuk matriks dapat ditulis menjadi :

$\mathbf{y} = \mathbf{B}a + \boldsymbol{\varepsilon}$

dimana

$$y = (y_i, \dots, y_n)^T, a = (a_0, \dots, a_m)^T, \varepsilon = (\varepsilon_1, \dots, \varepsilon_m)^T$$

$$\mathbf{B} = \begin{bmatrix} 1 & \prod_{k=1}^{K} [s_{1m}(x_{1(1m)} - t_m)] & \cdots & \prod_{k=1}^{K_M} [s_{Mm}(x_{1(M,m)} - t_{Mm})] \\ 1 & \prod_{k=1}^{K} [s_{1m}(x_{2(1m)} - t_m)] & \cdots & \prod_{k=1}^{K_M} [s_{Mm}(x_{2(M,m)} - t_{Mm})] \\ \vdots & \vdots & \ddots & \vdots \\ 1 & \prod_{k=1}^{K} [s_{1m}(x_{n(1m)} - t_{1m})] & \cdots & \prod_{k=1}^{K_M} [s_{Mm}(x_{n(M,m)} - t_{Mm})] \end{bmatrix}$$

Persamaan (2.8) dapat dijabarkan sebagai berikut.

$$\hat{f}(x)=a_0+\sum_{m=1}^{M}a_m\left[s_{1m}\left(x_{v(1,m)}-t_{1m}\right)\right]+\sum_{m=1}^{M}a_m\left[s_{1m}\left(x_{v(1,m)}-t_{1m}\right)\right]\left[s_{2m}\left(x_{v(2,m)}-t_{2m}\right)\right]$$
$$+\sum_{m=1}^{M}a_m\left[s_{1m}\left(x_{v(1,m)}-t_{1m}\right)\right]\left[s_{2m}\left(x_{v(2,m)}-t_{2m}\right)\right]\left[s_{3m}\left(x_{v(3,m)}-t_{3m}\right)\right]+\cdots$$

Secara umum, persamaan (2.8) dapat dituliskan sebagai berikut.

$$\hat{f}(x)=a_0+\sum_{Km=1}f_i(x_i)+\sum_{Km=2}f_{ij}\left(x_i,x_j\right)+\sum_{Km=3}f_{ijk}\left(x_i,x_j,x_k\right)+\ldots \tag{2.10}$$

Pada persamaan (2.10) menunjukkan bahwa suku pertama meliputi semua fungsi basis untuk satu variabel, suku kedua meliputi semua fungsi basis untuk interaksi antara dua variabel, suku ketiga meliputi semua fungsi basis untuk interaksi antara tiga variabel dan seterusnya (Friedman, 1991).

Metode MARS merupakan metode yang digunakan untuk mengatasi kelemahan pada *Recursive Partioning Regression* (RPR) yaitu menentukan *knot* secara otomatis oleh data dan menghasilkan model yang kontinu pada *knot*. Penentuan lokasi titik knot dan jumlah peubah ditentukan berdasarkan pada data dengan menggunakan kriteria *lack-of-fit* (LOF). MARS menentukan *knot* mengunakan algoritma *forward stepwise* dan *backward stepwise*. *Forward stepwise* dilakukan untuk mendapatkan fungsi dengan jumlah fungsi basis maksimum. Kriteria pemilihan fungsi basis pada *forward stepwise* adalah dengan meminimumkan kriteria *lack-of-fit*. Untuk memenuhi konsep parsemoni (model sederhana) dilakukan *backward stepwise* dengan membuang basis fungsi yang memiliki kontribusi kecil terhadap respon dari *forward stepwis*e hingga tidak ada fungsi basis yang dapat dikeluarkan. Tahap *backward* dapat digambarkan dalam tiga langkah, yaitu menentukan fungsi basis yang harus dihapus dari model, menghapus fungsi basis yang telah ditentukan, dan menentukan model akhir. Fungsi basis yang kontribusinya terhadap terhadap nilai dugaan terkecil akan dihilangkan. Ukuran kontribusi yang digunakan dalam tahap *backward stepwise* adalah nilai *Generelized Cross Validation* (GCV) (Cherkassky & Mulier, 1998). Beberapa hal yang perlu

diperhatikan dalam pemilihan model yang paling optimum (terbaik) dalam model MARS yaitu jika nilai GCV dari model tersebut memiliki nilai GCV yang paling rendah (minimum) diantara model-model lain. Fungsi GCV minimum dapat didefinisikan seperti pada persamaan 2.10 berikut.

$$GCV(M) = \frac{ASR}{\left[1 - \frac{C(M)}{n}\right]^2} = \frac{\frac{1}{n}\sum_{i=1}^{n}\left[y_i - \hat{f}_M(x_i)\right]^2}{\left[1 - \frac{C(M)}{n}\right]^2} \qquad (2.11)$$

dengan,

ASR = *Average Sum Square of Residual*

M = jumlah basis fungsi (*nonconstant* basis fungsi) yang ditentukan pada tahap *forward* $\hat{f}_M(x_i)$ = taksiran/prediksi y_i

x_i = variabel prediktor

y_i = variabel respon

n = banyaknya pengamatan

$C(M)$ = trace $(\mathbf{B}(\mathbf{B}^T\mathbf{B})^{-1}\mathbf{B}^T) + 1$

$C(M)$ = nilai kompleksitas model yang terdiri atas M basis fungsi

Banyak peubah penjelas yang digunakan memungkinkan terjadinya kasus multikolinieritas pada matriks $\mathbf{B}$. Menurut Friedman (1991) cara mengatasi masalah korelasi antar variabel prediktor pada MARS yaitu dengan menambahkan satu faktor *penalty* (γ) pada algoritma tahap *forward*.

$$LOF(f) \leftarrow LOF(f)\left[1 + \gamma I\left(x \notin \bigcup_{i=1}^{L-1}\{x(k,l)\}_1^{K_1}\right)\right] \qquad (2.12)$$

Pada iterasi ke-L terdapat L-1 fungsi basis yang ada dalam model dan fungsi indikator (I) bernilai nol jika paling sedikit satu peubah penjelas masuk, dan lainnya bernilai satu. Besarnya nilai γ yang optimum bergantung pada kondisi tertentu (tingkat kolinieritas) dan besarnya *goodness-of-fit* yang digunakan oleh

pengguna dalam membentuk model parsimoni (model sederhana). Hal ini dapat dilakukan dengan simulasi γ (secara meningkat), kemudian dilakukan evaluasi melalui nilai GCV akhir. Menurut Priambudi (2006) nilai *penalty* berkisar antara 0,01 hingga 0,1 dalam pembuatan model. Model MARS pada persamaan 2.9 setelah dimodifikasi dengan adanya *penalty* menjadi persamaan 2.13.

$$\hat{f}(\mathbf{x}) = a_0 + \sum_{m=1}^{M} a_m B_m(\mathbf{x}) + \gamma \sum_{k=1}^{n} \sum_{l=1}^{n} \int \left| \frac{\partial^2 g}{\partial x_k \partial x_l} \right|^2 d\mathbf{x} \quad (2.13)$$

2.4 *Numerical Weather Prediction*

Numerical Weather Prediction (NWP) adalah sekumpulan kode komputer yang mempresentasikan secara numerik persamaan-persamaan atmosfer. NWP digunakan untuk memprediksi kondisi atau status atmosfer yang akan datang dengan menggunakan kemampuan komputer yang tinggi (Idowu & Rautenbach, 2009). Prediksi cuaca dirumuskan dengan menyelesaikan persamaan pergerakan atmosfer. Model NWP pertama kali dikembangkan pada tahun 1945 oleh John Von Neumann dan Vladimir Zworykin dengan menggunakan komputer elektronik, yaitu dengan memodifikasi iklim dan pencarian metode yang handal untuk menghitung sirkulasi umum atmosfer.

Model WRF-EMS (*Weather Research and Forecasting Environment Modeling System*) merupakan model yang di kembangkan oleh *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).* Untuk keperluan prakiraan 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)* yang dikembangkan oleh *National Center for Atmospheric Research (NCAR)* dan *non-Hydrostatic*

Mesoscale Model (NMM) yang dikembangkan oleh *National Center for Environmental Prediction (NCEP)*. Di dalam WRF-EMS, hampir semua sistem operasional NWP sudah diintegrasikan termasuk proses pengambilan dan pengolahan data, eksekusi model, pengolahan data output serta migrasi hasil output dan penyimpanan, perangkat lunak untuk menampilkan hasil prakiraan juga terdapat dalam model WRF-EMS tersebut.

Beberapa kelebihan pada skema ini antara lain adalah sebagai berikut.

a. Baik digunakan pada lingkungan yang lembab.
b. Memperlakukan *elevated-convection* lebih baik daripada skema-skema lainnya.
c. Merupakan skema konvektif yang paling efektif dalam mencegah skema mikrofisik membentuk proses konveksi.
d. Tidak memerlukan perhitungan yang banyak.

Sistem Model WRF terdiri dari 4 program utama, yaitu :

1. *WRF Preprocessing System* (WPS)
   Program ini digunakan terutama untuk simulasi data yang berfungsi untuk mendefinisikan simulasi domain, dan interpolasi data permukaan.
2. WRF-DA
   Program ini bersifat opsional, tetapi dapat digunakan untuk observasi pada analisis interpolasi yang dihasilkan oleh WPS. Selain itu juga bisa bisa digunakan untuk memperbarui model WRF ketika model WRF sedang dijalankan.
3. ARW *solver*
   ARW solver merupakan komponen utama dari sistem pemodelan, yang terdiri dari beberapa program inisialisasi, data *real* yang simulasi, dan program integrasi numerik.
4. *Post-processing* & Visualisasi.
   (NCAR, 2017)

Hasil prakiraan NWP dengan resolusi tinggi di suatu tempat (grid) seringkali menghasilkan bias yang besar terutama untuk wilayah dengan topografi dan tutupan vegetasi yang

kompleks. Kondisi nyata permukaan bumi dan atmosfer di suatu tempat sangat beragam baik dalam domain spasial, temporal dan ketinggian. Namun, berdasarkan sudut pandang NWP, suatu area yang luas dianggap mempunyai keragaman topografi dan keadaan atmosfer yang homogen. Sehingga output NWP belum bisa menjelaskan keragaman cuaca di wilayah yang luas. Hubungan statistik dapat dibangun antara informasi yang dihasilkan NWP dan nilai prakiraan yang dimaksud. Model NWP tidak sempurna, dan hasil prakiraannya masih terdapat *error*. Prakiraan statistik berdasarkan pada NWP dapat menggantikannya dan mengkoreksi beberapa kesalahan prakiraan. Model NWP adalah deterministik dan tidak bisa secara penuh menjelaskan proses stokastik cuaca. Informasi NWP yang digunakan bersamaan dengan metode statistik memungkinkan untuk mengkuantifikasi dan menjelaskan ketidakpastian dengan menghubungkannya dengan kondisi prakiraan yang berbeda atau prakiraan probabilistik (Wilks, 2006).

2.5 *Model Output Statistics*

Salah satu metode yang dapat digunakan dalam meramal parameter cuaca yang tidak dapat secara langsung dihasilkan dari sebuah model numerik (NWP) adalah *Model Output Statistics* (MOS), metode ini menentukan hubungan statistik antara prediktan dan variabel dari model numerik pada beberapa proyeksi waktu.

MOS diperkenalkan dan dikembangkan pertama kali oleh Glahn dan Lowry pada tahun 1969 dan dipublikasikan pada tahun 1972. MOS digunakan untuk *post processing* ramalan NWP. MOS merupakan model yang meng-hubungkan antara variabel respon **y** (observasi stasiun cuaca, seperti temperatur minimum, temperatur maksimum, kecepatan angin dan sebagainya) dan variabel prediktor **x** (parameter NWP, seperti temperatur, angin dan sebagainya pada berbagai grid dan level) dengan model berbasis regresi. Di samping itu variabel prediktor dapat juga berupa parameter geografi seperti lintang, bujur dan waktu (t).

Menurut Neilly dan Hanson (2004) MOS mempunyai dua fungsi utama, yaitu :

1. Teknis MOS menghasilkan ramalan cuaca kuantitatif ke depan yang mungkin tidak secara eksplisit diperoleh dari model.
2. MOS mereduksi *error* dari ramalan NWP dengan memperkecil bias dan pengkoreksian model secara statistik. Pengkoreksian yang dimaksud yaitu jika terdapat kesalahan yang sistematik pada *output* model NWP, seperti *output* ramalan suhu pada kondisi terlalu dingin pada hari mendung dan terlalu panas pada hari cerah.

Menurut Wilks (2006) secara umum persamaan matematis MOS adalah sebagai berikut:

$$\hat{y}_t = \hat{f}_{MOS}(x_t) \tag{2.14}$$

Keterangan :

$\hat{y}_t$ = ramalan cuaca saat waktu ke-t

x_t = variabel-variabel NWP pada waktu ke-t

MOS akan menghasilkan ramalan yang optimal jika terpenuhi syarat-syarat diantaranya:

1. Periode data untuk *training* (verifikasi) model seharusnya sepanjang mungkin (beberapa tahun). Data *training* yang dimaksud adalah data yang digunakan dalam pembangunan model regresi berganda.
2. Model yang terbentuk seharusnya tidak berubah pada kondisi ekstrim selama verifikasi model.
3. Pada tahap validasi model, MOS seharusnya dapat diaplikasikan dan tidak berubah modelnya. Validasi model dimaksudkan untuk menguji keterandalan model yang sudah terbangun dengan menggunakan data independen. Salah satu cara menvalidasi adalah validasi silang (*cross validation*), yaitu mempartisi (memotong) data (misal setiap bagian 10%) kemudian model regresi dibentuk dengan data 90% (untuk verifikasi) dan sisanya digunakan untuk validasi. Proses ini dilakukan secara berulang

sebanyak 10 kali dengan sekumpulan data yang berbeda. (BMKG, 2006).

Menurut Priambudi (2006), kombinasi linier terbaik antara peubah respon dan peubah prediktor (data NWP) terletak pada 9 grid di sekitar stasiun pengamatan. Model MOS memiliki kemampuan untuk melakukan peramalan hingga 72 jam ke depan.

2.6 Validasi Model

Validasi model dilakukan untuk melihat kemampuan model dalam melakukan pendugaan terhadap data baru yang bukan merupakan bagian dari data penyusun model. Menurut Shao dan Yadong dalam Sari (2013) salah satu ukuran yang dapat digunakan sebagai ukuran hasil pendugaan adalah RMSEP (*Root Mean Square error Prediction*). Semakin kecil RMSEP maka semakin baik dugaan model yang dihasilkan. Rumus untuk mendapatkan RMSEP secara *univariate* adalah sebagai berikut.

$$RMSEP = \sqrt{\frac{\sum_{t=1}^{n_{pred}} \left(Y_t - \hat{Y}_t\right)^2}{n_{period}}} \tag{2.15}$$

Berdasarkan hasil verifikasi laporan Bidang Analisa BMKG tahun 2004 melalui kegiatan "Verifikasi dan Jangkauan Prakiraan Cuaca Jangka Pendek", kriteria nilai RMSEP seperti pada Tabel 2.1 berikut.

Tabel Error! No text of specified style in document.**.1** Kriteria Nilai RMSEP

Unsur	**RMSEP**	**Kriteria**
Suhu	0,0-0,4	Baik sekali
	0,5-0,8	Baik
	0,9-1,2	Sedang
	1,3-1,6	Buruk
	>1,6	Buruk sekali
Kelembapan	0,0-2,5	Baik sekali
	2,6-5,0	Baik
	5,1-7,5	Sedang
	7,6-10,0	Buruk
	>10,0	Buruk sekali

(Sumber : BMKG, 2004)

2.7 Ukuran Pengoreksi Bias

Persentase perbaikan model MOS terhadap model NWP ditunjukkan oleh *Percentage Improval* (%IM) yang dihitung dengan rumus sebagai berikut.

$$\%IM = \frac{RMSEP_{NWP} - RMSEP_{MOS}}{RMSEP_{NWP}} \times 100\% \qquad (2.15)$$

Nilai %IM antara 0% dampai 100%. Semakin besar %IM menunjukkan bahwa semakin baik model MOS mengkoreksi bias dan hasil ramalan NWP (Davis, 2004).

2.8 Suhu dan Kelembapan

2.8.1 Suhu

Suhu atau temperatur udara adalah derajat panas dan aktivitas molekul dalam atmosfer. Suhu dikatakan sebagai derajat panas atau dingin yang diukur berdasarkan skala tertentu dengan menggunakan thermometer (Ance, 1986).

Suhu merupakan karakteristik yang dimiliki oleh suatu benda yang berhubungan dengan panas dan energi (Lakitan, 2002). Suhu udara akan berfluktuasi dengan nyata setiap periode 24 jam. Fluktuasi itu berkaitan erat dengan nyata setap periode 24 jam. Fluktuasi suhu akan terganggu jika turbulensi udara atau pergerakan massa udara menjadi sangat aktif, misalnya pada kondisi kecepatan angin tinggi. Jika pergerakan massa udara tersebut melibatkan seluruh lapisan udara dekat permukaan, maka suhu udara pada lapisan tersebut relatif homogen.

Suhu udara harian rata-rata didefinisikan sebagai rata-rata pengamatan selama 4 jam (satu hari) yang dilakukan tiap jam. Secara kasar, suhu udara harian rata-rata dapat dihitung dengan menjumlah suhu maksimum dan suhu minimum kemudian dibagi dua. Suhu bulanan rata-rata adalah jumlah dari suhu harian dalam

satu bulan dibagi dengan jumlah hari dalam bulan tersebut (Tjasyono, 2006).

2.8.2 Kelembapan Udara

Kelembapan adalah jumlah rata-rata kandungan air keseluruhan (uap, tetes air, dan kristal es) di udara pada suatu waktu yang diperoleh dari hasil harian dan dirata-ratakan setiap bulan, sedangkan berdasarkan *glossary of meteorology*, kelembapan diartikan sebagai jumlah uap air di udara atau tekanan uap yang teramati terhadap tekanan uap jenuh untuk suhu yang diamati dan dinyatakan dalam persen (Neiburger, 1995).

Kelembapan udara adalah banyaknya uap air yang terkandung dalam massa udara pada saat dan tempat tertentu. Menurut Lakitan (2002), kelembapan udara mempunyai beberapa istilah yaitu :

a. Kelembapan mutlak atau kelembapan absolut, yaitu total massa uap air persatuan volume udara dinyatakan dalam satuan kg/m^3.
b. Kelembapan spesifik yaitu perbandingan antara massa uap air dengan massa udara lembap dalam satuan volume udara tertentu, dinyatakan dalam g/kg.
c. Kelembapan nisbi atau kelembapan relatif, yaitu perbandingan antara tekanan uap air aktual (yang terukur) dengan tekanan uap air pada kondiis jenuh, dinyatakan dalam persen.

Besarnya kelembapan suatu daerah merupakan faktor yang dapat menstimulasi hujan. Data klimatologi untuk kelembapan udara yang umum dilaporkan adalah kelembapan relatif yang diukur dengan psikometer atau hygrometer. Kelembapan relatif berubah sesuai dengan tempat dan waktu. Menjelang tengah hari, kelembaban relatif berangsur-angsur turun kemudian bertambah besar pada sore hari sampai menjelang pagi (Tyasono, 2004).

(Halaman ini sengaja dikosongkan)

BAB III
METODOLOGI PENELITIAN

3.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) Pusat Jakarta bagian Pusat Penelitian dan Pengembangan, dengan data meliputi observasi cuaca permukaan dan data *Numerical Weather Prediction* (NWP). Data luaran NWP yang akan digunakan adalah model WRF-EMS (*Weather Reasearch and Forecasting-Environment Modelling System*) harian pada periode 1 Januari 2015 sampai 31 Desember 2016. Lokasi yang dilakukan dalam penelitian ini adalah dua stasiun pengamatan yaitu Soekarno Hatta dan Juanda seperti yang ditunjukkan pada Gambar 3.1. Ketiga stasiun pengamatan tersebut dipilih karena pengukuran cuaca pada stasiun tersebut dilakukan secara rutin, sehingga data pengamatan yang dihasilkan cukup baik dan lengkap.

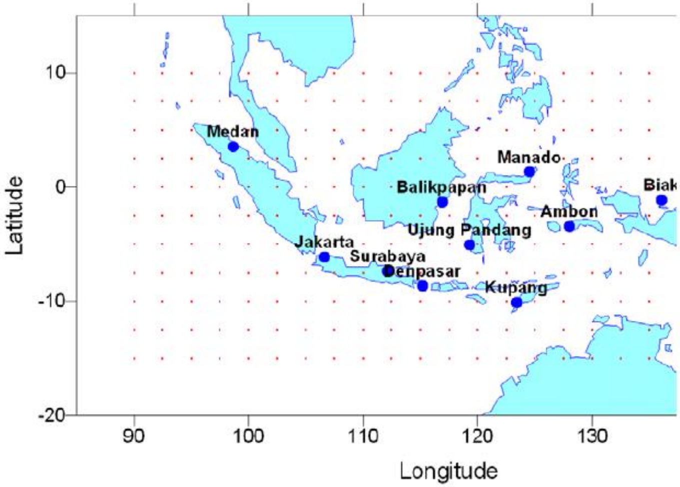

Gambar 3.1 Lokasi Stasiun Pengamatan

3.2 Variabel Penelitian

Data yang digunakan meliputi observasi cuaca permukaan dan data *Numerical Weather Prediction* (NWP). Data permukaan selanjutnya digunakan sebagai variabel respon yaitu suhu minimum, suhu maksimum, dan kelembapan rata-rata dan data NWP model WRF-EMS (*Weather Research and Forecasting Environment Modeling System*) sebagai variabel prediktor.

Input untuk *initial condition* yang digunakan dalam pengoperasian model WRF adalah luaran *Global Forecasting System* (GFS) pada jam 12 UTC dengan resolusi spasial luaran model ini 27 km, dan resolusi temporal 1 jam. Input lain yang adalah data topografi dari USGS (*United States Geological Survey*).

Parameter NWP model WRF-EMS yang digunakan seperti yang disajikan pada Tabel 3.1 berikut.

Tabel 3.1 Parameter NWP WRF EMS

No	Variabel	Satuan
1	Hujan Total (hujan_tot)	mm/hari
2	*Dew Point 2m* (dew2m)	celcius
3	*Wind Gust* (windgust)	ms^{-1}
4	*High Cloud* (hi_cloud)	%
5	*Low Cloud* (low_cloud)	%
6	*Middle Cloud* (mid_cloud)	%
7	*Total Cloud* (tot_cloud)	%
8	*Mean Sea Level Pressure* (mslp)	mb
9	*Surface pressure* (sur_press)	mb
10	*Relative humidity 2m* (rhum2m)	%
11	*Specific humidity* (shum2m)	kg/kg
12	*Temperatur 2 m* (temp2m)	celcius
13	*U wind 10 m* (uwind)	ms^{-1}
14	*V wind 10 m* (vwind)	ms^{-1}
15	*Surface Vis* (survis)	m

Definisi parameter NWP yang digunakan adalah sebagai berikut.

1. Hujan Total adalah potensi hujan yang akan turun dalam sehari.
2. *Dew Point 2m* adalah pengukuran titik embun yang dilakukan pada ketinggian 2 meter.
3. *Wind Gust* adalah angin yang berkaitan dengan badai 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 taka da angin.
4. *High Cloud* adalah awan yang letaknya pada ketinggian lebih dari 3 km tetapi tidak sama disetiap wilayah.
5. *Low Cloud* adalah awan yang terletak pada paras rendah kurang dari 2 km.
6. *Middle Cloud* adalah awan yang terletak pada paras antara 2 dan 8 km tetapi tidak sama disetiap wilayah
7. *Total Cloud* adalah keseluruhan awan disetiap wilayah.
8. *Mean Sea Level Pressure* adalah suhu rata-rata di atas permukaan laut
9. *Surface pressure* adalah tekanan permukaan diukur berdasarkan tekanan gaya pada permukaan dengan luas tertentu. Tekanan udara berkurang dengan bertambahnya ketinggian.
10. *Relative humidity 2m* adalah nilai perbandingan antara tekanan uap air ang 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* adalah perbandingan antara massa uap air dan massa udara dalam tiap satuan volume udara yang di ukur pada 2 meter di atas permukaan laut.
12. *Temperatur 2 m* adalah derajat panas dan dingin udara di atmosfer yang diukur pada ketinggian 2 meter di atas permukaan.
13. *U wind 10m* adalah kecepatan angin harian hingga ketinggian 10m diatas permukaan.
14. *V wind 10m* merupakan kecepatan angin harian hingga mencakup luas 10m dari lokasi pengamatan..
15. *Surface Visible* adalah jarak permukaan air laut yang tampak.

Parameter WRF EMS sebanyak 15 parameter ditentukan oleh BMKG pada masing-masing lokasi pengamatan. Masing-masing parameter tersebut diukur pada 9 grid(3x3)pengukuran yang terdekat dari lokasi stasiun pengamatan. Berikut merupakan proyeksi pengukuran NWP dalam sembilan grid yang ditunjukkan pada Gambar 3.2. Titik yang berwarna merah menunjukkan grid yang paling dekat dengan lokasi pengamatan, sedangkan titik yang berwarna hitam merupakan kombinasi grid di sekitar lokasi pengamatan.

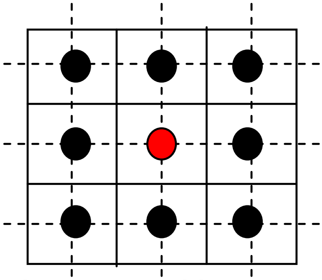

Gambar 3.2 Pengukuran NWP Model WRF EMS dalam grid 3x3

3.3 Struktur Data

Struktur data untuk pengamatan di seluruh wilayah penelitian disajikan pada Tabel 3.2 berikut.

Tabel 3.2 Struktur Data Penelitian

Stasiun SoekarnoHatta						**Stasiun Juanda**					
Y_{1i}	Y_{2i}	Y_{3i}	X_{1i}	$\cdots$	X_{nm}	Y_{1i}	Y_{2i}	Y_{3i}	X_{1i}	$\cdots$	X_{nm}
Y_{11}	Y_{21}	Y_{31}	X_{11}		X_{n1}	Y_{11}	Y_{21}	Y_{31}	X_{11}		X_{n1}
Y_{12}	Y_{22}	Y_{32}	X_{12}		X_{n2}	Y_{12}	Y_{22}	Y_{32}	X_{12}		X_{n2}
$\vdots$	$\vdots$	$\vdots$	$\vdots$		$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$		$\vdots$
Y_{1m}	Y_{2m}	Y_{3m}	X_{1m}	$\cdots$	X_{nm}	Y_{1m}	Y_{2m}	Y_{3m}	X_{1m}	$\cdots$	X_{nm}

dengan :

Y_1 = suhu maksimum (celcius)

Y_2 = suhu minimum (celcius)

Y_3 = kelembapan (%)

X_{nm} = pengamatan ke-n pada parameter NWP ke-m

i : 1,2,..., n = banyaknya observasi

j : 1,2,..., m = banyaknya paramater NWP

3.4 Langkah Analisis Data

Langkah analisis yang dilakukan dalam penelitian ini adalah sebagai berikut.

1. Melakukan pengujian distribusi normal multivariat.
   Pengujian normalitas yang digunakan adalah Shapiro-Wilk untuk normal multivariat
2. Pra-pemrosesan secara statistik.
   a. Melakukan standarisasi data pada variabel X dan variabel Y.
   b. Membagi data menjadi data *in sample* dan *out sample* pada masing-masing variabel respon dan prediktor.

Banyaknya data *in sample* sebanyak 346 hari, dan data *out sample* sebanyak 7 hari.

3. Mereduksi dimensi masing-masing variabel prediktor *in sample* dalam 9 grid pengukuran menggunakan ICA dengan algoritma sebagai berikut.
   a. Memilih sebuah *initial vector* $\mathbf{w}$.
   b. Membentuk $\mathbf{w}^{+} = E\{\mathbf{x}g(\mathbf{w}^{T}\mathbf{x})\} - E\{g^{'}(\mathbf{w}^{T}\mathbf{x})\}\mathbf{w}$
   c. Membentuk $\mathbf{w} = \mathbf{w}^{+} / \|\mathbf{w}^{+}\|$
   d. Jika $\mathbf{w}$ tidak konvergen kembali ke langkah 2.
4. Melakukan pemodelan MOS dengan MARS pada tiga stasiun pengamatan untuk memperkirakan suhu maksimum, suhu minimum, dan kelembapan dengan langkah-langkah sebagai berikut.
   a. Menentukan maksimum fungsi basis (BF).
   b. Menentukan jumlah maksimum interaksi (MI).
   c. Menentukan minimal jumlah pengamatan setiap knot atau observasi minimum (MO).
   d. Mengulangi langkah a,b,c sampai didapat model dengan GCV minimum
   e. Membentuk model MARS berdasarkan data *in sample*.
5. Melakukan validasi model berdasarkan data *out sample* untuk mendapatkan nilai RMSEP yang menunjukkan akurasi model.
6. Mengoreksi bias model MOS terhadap model NWP dengan ukuran %IM.

Tahapan analisis data selengkapnya disajikan pada Gambar 3.2.

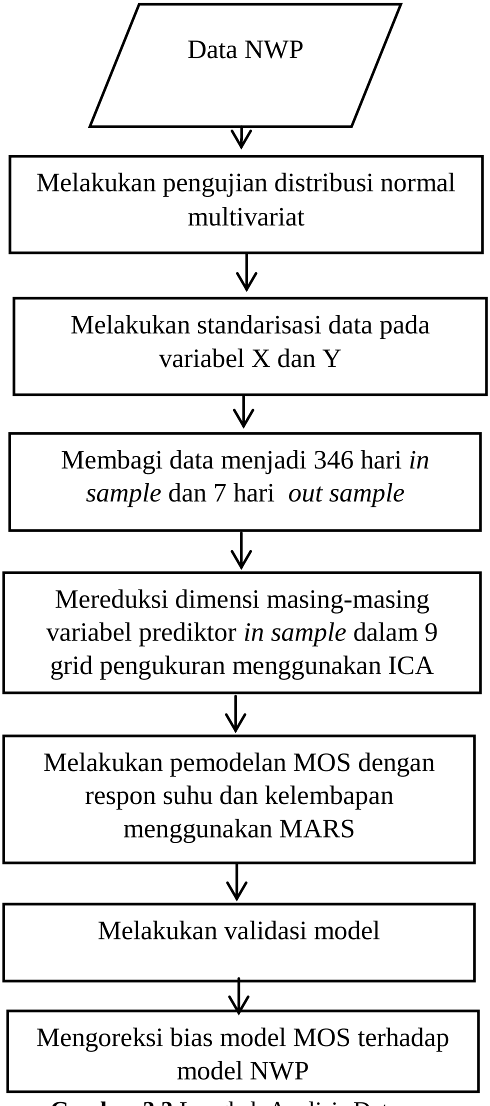

Gambar 3.3 Langkah Analisis Data

(Halaman ini sengaja dikosongkan)

BAB IV
ANALISIS DAN PEMBAHASAN

Pada bab ini dijelaskan tentang penyusunan *Model Output Statistics* (MOS) dengan metode *Multivariate Adaptive Regression Spline* (MARS). Pembahasan diawali dengan karakteristik variabel respon dan reduksi yang dilakukan saat pra-pemrosesan data NWP dengan metode *Independent Component Analysis* (ICA). Sebelum direduksi, dilakukan uji distribusi normal multivariat. Kemudian dilakukan pemodelan MARS pada komponen independen NWP dan menghitung validasi model serta ukuran pengkoreksi bias pada model. Lokasi stasiun yang diamati adalah Stasiun Soekarno Hatta dan Juanda dengan satuan observasi adalah hari.

4.1 Karakteristik Variabel Respon

Unsur cuaca yang dijadikan variabel respon yaitu Tmaks, Tmin, dan RH memiliki karakteristik yang berbeda-beda di masing-masing stasiun yang diamati. Dari kedua stasiun, rata-rata suhu maksimum dan kelembapan paling tinggi dan rata-rata suhu minimum paling rendah terletak di stasiun Soekarno Hatta. Deskriptif variabel respon di masing-masing stasiun selengkapanya untuk data *in sample* dan *out sample* disajikan pada Tabel 4.1.

Tabel 4.1 Rata-rata dan Standar Deviasi Variabel Respon

Stasiun	Variabel	Rata-rata	Standar Deviasi
Soekarno Hatta	Tmaks (°C)	32,10	1,22
	Tmin (°C)	24,08	0,83
	RH (%)	77,97	5,85
Juanda	Tmaks (°C)	31,93	0,98
	Tmin (°C)	24,59	1,30
	RH (%)	77,16	6,16

Tabel 4.1 menunjukkan bahwa rata-rata suhu maksimum di Soekarno Hatta sebesar 32,10°C dan rata-rata suhu minimum 24,08°C. Rata-rata suhu maksimum di stasiun Juanda lebih rendah dari Soekarno Hatta yaitu sebesar 31,93. Rata-rata kelembapan di dua stasiun pengamatan hampir sama yaitu selisih 0,81 dimana lebih besar kelembapan di Sokarno Hatta sebesar 77,97%. Standar deviasi suhu maksimum di Stasiun Soekarno Hatta sebesar1,22°C yang menunjukkan bahwa simpangan baku dari semua nilai data terhadap rata-rata 32,1°C adalah sebesar 1,22°C. Keragaman atau varians data untuk suhu maksimum dan suhu minimum di dua stasiun cukup rendah dengan nilai standar deviasi berkisar antara 0,83 sampai 1,3, sedangkan variasi data untuk kelembapan di dua stasiun cukup tinggi terlihat dari nilai standar deviasi yang tinggi diatas 5%.

4.2 Uji Distribusi Normal Multivariat

Sebelum dilakukan analisis pereduksian variabel dengan metode ICA perlu pengujian normal multivariat untuk mengetahui asumsi tentang kenormalan data. Uji distribusi normal multivariat untuk variabel hujan total di stasiun pengamatan Soekarno Hatta adalah sebagai berikut.

H_0 : Data hujan total berdistribusi normal multivariat

H_1 : Data hujan total tidak berdistribusi normal multivariat

Dengan taraf signifikan 5%, maka tolak H_0 karena *p-value* ($2{,}2 \times 10^{-16}$) < α (5%), yang berarti bahwa variabel hujan total dengan 9 grid di stasiun Soekarno Hatta tidak berdistribusi normal multi-variat.

Setelah melakukan pengujian yang sama untuk semua variabel di dua stasiun pengamatan diperoleh bahwa tiap variabel prediktor tersebut tidak berdistribusi normal multivariat. Hasil uji distribusi normal multivariat selengkapnya untuk seluruh variabel prediktor di masing-masing stasiun akan disajikan pada Lampiran 9 dan 10.

4.3 Pemodelan Suhu dan Kelembapan

Pemodelan variabel respon yang meliputi suhu dan kelembapan dengan variabel prediktor data NWP model WRF EMS. Sebelum pemodelan MARS dilakukan, variabel prediktor pada masing-masing grid direduksi dengan ICA.

4.3.1 Reduksi Dimensi ICA

Variabel NWP yang digunakan berjumlah 15 variabel dengan masing-masing variabel diukur pada 9 grid pengukuran sehingga perlu dilakukan reduksi dimensi di masing-masing variabel tersebut. Metode yang digunakan untuk reduksi adalah ICA karena metode tersebut dapat menemukan representasi linier dari data *nongaussian* sehingga komponennya independen secara statistik. Pada bagian ini akan dijelaskan hasil reduksi dimensi untuk variabel hujan total dan dew2m (*dew point 2m*) pada stasiun Soekarno Hatta. Nilai eigen dan kumulatif varians variabel hujan total dan dew2m setelah direduksi dimensi dalam 9 grid di stasiun Soekarno Hatta disajikan pada Tabel 4.2.

Tabel 4.2 Nilai Eigen dan Varians Kumulatif Variabel Hujan Total dan dew2m di Stasiun Soekarno Hatta

Jumlah Komponen	**Nilai Eigen**		**Varians Kum.(%)**	
	hujan total	dew2m	hujan total	dew2m
1	**6,20**	**8,32**	68,90	**92,39**
2	**1,54**	0,60	**86,03**	99,09
3	0,55	0,05	92,12	99,63
4	0,33	0,02	95,81	99,84
5	0,23	0,01	98,34	99,93
6	0,09	0,00	99,38	99,98
7	0,04	0,00	99,78	99,99
8	0,02	0,00	100,00	100,00
9	0,00	0,00	100,00	100,00

Penentuan banyaknya komponen independen (IC) pada ICA melalui nilai eigen lebih dari satu dan prosentase varians kumulatif. Pada variabel hujan total terbentuk 2 komponen dan variabel dew2m terbentuk 1 variabel dengan varians kumulatif keduanya diatas 80% di stasiun Soekarno Hatta. Langkah yang sama akan dilakukan untuk kelima belas variabel NWP. Jumlah komponen independen yang terbentuk pada stasiun Sokarno Hatta akan disajikan pada Tabel 4.3 sebagai berikut.

Tabel 4.3 Jumlah Komponen Independen Variabel NWP di Stasiun Soekarno Hatta

Variabel	Jml. IC	Nilai Eigen	Varians Kum. (%)	Variabel	JmI IC	Nilai Eigen	Varians Kum.(%)
hujantot	2	6,20	68,90	surpress	1	8,97	99,69
		1,54	86,03	rhum2m	2	7,54	83,8
dew2m	1	8,31	92,39			1,26	97,9
windgust	1	8,16	90,71	shum2m	1	8,37	93,08
hicloud	1	8,28	92,08	temp2m	2	4,97	55,31
lowcloud	2	6,24	69,36			3,05	89,29
		1,48	85,90	uwind	1	8,85	98,36
midcloud	1	8,15	90,66	vwind	1	7,92	88,11
totcloud	1	8,18	90,95	survis	2	6,75	75,05
mslp	1	8,95	99,46			1,48	91,58

Tabel 4.3 menunjukkan bahwa jumlah komponen independen di Soekarno Hatta untuk masing-masing variabel NWP adalah satu komponen kecuali hujan total, *low cloud, relative humidity 2m, temperature 2m,* dan *surface vis* sebanyak 2 komponen dengan varians kumulatif diatas 80%. Jumlah komponen independen yang terbentuk di stasiun Juanda akan disajikan pada Tabel 4.4.

Tabel 4.4 Jumlah Komponen Independen Variabel NWP di Stasiun Juanda

Variabel	Jml. IC	Nilai Eigen	Varians Kum. (%)	Variabel	Jml. IC	Nilai Eigen	Varians Kum. (%)
hujantot	2	6,31	70,14	surpress	1	8,93	99,22
		1,45	86,28	rhum2m	1	7,73	85,83
dew2m	1	8,60	95,53	shum2m	1	8,52	94,68
windgust	2	6,81	75,66	temp2m	2	6,56	72,90
		1,17	88,62			2,05	95,73
hicloud	1	8,30	92,18	uwind	1	8,86	98,43
lowcloud	2	5,63	62,59	vwind	1	6,55	72,74
		1,73	81,77			1,85	93,33
midcloud	1	8,44	93,73	survis	2	6,78	75,30
totcloud	1	8,19	90,95			1,42	91,06
mslp	1	8,94	99,36				

Jumlah komponen independen di Juanda untuk masing-masing variabel NWP adalah satu komponen kecuali hujan total, *windgust*, *low cloud*, *temperature 2m*, dan *surface vis* sebanyak 2 komponen dengan varians kumulatif masing-masing variabel diatas 80% (Tabel 4.4). Jumlah komponen independen yang terbentuk dari variabel NWP untuk stasiun Soekarno Hatta sebanyak 20 komponen dan di Stasiun Juanda sebanyak 21 komponen. Komponen independen yang terbentuk dari seluruh variabel NWP di masing-masing stasiun pengamatan digunakan sebagai variabel prediktor dalam pemodelan MOS menggunakan MARS.

4.3.2 Pemodelan Suhu dan Kelembapan dengan MARS

Komponen independen yang diperoleh dari hasil reduksi sembilan grid pengukuran dengan metode ICA akan dilakukan pemodelan menggunakan MARS untuk memprakirakan Tmaks,

Tmin, dan RH. Pemodelan ini bertujuan untuk mendapatkan model MOS terbaik dengan nilai RMSEP yang kecil.

Model MARS untuk Tmaks, Tmin, dan RH pada stasiun Soekarno Hatta dijelaskan secara rinci sebagai ilustrasi. Sedangkan untuk stasiun pengamatan lain akan disajikan pada Lampiran 20-21 karena langkah analisis yang digunakan sama.

Pembentukan model MARS untuk ketiga variabel respon di stasiun Soekarno Hatta dilakukan dengan cara simulasi terhadap maksimum jumlah basis fungsi (BF), maksimum interaksi (MI), dan minimum observasi (MO). Kemudian dilakukan penambahan *penalty* (γ) dengan kriteria antara 0,01 sampai 1, namun pada penelitian ini menggunakan *penalty* 0,05 (*moderate*) dan 0,1 (*heavy*). Pemilihan besarnya γ mengikuti metode yang dilakukan oleh Friedman (1991), karena penelitian untuk kasus iklim sangat terbatas. Penggunaaan nilai *penalty* pada MARS menyebabkan variabel yang digunakan dalam model semakin berkurang. Semakin besar nilai *penalty*, maka semakin sedikit variabel yang masuk dalam model. Pemilihan model MARS terbaik menggunakan kriteria GCV paling minimum. Hasil simulasi model MARS untuk ketiga variabel respon di masing-masing stasiun pengamatan dapat dilihat pada Lampiran 14-19. Kombinasi model MARS terbaik untuk variabel respon Tmaks, Tmin, dan RH pada stasiun Soekarno Hatta disajikan pada Tabel 4.5.

Tabel 4.5 Kombinasi Model MARS terbaik di Stasiun Soekarno Hatta

Respon	BF	MI	MO	*Penalty*	GCV	MSE	R^2
Tmaks	80	2	5	0,05	0,581	0,514	0,496
Tmin	40	2	5	0,05	0,736	0,676	0,330
RH	80	3	20	0,05	0,462	0,423	0,589

Tabel 4.5 menunjukkan bahwa model MARS terbaik di stasiun Soekarno Hatta dengan variabel respon Tmaks adalah

dengan maksimum basis fungsi sebesar 80, jumlah maksimum interaksi sebanyak 2, dan minimal jumlah pengamatan tiap knot sebesar 5. Model MARS terbaik dengan variabel respon Tmin adalah dengan maksimum basis fungsi sebesar 40, jumlah maksimum interaksi sebanyak 2, dan minimal jumlah pengamatan tiap knot sebesar 5. Model MARS terbaik dengan variabel respon Tmin adalah dengan maksimum basis fungsi sebesar 80, jumlah maksimum interaksi sebanyak 3, dan minimal jumlah pengamatan tiap knot sebesar 20. Model MARS terbaik dengan variabel respon RH adalah dengan maksimum basis fungsi sebesar 80, jumlah maksimum interaksi sebanyak 3, dan minimal jumlah pengamatan tiap knot sebesar 20. *Penalty* model terbaik di Soekarno Hatta sebesar 0,05. Model MARS terbaik untuk Tmaks, Tmin, dan RH di stasiun Soekarno Hatta disajikan sebagai berikut.

Model suhu maksimum

$$\hat{Y}_{Tmaks} = 0{,}359 + 0{,}088\ BF2 + 0{,}101\ BF9 - 0{,}193\ BF19 - 0{,}124\ BF30 + 0{,}548\ BF38 + 0{,}029\ BF49 - 0{,}012\ BF75$$

dimana :

BF1 = max(0, IC2_TEMP + 5,182);
BF2 = max(0, IC_MIDCL – 0,353) BF1;
BF6 = max(0, IC1_TEMP + 0,386);
BF7 = max(0, - 0,386 - IC1_TEMP);
BF9 = max(0, 1,401 - IC_MIDCL) BF7;
BF19 = max(0, IC2_TEMP + 2,401);
BF28 = max(0, - 1.875 - IC_MIDCL);
BF30 = max(0, - 0,010 - IC1_TEMP) BF28;
BF38 = max(0, - 3,103 - IC_SHUM2);
BF49 = max(0, IC_SHUM2 + 1,386) BF6;
BF75 = max(0, IC_VWIND + 7,268) BF1;

Model MARS suhu maksimum di Soekarno Hatta terdiri atas satu intersep dan 7 fungsi basis, yang meliputi 2 interaksi level pertama, dan 5 interakasi level kedua. Pada interaksi pertama, model memberikan gambaran bahwa kontribusi

komponen independen (KI-2) variabel TEMP terhadap model sebesar -0,193 bila nilai KI perubah tersebut (BF19) lebih besar dari -2,401 dan tidak ada kontribusi (0) jika lebih kecil dari -2,401. Untuk interaksi level 2 yaitu KI MIDCL dan KI-2 TEMP (BF2) memberi arti bahwa fungsi basis ini akan memberikan kontribusi terhadap model sebesar 0,088 bila KI peubah TEMP lebih besar dari -5,182 dan KI MIDCL lebih besar dari 0,353. Namun jika KI-2 TEMP lebih kecil dari -5,182 dan KIMDCL lebih kecil dari 0,353 maka interaksi 2 level antara KI MDCL dan KI-2 TEMP tidak memberikan kontribusi atau bernilai 0.

Model suhu minimum

$$\hat{Y}_{T\,\min} = -0{,}425 + 0{,}582\ BF2 + 0{,}279\ BF3 + 0{,}076\ BF18 + 0{,}323\ BF22 - 0{,}313\ BF24$$

dimana :

BF2 = max(0, - 2,749 - IC_DEW2M);
BF3 = max(0, IC_UWIND – 1,226);
BF5 = max(0, IC_DEW2M – 1,501);
BF18 = max(0, IC_SURPR + 4,875);
BF22 = max(0, IC_SURPR + 4,875) BF5;
BF24 = max(0, IC_SURPR + 5,866) BF5;

Model MARS suhu minimum di Soekarno Hatta terdiri atas satu intersep dan 5 fungsi basis, yang meliputi 3 interaksi level pertama, dan 2 interaksi level kedua. Pada interaksi pertama, model memberikan gambaran bahwa kontribusi komponen independen (KI) variabel DEW2M terhadap model sebesar 0,582 bila nilai KI perubah tersebut (BF2) lebih kecil dari -2,749 dan tidak memberikan kontribusi jika KI DEW2M lebih besar dari -2,749. Untuk interaksi level 2 yaitu KI SURPR dan KI DEW2M (BF22) memberi arti bahwa fungsi basis ini akan memberikan kontribusi terhadap model sebesar 0,323 bila KI peubah SURPR lebih besar dai -4,875 dan DEW2M lebih besar dari 1,501. Namun jika KI SURPR lebih kecil dari -4,875 dan KI DEW2M lebih kecil dari 1,501 maka interaksi 2 level antara KI SURPR dan KI DEW2M tidak memberikan kontribusi atau bernilai 0.

Model kelembapan rata-rata

$\hat{Y}_{RH}$ = 1,144 – 0,038 BF8 – 0,028 BF24 – 0,041 BF55
- 0,018 BF70 – 0,068 BF76;

dimana :

BF2 = max(0, 3,866 - IC1_RHUM);
BF3 = max(0, IC_UWIND + 1,354);
BF8 = max(0, 3,769 - IC1_RHUM) BF3;
BF24 = max(0, - 1,653 - IC_VWIND) BF2;
BF34 = max(0, IC1_RHUM + 3,278);
BF53 = max(0, IC_VWIND + 3,459);
BF55 = max(0, IC_DEW2M + 1,348) BF53;
BF70 = max(0, IC_UWIND + 9,077) BF34;
BF74 = max(0, - 0,180 - IC_UWIND) BF34;
BF76 = max(0, - 1,087 - IC1_TEMP) BF74;

Model MARS kelembapan rata-rata di Soekarno Hatta terdiri atas satu intersep dan 5 fungsi basis tanpa interaksi level pertama, 4 interaksi level kedua, dan 1 interaksi level ketiga. Pada interaksi kedua (BF8) yaitu KI-1 RHUM pada basis ke-8 dan KI UWIND pada basis ke-3 memberi arti bahwa fungsi basis ini akan memberikan kontribusi terhadap model sebesar -0,038 bila KI peubah RHUM lebih kecil dari 3,769 dan KI UWIND lebih besar dari -3,866. Namun jika KI-1 RHUM lebih besar dari 3,769 dan KI UWIND lebih kecil dari -3,866 maka interaksi 2 level antara KI-1 RHUM dan KI UWIND tidak memberikan kontribusi atau bernilai 0.Sedangkan untuk interaksi level 3 seperti BF76, fungsi akan memberikan kontribusi sebesar -0,068 bila KI-1 TEMP lebih kecil dari -1,087, KI UWIND lebih kecil dari -0,18, dan KI RHUM lebih besar -3,278. Namun jika KI-1 TEMP lebih besar dari -1,087, KI UWIND lebih besar dari -0,18, dan KI RHUM lebih kecil dari -3,278 maka interaksi 3 level antara KI-1 TEMP , KI UWIND , dan KI RHUM tidak memberikan kontribusi atau bernilai 0

Variabel prediktor (parameter NWP) yang berpengaruh pada pembentukan model suhu maksimum adalah sebanyak 5 variabel prediktor, suhu minimum sebanyak 3 variabel prediktor,

dan kelembapan rata-rata sebanyak 5 variabel prediktor. Untuk mengetahui kebaikan model yang sudah terbentuk pada data *in sample*, digunakan nilai R^2. Nilai R^2 di kedua stasiun pengmatan disajikan pada Tabel 4.6.

Tabel 4.6 Nilai R^2 Model MARS di Stasiun Pengamatan

Stasiun	**Variabel Respon**	**R^2(%)**
Soekarno Hatta	Tmaks	49,6
	Tmin	33,0
	RH	58,9
Juanda	Tmaks	74,7
	Tmin	51,8
	RH	79,8

Tabel 4.6 menunjukkan bahwa R^2 yang dihasilkan pada pemodelan MARS di stasiun Juanda lebih baik dari stasiun Soekarno Hatta. Nilai R^2 untuk pemodelan Tmaks berkisar antara 49,6%-74,7% dan untuk pemodelan RH berkisar antara 58,9%-79,8%. Model MARS untuk variabel RH di stasiun Juanda cukup baik dengan R^2 79,8% yang berarti kontribusi/peran komponen independen yang menjadi variabel prediktor terhadap variabel respon adalah 79,8% dan sisanya dijelaskan oleh variabel lain yang tidak dijelaskan dalam model.

4.4 Validasi Model MARS

Validasi model digunakan untuk mengetahui kebaikan model yang sudah terbentuk. Model MARS yang didapatkan masih dalam bentuk komponen independen, sehingga sebelum dilakukan validasi model perlu dikembalikan ke dalam bentuk variabel sembilan grid dengan cara mengalikan variabel sembilan

grid yang telah distandarisasi tersebut dengan masing-masing *eigenvector*nya.

Nilai prakiraan suhu maksimum, suhu minimum, dan kelembapan di stasiun Soekarno Hatta dengan model MARS disajikan pada Tabel 4.7.

Tabel 4.7 Nilai Prediksi Tmaks, Tmin, dan RH di Stasiun Soekarno Hatta

N	Tmaks		Tmin		RH	
	Y(obs)	$\hat{Y}_{Tmaks}$	Y(obs)	$\hat{Y}_{T\min}$	Y(obs)	$\hat{Y}_{RH}$
346	31,80	31,65	23,70	24,05	81,48	78,96
347	32,90	31,79	24,10	23,92	76,93	79,90
348	33,00	32,32	24,70	23,93	79,96	79,90
349	31,00	31,49	24,80	24,20	82,61	78,26
350	32,80	31,59	23.40	23,96	80,57	79,25
351	33,20	31,91	24.50	23,93	78,24	80,07
352	34,60	31,41	26.20	23,97	72,71	78,67

Validasi model MARS dilakukan pada data *out sample* sehingga diperoleh RMSEP yang disajikan pada Tabel 4.8.

Tabel 4.8 Kriteria RMSEP di Stasiun Pengamatan

Stasiun	**Respon**	**Nilai RMSEP**	**Kriteria RMSEP BMKG**
Soekarno Hatta	Tmaks	1,48	Buruk
	Tmin	0,97	Sedang
	RH	3,27	Baik
Juanda	Tmaks	1,32	Buruk
	Tmin	0,89	Sedang
	RH	7,58	Buruk

Tabel 4.8 menunjukkan nilai RMSEP dari masing-masing variabel respon di stasiun Soekarno Hatta dan Juanda menggunakan metode MARS. Nilai RMSEP pada pemodelan Tmaks menggunakan metode MARS di Stasiun Soekarno Hatta dan Juanda berkriteria buruk, yaitu berkisar antara 1,32-1,48. Nilai RMSEP pada pemodelan Tmin di stasiun Soekarno Hatta dan Juanda berkriteria sedang yaitu 0,97 dan 0,89. Pemodelan MARS untuk variabel respon RH pada stasiun Soekarno Hatta berkriteria baik dengan nilai RMSEP sebesar 1,32 dan Juanda memiliki kriteria buruk karena nilai RMSEP diatas 7.

4.5 Perbandingan Keakuratan Hasil Prediksi NWP dengan Model MOS

Besarnya bias yang dapat terkoreksi oleh model MOS terhadap model NWP ditunjukkan oleh *Percentage Improval* (%IM). %IM dihitung dari selisih antara $RMSEP_{NWP}$ dengan $RMSEP_{MOS}$ kemudian dibagi dengan $RMSEP_{NWP}$. $RMSEP_{NWP}$ dihitung berdasarkan selisih hasil ramalan NWP dengan data observasi untuk variabel Tmaks, Tmin, dan RH pada grid 0,0 yang merupakan grid terdekat pada stasiun pengamatan. Besarnya bias yang dapat terkoreksi oleh model MOS dengan metode MARS di masing-masing stasiun disajikan pada tabel 4.9.

Tabel 4.9 Nilai $RMSEP_{NWP}$, $RMSEP_{MOS}$, dan %IM

Stasiun	Respon	RMSEP NWP	RMSEP MOS	%IM
Soekarno Hatta	Tmaks	10,2	1,48	85,5
	Tmin	1,17	0,98	15,94
	RH	7,23	3,27	54,83
Juanda	Tmaks	11,04	1,32	88,08
	Tmin	1,47	0,89	39,48
	RH	13,7	7,58	44,65

Tabel 4.9 menunjukkan bahwa nilai RMSEP yang dihasilkan oleh model MOS lebih kecil daripada nilai RMSEP yang dihasilkan oleh ramalan NWP. Model MOS dapat mengoreksi bias antara 85,5%-88,08% untuk prediksi suhu maksimum, 15,94%-39,48% untuk prediksi suhu minimum, dan 44,65%-54,83% untuk prediksi kelembapan rata-rata.

(Halaman ini sengaja dikosongkan)

BAB V
KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil analisis dan pembahasan, maka diperoleh kesimpulan sebagai berikut.

1. Hasil prapemrosesan NWP menggunakan metode ICA menghasilkan sejumlah 20 komponen di Stasiun Soekarno Hatta dan 21 komponen di Stasiun Juanda, dimana sebagian besar masing-masing variabel prediktor menjadi satu komponen utama. Komponen yang didapatkan dipakai untuk pembentukan model MARS.
2. Nilai RMSEP pada pemodelan Tmaks menggunakan metode MARS di Stasiun Soekarno Hatta dan Juanda berkriteria buruk. Nilai RMSEP pada pemodelan Tmin di stasiun Soekarno Hatta dan Juanda berkriteria sedang. Pemodelan MARS untuk variabel respon RH pada stasiun Soekarno Hatta berkriteria baik dan Juanda memiliki kriteria buruk.
3. Nilai RMSEP yang dihasilkan oleh model MOS lebih kecil daripada nilai RMSEP yang dihasilkan oleh ramalan NWP. Model MOS dapat mengoreksi bias antara 85,5%-88,08% untuk prediksi suhu maksimum, 15,94%-39,48% untuk prediksi suhu minimum, dan 44,65%-54,83% untuk prediksi kelembapan rata-rata.

5.2 Saran

Pada penelitian selanjutnya diharapkan terdapat data NWP yang tersedia setiap harinya sehingga metode analisis selanjutnya menggunakan metode MARS-*timeseries* untuk mengatasi masalah autokorelasi pada data cuaca.

(Halaman ini sengaja dikosongkan)

DAFTAR PUSTAKA

Aldrian, & Susanto. (2003). Identification of Three Dominant Rainfall Regions within Indonesia and Their Relationship to Sea Surface Temperature. *International Journal of Climatology*, 1-2.

Ance. (1986). *Klimatologi Pengaruh Iklim terhadap Tanah dan Tanaman.* Jakarta: Bina Aksara, Jakarta Asian Development Bank.

Anuravega, A. (2013). *Post Processing Permalan Unsur Cuaca dengan Model Output Statistics (MOS) : Studi Perbandingan antara Reduksi Dimensi Independent Component Analysis (ICA) dan Principal Component Ananlysis (PCA).* Surabaya: Jurusan Statistika, InstitutTeknologi Sepuluh Nopember.

Arfianto, A. D. (2006). *Aplikasi Model Regresi Logistik untuk Prakiraan Kejadian Hujan.* Bogor: Departemen Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Teknologi Bogor.

BMKG. (2010, Oktober 12). Kondisi Cuaca Ekstrem dan Iklim Tahun 2010-2011. *Press Release*, p. 7.

BMKG, B. (2004). *Verifikasi dan Jangkauan Prakiraan Cuaca Jangka Pendek.* Jakarta: BMKG.

Budiantara, I. N., Suryadi, F., Otok, B. W., & Guritno, S. (2006). Pemodelan B-Spline dan MARS Pada Nilai Ujian Masuk terhadap IPK Mahasiswa Jurusan Desain Komunikasi Visual UK. Petra Surabaya. *Jurnal Teknik Industri*,, pp-1.

Cherkassky, F., & Mulier, F. M. (1998). *Learning from Data : Concepts, Theory, and Methods.* John & Wiley.

Clark, M. P., Hay, L. E., & Whitaker, J. S. (2001). Development of Operational Hydrologic Forecasting Capabilities. *AGU Fall Meeting Abstract*, Vol. 1, p. 267.

Davis, J.T. (2004). Bias Removal and Model Consensus Forecast of Maximum and Minimum Temperatures using the

Graphical Forecast Editor. *NOOA NWS Office Tusco, Arizona, WR Technical 04*, 10-13.

Drapper, N. R., & Smith, H. (1992). *Analisis Regresi Terapan Edisi ke-3 (Penerjemah : Bambang Sumantri)*. Jakarta: PT Gramedia Pustaka Utama.

Friedman, J. H. (1991). Multivariate Adaptive Regression Splines. *The Annals of Statistics*, 1-67.

Glahn, H. R., & Lowry, D. A. (1972). The Use Model Output Statistics (MOS) in Objective Weather Forecasting. *Journal of Apllication Meteorology*, 11.

Hyvarinen, A., & Oja, E. (2000). Independent Component Analysis. (pp. 411-430). Neural Networks 13.

Idowu, O. S., & Rautenbach, C. d. (2009). *Model Output Statistics to Improve Severe Storm Prediction Over Western Sahel.* South Afrika: Departement of Geography, Geoinformatics, and Meteorology, University of Pretoria.

Lakitan, B. (2002). *Dasar-dasar Klimatologi.* Jakarta: PT Raja Grafindo Jakarta.

Nash, M. S., & Bradford, D. F. (2001). *Parametric and Nonparamteric Logistic Regression for Prediction of Presence/Absence of an Amphibian.* U.S. Environmental Protection Agency, Office of Research and Development, National Exposure Research Laboratory, Environmental Sciences Division.

NCAR, N. (2017). *User's Guide Describe the Advanced Research WRF (ARW) Version 3.8 Modelling.* USA.

Neiburger. (1995). *Memahami Lingkungan Sekitar Kita.* Bandung: Institut Teknologi Sepuluh Nopember.

Neilley, P. P., & Hanson, K. A. (2004). Are Model Output Statistics Still Need? *Preprints, 20tn Conference on Weather Analysis and Forecasting/16th Conference on Numerical Weather Prediction, Seatle, WA* (p. 64). Amer: Meteor.

Nichols, M. (2008-2009). *Model Output Statistics.* Independent Research Program.

Priambudi, A. K. (2006). *Regresi Splines Adaptif Berganda untuk Peramalan Suhu dan Kelembapan.* Bogor: Skripsi, Jurusan Statistika, Institut Pertanian Bogor.

Priastuti, M. (2013). *Klasifikasi Kejadian Hujan Menggunakan Regresi Logistik Ordinal dan Principal Component Analysis sebagai Pra-Pemrosesan Data Numerical Weather Prediction.* Surabaya: Tugas Akhir, Jurusan Statistika, Institut Teknologi Sepuluh Nopember.

Royston, J. P. (1982). An Extension of Shapiro and Wilk's W Test for Normality to Large Samples. *Jornal Application Statistics*, 115-124.

Sari, I. G. (2013). *Pendekatan Regresi Partial Least Square Univariate & Multivariate Response untuk Prediksi Suhu dan Kelembapan.* Surabaya: Tesis Jurusan Statistika ITS.

Setiawan, D. I. (2015). *Multivariate Adaptive Regression Spline untuk Prediksi Suhu dan Kelembapan dengan Pra-Pemrosesan Principal Component Analysis.* Surabaya: Jurusan Statistika, Institut Teknologi Sepuluh Nopember.

Stull, R. B. (2000). *Meteorology for Science and Enginers.* USA: Brooks/Cole.

Sutikno. (2002). *Penggunaan Regresi Splines Adaptif Berganda untuk Peramalan Indeks ENSO dan Hujan Bulanan.* Bogor: Tesis Jurusan Statistika Institut Pertanian Bogor.

Sutikno. (2008). *Statistical Downscaling Luaran GCM dan Pemanfaatannya untuk Peramalan Produksi Padi.* Bogor: Tesis, Jurusan Statistika, Institut Pertanian Bogor.

Tjasyono, B. H. (2006). *Klimatologi.* Bandung: ITB.

Tyasono, B. (2004). *Klimatologi.* Bandung: Institut Teknologi Bandung.

Walpole, R. (1995). Pengantar Statistika. In B. Sumantri , *Pengantar Statistika.* Jakarta: PT. Gramedia Pustaka Utama.

Wilks, D. S. (2006). *Statistical Methods in the Atmospheric Sciences (2nd).* Boston: Elsevier.

(Halaman ini sengaja dikosongkan)

LAMPIRAN

Lampiran 1 Data Observasi Stasiun Soekarno Hatta

Waktu	Tmaks	Tmin	Rh
02/01/2015	30,2	23,9	88,61667
03/01/2015	29,9	23,4	86,12105
04/01/2015	28,4	24,2	88,09565
05/01/2015	31,6	23,8	80,9375
06/01/2015	31,6	24,4	79,325
07/01/2015	32,2	24	78,45833
08/01/2015	31,2	24,2	80,33043
09/01/2015	32,6	25,4	76,13182
10/01/2015	32,2	24,2	77,31304
⋮	⋮	⋮	⋮
16/06/2015	32,1	24,6	72,28333
⋮	⋮	⋮	⋮
17/11/2016	32,6	23,5	76,37083
18/11/2016	31,8	23,7	81,475
19/11/2016	32,9	24,1	76,925
20/11/2016	33	24,7	79,9625
21/11/2016	31	24,8	82,6125
22/11/2016	32,8	23,4	80,57083
23/11/2016	33,2	24,5	78,24167
10/12/2016	34,6	26,2	72,7125

Lampiran 2 Data Observasi Stasiun Juanda

Waktu	Tmaks	Tmin	Rh
02/01/2015	32,5	23,6	82,487
03/01/2015	30,1	24,8	82,608
04/01/2015	32,6	24,3	83,965
05/01/2015	32,4	24,2	84,758
06/01/2015	32,7	24,5	75,675
07/01/2015	33,7	24,7	73,767
08/01/2015	33,4	25,2	71,725
09/01/2015	32,9	24,8	68,908
10/01/2015	34	24,4	68,267
⋮	⋮	⋮	⋮
19/06/2015	31,3	24,2	76,625
⋮	⋮	⋮	⋮
17/11/2016	33	21	82,571
18/11/2016	33,2	24,7	77,621
19/11/2016	34	26	74,025
20/11/2016	33,8	26	76,858
21/11/2016	33,4	26,8	78,029
22/11/2016	31,8	25,6	81,8
23/11/2016	32	26,4	84,913
10/12/2016	31,4	25,8	76,988

Lampiran 3 Data NWP Model WRF-EMS di Stasiun Soekarno Hatta

Hujan Total									
Waktu	(1,1)	(0,1)	(-1,1)	(1,0)	(0,0)	(-1,0)	(1,-1)	(0,-1)	(-1_-1)
2015:1:2:0	9,3	6,54	5,74	0,88	5,23	4,73	3,52	5,79	5,56
2015:1:3:0	6,43	6,51	10,71	1,02	0,68	1,99	0,33	1,38	3,41
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2015:6:19:0	0	0	0	0	0	0	0	0	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2016:12:10:0	2,94	2,24	2,14	0,26	0	0	0	0	0
Dew2m									
2015:1:2:0	24,28619	24,23073	24,20148	23,8651	22,33902	22,2911	21,63602	21,82398	21,94256
2015:1:3:0	24,07083	23,99804	23,99929	23,63066	21,97429	22,00138	21,46233	21,54379	21,68908
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2015:6:19:0	22,97092	23,10921	23,1598	22,1843	20,48684	20,47255	18,92647	19,30505	19,622
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2016:12:10:0	24,30028	24,17774	24,13974	24,06187	22,24866	22,07353	21,6932	21,67499	21,73062

Lampiran 3 Data NWP Model WRF-EMS di Stasiun Soekarno Hatta (Lanjutan)

V wind 10m									
Waktu	(1,1)	(0,1)	(-1,1)	(1,0)	(0,0)	(-1,0)	(1,-1)	(0,-1)	(-1_-1)
2015:1:2:0	-0,70361	-0,56611	-0,31069	-0,43527	-0,27694	-0,05944	-0,10444	0,375976	0,577226
2015:1:3:0	0,845254	0,953171	1,155671	0,866504	0,900671	1,074005	0,608588	0,987338	1,188171
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2015:6:19:0	0,700989	0,358072	-0,05818	-0,04484	-0,24943	-0,29109	0,01724	-0,06693	-0,13734
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2016:12:10:0	1,258276	1,279375	1,357242	0,974884	0,842097	0,983895	0,846104	0,988704	1,212001
Surface Vis									
2015:1:2:0	24160,83	24160,8292	24160,83	24160,83	24160,83	24160,83	24160,83	24160,83	24160,83
2015:1:3:0	24135,36	24135,3625	24135,36	24135,36	24043,7	23402,03	24135,36	23752,03	22727,03
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2015:6:19:0	24083,95	24083,9542	24083,95	24083,95	24083,95	24083,95	24083,95	24083,95	24083,95
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2016:12:10:0	490,1511	554,930108	502,9901	495,2416	593,1531	534,3176	567,3944	641,365	602,1978

Lampiran 4 Data NWP Model WRF-EMS di Stasiun Juanda

				Hujan Total					
Waktu	(1_1)	(0_1)	(-1_1)	(1_0)	(0_0)	(-1_0)	(1_-1)	(0_-1)	(-1_-1)
2015:1:2:0	4,55	2,01	2,78	0	5,61	9,61	4,51	5,41	11,86
2015:1:3:0	8,05	8,26	9,19	2,8	8,45	9,6	3,1	2,65	5,68
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2015:6:19:0	0	0	0	0	0	0	0	0	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2016:12:10:0	29,24	16,57	15,49	2,89	6,86	12,05	0	3,04	9,91
				dew2m					
2015:1:2:0	24,452646	23,241229	23,0969	24,108646	22,624396	22,657854	21,353438	21,065313	21,351438
2015:1:3:0	24,414329	23,257329	23,077413	24,264538	22,714704	22,682704	21,566288	21,142163	21,497538
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2015:6:19:0	23,104504	19,996879	18,877879	22,749796	18,919046	18,042629	18,855004	17,421921	17,052629
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2016:12:10:0	24,108663	23,022867	23,015908	23,866033	22,228996	22,060992	20,799408	20,099663	20,317492

Lampiran 4 Data NWP Model WRF-EMS di Stasiun Juanda (Lanjutan)

				v wind 10m					
Waktu	(1_1)	(0_1)	(-1_1)	(1_0)	(0_0)	(-1_0)	(1_-1)	(0_-1)	(-1_-1)
2015:1:2:0	-1,6461069	-1,1490235	-0,8315236	-1,3823568	-0,1690235	0,1943094	0,6168095	2,03931	1,7772264
2015:1:3:0	-2,5772463	-1,6630798	-1,1255801	-2,5455793	-0,4109968	-0,0372466	0,2490041	2,6094213	2,5573379
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2015:6:19:0	4,1822392	2,3080727	0,8518227	4,2084891	1,433906	0,1968227	3,8601562	1,7326559	1,0376557
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2016:12:10:0	-0,5179288	-0,6587619	0,0349878	-1,1087622	0,5149877	2,337904	0,3749875	3,2599878	4,8824879
				Surface vis					
2015:1:2:0	24160,829	24160,829	24160,829	24160,829	24160,829	24160,829	24160,829	24160,829	24160,829
2015:1:3:0	24135,363	24135,363	24135,363	24135,363	24135,363	24135,363	24135,363	24135,363	24135,363
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2015:6:19:0	24083,954	24083,954	24083,954	24083,954	24083,954	24083,954	24083,954	24083,954	24083,954
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2016:12:10:0	21166,275	21824,609	22099,607	23824,608	24207,942	24207,942	24207,942	24207,942	24207,942

Lampiran 5 Rata-rata dan Standar Deviasi Variabel Respon di Stasiun Soekarno Hatta

Variabel	Rata-rata	Standar Deviasi
Tmaks	32,10	1,22
Tmin	24,08	0,83
RH	77,97	5,85

Lampiran 6 Rata-rata dan Standar Deviasi Variabel Respon di Stasiun Juanda

Variabel	Rata-rata	Standar Deviasi
Tmaks	31,93	0,98
Tmin	24,59	1,30
RH	77,16	6,16

Lampiran 7 Syntax Uji Distribusi Normal Multivariat

```
library(mvnormtest)
data=read.csv("E://hujan_tot.csv", sep=";",header=TRUE)
C=t(data)
mshapiro.test(C)
```

Lampiran 8 Syntax ICA

```
ica=function(data,m,x,y)
{
a=fastICA(data,9,alg.typ="deflation",fun="exp",alpha=1,method="R",
row.norm=FALSE,maxit=200,tol=0.0001,verbose=TRUE)
par(mfrow=c(1,3))
plot(a$X, main="Pre-processed data")
plot(a$X%*%a$K, main="PCA components")
plot(a$S, main="ICA components")
cor_ica=cor(a$A)
eig_ica=eigen(cor_ica)
ic=as.matrix(data)%*%eig_ica$vectors[1:9,1:x]
cor_pca=cor(a$X)
eig_pca=eigen(cor_pca)
pc=as.matrix(data)%*%eig_pca$vectors[1:9, 1:y]
write.csv(eig_ica, file="e://eigen_ica.csv")
write.csv(ic, file="e://comp_ica.csv")
write.csv(eig_pca, file="e://eigen_pca.csv")
write.csv(pc, file="e://comp_pca.csv")
}
library(fastICA)
setwd("E:/")
file=read.csv("E://soetta1.csv", sep=";",header=TRUE)
data=as.matrix(file)
ica(data,9,x,y)
```

Lampiran 9 Hasil Uji Normal Multivariat Variabel Prediktor Stasiun Soekarno Hatta

Variabel	**MVW**	***P-value***	**Keputusan**
hujan_tot	0,38	$2.20\text{x}10^{-16}$	Tidak berdistribusi normal multivariat
dew2m	0,92	$1{,}49\text{x}10^{-12}$	Tidak berdistribusi normal multivariat
windgust	0,90	$4{,}19\text{x}10^{-14}$	Tidak berdistribusi normal multivariat
hi_cloud	0,68	$2{,}20\text{x}10^{-16}$	Tidak berdistribusi normal multivariat
low_cloud	0,47	$2{,}20\text{x}10^{-16}$	Tidak berdistribusi normal multivariat
mid_cloud	0,85	$2{,}20\text{x}10^{-16}$	Tidak berdistribusi normal multivariat
tot_cloud	0,83	$2{,}20\text{x}10^{-16}$	Tidak berdistribusi normal multivariat
mslp	0,85	$2{,}20\text{x}10^{-16}$	Tidak berdistribusi normal multivariat
sur_press	0,91	$6{,}18\text{x}10^{-14}$	Tidak berdistribusi normal multivariat
rhum2m	0,92	$4{,}59\text{x}10^{-13}$	Tidak berdistribusi normal multivariat
shum2m	0,93	$2{,}27\text{x}10^{-11}$	Tidak berdistribusi normal multivariat
temp2m	0,77	$2{,}20\text{x}10^{-16}$	Tidak berdistribusi normal multivariat
uwind	0,94	$5{,}80\text{x}10^{-11}$	Tidak berdistribusi normal multivariat
vwind	0,85	$2{,}20\text{x}10^{-16}$	Tidak berdistribusi normal multivariat
survis	0,29	$2{,}20\text{x}10^{-16}$	Tidak berdistribusi normal multivariat

Lampiran 10 Hasil Uji Normal Multivariat Variabel Prediktor Stasiun Juanda

Variabel	MVW	*P-value*	Keputusan
hujan_tot	0,32	$2,20x10^{-16}$	Tidak berdistribusi normal multivariat
dew2m	0,80	$2,20x10^{-16}$	Tidak berdistribusi normal multivariat
windgust	0,90	$3,60x10^{-14}$	Tidak berdistribusi normal multivariat
hi_cloud	0,89	$3,10x10^{-16}$	Tidak berdistribusi normal multivariat
low_cloud	0,38	$2,20x10^{-16}$	Tidak berdistribusi normal multivariat
mid_cloud	0,59	$2,20x10^{-16}$	Tidak berdistribusi normal multivariat
tot_cloud	0,73	$2,20x10^{-16}$	Tidak berdistribusi normal multivariat
mslp	0,84	$2,20x10^{-16}$	Tidak berdistribusi normal multivariat
sur_press	0,89	$2,15x10^{-14}$	Tidak berdistribusi normal multivariat
rhum2m	0,95	$4,57x10^{-13}$	Tidak berdistribusi normal multivariat
shum2m	0,81	$2,20x10^{-16}$	Tidak berdistribusi normal multivariat
temp2m	0,89	$3,90x10^{-16}$	Tidak berdistribusi normal multivariat
uwind	0,88	$4,53x10^{-11}$	Tidak berdistribusi normal multivariat
vwind	0,83	$2,20x10^{-16}$	Tidak berdistribusi normal multivariat
survis	0,27	$2,20x10^{-16}$	Tidak berdistribusi normal multivariat

Lampiran 11 Jumlah Komponen Independen Variabel NWP di Stasiun Soekarno Hatta

Variabel	Jml. IC	Nilai Eigen	Varians Kum.	Variabel	JmI IC	Nilai Eigen	Varians Kum.
hujantot	2	6,20	68,90%	surpress	1	8,97	99,69%
		1,54	86,03%	rhum2m	2	7,54	83,8%
dew2m	1	8,31	92,39%			1,26	97,9%
windgust	1	8,16	90,71%	shum2m	1	8,37	93,08%
hicloud	1	8,28	92,08%	temp2m	2	4,97	55,31%
lowcloud	2	6,24	69,36%			3,05	89,29%
		1,48	85,90%	uwind	1	8,85	98,36%
midcloud	1	8,15	90,66%	vwind	1	7,92	88,11%
totcloud	1	8,18	90,95%	survis	2	6,75	75,05%
mslp	1	8,95	99,46%			1,48	91,58%

Lampiran 12 Jumlah Komponen Independen Variabel NWP di Stasiun Juanda

Variabel	Jml. IC	Nilai Eigen	Varians Kum.	Variabel	Jml. IC	Nilai Eigen	Varians Kum.
hujan_tot	2	6,31	70,14%	sur_press	1	8,93	99,22%
		1,45	86,28%	rhum2m	1	7,73	85,83%
dew2m	1	8,60	95,53%	shum2m	1	8,52	94,68%
wind_gust	2	6,81	75,66%	temp2m	2	6,56	72,90%
		1,17	88,62%			2,05	95,73%
hi_cloud	1	8,30	92,18%	uwind	1	8,86	98,43%
low_cloud	2	5,63	62,59%	vwind	1	6,55	72,74%
		1,73	81,77%			1,85	93,33%
mid_cloud	1	8,44	93,73%	survis	2	6,78	75,30%
tot_cloud	1	8,19	90,95%			1,42	91,06%
Mslp	1	8,94	99,36%				

Lampiran 13 Kombinasi Basis Fungsi (BF), Maksimum Interaksi (MI), Minimum Observasi (MO), dan Nilai *Penalty* Pemodelan Tmaks Stasiun Soekarno Hatta

Model	BF	MI	MO	Penalty	GCV	MSE	R^2	R^2 (Adj)	Jml Variabel
1	40	1	5	0,05	0,606	0,54	0,472	0,46	4
2	40	2	5	0,05	0,614	0,547	0,464	0,453	4
3	40	3	5	0,05	0,612	0,481	0,539	0,519	4
4	40	1	10	0,05	0,608	0,526	0,488	0,473	4
5	40	2	10	0,05	0,621	0,571	0,437	0,429	3
6	40	3	10	0,05	0,593	0,537	0,472	0,463	3
7	40	1	20	0,05	0,602	0,544	0,466	0,455	4
8	40	2	20	0,05	0,651	0,531	0,485	0,468	3
9	40	3	20	0,05	0,602	0,528	0,484	0,472	4
10	40	1	5	0,1	0,675	0,606	0,406	0,393	2
11	40	2	5	0,1	0,637	0,567	0,444	0,432	3
12	40	3	5	0,1	0,633	0,544	0,468	0,456	3
13	40	1	10	0,1	0,684	0,614	0,398	0,386	2
14	40	2	10	0,1	0,594	0,525	0,485	0,474	3
15	40	3	10	0,1	0,601	0,523	0,49	0,476	3
16	40	1	20	0,1	0,69	0,629	0,382	0,371	2
17	40	2	20	0,1	0,63	0,552	0,459	0,448	3
18	40	3	20	0,1	0,621	0,559	0,45	0,44	3
19	60	1	5	0,05	0,602	0,527	0,486	0,472	4
20	60	2	5	0,05	0,605	0,528	0,484	0,472	4
21	60	3	5	0,05	0,61	0,483	0,536	0,517	4
22	60	1	10	0,05	0,605	0,554	0,455	0,446	4
23	60	2	10	0,05	0,651	0,55	0,465	0,45	3
24	60	3	10	0,05	0,609	0,528	0,483	0,471	3
25	60	1	20	0,05	0,598	0,532	0,48	0,468	4

Lampiran 15 Kombinasi Basis Fungsi (BF), Maksimum Interaksi (MI), Minimum Observasi (MO), dan Nilai *Penalty* Pemodelan Tmaks Stasiun Soekarno Hatta (Lanjutan)

Model	BF	MI	MO	Penalty	GCV	MSE	R^2	R^2 (Adj)	Jml Variabel
26	60	2	20	0,05	0,62	0,547	0,464	0,453	3
27	60	3	20	0,05	0,609	0,53	0,393	0,47	4
28	60	1	5	0,1	0,679	0,61	0,402	0,39	2
29	60	2	5	0,1	0,622	0,512	0,504	0,488	3
30	60	3	5	0,1	0,64	0,574	0,436	0,426	3
31	60	1	10	0,1	0,688	0,637	0,372	0,363	2
32	60	2	10	0,1	0,627	0,543	0,47	0,457	3
33	60	3	10	0,1	0,621	0,557	0,454	0,443	3
34	60	1	20	0,1	0,647	0,6	0,408	0,4	3
35	60	2	20	0,1	0,642	0,533	0,482	0,467	3
36	60	3	20	0,1	0,668	0,537	0,482	0,463	3
37	80	1	5	0,05	0,601	0,533	0,479	0,466	4
38	**80**	**2**	**5**	**0,05**	**0,581**	**0,514**	**0,496**	**0,486**	**5**
39	80	3	5	0,05	0,635	0,513	0,506	0,487	4
40	80	1	10	0,05	0,606	0,554	0,455	0,446	4
41	80	2	10	0,05	0,668	0,625	0,382	0,275	3
42	80	3	10	0,05	0,618	0,566	0,442	0,434	3
43	80	1	20	0,05	0,598	0,531	0,481	0,468	4
44	80	2	20	0,05	0,622	0,486	0,532	0,513	4
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
53	80	2	20	0,1	0,619	0,544	0,466	0,455	3
54	80	3	20	0,1	0,622	0,559	0,45	0,44	3

Lampiran 14 Kombinasi Basis Fungsi (BF), Maksimum Interaksi (MI), Minimum Observasi (MO), dan Nilai *Penalty* Pemodelan Tmin Stasiun Soekarno Hatta

Mode	MI	MO		Penalty	GCV	MSE	R^2	R^2 (Adj)	Jml Variabel
1	40	1	5	0,05	0,743	0,712	0,29	0,283	3
2	**40**	**2**	**5**	**0,05**	**0,736**	**0,676**	**0,33**	**0,32**	**3**
3	40	3	5	0,05	0,828	0,71	0,303	0,286	3
4	40	1	10	0,05	0,742	0,702	0,302	0,294	3
5	40	2	10	0,05	0,744	0,648	0,363	0,348	3
6	40	3	10	0,05	0,763	0,669	0,341	0,327	3
7	40	1	20	0,05	0,747	0,707	0,297	0,289	3
8	40	2	20	0,05	0,795	0,743	0,261	0,253	3
9	40	3	20	0,05	0,756	0,679	0,329	0,317	3
10	40	1	5	0,1	0,83	0,793	0,209	0,202	1
11	40	2	5	0,1	0,776	0,717	0,288	0,279	2
12	40	3	5	0,1	0,766	0,74	0,26	0,256	2
13	40	1	10	0,1	0,766	0,733	0,269	0,263	2
14	40	2	10	0,1	0,768	0,74	0,26	0,256	3
15	40	3	10	0,1	0,768	0,701	0,305	0,295	3
16	40	1	20	0,1	0,769	0,736	0,266	0,259	2
17	40	2	20	0,1	0,771	0,74	0,26	0,256	2
18	40	3	20	0,1	0,76	0,692	0,314	0,304	3
19	60	1	5	0,05	0,744	0,712	0,29	0,283	3
20	60	2	5	0,05	0,764	0,71	0,294	0,286	3
21	60	3	5	0,05	0,792	0,706	0,303	0,29	3
22	60	1	10	0,05	0,744	0,702	0,302	0,294	5
23	60	2	10	0,05	0,805	0,735	0,272	0,261	3
24	60	3	10	0,05	0,769	0,698	0,308	0,298	3
25	60	1	20	0,05	0,743	0,702	0,303	0,294	3

Lampiran 14 Kombinasi Basis Fungsi (BF), Maksimum Interaksi (MI), Minimum Observasi (MO), dan Nilai *Penalty* Pemodelan Tmin Stasiun Soekarno Hatta (Lanjutan)

Model	BF	MI	MO	Penalty	GCV	MSE	R^2	R^2 (Adj)	Jml Variabel
26	60	2	20	0,05	0,788	0,733	0,271	0,262	3
27	60	3	20	0,05	0,793	0,698	0,312	0,298	4
28	60	1	5	0,1	0,772	0,749	0,251	0,247	2
29	60	2	5	0,1	0,784	0,741	0,262	0,255	2
30	60	3	5	0,1	0,79	0,728	0,268	0,208	3
31	60	1	10	0,1	0,767	0,733	0,269	0,263	2
32	60	2	10	0,1	0,795	0,778	0,22	0,217	2
33	60	3	10	0,1	0,769	0,74	0,26	0,256	2
34	60	1	20	0,1	0,743	0,701	0,303	0,295	3
35	60	2	20	0,1	0,801	0,727	0,28	0,269	2
36	60	3	20	0,1	0,763	0,692	0,314	0,304	3
37	80	1	5	0,05	0,745	0,712	0,29	0,283	3
38	80	2	5	0,05	0,766	0,71	0,294	0,286	3
39	80	3	5	0,05	0,791	0,706	0,303	0,29	3
40	80	1	10	0,05	0,744	0,702	0,302	0,294	3
41	80	2	10	0,05	0,808	0,749	0,256	0,247	3
42	80	3	10	0,05	0,765	0,669	0,341	0,327	3
43	80	1	20	0,05	0,744	0,702	0,303	0,294	3
44	80	2	20	0,05	0,772	0,704	0,302	0,292	3
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
53	80	2	20	0,1	0,821	0,743	0,263	0,253	2
54	80	3	20	0,1	0,784	0,752	0,248	0,244	2

Lampiran 15 Kombinasi Basis Fungsi (BF), Maksimum Interaksi (MI), Minimum Observasi (MO), dan Nilai *Penalty* Pemodelan RH Stasiun Soekarno Hatta

Model	BF	MI	MO	Penalty	GCV	MSE	R2	R^2 (Adj)	Jml Variabel
1	40	1	5	0,05	0,468	0,426	0,588	0,58	4
2	40	2	5	0,05	0,472	0,439	0,573	0,567	4
3	40	3	5	0,05	0,485	0,357	0,668	0,648	4
4	40	1	10	0,05	0,477	0,45	0,562	0,556	4
5	40	2	10	0,05	0,463	0,418	0,596	0,588	5
6	40	3	10	0,05	0,483	0,441	0,573	0,565	4
7	40	1	20	0,05	0,493	0,46	0,553	0,546	3
8	40	2	20	0,05	0,487	0,451	0,562	0,556	4
9	40	3	20	0,05	0,483	0,422	0,594	0,584	4
10	40	1	5	0,1	0,524	0,509	0,501	0,498	2
11	40	2	5	0,1	0,553	0,476	0,541	0,53	2
12	40	3	5	0,1	0,5	0,42	0,599	0,86	3
13	40	1	10	0,1	0,513	0,498	0,512	0,509	2
14	40	2	10	0,1	0,537	0,499	0,514	0,508	2
15	40	3	10	0,1	0,496	0,421	0,597	0,585	3
16	40	1	20	0,1	0,516	0,501	0,509	0,506	2
17	40	2	20	0,1	0,519	0,5	0,51	0,507	2
18	40	3	20	0,1	0,495	0,435	0,581	0,571	3
19	60	1	5	0,05	0,466	0,422	0,532	0,584	4
20	60	2	5	0,05	0,478	0,441	0,571	0,565	4
21	60	3	5	0,05	0,463	0,394	0,624	0,612	5
22	60	1	10	0,05	0,473	0,439	0,573	0,567	4
23	60	2	10	0,05	0,468	0,377	0,642	0,628	5
24	60	3	10	0,05	0,499	0,381	0,643	0,624	4

Lampiran 15 Kombinasi Basis Fungsi (BF), Maksimum Interaksi (MI), Minimum Observasi (MO), dan Nilai *Penalty* Pemodelan RH Stasiun Soekarno Hatta (Lanjutan)

Model	BF	MI	MO	Penalty	GCV	MSE	R^2	R^2 (Adj)	Jml Variabel
25	60	1	20	0,05	0,477	0,449	0,562	0,557	4
26	60	2	20	0,05	0,48	0,444	0,569	0,563	4
27	60	3	20	0,05	0,48	0,441	0,571	0,565	4
28	60	1	5	0,1	0,514	0,498	0,512	0,509	2
29	60	2	5	0,1	0,548	0,509	0,504	0,498	2
30	60	3	5	0,1	0,509	0,396	0,626	0,609	3
31	60	1	10	0,1	0,515	0,5	0,51	0,507	2
32	60	2	10	0,1	0,53	0,51	0,5	0,497	2
33	60	3	10	0,1	0,485	0,413	0,604	0,593	3
34	60	1	20	0,1	0,494	0,46	0,553	0,546	3
35	60	2	20	0,1	0,554	0,512	0,501	0,495	2
36	60	3	20	0,1	0,5	0,467	0,545	0,54	3
37	80	1	5	0,05	0,483	0,407	0,612	0,598	5
38	80	2	5	0,05	0,495	0,436	0,58	0,57	4
39	80	3	5	0,05	0,473	0,353	0,67	0,652	5
40	80	1	10	0,05	0,473	0,439	0,573	0,567	4
41	80	2	10	0,05	0,491	0,443	0,571	0,563	4
42	80	3	10	0,05	0,471	0,389	0,63	0,617	5
43	80	1	20	0,05	0,471	0,42	0,596	0,586	6
44	80	2	20	0,05	0,483	0,351	0,673	0,654	6
45	**80**	**3**	**20**	**0,05**	**0,462**	**0,423**	**0,589**	**0,582**	**5**
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
54	80	3	20	0,1	0,502	0,42	0,598	0,586	3

Lampiran 16 Kombinasi Basis Fungsi (BF), Maksimum Interaksi (MI), Minimum Observasi (MO), dan Nilai *Penalty* Pemodelan Tmaks Stasiun Juanda

Model	BF	MI	MO	Penalty	GCV	MSE	R2	R^2 (Adj)	Jml Variabel
1	42	1	5	0,05	0,555	0.509	0.492	0,483	4
2	42	2	5	0,05	0,498	0,388	0,624	0,606	6
3	42	3	5	0,05	0,498	0,385	0,627	0,609	6
4	42	1	10	0,05	0,472	0,397	0,612	0,597	6
5	42	2	10	0,05	0,543	0,433	0,579	0,56	5
6	42	3	10	0,05	0,515	0,42	0,591	0,573	6
7	42	1	20	0,05	0,513	0,443	0,564	0,55	7
8	42	2	20	0,05	0,538	0,449	0,559	0,544	6
9	42	3	20	0,05	0,509	0,418	0,592	0,576	6
10	42	1	5	0,1	0,588	0,53	0,473	0,462	3
11	42	2	5	0,1	0,571	0,523	0,476	0,468	3
12	42	3	5	0,1	0,581	0,535	0,465	0,457	3
13	42	1	10	0,1	0,597	0,522	0,483	0,469	3
14	42	2	10	0,1	0,607	0,526	0,478	0,465	3
15	42	3	10	0,1	0,601	0,513	0,492	0,479	3
16	42	1	20	0,1	0,703	0,671	0,324	0,318	2
17	42	2	20	0,1	0,706	0,667	0,328	0,323	2
18	42	3	20	0,1	0,682	0,602	0,401	0,389	3
19	63	1	5	0,05	0,53	0,467	0,538	0,526	5
20	63	2	5	0,05	0,503	0,345	0,672	0,649	6
21	63	3	5	0,05	0,457	0,349	0,664	0,646	6
22	63	1	10	0,05	0,476	0,399	0,61	0,595	6
23	63	2	10	0,05	0,521	0,403	0,61	0,59	5
24	63	3	10	0,05	0,474	0,34	0,676	0,654	7
25	63	1	20	0,05	0,501	0,418	0,592	0,576	8

Lampiran 16 Kombinasi Basis Fungsi (BF), Maksimum Interaksi (MI), Minimum Observasi (MO), dan Nilai *Penalty* Pemodelan Tmaks Stasiun Juanda (Lanjutan)

Model	BF	MI	MO	Penalty	GCV	MSE	R2	R^2 (Adj)	Jml Variabel
26	63	2	20	0,05	0,549	0,432	0,579	0,561	6
27	63	3	20	0,05	0,537	0,411	0,603	0,582	6
28	63	1	5	0,1	0,582	0,525	0,477	0,466	3
29	63	2	5	0,1	0,587	0,487	0,521	0,505	3
30	63	3	5	0,1	0,602	0,543	0,458	0,448	3
31	63	1	10	0,1	0,599	0,524	0,481	0,467	3
32	63	2	10	0,1	0,662	0,537	0,472	0,454	3
33	63	3	10	0,1	0,607	0,526	0,478	0,465	3
34	63	1	20	0,1	0,659	0,621	0,376	0,369	3
35	63	2	20	0,1	0,568	0,473	0,533	0,519	5
36	63	3	20	0,1	0,686	0,627	0,373	0,363	3
37	84	1	5	0,05	0,512	0,43	0,578	0,563	6
38	84	2	5	0,05	0,479	0,33	0,687	0,664	7
39	**84**	**3**	**5**	**0,05**	**0,445**	**0,274**	**0,747**	**0,722**	6
40	84	1	10	0,05	0,481	0,399	0,61	0,595	6
41	84	2	10	0,05	0,527	0,376	0,641	0,617	5
42	84	3	10	0,05	0,482	0,314	0,707	0,681	7
43	84	1	20	0,05	0,511	0,425	0,584	0,568	7
44	84	2	20	0,05	0,546	0,435	0,574	0,558	6
45	84	3	20	0,05	0,547	0,407	0,608	0,586	6
46	84	1	5	0,1	0,55	0,503	0,498	0,489	4
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
54	80	3	20	0,1	0,732	0,69	0,315	0,309	3

Lampiran 17 Kombinasi Basis Fungsi (BF), Maksimum Interaksi (MI), Minimum Observasi (MO), dan Nilai *Penalty* Pemodelan Tmin Stasiun Juanda

Model	BF	MI	MO	Penalty	GCV	MSE	R^2	R^2 (Adj)	Jml Variabel
1	42	1	5	0,05	0,567	0,534	0,469	0,463	3
2	42	2	5	0,05	0,575	0,472	0,541	0,526	4
3	42	3	5	0,05	0,543	0,47	0,54	0,528	4
4	42	1	10	0,05	0,563	0,515	0,491	0,482	3
5	42	2	10	0,05	0,567	0,477	0,535	0,521	4
6	42	3	10	0,05	0,572	0,509	0,499	0,488	3
7	42	1	20	0,05	0,544	0,488	0,52	0,509	4
8	42	2	20	0,05	0,552	0,513	0,49	0,484	4
9	42	3	20	0,05	0,544	0,493	0,513	0,504	4
10	42	1	5	0,1	0,584	0,557	0,445	0,44	2
11	42	2	5	0,1	0,596	0,532	0,475	0,466	2
12	42	3	5	0,1	0,547	0,499	0,505	0,498	3
13	42	1	10	0,1	0,584	0,557	0,445	0,44	2
14	42	2	10	0,1	0,583	0,529	0,476	0,468	2
15	42	3	10	0,1	0,549	0,501	0,503	0,496	3
16	42	1	20	0,1	0,582	0,542	0,463	0,455	2
17	42	2	20	0,1	0,593	0,538	0,467	0,459	2
18	42	3	20	0,1	0,564	0,505	0,501	0,492	4
19	63	1	5	0,05	0,549	0,511	0,494	0,486	4
20	63	2	5	0,05	0,545	0,433	0,581	0,565	5
21	63	3	5	0,05	0,554	0,483	0,526	0,515	4
22	63	1	10	0,05	0,543	0,484	0,525	0,513	4
23	63	2	10	0,05	0,553	0,486	0,521	0,511	4
24	63	3	10	0,05	0,553	0,501	0,505	0,496	4
25	63	1	20	0,05	0,546	0,487	0,522	0,511	4

Lampiran 17 Kombinasi Basis Fungsi (BF), Maksimum Interaksi (MI), Minimum Observasi (MO), dan Nilai *Penalty* Pemodelan Tmin Stasiun Juanda (Lanjutan)

Model	BF	MI	MO	Penalty	GCV	MSE	R^2	R^2 (Adj)	Jml Variabel
26	63	2	20	0,05	0,552	0,513	0,49	0,484	4
27	63	3	20	0,05	0,534	0,5	0,503	0,497	4
28	63	1	5	0,1	0,585	0,543	0,462	0,455	2
29	63	2	5	0,1	0,612	0,539	0,469	0,458	2
30	63	3	5	0,1	0,558	0,508	0,496	0,489	3
31	63	1	10	0,1	0,583	0,541	0,464	0,457	2
32	63	2	10	0,1	0,574	0,522	0,483	0,475	2
33	63	3	10	0,1	0,559	0,499	0,507	0,498	3
34	63	1	20	0,1	0,568	0,52	0,487	0,478	3
35	63	2	20	0,1	0,602	0,535	0,471	0,462	2
36	63	3	20	0,1	0,56	0,511	0,494	0,486	4
37	84	1	5	0,05	0,551	0,511	0,494	0,486	4
38	84	2	5	0,05	0,542	0,471	0,537	0,527	5
39	84	3	5	0,05	0,556	0,501	0,505	0,496	4
40	84	1	10	0,05	0,547	0,5	0,506	0,497	4
41	84	2	10	0,05	0,583	0,521	0,485	0,476	3
42	84	3	10	0,05	0,552	0,501	0,505	0,496	4
43	84	1	20	0,05	0,546	0,487	0,522	0,511	4
44	84	2	20	0,05	0,539	0,484	0,522	0,514	4
45	**84**	**3**	**20**	**0,05**	**0,529**	**0,486**	**0,518**	**0,511**	**4**
46	84	1	5	0,1	0,588	0,545	0,46	0,453	2
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
54	84	3	20	0,1	0,567	0,478	0,472	0,432	3

Lampiran 18 Kombinasi Basis Fungsi (BF), Maksimum Interaksi (MI), Minimum Observasi (MO), dan Nilai *Penalty* Pemodelan RH Stasiun Juanda

Model	BF	MI	MO	Penalty	GCV	MSE	R^2	R^2 (Adj)	Jml Variabel
1	42	1	5	0,05	0,288	0,249	0,762	0,754	4
2	42	2	5	0,05	0,274	0,25	0,758	0,754	4
3	42	3	5	0,05	0,276	0,238	0,772	0,765	4
4	42	1	10	0,05	0,284	0,264	0,743	0,74	4
5	42	2	10	0,05	0,294	0,26	0,749	0,743	4
6	42	3	10	0,05	0,722	0,224	0,787	0,779	5
7	42	1	20	0,05	0,285	0,265	0,742	0,739	4
8	42	2	20	0,05	0,288	0,255	0,754	0,749	4
9	42	3	20	0,05	0,302	0,245	0,767	0,758	4
10	42	1	5	0,1	0,304	0,269	0,741	0,735	2
11	42	2	5	0,1	0,322	0,28	0,729	0,724	2
12	42	3	5	0,1	0,301	0,274	0,733	0,729	3
13	42	1	10	0,1	0,313	0,304	0,702	0,7	2
14	42	2	10	0,1	0,313	0,3	0,705	0,703	2
15	42	3	10	0,1	0,288	0,272	0,734	0,731	3
16	42	1	20	0,1	0,316	0,297	0,71	0,707	2
17	42	2	20	0,1	0,309	0,303	0,702	0,701	2
18	42	3	20	0,1	0,317	0,285	0,723	0,718	3
19	63	1	5	0,05	0,283	0,263	0,744	0,74	4
20	**63**	**2**	**5**	**0,05**	**0,264**	**0,213**	**0,798**	**0,79**	**5**
21	63	3	5	0,05	0,267	0,208	0,805	0,795	5
22	63	1	10	0,05	0,277	0,255	0,753	0,748	5
23	63	2	10	0,05	0,287	0,231	0,781	0,772	5
24	63	3	10	0,05	0,271	0,24	0,768	0,763	6
25	63	1	20	0,05	0,285	0,265	0,742	0,738	4

Lampiran 18 Kombinasi Basis Fungsi (BF), Maksimum Interaksi (MI), Minimum Observasi (MO), dan Nilai *Penalty* Pemodelan RH Stasiun Juanda (Lanjutan)

Model	BF	MI	MO	Penalty	GCV	MSE	R^2	R^2 (Adj)	Jml Variabel
26	63	2	20	0,05	0,297	0,251	0,759	0,752	4
27	63	3	20	0,05	0,274	0,252	0,755	0,751	5
28	63	1	5	0,1	0,303	0,269	0,741	0,735	2
29	63	2	5	0,1	0,307	0,279	0,728	0,724	2
30	63	3	5	0,1	0,3	0,274	0,733	0,729	3
31	63	1	10	0,1	0,313	0,304	0,702	0,7	2
32	63	2	10	0,1	0,332	0,278	0,733	0,726	2
33	63	3	10	0,1	0,285	0,262	0,745	0,742	3
34	63	1	20	0,1	0,298	0,277	0,731	0,727	3
35	63	2	20	0,1	0,309	0,303	0,701	0,701	2
36	63	3	20	0,1	0,318	0,28	0,729	0,724	3
37	84	1	5	0,05	0,289	0,249	0,762	0,755	4
38	84	2	5	0,05	0,268	0,239	0,769	0,764	5
39	84	3	5	0,05	0,267	0,222	0,79	0,781	5
40	84	1	10	0,05	0,278	0,255	0,753	0,749	5
41	84	2	10	0,05	0,276	0,237	0,772	0,766	6
42	84	3	10	0,05	0,28	0,252	0,757	0,752	6
43	84	1	20	0,05	0,285	0,265	0,742	0,739	4
44	84	2	20	0,05	0,289	0,241	0,769	0,762	5
45	84	3	20	0,05	0,278	0,256	0,751	0,748	5
46	84	1	5	0,1	0,304	0,269	0,741	0,735	2
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
54	84	3	20	0,1	0,337	0,269	0,744	0,735	3

Lampiran 19 Model MARS Stasiun Soekarno Hatta

Model Suhu Maksminum

$\hat{Y}_{Tmaks}$ = 0.359 + 0.088 * BF2 + 0.101 * BF9 - 0.193 * BF19 - 0.124 * BF30+ 0.548 * BF38 + 0.029 * BF49 - 0.012 * BF75;

dimana

BFKEEP1 = max(0, IC2_TEMP + 5.182);
BF2 = max(0, IC_MIDCL - 0.353) * BF1;
BF6 = max(0, IC1_TEMP + 0.386);
BF7 = max(0, - 0.386 - IC1_TEMP);
BF9 = max(0, 1.401 - IC_MIDCL) * BF7;
BF19 = max(0, IC2_TEMP + 2.401);
BF28 = max(0, - 1.875 - IC_MIDCL);
BF30 = max(0, - 0.010 - IC1_TEMP) * BF28;
BF38 = max(0, - 3.103 - IC_SHUM2);
BF49 = max(0, IC_SHUM2 + 1.386) * BF6;
BF75 = max(0, IC_VWIND + 7.268) * BF1;

Model Suhu Minimum

Y = -0.425 + 0.582 * BF2 + 0.279 * BF3 + 0.076 * BF18 + 0.323 * BF22 - 0.313 * BF24;

dimana

BF2 = max(0, - 2.749 - IC_DEW2M);
BF3 = max(0, IC_UWIND - 1.226);
BF5 = max(0, IC_DEW2M - 1.501);
BF18 = max(0, IC_SURPR + 4.875);
BF22 = max(0, IC_SURPR + 4.875) * BF5;
BF24 = max(0, IC_SURPR + 5.866) * BF5;

Model Kelembapan Rata-rata

$\hat{Y}_{RH}$ = 1.144 - 0.038 * BF8 - 0.028 * BF24 - 0.041 * BF55- 0.018 * BF70 - 0.068 * BF76;

dimana

BF2 = max(0, 3.866 - IC1_RHUM);
BF3 = max(0, IC_UWIND + 1.354);
BF8 = max(0, 3.769 - IC1_RHUM) * BF3;
BF24 = max(0, - 1.653 - IC_VWIND) * BF2;
BF34 = max(0, IC1_RHUM + 3.278);
BF53 = max(0, IC_VWIND + 3.459);
BF55 = max(0, IC_DEW2M + 1.348) * BF53;
BF70 = max(0, IC_UWIND + 9.077) * BF34;
BF74 = max(0, - 0.180 - IC_UWIND) * BF34;
BF76 = max(0, - 1.087 - IC1_TEMP) * BF74;

Lampiran 20 Model MARS Stasiun Juanda

Model Suhu Maksimum

Y = 6.506 - 0.159 * BF1 - 2.949 * BF4 + 1.903 * BF6 - 0.203 * BF8 + 0.502 * BF11 + 1.382 * BF12 - 1.136 * BF13 - 0.325 * BF14 - 0.984 * BF16 + 0.437 * BF18 - 0.118 * BF20;

BF1 = max(0, TEMP2M11 + 6.900);
BF4 = max(0, V8_A - 3.165);
BF6 = max(0, V8_A - 2.398);
BF8 = max(0, V8_A + 0.388);
BF11 = max(0, - 2.211 - SHUM2M);
BF12 = max(0, RHUM2M + 0.155);
BF13 = max(0, - 0.155 - RHUM2M);
BF14 = max(0, SHUM2M + 0.806);
BF16 = max(0, RHUM2M + 4.419);
BF18 = max(0, TEMP2M11 - 3.427);
BF20 = max(0, UWIND + 8.693);

Model Suhu minimum

Y = -0.212 + 0.015 * BF7 + 0.291 * BF18 + 0.355 * BF30
- 2.572 * BF40 + 0.284 * BF46 - 0.099 * BF48
- 0.440 * BF50;
dimana

BF3 = max(0, RHUM2M + 5.737);
BF4 = max(0, HUJAN_TO + 3.313) * BF3;
BF7 = max(0, 0.274 - SHUM2M) * BF4;
BF18 = max(0, HUJAN_TO - 0.582) * BF3;
BF30 = max(0, UWIND - 1.921);
BF39 = max(0, 4.929 - RHUM2M);
BF40 = max(0, HUJAN_TO - 1.140) * BF39;
BF42 = max(0, UWIND + 2.457);
BF45 = max(0, 1.097 - HUJAN_TO) * BF42;

BF46 = max(0, SHUM2M + 1.644) * BF45;
BF48 = max(0, RHUM2M + 1.086) * BF45;
BF50 = max(0, SHUM2M + 0.897);

<u>Model Kelembapan rata-rata</u>

Y = 1.628 - 1.631 * BF2 - 0.229 * BF6 - 0.194 * BF7 + 0.214 * BF8 + 0.364 * BF14 + 0.160 * BF16 + 0.079 * BF17
- 0.123 * BF18 - 0.048 * BF21 - 0.215 * BF22
- 0.035 * BF24 + 1.378 * BF26 + 0.074 * BF28
- 0.292 * BF32 + 0.113 * BF38 + 0.043 * BF49
- 0.008 * BF54 - 0.226 * BF59;

dimana

BF1 = max(0, RHUM2M + 5.737);
BF2 = max(0, HUJAN_TO + 0.049) * BF1;
BF3 = max(0, - 0.049 - HUJAN_TO) * BF1;
BF6 = max(0, UWIND + 2.457);
BF7 = max(0, - 2.457 - UWIND);
BF8 = max(0, HUJAN_TO + 2.306) * BF1;
BF12 = max(0, HUJAN_TO - 0.452) * BF1;
BF13 = max(0, 0.452 - HUJAN_TO) * BF1;
BF14 = max(0, UWIND - 0.623) * BF13;
BF16 = max(0, UWIND + 0.764) * BF12;
BF17 = max(0, - 0.764 - UWIND) * BF12;
BF18 = max(0, MID_CLOU + 0.234) * BF8;
BF21 = max(0, - 0.222 - UWIND) * BF8;
BF22 = max(0, UWIND + 0.222) * BF3;
BF24 = max(0, UWIND + 5.822) * BF8;
BF26 = max(0, HUJAN_TO + 0.234) * BF1;
BF27 = max(0, - 0.234 - HUJAN_TO) * BF1;
BF28 = max(0, MID_CLOU + 1.300) * BF27;
BF32 = max(0, MID_CLOU + 1.465);
BF38 = max(0, MID_CLOU + 0.671) * BF8;
BF45 = max(0, - 1.416 - UWIND);
BF49 = max(0, - 0.890 - WIND_GUS) * BF45;
BF50 = max(0, RHUM2M + 4.148);

BF52 = max(0, HUJAN_TO + 1.192) * BF50;
BF54 = max(0, WIND_GUS + 10.817) * BF52;
BF59 = max(0, RHUM2M + 1.086);

Lampiran 21 Nilai Prediksi Tmaks, Tmin, dan RH di Stasiun Soekarno Hatta

N	Tmaks			Tmin			RH		
	Y(obs)	$\hat{Y}_{Tmaks}$	$\hat{Y}_{NWP}$	Y(obs)	$\hat{Y}_{T\min}$	$\hat{Y}_{NWP}$	Y(obs)	$\hat{Y}_{RH}$	$\hat{Y}_{NWP}$
346	31,80	31,65	40,51	23,70	24,05	24,84	81,48	78,96	77,32
347	32,90	31,79	42,96	24,10	23,92	25,48	76,93	79,90	72,89
348	33,00	32,32	41,53	24,70	23,93	25,44	79,96	79,90	74,26
349	31,00	31,49	42,50	24,80	24,20	24,71	82,61	78,26	72,18
350	32,80	31,59	46,30	23,40	23,96	24,49	80,57	79,25	70,11
351	33,20	31,91	43,69	24,50	23,93	25,49	78,24	80,07	70,38
352	34,60	31,41	41,89	26,20	23,97	24,31	72,71	78,67	68,26

Lampiran 22 Nilai Prediksi Tmaks, Tmin, dan RH di Stasiun Juanda

N	**Tmaks**			**Tmin**			**RH**		
	Y(obs)	$\hat{Y}_{Tmaks}$	$\hat{Y}_{NWP}$	Y(obs)	$\hat{Y}_{T\min}$	$\hat{Y}_{NWP}$	Y(obs)	$\hat{Y}_{RH}$	$\hat{Y}_{NWP}$
346	33,20	31,80	43,50	24,70	25,14	25,24	77,62	85,79	60,74
347	34,00	32,10	42,86	26,00	25,32	25,29	74,03	86,22	63,12
348	33,80	31,86	44,40	26,00	25,30	25,32	76,86	84,24	61,58
349	33,40	31,75	44,29	26,80	25,15	24,75	78,03	86,03	62,11
350	31,80	31,83	44,42	25,60	25,16	24,50	81,80	84,55	68,14
351	32,00	32,03	44,89	26,40	25,37	24,37	84,91	82,33	70,07
352	31,40	31,64	41,98	25,80	25,18	23,73	76,99	84,37	72,91

Lampiran 23 Legalitas Data

SURAT PERNYATAAN

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

Nama : Binti Fatmawati
NRP : 1315 105 049

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

Sumber : Data Penelitian Dr. Sutikno, S.Si, M. Si. Dengan judul "Pengembangan Model Prakiraan Cuaca Melalui Model Output Statistik dengan Pendekatan Linear dan Non-Linier dalam Antisipasi Bencana Hidrometeorologi"

Keterangan : 1. Data Suhu Maksimum, Suhu Minimum, dan Kelembapan Rata-rata harian pada Stasiun Meteorologi Juanda, Ngurai Rai dan Soekarno-Hatta 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	Surabaya, 14 Juni 2017
Pembimbing Tugas Akhir	
(Dr. Sutikno, S.Si, M.Si.)	Binti Fatmawati
NIP. 19710313 199702 1 001	NRP 1315 105 049

*(coret yang tidak perlu)

(Halaman ini sengaja dikosongkan)

BIODATA PENULIS

Penulis dengan nama lengkap Binti Fatmawati dan akrab dipanggil Fatma terlahir dari pasangan Moh. Ghafur dan Umi Nurhayati tepatnya pada tanggal 4 Januari 1993 dan merupakan anak pertama dari 4 bersaudara. Penulis yang lahir dan besar di Kepung, Kediri ini telah menempuh pendidikan formal di MI Miftahul Huda Jatisari Kediri (1999-2005), MTs Negeri Pare 1 (2005-2008), dan SMA Negeri 7 Kediri (2008-2011). Selepas itu, penulis memutuskan untuk melanjutkan pendidikan ke Perguruan Tinggi Institut Teknologi Sepuluh Nopember Surabaya jurusan Statistika melalui jalur diploma III reguler (2012-2015) dan melanjutkan studi ke Lintas Jalur S1 Departemen Statistika ITS.

Semasa perkuliahan, penulis aktif di kegiatan organisasi antara lain Forum Studi Islam Statistika (Forsis) staf Syiar yang kemudian menjadi sekretaris departemen Humas, KOPMA Dr Angka ITS sebagai staff PSDA, JMMI sebagai staf HUMED (Humas dan Media) dan penulis juga aktif dalam kegiatan organisasi ekstra kampus KAMMI. Penulis juga mendapatkan beasiswa bidik misi selama menempuh pendidikan Diploma dan beasiswa Yayasan Asahimas selama satu tahun. Selain itu, penulis mempunyai prinsip yang selalu dipegang teguh adalah "Everything's possible!", tidak ada kata tidak mungkin jika kita mau berusaha.Kritik dan saran terhdap penulis dapat melalui email pribadi penulis fatma.nahl@gmail.com.

(Halaman ini sengaja dikosongkan)